

T.C.
AKDENİZ ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ
BİYOİSTATİSTİK VE TIBBİ BİLİŞİM ANABİLİM DALI

**İSTANBUL’DA TEDAVİ GÖRMÜŞ DİYABET HASTALARINA AİT
SAĞLIK KAYITLARININ BÜYÜK VERİ TEKNİKLERİ İLE
İNCELENMESİ**

Mustafa Mahir ÜLGÜ

DOKTORA TEZİ

“Kaynakça gösterilerek tezimden yararlanılabilir”

2022-ANTALYA

T.C.
AKDENİZ ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ
BİYOİSTATİSTİK VE TIBBİ BİLİŞİM ANABİLİM DALI

İSTANBUL’DA TEDAVİ GÖRMÜŞ DİYABET HASTALARINA AİT
SAĞLIK KAYITLARININ BÜYÜK VERİ TEKNİKLERİ İLE
İNCELENMESİ

Mustafa Mahir ÜLGÜ

DOKTORA TEZİ

DANIŞMAN

Doç. Dr. Kemal Hakan GÜLKESEN

“Kaynakça gösterilerek tezimden yararlanılabilir”

2022-ANTALYA

Sağlık Bilimleri Enstitüsü Müdürlüğüne;

Bu çalışma jürimiz tarafından Anabilim Dalı
.....Programında tezi olarak kabul
edilmiştir. .../...../.....

İmza

Tez Danışmanı : Doç. Dr. Kemal Hakan GÜLKESEN
Akdeniz Üniversitesi

.....

Üye :
(Ünvanı, Adı Soyadı)
(Üniversite)

.....

Üye :
(Ünvanı, Adı Soyadı)
(Üniversite)

.....

Üye :
(Ünvanı, Adı Soyadı)
(Üniversite)

.....

Üye :
(Ünvanı, Adı Soyadı)
(Üniversite)

.....

Bu tez, Enstitü Yönetim Kurulunca belirlenen yukarıdaki jüri üyeleri tarafından uygun
görölmüş ve Enstitü Yönetim Kurulu'nun/...../..... tarih ve/.....
sayılı kararıyla kabul edilmiştir.

Enstitü Müdürü

ETİK BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün safhalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı beyan ederim.

Öğrenci

Mustafa Mahir ÜLGÜ

İmza

Tez Danışmanı

Doç. Dr. Kemal Hakan GÜLKESEN

İmza

TEŞEKKÜR

Öğrenim hayatımın en önemli basamağı olan Akdeniz Üniversitesi Sağlık Bilimleri Enstitüsü Tıp Bilişimi Doktora Programında tüm bilgi birikimini en yalın dil ile bana ve öğrenci arkadaşlarıma aktaran aynı zamanda tez danışmanım olan Doç. Dr. Kemal Hakan GÜLKESEN'e, bizlere bu alanda yetkinlik kazandırmak için samimiyetle gayret gösteren hocalarım Doç. Dr. Neşe ZAYİM, Prof. Dr. Ahmet YARDIMCI, Doç. Dr. Uğur BİLGE'ye; Araştırma konusunun belirlenmesi ve tez izleme dönemindeki yönlendirme ve katkılarından dolayı Prof. Dr. Mustafa Kemal BALCI ve Prof. Dr. Sadi ÖZDEM hocalarıma; Makine Öğrenmesi sürecinde bilgi ve deneyimleri ile çalışmamı destekleyen, yol gösteren Prof. Dr. Ebru AKÇAPINAR SEZER ve Dr. Begüm MUTLU'ya; Laboratuvar tetkik verilerinin düzenlenmesi sırasındaki tecrübesinden yararlandığımız Özen AKYÜREK'e; Sorguların yazılması ve sayısal tabloların oluşturulması sürecinde uzun saatlerini harcayarak bu tezin ortaya çıkmasını sağlayan Sağlık Bilgi Sistemleri Genel Müdürlüğü Danışmanları Mustafa Okan AYVALI ve Abdullah AKÜNAL'a; Çalışmamı onaylayan ve katkılarını esirgemeyen Bakan Yardımcımız Dr. Şuayip BİRİNCİ'ye; Bana insanlığa hizmet etme bilincini kazandıran rahmetli Annem Zübeyde AKTÜRK ÜLGÜ, Ablam Dr. Nimet ÜLGÜ ERSİN'e, bugünlere gelmeme katkıda bulunan Kadri DUYUR ağabeyim ve Öğretmen İbrahim ÇAKAR ağabeyim ile ailelerine, eğitim öğretim hayatımın ilk adımında beni karşılayan rahmetli İlkokul öğretmenim Emin ERKAN ve tüm öğretmenlerime şükranlarımı sunarım. Son olarak; doktora sürecinde idari soru ve sorunlarıma sabırla ve hızlı bir şekilde çözüm sunan Sağlık Bilimleri Enstitüsü çalışanlarına ayrı ayrı teşekkür ederim.

ÖZET

Amaç: Çalışmamızda, Türkiye’de ve spesifik olarak İstanbul’da diyabetin prevalansını, Türkiye genelinde diyabetlilerdeki belli başlı komorbiditeleri araştırmayı ayrıca, İstanbul’da tedavi görenlerde makine öğrenmesi yöntemleri ile kan şekeri kontrolünü tahmin eden model geliştirmeyi amaçladık.

Yöntem: T.C. Sağlık Bakanlığı’nın kişisel sağlık kaydı sistemi e-Nabız’dır. Sistemdeki veriler de-identifiye edilmiş olarak Hadoop temelli büyük veri ortamı Cloudera (CDH, v. 6.3.2)’ya aktarılmaktadır. Sorgulamalar Cloudera’da Apache Impala (v. 3.2.0) ile yapılmıştır. İstanbul’da 2017 yılında diyabet tanısı konan vakaların 2020 yılına kadar olan verilerini inceledik. Yılda en az bir HbA1c değeri olanlardan son iki HbA1c değeri 7’nin altındakileri kontrol altında kan şekeri, diğerlerini kontrol altına alınamayan kan şekeri olarak grupladık. Grubu tahmin edebilecek modeller tasarlamak için İkili Lojistik Regresyon (LR), Çok Katmanlı Tam Bağlantılı Sinir Ağı (MLP), Rastgele Orman (RO) ve eXtreme Gradient Boost (XGBoost, XGB) kullandık. MLP ve RO, scikit-learn python kitaplığına dayanıyordu. XGBoost’un scikit-learn uyumlu API’si kullanıldı. LR, Jamovi v2.2.5 yazılımı ile yapıldı. Makine öğrenimi algoritmalarının performansını değerlendirmek için eğri altında kalan alan (%95 Güven Aralığı), duyarlılık, seçicilik, kesinlik, F1 puanı ve doğruluk kullanıldı.

Bulgular: Türkiye genelinde 2020 yılı sonunda kadınlarda %13,10; erkeklerde %9,12 olmak üzere diyabetli oranı %11,12 (7.178.674 kişi), İstanbul’da %9,77’dir. 2019’da kişi başına yaşa göre ağırlıklı hekim başvurusu diyabetliler için 15,5; Diyabetli olmayanlar için 9,5; Diyabetliler için reçete sayısı 7,9; Olmayanlar için 4,5’tir. Antidiyabetik içeren ortalama reçete sayısı 2,88’dir. Yeterli verisi olan 77.724 diyabet kaydından 28.791 (%37)’sinde kan şekeri kontrol altındadır. Modellerden XGB 0,895 ROC AUC ve 0,890-0,899 güven aralığı ile en başarılı yöntem olarak tesbit edildi. LR, MLP, RO yöntemleri sırası ile 0,889 (0,883-0,894); 0,887 (0,884- 0,892); 0,878 (0,873-0,883) sonuçlarını verdi.

Sonuç: Ulusal elektronik sağlık kayıtlarının diyabet ve pek çok sağlık probleminde önemli bilgiler sağlayabileceği görülmüştür. Kan şekeri kontrolünü tahmininde en başarılı yöntemin XGB olduğu, diğer yöntemlerin de tatmin edici sonuçlar verdiği görülmektedir.

Anahtar Kelimeler: diyabetes mellitus, büyük veri, makine öğrenmesi, epidemiyoloji

ABSTRACT

Objective: In our study, we aimed to investigate the prevalence of diabetes in Turkey and specifically in Istanbul, the main comorbidities in patients with diabetes throughout Turkey, and also to develop a model that predicts blood sugar control in those receiving treatment in Istanbul using machine learning methods.

Method: The PHR system of the Ministry of Health of Turkey is e-Nabız. The data in the system is transferred to the Hadoop-based big data environment Cloudera (CDH, v.6.3.2) as de-identified. Queries were made on Cloudera with Apache Impala (v.3.2.0). We analyzed the data of cases diagnosed with diabetes in Istanbul in 2017 until 2020. Among those with at least one HbA1c value per year, the last two HbA1c values below 7 were grouped as controlled blood sugar and the others as uncontrolled blood sugar. We used Binary Logistic Regression(LR), Multilayer Fully Connected Neural Network(MLP), Random Forest(RF), and eXtreme Gradient Boost(XGB) to design models that can predict the group. Area under the curve (95% CI), sensitivity, selectivity, precision, F1 score, and accuracy were used to evaluate the performance of machine learning algorithms.

Results: At the end of 2020 in Turkey, the prevalence of diabetic patients was 11.12% and 9.77% in Istanbul. In 2019, the number of age-weighted physician admissions per capita was 15.5 for diabetics, 9.5 for non-diabetics, and the number of prescriptions per capita was 7.9 for diabetics, and 4.5 for non-diabetics. Of the 77,724 diabetes records with sufficient data, 28,791 (37%) had blood sugar under control. Among the models, XGB was determined as the most successful method with 0.895 ROC AUC and 0.890-0.899 CI. LR, MLP, RF methods gave the results 0.889 (0.883-0.894); 0.887 (0.884- 0.892); 0.878 (0.873-0.883), respectively.

Conclusion: It was seen that national electronic health records can provide important information on diabetes and many health problems. It is seen that the most successful method in estimating blood sugar control is XGB, and other methods also give satisfactory results.

Keywords: diabetes mellitus, big data, machine learning, epidemiology.

İÇİNDEKİLER

ÖZET	i
ABSTRACT.....	ii
TABLolar DİZİNİ	x
ŞEKİLLER DİZİNİ.....	xiii
SİMGELER VE KISALTMALAR	xiv
1. GİRİŞ	1
2. GENEL BİLGİLER.....	3
2.1. Diabetes Mellitus	3
2.2. Diyabet ve Bazı Komorbid Hastalıklar	9
2.2.1. Kronik Hastalıklar	9
2.2.2. Kanserler	10
2.3. Türkiye’de Dijital Sağlık Altyapısı.....	14
2.4. Büyük Veri.....	17
2.5. Veri Madenciliği	19
2.6. Makine Öğrenmesi ve Yapay Zekâ.....	20
2.7. Tez Çalışmasında Kullanılan Makine Öğrenmesi Modelleri.....	27
2.7.1. Yapay Sinir Ağı: Çok Katmanlı Algılayıcı	27
2.7.2. Rastgele Orman (RO).....	28
2.7.3. Aşırı Gradyan Artırma	28
2.8. Diyabet ve Büyük Veri	28
2.8.1. Diyabette Makine Öğrenmesi ile Risk Tahmin Çalışmaları.....	34
2.8.2. Diyabette Tanı Tahmini İçin Makine Öğrenmesi Modelleri.....	36
2.8.3. Diyabet Yönetiminde Makine Öğrenmesi Çalışmaları	39
2.8.4. Diyabet Farmakoterapisinde Makine Öğrenmesi.....	44
2.8.5. Diyabette Klinik Karar Destek Sistemi Çalışmaları.....	49

2.8.6. Kan Şekeri Düzeyi Tahmini İçin Makine Öğrenmesi Çalışmaları.....	59
2.9. Çalışmanın Amacı.....	63
3. GEREÇ VE YÖNTEM.....	65
3.1. Evren.....	65
3.2. Veri Anonimizasyonu ve Tekilleştirilmesi	65
3.3. Büyük Veri Platformu.....	67
3.4. Kısıtlılıklar, Seçimler ve Veri Temizliği	67
3.4.1. Ölümler	68
3.4.2. Boy, Kilo, Beslenme ve Egzersiz.....	68
3.4.3. Yaş.....	68
3.4.4. İkamet İli	68
3.4.5. Diyabetes Mellitus Tanı ve Kodları	68
3.4.6. Reçete.....	69
3.4.7. Laboratuvar Tetkikleri.....	70
3.4.8. Rapor	71
3.4.9. Bilinmeyen Diyabetes Mellitus Vakaları	71
3.5. Sorgulama Kriterleri, Veri İçerik ve Özellikleri	72
3.5.1. Diyabetes Mellitus Tanıları.....	73
3.5.2. Diyabet Tipi Belirleme Kriterleri.....	74
3.5.3. Eşlik Eden Diğer Hastalık Tanı Sorgulamaları	74
3.5.4. Kanseri Tanıları.....	77
3.5.4.1. Hodgkin ve Non-Hodgkin Lenfomalar	77
3.5.4.2 Solid Organ Malign Tümörleri	79
3.5.4.3. Diğer Malign Tümörler.....	80
3.5.4.4. Benign, Davranışı Bilinmeyen ve İn Situ Tümörler	80
3.6. Tabloların Oluşturulması	81

3.6.1. Nüfus Tablosu	81
3.6.2. Diyabetes Mellitus Vakaları Geçici Tablosu.....	81
3.6.3. Bilinmeyen Diyabetes Mellitus Vakaları Geçici Tablosu	81
3.6.4. Diyabetes Mellitus Popülasyon Ana Tablosu	81
3.6.5. Reçete Tablosu	82
3.6.6. Ölüm Kaydı Tablosu	82
3.6.7. Rapor Tablosu	82
3.6.8. Laboratuvar İşlemleri Tablosu	83
3.6.9. İstanbul İli Hastaneleri Laboratuvar Tetkik Sonuçları Tablosu	83
3.6.10. Diyabetes Mellitus Merkez Tablosu.....	83
3.6.11. Diyabetli Olmayanlar Grubu Popülasyon Tablosu	83
3.6.12. Diyabetli Olmayanlar Grubu Reçete Tablosu	84
3.6.13. Diyabetli Olmayanlar Grubu Tanı Tablosu.....	84
3.6.14. Diyabetli Olmayanlar Grubu Merkez Tablosu.....	84
3.7. Makine Öğrenmesi Veri Seti	84
3.7.1. İstanbul 2017 Yılı Yaş Grupları ve Cinsiyete Göre Nüfus Dağılımı	85
3.7.2. Makine Öğrenmesi Veri Seti Genel Özellikleri	85
3.7.3. Makine Öğrenmesi Veri Seti Laboratuvar Tetkikleri.....	85
3.7.3.1. Açlık Kan Şekeri (AKŞ) Ölçümleri	86
3.7.3.2. Hemogloblin A1c (HbA1c) Ölçümleri.....	86
3.7.3.3. Hemogloblin A1c Değişim Oranı	87
3.7.3.4. Diğer Laboratuvar Tetkikleri	87
3.7.4. Makine Öğrenmesi Veri Seti Eşlik Eden Diğer Hastalık Tanıları	88
3.7.5. Makine Öğrenmesi Veri Seti Reçete Kayıtları.....	90
3.7.6. Makine Öğrenmesi Veri Seti Antidiyabetik İlaçlar.....	93
3.7.7. Makine Öğrenmesi Veri Seti Oluştururken Yapılan Veri Temizliği.....	95

3.8. Makine Öğrenmesi Ön İncelemeleri	95
3.9. Makine Öğrenmesi Çalışmaları	98
3.9.1. Yapay Sinir Ağı: Çok Katmanlı Algılayıcı	99
3.9.2. Rastgele Orman (RO).....	99
3.9.3. Aşırı Gradyan Artırma	99
3.9.4. Trend Analizi Çalışmaları	100
3.9.5. Kontrol Grubu Tahmini ve Trend Analizi Seri Modeli.....	101
3.10. İstatistik Metodolojileri ile Yapılan Analizler	101
4. BULGULAR.....	103
4.1. Türkiye Geneline Ait Bulgular	103
4.1.1. e-Nabız Sistemi	103
4.1.2. Diyabet Sıklığı	103
4.1.3. Başvuru ve Reçeteler.....	114
4.2. İstanbul'a Ait Bulgular	118
4.2.1. İstanbul Diyabet Sıklığı.....	118
4.2.2. İstanbul İli Başvurular ve Reçeteler	125
4.3. Diyabetli Olanlar ile Diyabetli Olmayanların Komorbidite Karşılaştırması	129
4.4. Makine Öğrenmesi İçin Hazırlanan Veri Seti ile Yapılan Analizler	132
4.4.1. Makine Öğrenmesi Veri Seti Değişkenleri	132
4.4.2. Tek Değişkenli Analiz.....	134
4.4.3. Lojistik Regresyon	141
4.4.4. Makine Öğrenmesi ile Gerçekleştirilmiş Olan Görevler.....	147
4.4.5. Deneyi Yapılan Makine Öğrenmesi Yöntemleri.....	150
4.4.6. Kontrol Grubu Tahminleme Üzerine Yapılan Çalışmalar.....	150
4.4.6.1. Kontrol Grubu Tahminlemede Parametre Etkisinin İncelenmesi	150
4.4.6.2. Kontrol Grubu Tahminleme.....	150

4.4.7. Trend Analizi Üzerine Yapılan Çalışmalar	153
4.4.8. Kontrol Grubu Tahmini ve Trend Analizi Seri Modeli.....	155
5. TARTIŞMA.....	159
5.1. Anahtar Bulgular.....	159
5.2. Türkiye Diyabet Epidemiyolojisi.....	160
5.3. İstanbul Diyabet Epidemiyolojisi	164
5.4. Komorbidite İncelemeleri	166
5.5. Makine Öğrenmesi Çalışmaları	169
5.6. Kısıtlılıklar	175
6. SONUÇ VE ÖNERİLER.....	181
KAYNAKLAR	185
EKLER	216

Tablo Ek.1. 2019 yılındaki akut miyokard infarktüsü vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.2. 2019 yılındaki akut ve kronik iskemik kalp hastalığı vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.3. 2019 yılındaki kalp yetmezliği vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.4. 2019 yılındaki hipertansiyon vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.5. 2019 yılındaki nefropatiler ve kronik böbrek yetmezliği vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.6. 2019 yılındaki serebrovasküler hastalık vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.7. 2019 yılındaki retinopati vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.8. 2019 yılındaki katarakt vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.9. 2019 yılındaki lipid metabolizma bozukluğu vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.11. 2019 yılındaki nöropati vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.12. 2019 yılındaki baş boyun kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.13. 2019 yılındaki tiroid kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.14. 2019 yılındaki larenks kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.15. 2019 yılındaki akciğer kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.16. 2019 yılındaki mide kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.17. 2019 yılındaki kolon, rektosigmoid ve rektum kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre dağılımı

Tablo Ek.18. 2019 yılındaki karaciğer ve intrahepatik safra yolları kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.19. 2019 yılındaki pankreas kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.20. 2019 yılındaki böbrek kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.21. 2019 yılındaki mesane kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.22. 2019 yılındaki melanom vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.23. 2019 yılındaki hodgkin lenfoma vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına insidans ve odss oranları göre dağılımı

Tablo Ek.24. 2019 yılındaki non hodgkin lenfoma vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.25. 2019 yılındaki meme kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.26. 2019 yılındaki uterus kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.27. 2019 yılındaki over kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.28. 2019 yılındaki prostat kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.29. 2019 yılındaki diğer malignite vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.30. 2019 yılındaki toplam malignite vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tablo Ek.31. 2019 yılındaki benign, insitu ve davranışı bilinmeyen neoplazm vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

ÖZGEÇMİŞ.....248

TABLÖLAR DİZİNİ

Tablo 2.1. Diyabetle ilgili bazı büyük veri çalışmaları	32
Tablo 3.1. Çalışmada kullanılan Diyabetes Mellitus ICD-10 kodları	74
Tablo 3.2. Çalışmada kullanılan diğer hastalık ve eşlik eden hastalıklara ait ICD-10 kodları	75
Tablo 3.3. Çalışmada kullanılan Lenfoma tanılarına ait ICD- O3 kodları	77
Tablo 3.4. Çalışmada kullanılan solid organ malign tümörleri tanılarına ait ICD- O3 kodları	79
Tablo 3.5. Çalışmada kullanılan benign tümör türleri ICD- O3 sorgulama kriterleri	80
Tablo 3.6. 2017 yılı İstanbul yaş grupları ve cinsiyete göre nüfus dağılımı	85
Tablo 3.7. Çalışmada kullanılan ilaçların ATC grup kodları	90
Tablo 3.8. Çalışmada kullanılan tüm antidiyabetik ilaçların ATC kodları	94
Tablo 4.1. Yıllara göre e-Nabız'ın her bir yıl için kapsayıcılık oranı (15 yaş ve üzeri)	103
Tablo 4.2. Yıllara göre e-Nabız sisteminde kaydı bulunanlara göre diyabetli sayısı ve prevalans (%)	104
Tablo 4.3. Türkiye geneli 15 yaş ve üzeri nüfusun yaş grupları ve cinsiyete göre dağılımı	105
Tablo 4.4. 2016 yılı yaş grupları, DM tipi ve cinsiyete göre diyabetli kayıt sayısı ve prevalansı (%)	106
Tablo 4.5. 2017 yılı yaş grupları, DM tipi ve cinsiyete göre diyabetli kayıt sayısı ve prevalansı (%)	107
Tablo 4.6. 2018 yılı yaş grupları, DM tipi ve cinsiyete göre diyabetli kayıt sayısı ve prevalansı (%)	108
Tablo 4.7. 2019 yılı yaş grupları, DM tipi ve cinsiyete göre diyabetli kayıt sayısı ve prevalansı (%)	109
Tablo 4.8. 2020 yılı yaş grupları, DM tipi ve cinsiyete göre diyabetli kayıt sayısı ve prevalansı (%)	110
Tablo 4.9. İl bazında yaş gruplarına göre diyabet prevalansı ve yaş ağırlıklı (age adjusted) prevalans	111

Tablo 4.10. 2019 ve 2020 yılı Türkiye geneli 15 yaş ve üzeri diyabetli vaka başvurularının klinik branşlara göre dağılımı.....	114
Tablo 4.11. 2019 ve 2020 yıllarında diyabetik vakaların başvurularının kurum türlerine göre dağılımı.....	116
Tablo 4.12. 2016-2020 yıllarında diyabetik vakaların muayene ve reçete bilgileri	117
Tablo 4.13. Yıllara göre diyabetik olmayan kişilere ait başvuru ve reçete dağılımı.....	118
Tablo 4.14. 2019 ve 2020 yıllarında kayıt sistemine giren diyabet vakaları ve yıllık prevalans (%).....	118
Tablo 4.15. İstanbul 2019 yılı yaş grupları, DM tipi ve cinsiyete göre diyabetli kayıt sayısı ve prevalansı (%).....	120
Tablo 4.16. İstanbul 2020 yılı yaş grupları, DM tipi ve cinsiyete göre diyabetli kayıt sayısı ve prevalansı (%).....	121
Tablo 4.17. 2019 yılında İstanbul’da ilçeler, yaş grupları, DM tipi ve cinsiyete göre diyabetli kayıt sayısı ve prevalansı (%).....	122
Tablo 4.18. 2020 yılında İstanbul’da ilçeler, yaş grupları, DM tipi ve cinsiyete göre diyabetli kayıt sayısı ve prevalansı (%).....	124
Tablo 4.19. 2019 ve 2020 yılında İstanbul’daki 15 yaş ve üzeri diyabetli vaka başvurularının klinik branşlara göre dağılımı.....	125
Tablo 4.20. 2019 ve 2020 yılında İstanbul’daki diyabetli vaka başvurularının kurum türlerine göre dağılımı	127
Tablo 4.21. 2019 ve 2020 yılında İstanbul’daki diyabetli vakaların muayene ve reçete bilgileri	128
Tablo 4.22. Diyabetik ve diyabetik olmayan popülasyonda bazı komorbid hastalıkların insidansı	130
Tablo 4.23. Tek değişkenli analiz çalışması sonucu özet tablosu	134
Tablo 4.24. Çok değişkenli analiz çalışması sonucu özet tablosu.....	142
Tablo 4.25. Tek değişkenli ve çok değişkenli analizler özet tablosu	145
Tablo 4.26. Veri kümesi nitelikleri	148
Tablo 4.27. Dört sınıflı kontrol grubu sınıflandırıcı performans değerleri	151
Tablo 4.28. İki sınıflı kontrol grubu sınıflandırıcı performans değerleri	152

Tablo 4.29. Dört sınıflı ve iki sınıflı kontrol grubu sınıflandırıcılar için makro-ortalama performans değerleri.....	152
Tablo 4.30. Trend analizi performans ölçüm sonuçları.....	154
Tablo 4.31. Trend analizi makro-ortalama performans ölçüm sonuçları	154
Tablo 4.32. Kontrol grubu ve trend analizi seri modelinin her bir alt modülünün test için ayrılan veri kümelerindeki performansının karmaşıklık matrisi gösterimi ...	156
Tablo 4.33. Kontrol grubu ve trend analizi seri modelinin her bir alt modülünün test için ayrılan veri kümelerindeki performansı	156
Tablo 4.34. Kontrol grubu ve trend analizi seri modelinin test için ayrılan veri kümelerindeki performansı.....	157
Tablo 4.35. Kontrolsüz kan şekeri olan DM hastalarının tahminine yönelik modellerin performans metrikleri	158

ŞEKİLLER DİZİNİ

Şekil 2.1. e-Nabız sisteminin basitleştirilmiş mimarisi	16
Şekil 3.1. Veri anonimizasyonu ve tekilleştirme prosedürü	66
Şekil 3.2. Gruplama iş akış şeması	97
Şekil 4.1. İllere göre yaş ağırlıklı (age adjusted) diyabet prevalansı	111
Şekil 4.2. İstanbul’da, DM vakalarının ilçelere göre dağılımı yoğunluk skalası haritası	119
Şekil 4.3. Kayan nokta tipi sürekli değer alan bağımsız değişkenlerin dağılım grafikleri	149
Şekil 4.4. Tamsayı tipi sürekli değer alan bağımsız değişkenlerin dağılım grafikleri...	149
Şekil 4.5. Kontrol grubu tahmini ve trend analizi seri bağlı makine öğrenmesi modeli	155

SİMGELER ve KISALTMALAR

ACC	: Accuracy (Kesinlik)
ADA	: American Diabetes Association (Amerikan Diyabet Derneği)
ADT	: Alternative Desicion Tree (Alternatif Karar Ağacı)
AHC	: Agglomerative Hierarchical Clustering
AI	: Artificial Intelligence (Yapay Zeka)
AIDA	: An Interactive Educational Diabetes Simulator
ALT	: Alanin Aminotransferaz
ANN	: Artificial Neural Network (Yapay Sinir Ağı)
ARM	: Auto Regression Model
ATC	: Anatomic Therapeutic Chemical Classification
AUC	: Area Under the ROC Curve
BN	: Bayes Network
CART	: Classification and Regression Trees
CBR	: Case-Based Reasoning (Vaka Tabanlı Akıl Yürütme)
CGM	: Continuous Glucose Monitoring (Sürekli Glukoz İzleme)
CHAID	: Chi-Square Automatic Interaction Detector
CNN	: Convolutional Neural Networks
CRP	: c-Reaktif Protein
CSII	: Continuous Subcutaneous Insulin Infusion
DBN	: Deep Belief Networks
DIAS	: The Diabetes Advisory System (Diyabet Danışma Sistemi)
DKBN	: Diyabet Kaydı Bulunmayan Nüfus
DL	: Deep Learning (Derin Öğrenme)
DM	: Diabetes Mellitus
DN	: Diyabetik Nüfus
DNN	: Deep Neural Networks
DPP-4	: Dipeptidyl Peptidase-4
DR	: Diyabetik Retinopati
DS	: Dempster-Shafer

DT	: Desicion Tree (Karar Ağacı)
DVM	: Destek Vektör Makinesi
EA	: Evolutionary Algorithm (Evrimsel Algoritma)
EASD	: European Association for the Study of Diabetes
EEG	: Elektroensefalografi
eGFR	: Estimated Glomerular Filtration Rate
EKG	: Elektrokardiyografi
ELM	: Extreme Learning Machines
EMG	: Elektromiyografi
e-Nabız	: T.C. Sağlık Bakanlığı Kişisel Sağlık Kaydı Sistemi
ESK	: Elektronik Sağlık Kaydı
ESRD	: End Stage Renal Disease (Son Dönem Böbrek Hastalığı)
FAHP	: Fuzzy Analytic Hierarchy Process
FDA	: U.S. Food and Drug Administration
FHIR	: The Fast Healthcare Interoperability Resource
FRBS	: Fuzzy Rules Based System
GBT	: Gradient Boosting Tree
GDM	: Gestasyonel Diyabetes Mellitus
GDPR	: Global Data Protection Regulation
GFA	: Gradient Forest Aanalysis
G-GT	: Gama-Glutamil Transferaz
GLP-1	: Glucagon-Like Peptide-1
Hcy	: Homosistein
HDL	: High Density Lipoprotein
HL7	: Health Level Seven
ICD-10	: International Classification of Diseases (ICD) Revision-10
ICD-O3	: International Classification of Diseases for Oncology, Third Edition
IDDM	: Insulin Dependent Diabetes Mellitus
IDF	: International Diabetes Federation
Idhash	: Kimliksizleştirilmiş Vaka Kaydı Tekil Numarası
IDS	: Intrusion Detection System

IL-6	: İnterlökin-6
IoT	: Internet of Things
ISPAD	: International Society for Pediatric and Adolescent Diabetes
IUPAC	: International Union of Pure and Applied Chemistry
JESS	: Java Expert System Shell
KA	: Karar Ağacı
KADIS	: Karlsburg Diabetes Management System
k-NN	: k-Nearest Neighbor
KÜB	: İlaç Kısa Ürün Bilgisi
LDA	: Latent Dirichlet Allocation
LDL	: Low Density Lipoprotein
LL	: Learning to Learn (Öğrenmeyi Öğrenme)
LOINC	: Logical Observation Identifiers Names and Codes
LR	: Logistic Regression
LSTM	: Long Short-Term Memory
l-SVM	: Linear-Support Vector Machine
MCHC	: Mean Corpuscular Hemoglobin Concentration
MERNİS	: Merkezi Nüfus İdare Sistemi
MHRS	: Merkezi Hekim Randevu Sistemi
MIL	: Multiple Instance Learning (Çoklu Örnek Öğrenme)
MIT	: Massachusetts Institute of Technology
ML	: Machine Learning (Makine Öğrenmesi)
MÖ	: Makine Öğrenmesi
MP	: Macro-Precision (Makro Hassasiyet)
MR	: Manyetik Rezonans
m-RMR	: Minimum Redundancy Maximum Relationship
MRODC	: Map Reduce Based Optimal Data Classifier
MSVS	: Minimum Sağlık Veri Seti
NB	: Naive Bayes
NHS	: National Health System
NIDDM	: Non Insulin Dependent Diabetes

OAD	: Oral Antiyabetik
OGTT	: Oral Glukoz Tolerans Testi
openEHR	: Open Electronic Health Record
OO	: Odss Oranı
PCA	: Principal Component Analysis (Temel Bileşen Analizi)
PM	: Precision Medicine (Hassas Tıp)
PMD	: Personalized Mobile Device
PMI	: Precision Medicine Initiative (Hassas Tıp İnisiyatifi)
RAND	: Reasonable and Non Discriminatory
RBR	: Rule-Based Reasoning (Kural Tabanlı Alık Yürütme)
REFS	: Reverse Engineering and Forward Simulation
RF	: Random Forest
RL	: Reinforcement Learning (Pekiştirmeli Öğrenme)
RNN	: Recurrent Neural Networks
RO	: Rastgele Ormanlar
ROC	: Receiver Operating Characteristic
RR	: Rölatif Risk
RSF	: Random Survival Forest
r-SVM	: Radial-Support Vector Machine
RT	: Random Tree (Rastgele Ağaç)
rt-CDSS	: Real Time Clinical Desicion Support System
RUAM	: Remote User Access Module
SGK	: Sosyal Güvenlik Kurumu
SIR	: Standardize İnsidans Oranı
SİNA	: Sağlıkta İstatistik ve Nedensel Analizler Platformu
SKRS	: Sağlık Kodlama Referans Sunucusu
SL	: Supervised Learning (Gözetimli Öğrenme)
SNOMEDCT	: Systematized Nomenclature of Medicine-Clinical Terms
SOM	: Self-Organizing Map
s-SL	: Semi-Supervised Learning (Yarı Gözetimli Öğrenme)
SUT	: Sağlık Uygulama Tebliği

SVM	: Support Vector Machine (Destek Vektör Makinesi)
SWRL	: Semantic Web Rule Language
T1DM	: Tip 1 Diyabetes Mellitus
T2DM	: Tip 2 Diyabetes Mellitus
TCSB	: Türkiye Cumhuriyeti Sağlık Bakanlığı
TDCP	: The Diabetes Care Protocol (Diyabet Bakım Protokolü)
TİTCK	: Türkiye İlaç ve Tıbbi Cihaz Kurumu
TN	: Toplam Nüfus
UACR	: Urine Albumin/Creatinin Rate (İdrar Albümin/Kreatinin Oranı)
UCLA	: University of California at Los Angeles
u-SL	: Unsupervised Learning (Gözetimsiz Öğrenme)
USVS	: Ulusal Sağlık Veri Sözlüğü
VKİ	: Vücut Kütle İndeksi
VLDL	: Very Low Density Lipoprotein
WANDA	: Weight and Activity with Blood Pressure and Other Vital Signs
YSA	: Yapay Sinir Ağı

1. GİRİŞ

Diabetes Mellitus içinde bulunduğumuz çağın, insan sağlığını tehdit eden en önemli ve en yaygın hastalıklardan biridir. Yine tüm Dünyada en önemli halk sağlığı problemlerinden biri olarak görülmektedir. Bu çalışmada, Türkiye’de Diabetes Mellitus’un genel bir çerçevesi ele alınmış ve komorbiditeleri ve bu komorbiditelerin diyabeti olmayan vakalardan farklı olup olmadığı incelenmiştir. Ayrıca, çalışma ile İstanbul ilinde 2017 yılında tanı konulan diyabet vakalarının 2020 itibarı ile kan şekeri düzeylerinin kontrol altında olup olmadığı saptanarak kan şekeri kontrolünü öngören modeller geliştirilmeye çalışılmıştır.

Çalışma için e-Nabız Kişisel Sağlık Kaydı Sisteminde bulunan verilerden büyük veri ortamına aktarılan verilerle oluşturulmuş büyük veri ortamı kullanılmıştır. E-Nabız sisteminde hastaların laboratuvar değerleri, reçeteleri, konulan tanılar, yapılan işlemler bulunmaktadır. Veriler, klasik istatistiksel teknikler yanı sıra makine öğrenmesi (MÖ) teknikleri ile incelenmiştir. Hastaların kan şekeri kontrolüne etki eden faktörleri incelemek için çeşitli yöntemlerle (kümeleme, derin öğrenme vb) oluşturulan modellerin başarısı ROC (Receiver Operating Characteristic), AUC (Area Under the ROC Curve) ve benzeri tekniklerle kıyaslanarak en iyi modeller seçilmek istenmiştir.

Ülkemizde hastaların elektronik ortamdaki sağlık verileri kullanılarak bu çapta bir çalışma hiç yapılmamıştır. Dünyada da bu çapta çalışmalar sayılıdır. Ayrıca, ülkemizdeki diyabet sıklığı ve İstanbul’daki hasta sayısına ilişkin güvenilir sayılar yoktur. Çalışmamızda optimum veri temizliği yapılmış ve bu rakamlar gerçeğe en yakın şekilde verilmeye çalışılmıştır. Bundan başka, kullanılan ilaç tedavileri, diyabet hastalarının tedavilerinin başarısı, hastalarda normal popülasyondan farklı oranda bulunan komorbiditelere bakılmıştır. Kan şekeri kontrol altına alınamayan vakalarda vakanın yaş, cinsiyet, kullandığı ilaçlar, diğer hastalıkları gibi verileri hem klasik istatistiksel yöntemlerle incelenmiş hem de Makine Öğrenmesi (MÖ) modelleri geliştirilerek incelenmiştir.

Bu çalışmada Türkiye ve spesifik olarak İstanbul ilinde tedavi görmüş diyabetli vaka sayısı ve bunların klinik durumları ile ilgili veriler elde edilmiştir. Ülkemizdeki diyabet

sıklığı, diyabet hastalarına verilen farmakolojik tedaviler, hastaların Hemoglobin A1c (HbA1c) tetkiki yaptırma sıklıkları, ilaçlarını düzenli reçete ettirip ettirmedikleri, hangi oral antidiyabetiklerin kullanıldığı, insülin tedavileri, kan şekeri kontrolünü etkileyen faktörler üzerinde kıymetli veriler elde edilmiştir. Ayrıca, bu kapsamdaki bir büyük verinin analizi konusunda Türkiye’de ve Dünya’da deneyim azdır. Bu verinin temizlenmesi, Impala ile sorgulanması sürecinde elde edilen deneyimlerle tüm Dünya’da uygulanabilir öneriler oluşturulabileceği düşünülmüştür.



2. GENEL BİLGİLER

2.1. Diabetes Mellitus

Diabetes Mellitus (DM), ana bulgusu kronik hiperglisemi olan bir grup metabolik bozukluk için kullanılan bir terimdir. En genel anlatım ile diyabet, vücuda alınan besinlerin enerjiye dönüştürülmesi sürecindeki anormal durumdur (<https://www.cdc.gov/diabetes/basics/diabetes.html>, Erişim Tarihi: 18.09.2021). Nedeni, insülin salgılanmasında bozukluk veya insülin etkisinde yetersizlik olabilir, sıklıkla da bu iki problem bir arada bulunur (Petersmann et al., 2019). Kanda yüksek seyreden glukoz düzeyi ile karakterizedir. Diyabetin komplikasyonları, vücutta neredeyse her dokuyu etkiler ve diyabet kardiyovasküler morbidite ve mortalitenin, körlüğün, böbrek yetmezliğinin, sinir sistemi hasarlarının ve amputasyonların önde gelen bir sebebidir (Schmidt, 2018). Sinir sistemi ve dolaşım sistemi bozuklukları neredeyse tüm vücutta uzun dönemde ortaya çıkacak birçok başka hasarlar oluşturur. Normal şartlarda besin alımı ile kanda yükselen glukoz, vücutta pankreas bezi tarafından üretilen insülin hormonu etkisi ile hücre içine gönderilir, depolanması için karaciğerde bazı metabolik değişimlere uğratılır ve kandaki seviyesi normal değerler arasına geriler.

Diyabet tek tip bir hastalık değildir. Çeşitli sınıflandırmalar vardır. Dünya Sağlık Örgütü tarafından Tip 1 Diyabetes Mellitus (T1DM), Tip 2 Diyabetes Mellitus (T2DM), Gestasyonel Diyabetes Mellitus (GDM), Bozulmuş Glukoz Toleransı (BGT) ve Bozulmuş Açlık Glisemisi (BAG) olarak sınıflandırılmaktadır. Diyabetin en yaygın olanı T2DM, genellikle yetişkinlerde ortaya çıkan vücudun insüline dirençli hale gelmesi veya yeterli insülin üretmemesi sonucu oluşan diyabettir. T1DM, vücutta insülin üreten pankreas bezinin az ya da hiç insülin üretememesi veya üretilen insülinin beklenen etkiyi göstermesindeki yollarda var olan hasar sebebiyle dışarıdan insülin alınmasını zorunlu kılan klinik formdur. Diyabetle yaşayan insanlar için, insülin de dahil olmak üzere uygun fiyatlı tedaviye erişim, hayatta kalmaları için kritik öneme sahiptir. Dünya Sağlık Örgütü diyabet konusuna özel olarak önem vermektedir (https://www.who.int/health-topics/diabetes#tab=tab_1, Erişim Tarihi: 18.09.2021). T1DM'li hastalar genellikle 30 yaş altı genç hastalardır. Tipik olarak çok su içme, susuzluk, ağız kuruluğu, sık idrara çıkma, yüksek seyreden kan şekeri seviyeleri ile karakterizedir (Iancu et al., 2008).

Tedavisi insülin gerektirir. T2DM, orta ve ileri yaş grubu olmak üzere daha ileri yaşlarda ortaya çıkar ve genellikle obezite, hipertansiyon, dislipidemi, arterioskleroz gibi diğer bazı kronik hastalıklarla birlikte (Robertson et al., 2011).

Anlık kan glukoz düzeyinin bilinmesi, diyabetli hastalar için kullanılacak ilaç ve dozunu belirlemek bakımından zorunludur. Anlık kan glukoz tespiti ilaç seçimi ve dozu bakımından önemli iken hastalığın uzun dönem takibinde, kanda oksijen taşıyan Hemoglobin'in kandaki yüksek glukoz ile etkileşime girmesi sonucu oluşan HemoglobinA1c (HbA1c) adı verilen biyobelirteç ölçümleri yaygın kullanılmaktadır. Bu ölçüm hem görece kolay ve erişilebilir hem de ekonomik bakımdan görece avantajlıdır.

Ancak tek başına HbA1c ölçüm sonucuyla karar vermek beraberinde bazı tıbbi hataları da tetikleyebilir. Hemoglobin molekülünü taşıyan eritrosit hücrelerinin ortalama yaşam döngü süresini kısaltan sferositoz gibi hastalıkların yanı sıra ömrü uzatan örneğin splenektomi (eskiyen ve ömrünü tamamlayan eritrositlerin yıkıldığı organ olan dalağın çıkarılması), demir eksikliğine bağlı yetersiz Hemoglobin (Hb) üretimi sebebiyle ortaya çıkan anemi gibi diğer komorbiditeler de yanlış HbA1c sonuçlarına ve dolayısıyla yanlış ilaç, yanlış doz, yanlış zaman problemlerine neden olabilmektedir (O'Keeffe et al., 2016). Bazı hemoglobinopatilerin varlığında HbA1c düzeylerini alışlageldik bir yaklaşımla yorumlamak önemli klinik problemlere neden olabilir. Anormal hemoglobin ile karakterize orak hücre özelliği olanlar gibi normal kırmızı kan hücresi döngüsüne sahip hastalar için bu durumdan etkilenmeyen bir HbA1c test tekniğinin kullanılması gerekmektedir. Hamileliğin ikinci ve üçüncü üç aylık dönemi, hemodiyaliz tedavisi gören hastalar, yakın geçmişte kan kaybı ya da transfüzyonu, eritropoietin tedavisi gibi kırmızı kan hücresi yaşam döngüsüne doğrudan yansıyan durumlarda da diyabet tanısı için sadece kan şekeri kriterlerinin kullanılması önerilmektedir (ADA, 2016).

T2DM zaman içerisinde ve çok yavaş ortaya çıkar, yavaş ilerler, yıllarca fark edilmeden kalabilir (Brill et al., 2016). Tanı genellikle komplikasyonlar ortaya çıkana kadar konmamış olur ve bu nedenle diyabet veya prediyabet için tarama ve erken tespit büyük önem taşır (Harris & Eastman, 2000). Diğer yandan yaygın olarak kullanılan tarama programlarının, nüfusun bir bölümünde etkisiz olduğu gösterilmiştir (Toscano et al., 2015) ancak bu sonuç taramanın yapılmasının anlamsız olacağı sonucunu doğurmaz.

Diyabetin tanısı için kesin bir Açlık Kan Şekeri (AKŞ) eşik değeri vardır. AKŞ düzeylerinin kritik eşiği aşmadığı, ancak diyabet komplikasyonlarının bu dönemde kendini göstermeye başlayabildiği potansiyel olarak uzun bir klinik öncesi dönem vardır (Control & Prevention, 2008). Tanı konmamış T2DM'si olan bireyler, diyabetik olmayan popülasyona göre önemli ölçüde felç, kalp damar hastalıkları gibi makro vasküler hastalık ve periferik vasküler hastalık riski altındadır (ADA, 2002). 2019 yılı itibariyle literatür, çoğunlukla dünyadaki diyabet hastalarının yarısının henüz tanı almadığını göstermektedir. (Saeedi et al., 2019). Dolayısıyla diyabetin gelişimini önlemek için riskli grupları normoglisemik durumdayken belirlemek ve onların normoglisemiden bozulmuş glukoz toleransına daha sonrasında aşikâr diyabete geçişlerini yavaşlatıcı tedbirleri almak veya tedavi etmek diyabet açısından değerli yaklaşımlardır (Lindström & Tuomilehto, 2003). T2DM'nin yaşam tarzı değişiklikleri ile etkili bir şekilde önlenebileceği de gösterilmiştir (Tuomilehto et al., 2001).

İnsulin, esas olarak T1DM'li hastaların tedavisinde kullanılan farmakolojik bir ürün iken T2DM'li hastaların da yaklaşık %15 ila %24'ü de insülin tedavisine rastlanmaktadır (S. J. Lee et al., 2015). Bu durum klinikte Tip 1, Tip 2 karmaşasını artırmaktadır. İnsülin tedavi sürecinde demografik, genetik, klinik ve psikososyal özelliklere bağlı olarak tedaviye yanıtta ciddi değişkenlikler görülmektedir (Cantrell et al., 2010).

Türkiye'de prevalans 2018 yılında bir meta-analiz ile değerlendirilmiştir. Yazarlar, Türkiye'de erişkin diyabet prevalansını araştıran sekiz çalışma bulabilmiştir. Bu çalışmalardan dördü yüksek önyargı riskine sahip olarak puanlanmıştır. Kalan dört çalışma 2003-2013 yılları arasında yapılmıştır. Diyabetli olma kriterleri, bilinen diyabet veya açlık kan şekeri ≥ 126 mg/dl olması hali olarak belirlenmiştir. Bu dört çalışmada, 15 ila 21 arasında çeşitli alt yaş sınırları vardır. Düşük önyargı risk grubunun (n=56.853) meta-analizi, tüm grupta diyabet prevalansının %13.5 (%95 GA: %11.6-15.5) olduğunu ortaya koymuştur. Cinsiyete göre prevalans ise kadınlarda %14,2 (%95 GA: %12,3-16,2) ve erkeklerde %12.6 (%95 GA: %10,5-14,9) olarak bildirilmiştir (Yılmaz et al., 2018).

Ulusal Hanehalkı Sağlığı Araştırması-Türkiye'de Bulaşıcı Olmayan Hastalık Risk Faktörlerinin Yaygınlığı çalışması, DSÖ onaylı STEPwise anket yöntemi kullanılarak 2017 yılında yapılmıştır. Anket 15 yaş ve üzeri genel nüfusta yapılmıştır. Katılımcıların

ifadelerine göre (n=6.053) kan şekeri yükselme veya diyabet görülme sıklığı %9,1; Erkekler için %7,6 ve kadınlar için %10,6 olarak bulunmuştur. Çalışma popülasyonunda yüksek kan şekeri veya diyabet sıklığı 15-29 yaş grubundaki %1,1'den 70 yaş ve üzeri grubunda %28,8'e yükselmektedir. Ankete katılanların bir kısmı (n=3.352) ayrıca biyokimyasal testler için kan vermiştir. Bu popülasyonun %17,3'ünde HbA1c veya kan şekeri yüksek bulunmuştur. Bu oran erkekler için %16,3 ve kadınlar için %18,3 olarak tespit edilmiştir. Bu kez sıklık 15-29 yaş grubunda %2,8'den 70 yaş ve üzeri grupta %43,0'e yükselmiştir. Bu çalışmaya göre, katılımcıların %8,2'sinde teşhis edilmemiş diyabetin olduğu, bunun da diyabet hastalarının %47,4'ünün teşhis edilmemiş diyabete sahip olduğu anlamına gelebileceği bildirilmiştir (S. Üner et al, 2018). IDF Diyabet Atlası, Türkiye'de teşhis edilmemiş diyabetin %41,8 olduğunu tahmin etmektedir (H. Sun et al., 2022).

2021'de diyabetli 537 milyon kişinin mevcut olduğu ve bunun da küresel yetişkin (20-79 yaş) nüfusunun %10,5'ini temsil ettiği tahmin ediliyordu. Diyabet prevalansı coğrafi konuma göre değişmekle birlikte, en yüksek MENA (Orta Doğu ve Kuzey Afrika) bölgesinde %18,1 ve en düşük Afrika'da %5,3'tür. Diyabet prevalansı gelir durumundan da etkilenmektedir. Prevalans, yüksek gelirli ülkelerde (%8,4) ve orta gelirli ülkelerde (%10,5) düşük gelirli ülkelere göre (%6,7) daha yüksektir. Erkeklerde kadınlara göre biraz daha yüksektir. Prevalansı kentsel alanlarda kırsal alanlara göre nispeten daha yüksektir (%12,1'e karşı %8,3). Yaş da önemli bir faktördür. Diyabet prevalansı yaşla birlikte artmakta ve en yüksek %24,0 ile 75-79 yaş grubunda görülmektedir (H. Sun et al., 2022). Diyabetle yaşayan 537 milyon kişinin %44,7'si durumlarından habersizdir. Tanı konmamış diyabet, düşük ve orta gelirli ülkelerde daha sık görülür. %53,6 (Afrika, Batı Pasifik) ile %24,2 (Kuzey Amerika ve Karayipler) arasında değiştiği tahmin edilmektedir (Ogurtsova et al., 2016).

Bir başka yayında diyabet prevalansının 2030 yılına kadar dünya genelinde %1,3 artacağı tahminine yer verilmektedir (Shaw et al., 2010). Bir başkasında ise dünya çapında halen 400 milyondan fazla insanın diyabetli olduğu, küresel prevalansın giderek arttığı bildirilmektedir (Saeedi et al., 2019).

Cinsiyet, yaş, ırk/etnik köken, anemi/hemoglobinopatiler, Vücut Kitle İndeksi (VKİ) ve hareketsiz yaşam tarzı gibi klinik ve demografik özelliklerin diyabet için risk faktörleri olduğu bulunmuştur (Erickson et al., 2012; Sohn et al., 2015).

Dünya Sağlık Örgütü verilerine göre 2021 yılı itibariyle Dünya çapında yaklaşık 422 milyon insan diyabet hastasıdır. Asya Diyabeti Önleme Örgütü'nün bir çalışmasına göre, tüm Dünyadaki diyabetik popülasyonun %60'ı Asya'dadır (Chan et al., 2009).

Diyabet prevalansının belirlenmesi karmaşık bir konudur. Genel olarak, diyabet kayıtları veya epidemiyolojik araştırmalar, diyabet prevalansı tahminlerinin ana kaynaklarıdır (Zimmet et al., 2016). Yakın tarihli bir çalışmada, yazarlar, İsveç, Finlandiya, Danimarka, Norveç, Hollanda, Almanya, İskoçya, Letonya, İngiltere, ABD, Avustralya ve Suudi Arabistan olmak üzere ulusal diyabet kayıtları olan 12 ülke bildirmişlerdir. Listedeki ülkelerin ortak özelliği, kişi başına düşen gelirlerinin yüksek olmasıdır. Bununla birlikte, diyabet kayıtlarının yalnızca nispeten küçük nüfuslu ülkelerde örneğin, İskoçya'da tama yakın kapsama ve Finlandiya ve İsveç'te %95'e yakın kapsama ile önemli bir nüfusu temsil ettiği görülmektedir (Bak et al., 2021). Doğal olarak, kayıtlar diyabeti bilinmeyen hastaları kapsayamaz. Öte yandan, epidemiyolojik saha araştırmalarının örnekleme yöntemi sorunları, maliyet ve diyabet prevalansının değişme olasılığı nedeniyle tekrarlama ihtiyacı gibi çeşitli sorunları vardır.

Her yıl 1,6 milyon ölüm doğrudan diyabete bağlanmaktadır (https://www.who.int/health-topics/diabetes#tab=tab_1, Erişim Tarihi: 18.09.2021). Dolayısıyla diyabet en önemli halk sağlığı problemlerinden biridir. Bu problemin çözümü için Tıp ve çeşitli disiplinler çözüm arayışlarına devam etmektedir.

Bu arayışların sayısını artıran tek neden ölüm değildir, diyabetin sebep olduğu diğer ağır sağlık problemleri de söz konusudur. Sağlıklı bireylerde endokrin fizyolojisi içerisinde normal değer aralıklarında tutulabilen kan şekeri düzeyinin en önemli bileşeni pankreas bezi tarafından üretilen insülin ve glukagon hormonudur. Kan şekeri düzeyinin yükselmesi halinde İnsülin, düşmesi halinde ise pankreas bezinden Glukagon salınımı başlamaktadır. Dolayısıyla yükselmiş kan şekeri seviyesini düşürmek üzere T1DM için ana tedavi İnsülin'dir. T2DM, glukozun zamanla yükselmeye devam etmesi şeklinde

ilerler (UPDS, 1998). Çeşitli nedenlerle vücutta İnsülin'in ihtiyaç duyulan zamanda ve miktarda yerine konması yaşamsal kritik önemdedir. Diyet, kilo kaybı, egzersiz ve oral ilaçlarla kan şekeri düzeyi normal sınırlarda tutulamayan bazı T2DM vakalarında da insülin kullanılmaktadır.

Mevcut ilaçlar a) kişinin hayatını kurtarmayı ve hastalık semptomlarını hafifletmeyi, b) uzun vadeli diyabet komplikasyonlarının önlenmesini ve/veya çeşitli risk faktörlerinin ortadan kaldırılmasını ve böylece ömrün uzatılmasını, yaşam kalitesinin artırılmasını hedefler. En yaygın anti-diyabetik ajanlar arasında Sülfonilüre, Metformin, Alfa-glukozidaz inhibitörü, peptit analogları, sülfonilüre olmayan sekretagoglar vb. bulunur (Krentz & Bailey, 2005).

Günlük fiziksel aktivite, diyabetin kontrol altında tutulması için kritik önemde olduğundan bunu ölçmek için de çok çeşitli sensörler geliştirilmiştir. Örneğin; adım sayısı, harekete bağlı ivme, harekete bağlı olarak kalp atım hızı ve kandaki oksijen saturasyon düzeylerindeki değişimler aracılığıyla aktiviteyi ölçen sensörler gibi. Fiziksel aktivite sensörleri sadece diyabet vakalarının takibi için geliştiriliyor olmasa da Google akademik veri tabanında “diabetes and activity sensors” anahtar kelimeleri ile arama yapıldığında 11.500 makale bulunduğu sonucu görülmüştür (<https://scholar.google.com>, Erişim Tarihi: 27.10.2021).

Dünyada etkilediği birey sayısı, hastalığa yakalanmış bireylerdeki hasarlar, beklenen yaşam süresindeki azalma, yaşam kalitesindeki bozulma, takip ve tedavi maliyetlerindeki olumsuzluklar ve bu olumsuzluklardaki zamana bağlı artışlar diyabet konusunda yapılan çalışmaları da çok boyutlu olmaya zorlamaktadır. Diyabetin kesin tanısında değerli olmasına rağmen Oral Glukoz Tolerans Testi (OGTT) klinik pratikte uygulanması zor olduğundan daha az kullanılır. Diyabet taramalarında, kolay uygulanabilir ve ucuz bir test olmasına rağmen AKŞ ölçümü toplum tabanlı taramalarda pratik bulunmayabilir. Bu nedenle, tanısal amaçlı ya da tarama amaçlı kullanılabilecek laboratuvar dışı bir klinik risk puanı belirleme arayışları devam etmektedir (Kengne et al., 2014). FINnish Diabetes RiSk SCore daha az parametrelili olduğundan yaygın olarak kullanılan bir risk hesaplama aracı olarak karşımıza çıkmaktadır (Noble et al., 2011). Archimedes adı verilen çok daha ayrıntılı ve incelikli bir model, glisemik indeksler, diğer laboratuvar testleri, tedaviler ve

sonuçlar dahil olmak üzere sürekli etkileşim halinde olan ve güncellenen 50'den fazla biyolojik değişkeni içerdiğinden pratikte çok kullanılmayabilir ancak daha başarılı sonuçlar üretir (Eddy & Schlessinger, 2003).

2.2. Diyabet ve Bazı Komorbid Hastalıklar

Diyabete sebep olduğu düşünülen ekonomik, kültürel, sosyal ve çevresel faktörlerin belirlenmesi ve önleyici tedbirlerin alınması çalışmaları yanı sıra genetik faktörler bakımından yapılan araştırmalar da pahalı ve zor olmakla birlikte hiç de azımsanmayacak sayıdadır. Çünkü diabetes mellitusun vücuttaki diğer sistemleri olumsuz etkileyerek sebep olduğu komplikasyonların tedavisi, ciddi küresel mali yükler getirmektedir (Alwafi et al., 2020).

Diyabete bağlı morbidite ve mortalite bilim dünyasının ilgi odaklarından biridir ve çok sayıda morbidite ve mortalite çalışması yayımlanmıştır. Örneğin Currie ve arkadaşları, klinik çalışmalarda agresif glisemik kontrol müdahalelerinin kardiyovasküler olay insidansında ve tüm nedenlere bağlı mortalitedeki artışına dikkat çekmişlerdir (Currie et al., 2010). Aralıklı hipogliseminin daha yüksek düzeyde oksidatif strese neden olduğu (Tse et al., 2016), endotel disfonksiyonuna ve kronik inflamasyona neden olarak mortalite riskinde artışa yol açtığını gösteren çalışmalar vardır (Costantino et al., 2017). Hem akut hem de kronik glisemik değişkenliğin oksidatif stresi ve kronik inflamasyonu şiddetlendirdiği (Chang et al., 2012), artan metabolik değişkenliğin, farklı organlara zarar vererek kalp yetmezliği gibi komplikasyonlara yol açabildiğini (Roever et al., 2019) açıklayan yayınlara çokça rastlanır. Lipid değişkenliğinin kardiyak risk (Bangalore et al., 2015), diyabetli hastalarda sıkça kullanılan sülfonilürenin böbrek yetmezliği riskini önemli ölçüde arttırdığı bildirilmiştir (Hung et al., 2013).

2.2.1. Kronik Hastalıklar

Diyabetik nöropati, diyabetin en bilinen komplikasyonlarından birisidir (Vinik et al., 2013). Diabetes mellitus damarlar ve genel olarak kardiyovasküler sistem üzerinde olumsuz etkilere sahiptir. Diyabette kalp yetmezliği, iskemik kalp hastalığı, periferik damar hastalıkları, miyokard enfarktüsü ve serebrovasküler hastalık riskleri artmıştır (Strain & Paldanius, 2018). Hipertansiyon ile diyabet sıklıkla biriktir ve bu iki ilişkili hastalık birbirlerinin zararlı etkilerini artırır (Yamazaki et al., 2018). Diyabet, böbrek

komplikasyonlarına da yol açar ve kronik böbrek yetmezliğinin sebeplerinden birisidir (Akhtar et al., 2020). Retinopati ve katarakt da diyabetin komplikasyonları arasında sözü edilmesi gereken sağlık problemleridir (Khan et al., 2017).

2.2.2. Kanserler

Diyabette malignite gelişme mekanizmasına ilişkin bazı açıklamalar bulunmaktadır. Bazı araştırmacılar, yaş, cinsiyet, obezite ve dislipidemi gibi her iki hastalıkta da paylaşılan risk faktörlerinden şüphelenmektedir (Abudawood, 2019). Hipergliseminin doğrudan etkisi (Zhang et al., 2021) dahil olmak üzere diyabette karsinogenez için önerilen birkaç başka mekanizma vardır, ancak mekanizmaları henüz net değildir (Cebioglu et al., 2008). Muhtemelen her iki tip faktör de karsinogenezde birlikte sorumludur, ancak çalışmalar, obezite ve dislipidemi gibi diğer karıştırıcı faktörler için düzeltme yapıldıktan sonra bazı kanser risklerinin yüksek olduğunu göstermiştir (Abudawood, 2019). Ek olarak, bazı antidiyabetikler kanser riskini artırabilir (Srivastava & Goodwin, 2020). Metforminin kanser riskini azalttığını bildiren çalışmalar da vardır (Lv & Guo, 2020).

Hem T1DM hem de T2DM’de kanser riski artar. T1DM’li kişilerde mide, rahim ağzı, endometrium, yumurtalık, pankreas kanseri riskleri daha yüksektir (Stevens et al., 2007; Swerdlow et al., 2005; Zendejdel et al., 2003). Çalışmalar ayrıca endometrium, meme, mide, kolorektum, pankreas, karaciğer ve kan gibi birçok organda T2DM ile kanser arasında bir ilişki olduğunu düşündürmektedir (Abudawood, 2019). İlginç bir şekilde, diyabetik hastalarda prostat kanseri insidansının daha düşük olduğu bildirilmektedir (Waters et al., 2009).

Diyabette majör kanser türlerinin riskine ilişkin önceki çalışmalar aşağıdaki bölümde özetlenmiştir. Tip 1 ve tip 2 diyabette kanser riskleri farklı olabilir. Aşağıdaki notlarda diyabetin tipi hakkında bilgi yoksa çalışma her iki tipten diyabet hastalarını içermektedir ve hastaların büyük çoğunluğunun T2DM olması beklenmektedir.

Dudak, ağız boşluğu ve farenks kanserleri: Kırkdokuz çalışmanın meta-analizinde, ağız kanserleri için olasılık oranı (OR) 1,41 (%95 güven aralığı, 1,10-1,81) olarak bildirilmektedir (Ramos-Garcia et al., 2021). T2DM’nin bir meta-analizinde, baş ve

boyun kanserlerinde 1,04 (0,88-1,23) r latif risk (RR) ve farenks kanserlerinde 1,18 (0,94-1,49) RR bildirilmektedir (Yan et al., 2021).

Mide kanseri: Zehdehdel T1DM'li kiřilerde mide kanseri riski y kseklięinden s z etmektedir, ř yleki; SIR (standardize insidans oranı) 2,3 (1,1-4,1) olarak raporlanmıřtır (Zendehtel et al., 2003). 2011'deki 21  alıřmanın meta-analizinde 1,09 RR (0,98-1,22) bildirilmiřtir (Ge et al., 2011). 25  alıřma  zerinde yapılan bařka bir meta-analiz, benzer bir sonu  bildirilmektedir; RR 1,11 (1,00-1,24) (Tian et al., 2012). 15 kohort  alıřmasını i eren yakın tarihli bir meta-analiz, RR'nin 1,10 (0,94-1,29) olduęunu bildirmektedir (Miao et al., 2017).

Kolon kanseri: Onbeř  alıřmanın yer aldıęı 2005 meta-analizine g re, diyabetin kolorektal kanser insidansının RR deęeri 1,30 (1,20-1,40)'dur (Larsson et al., 2005). 30  alıřmanın bir bařka meta-analizinde 2011 yılında RR 1,27 (1,21-1,34) olarak bildirilmiřtir (Jiang et al., 2011).

Karacięer kanseri: 2012 yılında dokuz intrahepatik kolanjiokarsinom  alıřmasına iliřkin bir meta-analiz, diyabet i in RR'in 1,97 (1,57-2,46) olduęunu ortaya koymuřtur (Jing et al., 2012). 2006'da hepatosel ler karsinom  zerine bir meta-analiz, 13 olgu-vaka kontrol  alıřmasının 2,5 OO (1,8-3,5) deęeri ve yedi kohort  alıřmasının 2,5 RR (1,9-3,2) ortaya koyduęunu bildirmektedir (El-Serag et al., 2006). Hepatosel ler karsinomla ilgili 49  alıřmanın 2012 tarihli bir meta-analizi, 2,31 (1,87-2,84) RR bildirmektedir (Wang et al., 2012).

Pankreas kanseri: 2005 yılında 36  alıřmanın meta-analizi, T2DM i in OO'nun 1,82 (1,66-1,89) olduęunu ortaya koymaktadır (Huxley et al., 2005). 2011'deki 35  alıřmayı i eren bir bařka meta-analiz, RR'nin 1,94 (1,66-2,27) olduęunu bildirmektedir (Ben et al., 2011).  in'de 26 arařtırmayı kapsayan meta-analiz  alıřması, 3,69 (3,12-4,37) RR bildirmektedir (J. J. Zhang et al., 2019).

Larenks kanseri: Tip 2 diyabetlilerde yapılan bir meta-analizde RR 1,03 (0,88-1,22) olarak bildirilmiřtir (Yan et al., 2021).

Akciğer kanseri: Yirmi çalışmanın meta analizi, diyabetin akciğer kanseri riski üzerinde çok az veya hiç önemli bir etki göstermediğini bildirmektedir; RR 1,10 (0,99-1,23)'dur (Yi et al., 2020).

Malign melanom: Dokuz kohort çalışmasına ilişkin bir meta-analiz, T2DM için RR'nin 1,15 (1,00-1,32) olduğunu bildirmektedir (Qi et al., 2014).

Meme kanseri: 2007 yılında yapılan bir meta-analizde, 20 çalışmanın analizi sonucu T2DM'lilerde RR 1,20 (1,12-1,28) olarak bildirilmektedir (Larsson et al., 2007). Daha sonraki bir meta-analiz, tüm diyabet tipleri için RR'nin 1,32 (1,14-1,52) olduğunu ortaya çıkarmıştır ve RR, T2DM için 1,24 (1,06-1,44) ve T1DM için 1,83 (1,21-2,78)'dir (Zhang et al., 2017).

Rahim kanseri: Tüm diyabet tipleri için 16 endometrium kanseri çalışmasının 2007 tarihli bir meta-analizi, 2,10 RR (1,75-2,53) sonucunu vermiştir (Friberg et al., 2007).

Over kanseri: 2013'te yapılan 19 çalışmanın meta analizi, RR'nin 1,17 (1,02-1,33) olduğunu bildirmektedir (Lee et al., 2013).

Prostat kanseri: 2013 yılında T2DM'li grupta 45 çalışmanın meta-analizinde, RR 0,86 (0,80-0,92) olarak bulunmuştur (Bansal et al., 2013).

Böbrek kanseri: İsveç'ten yapılan bir kohort çalışması, diyabetli kişilerde böbrek kanseri için 1,50 (1,30-1,70) SIR bildirmektedir (Lindblad et al., 1999). Japonya'dan yapılan bir başka kohort çalışması, 2,22 (1,04-4,70) değerinde bir hazard riski bildirmektedir (Washio et al., 2007). 2013'te yapılan 24 çalışmanın meta analizi, 1,40 RR (1,16-1,69) bildirmektedir (Bao et al., 2013).

Mesane kanseri: 2006'daki bir meta-analiz, yedi olgu-kontrol çalışmasının RR değerini 1,37 (1,04-1,80), üç kohort çalışmasının RR değerini 1,43 (1,18-1,74) olarak bildirmiştir (Larsson et al., 2006). 2013'te 36 çalışmayı içeren başka bir meta-analiz, RR değerini 1,35 (1,17-1,56) bildirmiştir (Zhu et al., 2013).

Tiroid kanseri: Sekiz çalışmanın meta analizi, RR'nin 1,17 (0,99-1,39) olduğunu bildirmektedir (Schmid et al., 2013). 16 çalışmayı içeren bir meta-analiz ise RR değerini 1,20 (1,09-1,33) olarak bildirilmiştir (Li & Qian, 2017).

Hodgkin hastalığı: Yirmibir çalışmanın meta-analizi, T2DM için OO'nun 1,02 (0,86-1,19) olduğunu bildirmektedir (Castillo et al., 2012).

Non-Hodgkin lenfoma: T2DM grubunda yapılan 21 çalışmanın meta analizi, OO değerini 1,22 (1,07-1,39) olarak bildirmektedir (Jiang et al., 2011). Başka bir meta-analiz, T2DM için 1,20 (1,12-1,30) RR ve T1DM için 1,55 (1,15-2,08) RR bildirmektedir (Y. Wang et al., 2020).

Diğer malign tümörler: Onyeddi çalışmanın özofagus kanseri meta-analizi, RR'nin 1,30 (1,12-1,50) olduğunu bildirmektedir (Huang et al., 2012). T2DM ile ilgili 11 lösemi çalışmasının bir meta-analizi RR değerini 1,22 (1,03-1,44) olarak bildirmiştir (Jiang et al., 2011).

Tüm malign tümörler (C00-C97): Yedi prospektif çalışmanın verileriyle ilgili bir araştırmaya göre, diyabet tüm kanserlerin riski ile ilişkili kombine hazard oranı (HR) 0,94 (0,86-1,04) olarak bildirilmiştir (Amadou et al., 2021).

İn situ, iyi huylu, davranışı belirsiz veya bilinmeyen neoplazmalar (D00-D48): Bir meta-analize göre, diyabet hastalarında tiroid nodülü geliştirme olasılığı daha yüksektir, tiroid nodülü için OO 1,78 (1,25-2,55) olarak bulunmuştur (H. M. Zhang et al., 2019). Diyabet ayrıca leiomyoma uteri için bir risk faktörüdür ve bir çalışmada RR 1,29 (1,24-1,33) olarak hesaplanmıştır (Alashqar et al.). Smear ve biyopsi sonuçlarında Servikal İntraepitelyal Neoplazi 1 (CIN 1) DM'li hastalarda DM olmayan hastalara göre daha yüksek oranda bulunmuştur (%27.3'e karşı %9.8) (Cakir et al., 2022).

Diyabete yatkınlık ve risk faktörleri analizlerinde, hastalığın tanı, takip, tedavisi, hastalığın ortaya çıkışını ve seyrini etkileyen genetik, sosyal, çevresel, ekonomik faktörler, hastalığın oluşturduğu ağır mali yük gibi nedenlere bağlı olarak tüm boyutları ile düşünülmesini zorunlu kılmaktadır. Diğer taraftan önleme, tanı koyma, takip ve tedavi prosedürlerinin en ucuz, en kolay, en hızlı yöntemlerle sağlanması ihtiyacı da literatürdeki

alıřmaların ok byk bir blmnn ok boyutlu olmasına neden olduėu iin risk faktrleri, lm teknikleri, tanı, takip, tedavi, ynetim gibi arařtırma konuları i ie gemiř, bu nedenle literatr, tmyle tam ve kesin sınırları ile gruplanarak sunulamamıřtır. Ancak grlmektedir ki tm Dnya, bu kresel saėlık probleminin zm iin olanca gcyle alıřmaktadır.

2.3. Trkiye’de Dijital Saėlık Altyapısı

Trkiye, dijital saėlık (e-Saėlık) alanındaki en kapsamlı alıřmalarına 2000’li yıllarda bařlamıřtır. Tıp Biliřimi Derneėi tarafından 2001 yılında yayımlanan “İkibinli Yıllar Trkiye’sinde Saėlıkta Bilgi Stratejileri; Tıp Biliřimi Derneėi alıřma Grupları Sonu Raporu” kamu, akademik dnya, zel sektr ve tm arařtırmacı kurumlara sistematik bilgi ve stratejiler sunan ilk ve en deėerli rapordur (<https://turkmia.net/file/ikibinli-yillar.pdf>., Eriřim Tarihi: 30.09.2021). oėunluėu, bu raporu hazırlayan kiřilerden oluřan alıřma gruplarının katıldıėı ve Trkiye Cumhuriyeti Saėlık Bakanlığı (TCSB)’nın koordine ettiėi ikinci rapor “Trkiye Saėlık Bilgi Sistemi Eylem Planı” adıyla Ocak 2004’te yayınlanmıřtır. Her iki rapor da saėlık hizmeti alan, sunan, finanse eden, tedarik eden, kamu kurum ve kuruluřları, niversiteler, sivil toplum kuruluřları, zel sektr, vb. katılımıyla hazırlanmıřtır. Bu raporlar Saėlıkta Dnřm Programı ierisinde Saėlıkta e-Dnřm olarak yerini almıřtır. TCSB tarafından Saėlık.Net olarak adlandırılan Trkiye Ulusal Saėlık Bilgi Sisteminin kurulum alıřmalarında nem kazanmıřtır (Saėlık Bakanlığı, 2004).

Saėlık.Net, saėlık kurumlarında retilen ve esas olarak saėlık verileri olmakla birlikte idari ve mali verileri de kapsayan, standartlara uygun řekilde retilen verilerin doėrudan retildikleri yerden toplanmasını, toplanan verilerden tm paydařlar iin gerekli bilgilerin elde edilmesini, saėlık hizmetlerinde verim ve kalitenin artırılmasını hedefleyen, entegre, gvenli, hızlı ve geniřleyebilen bir bilgi sistemi olarak tanımlanmıřtır. Toplanan saėlık verilerinin Elektronik Saėlık Kaydı (ESK) veritabanı ve analiz amalı gstergelere dnřtrldė Karar Destek Sistemi (KDS)’de Saėlık.Net’in bileřenleri arasındadır.


Saėlık biliřimi alanında kullanılacak her bir veri elemanının tm ayrıntılarıyla tanımlandıėı Ulusal Saėlık Veri Szlė (USVS) Saėlık.Net’in tasarlanması ařamasında geliřtirilmiřtir. Bu szlkte her bir veri elemanının hangi saėlık veri setleri iinde yer

alacağı, diğer veri eleman ve veri setleriyle ilişkisi ayrıntılarıyla tanımlanmıştır. Veri elemanlarından Minimum Sağlık Veri Setleri (MSVS) oluşturulmuştur. Kodlanabilir alanların alabileceği değerler kümesinin ve standartlarının belirlendiği Sağlık Kodlama Referans Sunucusu (SKRS) Sağlık.Net'in diğer önemli parçasıdır. Standardize edilmiş verilerden oluşan sağlık veri seti paketlerinin Sağlık Bakanlığı merkezindeki elektronik sağlık kaydı (ESK) veri tabanına gönderilmesinde Health Level 7 (HL7) V.3 standardı kullanılmıştır. Aynı şekilde merkezden veri alınmasında da bu standart söz konusudur (<https://e-saglik.gov.tr/TR,7141/usvs.html>., Erişim Tarihi: 30.09.2021). 2006 yılında Sağlık.Net ile birinci basamak sağlık kuruluşlarında üretilen sağlık verileri ulusal ve uluslararası standartlara göre toplanmaya ve işlenmeye başlamış, 2009 yılı sonundan itibaren ikinci ve üçüncü basamak sağlık kuruluşları da sisteme dâhil edilmiştir. Sistem, kısmi de olsa 2015 yılı ilk çeyreğine kadar işletilebilmiştir.

Sağlık.Net teknolojisinin yenilenmesi, işlevlerin güçlendirilmesi, kapsamın genişletilmesi ile 4 Nisan 2015 tarihinde Türkiye Cumhuriyeti vatandaşlarının kullanımına sunulan e-Nabız Kişisel Sağlık Kaydı Sistemi (<https://enabiz.gov.tr/>, Erişim Tarihi: 18.09.2021) için büyük bir deneyim havuzu olmuştur. Aynı tarihte yeni kurulan Ulusal Tele Radyoloji Sisteminde tutulan (<https://teletip.saglik.gov.tr/>, Erişim Tarihi: 18.09.2021) radyolojik görüntüler de E- Nabız Kişisel Sağlık Kaydı Sistemine eklenmiş, kişiler radyolojik görüntülerine ve bu görüntülere ait raporlarına da erişebilmişlerdir. Yine aynı tarihte veri tabanında toplanan verilerden anlık Yönetici Karar Destek Sistemi (YKDS) sunan bir raporlama arayüzü de rol bazlı olarak sağlık yöneticilerinin kullanımına sunulmuştur. Bu YKDS, halen Sağlıkta İstatistik ve Nedensel Analizler (SİNA) Platformu olarak (<https://sina.saglik.gov.tr/#/login>, Erişim Tarihi: 18.09.2021) 100 binden fazla kullanıcıya hizmet vermektedir. E-Nabız'ın 56.256.158 tekil vatandaş kullanıcısı mevcuttur (<https://yonetim.enabiz.gov.tr/Istatistik/Enabiz>, Erişim Tarihi: 06.02.2022). On altı yaşından küçük çocuklar e-Devlet servisi kullanıcısı olmadıkları için çocuklarının verilerine erişebilmek için ebeveynlerin sistem üzerinden karşılıklı onay vermeleri gerekmektedir. Bu onay mekanizması yine 06.02.2022 tarih itibarıyla toplam 33.536.668 kez kullanılmıştır. Aile bütünlüğünün olmadığı durumlarda mahkeme tarafından karara bağlanan velayet sahibi çocuğun kayıtlarına erişebilmektedir. Hekimler, kendilerine müracaat eden hastalarının geçmiş sağlık kayıtlarına, hastanın izin verdiği ölçüde

erişebilmektedir. Bu servisi kullanan tekil hekim sayısı 06.02.2022 tarih itibarıyla 101.137 olup 127.660.369 sorgulama yapmışlardır. Burada anlatılmak istenen husus, E-Nabız'ın erişilebilirlik, gizlilik, güvenlik ve mahremiyetin korunması bakımından taşıdığı teknik özelliklerdir. Sistem mimarisi Şekil 2.1'de sunulmuştur.

Her bir kullanıcının, herhangi bir sağlık tesisinde oluşan sağlık kayıtlarına zaman ve mekândan bağımsız olarak kendisinin ve/veya erişim hakkı verdiği kişilerin web sitesi veya e-Nabız Mobil üzerinden erişimi mümkündür. e-Nabız, Merkezi Hekim Randevu Sistemi (MHRS) ile de entegre edilmiştir ve muayene randevusu alınabilir. Covid-19 aşı kaydı ve randevusu, pandemi döneminde geçerli olmak üzere sağlık risk gruplarındaki kişilere idari izin raporu verilmesi dahil olmak üzere bir çok bireysel işlem bu sistem üzerinden yürütülmektedir. Kişiler sağlık durumları ile ilgili tüm kayıtlarına erişebilmekte ve bu kayıtlarını kendileri yönetebilmektedir.



Şekil 2.1. e-Nabız sisteminin basitleştirilmiş mimarisi

E-Nabız, doğum öncesinden başlayan ve ölüm sonrası verileri kapsayan kişisel bir elektronik sağlık dosyasıdır. Kişiler manuel ya da kullanmakta oldukları akıllı telefon ve/veya tıbbi cihazları üzerinden de kendi dosyalarına adım, nabız sayısı, kan basıncı, solunum sayısı, solunum fonksiyon testi, uykuda geçen süre, kan şekeri ölçüm sonucu gibi verileri kaydedebilmekte, sonuçlarını grafiksel olarak görüntüleyebilmektedir.

2.4. Büyük Veri

Basit bir ifadeyle büyük veri, çok çeşitli bilgisayar uygulamaları ve elektronik cihazlar tarafından üretilen muazzam miktarda yapılandırılmış, yarı yapılandırılmış ve yapılandırılmamış karmaşık verileri ifade eder (Emani et al., 2015).

Bir başka makalede ise büyük veri, evrensel olarak kabul edilmiş bir tanım olmamasına rağmen, genellikle 5 V (Volume, Variety, Velocity, Veracity, Value) ile karakterize edilen veri kümeleri olarak tanımlanmıştır (Marr, 2015).

Zhang ve arkadaşlarının 2016 yılında yayımladıkları “Klinik Tıpta Büyük Veri Madenciliğinin Uygulaması ve Keşfi” adındaki derleme çalışmalarında Büyük Veri’yi “endüstri standardı yazılım araçları tarafından yakalanamayan, yönetilemeyen veya işlenemeyen büyük ölçekli ve Dört V ile karakterize edilen veri kümeleri” olarak tanımlamışlardır. Buradaki Dört V ise Volume, Variety, Velocity, Value (hacim, çeşitlilik, hız ve değer)’dir (Zhang et al., 2016).

Diyabet hastalığı yaşam kalitesine ve yaşam süresine olumsuz etkileri ile bireylerin, kronik bir hastalık olması ve uzun dönem bakım gerektirmesi nedeniyle sağlık sistemlerinin ve oluşturduğu yüksek sağlık harcamaları ile devletlerin önünde her zaman ağır bir yük olarak durmaktadır. Bu yüklerin hafifletilmesi arayışı, başta tıp ve mühendislik bilimleri olmak üzere birçok disiplini bir araya gelmeye zorlamaktadır.

Bu disiplinler arasında sağlık başlığı altındaki çalışmalara yaygın olarak PubMed gibi sağlık alanında özelleşmiş kütüphaneler ev sahipliği yapmaktadır. Bu sebeple diyabette veri madenciliği, Makine Öğrenmesi(MÖ)/Yapay Zekâ(YZ) teknolojilerine ilişkin bilimsel yayınları tek bir kütüphanede bulmak zordur. Örneğin bir çalışmada PubMed tarafından indekslenmeyen ancak bilgisayar bilimleri alanında yüksek etkili uluslararası

bilimsel dergiler için ev sahipliği yapan DBLP Bilgisayar Bilimi Bibliyografyası kullanılmıştır (Kavakiotis et al., 2017). Diyabet, büyük veri, MÖ bu yönüyle şimdilik interdisipliner bir konudur.

Biyoteknoloji ve sağlık bilimleri, elektronik sağlık kayıtları, nitelikli genetik ve klinik veriler her geçen gün büyümektedir. Bu verilerin diyabet ile ilgili bölümü diyabetin önlenmesi, geciktirilmesi veya tedavisi için kullanılmak üzere tüm dünyada önemli bir kaynak olma yolundadır. Diğer yandan veri madenciliği, MÖ ve yapay zekâ alanındaki ilerleme ve deneyimler de her geçen gün artmaktadır. Elektronik ortama kaydedilmiş büyük verilerin yapay zekâ yöntemleri ile değerli bilgilere dönüştürülmesi bilim dünyasının ortak hedefidir.

Sağlıkta büyük veri uygulamaları hakkında yapılan birçok araştırma ve iddiaya rastlamak mümkün olsa da bazılarının gerçekçilikten uzak olduğunu rapor edenler de vardır (Sul Gi, 2013). Çünkü sağlıkta büyük veri kullanımının sağlığa özgü bazı sorunları da vardır (Rothstein, 2015). Örneğin sağlık verilerini serbestçe kullanmak mümkün değildir. Sağlık verileri, veri koruma hukuku açısından doğası gereği hassas nitelikli verilerdir ve hemen her ülkede hem yasal hem sosyal değerler açısından korumaya yönelik kurallara tabidir. Avrupa Birliğine üye ülkelerde bu koruma 2018 yılında yürürlüğe giren Genel Veri Koruma Yönetmeliği (GDPR: Global Data Protection Regulation) ile hukuki koruma altına alınmıştır. Birçok yasal düzenlemede istisna kapsamında işlenen hassas verilerle yapılan araştırmaların kamu yararına olması koşulu getirilmiştir (Rumbold & Pierscionek, 2017). Sağlıkta büyük veri söz konusu olduğunda veri öznelerinin çok sayıda olması, bilgilendirilmiş rıza almayı uygulanamaz hale getirebilmektedir.

Bazı olumsuz koşullar olsa da Tıpta büyük veri, gelişmekte olan bir alan olmaya devam etmektedir (Jacobson et al., 2013). Bu gelişim hassas tıp (precision medicine) için bir fırsat olmakla birlikte önce üstesinden gelinmesi gereken önemli teknik ve politik zorlukların aşılması gerekir. Verinin kullanım seyrinde sadece bireysel tıp ya da hassas tıp değil hastalığın epidemiyolojik yönüne odaklanılması özellikle diyabet gibi hastalıklar için oldukça önemlidir. Epidemiyolojik çalışmalar için ise çok merkezli ve ülkeler arası standardizasyon sorunları, fizyolojik olayların stokastikliği, genetik heterojenlik ve insan popülasyonlarındaki kişisel koşulların çeşitliliği nedeniyle örneğin istatistiksel

yöntemlerden bağımsız olarak, tek bir kan örneğinden bireysel düzeyde vasküler komplikasyonlar bakımından nihai durumun tahminini gerçekleştirmek zordur fakat epidemiyoloji çalışmalarında büyük veri güçlü fırsatlar sunmaktadır (Alyass et al., 2015). Yine de veriye dayalı hassas tıptaki istatistiksel modellerin doğru olmasını, yorumların sağlam ve tarafsız olmasını ve mevcut en iyi uygulamaların yeni veri analizi çerçevelerine dahil edilmesini sağlamak için önemli zorluklar hala devam etmektedir.

Günümüzde, pek çok kurum büyük miktarda veri toplamakta, kaydetmekte ve analiz etmektedir. Bu verinin hacmi, oluşturulma hızı ve değişik biçimlerde olabilmesi özelliği nedeni ile bu tip veriye “büyük veri” (big data) denir. Büyük veriden fayda elde etmenin anahtarı analizdir. Büyük verinin toplanması ve kaydedilmesinin yarattığı değer pek azdır. Değer üretebilmek için verinin analiz edilmesi ve bunun sonuçlarının karar vericiler ve kurumsal süreçler tarafından kullanılabilmesi gerekir (Watson, 2014). Büyük veri kullanımının dünya genelinde sağlık sektörlerine büyük maliyet tasarrufları sağlayabileceği vurgulanmaktadır (Bakker et al., 2020).

2.5. Veri Madenciliği

Büyük veriden bahsedildiğinde akla gelen terimlerden biri veri madenciliğidir. Veri madenciliği; kaba veya saf olmayan verilerden bilgi, rapor ve gerçekleri ayırmaya veya çıkarmaya yardımcı olan yaklaşım veya prosedür olarak tanımlanmıştır (Kaur, 2019).

Veri madenciliği, bir veri kümesinden bilgi çıkarma işlemidir. Bunun gerçekleştirilebilmesi için veri setinin yeterli miktarda ve kalitede olması ön koşulu vardır. Veri kalitesinin artırılması için yapılan veri temizliği, çalışılacak veri seti boyutunda aşırı küçülmeye neden olduğunda sonuçsuz kalabilmektedir. Bazan da farklı veri kaynaklarından derlenen verilerin bir arada kullanılması gerekebilir. Bu gereklilik aynı şekilde süreci tıkayıcı bir etki oluşturabilmektedir. Çünkü bir veri elemanı, veri setlerinde aynı şekilde yer almakla birlikte anlam ve/veya değer açısından farklı olabilmektedir. Yani farklı kaynaklardan gelen aynı verinin anlamsal farklılıklarının olduğu durumlar söz konusu olabilmekte, bu ise araştırma sonuçlarını olumsuz etkilemektedir. Belirli bölümlerin tanımları veya belirli bir değişkenin ölçülme şekli, veri tabanları arasında farklılık gösterebilir. Farklı veri tabanı mimarilerinin söz konusu olduğu kaynaklar çalışmaları çıkmaza sokabilmektedir. Laboratuvar testleri veya diğer ölçümler için

birimlerdeki farklılıkların basit bir kod parçası ile üstesinden gelmek görece kolay olsa da uzun soluklu çalışma gerektirmektedir. Analize başlamadan önce yapılan ön işlemler sonlandığında bazan elde edilen verilerin bir bölümü anlamsızlaşabilir. Rutin olarak toplanan verilerin kullanıldığı durumlar daha düşük maliyetli iken genom analizi gibi ileri tekniklerle elde edilmesi gerekecek veriler yüksek maliyeti sebebiyle elde edilemeyebilir

İstatistiksel analizin, en eski veri madenciliği teknolojilerinden biri olduğu söylenebilir. İstatistik metodlarla ilişki niteliklerini analiz etmek ve korelasyonlarını bulmak çoğu kez mümkündür. En yaygın olarak kullanılan modeller, doğrusal ve doğrusal olmayan regresyon, lojistik regresyon analizi, çok değişkenli analiz ve zaman serisi analizine dayalıdır.

2.6. Makine Öğrenmesi ve Yapay Zekâ

Makine Öğrenmesi (MÖ), verilerdeki kalıpları belirlemek ve sonuçları tahmin etmek için deneyimlerden öğrenen bilgisayar sistemlerinin inşasını içeren bilim dalıdır (Anderson et al., 2016).

MÖ, bilgisayar sistemlerinin belirli bir görevdeki performanslarını aşamalı olarak iyileştirmesini sağlayan modellerin ve karmaşık ağların geliştirilmesiyle ilgilenen bir yapay zekâ alanı olarak da tanımlanmıştır (Bishop, 2006).

MÖ, bilgisayarların çeşitli sensörlerden aldıkları veriler ya da veri tabanlarında kayıtlı veriler gibi akışkan ya da durağan veri türlerine dayalı öğrenimini olanaklı kılan algoritmaların tasarım ve geliştirme süreçlerini konu edinen bir bilim dalıdır. MÖ, bilgisayarlara karmaşık örüntüleri algılama ve veriye dayalı akılcı kararlar verebilme becerisi kazandırmaktır. Bu, MÖ'nin istatistik, olasılık kuramı, veri madenciliği, örüntü tanıma, yapay zekâ, uyarlamalı denetim ve kuramsal bilgisayar bilimi gibi alanlarla yakından ilintili olduğunu göstermektedir (https://tr.wikipedia.org/wiki/Makine_Ogrenimi, Erişim Tarihi: 02.12.2021).

Sağlıkta makine öğrenmesi, devasa klinik verileri insan beyninin anlama kapasitesinin ötesinde anlamlandıracak bir şekilde işleyebilen önemli bir teknoloji olarak tanımlanmıştır (Rajkomar et al., 2019).

MÖ algoritmaları gözetimsiz ya da denetimsiz öğrenme yani kendiliğinden örüntü algılama, gözetimli ya da denetimli öğrenme yani önceki örneklerle dayalı algoritmalar oluşturma veya pekiştirmeli öğrenme yani istenen sonucu elde etmek için ödül/ceza tekniklerinin kullanılması şeklinde üç ana kategoride incelenebilir (Hamet & Tremblay, 2017). Hedeflenen sonuca göre sınıflama yapmak gerekirse; Gözetimli Öğrenme, girdileri hedef çıktılara eşleyen bir işlev üretirken Gözetimsiz Öğrenme, bir girdi kümesi modeller. Pekiştirmeli Öğrenme, doğa algısına dayalı bir öğrenme biçimidir. Her eylem ortamda bir etki oluşturmakta ve ortam, öğrenme algoritmasına yol gösteren ödüller biçiminde dönütler vermektedir. Yarı Gözetimli Öğrenme, uygun işlev ya da sınıflandırıcılar oluşturmak için etiketli ve etiketsiz örnekleri birlikte ele alır. Öğrenmeyi öğrenme modeli ise önceki deneyimlerden yararlanır.

Derin Öğrenme (DL: Deep Learning), derin yapılandırılmış öğrenme olarak da bilinir. Temsili öğrenmeye sahip yapay sinir ağlarına dayanan makine öğrenme yöntemleri ailesinin bir parçasıdır. Öğrenme gözetimli, yarı gözetimli veya gözetimsiz olarak yapılabilir. Konuşma tanıma, doğal dil işleme, ses tanıma, sosyal ağ filtreleme, makine çevirisi, biyoinformatik gibi alanlara Derin Sinir Ağları (DNN: Deep Neural Networks), Derin İnanç Ağları (DBN: Deep Belief Networks), Tekrarlayan Sinir Ağları (RNN: Recurrent Neural Networks) ve Evrişimli Sinir Ağları (CNN: Convolutional Neural Networks) gibi derin öğrenme mimarileri uygulanmıştır.

Yapay Sinir Ağları (YSA), biyolojik sistemlerdeki bilgi işleme ve dağıtılmış iletişim düğümlerinden esinlenmiştir. Derin öğrenmede "derin" sıfatı, ağda birden çok katman kullanılması ile ilgilidir (https://en.wikipedia.org/wiki/Deep_learning, Erişim Tarihi: 02.12.2021).

Evrişimli Sinir Ağları (ESA) derin öğrenme, çoğunlukla görüntüleri analiz etmek için uygulanan bir derin sinir ağı sınıfıdır. Tıbbi görüntü ve video tanıma gibi görüntü analizlerinde karşımıza çıkmaktadır. ESA'lar çok katmanlı algılayıcıların düzenli versiyonlarıdır. Bir katmandaki her nöron, bir sonraki katmandaki tüm nöronlara bağlanır. Bu model normalleşmeye farklı bir yaklaşım getirir. Verilerdeki hiyerarşik kalıptan yararlanır ve daha küçük ve basit kalıplar kullanarak daha karmaşık kalıplar oluşturur. Diğer görüntü sınıflandırma algoritmalarına göre daha az ön işleme kullanır

(https://en.wikipedia.org/wiki/Convolutional_neural_network,
02.12.2021).

Erişim Tarihi:

Naive Bayes (NB) sınıflandırıcıları, Bayes teoreminin özellikler arasında güçlü bağımsızlık varsayımlarıyla uygulanmasına dayanan olasılık sınıflandırıcıları kümesidir. Bu tür sınıflandırıcıları eğitmek için birden fazla algoritma vardır, fakat ortak bir ilkeye dayanan bir algoritma kümesinden söz edilir. Tüm NB sınıflandırıcıları, sınıf değişkeni göz önüne alındığında belirli bir özelliğin değerinin, herhangi bir özelliğin değerinden bağımsız olduğunu varsayar. Bazı olasılık modelleri için NB sınıflandırıcılar, denetimli bir öğrenme ortamında çok etkin bir şekilde eğitilebilir. NB'nin önemli avantajlarından biri, sınıflandırma için gerekli parametreleri tahmin etmek üzere az sayıda eğitim verisi gerektirmesidir.

Destek Vektör Makinesi (DVM), temel olarak farklı sınıflara ait verileri birbirinden en uygun şekilde ayırmak için kullanılır. Bunun için karar sınırları ya da diğer bir ifadeyle hiper düzlemler belirlenir. Sınıflandırma ve regresyon problemleri için uygulanan bir metottur. En önemli özelliklerinden birisi, veri noktalarındaki karmaşık ilişkileri çok başarılı bir şekilde çözebilmesidir (Zhou et al., 2014). Karar fonksiyonunda bir takım eğitim noktaları (support vectors) kullanılır. Dolayısıyla bellek verimli bir şekilde kullanılmış olur.

Rastgele Orman (RO), makine öğrenmesinin en popüler metotlarından birisidir. Hem regresyon hem de sınıflandırma problemlerinde kullanılan bir modeldir. RO, eğitim zamanında çok sayıda karar ağacı oluşturarak ve sınıfların modu (sınıflandırma) veya ortalama tahmin (regresyon) olan sınıfı çıkararak çalışan bir topluluk öğrenme yöntemidir. Bu yöntem, KA'nın eğitim setlerine fazla uyma (outfitting) alışkanlığını yenmek için tercih edilir (Rish, 2001).

Uzun Kısa Bellek (LSTM: Long Short-Term Memory), derin öğrenme alanında kullanılan yinelemeli yapay sinir ağı (RNN: Recurrent Neural Network) mimarisidir. Standart ileri beslemeli sinir ağlarının aksine, Uzun Kısa Bellek (UKB) modelinin geri bildirim bağlantıları vardır. Yalnızca tek veri noktalarını (görüntüler gibi) değil, aynı zamanda tüm veri dizilerini (konuşma veya video gibi) işleyebilir. Örneğin UKB modeli

bölümlememiş, bağlı el yazısı tanıma, konuşma tanıma ve ağ trafiğinde veya Saldırı Tespit Sistemlerinde (IDS: Intrusion Detection System) anomali tespiti gibi görevlere uygulanabilir. Bu model, zaman serisi verilerine dayalı sınıflandırma, işleme ve tahminler yapmak için çok uygundur. Çünkü bir zaman serisindeki önemli olaylar arasında bilinmeyen süre gecikmeleri olabilir. UKB, geleneksel tekrarlayan sinir ağlarını eğitirken karşılaşılabilecek yok olan gradyan problemiyle başa çıkmak için geliştirilmiştir (https://en.wikipedia.org/wiki/Long_short-term_memory, Erişim Tarihi: 02.12.2021).

Farklı veri kümelerinden gelen verileri birleştiren bağlantı çalışmaları sonucunda ortaya konan veri kümeleri değerli bilgiler sağlayabilir. Büyük verilerden yararlanmanın sağlık hizmeti sunumu için önemli etkileri olabilir. Büyük veri analitiğinin sağlık hizmetleri için tanımlanmış faydalarından bazıları şunlardır; hastalık salgınlarını tahmin etmek, bakım sunumundaki boşlukları tespit etmek, en etkili tedavileri keşfetmek, ilaç yan etkilerini, hastaneye yeniden yatışlarla ilgili kalıpları belirlemek, farmasötik araştırmaları geliştirmek ve bireysel tıp uygulamaları ve araştırmaları (Weerasinghe et al., 2022).

Bayesian olasılık teorisinden daha zayıf koşulları karşılayan ve doğrudan ifade etme yeteneğine sahip olduğu düşünülen Dempster-Shafer (DS) teorisinin amacı, veri işlemeyi iyileştirmek için kaba küme teorisi, bulanık teori ve yapay sinir ağını birleştirmektir. Bu teori klinik tıpta yaygın olarak kullanılmaktadır. Örneğin, Lian ve Denoeux kanser tedavisinin sonuçlarını değerlendirmek için kullandıkları bu model ile hem akciğer kanseri hem de özofagus kanseri gruplarında yüksek tahmin doğruluğu elde etmişlerdir (Lian et al., 2015). Worsley ve arkadaşları diz artroplastisi öncesi ve sonrası arasındaki subjektif ve objektif fonksiyonlardaki değişiklikleri değerlendirmek için Cardiff DS teorisini kullanmışlar ağrı seviyelerini, eklem stabilitesini, aktivite seviyelerini ve subjektif yönlerdeki işlevi ve gonyometri, ultrasonografik görüntüleme, üç boyutlu hareket analizi/yürüyüşün dönüşüm modellemesi ve otur-kalk dahil nesnel fonksiyonel değerlendirme verilerini işleyerek yaptıkları hesaplama sayesinde sağlıklı bireylerin ve diz artroplastisi öncesi hastalarının sınıflandırma doğruluğu %90 ile %94 arasında tahmin etmişlerdir. Bu yöntemin, diz protezi ameliyatına ihtiyaç duyan gerçek hastaları ayırt etmek için kullanılabileceği tartışılmıştır (Worsley et al., 2016).

İnsan beyninin simülasyonlarından geliştirilen bir algoritma olarak Yapay Sinir Ağları (YSA), zihnin belleğine benzer bir şekilde, verilerin istatistiksel yasasını öğrenir ve bir örneğin özelliklerini tanımlayabilen bir veri modelini üretir. Daha sonra öğrenilen veri modeli yeni verileri sınıflandırmak için kullanılır. Büyük ölçüde paralel işlem, yüksek derecede hata toleransı, kendi kendine organizasyon, uyarlanabilirlik ve ilişkilendirme işlevleri gibi özelliklere sahiptir. Bulanık mantık sistemi ile karşılaştırıldığında, bir YSA daha akıllıdır. Tıp alanında, bu yöntem ileriye doğru bir sıçrama sağlamıştır. Sunkaria ve arkadaşları, hastaların kalp sağlığı prognozlarını değerlendirmek için YSA'ya dayalı bir kalp hızı sınıflandırma algoritması geliştirmişler sonuç olarak Elektrokardiyografi (EKG) verilerini sınıflandırmada hem geliştirdikleri algoritmanın hem de uzmanların sonuçlarının, hastaların gerçek kalp sağlığı durumu ile oldukça yüksek oranda eşleştiğini göstermişlerdir (Sunkaria et al., 2014).

Literatürde Genetik Algoritma, Tümevarımsal Öğrenme gibi makine öğrenme teorilerine rastlanmaktadır. Araştırmada en çok karşılaştığımız teorilerden birisi de Bayes Network (BN)'tür. Bir BN, olasılık analizi ve graf teorisine dayanan belirsiz bilgi ifadesi ve muhakeme modelidir. Ağdaki her düğüm bir değişkeni temsil eder ve değişkenler arasındaki yay, olaylar arasındaki doğrudan nedensel ilişkiyi ifade eder. BN'nin koşullu bağımsızlığı nedeniyle, bir problemi çözmenin zorluğu, her bir değişkenle ilişkili sonlu değişkenler dikkate alınarak büyük ölçüde basitleştirilebilir. Lee ve arkadaşları bu tekniği radyasyon pnömonisi riskini tahmin etmek için bir araç olarak kullanmışlar AUC değerini 0,83 olarak bulmuşlar ve çok değişkenli LR'ye göre (0,77) önemli ölçüde daha başarılı olduğunu belirtmişlerdir (S. Lee et al., 2015).

Selvi ve Muthulakshmi, sonucunu 2021 yılında yayımladıkları çalışmalarında Harita Azaltma Tabanlı Optimal Veri Sınıflandırması (MRODC: Map Reduce Based Optimal Data Classifier) modeli ile diyabeti güçlü şekilde teşhis edebileceklerini göstermeye çalışmışlardır. Bu çalışmada da PIM A Indians Diabetes veri seti kullanılmıştır. MRODC modelini, Hadoop ekosisteminin farklı aşamalarını, veri toplamayı ve Gradient Boosting Tree (GBT)'ye dayalı sınıflandırmayı kullanan bir yapı olarak tanımlamışlardır. Elde ettikleri simülasyon sonucu, MRODC modelinin sırasıyla 99,23 duyarlılık, 97,48 hatırlama (recall), 97,79 doğruluk, 98,34 F skoru ve 95,02 kappa değeri ile karşılaştırılan

yöntemlere göre sürekli olarak daha iyi sonuçlar ürettiğini rapor etmişlerdir (Selvi & Muthulakshmi, 2021).

MÖ’de bir tahmin modeli olarak Karar Ağacı (KA) modeli de sıkça karşılaşılan bir diğer modeldir. KA, koşullu denetim ifadeleri içeren bir algoritma türüdür. Bir hedefe ulaşma olasılığı en yüksek olan stratejiyi belirlemeye yardımcı olmak için, özellikle de karar analizinde, yöneylem araştırmasında yaygın olarak kullanılır. MÖ’de popüler bir araçtır. KA her bir iç düğümün, bir öznelik üzerinde, yine bir "testi" temsil ettiği, her dalın testin sonucunu temsil ettiği ve her yaprak düğümünün bir sınıf etiketi (tüm niteliklerin hesaplanmasından sonra alınan karar) olduğu flow-chart benzeri yapıdır. Kökten yaprağa giden yollar sınıflandırma kurallarını temsil eder. Bu model, verileri bir dizi kurala göre sınıflandırır ve veri tabanındaki en büyük bilginin alanını bulur. Sonrasında karar ağacının bir düğümü oluşturulur ve alanın farklı değerlerine göre ağacın dalı kurulur. Son olarak, ağacın alt düğümleri ve dalların her birinde diğer dallar kurulur. Bir karar ağacı, kolayca anlaşılabilen kurallar oluşturabilen açık ve belirgin bir özellik gösterir. Hesaplama kullandığı kaynak hacmi düşük olduğundan popüler bir veri madenciliği tekniğidir. Yaël ve arkadaşları ortalama korpüsküler hemoglobin konsantrasyonunun (MCHC) tespit doğruluğunu geliştirmek için kan örneklerini analiz eden bir karar ağacı yöntemi kullanmıştır (Yaël et al., 2015).

Büyük verilerin sınıflandırılması ve faydalı verilerin çıkarılması için farklı bilgi kalıplarına göre filtreleme amacıyla kullanılan tekniğe ise Örüntü Tanıma (PR: Pattern Recognition) denmektedir (Theodoridis et al., 2010). Kalıplar, zaman ve mekân dağılımlarına sahip verilerdir ve farklı veriler farklı kalıplara sahiptir. Tıp ve sağlık alanlarında örüntü tanıma klinik test analizi, EKG ve Elektroensefalografi (EEG)’nin analizi, tıbbi görüntü işleme ve analizi, otomatik tedavi planlaması ve yardımcı teşhiste büyük başarılar elde edebilir. Örneğin, Shi ve Luo bu tekniği manyetik rezonans (MR) görüntülerinin gürültü azaltmasında kullanmış ve dikkate değer iyi sonuçlar elde etmişlerdir (Shi & Luo, 2010).

Büyük verinin çağrıştırdığı en önemli kavramlardan biri de Yapay Zekâ (YZ)’dır. Rigla ve arkadaşları 2017 yılında yayımladıkları “Artificial Intelligence Methodologies and Their Application to Diabetes” adlı çalışmalarında zekâyı “genellikle karar verme ve

problem çözme için anlama, öğrenme ve akıl yürütme gibi bir grup yetenek” olarak, yapay zekâ’yı “bir bilim olarak, insanlar tarafından yapıldığında zekâ gerektiren şeyleri bilgisayarlara yaptırabilme yeteneği” olarak tanımlamışlardır. Aynı çalışmada diyabetin göz dibinde oluşturduğu retinopati tablosuna ait görüntülerin yapay sinir ağları kullanılarak işlenmesi ile sonraki hastaların tanısında yüksek başarı sağladığı belirtilmektedir. Ayrıca 2017 yılına kadar, en çok ve başarı ile kullanılan yapay zekâ modellerinin bir listesi de verilmiştir (Rigla et al., 2018).

İnsanların problem çözme yeteneklerinin bazı yönlerini taklit edebildiği söylenen ilk yapay zekâ geliştirilmesi çalışmasının, literatürde genellikle 1950’lerin ortalarında Herbert Simon, Allen Newell ve John Shaw tarafından yapıldığı belirtilmektedir (Newell & Simon, 1956).

Erken döneme ait bir başka yapay zekâ çalışması Massachusetts Teknoloji Enstitüsü’nden Joseph Weizenbaum tarafından, bir yanıt üretmek için kullanıcı tarafından girilen anahtar kelimeleri veya cümleleri birleştirerek bir insan terapistini taklit eden ELIZA dil işleme programı olarak karşımıza çıkmaktadır (Weizenbaum, 1966). O yıllarda bilgisayar sistemleri koruyucu tıpta da uygulanabilirlik bulmaya başlamıştır (Debray et al., 1969).

1970’lerde Stanford Üniversitesi’ndeki araştırmacılar tarafından geliştirilen bir bilgisayar programı olan MYCIN, enfeksiyon etkeni olan bakterileri tanımlayarak ciddi enfeksiyonlar için tedavide kullanılacak antibiyotikleri, her bir hastanın vücut ağırlığına göre doz önermek için kullanılmıştır (Shortliffe, 1977).

1980’lerde CASNET ve EXPERT adını verilen projeler yapay zekânın erken dönem çalışmaları arasına girmiştir. İlki glokom bakımı üzerine, ikincisi romatoloji ve endokrinolojide akıl yürütme modelleri oluşturmaya yardımcı olma üzerine geliştirilmişlerdir (Kulikowski & Weiss, 2019).

Diyabet literatüründe yapay zekâ tekniklerini, genomik analiz ve çevresel faktörlerin kombinasyonunu kullanarak diyabet, hipertansiyon, kanser veya bunama gibi kronik hastalıkların başlamasını geciktirmeyi ve hatta oluşumunu önlemeyi amaçlayan “önleyici tıp” kavramına rastlamak olasıdır (Itoh et al., 2019).

Yapay zekânın kendisine en çok yer bulduğu tıp alanının kalp ve dolaşım sistemi hastalıkları olduğu ifade edilmesine rağmen (Li et al., 2017) DM'yi konu alan çalışmalar küçümsenmeyecek kadar fazla sayıda ve çeşitliliktedir. Amerika Birleşik Devletleri Gıda ve İlaç Dairesi (FDA, Food and Drug Administration) tarafından yakın zamanda onaylanan IDx-DR yazılım programı (IDx, LLC, Coralville, IA, ABD) retinal kamera ile çekilen gözün görüntülerini analiz etmek için yapay zekâ algoritması kullanan diyabetle ilişkili görme kaybı semptomlarını saptayan bir üründür (Abramoff et al., 2018).

Ahuja, yapay zekânın doktorlar üzerindeki etkisini değerlendirmek için yaptığı araştırmada, bu teknolojinin tıbbi nasıl dönüştürdüğünü daha iyi anlamayı amaçladığını söylemektedir. Sonuç olarak ise radyoloji, patoloji, oftalmoloji ve kardiyoloji gibi uzmanlık alanlarında tıbbi çalışmaların gerçekleştirilmesinde, yapay zekâ tabanlı sistemlerin hekimleri güçlendireceği ve geleneksel hekim-hasta ilişkisinin yerini alma ihtimalinin düşük olduğunu belirtmiştir (Ahuja, 2019).

2.7. Tez Çalışmasında Kullanılan Makine Öğrenmesi Modelleri

Bu tez çalışması için hazırlanmış veri seti kullanılarak yapılan makine öğrenmesi modellerine ait özellikler kısaca aşağıda açıklanmıştır.

2.7.1. Yapay Sinir Ağı: Çok Katmanlı Algılayıcı

Çok Katmanlı Algılayıcılar (MLP) yapay sinir ağlarının temelini oluşturur. Genel amaç, girdilerle çıktı(lar) arasındaki ilişkinin modellenmesi yani girdi-çıkıtı arasındaki karmaşık fonksiyonu öğrenmektir. Bu çalışmada kullanılmış olan MLP, tam bağlı, ileri beslemeli bir yapay sinir ağıdır. Bu ağın girdi ve çıktı katmanları ve bu katmanlar arasında tam bağlı gizli katmanlar bulunur. Her bir katman içerisinde bir veya birden çok yapay sinir hücresi bulunur ve bir sinir hücresinin çıkışı bir diğer sinir hücresine girdi olarak verilmektedir. Her bir sinir hücresinin içerisinde giriş, girdi ağırlıkları, çekirdek ve çıkış bileşenleri bulunur. Bir yapay sinir ağının eğitilmesi süreci, ileri besleme ve geri besleme olmak üzere iki aşamadan oluşur. İleri beslemede, girdiler ve bu girdilerin ağırlıkları üzerinden çekirdekteki fonksiyonlar ve aktivasyon fonksiyonu kullanılarak bir çıkış üretilir ve bu çıkış değeri sonraki katmanda yer alan sinir hücresine taşınır. Bu süreç ilk katmandaki orijinal girdilerden, ara katmanlara ve son katmana kadar devam eder. Ardından model tarafından üretilmiş olan sonuç, veri kümesindeki beklenen sonuç değeri ile karşılaştırılır

ve bu iki deęer arasında bir kayıp deęeri üretilir. Üretilen bu kayıp deęeri, beklenen çıktıdan ne ölçüde farklı sonuç üretildiğinin bir ölçüsüdür. Bu deęerin üretilmesinin ardından geri besleme aşamasına geçilir. Geri beslemede amaç hatanın geri yayılımıdır. Bunun için, son katmandan başlamak üzere her katmandaki her bileşenin o kayba ne ölçüde sebep olduđu ölçülür ve bunun üzerinden katmanlardaki ağırlık deęerleri önceden belirlenmiş olan bir öğrenme katsayısıyla bağlantılı olarak güncellenir. Öğrenme süreci hatanın, yani kayıp fonksiyonu ölçüsünün belirli bir deęerin altında seyretmesi ile veya maksimum iterasyon sayısına ulaşılması dolayısıyla sonlanır.

2.7.2. Rastgele Orman (RO)

Rastgele Orman (Random Forest, RF), karar ağaçlarına dayalı bir makine öğrenmesi yaklaşımıdır. Burada bir karar ağacının deęil birden çok ağacın birlikteliğinden oluşan bir orman yapısı söz konusudur. Ormandaki ağaçların her biri, yeni gelen girdi için bir sonuç üretir ve nihai sonuç, ormandaki tüm ağaçların ürettiği çıktının ortalaması veya oy birliği sonucudur. Ağaçların üretilmesi sırasında belirsizlik ölçütü olarak Gini veya Entropi hesabı yapılmaktadır ve belirsizliğin minimize edilmesi için gerekli en iyi bölümlendirmeyi sağlayan nitelik aranmaktadır. Karar ağaçlarında ağaç üretilmesiyle paralellik gösteren bu sürecin orman yaklaşımına geçildiğinde ürettiği en büyük farklılık her ağacın tüm veri kümesinin rastgele örneklenen farklı alt kümelerinden elde ediliyor olmasıdır. Bunun yanında tüm niteliklerin deęil bu niteliklerin de rastgele bir alt kümesinin bölümlendirme için kullanılıyor olması ağaçlardaki çeşitliliği artırdığından performansa olumlu etki sunmaktadır.

2.7.3. Aşırı Gradyan Artırma

Aşırı Gradyan Artırma (eXtreme Gradient Boosting, XGBoost), son yıllarda uygulamalı makine öğrenimi için özellikle tabular veride güçlü performans ve eğitimde paralellik sunması açısından avantajlı ve güçlü bir makine öğrenmesi modelidir. Hız ve performans için tasarlanmış gradient yükseltme çerçevesini kullanır, karar ağacı tabanlı bir uygulamadır.

2.8. Diyabet ve Büyük Veri

Diyabet ve büyük veri terimlerinin bir arada kullanıldığı ilk makale 2012’de yayımlanmıştır (Harrison, 2012). Bu makalede, büyük veri kullanarak klinik denemelerle

ilgili modelleme yapılacağından söz edilmektedir. Çalışmamızın konusu ile ilgili teorik bir makale 2013'te yayımlanmıştır. Bu makalede elektronik sağlık kaydından yararlanarak yapılacak büyük veri uygulamalarının halk sağlığı açısından önemli olabileceği anlatılmaktadır. Yazarlar, çeşitli kaynaklardan gelen verilerin hasta merkezli bir veri tabanında toplanmasını, sağlık riskleri ve finansal risklerle ilgili kümeleme (clustering) analizleri yapılmasını sağlayan bir sistem kurulmasını önermektedir. Bu şekilde bir sağlık riski veya finansal risk taşıyan hastaların önceden tahmin edilebileceği savunulmaktadır (Bradley, 2013).

MÖ çalışmalarında büyük veriye ihtiyaç vardır. Bu amaçla kullanılmak üzere anonim ve açık veri kaynağı sınırlıdır. Bu çalışma için yapılan araştırmalar sırasında en fazla karşılaşılan iki açık veri tabanı: 1) Pima Indians Diabetes Database (<https://www.kaggle.com>, 2016), 2) UC Irvine Machine Learning Repository'dir (Kahn, 1994). Bu veri setleri ile çok sayıda çalışma yapılmıştır. Açık kaynak yok denecek kadar az olduğu için birçok araştırmacı kendi amacına yönelik veri setlerini kendileri oluşturma gayretindedir. Bu da çoğu kez büyük veri kavramı ile çelişmektedir. Diğer taraftan diyabet odaklı çok sayıda MÖ çalışması vardır.

Kavakiotis ve arkadaşları 103 makaleyi inceledikleri çalışmada makaleleri beş kategoride sınıflandırmışlardır: 1) Diyabette biyobelirteç tahmini ve tanısı, 2) Diyabetik komplikasyonlar, 3) İlaçlar ve tedaviler, 4) Genetik geçmiş, 5) Çevre ve sağlık yönetimi. Çalışma sonucunda en yaygın kullanılan makine öğrenme tekniklerinin DVM, YSA ve KA olduğunu bulmuşlardır (Kavakiotis et al., 2017).

2017 yılındaki “Büyük veri analitiği kullanılarak diyabet veri setinde MÖ algoritmalarının performans analizi” adlı çalışmada Diabetes Mellitus üç tipe ayrılmıştır; 1) T1DM, “İnsüline Bağımlı Diabetes Mellitus” (IDDM) veya “juvenil diyabet”, 2) Diyabetik vakaların yaklaşık %95'ini oluşturan yetişkinlerde sıklıkla görülen T2DM “İnsüline Bağımlı Olmayan Diabetes Mellitus” (NIDDM) olarak adlandırmış, 3) Gebelik sürecine bağlı olarak kadınlarda ortaya çıkan hamile kadınların %2-10'unu etkileyen doğumdan sonra Tip 2 olarak devam edebilen ya da kendiliğinden düzelen Gestasyonel Diyabet. Bilindiği gibi T2DM'li hastalarda da zaman zaman insülin tedavisine başvurulabilmektedir. Bu durum klinik açıdan Tip 1 ve Tip 2 ayrımını zorlaştırmaktadır.

Yazarlar tam da bu noktaya işaret ederek makalenin temel amacını, diyabetin tipini tahmin etmek üzere MÖ yoluyla doğru tahminler elde etmek için uygun makine öğrenme modelini ortaya çıkarmak olarak bildirmişlerdir. Bu tahmin için RO, DVM, CART (Classification and Regression Trees), LDA (Latent Dirichlet Allocation) ve k-NN gibi farklı makine öğrenme algoritmalarını ele aldıkları çalışmalarında bu algoritmaların seçilmesinin nedeni, temsil çeşitliliği ve öğrenme stiline göre yarı rasgele algoritmaların seçilmesi, doğruluk, kesinlik, kappa değeri, geri çağırma, duyarlılık ve özgüllük gibi çeşitli ölçütlere dayalı en iyi tahmin algoritmasını belirlemek, farklı makine öğrenme algoritmalarını analiz etmek ve karşılaştırmak olarak açıklanmıştır. Bu çalışmanın sonucunda, RO algoritmasının sonuçları doğru tahmin ettiği ve verileri en doğru şekilde sınıflandırdığı gösterilmiştir. RO algoritması LDA, DVM, CART ve k-NN ile karşılaştırıldığında daha iyi doğruluk sağlamış, doğruluk değeri 0,99 olarak diğer tüm algoritmalar arasında en iyisi seçilmiştir. Bu algoritmanın kappa değeri 0,99 kesinlik değeri 1 ve recall değeri 1 olarak tespit edilmiştir (Kumar & Pranavi, 2017).

En yaygın kullanılan tekniklerin YSA, RO, DL, DVM, Evrimsel Algoritmalar (EA: Evolutionary Algorithm), NB, KA ve regresyon algoritmaları olduğu, bu sistemlerin genellikle üç ana bileşen içerdiği ve bunları bilgi edinme arayüzleri, kural ve bilgilerin bilgi tabanları ve çıkarım motorları olarak adlandırılabilceği, bu sistemlerin, diyabet açısından değerlendirildiğinde önceki vakalardan öğrenilen bilgilerin uzman bilgisi ile birleştirilmesinden belirsiz kavramların ve belirsizliğin çözümlenerek yeni vakalar için karar verme desteğinin sağlanabileceği, belirsizliğin çözümlenmesinde en yaygın olarak kullanılan tekniklerin, Kural Tabanlı Akıl Yürütme (RBR: Rule Based Reasoning), Vaka Tabanlı Akıl Yürütme (CBR: Case-Based Reasoning) ve Bulanık Mantık (FL: Fuzzy Logic) olduğu yakın geçmişte yayımlanan bir makalenin konusu olmuştur (Li et al., 2020). Bu çerçevede diyabetle ilgili uygulamaların amaçlarına bağlı olarak, yapay zekâ metodolojileri üç kategoride sınıflandırılmıştır: bilgiyi keşfetme, bilgiyi kullanmayı öğrenme ve bilgidan sonuç çıkarma (Contreras & Vehi, 2018).

Journal of Big Data'da 2019 yılında yayımlanan araştırmada şu veriler kullanılmıştır: cinsiyet, yaş, diyabet teşhis zamanı, genetik geçmiş, boy, kilo, VKİ, HbA1c, OGTT 2. saat dahil olmak üzere açlık ve tokluk gibi durumlarda ölçülen kan şekeri düzeyleri, kadınlarda

gebelik sayısı, arteriyel kan basıncı, cilt kalınlığı (triceps derisi kıvrım kalınlığı mm cinsinden), insulin düzeyi, serum kreatinin, serum sodyum, serum potasyum düzeyi ve sigara içme alışkanlığı. Bu çalışmada da PIMA Indian Diabetes DataSet karşımıza çıkmakta ve makalede bu DataSet'in neredeyse tüm diyabet ve yapay zekâ çalışmaları için bir standart haline geldiğine değinilmektedir. Bu set kullanılarak yapılan çalışmada yapay zekâ modellemeleri arasından en yüksek özgüllüğü verenler arasında ilk iki model KA %98,20 ve RO %98,00 olmak üzere diyabet verilerinin analizi için en iyi sonucu vermiştir. DVM %77,73 ve NB %73,48 doğruluk vermiştir (Sneha & Gangil, 2019).

2020 yılında yayımlanan bir derlemede, hasta verilerinin elektronik ortamlarda kaydedilmesinin şimdiye kadar klinik denemelerden elde edilen bilgilere ek olarak gerçek dünyadan elde edilen bilgilere ulaşmamıza yardımcı olacağı anlatılmaktadır (Zaccardi et al., 2020). Bu makaleye göre antidiyabetik ilaç kullanım profili ve antidiyabetiklerin etkinliğinin karşılaştırılmasının etyolojik ve demografik araştırmalara katkısı büyük olacaktır.

Angehrn ve arkadaşları Haziran 2020'de yayımladıkları çalışmada yapay zekânın diyabet alanında kullanımını 1) Evde izleme ve uzaktan yönetim, 2) Özellik algılama ve tanılama desteği, 3) Klinik karar destek sistemi, 4) Hassas dozlama olarak 4 başlık altında incelemiştir. Ayrıca, yapay zekânın etik ve hukuki yönüyle de ilgilenmiş, ihtiyaç duyulan düzenlemeleri tespit etmişlerdir (Angehrn et al., 2020).

Vu ve arkadaşları yaptıkları çalışmada, diyabet teşhisi ve yönetiminde yapay zekânın uygulanmasıyla ilgili ortaya çıkan ilk beş araştırma alanını bulmuşlardır. Bunlar; 1) Diyabet tanısında yapay zekâ kullanımı, 2) Diyabet risk değerlendirmesi ve komplikasyonları, 3) Diyabette yeni tedaviler ve izlemede yapay zekânın rolü, 4) Diyabetin günlük yönetiminde tele-sağlık ve giyilebilir teknoloji uygulamaları, 5) Diyabetlilerde robotik cerrahi sonuçlarıdır. 1991-2018 yılları arasında diyabette yapay zekâ araştırmalarına artan bir ilginin olduğunu açıkladıkları çalışmalarında, 2014-2018 döneminde yayınlanan 372 makalenin üçte ikisinin bu alanda oluşunun bu ilgiyi ortaya koyduğu ifade edilmiştir. Ayrıca etik konular, özellikle hasta verilerinin mahremiyeti ve gizliliğinin, mevcut literatürde bir tartışma konusu olduğu vurgulanmıştır (Vu et al., 2020).

Diyabet hastalarının verilerini tek bir veri tabanında toplamak suretiyle büyük veri geliştirme çalışmaları vardır. Bunlardan biri de gönüllü T1DM hastalarının verilerini toplamayı amaçlayan “T1D Exchange Clinic Network” inisiyatifidir (Miller et al., 2013). Bu kapsamda 2020 itibarı ile ABD’deki 81 merkezden 30 bini aşkın gönüllünün verisi toplanmıştır (Casu et al., 2020). Birleşik krallıkta da diyabet hastalarının sayısını ve gereken kontrollerin yapılıp yapılmadığını takip etmeyi amaçlayan NHS (National Health System) tarafından yürütülen “Core National Diabetes Audit” sistemi kurulmuştur (<https://digital.nhs.uk/data-and-information/clinical-audits-and-registries/national-diabetes-audit/core>, Erişim Tarihi: 18.09.2021).

Haneef ve arkadaşları, 44.659 katılımcının tıbbi ve idari verilerinin dahil edildiği büyük veri çalışmasından elde ettikleri sonuçları T2DM gelişimini etkileyen faktörleri belirlemek (Fransa Ulusal Sağlık Veri Tabanı SNDS: Système National de Données Santé: French National Health Database) ve dolayısıyla sağlık politikasını iyileştirmek amacıyla kullanmaya çalışmışlar, risklerin etkisini doğru belirlemek için daha fazla çalışmaya ihtiyaç olduğu sonucuna varmışlardır (Haneef et al., 2021).

Diyabetle ilgili teorik olmayan büyük veri çalışmaları 2013’ten itibaren yayımlanmaya başlamıştır. Bu tarihten itibaren yüksek sayıda diyabet hastası ile yapılan önemli çalışmalardan bir kısmı Tablo 2.1’de özetlenmiştir.

Tablo 2.1. Diyabetle ilgili bazı büyük veri çalışmaları

Yazar	Yıl	Ülke	Veri kaynağı	Hasta sayısı	Hasta türü	İnceleme konusu	İnceleme tekniği
(Maguire, 2013)	2013	ABD	Sigorta şirketi	66 bin	+18 yaş, tip II	Antidiyabetiklerin etkinliği	Karar ağacı, OLS regresyon
(Takahashi et al., 2014)	2014	Japonya	21 önleyici sağlık merkezi	265 bin	20-79 yaş tüm bireyler	Hb, HbA1c ve açlık kan şekeri arasındaki ilişki	Korelasyon analizi
(Razavian et al., 2015)	2015	ABD	Sigorta şirketi	4,1 milyon	+18 yaş, tip II	Diyabet risk faktörleri	L1 düzenlemeli loj. regresyon
(Kauhl, 2016)	2016	Almanya	Sigorta şirketi	361 bin	Tip II	Lokalizasyona göre diyabet risk faktörleri değişiyor mu?	Kernel density estimation, geographically weighted regression

Tablo 2.1.’in devamı

Yazar	Yıl	Ülke	Veri kaynağı	Hasta sayısı	Hasta türü	İnceleme konusu	İnceleme tekniği
(Y. Chen et al., 2017)	2017	Doğu ve Güney Asya ülkeleri	20 farklı kohort verisinin toplamı	847 bin	Tip II	Tip II diyabetle kanser arasında ilişki var mı?	Cox regresyonu
(Lee et al., 2017)	2017	Güney Kore	Ulusal Sağlık Sigorta Kurumu	12,8 milyon	Normoglisemi, bozulmuş açlık glükozu, diyabet	Diyabet ve VKİ ile mortalite arasındaki ilişki	Cox regresyonu
(Heald et al., 2018)	2017	Birleşik Krallık	UK National Diabetes Audit	1,6 milyon	Tip II	Glisemik kontrolü etkileyen faktörler	Lineer regresyon
(Ahlqvist et al., 2018)	2018	İsveç	Beş farklı kohort	15 bin	Tip I ve II	Komplikasyon riski yüksek hastaları belirlemek	k-means ve hiyerarşik kümeleme
(Makino et al., 2019)	2019	Japonya	Hastane bilgi sistemi	64 bin	Tip II	Diyabetik böbrek hastalığının öngörülmesi	Convolutional autoencoder, lojistik regresyon, Kaplan-Meier
(Koren et al., 2019)	2019	İsrail	Sağlık sigorta kurumu	29 bin	Tip II	Diyabet için kullanılmayan ilaçların kan şekeri üzerine etkisi	Karar ağacı, “fully connected” sinir ağı
(Song et al., 2020)	2020	ABD	Hastane bilgi sistemi	14 bin	+18 yaş, gestasyonel olmayan	Kronik böbrek hastalığı riski	Gradient Boosting Machine
(Ruan et al., 2020)	2020	Birleşik Krallık	Hastane bilgi sistemi	18 bin	Tüm diyabetler	Yatan hastalarda hipoglisemi riski	Lojistik regresyon, Extreme Gradient Boosting
(Y. T. Kim et al., 2020)	2020	Güney Kore	Ulusal Sağlık Sigorta Kurumu	490 bin	Diabetes mellitus	Hipertansiyon kategorilerine göre kardiyovasküler hastalık ve böbrek hastalığı riski	Hazard oranı
(S. M. Kim et al., 2020)	2020	Güney Kore	Ulusal Sağlık Sigorta Kurumu	2,5 milyon	20-39 yaş diyabet ve kardiyovasküler hastalığı olmayanlar	Yeni diyabet ve prediyabet tanısı konanlarda kardiyovasküler hastalık riski ve mortalite	Cox regresyonu

Diyabeti önlenmesi ve/veya ortaya çıkışının geciktirilmesi için riskli grupların tahmin analizleri, hastalığın toplumsal ve bireysel bazlı yönetimi, tanısal tahmin analizleri, tedavi

analizleri, klinik karar destek sistemleri, kan şekeri düzeyi kontrolünün sağlanmasına yönelik analizler, beslenme, hasta eğitimi, tanı ve tedaviye yönelik cihaz araştırma ve geliştirme çalışmaları dahil hastalığı çeşitli yönleriyle ele alan çok sayıda makine öğrenmesi çalışmaları yapılmıştır. Literatürde diyabet ve makine öğrenmesi hakkında, sayısı binlerle ifade edilebilecek kadar çok araştırma sonucuna ulaşılabilmektedir.

2.8.1. Diyabette Makine Öğrenmesi ile Risk Tahmin Çalışmaları

Hastalık ve komplikasyonları önlemek ya da geciktirmek oldukça önemli olduğundan dolayı T2DM gelişme riski yüksek olan hastaların erken tespitine yönelik çok sayıda araştırma mevcuttur. Buna rağmen risk gruplarının belirlenmesi ve takibinde ciddi kaçaklar vardır (Bertram & Vos, 2010). T2DM'nin gelecekteki gelişiminin en güçlü belirteci olarak kabul edilen insülin direnci, tanı konmadan önceki döneme ait risk gruplarını belirlemek için iyi bir tespit aracıdır (Taylor, 2012). İnsülin direnci arttıkça, insülin sekresyonunda daha fazla bozukluk meydana gelir ve sonunda hiperglisemi ortaya çıkar (Cerf, 2013). İnsülin direncinin ölçüm ve klinik değerlendirmelerinin birinci basamak sağlık hizmetinde çalışmakta olan pratisyen hekimlerce daha yoğun kullanılması halinde T2DM'nin epidemiyolojik kontrolünün daha da iyileşeceği düşünülmektedir. Birinci basamakta kolaylıkla çalışılabilen tetkiklerden olan trigliserit ve glukoz ölçümlerine dayanan trigliserit-glukoz indeksi yoluyla insülin direnci için kaba bir sonuç elde edilebileceğini bildiren yayınlara literatürde rastlamak mümkündür (Guerrero-Romero et al., 2010). Ayrıca trigliserit-glukoz indeksinin, T2DM riski altındaki bireylerin erken teşhisi için klinik çalışmalarda faydalı olduğu kanıtlanmış ve klinikte tahmin değerinin tek başına trigliserid ya da tek başına glukoz ölçümlerinden daha güçlü olduğu gösterilmiştir (Navarro-González et al., 2016). Dolayısıyla trigliserit-glukoz değişikliklerini öngören bir KKDS, T2DM riski yüksek olan hedef grupların belirlenmesi bakımından pratisyen hekimleri yönlendirici bir araç olarak iyi sonuçlar sağlayabilir.

Razavian ve arkadaşları 2005 ve 2009 yılları arasındaki 4,1 milyon kişinin idari ve tıbbi kayıtlarından bir veri seti oluşturmuşlardır. Daha sonra her bireyin tam sağlık durumu ve geçmişinin tanımlandığı bir eğitim seti oluşturup MÖ teknikleri kullanmışlardır. Bu sayede 2009–2011, 2010–2012 ve 2011–2013 yılları için T2DM'nin nüfus düzeyinde tahmini ve risk faktörlerinin analizini yapmışlardır (Razavian et al., 2015).

Normoglisemik bir durumdan prediyabete ve/veya diyabete giden süreçte risk faktörleri ve belirteçlerin neler olabileceğinin ortaya konması, risk altındaki hastaların tanımlanması ve zamanında müdahale ile hastalığın önlenmesi, tıbbi ve mali kaynakların doğru kullanımını sağlaması bakımından herkes için yüksek değerdedir. Bu amaçla, ABD'de yaşayanların klinik kayıtlarından oluşmuş Humedica Inc (www.humedica.com) tarafından sağlanan veri seti ile çalışılmıştır. 2007-2012 yılları arası döneme ait tanı, demografi, reçete ve laboratuvar değerleri, vital ölçümleri içeren veri seti ile hipotezsiz bir MÖ yaklaşımı kullanarak doğru tahmin modelleri oluşturmak üzere Tersine Mühendislik ve İleri Simülasyon (REFS: Reverse Engineering and Forward Simulation) modeli kullanılmıştır. T2DM için risk faktörlerinin tanımlanması, REFS tarafından seçilen yeni faktörlerin açığa çıkarılması, kişiselleştirilmiş tıp ve klinik araştırmalara yönelik yeni potansiyellerin belirlenmesi için mevcut veri örneğinde normoglisemik kişilerde prediyabet veya T2DM'ye yakalanma tahmin modelinde prediyabet veya T2DM gelişimi için 24.331 yetişkin geriye dönük olarak incelenmiştir. Normoglisemiden T2DM'ye, normoglisemiden prediyabete ve prediyabetten T2DM'ye ilerleme olmak üzere üç senaryoya bakılmıştır. Ardışık glukoz ölçümü yapılmış olanlarda en erken tarihteki yüksekliğin tespit edildiği tarih, prediyabet olarak kabul edilmiştir. Belirlemede açlık glukozu ≥ 110 mg/dl, 2 saatlik oral glukoz toleransı ≥ 140 mg/dl, rastgele glukoz ≥ 140 mg/dl veya HbA1c $\geq 5,7$ olarak tanımlanmıştır. REFS kullanarak, ESK tahmin modellerinin doğruluğu, eğrinin altındaki alan (AUC: Area Under The ROC) istatistiği kullanılarak değerlendirilmiş ve bağımsız bir veri setinde doğrulanmıştır. Normoglisemiden T2DM'ye ilerleme senaryosunda yüksek bir tahmin değeri bulunmuş, HDL ile prediyabete ilerleme hızı arasında orta derecede ters ilişki olduğu ortaya konmuş, ALT yüksekliğinin prediyabetin bir göstergesi olarak ele alınabileceği düşünülmüştür (Anderson et al., 2016).

Dagliati ve arkadaşları “Diyabet Komplikasyonlarını Öngörmek için Makine Öğrenmesi Yöntemleri” adlı çalışmalarında 1.000 T2DM'li hasta verisi ile MÖ modelleri kullanarak kronik mikrovasküler komplikasyonların başlangıcı için öngörücü modeller geliştirmek istemişlerdir. Bireysel faktörlere maruz kalma ile belirli bir komplikasyonun başlama riski arasındaki ilişkinin değerlendirilmesine ve bir tıp merkezindeki hasta popülasyonunun buna göre sınıflandırılmasına katkıda bulunabilecekleri sonucuna ulaşmışlardır. Hasta

sayısı az olmakla birlikte, Avrupa Birliği projesi kapsamında yapılan MOSAIC adındaki bu çalışmada diyabet komplikasyonlarının tahmin edilmesi için LR, NB, DVM ve RO teknikleri kullanılmıştır (Dagliati et al., 2018).

Mikroalbüminüri, diyabetik nefropatinin iyi bir göstergesidir (Ninomiya et al., 2009). Kronik böbrek hastalığı, T2DM'nin yaygın bir komplikasyonudur ve hastaların %30-40'ını etkiler (de Boer et al., 2011). Diyabetin ilerleyen aşamalarında ortaya çıkan böbrek hastalıkları son dönem böbrek hastalığı (ESRD: End Stage Renal Disease) olarak devam eder ve diyaliz tedavisi gerektirir. Bu nedenle böbrek hastalıkları diyabetli vakaların takibi bakımından özel bir öneme sahiptir. Elektronik tıbbi kayıtlara dayalı büyük veri kullanarak MÖ ile diyabet hastalarında yeni bir diyabetik böbrek hastalığı tahmin modeli oluşturulan çalışmada, 858.660 kayıttan 451.584 vakanın klinik verileri çıkarılmış, aranan kriterlere göre 64.059 hasta T2DM olarak tanımlanabilmiş ve çalışmada kullanılmıştır. Model çözümü için scikit-learn kütüphanesi (<https://scikit-learn.org/>) ile Python kullanılarak lojistik regresyon uygulanan süreçte yapay zekâ, 3.073 özellik ile tahmine dayalı modeli oluşturmuştur. Model, diyabetik böbrek hastalığı şiddetlenmesini %71 doğrulukla tahmin etmiştir (Makino et al., 2019).

Hindistan'ın kırsal kesimlerinde yaşayanların, T2DM açısından risk grubunda olanlarını daha erken aşamalarda tespit edebilmek için risk faktörlerini ve bu risk faktörleri arasında var olan korelasyonları bulmayı amaçlayan çalışmada LR, DVM, RO, KA, Naive Bayes (NB), k-NN modelleri tahmin için kullanılmış ve seçilen algoritmalar arasında en yüksek doğruluk değerini 0,96 ile DVM sağlamıştır (Rajput et al., 2021).

2.8.2. Diyabette Tanı Tahmini İçin Makine Öğrenmesi Modelleri

Diyabet ve yapay zekâ teknikleri söz konusu olduğunda ırksal farklılık göstermesine rağmen retina görüntülerinin yapay zekâ teknikleri ile işlenmesi, en çok karşılaşılan araştırma konusudur. Retinopati, beyazlara kıyasla siyah ırka mensup kişilerde daha düşük HbA1c düzeylerinde bile yaygın olarak bulunmuştur (Tsugawa et al., 2012).

Kulak klipsi ile ultrasonik, elektromanyetik ve termal teknolojileri kullanarak, kol bacak gibi uzuvlara takılan hareket algılayıcıları kullanarak, tükürük numunelerini kullanarak, akıllı kontakt lens ile gözyaşını kullanarak glukoz ölçen teknikler üzerindeki çalışmalar,

yapılmış olanlardan bazılarıdır. Bir başka araştırmada tükürük, ter gibi vücut salgılarından kan glukoz düzeyleri izlenmeye çalışılmıştır (Makaram et al., 2014).

Diyabet tanısı almış ya da yüksek riskli grupların kan glukoz düzeylerinin takibi hayati öneme sahiptir. Ölçümlerin düzenli ve hatta mümkünse insan fizyolojisini taklit edecek şekilde sürekli ve invaziv olmayan yollarla yapılabilmesi için çok sayıda yöntem geliştirme araştırması yapılmış ve halen yapılmaktadır. Vücut dışından olmak üzere çeşitli kromoskopik, spektroskopik renk skala algılayıcıları; transdermal olarak ters iyontoforez ve sonoforez, invaziv olmayan tekniklerden bazılarıdır (Zarkogianni et al., 2015).

Mercaldo ve arkadaşları diyabet teşhisine yardımcı olmak ve tanıyı hızlandırmak için Dünya Sağlık Örgütü kriterlerine göre seçilmiş bir dizi karakteristik ile Hoeffding Tree algoritmasını kullanarak diyabetten etkilenen hastaları sınıflandırabilen bir yöntem önermişlerdir (Mercaldo et al., 2017).

Sinir sistemi ve dolaşım sistemindeki bozulmalara bağlı olarak diyabetli vakalarda ayaklarda sıkça ciddi problemlere raslanır (Boulton et al., 2005). Ülserasyon ve doku kaybı ile sonuçlanabilen, dolayısıyla amputasyona kadar varan sonuçları sebebiyle bu, hem hasta hem hekim tarafından dikkatle yönetilmesi ve gözden kaçırılmaması gereken bir durumdur. Diyabetlilerde ayağın görünümü zaman içinde değişikliğe uğradığından bu değişikliklerin izlenmesi, diyabetik ayak bulgularının saptanması ve izlenmesinde gelişmiş görüntü işleme algoritmalarının kullanılmasının iyi bir fikir olabileceği düşünülmüştür. Bunun için görüntü elde etme koşullarının da standardize edilmesi şarttır. Örneğin görüntü almadan önce kişilerin aynı pozisyonda durması, yatırılması ya da ayaklarını sarkıtarak oturtulması gibi. Ortam ışık miktarı, ışık açısı, kamera çözünürlüğü, görüntüleme açısı, ayak-kamera arası uzaklık gibi tüm parametrelerin standardize edilmesi gerekir. Görüntü işleme tekniklerini kullanarak diyabetik ayak değerlendirmesi yapılmak istenen bir çalışmanın sonuçları 2017 yılında yayımlanmıştır. Çalışmada bir iPad kullanılmış, cihaz ile uyumlu FootSnap adı verilen bir mobil uygulama geliştirilmiş, karşılaştırmada referans değerler sağlamak için diyabetik olmayan sağlıklı kişiler de çalışmaya alınmıştır. Ayak görüntülerinin işlenmesinde, Jaccard benzerlik indeksi (JSI) ve k-ortalama kümeleme algoritması kullanılmıştır. Yaşları 43 ile 74 arasında değişen diyabetli veya ayak patolojisi olmayan 15 diyabet hastasının ayak görüntüleri çalışmaya

alınmıştır. Yine yaşları 20 ile 40 arasında değişen 15 sağlıklı kontrol vakasına ait her iki ayak görüntüsü kullanılmıştır. Görüntüler iki ayrı kişi tarafından ayrı ayrı çekilmiş, toplam 240 ayrı ayak görüntüsü oluşturulmuş ve görüntü analizleri sonucu uygulamanın diyabetik ayak tespitinde başarılı sonuçlar verdiği belirtilmiştir (Yap et al., 2017).

Spänig ve arkadaşları konuşma tanıma ve konuşma sentez sistemi kullanarak bir hastayla özerk bir şekilde sanal doktor olarak etkileşime girebilen bir yapay zekâ modeli geliştirmişlerdir. Özellikle kırsal alanlarda yaşayanlar için bir kavram kanıtı olarak geliştirilmiş olan sistem, invaziv olmayan sensörlere ve derin sinir ağlarına dayalı olarak T2DM'yi tahmin edebilmiştir (Spänig et al., 2019).

Mullan ve arkadaşları 2019 yılında bir derleme çalışması sunmuşlardır. Çalışmada 96 adet retina taraması, 135 adet tahmine dayalı modelleme ve risk sınıflandırması, 126 adet klinik karar desteği, 94 adet hasta diyabet öz yönetim makalesi incelemişlerdir. Bu tarama sırasında diyabet ve yapay zekâ alanındaki gelişmeleri raporlamak üzere yayınlanan teknik makale sayısının 2008 yılında 2600'den, 2013 yılında 5500'den, 2017'de 10.000'den fazla olduğunu bildirmişlerdir. Araştırmalardaki yapay zekâ yaklaşımlarının dört alanda hızla ilerlediğini, bunların; 1) Diyabetik Retinopati (DR) ve maküler ödem taraması ve tespiti, 2) Bireyselleştirilmiş tahmine dayalı risk sınıflandırması ve tedavisi, 3) Klinisyenler için karar destek araçları ve 4) Hasta öz-yönetim yardımcıları olduğunu ifade etmişlerdir. Çalışmada, ikincil körlüğün en ciddi nedeni olan DR'nin %98'inin gelişmiş tahmin, erken teşhis ve tedavi stratejileri ile önlenabilir olduğu, gereksiz acil servis ziyaretlerinin önlenmesinde diyabet popülasyonlarını proaktif olarak tanımlamak üzere yapay zekâ tabanlı modelleme çalışmalarının önem arz ettiği, doktorlar ve diğer sağlık çalışanları için pratik karar destek araçları sağladığı, MÖ yaklaşımlarının, doktorların, diyabet ilaçlarını kişiye özelleştirmesine yardımcı olduğu, yapay zekâ ve modern teknolojik cihazlar (sensorler, pompalar, akıllı telefonlar vb) sayesinde invaziv olmayan yöntemlerle ölçümlemenin her bakımdan olumlu sonuçlar elde edilmesini sağladığı, örneğin diyabetik nöropatinin şiddetini izlemek, diyabetik yaraların değişimini gözlemek ve kayıt altına almak gibi olanaklar sunduğu, hiper/hipoglisemiye azaltmak ve diyabet öz bakımını iyileştirmek için sürekli glukoz ölçümünü algoritmik insülin pompalarıyla birleştiren ve kapalı döngü bir sistem olarak da bilinen "yapay pankreas"

çalışmalarının önemli olduğu anlatılmıştır. Hatta sınıfının en iyisi olan uygulamaların, kullanıcıya barkodu taradıktan sonra besin içeriğini söyleyen, restoran menü öğelerini veya popüler yemekleri adlarına göre aramalarına veya bir tabaktaki yiyecekleri tanımlarına olanak sunan kapsamlı beslenme veritabanları da içerdiği belirtilmiştir. Çalışmanın en çarpıcı bölümlerinden biri ise araştırmacıların çoğunun çeşitli nedenlerle yaptıkları çalışmanın kaynak kodlarını paylaşmadıklarıdır. Son birkaç yılda gerçekleşen en iyi iki yapay zekâ konferansında sunulan makalelere ait 400 algoritma üzerinde yapılan bir ankette, sunum yapanların sadece %6'sının algoritmanın kodunu paylaştığı bildirilmiştir. Ayrıca, üçte birinin algoritmalarını test etmek için kullanılan verileri paylaştığı ve sadece yarısının, kaynak kod algoritmasının sınırlı bir özetini paylaştığı ortaya konmuştur (Dankwa-Mullan et al., 2019).

Xiang ve arkadaşları diyabetin göz dibinde neden olduğu tahribatın görüntüleri üzerinden MÖ metoduyla hem Tip 1 hem Tip 2 diyabetin hızlı ve invaziv olmayan bir teknik ile teşhisine dair bir teknik önermişlerdir (Yang et al., 2021).

Diyabeti önleme, risk tahmini, takip ve tedaviye yönelik olarak geliştirilen modellerden bazıları onay alarak ticari ürünlere dönüşmüştür. Örneğin, birlikte çalışabilir sürekli subkutan insülin infüzyonu (CSII: Continuous Subcutaneous Insulin Infusion) pompası ve sürekli glukoz izleme (CGM: Continuous Glucose Monitoring) konfigürasyonları için mevcut ticari ürün onaylarının yanı sıra ilk kapalı döngü yapay pankreas sistemi (Forlenza et al., 2019; Garg et al., 2017); Gerçek zamanlı sürekli glukoz monitörü (Shah et al., 2018; Wadwa et al., 2018) ve hipoglisemiye önlemeye yönelik glukoz süspansiyon sistemlerinin (WoodMichael et al., 2018) ticari onayları mevcuttur.

2.8.3. Diyabet Yönetiminde Makine Öğrenmesi Çalışmaları

Cichosz ve arkadaşları 2016 yılında gerçekleştirdikleri çalışmada, diyabette yaygın olan kısa ve uzun vadeli komplikasyonların taranmasında ve yönetiminde öngörücü modeller hakkındaki literatürü gözden geçirmeyi amaçlamışlardır. Çalışmada Diyabet ve komplikasyonlarının yönetimi için tahmine dayalı modellerle ilgili yayınların sayısının son on yılda artış gösterdiği, tahmin modeli geliştirmek için genellikle çoklu lojistik veya benzer bir doğrusal regresyon kullanıldığı belirtilmiştir. Araştırmacılar tahmin modellerinin faydalı olması için pozitif etkileyici sonuçlar göstermeleri gerektiği, yani

daha iyi hasta sonuçları üretmesi gerektiği, tahmine dayalı modelleri oluşturmak için yoğun çaba sarf edilmesine rağmen etki araştırmalarında dikkate değer bir azlığın olduğu sonucuna ulaşmışlardır. Günlük uygulamadan elde edilen kanıtlar eksik olsa da tahmine dayalı modellerin sağlık hizmeti sağlayıcılarının sofistike teknolojileri kullanma şeklini değiştirme potansiyeline sahip olduğu ve elektronik olarak depolanmış büyük miktarda klinik veriden yararlanılarak daha fazla çalışma yapılması gerektiği vurgulanmıştır (Cichosz et al., 2016).

Sağlık hizmetlerine erişimi iyileştirmeyi, hastaların gereksiz yer değiştirme ve mükerrer başvurularını önlemeyi, hasta başına değerlendirme süresini kısaltmayı ve gestasyonel diyabetin olumsuz sonuçlarını önlemeyi amaçlayan ve SINEDIE adı verilen sistem, İspanya'daki Parc Tauli Üniversite Hastanesi'nde gestasyonel diyabetli 90 hastanın katılımıyla 17 ay boyunca klinik olarak değerlendirilmiştir. Sinedie'nin, tedavi düzenlemeleri hakkında güvenli tavsiyeler ürettiği, klinisyenlerin iş yükünü azalttığı ve doktorların hangi hastaların daha acil veya daha kapsamlı muayeneye ihtiyaç duyduğunun belirlemede yardımcı olduğu ifade edilmektedir. Ek olarak, Sinedie'nin, hastaların mükerrer başvuru ve yer değiştirmelerini önlediği, sağlık hizmetine erişimi kolaylaştırıcı etkisi bulunduğu tespit edilmiştir (Caballero-Ruiz et al., 2017).

Abhari ve arkadaşları 2019 yılında yayılmadığı çalışmada yapay zekâ tekniklerinin T2DM için %45 oranında sağlık taramaları, %26 oranında tanı ve komplikasyonları belirlemek amacıyla kullanıldığını belirtmiştir. YSA, DVM, KA, NB, doğal dil işleme, robotik, bulanık mantık, uzman sistemler gibi tekniklerin çeşitli kombinasyonlarının birlikte kullanımından daha başarılı sonuçlar elde edileceği bildirilmiştir (Abhari et al., 2019).

Elektronik ortamda sunulan hizmetlerin akışını sağlıklı hale getirmek, artan son kullanıcı soru ve sorunlarına robotik yöntemlerle çözüm üretmek her zaman maliyet/etkinlik için kullanılıyor olmayabilir. Chatbot adı verilen MÖ temelli yazılım ürünleri, hem sesli hem de yazılı iletişim yoluyla insan geri bildirimlerini taklit etmeyi amaçlayan bilgisayar yazılımlarıdır. Chatbot'lar glisemi yönetimi için de kullanılmaktadır (Stephens et al., 2019). Diyabetli insanları anlamak ve onları tedavi ve öz bakımları bakımından motive

etmek için sohbet robotunun kullanımını araştıran çalışmalar devam etmektedir (Thompson & Baranowski, 2019).

Ellahham tarafından Ağustos 2020’de yayımlanan çalışma yapay zekânın diyabet hastalığının teşhis ve yönetiminde bir reform sağlayabileceğini belirtmektedir. Sadece semptomların ve biyobelirteçlerin sürekli ve zahmetsiz bir şekilde uzaktan izlenmesi değil sosyal medya ve çevrimiçi topluluk iletişim ortamının, hastaların diyabet bakımına katılımını artırması ile iyi bir glisemik kontrol sağlandığı ifade edilmiştir (Ellahham, 2020).

Diyabetik bireylere yardımcı olmak için EMPOWER, MOBIGUIDE, COMMODITY12 EU, DIADVISOR, DIABEO ve PEPPER dahil olmak üzere kamu tarafından finanse edilen birçok yapay zekâ araştırma projesi yürütülmüştür. Ülkemizin koordinatörlüğü üstlendiği PROEMPOWER 2 projesi T2DM’li hastaların öz bakım süreçlerini geliştirme amacını taşıyan bir Avrupa Birliği projesidir (<https://proempower-pcp.eu/>. Erişim Tarihi: 06.12.2021).

Diyabetin hasta düzeyinde yönetimi için geliştirilmiş modeller vardır. Örneğin; KADIS Karlsburg Diyabet Yönetim Sistemi (Rutscher et al., 1990), AIDA etkileşimli eğitici diyabet simülatörü (Lehmann et al., 2006) ve DIAS diyabet danışma sistemi (Pedersen et al., 2003), insülin/glukoz değerlerinin etkileşimli simülasyonuna odaklanan model tabanlı sistemlerin önceki dönemlere ait örnekleridir. AIDA ve DIAS ortalama diyabetik hastada genel etkileri tahmin ederken, KADIS günlük yaşam koşulları altında kişiselleştirilmiş metabolik müdahale ile birlikte glukoz profillerinin bireyselleştirilmiş değerlendirilmesine izin veren bir sistem olarak tanımlanmaktadır. Literatürde The Diabetes Care Protocol (TDCP) (Cleveringa et al., 2008), COMPETE II çalışması (Holbrook et al., 2009), CareManager aracı (Hunt et al., 2009), The Diabetes Wizard (O’Connor et al., 2011) gibi çalışmalara rastlanmıştır.

Tedavi ve bakım planına uyum, diyabet tedavisinin önemli bileşenlerinden biridir. İlaç kullanımını engelleyebilecek sorunları belirleme ve iyileştirmeye yönelik stratejiler hakkında hasta, hekim ve eczane iletişimini kolaylaştırma potansiyeline sahip entegre bir bilişim yaklaşımının uygulanabilirliğinin değerlendirildiği 2016 yılında yapılan bir

çalışmada tıbbi kayıtlar, eczane kayıtları ve bir hasta portalı olmak üzere üç kaynaktan gelen verileri kullanarak geliştirilen bir klinik gösterge panosunun, tedavi ve bakım planına uyumu %6-20 arasında değişen oranlarda iyileştirmiş olduğu gösterilmiştir. Az sayıda hasta ile yapılan bu çalışma sonucunda tarafları bir araya getiren entegre yaklaşımların, ilaç kullanımı ve bakım planına uyumu iyileştirme ve kronik hastalıkların daha iyi yönetimini destekleme konusunda umut verici olduğu açıklanmıştır (Dixon et al., 2016).

Ghoddusi Johari ve ark. (2018) Önceden oluşturulmuş mevcut diyabet rehberlerinin incelenerek diyabet tarama ve yönetimi akış şemalarının tasarlandığı, tarama endikasyonu belirlemenin de dahil edildiği tasarıma uygun web tabanlı bir yazılımın geliştirilerek kullanıma alındığı, mevcut kriterlere göre iş akışlarının geliştirildiği, yüksek riskli diyabetliler için otomatik tetkik istemlerinin oluşturulabildiği, uygun endikasyonlar için uygun reçete olanağının sunulduğu uçtan uca geliştirilmiş bir yazılımın uygulama sonuçlarını raporlamışlardır. Çalışmada, geliştirilen sistemin oral antidiyabetik kullanan diyabet hastalarının test sonuçlarının kılavuz tanımına göre normal bulunduğu, sistemin kontrol altına alınamayan hiperglisemili hastalarda tek ilaçla tedavi ediliyorsa ilaç dozunun maksimum doza kadar artırılmasını önerdiği, hasta iki ilaç kullanıyorsa ikinci ilacın maksimum doza kadar artırılması ve bu durumda hastanın hiperglisemisi devam ediyor ve her iki ilaç da maksimum doza ulaşıyorsa üçüncü ilaca başlanmasını önerdiği, buna rağmen kan şekeri kontrolünün sağlanamadığı durumlarda hastanın insülin tedavisine başlatılması için bir endokrinoloji uzmanına yönlendirildiği, tüm diyabetli hastalarda ilk muayenede göz hekimi konsültasyonunun istendiği, endikasyonlara göre nefroloji, nöroloji ve damar cerrahisi konsültasyonlarının önerildiği belirtilmiştir. Senaryo bazlı olmak üzere 50 vakanın plazma glukozuna göre tasarlanmış üç gruba ayrıldığı ve her grubun yazılım ile ayrı ayrı değerlendirilerek yazılımın geçerliliğinin onaylandığı web tabanlı sistemin zamanında kayıt, diyabet prevalansı raporları, kontrolsüz diyabet, diyabet komplikasyonları ve diyabetin kötü yönetim oranını azaltarak hekimlerin hastaları ve hastalıklarını daha iyi yönetmesine yardımcı olabildiği belirtilmiştir (Ghoddusi Johari et al., 2018).

Bir sađlık tesisine mükerrer başvuru oranı diyabetli hastalarda daha yüksektir. Taburculuktan sonraki 30 gün içerisinde tekrar başvurunun mükerrer başvuru olarak kabul edildiđi 70.000'den fazla tekil hastaya ait verilerle yapılan bir öđrenci grubu alıřmasında mükerrer başvurunun nedenlerinin aıđa ıkarılması için KA, RO ve LR modelleri kullanılmıřtır. 23'ü ilaç olmak üzere 50'den fazla özellik 1999- 2008 yılları arasında geen 10 yıllık zaman serisinde yatan hastalara ait 101.766 diyabet hastası verileri kullanılmıřtır. alıřmanın sonunda verilerin ön iřleme yöntemlerinin, modellerin ıktılarını önemli ölçüde etkileyebileceđini, aynı veri setini kullanan önceki alıřmaları ile karřılařtırıldıđında, anormal HbA1c deđerlerinin ilaç deđiřikliđi üzerindeki bađımsız etkisini, sonu tahmini ile ilgili olarak, diđer modellerin, karar sınırları dođrusal olmadıđında lojistik regresyondan daha iyi performans gösterdiđini belirtmiřlerdir (Lin et al., 2018).

Hong Kong'daki 43 kamu hastanesinden veri toplayan bölgesel aplı bir gözlemsel alıřmada hayatta kalma analizi için bir MÖ modeli olarak tanımlanan Random Survival Forest (RSF) (Ishwaran et al., 2008) üzerine bir arařtırma yapılmıřtır. Breiman'ın RO algoritmasından üretilmiř olan RSF'nin, girdi deđiřkenleri içindeki varyansı ve yanlılıđı azaltabildiđi ve bu deđiřkenler arasındaki dođrusal olmayan etkileri ve üst düzey etkileřimleri otomatik olarak dikkate alabildiđi böylece, deđiřkenlerin önemlerine göre seimi ve sıralanmasında avantaj sunduđu, diyabette glisemi ve lipid deđiřkenliđinin deđerlendirmesi için kullanıldıđı, 1 Ocak 2009 - 31 Aralık 2019 arasındaki 10 yıllık dönemde ait hasta verilerinin iřlendiđi ve tüm hastaların izlendiđi, özel olarak nörolojik, oftalmolojik ve renal diyabetik komplikasyonlar, demans, osteoporoz, periferik damar hastalıkları, intrakraniyal kanama, inme ve geici iskemik atak, iskemik kalp hastalıđı, akut miyokard enfarktüsü, kalp yetmezliđi, atriyal fibrilasyon yönünden takiplerin yapıldıđı, alıřma kohortuna 25.186 hastanın dahil edildiđi, alıřma süresi boyunca 12.372 ölümün gerekleřtiđi, en sık görülen olumsuz sonucun ölüm olduđu (%49.1), hastalarda %21,4 böbrek, %18,7 oftalmolojik diyabetik komplikasyonlar, %39,1 anemi geliřtiđi, tedavisinde Tiazolidindion bulunanlarda nörolojik komplikasyon, biguanid bulunanlarda kalp yetmezliđi riskinin düřtüđu, sülfonilüre, biguanid ve alfa-glukozidaz inhibitörü kullananlarda kardiyovasküler olay riskinin arttıđı, sülfonilürede böbrek hasarı ve demans, biguanidde oftalmolojik komplikasyonların iliřkili bulunduđu, HbA1c ve lipid

değişkenliğinin risk değerlendirmede kullanılabilir olduğu, yüksek riskli hastalarda gelişmesi olası komplikasyonların yakından izlenmesi sayesinde kişiselleştirilmiş bir yönetim yaklaşımının geliştirilebileceği belirtilmiştir. Çalışmanın ana amacının HbA1c veya lipid değişkenliğinin olumsuz sonuçlar için ne ölçüde belirleyici olabildiğinin değerlendirilmesi olduğu, sonuç olarak çalışmada, yüksek HbA1c ve lipid değişkenliğinin, farklı organ sistemlerinde diyabette olumsuz sonuçlar için artan risk ile ilişkili olduğunu gösterdiği, hipoglisemik sıklık, aralıklı hipoglisemi ve kronik inflamasyonun, HbA1c ve lipid düzeylerindeki dalgalanmaların diyabetin sistemik patogenezi hakkında fikir edinmek ve hasta sağ kalımı üzerindeki etkileri için yol göstericiliği rapor edilmiştir. Çalışmanın seyrinde diğer gözlemsel çalışmalara benzer şekilde yetersiz kodlama, eksik veri ve kodlama hataları için fazlaca efor gerektiği, gözlemsel çalışmalarda nedensellik değil, yalnızca korelasyon kurulabileceği, diyabet süresinin hesaba katılmadığı, takip boyunca yönetim kılavuzlarında, terapötik seçeneklerde ve tedavi hedeflerinde büyük değişikliklerin meydana gelmesinin çalışmayı zorlaştırdığı, veri tabanında hastanın vücut kitle indeksi, sigara, alkolizm ve diyet gibi yaşam tarzı faktörleri hakkındaki verilerin yetersiz bulunduğu, oysa bu değişkenlerin lipid seviyelerini etkileyebileceğinin göz önünde bulundurulması gerektiği çalışmanın sınırlılıkları olarak belirtilmiştir. Çalışmanın başlıca güçlü yönleri şu şekilde sunulmuştur: klinik ve biyokimyasal parametrelerin yan etkiler üzerindeki etkilerinin geniş bir popülasyona dayalı veri seti kullanılarak değerlendirilmiş olması, birden çok çeşit risklerin izlenebilir olması, kronik inflamasyon ile HbA1c ve lipid değişkenliği arasındaki ilişkilerin ortaya çıkarılabilir olması, patogenezi de altta yatan mekanizmalar hakkında bilgi sağlamak için derinlemesine araştırmaya olanak sunulabilmesi, doğal yanlılığın etkilerini sınırlamanın mümkün olması, uzun takip süresi sayesinde değişken serileri ve uzun vadeli olumsuz sonuçların yakalanmasına imkân vermesi (Lee et al., 2021).

2.8.4. Diyabet Farmakoterapisinde Makine Öğrenmesi

İlaçların yan etkilerinin ve getirdiği yüklerin, gelecekteki diyabet komplikasyonlarından daha büyük olabileceği iddia edilmiştir (Huang et al., 2007). Bu nedenle, uzun süre kullanılan antiyabetik ilaçların yararları ve zararları arasındaki denge göz önünde bulundurulmalıdır.

Antidiyabetik ilaç seçimi, diyabete eşlik eden diğer hastalıkların da mevcut olması ile daha da karmaşık ve zor bir hale gelmektedir. Böyle durumlarda kılavuzlarda açıklanan tedavi protokolleri yetersiz duruma düşmektedir. Hasta uyumunu artırmak, hekimine karar desteği sunmak, kişiye özel ilaç seçimi yaklaşımını güçlendirmek için gerçek elektronik sağlık kayıtlarının analiz edildiği, 2017 yılında yapılan ve “Elektronik Sağlık Kaydı Verilerini Kullanan Diyabet İlaç Seçimi için Paylaşılan Bir Karar Verme Sistemi” adıyla yayımlanan çalışmada, yatan bir T2DM hastasına aynı anda üç veya daha fazla antihiperглиsemik ilaç reçete edilebileceği ortaya çıkarılmış, bu nedenle, birden çok ilaç gerektiren durumlarda en uygun ilaç kombinasyonunun ne olabileceği üzerinde durulmuştur. Hastalara ve doktorlara karar desteği sunmak, antihiperглиsemik ilaçlar hakkında özel bilgi ve seçenekler sağlamak için veri madenciliği sonuçlarını ve ilgili bilgileri birleştirerek T2DM hastaları için klinik geçmişlerinin ve test değerlerinin ETK’den çıkarıldığı bir modelin önerildiği çalışmada bir prototip üretilmiş, Android akıllı mobil cihazlar için bir uygulama geliştirilerek sekiz antihiperглиsemik ilaç sınıfı arasında bir öneri elde etmek için bu verilere çok etiketli bir sınıflandırma yöntemi uygulanmıştır. Çok etiketli sınıflandırma yöntemini kullanarak geliştirilen modelin girdisi demografik veriler, eşlik eden hastalıklar, laboratuvar test sonuçları ve vital değerleridir. Modelin çıktısı, aşağıdaki sekiz antihiperглиsemik ilaç sınıfından biri veya daha fazlası olabilmektedir. Bu ilaçlar; alfa-glukozidaz inhibitörleri, DPP-4 inhibitörleri, meglitinidler, GLP-1 reseptör inhibitörleri, insülin, metformin, sülfonilüreler ve tiazolidindionlar. 2.542 T2DM yatan hasta verisi, 77 özellik ve sekiz çıktı etiketi, yani sekiz antihiperглиsemik ilaç ile eşleştirilmiş ve bu veriler, öneri modelini oluşturmak ve doğrulamak için kullanılmıştır. Çok etiketli öneri modeli, her tek etiketli sınıflandırmada istikrarlı performans sergilemiş ve sekiz sınıfın ortalama hatırlama değerinin (recall value) 0,9898 olduğu bir prototip geliştirilmiştir (Wang et al., 2017).

Kombine tedaviye başlama zamanı ve ilaç seçimi zorluğunun üstesinden gelmek için bazı hasta özellikleri, labortauvar değerleri ve ilaç etken maddeleri ile elde edilen veri setinden T2DM kombinasyon tedavisine ilişkin klinik deney verilerini analiz eden ve MÖ metodolojisini kullanarak $HbA1c \leq 7\%$ elde etmek ve sürdürmekle ilişkili hasta özelliklerini belirlemeyi amaçlayan bir çalışma şu şekildedir: Yaptıkları literatür taramasında diyabet alanında RO yaklaşımının hastalık tahmin edicileri arasındaki

ilişkileri keşfetme potansiyeline sahip, T2DM için potansiyel biyolojik belirteçlerin belirlenmesinde yardımcı, ayrıca hasta özelliklerini ve tedavi yanıtını analiz ederek T2DM’de tedavi başarısını tahmin etme olasılığına sahip olduğundan yola çıkmışlar, empagliflozin/linagliptin kombinasyonun empagliflozin veya linagliptin monoterapileri ile karşılaştıran klinik çalışma verilerini RO, KA modelleri kullanarak değerlendirmişler, 12. haftada $\leq 7\%$ ’lik bir HbA1c hedefine ulaşma ve 52 hafta boyunca hedefi sürdürme ile ilişkili hasta özelliklerini belirlemek istemişler, mevcut klinik veri kümesine yeni bir MÖ metodolojisi uygulayarak bu yaklaşımın klinik karar vermedeki potansiyel faydası değerlendirmeye çalışmışlar, bunun için $\text{yaş} \geq 18$, taramada $\text{HbA1c} > 7\%$ ve $\leq 10,5\%$ olan ve $\text{AKŞ} \leq 240 \text{ mg/dl}$ olan hastaları almışlar, sonuçları 12, 24 ve 52. haftalardaki duruma göre değerlendirmişler, temel değişken olarak yaş, cinsiyet, ırk, etnik köken, coğrafi bölge, tedavi görmemiş veya sadece metformin alanlar, boy, kilo, VKİ, bel çevresi, sigara içme durumu, alkol tüketimi, tanıdan bu yana geçen süre, kreatinin klirensi (CrCl), eGFR, hipertansiyon tanısı, sistolik kan basıncı, diyastolik kan basıncı, HbA1c ve AKŞ değerlerini incelemişlerdir. Hem geleneksel hem de yeni veri analizi metodolojilerini kullanan bu çalışmalarında kombine tedavi alan gruptaki hastaların hedefe ulaşmada monoterapi gruplarındakilerden önemli ölçüde daha başarılı olduğunu bulmuş ve diğer ilaçlara uygulanabileceğini öne sürmüş, sonuç olarak bir makine öğrenme algoritmasının klinik veri kümesine nasıl uygulanabileceğine ve klinik karar vermeyi kolaylaştırabilecek tahminler geliştirmek için nasıl kullanılabileceğine dair iyi bir örnek çalışma sunduklarına değinmişlerdir (Del Parigi et al., 2019).

Rodríguez ve arkadaşları tarafından yapılan çalışma T1DM vakalarının hiperglisemi veya hipoglisemiden kaçınmalarını sağlamak üzere insülin dozlarını belirlemek için kan şekeri düzeylerini doğru bir şekilde tahmin etmenin öneminden yola çıkarak sürekli glukoz izleme (CGM: Continuous Glucose Monitoring) cihazlarıyla kan glukoz düzeyine uygun insülin dozu hesaplayan bir sistem önermektedir. Bu çalışmada kişisel giyilebilir cihazlardan toplanan verilerin gizliliğinin sağlanması durumu da dikkate alınarak toplanan verilerin minimize edilmek suretiyle doz hesaplamaya çalışılması dikkat çekicidir. Yirmibeş T1DM’li vakanın katıldığı çalışmada vakalar 14 güne kadar kapsamlı bir şekilde pasif olarak izlenmiştir (Rodríguez-Rodríguez et al., 2019).

Mevcut tıbbi rehberlerin önemli bir kısmı hastanın kilosuna ve yaşına göre insülin programları önermekte ve bu yöntem çoğu kez istenen glisemik kontrolü sağlamakta yetersiz kalmaktadır (ADA, 2018). Bu problemin çözümü için yapay zekâ tekniklerinin kullanımı ile bazal insülin dozunu tahmin eden modeller üzerinde çalışılmıştır (Torrent-Fontbona, 2018; Wasylewicz & Scheepers-Hoeks, 2019). Guillermo Edinson Guzman Gomez ve arkadaşlarının yaptığı çalışmada modellerin eğitimi, test ve doğrulanması için, 56 hastanın 15 gün boyunca 640 kayıt seti 24 saatlik döngü boyunca tutulmuştur. Her hasta için toplam 1.456 kayıt söz konusudur. Yine 24 saatlik günlük ritimde bazal insülin dozunu tahmin etmek için dört farklı yapay zekâ tekniğinin araştırıldığı bu çalışmada YSA, BN, RO ve DVM eğitilmiştir. Eğitilen sistemler, hastalara özel dozun tahmin edebilmesi için temsil yeteneği olan değişkenler ile insülin dozu arasındaki ilişkiyi öğrenebilmiş, bazal insülin dozunu tahmin etmek için eğitim süreci tamamlanan dört model arasından en uygun tekniğin RO olduğu sonucunu bulmuşlardır (Guzman Gómez et al., 2020).

Diyabet ile birlikte başka kronik hastalıkların varlığı tedaviyi karmaşıklaştırmakta, çoklu ilaç kullanımına sebep olmakta, hasta ve hekim açısından istenmeyen sonuçlar ortaya çıkabilmektedir. Polifarmasi beş veya daha fazla ilacın birlikte kullanımı olarak tanımlanmıştır (Maher et al., 2014). Literatürde böylesi durumları çözümlemek için yapılmış bilimsel çalışmalar mevcuttur. Örneğin T2DM tedavisinde polifarmasi ve komorbiditenin rolünü araştıran tanımlayıcı bir çalışmanın sonunda yazarlar T2DM hastalarını tedavi etmenin aşırı karmaşıklığını dile getirmiş ve bu hastalar için uygun ilaç kombinasyonlarının belirlenmesi konusunda daha fazla araştırma yapılması çağrısında bulunmuşlardır (Indu et al., 2018). T2DM'li hastalarda bu karmaşaya çözüm bulmak üzere Mahsa Madani Hosseini ve arkadaşları komorbidite varlığı ve buna bağlı polifarmasiye uğramış hastaların tedavi optimizasyonunu sağlamak için büyük sağlık verilerini düzenleyip karmaşıklığı optimize etmek suretiyle veriye dayalı bir algoritma olarak rastgele değişkenler arasındaki tüm bağımlılık ve bağımsızlık ilişkilerini yakalayan BN'lerin Markov Blankets (MB) özelliğini kullanmışlardır. Sundukları araştırmalarında bağımlı değişken olarak ölüm, bağımsız değişken olarak hastalık ve şiddeti ile bunların tanımlayıcıları, antidiyabetik ilaçlar ve demografik verileri kullanmışlar, %88,75 kesinlik ve %71,15 (AUC) altında on kat çapraz doğrulama kullanarak BN üzerinde çalışmışlardır.

Çalışma döneminde diyabetik hastaların %12,28'inin öldüğü ispanyol kökenliler arasında ölüm oranını %4,18 daha fazla olduğu, yaşlanmanın mortalite üzerindeki etkisinin literatürle uyumlu olduğu, evliliğin hayatta kalma üzerinde ihmal edilebilir bir etkisinin olduğu bunun da diğer çalışmaların bulgularıyla çeliştiği, ölümler arasında erkek olmanın ölüm oranında %0,81'lik bir artış gösterdiği, diğer demografik değişkenlerin ölüm oranını etkilemediği, antidiyabetik ilaçların mortaliteye etkisinin çoğu literatürle uyumlu olduğu örneğin, insülin kullanımının ölüm olasılığını %1,4 oranında artırdığı, Rosiglitazon kullanımının mortaliteyi %5,43 oranında artırdığı, literatürde zaten rosiglitazon kullanımı ile artmış kardiyovasküler hastalık ve ani ölüm riski arasındaki ilişkinin varlığının gösterilmiş olduğu ve durumun kendi bulguları ile paralellik gösterdiği, Akarboz kullanımının mortaliteyi %1,99 artırdığı, glipizid kullanımının mortaliteyi %0,36 oranında azalttığı, pioglitazon kullanımının mortalite üzerinde ihmal edilebilir bir etkiye sahip olduğu, Gliburid kullanımının, kullanım süresi arttıkça mortaliteyi artırdığı, bu artışın literatürle uyumlu olduğu, Glimepirid kullanımının, mortalite üzerinde görece az etkiye sahip olduğu, DPP4 kullanımının da Glimepirid ile benzer sonuçlar ürettiği, monoterapide optimum seçeneğin metformin olduğu, Rosiglitazonun sağlık durumu iyi olan beyaz ırka mensup bir hasta için monoterapide en uygun ilaç olduğu ancak monoterapide Metforminin diğer tüm ilaçlardan daha fazla kullanıldığına dair sonuçları yayımlamışlardır (Hosseini et al., 2020).

Nimri ve arkadaşları tarafından yapılan çalışmada yapay zekâ tabanlı KKDS içeren yeni bir tedavi modalitesinin ürettiği insülin dozu titrasyonunun, uzman doktorlar tarafından yapılan titrasyonla karşılaştırılabilir olup olmayacağı değerlendirilmiştir. Bu randomize, kontrollü, eşit etkinlik çalışmasında, insülin pompası ayarlarının optimizasyonu için KKDS kullanımının, uzman doktorlar tarafından belirlenen doza göre etkinlik ve güvenlik açısından daha düşük olmadığı bulunmuştur. Çalışmada kullanılan sistem, T1DM'li genç insanlarda glukoz kontrolünü iyileştirmek için gerekli olan ve sıklıkla ihtiyaç duyulan insülin ayarlamalarını sunabilen yoğun insülin yönetimi için yeni bir modalite geliştirilmesinde yol gösterici olmuştur. Ancak çalışmaya katılan bireylerin genellikle T1DM'li gençleri temsil etmeyebileceği de belirtilmiştir (Nimri et al., 2020).

ETK, demografik veriler, tıbbi işlemler, laboratuvar test sonuçları, ilaç kayıtları ve ölüm oranları dahil olmak üzere 1999-2008 yılları arasında ABD'deki 120 hastaneye ait verilerden elde edilmiş bir veri tabanı olan Health Facts'den alınan 50 değişkenin kullanıldığı veri setinden yola çıkılarak diyabet tanısı ile hastaneye başvuran, 1-14 gün arasında hastanede yatan, laboratuvar testleri ve ilaç tedavisi uygulanan 101.766 kişinin çalışmaya dahil edildiği, verilerin eğitim verileri (%80) ve test verileri (%20) olarak rastgele iki kümeye ayrıldığı Mahout ve Scala'nın kullanıldığı çalışmada Mahout RF'in, yeni reçete gereksinimlerini daha iyi tahmin edebildiği, yeni bir reçete tahmininde risk faktörlerinin bilindiği durumlarda Mahout RF ile bir model oluşturulabildiği ve bu modelin hastaların tanısında alternatif ve yardımcı bir araç olarak kullanılabileceği rapor edilmiştir (Bakırarar et al., 2021).

Yapay zekâ uygulamalarının diyabet evreninde yer bulduğu alanlardan birisi de tedaviye yönelik yeni moleküllerin keşfidir. Yapay zekâ yaklaşımı kullanılarak, işlevsel bir bileşen olan NRT_N0G5IJ'nin, bezelyede bulunan pisum sativum proteini hidrolize edilerek üretildiği, bu molekülün in vitro ortamda insan iskelet kası hücrelerinin glukoz alımını önemli ölçüde arttırdığı gösterilmiştir (Chauhan et al., 2021).

2.8.5. Diyabette Klinik Karar Destek Sistemi Çalışmaları

Elektronik tıbbi kayıtların diyabet bakım kalitesinin iyileştirilmesiyle sonuçlanabilen klinik karar destek sistemlerini teşvik etmekte olduğunu, diyabet bakımına uyumu artırma potansiyeline sahip olduğunu (Ali et al., 2016); Özellikle birinci basamak sağlık ekibinin hizmet sunumunu desteklemek için karar destek sistemi kullanımının yararlarını (Maia et al., 2016); Rutin bakım ile birlikte bilgi teknolojisine dayalı bakım ve tedavilerin, diyabetli bireylerde çeşitli düzeylerde iyi sonuçlar verdiğini (Riazi et al., 2015); Teletıp çözümlerinin diyabet bakım ve tedavisinde ek yararlar sağladığını (Siriwardena et al., 2012) araştırmalara da rastlanabilmektedir.

Georga ve arkadaşları tarafından 2009 yılında yapılan çalışma, kapsamı ve tarihi itibarıyla ilgi çekicidir. METABO adını verdikleri sistem, hem hastaya hem de doktora karar desteği sağlamak üzere tasarlanmış bir diyabet izleme ve yönetim sistemi olarak tanımlanmıştır. METABO sistemi, 1) Hastanın mobil cihazı (PMD: Personalized Mobile Device), 2) farklı tipte göze batmayan biyosensörler, 3) Hastanede bulunan bir merkezi bilgi sistemi

altyapısı ve 4) Kontrol panelinden oluşturulmuştur. Doktorların, hastalarına ait kayıtlarına erişebileceği ve hastalarını takip edebileceği METABO, diyet, fiziksel aktivite, ilaç ve tıbbi bilgilerin (sürekli ve kesintili glukoz ölçümleri) verimli ve sistematik olarak kaydedilmesini kolaylaştıran çok parametrelili bir izleme sistemi sağlamıştır. Hastanın mobil cihazında kaydedilen tüm veriler üzerinde çalışan veri madenciliği şemaları, hastaların metabolizmasını modellemektedir. Hipo/hiperglisemik olayları tahmin etmek ve hastaya kısa ve uzun vadeli uyarılar sağlamak, ek olarak davranış kalıplarını çıkarmak, yeni bilgileri keşfetmek ve kontrol paneli aracılığıyla hekime hastası hakkında veri sağlamak için tüm geçmiş ve yakın zamanda kaydedilen veriler analiz edilmiştir. Kontrol panelindeki gelişmiş araçlar, doktorun her bir hastası için kişiselleştirilmiş tedavi planları sunmasına ve hastanın tedaviye uyumunu ölçmesine olanak tanımıştır (Georga et al., 2009).

DM, hedef ve tedavilerin sık sık yeniden ayarlanmasını gerektiren bir hastalıktır. Yeni klinik uygulama kılavuzları da kronik hastalıkların tedavi ve bakım planlarını kişiselleştirilmeyi önermektedir (Kim, 2012). Diyabet bakımının hedeflerini belirlemek ve tedaviye birey bazında karar vermek, hastaların ve doktorların birden fazla faktörü bir arada değerlendirmesini gerektirir (Ismail-Beigi et al., 2011). Klinik karar vermenin iki ana alanı bulunduğu varsayımı ile yola çıkılan bir çalışmada ilk ana alan risk faktörü hedeflerinin belirlenmesi (Örneğin; HbA1c, kan basıncı, kolesterol) ve ikinci ana alan tedavi seçimi olarak sabitlenmiştir. Bu iki karar verme alanının ikisinin de klinik faktörler (örneğin farmakogenomik, komorbidite, yaşam beklentisi, hastalığın evresi) ve hasta tercihleri temelinde kişiselleştirilebileceği, hastaların klinik özellikleri ve/veya hasta tedavi tercihlerinin klinik karar verme sürecine dahil edilmesi halinde oluşacak karar desteğinin “kişiselleştirilmiş” olarak tanımlanabileceği ifade edilmiştir (Wilkinson et al., 2013).

Hızlı değişen verileri işleyebilmek için veri akışı madenciliği adı verilen yeni bir veri madenciliği algoritma türü geliştirilmiştir (Hang & Fong, 2010). Bu algoritmalar artımlı öğrenme üzerine kuruludur. Artımlı öğrenme, potansiyel olarak sonsuz miktarda veriyi çok hızlı bir şekilde işleyebilir. Model güncelleme yaparken yeni veriler sisteme girdikçe tekrar tekrar baştan almaz, yeni örnekler geldiğinde anında reaktif olarak kendini yeniler.

Gerçek Zamanlı Klinik Karar Destek Sistemleri (rt-KKDS) olarak adlandırılan bu sistem akademik araştırmalarla sınırlı kalmamış (Fong, Mohammed, et al., 2013; Zhang et al., 2012) ticari prototipler de üretilmiştir (Sun et al., 2010; Yuan, 2011), gelişmeler devam etmektedir. Bu tasarımlar, klinik problemlere hızlı ve doğrulukla yanıt verebilen gerçek zamanlı bir muhakeme motoruna sahip olmaları ile karakterizedir. KKDS'de yaygın olarak kullanılan ve akış verileri yerine yapılandırılmış elektronik hasta kayıtlarına dayalı tasarımları olan geleneksel sınıflandırıcıların bazı gereksinimleri karşılamadığı bilinmektedir. Geleneksel KKDS ve rt-KKDS arasındaki temel fark, gereken reaksiyon süresidir. KKDS, belirli bir başlangıç süresi olan hastalığa odaklanır. rt-KKDS, acil tıbbi durumlar için yani zamanında ve doğru kararlar için çok önemlidir. HP Laboratories Cambridge tarafından geliştirilen ve veri akışını analiz eden BioStream, fizyolojik sensör veri akışlarını yönetmek için gerçek zamanlı, operatör tabanlı bir yazılım çözümüdür. Genel amaçlı bir akış işleme yazılımı mimarisi üzerine inşa edilmiştir (Bar-Or et al., 2004). Bir başka örnek Massachusetts Institute of Technology (MIT) tarafından geliştirilen Aurora'dır, veri akışlarını yönetmek ve uygulamaları izlemek için yeni bir sistem olduğu iddia edilmiştir (Abadi et al., 2003). Literatürde rt-KKDS adı verilen sistemler, hızla değişen tıbbi veri akışlarını analiz edebilir ve en son girdiye dayalı olarak gerçek zamanlı tahminde bulunabilir. EEG, EKG ve EMG (Elektromiyografi) gibi cihaz verileri, dakikalar hatta saniyeler içinde değişebilen, solunum hızı ve kan oksijen seviyesi gibi veriler ise hızlı değişen verilere örnek olarak verilebilir. rt-KKDS genellikle yoğun bakım, cerrahi ve acil müdahale gerektiren durumlarda hayat kurtarıcı olabilir. Diyabet hastalarının kan şekeri seviyelerinin sıklıkla yakından izlenmesi gerekir ve uygun bir kan şekeri seviyesini korumak için doğru insülin türü, dozu miktarı ve doz aralığı her zaman cevap aranan bir sorudur. Bu, hastanın genotip, fenotip, yaşam tarzı, gıda alımı, oral antidiyabetik ve insülin dozlarının çeşitliliği dahil olmak üzere birçok değişkene bağlıdır. Bu temelde yapılan çalışmaların yer aldığı bir makalede yazarlar geleceğe ışık tutan sonuçlar elde etmiş olduklarını, gelecekteki çalışmalarında daha geniş bir dizi akış madenciliği algoritmasını test etme eğiliminde olduklarını açıklamışlardır (Fong, Zhang, et al., 2013).

Zarkogianni ve arkadaşlarının 2015 yılında yaptığı diyabette ölçüm, tanı, tedavi, diyabet yönetimi gibi konuların yapay zekâ ekseninde değerlendirildiği araştırmaları tarayan geniş

kapsamlı çalışmada, kendi kendine hastalık yönetimini kolaylaştıran KKDS'lerle kan şekeri düzeyi ve yaşam tarzı izleme sensörlerindeki en son başarıları sunmak için yöntem olarak üç ana başlık belirlenmiştir: 1) Fizyolojik izlem ve yaşam tarzı izlemek için sensörler, 2) Diyabetes Mellitus'un başlangıcını tahmin etmek ve ilerlemesini değerlendirmek için modeller ve moleküler biyobelirteçler, 3) Glukozu düzenlemek için modelleme ve kontrol yöntemlerindeki gelişmelere odaklanan kritik bir literatür analizi. Bu çalışmada sonuç olarak ise glukoz ve yaşam tarzı algılama teknolojilerinin, doğru glukoz izlemi için invaziv olmayan sensörlerin geliştirilmesine odaklanan çok sayıda çalışmanın bulunduğu, diyabet yönetiminde KKDS'lerin geliştirilmesi için çok çeşitli modelleme, sınıflandırma, kümeleme ve kontrol yaklaşımları uygulandığı, diyabetin başlangıcını ve evrimini gösteren korelasyonları ve kalıpları ortaya çıkarmak için davranışsal düzeyden moleküler düzeye kadar bilgileri dikkate alan gelişmiş çok ölçekli, çok düzeyli modellemelere ihtiyacın olduğu, nihayetinde ise akıllı veri analitiği yöntemleri ve güçlü kullanıcı merkezli yaklaşımlarla birleştirilmiş sensör tabanlı sistemlerden ve ESK'lardan elde edilen verilerin entegrasyonu ile önleyici, öngörücü, kişiselleştirilmiş ve katılımcı diyabet bakımına geçişin mümkün olduğu yorumu yapılmıştır. Aynı çalışmada, hasta ya da riskli kişinin merkeze alınması ve kişinin diyabet açısından kendi kendini yönetebilmesinin opitimizasyonunu sağlamak üzere diyabetin başlangıcı ve ilerlemesi ile güçlü bir şekilde ilişkili olan biyobelirteçlerin tespit edilmesi, diyabet geliştirme riski yüksek olan bireylerin belirlenmesi, uygun tedaviyi başlatmak için diyabetin erken evrelerinde saptanması, erken müdahaleyi mümkün kılan uzun vadeli diyabet komplikasyonlarının insidansının tahmini, optimal tedavi seçimini kolaylaştıran hasta sınıflandırmasının yapılması, sıkı glisemik kontrol için hastanın aktif katılımının sağlanması gerekliliği fade edilmiştir (Zarkogianni et al., 2015).

Klinisyenlerce %87 oranında kabul gördüğü ifade edilen, bulanık mantık ve ontolojik akıl yürütmeyi birleştiren bir çalışmanın sonunda diyabetli hastalar için antidiyabetik ilaç öneren bir sistem geliştirilmiştir. "Hasta merkezli diyabet tedavisi" kavramının tartışıldığı bu çalışmada ayaktan gelen hastalara antidiyabetik ilaç önermenin yanısıra, en uygun ilaç sıralaması da yapılmaya çalışılmıştır. Esası itibariyle amacı aile hekimlerine antidiyabetik ilaç reçetelemede yardım etmek olan bu sistem, klinik tanıda da yardımcı olmayı hedeflemiştir. Geri besleme sistemini kullanan çalışmanın sonuçlarına dayanarak

yazarlar, gelecekteki arařtırmalarda sistem arayüzünü ve hesaplamalarını iyileřtirebileceklerini belirtmiřlerdir. Bunu, kurala dayalı ve vakaya dayalı akıl yürütmeyi birleřtirerek yapacaklarını açıklamıřlardır (R.-C. Chen et al., 2017).

“Dişabet Bakımı İin Klinik Karar Destek Sisteminin Geliřtirilmesi: Bir Pilot alıřma” bařlıđı ile 2017 yılında sunulan makale Singapur Ulusal Üniversite Hastanesi’nde kullanılan laboratuvar sonuç raporlama sisteminin, dişabet bakımıyla ilgili sonuçlarının aktif karar destek yetenekleri ile birleřtirilerek klinisyenlere sunulmasının hekim ve hasta yararına oluřacak sonuçlarını göstermeyi hedeflemiřtir. HbA1c’nin kılavuzların dıřında uygun olmayan řekilde izlenmesi, dişabet kontrolünde önemli bir bozulma ile iliřkili olduđundan, testlerin kısa veya uzun aralıklarla tekrarlanması önemli bir sorundur. Alık plazma glukozu, HbA1c, serum total kolesterol, HDL, LDL ve trigliseritler, tahmini glomerüler filtrasyon hızı (eGFR) ve idrar albümin/kreatinin oranı (UACR) hem dişabetin hem de komplikasyonlarının izlenmesinde anahtar tıbbi tetkiklerdendir. Bu laboratuvar testlerinin her birinin, klinisyenlere tedavi konusunda rehberlik eden ve belirli aralıklarla tekrarlanması gereken zaman ve hedef deđerleri vardır. Zaman aralıđı, hedef deđer, tetkik alıřma tekniđi, alıřılan laboratuvar cihazlarının özellikleri gibi eřitlilikler, laboratuvar belirtelerinin izlenmesini zorlařtıran unsurlardır. Laboratuvar sonuçlarının bu durumu, hekimlerin dişabet hastalarının takibi ile ilgili tetkik sonuçlarını birleřtirmesini ve yorumlanmasını zorlařtırmaktadır. Laboratuvar verilerini sunmak için entegre bir klinik karar destek arayüzünün dişabet takibinde kullanılan tetkik sonuçlarının yorumlanmasında hekimlere yardımcı olabileceđi varsayılarak harekete geilen bu arařtırma, dişabetin takibinde bazı laboratuvar test sonuçlarının sistematik ve yapılandırılmıř olarak hekime sunulmasının hasta ve hekime sađlayacađı yararları irdelemiřtir. “Diabetes Dashboard” adını verdikleri KKDS geliřtirme arařtırması olarak elektronik bir anket aracılıđıyla uygulanmaya bařlanan, vaka senaryolarını da ieren pilot alıřmada, “Diabetes Dashboard” hastanede mevcut laboratuvar raporlama arayüzü ile karřılařtırılmıřtır. Geliřtirilen sistemin anormal laboratuvar sonuçlarını ve uzun vadeli eđilimleri tespit edebilidiđi, tekrarlanması gereken testlerin belirlenmesini önemli ölçüde iyileřtirdiđi, doktorların özetlenmiř bilgilere dayanarak klinik kararları hızlı bir řekilde alabildikleri ve ek dikkat gerektiren iřler konusunda uyarılabildikleri, bu bakımdan ok yardımcı bir araç olduđu sonucu bulunmuřtur (Sim et al., 2017).

Diyabetin neden olduğu en ciddi komplikasyonlardan bir diğeri, ileri evrelerde körlük ile sonlanan diyabetik retinopatidir. Bu nedenle yakın takibi, erken evrede yakalanması ve önlem alınması gereken bir durumdur. Bu amaçla da retina görüntüleri üzerinden erken tanı, evreleme ve tedavi için çok sayıda görüntü işleme tabanlı yapay zekâ çalışması yapılmaktadır. T2DM olan 1.212 hastaya ait retina görüntüsü eğitim seti ve 1.111 hastaya ait set ise test seti olmak üzere toplamda 2.323 hastadan oluşan bir örneklemde KKDS geliştirilmiştir. Sistem, bulanık karar ağacı tabanında (f-DT) bir bulanık rastgele orman modeli (f-RF) olarak kurgulanmıştır. f-DT ile, hastanın diyabetik retinopati risk faktörleriyle ilgili özelliklerde sunduğu değerlere bağlı olarak bir hastayı birkaç sınıfta belirli bir düzeyde sınıflandıran hiyerarşik bir veri yapısı oluşturulmuştur. Ağacın her düğümü bir öznitelik ve düğümün her dalı öz niteliğin olası bir değeriyle ilişkilendirilmiştir. Ağacın yaprakları hastayı “diyabetik retinopati” veya “diyabetik retinopati yok” olmak üzere iki sınıftan birine bağlamıştır. Değişkenler mevcut yaş, cinsiyet, diyabet süresi ve tedavisi, hipertansiyon, VKİ, HbA1c, eGFR ve mikroalbuminüri olarak alınmıştır. Araştırmacılar bu doğrultuda yapılan çalışmalardan bazılarında, her üç yılda bir retina taramasının maliyet etkinliği sağladığı, ancak risk faktörlerini kişiselleştiremediği sonucuna varılmış olmasına rağmen kendi çalışmalarında bulanık kurallar kullanan RO testinin, kişiselleştirilmiş bir KKDS oluşturmaya olanak sağladığını belirtmişlerdir (Romero-Aroca et al., 2018).

MÖ modellerinden biri olan çoklu örnek öğrenme (MIL: Multiple Instance Learning) kullanan bir çalışma daha çok birinci basamak sağlık hizmeti sunumuna odaklanmıştır. Bu çalışmada diğer güncel MÖ modellerine göre deneysel karşılaştırma da yapılmış olması ilgi çekicidir. KA, RO, k-NN, l-DVM ve DVM Gauss ve DVM Lasso gibi tekniklerle karşılaştırmaların yapıldığı rapor edilmiştir. İşlenecek veriler bir pratisyen hekimin kendi takibinde olan 2.433 hastadan oluşan ESK veri tabanından toplanmıştır. Veriler 9 yıla yayılan bir zaman aralığındadır. Tanı kodlamada ICD-9 kullanılmıştır. Yukarıda da değinildiği üzere kötüleşen insülin direncini erken tahmin edebilen bir model oluşturmak amacıyla çok örnekli bir öğrenme artırma algoritması (MIL-Boost) için eş zamanlı olarak elde edilen en az bir trigliserit (mg/dl) ve açlık glisemisi (mg/dl) kaydı bulunan hastaların kayıtları üzerine yapılmış bir çalışmadır. Çalışmanın sonunda MIL-Boost algoritmasının, diğer güncel MÖ algoritmalarından daha iyi performans gösterdiği

sonucuna ulařılmıştır. MIL-Boost algoritmasının, doğrudan tetkik ölçüm sonuçlarını kullanmasa bile geçmiş ESK zamansal verilerinden gizli kalıpları çıkarabildiđi gözlemlenmiş, bunun da önemli bir avantaj olduđu savunulmuştur. Yazarlar ilk amaçlarının T2DM açısından risk altındaki hastaların belirlenmesini sağlamak üzere bir sınıflandırma metodu sunmak olduğunu ifade etmektedir. Tamamlayıcı olmak üzere hasta Alanin Aminotransferaz (ALT), Gama-Glutamil Transferaz (G-GT), HDL ve üre değerlerini MÖ başarısını artırmak için değerli girdiler olarak sunan arařtırmada, HbA1c'nin hiç kullanılmamış olması çalışmanın ilgi çekici noktalarından birini oluşturmaktadır. MIL-Boost'un, geçmiş kayıtların kullanılması ile T2DM risk durumunun erken tespiti için güvenilir bir yaklaşım olduđu, aynı zamanda tek başına bir pratisyen hekimin kendi ESK'ları ile etkin bir karar destek aracı sahibi olabileceđi ileri sürülmüştür (Bernardini et al., 2020). Bu çalışmadan elde edilecek KKDS'nin, erken tespit edilen vakalar için bakım planında egzersiz ve diyet önerebileceđine de yer verilmiştir. Gerçekten de KKDS sayesinde erken tespit edilen vakalar için diyet ve/veya egzersiz programları önererek hasta lehine iyi sonuçlar elde edilebileceđini kaydeden arařtırmalar vardır (Telle-Hansen et al., 2018).

2019 yılında yayımlanan ve ařađıda özetlenen bir makalede yazarlar ilginç noktalara değinmiştir. Makalede, bugün tıp pratiđinin büyük ölçüde ampirik olmaya devam ettiđi, doktorların genellikle hastaların tıbbi geçmiři, fizik muayenesi ve laboratuvar verilerinin kombinasyonuna dayalı bir tanı koymak için eşleşen kalıplara güvenmekte olduđu, bu nedenle belirli bir tedavinin genellikle doktorların benzer hastalarla geçmiş deneyimlerine dayandıđı, bunun bir sonucu olarak tedavi kararının deneme yanılma yoluyla elde edilen sonuca göre verilmekte olduđu ve hastanın bazen o spesifik hastalıktan etkilenen bazı kişilerde teorik olarak etkili olan bir ilaç için öngörülemeyen yan etkilerin kurbanı olduđu gerçeđini dile getirmişlerdir. Tıp pratiđinin değışim sürecince, Türkçe'ye hassas tıp olarak çevirilebilecek Precision Medicine (PM) kavramı üzerinden büyük veri ve yapay zekâ ekseninde bir tartışmaya yer verilmiştir. Son bilimsel atılımların ve teknolojik gelişmelerin, hastalık patogenezi anlayışını geliřtirdiđi ve hastalıđı teşhis etme ve tedavi etme şeklini değıştirerek, bireysel, hasta için özelleřtirilmiş daha kesin, öngörülebilir ve güçlü sađlık hizmetlerine yol açtıđı, dijital biyobelirteçlerin, nesnel ve tarafsız bir şekilde ölçülebileceđi için büyük bir fırsat sunduđu anlatılmıştır. Bununla birlikte büyük miktarda

veri seti analizlerinin, karmaşık hesaplama ve istatistiksel yöntemler gerektiren önemli bir darboğaz haline geldiği vurgulanmıştır. Büyük veri devrimi ve bu geniş veri kümesine yapay zekâ ve MÖ algoritmalarının kullanımı ile birlikte dijital sağlık fırsatlarındaki ilerlemelerin, özellikle yapay zekâ teşhis araçlarının güvenilirliğinin, klinik uygulama üzerindeki etkisi ve algoritmaların savunmasızlığı ile ilgili olarak sağlık uygulamalarının geleceği hakkında çok sayıda soru ve endişe yarattığına değinilmiştir. Yapay zekâ, MÖ algoritmaları, hesaplamalı biyoloji ve dijital biyobelirteçlerin, yeni verileri eyleme geçirilebilir bilgilere dönüştürme fırsatı sunacağı ve böylece daha erken teşhis ve kesin tedavi seçeneklerine olanak tanıyacağı anlatılmıştır. Makalede dijital biyobelirteç "dijital cihazlar aracılığıyla toplanan, nesnel, ölçülebilir, fizyolojik ve davranışsal veriler" olarak tanımlanmıştır. Bunlar ve eşlik eden hastalıklara ait verilerin birlikte kullanımı sayesinde artık ampirik tıptan hassas tıbbı (doğru hasta için, doğru ilaç, doğru dozda, doğru zamanda) geçişin mümkün olacağı, yakın gelecekte hekimlerin “herkese uyan tek beden” kavramından uzaklaşıp hassas tıbbı yönelmelerinin olası olduğu, hassas tıp ekosisteminin tanısal, prognostik ve terapötik stratejiler oluşturmak için yerleşik klinik indeksleri moleküler profil ile birlikte ele alacakları, en iyi eylem planını belirlemek için omik ve klinik verileri birleştirerek kullanabilecekleri, bu gelişmelerin büyük bir hızla büyüdüğü açıklanmıştır. Yazarların başkaca ciddi iddiaları da söz konusudur. Örneğin; Moleküler biyolojiye dayalı daha derin bir hastalık anlayışına geçişin kaçınılmaz olarak yeni, daha kesin bir hastalık sınıflandırmasına yol açacağı ve yeni bir taksonomi oluşturulmasını zorlayacağı, hastalık semptomlarının revizyona uğrayacağı, bununla birlikte herkes tarafından erişilebilir olan daha büyük veri tabanlarına ihtiyaç duyulacağı öne sürülmüştür. Akıllı telefonların, akıllı saatlerin ve bilekliklerin hayatımıza girmesiyle birlikte sensörlere bağlı veya bağlantısız olarak doğrudan veri sağlayan 300.000'den fazla sağlık uygulamasının bulunduğu, sensör cihazı sayısının her 2 yılda bir ikiye katlanarak arttığına dikkat çekilmiştir. Bu cihazlarda ağırlığın sağlık durumunu izlemek olduğu, bu gelişmelerin klinik deneylerin izlenmesi için de büyük bir olanak sunduğu, farklı sağlık uygulamalarını değerlendirmek, bireysel mahremiyet, veri kullanım sınırlamalarını ve risklerini değerlendirmek için daha özel bir araştırmaya ve dijital uzman değerlendirmesine ihtiyaç duyulacağı gerçeği dile getirilmiştir. En dikkat çekici ifadelerden biri de dijital biyobelirteçleri geliştirmedeki ilk ve en önemli hususun, hangi

cihazın kullanılacağına değil, hastalığı en iyi temsil eden hangi hastalık semptomlarının yakalanacağına karar vermek olduğu, hastaları ve doktorları tartışmaya dahil etmenin, hangi semptomların hastalar için önemli olduğunu anlamak için gerekli olduğu, bu semptomların objektif olarak ölçülüp ölçülemeyeceği ve tedavi yararını yansıtan ölçümde anlamlı bir değişikliğin ne olduğunun düşünülmesi gerektiği, ölçümlemede hangi uç noktaların yakalanması gerektiği netleştiginde doğru cihazı seçmenin kolaylaşacağı, cihaz teknolojisinin ölçüm hataları, güvenilirlik, altın standart veya bağımsız ölçümlere kıyasla doğruluk, hassasiyet ve sapmalara karşı doğrulanmasının gerekeceği, önce cihazın uygunluğunu sağlamak için gözlemsel bir çalışma gerektiği gibi ayrıntılar titizlikle ele alınmıştır (Seyhan & Carini, 2019).

Literatürde “Yapay Pankreas” terimine sıkça rastlanmaktadır. T1DM’de kan şekeri tahminine odaklanan MÖ uygulamalarının modelleme seçenekleri, stratejileri ve bunların hibrit sistemleri hakkında kompakt bir kılavuz geliştirmek amacıyla 2019 yılında yapılan bir derleme çalışmasında DBLP Computer Science, Diabetes Technology and Therapeutics, Google Scholar, IEEE, Journal of Diabetes, PubMed/Medline ve ScienceDirect gibi veri tabanları taranarak başlangıçta 417 makaleye ulaşılmıştır. İncelemede, yapay pankreas çerçevesinde kişiselleştirilmiş karar destek sistemlerini ve kan şekeri alarmı üretimini esas alan çalışmalara derinlemesine bakılmıştır. Temel olarak YSA, DVM, BN, KA teknikleri kullanan sistemler incelenmiştir. Değişken vücut kitle indeksi, stres düzeyi, uyku süresi, başka hastalıkların varlığı, ilaçlar, sigara alışkanlığı, regl dönemleri, alkolizm, alerjiler gibi diğer faktörlerin varlığının bu tür sistemlerin açmazları olabileceğine değinilmiştir. Kan şekeri dinamiklerinin karmaşıklığı nedeniyle, her durumda (yani, hipo/normo/hiperglisemi olayları) doğru bir tahmin üreten evrensel bir model elde etmek zor olmaya devam etmektedir. Buna rağmen yapay zekâ çalışmaları hız kesmemektedir. Mevcut çalışmaların tamamında başarıyı olumsuz etkileyen en önemli faktörlerden birisi ise karbonhidrat alımını tahmin etmek için iyi tanımlanmış bir yaklaşımın olmamasıdır. Kullanıcılar tarafından manuel olarak kaydı yapılan karbohidrat tüketim miktarı, tahmin performansını ciddi şekilde etkiler ve sonuçları da ciddi olabilecek tıbbi yaşamsal hatalara yol açabilir. Fiziksel aktivitelerin, stresin ve enfeksiyonların kan şekeri düzeyi üzerindeki yaklaşık etkisini tahmin etmek ve ölçmek için de evrensel bir yaklaşım oluşturulamamıştır. Hasta değişkenliğini yakalayabilen

modellerin taşınabilirliği konusunda da çok az şey yapılmıştır. Bütün bu olumsuzluklara rağmen araştırmacılar sonuç olarak geline noktaı uzun zamandır beklenen yapay pankreas (kapalı döngü sistemi) geliştirme çabaları için umut verici olarak nitelendirmişlerdir (Woldaregay et al., 2019).

Sonuçları 2021 yılında yayımlanmış olan en yeni çalışmalardan birinde Tedavi Yolu Grafiğine Dayalı Tahmin (TPGE) adında bir model çalışılmıştır. TPGE yöntemi üç süreçten oluşur: veri şekillendirme, grafik oluşturma ve model oluşturma. Çalışmanın amacı T2DM'de bütünleşik bir bakım planı ve tedavi karar desteği sunmaktır. Yazarlar klinik alanlardaki başarılı uygulamalarına rağmen, RO ve GBT gibi MÖ algoritmalarının, tedavi sonuçlarını tahmin etme bağlamında taraflı tahminlere yol açabileceğini ileri sürmektedir. Ayrıca, MÖ yaklaşımlarının sadece eğitim veri setinde karşılaşılan kalıpları öğrenebildiği, bu nedenle, MÖ yaklaşımları kullanılarak üretilen modellerin yeni klinik bağlamlarda beklenmedik sonuçlara yol açabileceği ve bu nedenle bu ortamlarda çalışan klinisyenler için kabul edilemez olabileceği belirtilmiştir. Vizyonlarını, tahmine dayalı analitik yoluyla geçmiş hasta deneyimlerinden yararlanan T2DM farmakoterapi kararlarını sorunsuz bir şekilde desteklemek için bir KDS aracını ESK ile entegre etmek olarak açıklamışlardır. Üretilen KKDS, Utah Üniversitesinde kullanılmakta olan Epic ESK ile entegre edilmiştir. Yazıda, kullanılan Metalearners adındaki modelin, T-learner olarak da bilindiği belirtilmiştir. Ocak 2012 ile Haziran 2017 arasını kapsayan ve Diyabetli 27.904 hastaya ait veri seti kullanılarak, bakım hedeflerine ulaşan alternatif tedavi stratejileri olasılığını öngören modelin analitik yöntemlerle doğrulamaları yapılmış, rastgele eğitim seti 7:3 oranında test seti olarak ayrılmıştır. ESK ile entegre MÖ tabanlı bir KKDS, klinisyenlerin ve hastaların ilgili hasta parametrelerini gözden geçirmesine, tedavi hedeflerini seçmesine ve tahmin sonuçlarına dayalı olarak alternatif tedavi stratejilerini gözden geçirmesine olanak tanımıştır. Sistem, tahmin doğruluğu konusunda önceki MÖ algoritmalarından daha iyi performans göstermiş, standartlara dayalı, birlikte çalışabilirliği garanti eden MÖ tabanlı KKDS'nin potansiyel olarak diğer birçok kronik duruma uygulanabileceği belirtilmiştir (Saeedi et al., 2019; Tarumi et al., 2021)

2.8.6. Kan Şekeri Düzeyi Tahmini İçin Makine Öğrenmesi Çalışmaları

Eşlik eden başka hastalıkları bulunan diyabetli hasta, genel popülasyona göre önemli ölçüde daha kısa yaşam beklentisine sahiptir. 2011 yılında yayımlanan bir makalede bu azalmanın diyabetin başlangıç yaşı ile ilgili olduğu, örneğin 40 yaşındaki bir hastada yaşam beklentisi yaklaşık 10 yıl azalırken, 20 yaşındaki bir hastada tahmin edilen azalmanın yaklaşık 18 yıl olduğu ileri sürülmüştür. Buna sebep olarak mikro ve makrovasküler komplikasyonlar diyabette erken ölüm ve ciddi morbiditenin başlıca nedeni olarak gösterilmiş, bu komplikasyonların başlangıç zamanı ve ciddiyetinin HbA1c seviyeleri ile yakından ilişkili bulunduğu, HbA1c'nin, diyabet tedavisinin kalitesi için uzun vadeli iyi bir belirteç olduğu net bir dil ile ifade edilmiştir (Salzsieder et al., 2011).

Şiddetli hipoglisemi, kalıcı beyin hasarı gibi fiziksel, depresyon ve düşük benlik saygısı gibi psikososyal hastalıklara yol açabilmektedir (Gonder-Frederick et al., 2008). Bu nedenle hipoglisemiye önlemeye yönelik çok sayıda ve çeşitlilikte araştırmaya rastlamak mümkündür. Nguyen ve arkadaşları tarafından test edilen invaziv olmayan bir hipoglisemi monitöründeki Bayesian sinir ağı algoritmasında kalp hızı, düzeltilmiş QT intervalı ve cilt empedansı gibi fizyolojik parametreler kullanılmıştır (Nguyen et al., 2007).

Günlük hayatı olumsuz etkilemeyecek, estetik problem yaratmayacak şekilde vücudun çeşitli bölümlerine yerleştirilebilen sensörler kullanılarak glukoz ölçümü için yapılan araştırmalar azımsanmayacak sayıda ve çeşitliliktedir.

Diyabetin hasta düzeyli yönetimi çabalarının çoğu, açlık plazma glukozunun kontrol altında tutulması hedeflenerek HbA1c seviyelerini düşürmeye odaklanmıştır. Oysa diyabetin kontrol altında tutulması ve tedavisine yönelik yeni geliştirilen test, cihaz ve ilaçlar özellikle insüline bağımlı diyabeti olan yetişkin yaş grubunda tokluk glukoz yönetimi ve genel bakımı iyileştirmek için çok iyi sonuçlar verebilir. Bu doğrultuda Uluslararası Diyabet Federasyonu'nun diyabetli hastalarda tokluk glukoz referans değerleri, tedavi ve değerlendirilmesi konusunda özel kılavuzlar yayınlamasıyla önemli bir yaklaşım değişimi sağlanmıştır (IDF, 2014).

DM takibinde kullanılan en önemli biyobelirteçlerden birisi HbA1c'dir. HbA1c'nin iyi özellikleri yanında bazı kısıtlılıkları söz konusudur. HbA1c eşik seviyelerinin T2DM tanısı

için ülkeler arasında farklılık gösterdiği açıklanan bir çalışmada Amerikan Diyabet Derneği (ADA) tarafından önerilen eşik değerin %6,5 (48 mmol/L) olduğu, bazı bireylerde düşük riskten yüksek riske kadar geniş bir yelpazede HbA1c ile ortalama kan şekeri ölçümleri arasında eksik bir korelasyon olduğundan yaklaşık %25 oranında teşhis edilmemiş diyabetin varlığı ileri sürülmüştür (ADA, 2015). HbA1c, T2DM teşhisinde alternatif bir test olarak veya AKŞ ve OGTT sonuçlarını desteklemek için yaygın olarak kullanılmaktadır. Bu durum, HbA1c'nin uzun vadeli kan şekeri seviyelerini tespit için değerli bir parametre olması özelliğini bozmamaktadır. Klinisyenler tarafında diyabetik komorbidite riskini belirlemede %6,5 ve üzeri şeklindeki HbA1c eşik değeri genel kabul görmektedir. Ancak laboratuvar uzmanlık alanlarında bu eşik değere farklı bakılmaktadır. Eşik değer olarak HbA1c'yi %6,5 olarak kabul eden büyük çalışma sonuçlarının, T2DM tanısı için tutarsızlık göstermekte olduğunu, yeterince hassas olmayabileceğini, basit kalabileceğini ve risk altındaki veya aşikâr ancak teşhis edilmemiş diyabeti olan bireyleri gözden kaçırabileceğini düşündürmektedir.

İnvaziv ölçüm tekniklerinin hala en ucuz, en kolay ulaşılabilen teknikler olması nedeniyle en az sayıda ölçüm ile kan şekeri düzeyini kontrol altında tutmak hala önemini korumaktadır. Sudharsan ve arkadaşları T2DM'li hastalarda hipoglisemi gelişimini en aza indirmek amacıyla bir çalışma yapmışlardır. Çalışmada, doktorların hipoglisemi riskini sezgisel olarak tahmin edebilmelerine rağmen bir bilgisayar sisteminde kodlanabilecek belirli kuralları açıklayamadıkları için, hastaların kendi kendilerine ölçtükleri kan şekeri verilerini MÖ algoritmalarını kullanarak hem hastalar hem hekimler yararına sonuç elde etmek üzere olasılıklı bir tahmin modeli geliştirmişlerdir. Mevcut MÖ algoritmaları arasından seçim yapmak için 3 kriter kullanmışlardır. Bunlar; a) Algoritmanın veri bilimi topluluğunda geniş çapta kabul görmesi, b) Algoritmanın doğruluk ve verimlilik için kanıtlanmış bir geçmişe sahip olması, c) Algoritmanın geniş bir kullanıcı tabanı, başarılı bir ticari kullanım geçmişine sahip olmasıdır. Bu kriterleri sağlayan RO, DVM, k-NN ve NB olarak tespit edilmiştir. Potansiyel değişkenler arasında yer almasını istedikleri fiziksel aktivite ve beslenme verilerine ulaşamadıkları için bu verileri kullanamamışlardır. Tasarladıkları çalışmada kullanabildikleri veri setine bağlı kısıtlılıklar çerçevesinde en iyi modelin RO olduğu çalışmalarında hipoglisemiyi, Kan Şekeri <70 mg/dl olarak tanımlamış hasta ölçüm değerlerini kullandıkları modele hastaların ilaç kullanım verilerini

de ekleyerek ikinci bir model daha tasarlamışlardır. Modelin eğitilmesi için ihtiyaç duyduğu optimal ölçüm değeri sayısını 10 Ölçüm/Hafta olarak optimize etmişler ve eğittikleri modelin sonraki 24 saat içinde bir hipoglisemi olayını tahmin etme duyarlılığını %92 ve özgüllüğünü %70 olarak bulmuşlardır. İlaç bilgilerini içeren modelde ise ilaç verilerinin de kullanılması ile tahmin penceresi özgüllük oranının %90'a yükseldiğini göstermişlerdir (Sudharsan et al., 2015).

Yapay zekâ alanında karşılaşılan bir başka algoritma ise ELM (Extreme Learning Machines) modelidir (Huang et al., 2011; Huang et al., 2015). Bu tekniği kullanan ve hipoglisemiye EKG sinyalleri ile çözümlmek, hipoglisemiye yakalama başarımını artırmak ELM'nin iyi performansını göstermek için T1DM'li 16 vakanın alındığı çalışmada, 60 mg/dl ve altındaki kan şekeri seviyesi hipoglisemik atak olarak kabul edilmiştir. EKG'nin kalp hızı, düzeltilmiş QT aralığı, kalp hızı değişimi ve düzeltilmiş QT aralığının değişimi olmak üzere dört fizyolojik parametreye bakılmış, sonuç olarak önerilen yöntemin gece ortaya çıkan hipoglisemik epizodları tespit etmede başarılı olduğu bulunmuştur (Ling et al., 2016). Bu çalışmanın çok benzeri T1DM'li 15 vakanın çalışmaya dahil edildiği ve EKG sinyallerinden kalp hızı ve doğru QT aralığının kullanıldığı, hipogliseminin başlangıcını tespit için DBNN modelinin kullanıldığı çalışmada bu modelin işlenmiş veya işlenmemiş veriler üzerinde özellik dönüşümü ile üstün bir sınıflandırma performansı sağladığı rapor edilmiştir (San et al., 2016).

Türkiye'de çalışmada HbA1c'yi etkileyen faktörleri tahmin etmek için ileri beslemeli bir YSA'da, girdi parametresi olarak 26 özellik kullanılmıştır. Çıkış katmanında biri normal ($HbA1c < 6.5$) ve diğeri yüksek ($HbA1c > 6.5$) olmak üzere iki sonuç tahmin edilmiş, önerilen yöntem ile %90,33 doğruluk oranına ulaşılmıştır (Peker et al., 2017).

Yine Türkiye'de yapılan ve kan glukoz düzeyini belirleme ve izlemeye yönelik derin öğrenme tekniklerine dayalı bir yaklaşım ilgi çekici bulunmuştur. Bu yaklaşımda glukoz kaynaklı enerjinin %20'sinin beyinde tüketildiği bilgisinden hareketle, derin öğrenme algoritmalarının otomatik özellik çıkarma yeteneği ve fizyolojik sinyallerin sınıflandırmada kullanabileceği düşünülmüştür. Yazarlar düşük kan şekeri seviyelerinin beyin nöronlarındaki iyonik akımları etkileyerek beyin fonksiyonunu bozduğu ve iyonik akımlardaki değişikliklerin, EEG tarafından belirlenebilen voltaj salınımları üretmesi

sebebiyle EEG sinyal verileri üzerinden, kan şekeri durumunun sınıflandırılmasını araştırmışlardır. EEG sinyallerinin hiperglisemi, hipoglisemi ve normal durum olarak sınıflandırılması için derin öğrenme teknikleri kullanmış, bu yolla değişen kan şekerinin sürekli izlenmesini sağlayacak bir model önermişlerdir (Berkol et al., 2018).

Contreras ve Vehi tarafından 2018 yılında yapılan çalışmada PubMed ve ilgili bibliyografik kaynaklar kullanılarak literatür taraması yapılmıştır. 2010'dan 2018'e kadar olan döneme ait literatür analizleri, ayrıntılı inceleme için 141'ini seçtikleri 1.849 adet ilgili makaleyi ortaya çıkarmıştır. Sonuç olarak incelenen 141 çalışmadan 41'i, ya kan şekeri düzeyinin doğru tahminini sağlayan modeller geliştirmek (27 çalışma) ya da olası kan şekeri düzeyi anormalliklerini (14 çalışma) tespit etmek için yapılmış çalışmalardır (Contreras & Vehi, 2018).

Genel HbA1c hedeflerine ulaşmada ve diyabetle ilişkili komplikasyon riskini azaltmada, tokluk glukoz dalgalanmalarını azaltmanın, açlık kan şekerini azaltmakla eşit veya daha önemli olabileceğini düşünülmektedir (Riddle, 2017). Tokluk glukoz durumunu değerlendirmek, yenilikçi yolları belirlemek için ABD'de diyabet uzmanlarının katılımıyla düzenlenen çalıştayda dünya çapında insülin bağımlı diyabet hastası olan yaklaşık 200 milyon yetişkin için öz-yönetim ve yaşam kalitesini iyileştirmeye yönelik bir rapor hazırlanmıştır (Garg et al., 2018). Yukarıdaki bilgiler ışığında tokluk glukoz düzeyi üzerinden diyabet kontrolü yapılmak istenen araştırmalara bakılmıştır. Tokluk glukoz düzeyini iyileştirmeyi hedefleyen 2019 tarihli çalışmanın sonuçları sadece insülin bağımlı T1DM'liler için değil, insüline ihtiyaç duyan T2DM'li vakalar için de kritik öneme sahiptir. Bu doğrultuda yapılan bir çalışmada tokluk glukoz yönetimi için, izin verilen maksimum tokluk glukoz değeri ve bunu ölçmek için sabitlenmiş zaman dahil titiz tanımlanmış parametrelere ihtiyaç olduğu, hastalık seyrinin bütünü hakkında klinik yargı oluşturulabilmesi için postprandiyal dönemde bakılacak glukoz düzeyi ölçümlerinin hangi zaman aralığında hangi seviyenin normal sayılacağına, yani referans değerlerinin önemine dikkat çekilmiştir. Ek olarak hangi kan şekeri düzeyinin hangi süre boyunca biyolojik hasar ve komplikasyonlarla ilişkili olabileceği, hastalığın tipi, hastalık süresi, öğün miktarı, öğün içeriği gibi faktörlerin sonuca ve birbirileri ile olan ilişkilerinin açıklanmasına yönelik kapsamlı araştırmalar gerektiği, beslenme içeriği ve miktarı gibi

periyodu da kültürel farklılıklar gösterebileceğinden genel bir kural belirlemenin oldukça güç olduğu, etnik kökenin de dikkate alınması gereken değişkenlerden birisi olduğu, ayrıca tokluk durumunda dolaşımdaki lipidlerin, amino asitlerin, diğer metabolitlerin ve inflamatuvar faktörlerin etkilerinin de incelenmesi gerektiği, çalışma sonucunda klinik değeri anlamlı birkaç umut verici davranış stratejisinin belirlenmiş olmasına rağmen sağlıklı tokluk glukoz yönetimi için etkili ve sürdürülebilir klinik stratejileri ve araçları ortaya koymanın uzun, geniş kapsamlı ve çok sayıda başka araştırmaları gerektirdiği ifade edilmiştir (Leahy et al., 2019).

Zhu ve arkadaşları D-RNN modeli kullanarak bir çalışma yapmış T1DM’li denekleri için glukoz konsantrasyonunu tahmin etmek istemişlerdir. İlk olarak veri kalitesinin tahmin performansında kritik bir role sahip olduğu ortaya konmuştur. Klinik verilerin bir kısmının manuel olarak kaydedilmesi kaliteyi dolayısıyla çalışma sonucunu olumsuz etkiler. Glukoz tahminini elde etmek için kullanılan geçmiş döneme ait kan şekeri, insülin kullanımı, diyet içeriği zaman indeksini içeren çok boyutlu bir zaman serisi dahil bir çok faktör çalışma sonucunu etkilemektedir. Bu nedenle daha geniş bir senaryo ile çalışmanın daha doğru sonuçlara götüreceği bildirilmektedir. Yine de D-RNN modelinin kan şekeri düzeyi tahmini elde etmek için umut verici bir yaklaşım olduğu ve diyabet yönetiminde gelecekteki araştırmalar için büyük potansiyele sahip olduğu ifade edilmektedir (Zhu et al., 2020).

Porumb ve arkadaşları hipogliseminin, kalbin elektrofizyolojisini etkilemesinden yola çıkmış ve izlenen EKG sinyalleri ile gece hipoglisemisini otomatik olarak tespit etmek istemişlerdir. Kişiselleştirilmiş tıp ve yapay zekâ kullanımı yaklaşımıyla yapılan çalışmanın sonunda, serbest yaşam koşullarında giyilebilir cihazlarla kaydedilen EKG kayıtları kullanılarak hipoglisemik olayların otomatik olarak tespit edilebileceği gösterilmiştir. Ancak sonuçların daha güvenilir olması için daha geniş bir popülasyon üzerinde ek testlerin yapılması gerektiği belirtilmiştir (Porumb et al., 2020).

2.9. Çalışmanın Amacı

Ülkemizde, diyabet hastalarının elektronik sağlık kayıtları kullanılarak büyük çaplı bir çalışma yapılmamıştır. Bu çalışmada Türkiye’deki diyabet hastalarının sayısı, her yıl kaç yeni tanı konulduğu, İstanbul ilinde 2017 yılında ilk kez DM tanısı ile e-Nabız kayıtlarına

girmiş vakaların kan şekeri kontrollerindeki başarı, kan şekeri kontrolünü etkileyen faktörler, hastalarda görülen komorbideteler ve kullandıkları ilaçlar incelenmiştir. Ayrıca, kan şekeri kontrolünü tahmin etmek için kullanılabilecek modeller geliştirilmek amaçlanmıştır. Bu çalışmanın sonucunda hem İstanbul ilinde diyabet sıklığı ve hastaların klinik durumları ile ilgili daha fazla bilgi sahibi olmamız, hem de kan şekeri kontrolünü belirleyen faktörlerin daha iyi anlaşılması hedeflenmiştir. Bu sonuçlar ülkemizde diyabetle ilgili yönetsel ve medikal yaklaşımlara faydalı olacak, kan şekeri kontrolü ile ilgili sonuçlar Dünyada da diyabet hastalığına yaklaşımı etkileyebilecektir.

Diyabet epidemiyolojisi, diyabetle birlikte sık görülen bazı hastalıklar ve özellikle kanserler de bu tez kapsamında ele alınan önemli bir bileşendir. Ancak birincil amacımız, glisemik kontrol durumunu tahmin etmek için MÖ algoritmalarının performansını değerlendirmek ve diabetes mellitusta glisemik kontrol için en önemli faktörleri belirlemektir.

3. GEREÇ ve YÖNTEM

3.1. Evren


Çalışma evreni olarak genel epidemiyoloji ve komorbidite çalışmalarında Türkiye Cumhuriyeti 14 yaş üstü nüfusunun tamamı, İstanbul ili için yapılan epidemiyolojik çalışmada İstanbul'daki sağlık kurumlarında kaydı bulunan 14 yaş üstü vatandaşların tamamı, makine öğrenmesi için İstanbul'daki sağlık kurumlarında kaydı bulunan vatandaşların tamamı alınmıştır.

Bu çalışmada Türkiye Cumhuriyeti Sağlık Bakanlığı (TCSB) e- Nabız Kişisel Sağlık Kaydı Sistemi (e-Nabız) veri tabanından büyük veri platformuna aktarılmış olan kayıtlar üzerinde çalışılmıştır. İlk olarak DM'nin epidemiyolojisi çeşitli boyutlarıyla ortaya konmuştur. TCSB tarafından 2015 yılı öncesine ait kayıtlar, Sağlık.Net adı verilen platformda toplanmaya çalışılmıştır. Sağlık.Net dönemine ait veriler var olsa da nitelik ve nicelik bakımından değerlendirilerek bu çalışma dışında tutulmasına karar verilmiştir. Bu çalışmaya dahil edilen veriler Nisan 2015'te kullanıma alınan e- Nabız sonrasına aittir. Sahada oluşan verinin e-Nabız veri tabanına kolay ve hızlı aktarılması için geliştirilen mimari ve algoritmalarla veriler tek merkezde daha kapsamlı, kolay ve hızlı toplanmaya başlamıştır. Bu nedenle eski kayıtlar dikkate alınmamış e-Nabız sonrası kayıtlar incelenmiştir. e-Nabız 2015 yılı ilk çeyreğine ait verileri kapsamadığından 2015 yılı kayıtları, çalışma başladığında 2021 yılı henüz tamamlanmadığından 2021 yılı kayıtları çalışma dışında tutulmuştur. İncelenen veriler 2016, 2017, 2018, 2019 ve 2020 yılı sonu itibarıyla kapsamdadır. Yani çalışmaya alınan veriler 2016 ve daha sonraki dönemlerde e-Nabız'da en az bir defa bulunan vaka kayıtları arasından alınmıştır.

3.2. Veri Anonimizasyonu ve Tekilleştirilmesi

Türkiye'nin kişisel sağlık kaydı sistemi olan e-Nabız veri tabanında vaka kimlik numaraları kriptolu olarak tutulmakta ve analiz için büyük veri ortamına aktarılmaktadır. Bu çalışmada da farklı tablolardaki kayıtlar üzerinden yapılan sorgulamaların ilişkilendirilebilmesi için Avrupa Birliği General Data Protection Regulation GDPR 2016/679 içeriğinde tanımlanan "pseudonymisation" prosedürüne uygun bir prosedür yürütülmüştür. Kayıtlar e-Nabız dahil kişi verisi içeren tüm sistemlerden büyük veri

ortamına aktarılırken de tekil tanımlayıcı numara üretme algoritmasından üretilen bir anahtara bağlı olarak büyük veri ortamına aktarılmaktadır. Bunun amacı, büyük veri ortamına diğer sistemlerden gelen verilerin birbiriyle doğru ilişkilendirilebilmesi ve raporların sistem üzerinde doğru olarak üretilebilmesidir. Böylelikle tüm sistemlerden büyük veri ortamına aktarılan veriler kişisel bilgilerden arındırılmış, tek yönlü şifreleme ve tekil tanımlayıcı anahtarlar ile şifrelenmiş şekilde aktarılmaktadır. Veri ambarında tüm sistemler ile ilişkilendirilmiş verilerin birbirleri ile eşleştirmeleri kişisel bilgileri içermeyen anahtarların bulunduğu eşleşme tablosu üzerinden yapılmaktadır Şekil 3.1)



Şekil 3.1. Veri anonimizasyonu ve tekilleştirme prosedürü

Yani büyük veri ortamındaki kayıtlar TCSB tarafından kimliksizleştirilmiş (de-identifiye edilmiş) olarak işlenmekte olup bu çalışma kapsamındaki erişim de bu şekildedir. Veriler tümüyle TCSB büyük veri platformundadır. Bu çalışma kapsamındaki tüm sorgulamalar ve oluşturulan tablolar, aynı platform üzerinde log kayıtları ile birlikte tutulmaktadır. Her bir idhash (Kimliksizleştirilmiş Tekil Vaka Kaydı Numarası)’na ait veriler, bu çalışma için oluşturulan tüm tablolarda aynı idhash ile kayıt altına alınmış böylelikle tanı, reçete, işlem, tetkik sonuç tabloları arası ilişkiler kurulabilmiştir. Çalışmanın yapıldığı bilgisayara aktarılan veriler sadece kümülatif sayısal değerlerden ve bunlardan oluşan

tablolardan ibarettir. Bu aktarımların log kaydı büyük veri platformunda saklanmaktadır. Sorgulamalar sonucu elde edilen sayısal değerler ve çalışmanın niteliğine göre hazırlanan sayısal tablolar, sistem üzerinden bilgisayara xls ve csv formatında aktarılmış, çalışmada kullanılmak üzere xls veya csv formatında verilmiştir. Verilerin kişiye özel bir ortama aktarımı veya mahremiyet ihlali söz konusu değildir. İstanbulda tedavi görmüş, MÖ çalışmalarında kullanılmasına karar verilen ve aranan kriterlere uygun 77.724 vakaya ait kayıtlar csv formatında hazırlanırken her bir vaka kaydı ise sistemlerde bulunan idhash'lerden de farklı olacak şekilde başka bir tekil tanımlayıcı ile numaralandırılmıştır.

3.3. Büyük Veri Platformu

TCSB'de tüm veriler, raporlama ve analiz için anlık olarak Hadoop temelli bir büyük veri ortamı olan Cloudera (Cloudera CDH, v. 6.3.2)'ya aktarılmaktadır (Turboard, v.2020.07, E-Kalite Ltd., Ankara). Büyük veri ortamında, Hadoop üzerinde, canlı kaynaklardan gelen verilerin yazılması ve güncellenmesi için Kudu tablo tipinde depolama, rapor verileri ve analitik olarak sorgulanacak olan tablolar için ise Parquet tipinde depolama formatı, veri kayıt ve sorgulama için Apache Impala (v. 3.2.0) sorgulama motoru kullanılmaktadır.

Verilerin tutulduğu Impala sunucuları, Eylül 2021 itibarıyla toplamda 95 adet data node (veri tutan) ve 2 adet coordinator node (sorgu ve talepleri diğer sunuculara dağıtıp toplayan) olmak üzere toplam 97 adetlik bir clusterdan oluşmaktadır. Tüm sunucularda Centos 7 işletim sistemi kuruludur. Verilerin esas olarak işlendiği sunuculardaki (data node) toplam bellek 12.160 GB, toplam disk alanı 340 TB olup 190 adet Intel(R) Xeon(R) Silver 4114 CPU @ 2.20 GHz (1900 çekirdek) işlemci yer almaktadır.

3.4. Kısıtlılıklar, Seçimler ve Veri Temizliği

Çalışmada, büyük veri ortamında milyar satırlara ulaşan tablolarda bulunan kayıtlar arasındaki belirli kriterleri karşılayan kayıtlar arasından seçildiği için bazı kısıtlılıklarla karşılaşmış, bazı noktalarda seçim yapılması gerekmiş, gerçek olamayacak değerlerle karşılaşmış, verilerin MÖ incelemeleri sürecinde doğru sonuç vermesi ve sorgulamalarda yüksek performansın sağlanması için veri temizliği yapılması gerekmiştir.

3.4.1. Ölümle

Epidemiyolojik incelemelerde DM vaka ve kontrol grubu kayıtları sorgulanırken, vakanın o yıl içinde hayatta olması halinde kaydı aynı yıl içerisinde sayılmış, ölüm kaydının bulunduğu yıldan sonraki yıllarda ise sayılmamıştır.

3.4.2. Boy, Kilo, Beslenme ve Egzersiz

DM'li vakaların tedavisinde yer alan ilaç ya da tıbbi işlemler dışında kalan yaşam biçimindeki düzenlemeler, diyet, egzersiz programları gibi kayıtlar sistemde yeteri kadar bulunmadığından çalışmaya dahil edilememiştir. Boy ve vücut ağırlığı kayıtları için de benzer durum söz konusudur.

3.4.3. Yaş

Çalışmaya alınacak DM ve DM olmayan vaka kayıtlarının yaşları, kayıt yılından vakanın doğum yılı çıkarılarak elde edilmiştir. Örneğin 2019 yılındaki bir DM vakasının yaşı hesaplanırken doğum yılı 1987 ise $2019-1987 = 32$ yaşında olarak hesaplanıp tablolara bu şekilde kaydedilmiştir.

3.4.4. İkamet İli

İkamet ili tespiti için öncelikle kişinin Merkezi Nüfus İdare Sistemi (MERNİS)'de kayıtlı adresine bakılmıştır. Adres boş ise kayıtlı olduğu aile hekimliğinin bulunduğu il, eğer bu da boş ise en son başvurduğu sağlık tesisinin bulunduğu il ikamet ili kabul edilmiştir. Sadece İstanbul'daki epidemiyoloji tablolarının hazırlanması için ilçe düzeyine inilmiştir.

3.4.5. Diyabetes Mellitus Tanı ve Kodları

Türkiye'de hekimler tarafından konulan tanımlar, Ülke çapında kullanılmakta olan tüm elektronik sağlık kayıt sistemlerinde, Dünya Sağlık Örgütü tarafından yayımlanmış International Classification of Diseases (ICD) Revision-10, kısa adıyla ICD-10 olarak bilinen Hastalıkların Uluslararası Sınıflandırılması Revizyon-10 kodlama ve sınıflandırma sistemine göre tutulmakta ve kodlanmaktadır (ICD-10 Version: 2019). Dünya Sağlık Örgütü'nün yaptığı güncellemeler eş zamanlı olarak Türkçe versiyona yansıtılmaktadır. Çevirisine TCSB <https://skrs.saglik.gov.tr> adresindeki bir arayüzden ve web servis olarak erişilebilmektedir. Büyük veri ortamındaki veri tabanı taranırken DM

için kullanılan ICD-10 tanı kodları, tüm alt kırılımları ile birlikte E10, E11, E12, E13 ve E14'tür.

3.4.6. Reçete

Türkiye’de ilaçlar çeşitli sistemlerde çeşitli kodlarla tutulmaktadır. Türkiye İlaç ve Tıbbi Cihaz Kurumunda (TİTCK) her bir ilaç barkod, karekod ve ATC kodu ile kayıt altındadır. Ancak ilaç verileri çeşitli sistemlerde örneğin a) İlaç Takip Sisteminde piyasaya sunulan ticari adları, barkodları, ATC kodları, QR kodları ile, b) e-Nabız’da barkodları, piyasa adları ve ATC kodları ile, c) Büyük veri platformunda ATC Kodları, Barkodları ile olmak üzere çeşitli kodlama ve sınıflandırma sistematğine göre tutulmaktadır. Her birinin ortak kullandığı kod yapısı ATC’dir. Bu amaçla, ilaç olarak ruhsatlandırılıp kullanılabilen tüm moleküllerin uluslararası seviyede kodlanması ve sınıflandırılmasını sağlayan kısa adı ATC olan Anatomic Therapeutic Chemical Classification yani Yapısal Tedavi Edici Kimyasallar Sınıflaması üzerinde çalışılmıştır. ATC, Dünya Sağlık Örgütü İlaç İstatistikleri Metodolojisi İş Birliği Merkezi (Collaborating Centre for Drug Statistics Methodology) tarafından ilk kez 1976 yılında yayımlanmıştır. İlaçlar etki ettikleri organ veya sisteme, iyileştirici yönüne ve/veya kimyasal karakteristiklerine göre beş farklı seviyedeki gruplara bölünmüştür.

Bu çalışmaya esas ilaç tablolarını oluşturmak için ilaç ticari adı, ticari formu, kutu içerik ve doz bilgisi, etken madde adı, etken madde ATC kodu ve barkod verilerinden oluşan bir referans tablo oluşturulmuştur. E-Nabız reçete veri paketinde, reçete edilmiş ilaçlara ait barkodlar bulunmaktadır. Bir barkoda karşılık gelen ilacın içerdiği etken madde ya da maddeleri belirleyen ATC kodları ilaç referans tablosundan bulunmuş ve böylelikle tüm ilaçları kapsayan ATC kodları ve etken madde esas alınarak çalışmaya devam edilmiştir. Örneğin reçete veri paketindeki antidiyabetik ilaçlar sorgulanırken A10A ve/veya A10B ile başlayan ATC kodlarına karşılık gelen barkodlar ile idhash bazlı reçete paketi sorgulaması yapılmıştır. Bulunan barkodun temsil ettiği ilacın ticari formu, reçetede her bir ilacın kutu adedi, her bir kutu içerisindeki ampul, tablet, kartuş, soluyon, süspansiyon vb. içerik adedi ya da miktarı, her bir kutu içindeki toplam etken madde miktarı ATC kodu ve etken madde adı, bu çalışmanın MÖ için kullanılmak üzere özel olarak hazırlanan ilaç tablosunda idhash ile birlikte kayıt altına alınmıştır. Kutu adedi ve içerdiği her bir etken

madde miktarı üzerinden yapılan hesaplama ile her bir vakanın o yıl boyunca almış olduğu yıllık toplam ilaç dozu miktarına ulaşılmıştır. Oral antidiyabetik ilaçların tümü miligram (mg) birimi cinsinden hesaplanmıştır (bulgular kısmında metformin kg, diğer oral antidiyabetikler gr olarak sunulmuştur). İnsülinler için bu birim IU/ml'dir. Herhangi başka bir antidiyabetik ilaç kaydı ve DM tanı kaydı bulunmayıp sadece Metformin etken maddesi reçete kaydı bulunan vakalar çalışma dışı tutulmuştur. Çünkü Metformin tek başına DM tanısı haricinde de reçete edilebilmektedir. Her bir etken madde için üretici ya da ithalatçı firmalarının internet sitelerinden ve TİTCK web sitesinden o ilacın Kısa Ürün Bilgisine (KÜB) ulaşılmış ve günlük maksimum doz bilgileri çıkarılmıştır. Herhangi bir antidiyabetik ilacı günlük maksimum doz üzerinde olacak şekilde reçete edilmiş olan vakalara ait kayıtlar çalışma dışı bırakılmıştır. Veri temizliği sürecinde daha fazla veri kaybetmemek için kutu adedi boş olan kayıtlardaki kutu adedi ise o ilaç için tüm reçete kayıtları işlenerek hesaplanan medyan değeri ile doldurulmuştur.

3.4.7. Laboratuvar Tetkikleri

DM'li hastaların kan şekeri düzeyi takiplerinde kullanılmakta olan en önemli tetkiklerden birisi kanda glikolize hemoglobin ölçümü olup tıbbi laboratuvar dilinde Hemoglobin A1c (HbA1c) olarak bilinen bu biyobelirtecın ölçüm sonuçları ile serum glukoz düzeyi, oral glukoz tolerans testi, total kolesterol, HDL, LDL, VLDL, trigliserid, kreatinin, idrarda albümin ölçüm sonuçlarının büyük veri arasından ayrıştırılması gerekmiştir. Son olarak HbA1c ile aynı numunede çalışılmış olmak şartıyla AKŞ ölçüm sonuçları eklenmiştir. Türkiye'de sağlık hizmetleri finansmanı neredeyse tamamen Sosyal Güvenlik Kurumu (SGK) tarafından sağlanmakta olduğu için bu tetkiklerin SGK tarafından yayımlanan Sağlık Uygulama Tebliği (SUT) işlem kodlarının belirlenmesi çalışması yapılmıştır.

TCSB tarafından zorunlu kılınmış olmakla birlikte kullanımı henüz tam yaygınlaşmamış, Amerikan Regenstrief Enstitüsü Tıbbi Araştırma Organizasyonu tarafından 1994 yılında laboratuvar ve klinik test sonuçlarının her birini tekil bir tanımlayıcı kod ile tanımlamak ve verilerde standardizasyonu sağlamak için geliştirilmiş bir kodlama ve sınıflandırma sistemi de kullanılmaktadır. Kısa adı LOINC (Logical Observation Identifiers Names and Codes) olan mantıksal gözlem tanımlayıcılarının isimleri ve kodları bu laboratuvar tetkik işlemleri için tespit edilmiş, kullanılacak tetkiklerin LOINC kodları ayrıştırılmıştır.

Türkiye’de hastane bilgi yönetim sistemleri, aile hekimliği ve diğer birinci basamak sağlık kuruluşları bilgi sistemlerinde laboratuvar tetkik işlemleri SUT kodları ile laboratuvar bilgi yönetim sistemlerinde ise bu işlem kodları çoğunlukla LOINC kodları ile tutulmakta olduğundan her iki kodlama yapısı üzerinde de çalışılmıştır.

Tetkik adı, tetkik için alınan numuneye ait tekil numara, numune alma zamanı, numunenin laboratuvara kabul zamanı, tetkikin çalışılmaya başlanması zamanı, tetkik sonuç üretim zamanı, sonucun onaylanması zamanı, ölçümün sonuç değeri, ölçüm birimi, referans değer aralıkları veri tabanında mevcuttur.

Her ne kadar TCSB tarafından SUT kodları ile LOINC kodları eşleştirmesi yapılmış olsa da eşleştirmelerde görülen hatalar nedeniyle her iki kodlama ve sınıflandırma sisteminin keşişim kümesi olan tetkik adları ile arama yapılmış, tetkik adlarının kaydedilebileceği olası tüm değişkenlikler manuel olarak gözden geçirilmiş, oldukça geniş kapsamlı ve uzun süren bir veri temizliği çalışması yapılmış, sorgulama sonucu laboratuvar tetkik sonuçları tablosu oluşturulabilmiştir.

3.4.8. Rapor

DM kronik bir hastalık olduğundan hemen her vakanın takip ve tedavi aşamasında, hastanın kullanacağı antidiyabetik ilaçlar ve çeşitli tıbbi malzemeler için sürekli kullanım ve ödeme muafiyet raporları hazırlanmaktadır. Antidiyabetik ilaçlar, hastanın evde kan şekeri takibi yapabilmesi için gerekli glukometre cihazı, tek kullanımlık strip, parmak ucu delmek için iğne, insülin kalemi, insülin ejektörü gibi malzeme giderlerinin sağlık sigorta kuruluşları tarafından karşılanabilmesi için bu raporlara ihtiyaç bulunmaktadır. Antidiyabetik tedavi giderlerinin cepten karşılanma oranı hakkında veri bulunamamış olsa da genellikle rapor düzenlenmekte olduğu varsayılmıştır. Bu içerikte bir raporun varlığı DM tanısının kesinleştirilmesinde doğrulayıcı bir faktör olarak değerlendirilmiştir. Rapor tablosu sadece rapor var/rapor yok olarak doğrulama amaçlı kullanılmıştır.

3.4.9. Bilinmeyen Diyabetes Mellitus Vakaları

Birçok tıp otoritesi tarafından DM’li olduğu halde tanı almamış ve diyabetli olduğunun farkında olmaksızın yaşayan bir kitlenin var olduğu kabul edilmektedir (Olivera et al., 2017). Bu durumdaki kişilerin tespiti ve çalışma kapsamına alınması için bir planlama

yapılmıştır. Tespit için AKŞ parametresi esas alınmıştır. Sağlık tesislerinde AKŞ ölçüm işlemi, en az 8 saat süren açlık sonrası alınan bir kan numunesi gerektirdiğinden genellikle sabah saatlerinde yapılmaktadır. Herhangi bir diyabet tanısı ya da antidiyabetik reçete kaydı bulunmadığı halde acil tıp dışındaki branşlardan yapılan istemlere ait, tetkikin yapıldığı numune kabul zamanı Türkiye saati ile 08:00-13:00 saatleri arasında olan, aynı yıl içerisinde olmak üzere en az iki kez AKŞ ölçümü yapılmış ve her iki ölçüm sonucu da normal değerin üst sınırı üzerinde bulunan kayıtlar tespit edilmiştir. AKŞ normal üst sınır değeri 126 mg/dl olarak alınmış ve bunun üzerindeki sonuçları bulunanlar diyabetli kabul edilerek epidemiyolojik çalışmaya dahil edilmiştir. Bu vaka kayıtları MÖ çalışması dışında tutulmuştur. Bu vakalar, bu çalışmada da diyabetli kabul edilmediği için HbA1c sonuçlarına da bakılmamıştır. Amaç sadece diyabetin epidemiyolojisine yönelik çalışmalarımızda gerçeğe yaklaşımdır. Özetle, DM tanısı ile birlikte ve/veya antidiyabetik içeren bir reçete kaydı olmadığı halde AKŞ değerinin aynı kişide aynı yıl içerisinde üst üste iki kez yüksek çıkması epidemiyolojik çalışmalara dahil edilme kriteridir. Ancak DM vaka başına reçete, reçete başına antidiyabetik ilaç hesaplamalarında bu metodla bulunan vakalar hesaplama dışı bırakılmıştır.

3.5. Sorgulama Kriterleri, Veri İçerik ve Özellikleri

Sistemdeki veri miktarı ve çeşitliliği çok fazla olduğundan epidemiyolojik çalışmalar ve makine öğrenmesine esas olmak üzere aranan kriterlerin tamamını sağlayan kayıtlar aşamalı olarak ayrıştırılmıştır. İlk olarak DM tanısı ve tek başına Metformin reçetesi hariç en az bir antidiyabetik ilaç reçete kaydı bulunan idhashlere ulaşılmıştır. Daha sonra bu idhashler ait rapor kaydı bulunup bulunmadığına bakılarak kayıtların gerçek DM'li vakalar olduğu kontrolü yapılmıştır. Hasta tablosunda DM kaydı olduğu halde rapor veri tabanında rapor kaydı bulunmayanlar olabilir çünkü rapor düzenlenmesi tanı ve ilk dönem tedavileri sonrasına kalabilmektedir. Zira en efektif ve hastanın uyum sağlayabileceği tedavi kapsamı belirlenene kadar rapor düzenlenmesi ertelenebilmektedir.

Ayrıştırılarak küçültülmüş verilerde veri temizliği yapılmak suretiyle hata riskinin azaltılabileceği, ayrıştırılmış verilerin yönetilmesinin daha kolay bir çalışma modeli olduğu düşünülmüştür. Her bir diyabet tanısı almış vaka kaydı bazında bir tanı tablosu, bir laboratuvar işlem tablosu ve bir reçete tablosu öncelikle oluşturulmuştur. Her bir vaka

kaydı, aynı vaka için aynı idhash ile tutulmakta olduğundan tablolar arası ilişki de kurulabilmiştir. Öneme binaen tekrar etmek gerekir ki veriler TCSB tarafından zaten kimliksizleştirilmiş (de-identifiye edilmiş) olarak tutulmaktadır ve erişimimize bu şekilde açılmıştır, tüm veriler TCSB büyük veri platformundadır, tüm sorgular ve oluşturulan tablolar, log kayıtları ile birlikte aynı yerde saklanmaktadır.

Bu tezin konusu olan DM tanısı için Türkiye’de tüm sağlık kurum ve kuruluşlarındaki bilişim sistemlerinde kullanılmakta olan ICD-10 kodlama ve sınıflandırma sistemindeki diyabet tanı kodları kullanılarak sorgulamalar büyük veri ortamında yapılmış, sorgulamaya 2015 yılı kayıtlarından başlanmış ancak 2015 yılı verileri ile ilgili raporlama yapılmamıştır. Her bir yıl için ayrı ayrı olmak üzere karşılaşılan ilk E10, E11, E12, E13 ve E14 ICD-10 tanı kodu ayrıştırılarak idhash, yaş, cinsiyet, ikamet ili, başvuru sağlık tesisi, başvuru sağlık tesisi statüsü (Aile Sağlığı Merkezi, Tıp Merkezi, 2 ve 3. Basamak Sağlık Tesisi), başvuru klinik/branş, başvuru zamanı, tetkik kodu, tetkik adı, aynı gün içerisindeki mükerrer tetkikleri birbirinden ayırmak için tetkik istem zamanı, numune kabul zamanı, tetkik sonuç zamanı, tetkik ölçüm sonucu, tetkik referans değer aralığı, tetkik ölçüm birimi, diyabetes mellitus dışı tanı kayıtları (ICD-10), reçete kayıt zamanı, reçete tekil kodu, her bir reçetede ilaç barkodu ve ATC kodu, ilaç adı, ilacın formu (tablet, kapsül, draje, ampul, çözelti vb), kutunun içerdiği adet, birim etken madde miktarı, her bir ilaç için önerilen günlük doz, reçeteye yazılmış kutu adedi ve yapılan işlemlerin SUT’da yer alan kodları, işlemin adı, işlemin yapılma zamanı, işlem adedi kayıtları sorgulanmak suretiyle ilk tablolar oluşturulmuştur.

3.5.1. Diyabetes Mellitus Tanıları

İlk olarak diyabet tanısı sorgulamalarında tüm diyabet tiplerine bakılmıştır. MÖ çalışmalarında ise Gebeliğe Bağlı Diyabetes Mellitus çalışma dışı bırakılmıştır. Kullanılacak tanı kodları Dünya Sağlık Örgütü web sitesi (<https://icd.who.int/browse10/2019/en/> Erişim Tarihi: 01.06.2021) ve TCSB Sağlık Bilgi Sistemleri Genel Müdürlüğü Sağlık Kodlama Referans Sunucusunda bulunan (SKRS) (<https://skrs.saglik.gov.tr/> Erişim Tarihi 02.06.2021) ICD-10 tanı kodlarına bakılarak doğrulanmıştır. DM tanısı olarak alınan ana ICD-10 tanı kodları şunlardır:

Tablo 3.1. Çalışmada kullanılan Diyabetes Mellitus ICD-10 kodları

KODU	HASTALIK ADI
Diabetes Mellitus	
E10	Tip 1 Diyabetes Mellitus
E11	Tip 2 Diyabetes Mellitus
E12	Malnutrisyon ilişkili Diyabetes Mellitus
E13	Diğer Spesifik Diyabetes Mellitus
E14	Non-Spesifik Diyabetes Mellitus

* Tüm alt kodlar dahil edilmiştir.

3.5.2. Diyabet Tipi Belirleme Kriterileri

Reçete kayıtlar arasında insülin haricinde hiç oral antidiyabetik kullanımı yok ise kayıt Tip 1 olarak etiketlenmiştir. Tip 1 diyabetli kişileri belirlerken 2015-2020 yılları arasındaki tüm insulin ve oral antidiyabetik reçetelerine bakılmıştır. Bu dönem içerisinde insulin kullanım raporu olan veya en az üç defa insulin reçetesi almış olup beş yıllık süreçte en fazla bir defa oral antidiyabetik reçetesi yazılmış olan vakalar yine Tip 1 olarak kaydedilmiştir. Sadece insülin kaydı bulunanlar arasında herhangi bir yılda, sadece bir defa oral antidiyabetik kaydına rastlanmış olması ya da insülin beraberinde sadece metformin bulunması Tip 1 etiketini değiştirmemiştir. ATC kodu A10 ile başlayan ilaç kullanan ve ICD-10 kodu E10-14 arası tanı alan kişiler arasında Tip 1 kriterlerini sağlamayan DM kayıtları Tip 2 olarak kaydedilmiştir. Sadece bir ya da birden çok oral antidiyabetik kombinasyonunu devamlı olarak kullananlar İnsülin kaydı bulunsu dahi Tip 2 olarak etiketlenmiştir. Tek başına metformin kaydı bulunanlar beraberinde DM tanı kaydı yok ise DM sınıfına alınmamıştır.

3.5.3. Eşlik Eden Diğer Hastalık Tanı Sorgulamaları

Çalışmaya dahil edilecek vakalarda diyabete eşlik eden diğer hastalıklar özellikle ve öncelikle kronik böbrek hastalığı, kardiyovasküler ve serebrovasküler hastalıklar, nefropatiler, lipid metabolizma bozuklukları, retinopatiler ve nöropatik hastalıklar ile malign-benign kanserler olarak belirlenmiştir. Bunların tanı kodları, DM tanı kodlarında olduğu gibi ICD-10 kullanılarak çözümlenmiş ve gruplandırılmıştır. Daha sonraki aşamada ise gerçeği temsil etme niteliğinin en yüksek olmasını sağlamak için malign-benign kanserler International Classification of Diseases for Oncology, Third Edition

(ICD-O3) kodlama ve sınıflandırma sistemine göre Patoloji Veri Paketinden elde edilmiştir.

Tablo 3.2. Çalışmada kullanılan diğer hastalık ve eşlik eden hastalıklara ait ICD-10 kodları

KODU	HASTALIK ADI
	Akut ve Kronik İskemik Kalp Hastalıkları
I21	Akut Miyokard Enfarktüsü
I22	Tekrarlayan (Subsequent) Miyokard Enfarktüsü
I23	Akut Miyokard Enfarktüsü Sonrası Bazı Komplikasyonlar
I24	Akut İskemik Kalp Hastalıkları, Diğer
I25	Kronik İskemik Kalp Hastalığı
	Kalp Yetmezlikleri
I50	Kalp Yetmezliği
	Hipertansiyon
I10	Esansiyel (Primer) Hipertansiyon
I15.0	Renovasküler Hipertansiyon
I15.1	Sekonder Hipertansiyon, Diğer Böbrek Bozukluklarına Bağlı
I15.2	Sekonder Hipertansiyon, Endokrin Hastalıklara Bağlı
I15.8	Sekonder Hipertansiyon, Diğer
I15.9	Sekonder Hipertansiyon, Tanımlanmamış
	Periferik Dolaşım Bozuklukları
I73.9	Periferik Vasküler Hastalık, Tanımlanmamış
I78.8	Kapiller Damarların Diğer Hastalıkları
I78.9	Kapiller Damarların Hastalığı, Tanımlanmamış
E10.5	İnsülin Bağımlı Diyabetes Mellitus, Periferik Dolaşım Komplikasyonu ile Birlikte
E11.5	İnsülin Bağımlı Olmayan Diyabetes Mellitus, Periferik Dolaşım Komplikasyonu ile Birlikte
E12.5	Malnütrisyona Bağlı Diyabetes Mellitus, Periferik Dolaşım Komplikasyonu ile Birlikte
E13.5	Diyabetes Mellitus, Diğer Tanımlanmış, Periferik Dolaşım Komplikasyonu ile Birlikte
E14.5	Diyabetes Mellitus, Tanımlanmamış, Periferik Dolaşım Komplikasyonu ile Birlikte
	Nefropatiler ve Kronik Böbrek Yetmezliği
N08.3	Glomerüler Bozukluklar, Diyabetes Mellitusde
N18.1	Kronik Böbrek Yetmezliği, Evre 1
N18.2	Kronik Böbrek Yetmezliği, Evre 2
N18.3	Kronik Böbrek Yetmezliği, Evre 3
N18.4	Kronik Böbrek Yetmezliği, Evre 4
N18.5	Kronik Böbrek Yetmezliği, Evre 5
N18.9	Kronik Böbrek Yetmezliği, Tanımlanmamış
N19	Böbrek Yetmezlikleri, Tanımlanmamış
E10.2	İnsülin Bağımlı Diyabetes Mellitus, Böbrek Komplikasyonu ile Birlikte

Tablo 3.2.'nin devamı

KODU	HASTALIK ADI
	Nefropatiler ve Kronik Böbrek Yetmezliği
E11.2	İnsülin Bağımlı Olmayan Diyabetes Mellitus, Böbrek Komplikasyonu ile Birlikte
E12.2	Malnütrisyonu Bağılı Diyabetes Mellitus, Böbrek Komplikasyonu ile Birlikte
E13.2	Diyabetes Mellitus, Diğer Tanımlanmış, Böbrek Komplikasyonu ile Birlikte
E14.2	Diyabetes Mellitus, Tanımlanmamış, Böbrek Komplikasyonu ile Birlikte
	Retinopatiler
E10.3	İnsülin Bağımlı Diyabetes Mellitus, Göz Komplikasyonu ile Birlikte
E11.3	İnsülin Bağımlı Olmayan Diyabetes Mellitus, Göz Komplikasyonu ile Birlikte
E12.3	Malnütrisyonu Bağılı Diyabetes Mellitus, Göz Komplikasyonu ile Birlikte
E13.3	Diyabetes Mellitus, Diğer Tanımlanmış, Göz Komplikasyonu ile Birlikte
E14.3	Diyabetes Mellitus, Tanımlanmamış, Göz Komplikasyonu ile Birlikte
H35.0	Background Retinopati ve Retina Damar Değişiklikleri
H35.2	Proliferatif Retinopati, Diğer
H35.6	Retinal Hemoraji
H35.8	Retina Bozuklukları Diğer, Tanımlanmış
H35.9	Retinal Bozukluk, Tanımlanmamış
H36.0	Diyabetik Retinopati
	Kataraktlar
H25	Senil Katarakt
H26	Katarakt, Diğer
H27	Lensin Diğer Bozuklukları
H28	Katarakt ve Lensin Diğer Bozuklukları, Başka Yerde Sınıflanmış Hastalıklarda
	Serebrovasküler Hastalıklar
I60	Subaraknoid Hemoraji
I61	İntraserebral Hemoraji
I62	Kafa İçi Travmatik Olmayan Diğer Hemoraji
I63	Serebral Enfarktüs
I64	İnme, Hemoraji veya Enfarktüs Olarak Tanımlanmamış
I65	Preserebral Arterlerin Oklüzyon ve Stenozu, Serebral Enfarktüsle Sonuçlanmayan
I66	Serebral Arterlerin Oklüzyon ve Stenozu, Serebral Enfarktüsle Sonuçlanmayan
I67	Serebrovasküler Hastalıklar, Diğer
I68	Serebrovasküler Bozukluklar, Başka Yerde Sınıflanmış Hastalıklarda
I69	Serebrovasküler Hastalık Sekeli
	Nöropatiler (Mononöropati ve Polinöropatiler)
G63.2	Diyabetik Polinöropati
G73.0	Miyastenik Sendromlar, Endokrin Hastalıklarda
G99.0	Otonom Nöropati, Endokrin ve Metabolik Hastalıklarda
G59.0	Diyabetik Mononöropati
E10.4	İnsülin Bağımlı Diyabetes Mellitus, Nörolojik Komplikasyonla Birlikte

Tablo 3.2.’nin devamı

KODU	HASTALIK ADI
	Nöropatiler (Mononöropati ve Polinöropatiler)
E11.4	İnsülin Bağımlı Olmayan Diyabetes Mellitus, Nörolojik Komplikasyonla Birlikte
E12.4	Malnütrisyonu Bağlı Diyabetes Mellitus, Nörolojik Komplikasyonla Birlikte
E13.4	Diyabetes Mellitus, Diğer Tanımlanmış, Nörolojik Komplikasyonla Birlikte
E14.4	Diyabetes Mellitus, Tanımlanmamış, Nörolojik Komplikasyonla Birlikte
	Atropatiler
M14.2	Diyabetik Artropati
M14.6	Nöropatik Artropati
E10.6	İnsülin Bağımlı Diyabetes Mellitus, Tanımlanmış Diğer Komplikasyonlarla Birlikte
E11.6	İnsülin Bağımlı Olmayan Diyabetes Mellitus, Tanımlanmış Diğer Komplikasyonlarla Birlikte
E12.6	Malnütrisyonu Bağlı Diyabetes Mellitus, Tanımlanmış Diğer Komplikasyonlarla Birlikte
E13.6	Diyabetes Mellitus, Diğer Tanımlanmış, Tanımlanmış Diğer Komplikasyonlarla Birlikte
E14.6	Diyabetes Mellitus, Tanımlanmamış, Tanımlanmış Diğer Komplikasyonlarla Birlikte
	Lipid Metabolizma Bozuklukları
E78.0	Saf Hiperkolesterolemi
E78.1	Saf Hipertrigliseridemi
E78.2	Hiperlipidemi Karma
E78.3	Hiperşilomikronemi
E78.4	Hiperlipidemi, Diğer
E78.5	Hiperlipidemi, Tanımlanmamış

*Tabloda ICD10 kodları ilk üç hane olanların alt kodlar dahil edilmiştir.

3.5.4. Kanser Tanıları

Kanser kayıtlarına dair veriler ICD-O3 morfoloji ve topografi kodlarına göre patoloji veri paketi içerisinde gelen kayıtlardan alınmıştır. Sorgulamalarda kullanılan standartlar aşağıdaki gibidir:

3.5.4.1. Hodgkin ve Non-Hodgkin Lenfomalar

Tablo 3.3. Çalışmada kullanılan Lenfoma tanılarına ait ICD- O3 kodları

ICD-O3 KODU	Hodgkin Lenfoma
9650/3	Hodgkin lenfoma, Başka biçimde tanımlanmamış
9651/3	Hodgkin lenfoma, lenfositten-zengin
9652/3	Hodgkin lenfoma, mikst sellüler, Başka biçimde tanımlanmamış
9653/3	Hodgkin lenfoma, lenfositten yoksun, Başka biçimde tanımlanmamış
9654/3	Hodgkin lenfoma, lenfosit yoksun, diffüz fibrosis

Tablo 3.3'ün devamı

ICD-O3 KODU	Hodgkin Lenfoma
9655/3	Hodgkin lenfoma, lenfosit yoksun, retiküler
9659/3	Hodgkin lenfoma, nodüler lenfosit baskın
9663/3	Hodgkin lenfoma, nodüler sklerozan, NOS
9664/3	Hodgkin lenfoma, nodüler sklerozan, sellüler faz
9665/3	Hodgkin lenfoma, nodüler sklerozan, grade 1
9667/3	Hodgkin lenfoma, nodüler sklerozan, grade 2
	Non-Hodgkin Lenfoma
9590/3	Malign lenfoma, NOS
9591/3	Malign lenfoma, Hodgkin dışı
9597/3	Primer kutanöz folikül merkezli lenfoma
9670/3	Malign lenfoma, küçük B lenfositik, Başka biçimde tanımlanmamış
9671/3	Malign lenfoma, lenfoplazmositik
9673/3	Mantle hücreli lenfoma
9675/3	Malign lenfoma, mikst küçük ve büyük hücreli, diffüz
9678/3	Primer effüzyon lenfoması
9679/3	Primer mediastinal büyük B-hücreli lenfoma
9680/3	Diffüz büyük B-hücreli lenfoma
9684/3	Malign lenfoma, büyük B hücreli, diffüz, immünoblastik, Başka biçimde tanımlanmamış
9687/3	Burkitt lenfoma
9688/3	T hücresi ve histiyosit zengin büyük B hücreli lenfoma
9689/3	Splenik marjinal zon B hücreli lenfoma
9690/3	Foliküler lenfoma, Başka biçimde tanımlanmamış
9691/3	Foliküler lenfoma, derece 2
9695/3	Foliküler lenfoma, derece 1
9698/3	Foliküler lenfoma, derece 3
9699/3	Marjinal zon B hücreli lenfoma, NOS
9700/3	Mikozis fungoides
9701/3	Sezary sendromu
9702/3	Matür T-hücreli lenfoma, Başka biçimde tanımlanmamış
9705/3	Anjiyoimmünoblastik T-hücreli lenfoma
9708/3	Subkutanöz pannikülit benzeri T-hücreli lenfoma
9709/3	Primer Kutanöz T-hücreli lenfoma
9712/3	İntravasküler büyük B hücreli lenfoma

Tablo 3.3'ün devamı

ICD-O3 KODU	Hodgkin Lenfoma
9714/3	Anaplastik büyük hücreli lenfoma, T-hücreli ve Null hücreli tip
9716/3	Hepatosplenik gama-delta hücreli lenfoma
9717/3	İntestinal T-hücreli lenfoma
9718/3	Primer kutanöz CD30+ T-hücreli lenfoproliferatif hastalık
9719/3	NK/T-hücreli lenfoma, nazal ve nazal tip
9724/3	Çocukluğun Sistemik EBV pozitif T-hücreli lenfoproliferatif hastalığı
9725/3	Hydroa vacciniforme benzeri lenfoma
9726/3	Primer kutanöz gama-delta T-hücreli lenfoma
9727/3	Blastik plazmositoid dendritik hücreli neoplazi
9728/3	Prekürsör B hücreli lenfoblastik lenfoma B lenfoblastik lenfoma
9729/3	Prekürsör T-hücreli lenfoblastik lenfoma T lenfoblastik lenfoma
9596/3	B-hücreli lenfoma, klasifiye edilemeyen, diffüz büyük B-hücreli ve klasik hodgkin lenfoma arasında özellikler gösteren

3.5.4.2 Solid Organ Malign Tümörleri

Tablo 3.4. Çalışmada kullanılan solid organ malign tümörleri tanılarına ait ICD- O3 kodları

Dudak, ağız boşluğu ve yutak kanserleri
Topografi kodu C00-C14 aralığı alt kırılımları, Davranış kodu /3
Mide Ca
Topografi kodu C16 ve alt kırılımları, Davranış kodu /3
Kolon-Rektosigmoid-Rektum Ca
Topografi kodu C18-C20 aralığı ve alt kırılımları, Davranış kodu /3
Karaciğer ve İntrahepatik Safra Yolları Ca
Topografi kodu C22 ve alt kırılımları, Davranış kodu /3
Pankreas Ca
Topografi kodu C25 ve alt kırılımları, Davranış kodu /3
Larenks Ca
Topografi kodu C32 ve alt kırılımları, Davranış kodu /3
Akciğer Ca
Topografi kodu C34 ve alt kırılımları, Davranış kodu /3

Tablo 3.4.’ün devamı

Deride Malign Melanom
Topografi kodu C44, Morfoloji kodu 8720/3
Meme Ca
Topografi kodu C50 ve alt kırılımları, Davranış kodu /3
Korpus Uteri Ca
Topografi kodu C54 ve alt kırılımları, Davranış kodu /3
Ovaryum Ca
Topografi kodu C56 ve alt kırılımları, Davranış kodu /3
Prostat Ca
Topografi kodu C61 ve alt kırılımları, Davranış kodu /3
Renal Ca
Topografi kodu C64 ve alt kırılımları, Davranış kodu /3
Mesane Ca
Topografi kodu C67 ve alt kırılımları, Davranış kodu /3
Tiroid Ca
Topografi kodu C73 ve alt kırılımları, Davranış kodu /3

3.5.4.3. Diğer Malign Tümörler

Hodgkin ve Non-Hodgkin Lenfomalar ile solid organ malign tümörler hariç tutularak geriye kalan tüm malign kanserler davranış kodu ve topolojisine göre sorgulanmış ICD-O3 morfoloji kodu davranış kodu /3 malign olanların tamamı bu gruba dahil edilmiştir.

3.5.4.4. Benign, Davranışı Bilinmeyen ve İn Situ Tümörler

Benign, benign ya da malign olduğu bilinmeyen ve insitu tümörlere ait tüm kayıtlar aşağıdaki kriterlere göre sorgulanmıştır:

Tablo 3.5. Çalışmada kullanılan benign tümör türleri ICD- O3 sorgulama kriterleri

BENİGN, BİLİNMEYEN ve İNSİTU TÜMÖRLERE AİT TÜM KAYITLAR
Tüm topografilerde davranış kodu/0 olan benign
Tüm topografilerde davranış kodu/1 olan benign ya da malign olduğu belirsiz
Tüm topografilerde davranış kodu/2 in situ

3.6. Tabloların Oluşturulması

Çalışmaya esas olacak verilerin büyük veri ortamından ayrıştırılması, ayrı bir veri tabanındaki tablolara aktarılması sırasında, esas tablolar oluşturulmadan önce de bazı ara tablolara ihtiyaç duyulmuş aşağıdaki çalışmalar yapılmıştır. Bu veri taramaları yapılırken Ocak 2015 – Eylül 2021 arasındaki tüm kayıtlara bakılmıştır. Bir bölümü geçici olmak üzere büyük veri ortamında aşağıdaki tablolar oluşturulmuştur:

3.6.1. Nüfus Tablosu

İl nüfusları TÜİK veri tabanından alınarak yıl, il, ilçe, yaş, yaştaki nüfus sayısı, cinsiyet parametrelerinden oluşturulmuştur (<https://www.tuik.gov.tr> Erişim Tarihi: 19.09.2021). İstanbul için İlçe nüfusları da aynı kaynaktan alınmıştır.

3.6.2. Diyabetes Mellitus Vakaları Geçici Tablosu

Idhash, hizmet kayıt ve takip numarası, ilk antidiyabetik ilaç içeren reçete tarihi, reçete tekil kayıt numarası, ICD-10 tanı kodlarından E10 ile E14 aralığındaki DM tanı kodları ve bu kodların alt kırılımları birlikte alınmıştır. Reçete kayıtlarına bakılırken ise ATC etken madde kodları arasında A10 ile başlayan tüm antidiyabetik ilaç kaydı bulunanlara bakılmıştır.

3.6.3. Bilinmeyen Diyabetes Mellitus Vakaları Geçici Tablosu

Yukarıda “Bilinmeyen Diyabetes Mellitus Vakaları” başlığı altında sunulan kriterlere göre yapılan sorgulama sonucunda elde edilen kayıtlar 3.6.2’deki “Diyabet Mellitus Vakaları Geçici Tablosu” ile aynı özelliklere sahip olacak şekilde oluşturulmuştur. Bu vakaların doğal olarak diyabet tanısı ve antidiyabetik reçete kaydı bulunmamaktadır.

3.6.4. Diyabetes Mellitus Popülasyon Ana Tablosu

Diyabete özgü ICD-10 ve ATC kodu birlikte bulunan idhashlerin ortak kümesi esas olmak üzere tüm kayıtları içeren yeni bir diyabet popülasyon tablosu oluşturulmuştur. Amacımız en geniş kapsamlı ve kesin diyabetli olan popülasyonu tespit etmektir. DM tanı, reçete veya raporu olanlar ile bunların olmadığı ve yukarıda 3.6.3.’te “Bilinmeyen Diyabetes Mellitus Vakaları Geçici Tablosu” başlığı altında tanımlanan vakaların birleştirilmesi ile bu tablo hazırlanmıştır.

3.6.5. Reçete Tablosu

3.6.4'teki "Diyabetes Mellitus Popölasyon Ana Tablosu"nda idhashi bulunan her bir kayda ait olmak üzere antidiyabetik olup olmadığına bakılmaksızın bu vakaların tüm reçete kayıtları bu tabloya aktarılmıştır. Idhash, tekil reçete referans numarası, reçete tarihi, reçete edilmiş ilaç barkodu, karekodu, ilaç ticari adı, ticari formu, kutu başına birim/adet miktarı, etken madde adı, etken madde ATC kodu, kullanılması önerilen günlük doz miktarı, reçetede ki kutu adedi. Tüm ilaçlar için antidiyabetiklerde olduğu gibi kutu adedi boş olan kayıtlar için o ilacın kutu medyan değeri hesaplanarak boş bulunan kutu adedi değeri medyan değeri ataması yapılmıştır. MÖ tablosunda antidiyabetik ilaçların bir yıl içerisinde kullanılan toplam doz miktarlarının hesaplanarak kullanılması planlanmıştır. Bunun için her bir ilacın kutu adedi, içindeki ilaç adedi, her bir ilaç birimi içerisindeki toplam etken madde miktarlarını doğru olarak kaydetmek gerekmektedir. Zira antidiyabetik ilaçların kullanım miktarları için MÖ tablosunda yıllık tüketilen toplam ilaç miktarları mg ve insülinler için IU/ml cinsinden kaydedilmiştir. Bu hesabı doğru yapabilmek için ilaçların üretim-tüketim sürecinin takibinin yapıldığı barkodlar kullanılmıştır. ATC kodları ile barkod eşleşmeleri titizlikle yapılmıştır. Sadece bir ilacın antidiyabetik olmadığı halde antidiyabetik olarak olarak kayıtlara girdiği tespit edilmiş, bu ilaç çalışma dışı bırakılmış ve hatanın nedeni de bulunarak düzeltilmiştir. ATC kodu var olmasına rağmen bazı antidiyabetik ilaçların ya hiç kaydına rastlanmamış ya da ihmal edilebilir düzeyde az miktarda olduğu tespit edilmiştir. Bu ilaçlara çalışmada yer verilmemiştir. Tatlandırıcı olarak bilinen ilaçlar çalışma dışı bırakılmıştır.

3.6.6. Ölüm Kaydı Tablosu

Diyabetes Mellitus Popölasyon Ana Tablosunda bulunanların, ölüm tarihi kaydı yıl olarak alınmıştır.

3.6.7. Rapor Tablosu

Diyabetes Mellitus Popölasyon Ana Tablosunda bulunanların ilaç raporu tarihleri, diğer rapor türleri ve tarihleri var/yok şeklinde bir tablodan ibarettir.

3.6.8. Laboratuvar İşlemleri Tablosu

Her bir Idhash'e ait tetkikin yapıldığı sağlık kuruluşu, hizmet takip numarası, numune kabul zamanı, tetkik kodu, tetkik adı, laboratuvar işlem referans numarası, tetkik sonucu, tetkik sonuç birimi, tetkik referans değer aralığı, tetkik sonuç onay zamanı alınmıştır.

3.6.9. İstanbul İli Hastaneleri Laboratuvar Tetkik Sonuçları Tablosu

İstanbul'da bulunan hastanelerdeki laboratuvarlarda üretilen veriler geçici bir tablo oluşturularak büyük veri ortamına ayrıca kaydedilmiştir. Tetkikler AKŞ, HbA1c, kreatinin, total kolesterol, HDL, LDL, trigliserid, ALT, AST, ALP, serum albümin ve idrarda albümin ile sınırlıdır. Her iki laboratuvar tablomuzdaki tetkik parametre adları ve birimlerinin temizliği için analitik fonksiyonlar kullanılarak tetkik parametre adları ve birimleri temizlenmiş, birimlerden bazılarında örneğin HbA1c sonucu mmol cinsinden olanların mg/dl birimine çevrilmesi işlemi yapılmıştır.

3.6.10. Diyabetes Mellitus Merkez Tablosu

Diyabetes Mellitus Popülasyon Ana Tablosunda kayıtlı vakalara ait tarafımızdan seçilmiş tanılar dahilinde Eşlik Eden Hastalıklar Tablosu, Reçete, SUT İşlemleri Tablosu, Laboratuvar Tetkikleri Tablosu ve Rapor Tablosu verileri birleştirilerek yeni bir tablo daha oluşturulmuştur, buna Diyabetes Mellitus Merkez Tablosu adı verilmiştir. Bu tabloya, büyük veri ortamında bulunan özlük tablosundan boy, kilo verileri, adres tablosundan ikamet ili verileri eklenmiştir. Ancak yeterli boy ve kilo verisi bulunmadığından kullanılmamıştır. Bu tabloların tümü büyük veri tabloları ile ilişkilidir, büyük veri tabloları güncellendikçe bu tablolar da güncellenmektedir, zira bu tablolar sadece bu çalışma için değil kurumun diğer ihtiyaçlarını da karşılaması için yapılandırılmıştır.

3.6.11. Diyabetli Olmayanlar Grubu Popülasyon Tablosu

Bu tablo TÜİK Nüfus verilerinden DM tanısı almış vaka sayıları çıkarılarak elde edilmiştir. Tablo, hiçbir surette Diyabetes Mellitus tanı kaydı, antidiyabetik reçete kaydı, antidiyabetik ilaç ve/veya malzeme rapor kaydı bulunmayan, o yıl içerisinde hayatta olanlardan oluşturulmuştur. Tanı almamış fakat AKŞ üzerinden DM epidemiyolojisine dahil edilmiş vakalar burada da diyabetik nüfus içerisinde sayılmamıştır.

3.6.12. Diyabetli Olmayanlar Grubu Reçete Tablosu

Bu grup için reçetede bulunan tüm ilaç kayıtları, etken madde ATC kodlama ve sınıflandırma sistemine göre taranmış, reçete kaydına rastlandığında bu ATC grubu için 1 (bir) değeri atanmıştır. Yok ise bu değer 0 (sıfır) olarak verilmiştir. ATC kodlama ve sınıflandırma sistemine göre A10 ile başlayan bir ilaç kaydına rastlanması halinde bu kayıt zaten diyabetli popülasyona dahil edildiğinden burada rastlanmaması beklenmiş, sorgu buna göre yapılmış ve düşünüldüğü gibi de rastlanmamıştır.

3.6.13. Diyabetli Olmayanlar Grubu Tanı Tablosu

Diyabetli grupta eşlik eden komorbidite tanılarının her birinin Diyabetli Olmayanlar grubundaki vakalarla karşılaştırmasının yapılması için bu gruptaki her bir idhash'in 2016-2020 yıllarında aynı tanıları aynı koşullarda alıp almadığına bakılarak oluşturulmuştur.

3.6.14. Diyabetli Olmayanlar Grubu Merkez Tablosu

Diyabet kaydına hiç rastlanmamış vakalara ait tabloların tümünün (reçete, tanı vb) birleştirilmesi ile oluşturulmuştur.

3.7. Makine Öğrenmesi Veri Seti

Bu tablo, kan şekeri kontrolünü tahmin etmek için kullanılabilecek modeller geliştirilmek üzere hazırlanmıştır. 2017 yılından daha önceki dönemlere ait herhangi bir DM kaydı bulunmayanlar çalışmaya alınmıştır. Veri seti boyutunu artırmak için tüm yaş grupları veri setine dahil edilmiştir. Bu çalışmanın sonucunda kan şekeri kontrolünü belirleyen faktörlerin daha iyi anlaşılması beklenmiştir. Sonuçların ülkemizde diyabetle ilgili yönetsel ve medikal yaklaşımlara, kan şekeri kontrolü ile ilgili sonuçların Dünyada da diyabet hastalığına yaklaşımlara fayda sağlaması amaçlanmıştır. MÖ çalışmalarında kullanılacak veri seti diğer tablolardan farklı olarak ikamet ili İstanbul olan, DM tanısı, reçetesi ve kabaca yılda bir HbA1c tetkiki olan kayıtlardan elde edilmiştir. Ayrıca hastaların kan şekeri kontrolü ile ilgili gruplara ayrılması için tasarlanan algoritma ve MÖ başarımını artırmak amacıyla boş değeri olmayan bir tablo oluşturulmaya çalışılmış, bu koşullarımız çalışmaya dahil edilebilecek vaka sayısını azaltmıştır. Hemen tüm özellikler DM genel epidemiyolojik çalışmaları ile aynıdır. Farklı özellikler aşağıda anlatılmaktadır.

3.7.1. İstanbul 2017 Yılı Yaş Grupları ve Cinsiyete Göre Nüfus Dağılımı

MÖ veri setinin hazırlandığı 2017 yılına ait 15 yaş üstü İstanbul nüfusunun yaş grupları ve cinsiyete göre dağılım aşağıdaki tabloda verilmiştir.

Tablo 3.6. 2017 yılı İstanbul yaş grupları ve cinsiyete göre nüfus dağılımı

2017 Yılı İstanbul Nüfusu			
Yaş Grubu	Erkek	Kadın	Toplam
15-19	571.017	534.535	1.105.552
20-24	585.796	587.131	1.172.927
25-29	644.630	642.682	1.287.312
30-34	688.645	678.364	1.367.009
35-39	719.284	705.934	1.425.218
40-44	615.044	603.237	1.218.281
45-49	522.234	504.084	1.026.318
50-54	442.422	434.991	877.413
55-59	346.440	345.236	691.676
60-64	263.109	280.112	543.221
65-69	176.777	202.308	379.085
70-74	110.176	137.977	248.153
75-79	68.698	100.300	168.998
80-84	41.260	66.533	107.793
85-89	19.244	41.191	60.435
90+	6.367	19.034	25.401
Toplam	5.821.143	5.883.649	11.704.792

3.7.2. Makine Öğrenmesi Veri Seti Genel Özellikleri

Yukarıdaki bölümlerde anlatıldığı üzere Türkiye genelindeki DM vaka kayıtları veri temizliği yapılarak büyük veri platformunda bu çalışmaya özel farklı tablolara yazılmıştır. Daha sonra bu kayıtlar içerisinde İstanbul ilindeki 2017 yılına ait vaka kayıtları seçilerek ayrı bir tabloya aktarılmıştır. MÖ teknikleri ile işlenecek olan verilere bakılır iken glisemik kontroldeki başarı gözlenmek istenmiş ve şu değişkenlere bakılarak başarı tahmin edilmeye çalışılmıştır; 2017 yılındaki yaş, cinsiyet, diyabet tipi, bazı laboratuvar tetkikleri, eşlik eden bazı hastalıklar ve reçete edilmiş olan ilaçlar.

3.7.3. Makine Öğrenmesi Veri Seti Laboratuvar Tetkikleri

HbA1c için 2017 yılında yakalanan ilk tetkik sonuç tarihinden itibaren en az 80 gün aralıklarla olmak ve en az bir tane daha olmak üzere takip eden tüm HbA1c değerleri 30 Mart 2018 tarihine kadar taranıp bu şartı sağlayan vaka kayıtları tetkik tablosuna

alınmıştır. Bu HbA1c sonuçlarının değerlendirmeye alınması için işletilen diğer kural, takip eden 2018, 2019 ve 2020 yıllarında da en az 1 HbA1c ölçüm değerinin daha bulunması şartıdır. Çünkü kan şekeri kontrol durumu tahmin edilmeye çalışılacaktır, çalışmalarımızda kan şekeri düzeyi tahmini için anahtar değişken HbA1c ölçüm sonucudur. Elde edilen HbA1c sonuçlarından HbA1c Ölçümlerindeki Azalma Oranı hesaplanmıştır.

Aynı başvuruda DM tanısı ve/veya antidiyabetik reçetesi bulunan kayıtlarda tanı tarihinden itibaren bulunan ilk total kolesterol, HDL, VLDL, trigliserid, kreatinin, serum ve idrarda albümin değerleri de bu tabloya işlenmiştir. LDL değerleri belirlenirken boş gelen kayıtlar $LDL = Kolesterol - (HDL + TG/5)$ formülü ile hesaplanarak doldurulmuştur. Total kolesterol ilk değer, HDL ilk değer, kreatinin ilk değer, trigliserid ilk değer verileri tabloya eklenmiştir.

3.7.3.1. Açlık Kan Şekeri (AKŞ) Ölçümleri

AKŞ olarak kaydedilmiş olmasına rağmen bulunan ölçüm değerlerinden bazıları açlık halindeyken yapılan ölçümlerin sonucu olmayabilir. Bu sebeple 1000 mg/dl üzeri olan ölçüm sonuçları çalışma dışı bırakılmıştır. Ayrıca AKŞ sonucu 50 mg/dl altı olanlar da hatalı kayıt olarak kabul edilip çalışma dışı bırakılmıştır. Bu değerler belirlenirken endokrinolog görüşü alınmıştır. DM tanısı ile birlikte ve/veya antidiyabetik içeren bir reçete ile birlikte olan AKŞ kayıtları çalışmaya dahil edilmiştir. Çalışmaya dahil etme kuralları diyabet tanı kaydı ve beraberinde (tek başına metformin hariç) en az bir antidiyabetik reçete kaydı bulunmasıdır.

3.7.3.2. Hemogloblin A1c (HbA1c) Ölçümleri

Çalışmada kullanılacak HbA1c verileri üzerinde aşağıdaki algoritmaya göre veri temizliği çalışması yapılmıştır:

Kullanılan limitler ve mmol/mol'den %'ye çevirim NGSP (National Glycohemoglobin Standardization Program)'ye göre belirlenmiştir. (<http://www.ngsp.org/convert1.asp>) Birim yok ise, sonuç 3-20 arasında ise sonuç % olarak kullanılmış, değilse çalışmadan çıkarılmıştır. Birim mmol/mol verilmiş, sonuç 9-195 arasında değilse çalışmadan çıkarılmıştır. Birim mmol/mol verilmiş, sonuç 9-195 arasında ise birimi %'ye çevrilmiştir.

Bu çevirimde kullanılan hesaplama modeli “% cinsi rakam = mmol/mol cinsi rakam*0,0915 + 2,15”dir. Uygunsuz birimler çalışmadan çıkarılmıştır. Birim % ise, sonuç 3-20 arasında değilse çalışmadan çıkarılmıştır. Birim % ise, sonuç %3-20 arasında ise çalışmaya dahil edilmiştir. Bu ve diğer laboratuvar tetkikleri değer aralıkları için endokrinolog görüşü alınmıştır.

3.7.3.3. Hemoglobin A1c Değişim Oranı

Bu çalışmanın ana konusu DM’li vakalarda uzun dönem kan şekeri kontrolü başarımının tahmin ve tespit edilmesidir. Kan şekeri düzeyinin uzun dönem takip ve kontrol altında olup olmadığını ortaya koyan biyobelirteç olarak HbA1c, uygulanması ve erişimi en kolay, en ucuz tetkiklerden birisi olması nedeniyle hala en yaygın kullanılanıdır. MÖ çalışmasına esas olmak üzere her bir hasta için yapılmış olan HbA1c tetkik çalışması için aranan kriterler yukarıda anlatılmıştır. MÖ için aranan kriterleri sağlayan ölçüm sonuçları üzerinden HbA1c değişim oranı hesaplanmıştır. Bu hesaplama esas denklem aşağıdadır:

2017 HbA1c değişim oranı, tarihler arasındaki fark gün cinsinden olmak üzere;

$$= (\text{HbA1c}_{\text{ilk_tarih}} - \text{HbA1c}_{\text{son_tarih}}) \times 30 \text{ (gün)} / (\text{ilk_tarih}_{\text{HbA1c}} - \text{son_tarih}_{\text{HbA1c}})$$

3.7.3.4. Diğer Laboratuvar Tetkikleri

ALT, AST, ALP değerleri ilgili tablolara alınmış olmakla birlikte veri eksikleri nedeniyle MÖ test çalışmaları aşamasında çıkarılmasına karar verilmiştir.

Kreatinin testi için çalışmaya alınmak üzere geçerli veri aralığı ve ölçüm birimi 0,3 – 25 mg/dl arası olanlardır. Burada sözü edilen aralıklar dışındaki veriler kirli veri olarak kabul edilmiş, vaka kaydı tümüyle çalışma dışı kalmıştır. Lipid profili verileri arasından trigliserid için çalışmaya alınmak üzere geçerli veri aralığı ve ölçüm birimi 9 – 2000 mg/dl arası olanlar; HDL için çalışmaya alınmak üzere geçerli veri aralığı ve ölçüm birimi 12 – 200 mg/dl arası olanlar; LDL için çalışmaya alınmak üzere geçerli veri aralığı ve ölçüm birimi 10 – 350 mg/dl arası olanlardır. Total kolesterol test sonuçları bu değerler üzerinden hesaplanarak bulunmuştur.

3.7.4. Makine Öğrenmesi Veri Seti Eşlik Eden Diğer Hastalık Tanıları

DM kaydı bulunan vakalar içerisinde 2017 yılında aşağıda özetlenen ICD-10 tanı kodlarından herhangi birisine herhangi bir başvuruda rastlanmış ise değer 1 (bir) olarak alınmış, yok ise 0 (sıfır) değeri atanmıştır. Tanı kodlarına bakılırken sistem seviyesinde (sinir sistemi, dolaşım sistemi gibi) tüm kodlara bakılmıştır. Bazı tanılara ise daha ayrıntılı bakılmıştır. Ayrıntısına bu şekilde özel olarak bakılmış olan kayıtlar, tüm kayıtlar sorgulanırken hariç tutulmuş, yani iki kez işlem görmemiş, iki kez sayılmamıştır. Bu durumun bir örnek ile anlatılması gerekirse; F31 tanı kodu kaydı bulunan bipolar duygulanım bozukluğu, F32, F33 ve F92 tanı kodu kaydı bulunan depresyonlar, F41 tanı kodu kaydı bulunan anksiyete bozukluğu kayıtları sayılarak tabloya ayrı ayrı işlenmiştir. Daha sonra tüm F00-F99 arasındaki tanı kodlarını içeren ruh hastalıkları sayılarak tabloya eklenmiş, bu sayımda F31, F32, F33, F41 ve F92 hariç tutulmuş ve mükerrerlik önlenmiştir. Buna göre yapılan sorguda aşağıdaki parametrelere bakılmış ve MÖ için kullanılacak tabloya aktarılmıştır. Tanı kod ve ve/veya tanımlar sorgulanırken kullanılan kurallar aşağıdaki gibidir:

- 1) A00-B99 arasındaki tanı kodlarını içeren enfeksiyon hastalıklarından herhangi biri, 2) C ile başlayan malign neoplazm tanılarından herhangi biri (bu sorgular daha sonra ICD-O3'e göre patoloji veri paketi kayıtlarının tutulduğu tablodan alınmıştır), 3) E65-E68 arasındaki tanı kodlarını içeren obezite tanılarından herhangi biri, 4) E00-E07 arasındaki tanı kodlarını içeren tiroid hastalıklarından herhangi biri, 5) E10-E14 arasındaki tanı kodlarını içeren diyabetes mellitus tanılarından herhangi biri (zaten birincil kuralımızdır), 6) D00-D48 arasındaki tanı kodlarını içeren bilinmeyen davranışlı tümörler tanılarından herhangi biri (bu sorgular daha sonra ICD-O3'e göre patoloji veri paketi kayıtlarının tutulduğu tablodan alınmıştır), 7) D50-D64 arasındaki tanı kodlarını içeren anemi tanılarından herhangi biri, 8) E50-E56 arasındaki tanı kodlarını içeren vitamin eksikliği tanılarından herhangi biri, 9) E78 ile başlayan lipoprotein metabolizma bozukluğu tanılarından herhangi biri, 10) Anemi hariç D65-D89 arasındaki tanı kodlarını içeren kan ve kan yapıcı organların hastalıkları tanılarından herhangi biri, 11) Diyabetes mellitus hariç E00-E90 arasındaki tanı kodlarını içeren endokrin bozukluk tanılarından herhangi biri, 12) F31 tanı kodu kaydı bulunan bipolar duygulanım bozukluğu, 13) F32, F33 ve F92 tanı kodu kaydı bulunan depresyonlar, 14) F41 tanı kodu kaydı bulunan anksiyete

bozukluğu, 15) F31, F32, F33, F41 ve F92 hariç F00-F99 arasındaki tanı kodlarını içeren ruh hastalıkları tanılarından herhangi biri, 16) G63.2 hariç G56-G63 arasındaki tanı kodlarını içeren nöropati tanılarından herhangi biri, 17) G63.2 tanı kodu kaydı bulunan diyabetik polinöropati, 18) G63.2 ve G56-G63 arası hariç G00-G99 arasındaki tanı kodlarını içeren sinir sistemi hastalıkları tanılarından herhangi biri, 19) H25 ve H26 tanı kodu kaydı bulunan katarakt, 20) H30-H36 arasındaki tanı kodlarını içeren retinopati tanılarından herhangi biri, 21) H52 tanı kodu kaydı bulunan gözde kırma kusurları, 22) H61.2 tanı kodu kaydı bulunan sıkışmış serümen, 23) H93.1 tanı kodu kaydı bulunan tinnitus (kulak çınlaması), 24) H25, H26, H52 ve H30-H36 arasındaki tanı kodları hariç göz hastalıkları tanılarından herhangi biri, 25) H60 tanı kodu kaydı bulunan otitis eksterna, 26) H60 hariç H60-H95 arası tanı kodu kaydı bulunan mostoid çıkıntı tanılarından herhangi biri, 27) I10 tanı kodu kaydı bulunan hipertansiyon, 28) I20-I25 arasındaki tanı kodlarını içeren iskemik kalp hastalığı tanılarından herhangi biri, 29) I42-I43 arasındaki tanı kodlarını içeren kardiyomiyopati tanılarından herhangi biri, 30) I60-I69 arasındaki tanı kodlarını içeren serebrovasküler hastalık tanılarından herhangi biri, 31) I10, I20-I25 arası, I42, I43, I60-I69 arası tanı kodları hariç I01-I99 arasındaki tanı kodlarını içeren dolaşım sistemi hastalıkları tanılarından herhangi biri, 32) J00-J99 arasındaki tanı kodlarını içeren solunum sistemi hastalıkları tanılarından herhangi biri, 33) K00-K14 arasındaki tanı kodlarını içeren ağız ve diş hastalıkları tanılarından herhangi biri, 34) K21 tanı kaydı bulunan gastroözofagial reflü, 35) K30 tanı kaydı bulunan dispepsi, 36) K00-K14 arası, K21, K30 hariç K00-K93 arasındaki tanı kodlarını içeren sindirim sistemi hastalıkları tanılarından herhangi biri, 37) L00-L99 arasındaki tanı kodlarını içeren deri ve subkutanöz dokunun hastalıkları tanılarından herhangi biri, 38) M00-M99 arasındaki tanı kodlarını içeren kas iskelet sistemi ve bağ dokusu hastalıkları tanılarından herhangi biri, 39) N00-N16 arasındaki tanı kodlarını içeren boşaltım sistemi hastalıkları tanılarından herhangi biri, 40) N17-N19 arasındaki tanı kodlarını içeren böbrek yetmezliği tanılarından herhangi biri, 41) N00-N16 arası, N17-N19 arası hariç N00-N99 arasındaki tanı kodlarını içeren genitoüriner sistem hastalıkları tanılarından herhangi biri, 42) O10-O16 arasındaki tanı kodlarını içeren gebelik tanılarından herhangi biri, 43) O80 tanı kaydı bulunan spontan doğum, 44) O81-O84 arasındaki tanı kodlarını içeren jinekoloji ve obstetri tanılarından herhangi biri, 45) O10-O16 arası, O80, O81-O84 arası hariç, O00-

O99 arasındaki tanı kodlarını içeren jinekoloji ve obstetri tanılarından herhangi biri var ise değerine 1(bir) yok ise 0 (sıfır) atanmıştır.

3.7.5. Makine Öğrenmesi Veri Seti Reçete Kayıtları

Tüm diyabet kayıtları arasında İstanbul’da tedavi görenlere özel sorgulama yapılırken ilaç kayıtları yine ATC kodları ile sorgulanmıştır. Antidiyabetikler haricindeki tüm ilaçlar, ATC kodlarının ana grupları üzerinden sorgulanmıştır. ATC kod listesindeki ana başlıklar şu şekildedir:

Tablo 3.7. Çalışmada kullanılan ilaçların ATC grup kodları

ATC Kodu	Sistem Adı
A	Sindirim Sistemi ve Metabolizma
A01	Ağız Sağlığı İlaçları
A02	Mide İlaçları
A03	Gastrointestinal Fonksiyonel Hastalıklar
A04	Bulantı ve Kusmada Kullanılan İlaçlar
A05	Safra Kesesi ve Karaciğer
A06	Kabızlık İlaçları
A07	İshal İlaçları, Barsak Antienflamatuar ve Antienfektifleri
A08	Obezite Tedavisi
A09	Sindirimi Kolaylaştıran İlaçlar
A10	Diyabetes Mellitus (Şeker Hastalığı) İlaçları
A11	Vitamin İlaçları
A12	Mineraller
A14	Anabolik İlaçlar
A16	Diğer Sindirim Sistemi ve Metabolizma İlaçları
B	Kan ve Kan Yapıcı Organlar
B01	Antitrombotikler
B02	Kanama Durdurucu İlaçlar
B03	Anemi (Kansızlık) İlaçları
B05	Kan ve Perfüzyon Solüsyonları
B06	Hematolojik Ajanlar
C	Kalp Damar Sistemi
C01	Kalp İlaçları
C02	Antihipertansif İlaçlar (Yüksek Tansiyon İlaçları)
C03	Diüretik İlaçlar - İdrar Arttırıcı İlaçlar
C04	Periferik Vazodilatörler
C05	Vazoprotektifler
C07	Beta Bloke Edici Ajanlar
C08	Kalsiyum Kanal Blokerleri

Tablo 3.7.'nin devamı

ATC Kodu	Sistem Adı
C09	Kan Basıncını Düzenleyen İlaçlar
C10	Lipid Metabolizması İlaçları
D	Dermatolojik İlaçlar
D01	Dermatolojik Mantar Tedavisi
D02	Yumuşatıcı ve Koruyucu İlaçlar
D03	Yara Ülser Tedavisi
D04	Antipruritik İlaçlar
D05	Antipsoriatik İlaçlar
D06	Dermatolojik Antibiyotik ve Kemoterapötik İlaçlar
D07	Dermatolojik Kortikosteroidler
D08	Antiseptik ve Dezenfektan İlaçlar
D09	İlaçlı Pansumanlar
D10	Akne İlaçları
D11	Diğer Dermatolojik İlaçlar
G	Ürogenital Sistem ve Cinsiyet Hormonları
G01	Jinekolojik Antiinfektif ve Antiseptikler
G02	Diğer Jinekolojik İlaçlar
G03	Cinsiyet Hormonları ve Genital Sistem
G04	Ürolojik İlaçlar
H	Endokrin Sistem İlaçları
H01	Hipofiz ve Hipotalamus Hormonları ve Analogları
H02	Sistemik Kortikosteroidler
H03	Tiroid İlaçları
H04	Pankreas
H05	Kalsiyum Metabolizması
J	Enfeksiyona Karşı Kullanılan (Antienfektif) İlaçlar
J01	Antibakteriyel (Antibiyotik) İlaçlar
J02	Antimikotik İlaçlar
J04	Antimikobakteriyel İlaçlar
J05	Sistemik Antiviral İlaçlar
J06	İmmün Serum ve İmmünoglobülinler
J07	Aşılar
L	Antineoplastik ve İmmünomodülatör Ajanlar
L01	Antineoplastik İlaçlar (Kanser İlaçları)
L02	Hormonal Tedavi İlaçları
L03	İmmüностimülanlar
L04	İmmünsupresif Ajanlar
M	Kas İskelet Sistemi İlaçları
M01	Antienflamatuar ve Antiromatikler
M02	Vücut Yüzeyine Uygulanan Kas-Eklemler Ağrısı İlaçları

Tablo 3.7.'nin devamı

ATC Kodu	Sistem Adı
M03	Kas Gevşeticiler
M04	Gut Hastalığı İlaçları
M05	Kemik
M09	Diğer Kas İskelet Sistemi İlaçları
N	Sinir Sistemi İlaçları
N01	Anestezi İlaçları
N02	Ağrı Kesici / Ateş Düşürücüler (Aneljezik)
N03	Antiepileptik İlaçlar
N04	Parkinson İlaçları
N05	Psikoleptikler (Psikolojik İlaçlar)
N06	Psikoanaleptikler
N07	Diğer Sinir Sistemi İlaçları
P	Parazit ve Böcek İlaçları
P01	Antiprotozoal İlaçlar
P02	Antihelmintik İlaçlar
P03	Ektoparazit İlaçları
R	Solunum Sistemi İlaçları
R01	Burunla İlgili İlaçlar
R02	Boğaz
R03	Solunum Sisteminde Tıkanma - Astım İlaçları
R05	Soğuk Algınlığı ve Öksürük İlaçları
R06	Sistemik Antihistaminikler
R07	Diğer Solunum Sistemi İlaçları
S	Duyu Organları İlaçları
S01	Göze Uygulanan İlaçlar
S02	Kulak Hastalıkları
S03	Göz ve Kulak İlaçları
V	Çeşitli İlaçlar
V01	Allerjenler
V03	Diğer Tüm Terapötik İlaçlar
V04	Tanı Ajanları
V06	Genel Besin İlaçları
V07	Tedavi Edici Olmayan Diğer Tüm Ürünler
V08	Kontrast Madde
V09	Radyofarmasötik İlaçlar

Diyabete eşlik eden diğer hastalık tedavileri için kullanılan ilaçlar ilk düzeyde örneğin, kardiyovasküler sistem ilaçları, hematolojik ilaçlar, lipid düzenleyici ilaçlar gibi gruplandırılmış ATC kodları ile sorgulanmıştır. Bu ilaçlardan herhangi birine ait reçete

kaydına 2017 yılı içerisinde bir kez rastlanması durumunda o ilaç için tabloda oluşturulan sütun altında o vakanın satır değerine 1 (bir) değeri verilmiş, rastlanmamışsa 0 (sıfır) değeri verilmiştir. Sorgulamada kullanılan ATC kodları şu şekildedir:

1) A01, A07, A09 ile başlayan ATC kodlarına sahip sindirim sistemi ilaçları, 2) A08 ile başlayan ATC kodlarına sahip antiobezite ilaçları, 3) A11-A16 arası ATC kodlarına sahip diğer sindirim sistemi ilaçları, 4) B ile başlayan ATC kodlarına sahip hematolojik ilaçlar, 5) C01-C09 arası ATC kodlarına sahip kardiyovasküler sistem ilaçları, 6) C10 ile başlayan ATC kodlarına sahip lipid metabolizma düzenleyici ilaçlar, 7) D ile başlayan ATC kodlarına sahip dermatolojik ilaçlar, 8) G01, G02, G04 ile başlayan ATC kodlarına sahip genitoüriner sistem ilaçları, 9) G03 seks hormonları, 10) H1-H3 arası ATC kodlarına sahip sistemik endokrin ilaçları, 11) H4 ile başlayan ATC koduna sahip glukagon, 12) H5 ile başlayan ATC koduna sahip hemostatik ilaçlar, 13) J01-J05 arası ATC kodlarına sahip antiinfeksiyöz ilaçlar, 14) J07 ile başlayan ATC koduna sahip aşılar, 15) I01 ile başlayan ATC koduna sahip antineoplastik ajanlar, 16) I02 ile başlayan ATC koduna sahip endokrin sistem ilaçları, 17) I03 ile başlayan ATC koduna sahip immünostimülanlar, 18) I04 ile başlayan ATC koduna sahip immünosüpresanlar, 19) M ile başlayan ATC koduna sahip kas iskelet sistemi ilaçları, 20) N01 ile başlayan ATC koduna sahip anestezikler, 21) N02 ile başlayan ATC koduna sahip analjezikler, 22) N03 ile başlayan ATC koduna sahip anti epileptik ilaçlar, 23) N04 ile başlayan ATC koduna sahip anti parkinson ilaçlar, 24) N05A ile başlayan ATC koduna sahip anti psikotikler, 25) N05B ile başlayan ATC koduna sahip anksiyolitikler, 26) N06 ile başlayan ATC koduna sahip psikoanaleptikler, 27) N07 ile başlayan ATC koduna sahip diğer sinir sistemi ilaçları, 28) P ile başlayan ATC koduna sahip antiparaziter ve insektisit ilaçlar, 29) R ile başlayan ATC koduna sahip solunum sistemi ilaçları, 30) S ile başlayan ATC koduna sahip görme ve işitme sistemi ilaçları, 31) V ile başlayan ATC koduna sahip diğer grubundaki ilaçlar.

3.7.6. Makine Öğrenmesi Veri Seti Antidiyabetik İlaçlar

DM tedavisine özgü tüm ilaçların belirlenmesi gerekmektedir. Antidiyabetik ajanlar tam ATC kodları ile sorgulamaya alınmıştır. Antidiyabetik ajanların sorgulanmasında kullanılan ATC kodları Tablo 3.8’de verilmiştir.

Tablo 3.8. Çalışmada kullanılan tüm antidiyabetik ilaçların ATC kodları

ATC KODU	ETKEN MADDE
A10AB01	INSULIN REGULER
A10AB04	INSULIN LISPRO
A10AB06	INSULIN GLUSILIN
A10AC01	INSULIN NPH
A10AD30	INSULIN ASPART
A10AE04	INSULIN GLARJIN
A10AE05	INSULIN DETEMIR
A10BA02	METFORMIN
A10BB01	GLIBENKLAMID
A10BB04	GLIBORNURID
A10BB07	GLIPİZİD
A10BB09	GLİKLAZİD
A10BB12	GLİMEPİRİD
A10BF01	AKARBOZ
A10BF02	MİGLİTOL
A10BF03	VOGLİBOZ
A10BG03	PIOGLİTAZON
A10BH01	SİTAGLİPTİN
A10BH02	VİLDAGLİPTİN
A10BH03	SAKSAGLİPTİN
A10BH04	ALOGLİPTİN
A10BH05	LİNAGLİPTİN
A10BJ01	EKSENATİD
A10BJ02	LİRAGLUTİD
A10BJ05	DULAGLUTİD
A10BK01	DAPAGLİFLOZİN
A10BK03	EMPAGLİFLOZİN
A10BX02	REPAGLİNİD
A10BX03	NATEGLİNİD
A10BX10	LİKSİSENATİD

* Bazı oral antidiyabetik etken maddeler Türkiye sağlık sisteminde kullanım oranları çok düşük veya hiç bulunmadığı için değerlendirmeye alınmamıştır.

Bu çalışmada ilaçlar belirlenirken öncelikle ATC kodları arasında A10A ve A10B ile başlayan etken maddeleri içeren ilaçların barkodları ve Türkiye’de ruhsatlandırılarak piyasaya arz edilen adları ve formları belirlenmiştir. Reçete veri tabanında ilaçların barkodları, piyasa adları ve formları, ATC kodları, her bir reçete başına yazılan kutu adetleri mevcuttur. Böylelikle, uyumsuzluk kontrolleri yapılmıştır. Diyabet tedavisine yönelik ilaçlar hızlı etkili insülinler, orta etkili insülinler, kombine insülinler, uzun etkili

insülinler, metformin, glimepirid, metformin+pioglitazon kombinasyonu, metformin+sitagliptin kombinasyonu, metformin+vildagliptin kombinasyonu, metformin+repaglinid kombinasyonu, metformin+dapagliflozin kombinasyonu, akarboz, pioglitazon, sitagliptin, vildagliptin, saxagliptin, linagliptin, exenatid, repaglinid, nateglinid olacak şekilde tasnif edilmiş ve ATC Kodları ayrıştırılmıştır.

Tüm bu etken maddeleri içeren ilaçların Kısa Ürün Bilgileri (KÜB) tek tek gözden geçirilerek her bir etken maddenin günlük minimum ve maksimum dozları bulunmuştur. Daha sonra reçete kaydı bulunmak şartıyla önerilen günlük doz miktarları üzerinden 2017 yılında alınan toplam doz miktarı miligram (mg) ve İnsülinler için International Unit (IU) cinsinden hesaplanmış ve tabloya eklenmiştir. Bulunan maksimum doz miktarının üst sınırı dışında kalanlara ait tüm kayıtlar veri kalitesi gerekçesiyle çalışma dışı tutulmuştur.

3.7.7. Makine Öğrenmesi Veri Seti Oluştururken Yapılan Veri Temizliği

Veri temizleme, bir MÖ algoritması için ham verilerin belirsizlik olmadan kolayca okunabilen bir forma dönüştürülmesini sağlamak için, belirli bir veri kümesindeki anormal değerlerin, hatalı verilerin ve veri setinde eksik olan değerlerin ortaya konması, çözüme kavuşturulması düzeltmesi gibi işlemleri kapsar. Veri temizliği makine öğrenmesi algoritmalarının veriyi kolayca anlamasını sağlasa da ham verilerdeki orijinal yapıyı değiştirmeye zorlaması ile yanlış sonuçlara götürme olasılığı göz önünde bulundurulmalıdır. Bu sebeple her bir uygulama dozu 100 IU üzerinde insülin reçetesi bulunan vakalar, KÜB'e göre mg cinsinden günlük toplam maksimum doz miktarı üzerinde oral antidiyabetik reçete kaydı bulunan vakalar, yukarıda bahsi geçen laboratuvar test sonuçları normal değer aralığı dışında ölçüm sonuç kaydı bulunan vakalar veri setine alınmamıştır.

3.8. Makine Öğrenmesi Ön İncelemeleri

Çalışmada vakaların HbA1c ölçüm sonuçlarına göre beş gruba ayrılması planlanmıştır;

1) Kan şekeri hakkında yeterli veri olmayanlar: İlk yüksek HbA1c tetkiki veya Diyabetes Mellitus tanı veya antidiyabetik içeren reçetesinden sonra yılda en az bir HbA1c testi yok veya ilk tanı kaydı tarihinden sonra altı aydan daha kısa bir süre geçmiş olanlar.


2) Kan şekeri kontrol altında olanlar: Yukarıdaki koşulları sağlayıp vakanın tüm HbA1c değerleri 7'nin altında veya son 2 değeri 7'nin altında olanlar.

3) Düzensiz kan şekeri: HbA1c sonuçları arasında 7'nin altında ve üstünde değerleri olanlar.

4) Azalan kan şekeri: 1 Ocak 2017'den itibaren elde edilen ilk HbA1c değeri 7'nin üstünde ama takip eden HbA1c değerleri azalıyor ve/veya 6,5'in altına inmiş olanlar. Bir önceki ölçüme göre 0,1'den fazla azalmamışsa bu azalma olarak kabul edilmemiştir.

5) Kontrol altında olmayan kan şekeri: HbA1c değerleri 7'nin üstünde ve azalma kaydı bulunmayanlar.

Ön inceleme aşamasındaki gruplamaya yönelik iş akış şeması aşağıda Şekil-3.3'de sunulmuştur.



Şekil 3.2. Gruplama iş akış şeması

3.9. Makine Öğrenmesi Çalışmaları

Kontrol grubu tahminleme ve trend analizi olmak üzere iki görevin makine öğrenmesi yöntemleri ile gerçekleştirilmesi yapılmıştır. Yapılan deneysel çalışmalar sonucunda en iyi performans gösterdiği tespit edilmiş olan üç makine öğrenmesi yönteminin teknik detayları aşağıda sunulmaktadır. Bu yöntemler, gözetimli öğrenmenin bir türü olan sınıflandırmadır. Buna göre, veri noktaları (bağımsız değişkenlerle temsil edilen girdi nitelikleri) ve bağımlı değişken niteliğindeki sonuç etiketleri her bir veri noktası için modele girdi olarak verilmekte, bunun sonucu olarak modelden bu girdi niteliklerinin çıktı sınıf etiketi ile ilişkisinin öğrenilmesi beklenmektedir. Bu ilişkinin öğrenilebilmesi için yeterli büyüklükte etiketli veri gereksinimi vardır. Bu veri, eğitim kümesi olarak isimlendirilir. Model, eğitim kümesini kullanarak çeşitli algoritmalar yardımıyla girdi ile çıktı sınıf etiketi arasında bir ilişki öğrenir. Modelin, bu ilişkiyi ne ölçüde öğrenebildiği, modelin eğitim süresince görmediği veri ile değerlendirilmesi yani test edilmesi sonucunda mümkün olur.

(Multi Layer Perceptron, MLP) Çok Katmanlı Algılayıcılar ve (Random Forest, RF) Rastgele Orman (RO) uygulaması, scikit-learn python kitaplığına (scikit-learn) dayanmaktadır (Pedregosa et al., 2011). MLP, girdi katmanı nöronlarının sayısının kullanılan parametre sayısı olduğu ve gizli katmanın 20 nörona sahip olduğu 3 katmanlı tam bağlantılı bir sinir ağıdır. Gizli katman boyutu ve ne kadar nöron içerdiği deneysel olarak belirlenmiştir (Kingma & Ba, 2014). Adam: Optimizasyon için Stokastik Optimizasyon Yöntemi kullanılmıştır. Erken durdurma kriteri ile maksimum öğrenme yineleme sayısı 10.000 olarak ayarlanmıştır.

Uygulanan RO, Gini kirliliğini temel alarak her bir ağacı maksimum 20 derinlikle (ezberlemeyi önlemek için) bölümlere ayıran bir yapıdır. Öznitelik sayısının logaritması kadar rastgele öznitelikler üzerinde ağaç bölümlene yapılmıştır. Yapraktaki (10) maksimum derinlik ve maksimum veri kaydı sayısı da ağaç üretiminde sonlandırma kriteri olarak belirlenmiştir.

XGBoost'un scikit-learn uyumlu API'si, XGB deneyleri için kullanılmıştır (Chen & Guestrin, 2016). RO yaklaşımında olduğu gibi ağaç derinliği 20 ile sınırlandırılmıştır. Öğrenme oranı 0,1 olarak ayarlanmıştır. Öğrenme 1.000 yineleme ile sınırlıdır.

3.9.1. Yapay Sinir Ağı: Çok Katmanlı Algılayıcı

Bu tez çalışmasında MLP'nin iki sınıflı ve çok sınıflı sınıflandırıcı olarak gerçekleştirimi yapılmıştır. Girdi katmanında veri kümesindeki bağımsız değişken adedi kadar sinir hücresi bulunmaktadır. Üç gizli katmanı vardır ve bu katmanlardaki sinir hücresi sayısı gerçekleştirilen göreve göre değişiklik gösterebilmektedir. Değişen sinir hücresi sayıları içerisinden performans ölçütleri açısından en avantajlı olması dolayısıyla 10, 4 ve 10 sinir hücresinin kullanılması makul bulunmuştur. Son katmanda çok sınıflı sınıflandırma yapan görevlerde sınıf sayısı kadar, iki sınıflı sınıflandırma yapan görevlerde ise bir sinir hücresi bulunmaktadır. Bu katmandaki aktivasyon fonksiyonu çok sınıflı sınıflandırıcı görevleri için softmax, iki sınıflı sınıflandırıcılar için sigmoid olarak belirlenmiştir. Aktivasyon fonksiyonu LBFGS (Limited-memory Broyden–Fletcher–Goldfarb–Shanno) ve Adam (Adaptive Moment Estimation) olarak değerlendirilmiş ve LBFGS'nin eğitim sürecinde bu veri kümeleri için daha başarılı olduğu tespit edilmiştir.

3.9.2. Rastgele Orman (RO)

Tez çalışması kapsamında kullanılan RO, her bir ağacı maksimum 20 derinliğinde (ezberlemeyi engellemek adına) Gini belirsizlik ölçütüyle bölümlendirme yapan bir yapıdadır. Nitelik sayısının logaritması kadar rastgele nitelik üzerinde bölümlendirmeler yapılmaktadır. Ağaçların üretilmesinde sonlandırma kriteri olarak maksimum derinlikle beraber yaprakta yer alan maksimum veri kaydı sayısı (10) da belirlenmiştir.

3.9.3. Aşırı Gradyan Artırma

Bu tez kapsamında Python programlama dilinde XGB Classifier Kütüphanesi kullanılmıştır. RO yaklaşımında olduğu gibi ağaç derinliği 20 ile sınırlandırılmıştır. Öğrenme oranı 0,1 olarak belirlenmiştir. Öğrenme 1.000 iterasyon ile sınırlandırılmıştır.

Kontrol grubu etiketlerinin atanması esnasında kontrol altında olan hastalar ve kontrol altında olmayan hastaların yanında dalgalı (düzensiz) ve azalan kan şekeri gibi diğer soyut sınıflarımız bulunmaktadır. Dalgalı ve azalan kan şekeri sınıfında olanlar bazı durumlarda kontrol altında olan, bazı durumlarda da kontrol altında olmayan içerisinde değerlendirilebilmektedir. Bu sınıflarda net bir ayırım yapılamamaktadır. Bu sebeple, bu tez çalışmasında kan şekeri kontrol altında olan hastalar (KG3), diğer üç gruptan

ayrıştırılmaya çalışılmış ve bu sayede ikili sınıflandırma problemi olarak değerlendirilmek üzere bir senaryo üretilmiş ve bu çizgide bir çalışma yapılmıştır.

3.9.4. Trend Analizi Çalışmaları

01.01.2017 ve 31.12.2020 tarihleri arasında en az 4 adet HbA1c sonucu olan hastaların HbA1c sonuçları, yatayda (X eksen) 01.01.2017 tarihi 0 kabul edilecek şekilde ve her gün için X değeri 1 artacak şekilde (0 gün – 1461 gün), düşeyde (Y eksen) yüzde birimi ile çalışılmış HbA1c sonuçları, Oracle Database 11g Enterprise Edition Release 11.2.0.4.0 kullanılarak regr_slope fonksiyonu ile lineer regresyon hesabı yapılmış ve elde edilen eğim (slope) değerleri 1.000 ile çarpılarak çalışmaya dahil edilmiştir. Bu değerler her bir veri kümesinde bir kolon olarak saklanmakta ancak bağımsız değişkenler içerisinde değerlendirilmediği için model girdisi olarak kullanılmamaktadır. Esasında bu değer kan şekerinin artış eğiliminde mi azalış eğiliminde mi olduğunu belirtmek adına üretilmiş olup bağımlı değişken niteliğindedir. Bir başka ifadeyle kan şekerinin hangi trendde değişmekte olduğunu belirlemede kullanılabilecek olan bir sonuç niteliğidir. Burada üretilen slope değerleri veri kümesine bağımlı olarak $[-\infty, +\infty]$ aralığında değer alabilmektedir (1000 ile çarpılmış bir değer olduğundan). Veri kümesinde hangi kayıtların kan şekerinin artan eğiliminde olduğunu, hangilerinin azalan eğiliminde olduğunu tespit etmek için bir eşik değere ihtiyaç duyulmuştur. Bu eşik değer, sürekli değer alan bu niteliği sınıf etiketlerine tekabül edecek şekilde kategorize etmektedir.

Yapılan ilk çalışmalarda slope değerinin üç kategoriye ayrılması planlanmıştır. Bu kategoriler azalan, durağan ve artan olarak değerlendirilmiştir. Bunun için iki eşit değere ihtiyaç duyulmuş ve bu eşit değerler empirik olarak her veri kümesine en uygun, en yüksek performans sunan değerler olarak çoklu deneyler sonucunda tanımlanmıştır. Buna göre -3'ün altında slope değeri olanlar azalan, +1 değerinin üzerindeki ise artan kan şekerini işaret etmektedir. Arada kalan kısımdaki hastaların kan şekeri trendi durağan olarak kabul edilmiştir.

Bu üç sınıflı yaklaşımın yanında kan şekerinin artan-azalan olmasına yönelik olarak iki sınıflı bir sınıf etiketi ataması da yapılmıştır. Bunun için gerekli olan eşik değere yine çoklu deneyler sonucunda karar verilmiş ve tüm veri kümeleri için $[0, -5]$ aralığındaki eşik değerinin model performanslarında çok büyük değişim yaratmadığı ancak bu aralığın

dışında performans değerlerinin çoğu durumda olumsuz etkilendiği görülmüştür. Bu durumdan yola çıkılarak -5 değeri eşik kabul edilmiştir ve bu değer altındaki slope değerlerinin trend etiketi azalan; üstündeki slope değerlerinin trend etiketi ise artan olarak kabul edilmiştir. Gerçekleştirilen üç sınıflı ve iki sınıflı trend analizinin performans ölçümleri yine 5 katlı çapraz geçерleme ile doğruluk, anma, duyarlılık, F ölçütü değerleriyle yapılmıştır.

3.9.5. Kontrol Grubu Tahmini ve Trend Analizi Seri Modeli

Çalışmamızda kontrol grubu tahminleme problemine kan şekeri kontrol altında olan hastaların sınıflandırılması ve kontrol altında olmayan hastaların kan şekeri trendlerinin tespit edilmesi olmak üzere iki adımda yaklaşılmıştır. Buna göre bu iki amacı gerçekleştirmek adına iki makine öğrenmesi modelinin seri bağılı olarak modellenmesi yapılmıştır. İlk olarak kontrol grubu modeli ile kontrol altında olan hastalar diğer hastalardan ayrılır ve kontrol altında olmayan hastalar trend analizine tabi tutularak kan şekerinin artma veya azalma eğiliminde olduğu ikili sınıflandırma yaklaşımı ile tespit edilir. Önerilen seri bağılı modelde her bir alt model bağımsız olarak yapılan deneylerdeki performans değerlendirmesinden elde edilen bulgular ışığında XGBoost olarak belirlenmiştir. Bu modelin eğitiminde veri kümelerinin her biri %75 eğitim, %25 test olmak üzere iki alt kümeye ayrılmıştır. Bu veri ayrıştırmada tabaka örnekleme yapılmış bu sayede orijinal veri kümesindeki sınıf etiketlerinin dağılımı eğitim ve test kümelerinde korunmuştur.

3.10. İstatistik Metodolojileri ile Yapılan Analizler

Çalışmada sınıflandırma performans ölçüm yöntemleri ile değerlendirme yapılmıştır. Buna göre karmaşıklık matrisi kullanılarak doğruluk (accuracy, A) (1), anma (recall, R) (2), duyarlılık (precision, P) (3), doğru negatif oranı (True Negative Rate, TNR) (5) ve anma ile duyarlılık değerlerinin harmonik ortalaması olan F ölçüt (4) kullanılmıştır. Model için bu metriklerin makro ortalama değerleri de hesaplanmış ve karşılaştırmalarda göz önüne alınmıştır. Metriklere ait formüller şu şekildedir;

$$A = (TP + TN) / (TP + TN + FP + FN) \quad (1)$$

$$R = (TP) / (TP + FN) \quad (2)$$

$$R = (TP) / (TP+FP) \quad (3)$$

$$F = 2(P.R) / (P+R) \quad (4)$$

$$TNR = (TN) / (TN+FP) \quad (5)$$

Makine öğrenmesi için oluşturulan veri seti klasik istatistik yöntemleri kullanılmak suretiyle de analiz edilmiştir. Bunun için, R tabanlı bir yazılım olan Jamovi'nin 2.2.5 versiyonu ile analiz çalışmaları yapılmıştır. Analizler hem tek değişkenli hem de çok değişkenli şekilde yapılmıştır. Analiz kolaylığı ve performans için MÖ veri setindeki kullanılmış antidiyabetik ilaç toplam dozları mg cinsinden gr ve kg'a insülin dozları 1000 IU birimler olacak şekilde çevrilmiş ve bu şekilde analize tabi tutulmuştur. İstatistik metodolojileri ile makine öğrenimi algoritmalarının performansını değerlendirmek için eğri altında kalan alan (%95 Güven Aralığı), duyarlılık, özgüllük, kesinlik, F1 puanı ve doğruluk kullanılmıştır. Her algoritma için Youden Index'e göre karar eşikleri düzenlenmiştir.

Sayısal veriler medyan (Q1-Q3, 25.-75. persentil) veya ortalama±standart sapma olarak, kategorik veriler ise sayı ve yüzde olarak özetlenmektedir. Verilerin normal dağılıma uygunluğu, Q-Q grafikleri kullanılarak incelenmiştir. İki bağımsız grup arasındaki sayısal verilerin karşılaştırılmasında Mann Whitney U-testi, kategorik değişkenlerin karşılaştırılmasında ise ki-kare testi kullanılmıştır. Makine öğrenimi modellerinin ayırt edici yeteneği, ROC (Receiver Operating Characteristics) AUC (Area Under Curve, Eğri Altındaki Alan) analizi ve %95 güven aralığı (GA) ile değerlendirilmiştir. Tüm istatistiksel analizlerde anlamlılık sınırı $p < 0.05$ alınmıştır. Etki büyüklükleri Psychometrica Etki Büyüklüklerinin Hesaplanması (https://www.psychometrica.de/effect_size) yardımıyla Cohen'in d değerine dönüştürülmüştür.

4. BULGULAR

4.1. Türkiye Geneline Ait Bulgular

4.1.1. e-Nabız Sistemi

Diyabetin epidemiyolojisi hakkındaki çalışmalarımız Türkiye Cumhuriyeti vatandaşlarının tümünü kapsadığından sağlık verilerinin istatistik değerlendirmeleri yapılırken elde edilen verilerin göz önünde bulundurulması gereken özelliklerinden birisi e-Nabız'da kayıtlı vaka sayılarının yıllara göre toplam nüfus içerisindeki oranının ortaya konmasını gerektirmesidir. Tablo 4.1'de, Sağlık tesislerine başvuruların cinsiyete göre değişimi ve 2015 yılında kullanıma alınan bu sistemin her geçen yıl kapsayıcılığının artışı görülmektedir.

Tablo 4.1. Yıllara göre e-Nabız'ın her bir yıl için kapsayıcılık oranı (15 yaş ve üzeri)

Yıllar	Başvuru Sayısı			Kadın/ Erkek	Başvuru Kaydı Bulunan Tekil Kişi Sayısı	e-Nabız'da Kaydı Bulunan Tekil Kişi Sayısı	Nüfus	e-Nabız Kapsama Oranı (%)
	Kadın	Erkek	Toplam					
2016	260.122.365	162.759.765	422.882.130	1,60	51.226.589	55.421.914	60.889.089	91,0
2017	318.154.628	212.916.199	531.070.827	1,49	54.017.673	58.594.269	61.777.037	94,8
2018	355.942.800	240.338.449	596.281.249	1,48	56.000.449	60.687.185	62.819.553	96,6
2019	380.654.089	261.520.122	642.174.211	1,46	57.545.113	62.442.436	63.942.652	97,7
2020	274.823.478	203.424.601	478.248.079	1,35	55.916.083	63.968.612	64.546.125	99,1

4.1.2. Diyabet Sıklığı

e-Nabız'ın 2015 yılında aktive edilmiş olmasına bağlı olarak ilk dönemde çok sayıda vakanın kaydı sisteme ilk kez yapılmıştır. 2020 yılındaki Pandemi, Covid-19 şüphesi sebebiyle başvurular haricindeki diğer başvuruların azalmasına sebep olmuştur. Buna bağlı olarak diyabetli yeni kayıt sayısının 2020 için azalma eğiliminde olduğu söylenebilir. Aşağıda sunulan Tablo 4.2'deki sayılara, Bölüm 3.4.9'da anlatılan

yöntemlerle yapılan sorgulamalardan elde edilen, diyabet tanı ve/veya reçete ve/veya raporu olmadığı halde diyabetli olduğu var sayılan vakalar dahil edilmiştir.

Tablo 4.2. Yıllara göre e-Nabız sisteminde kaydı bulunanlara göre diyabetli sayısı ve prevalans (%)

Yıl	Yıl sonu DM sayısı	15 yaş ve üzeri yılsonu nüfus	Prevalans (%)
2016	4.410.481	60.889.089	7,24
2017	5.414.900	61.777.037	8,77
2018	6.148.793	62.819.553	9,79
2019	6.775.054	63.942.652	10,60
2020	7.178.674	64.546.125	11,12

Türkiye genelinde 15 yaş ve üzeri nüfusun yaş grupları ve cinsiyete göre dağılımı aşağıdaki Tablo 4.3’de verilmiştir. Prevalans değerleri bu nüfus dikkate alınarak hesaplanmıştır. Türkiye genelinde e-Nabız’da kayıtlı vakaların yaş ve cinsiyet gruplarına göre dağılım detayları 2016 (Tablo 4.4), 2017 (Tablo 4.5), 2018 (Tablo 4.6), 2019 (Tablo 4.7) ve 2020 (Tablo 4.8) yılları için verilmiştir. Tablolarda, cinsiyet ve DM tipi de gruplandırmaya dahil edilmiştir. DM tipinin nasıl belirlendiğine dair ayrıntılar daha önce Bölüm 3.5.2’de anlatılmıştır. e-Nabız kapsayıcılığı arttıkça prevalans değeri de artmaktadır.

Tablo 4.3. Türkiye geneli 15 yaş ve üzeri nüfusun yaş grupları ve cinsiyete göre dağılımı

Yaş Grubu	2016			2017			2018			2019			2020		
	Erkek	Kadın	Toplam	Erkek	Kadın	Toplam	Erkek	Kadın	Toplam	Erkek	Kadın	Toplam	Erkek	Kadın	Toplam
15-19	3.400.443	3.222.876	6.623.319	3.351.043	3.175.544	6.526.587	3.299.449	3.124.818	6.424.267	3.254.891	3.076.703	6.331.594	3.201.588	3.028.526	6.230.114
20-24	3.247.764	3.117.959	6.365.723	3.294.336	3.162.174	6.456.510	3.347.297	3.199.832	6.547.129	3.392.374	3.231.704	6.624.078	3.408.434	3.255.202	6.663.636
25-29	3.169.360	3.076.681	6.246.041	3.163.889	3.067.653	6.231.542	3.190.023	3.086.446	6.276.469	3.240.657	3.126.654	6.367.311	3.240.543	3.130.411	6.370.954
30-34	3.196.645	3.113.766	6.310.411	3.189.075	3.107.849	6.296.924	3.205.205	3.127.948	6.333.153	3.221.381	3.141.636	6.363.017	3.199.710	3.119.184	6.318.894
35-39	3.275.175	3.219.158	6.494.333	3.308.413	3.252.283	6.560.696	3.316.603	3.259.469	6.576.072	3.324.759	3.260.084	6.584.843	3.270.512	3.203.071	6.473.583
40-44	2.833.655	2.800.662	5.634.317	2.891.799	2.849.020	5.740.819	2.953.329	2.892.697	5.846.026	3.016.898	2.950.486	5.967.384	3.145.645	3.089.465	6.235.110
45-49	2.412.875	2.335.639	4.748.514	2.556.364	2.498.790	5.055.154	2.670.183	2.640.524	5.310.707	2.772.838	2.760.721	5.533.559	2.788.035	2.775.631	5.563.666
50-54	2.381.640	2.374.604	4.756.244	2.349.139	2.326.316	4.675.455	2.372.182	2.329.142	4.701.324	2.367.577	2.307.796	4.675.373	2.325.190	2.259.442	4.584.632
55-59	1.855.171	1.860.565	3.715.736	1.977.328	1.989.399	3.966.727	2.076.882	2.095.459	4.172.341	2.178.454	2.211.543	4.389.997	2.273.088	2.304.499	4.577.587
60-64	1.636.510	1.706.438	3.342.948	1.651.215	1.720.023	3.371.238	1.692.130	1.753.731	3.445.861	1.754.500	1.800.269	3.554.769	1.764.938	1.809.456	3.574.394
65-69	1.132.464	1.280.073	2.412.537	1.188.986	1.322.918	2.511.904	1.245.979	1.366.228	2.612.207	1.301.371	1.421.301	2.722.672	1.399.052	1.539.663	2.938.715
70-74	763.121	917.371	1.680.492	784.614	952.653	1.737.267	835.353	1.021.569	1.856.922	907.850	1.109.063	2.016.913	960.742	1.170.963	2.131.705
75-79	512.607	689.443	1.202.050	533.757	715.428	1.249.185	539.825	722.725	1.262.550	560.695	747.604	1.308.299	583.671	771.675	1.355.346
80-84	336.206	473.119	809.325	330.240	471.436	801.676	318.882	474.854	793.736	323.732	493.998	817.730	339.767	521.432	861.199
85-89	136.238	265.520	401.758	152.317	282.516	434.833	182.957	302.957	485.914	192.938	304.472	497.410	177.532	289.216	466.748
90+	38.756	106.585	145.341	43.519	117.001	160.520	47.136	127.739	174.875	50.674	137.029	187.703	53.128	146.714	199.842
TOPLAM	30.328.630	30.560.459	60.889.089	30.766.034	31.011.003	61.777.037	31.293.415	31.526.138	62.819.553	31.861.589	32.081.063	63.942.652	32.131.575	32.414.550	64.546.125

Tablo 4.4. 2016 yılı yaş grupları, DM tipi ve cinsiyete göre diyabetli kayıt sayısı ve prevalansı (%)

	2016 YILI 15 YAŞ ve ÜSTÜ DİYABET PREVALANS TABLOSU																	
	Tip 1 DM						Tip 2 DM						Toplam (Tip 1 DM + Tip 2 DM)					
	Erkek		Kadın		Tip 1 Toplamı		Erkek		Kadın		Tip 2 Toplamı		Erkek		Kadın		Toplam	
	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.
Yaş Grubu	n	%	N	%	N	%	n	%	n	%	N	%	n	%	n	%	n	%
15-19	3.988	0,12	3.510	0,11	7.498	0,11	3.030	0,09	7.417	0,23	10.447	0,16	7.018	0,21	10.927	0,34	17.945	0,27
20-24	3.960	0,12	3.558	0,11	7.518	0,12	3.882	0,12	14.284	0,46	18.166	0,29	7.842	0,24	17.842	0,57	25.684	0,40
25-29	3.999	0,13	3.518	0,11	7.517	0,12	7.355	0,23	22.301	0,72	29.656	0,47	11.354	0,36	25.819	0,84	37.173	0,60
30-34	4.406	0,14	3.736	0,12	8.142	0,13	18.331	0,57	38.001	1,22	56.332	0,89	22.737	0,71	41.737	1,34	64.474	1,02
35-39	4.862	0,15	3.683	0,11	8.545	0,13	44.355	1,35	73.024	2,27	117.379	1,81	49.217	1,50	76.707	2,38	125.924	1,94
40-44	4.381	0,15	2.628	0,09	7.009	0,12	87.405	3,08	128.386	4,58	215.791	3,83	91.786	3,24	131.014	4,68	222.800	3,95
45-49	4.829	0,20	2.605	0,11	7.434	0,16	142.764	5,92	199.146	8,53	341.910	7,20	147.593	6,12	201.751	8,64	349.344	7,36
50-54	7.083	0,30	4.299	0,18	11.382	0,24	234.464	9,84	337.956	14,23	572.420	12,04	241.547	10,14	342.255	14,41	583.802	12,27
55-59	8.837	0,48	6.406	0,34	15.243	0,41	258.551	13,94	363.695	19,55	622.246	16,75	267.388	14,41	370.101	19,89	637.489	17,16
60-64	12.452	0,76	10.661	0,62	23.113	0,69	296.396	18,11	416.887	24,43	713.283	21,34	308.848	18,87	427.548	25,05	736.396	22,03
65-69	12.652	1,12	13.004	1,02	25.656	1,06	236.996	20,93	349.017	27,27	586.013	24,29	249.648	22,04	362.021	28,28	611.669	25,35
70-74	11.243	1,47	13.088	1,43	24.331	1,45	164.887	21,61	251.017	27,36	415.904	24,75	176.130	23,08	264.105	28,79	440.235	26,20
75-79	8.468	1,65	11.496	1,67	19.964	1,66	104.383	20,36	172.342	25,00	276.725	23,02	112.851	22,02	183.838	26,66	296.689	24,68
80-84	5.316	1,58	7.786	1,65	13.102	1,62	58.535	17,41	100.026	21,14	158.561	19,59	63.851	18,99	107.812	22,79	171.663	21,21
85-89	1.788	1,31	3.638	1,37	5.426	1,35	19.444	14,27	45.026	16,96	64.470	16,05	21.232	15,58	48.664	18,33	69.896	17,40
90+	344	0,89	1.115	1,05	1.459	1,00	4.254	10,98	13.585	12,75	17.839	12,27	4.598	11,86	14.700	13,79	19.298	13,28
Toplam	98.608	0,33	94.731	0,31	193.339	0,32	1.685.032	5,56	2.532.110	8,29	4.217.142	6,93	1.783.640	5,88	2.635.645	8,62	4.410.481	7,24

Tablo 4.5. 2017 yılı yaş grupları, DM tipi ve cinsiyete göre diyabetli kayıt sayısı ve prevalansı (%)

	2017 YILI 15 YAŞ ve ÜSTÜ DİYABET PREVALANS TABLOSU																	
	Tip 1 DM						Tip 2 DM						Toplam (Tip 1 DM + Tip 2 DM)					
	Erkek		Kadın		Tip 1 Toplamı		Erkek		Kadın		Tip 2 Toplamı		Erkek		Kadın		Toplam	
	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.
Yaş Grubu	n	%	N	%	N	%	n	%	n	%	n	%	n	%	n	%	n	%
15-19	4.488	0,13	3.994	0,13	8.482	0,13	5.081	0,15	11.861	0,37	16.942	0,26	9.569	0,29	15.855	0,50	25.424	0,39
20-24	4.587	0,14	4.153	0,13	8.740	0,14	6.566	0,20	24.867	0,79	31.433	0,49	11.153	0,34	29.020	0,92	40.173	0,62
25-29	4.642	0,15	4.223	0,14	8.865	0,14	11.404	0,36	37.330	1,22	48.734	0,78	16.046	0,51	41.553	1,35	57.599	0,92
30-34	4.935	0,15	4.584	0,15	9.519	0,15	26.637	0,84	58.567	1,88	85.204	1,35	31.572	0,99	63.151	2,03	94.723	1,50
35-39	5.627	0,17	4.858	0,15	10.485	0,16	60.567	1,83	103.274	3,18	163.841	2,50	66.194	2,00	108.132	3,32	174.326	2,66
40-44	5.176	0,18	3.208	0,11	8.384	0,15	113.776	3,93	166.895	5,86	280.671	4,89	118.952	4,11	170.103	5,97	289.055	5,04
45-49	5.702	0,22	3.009	0,12	8.711	0,17	186.838	7,31	259.240	10,37	446.078	8,82	192.540	7,53	262.249	10,50	454.789	9,00
50-54	7.416	0,32	4.280	0,18	11.696	0,25	278.858	11,87	393.335	16,91	672.193	14,38	286.274	12,19	397.615	17,09	683.889	14,63
55-59	9.577	0,48	6.547	0,33	16.124	0,41	324.581	16,42	452.892	22,77	777.473	19,60	334.158	16,90	459.439	23,09	793.597	20,01
60-64	12.590	0,76	10.286	0,60	22.876	0,68	347.790	21,06	481.635	28,00	829.425	24,60	360.380	21,83	491.921	28,60	852.301	25,28
65-69	13.140	1,11	12.786	0,97	25.926	1,03	291.154	24,49	414.700	31,35	705.854	28,10	304.294	25,59	427.486	32,31	731.780	29,13
70-74	11.301	1,44	13.025	1,37	24.326	1,40	199.953	25,48	301.114	31,61	501.067	28,84	211.254	26,92	314.139	32,98	525.393	30,24
75-79	8.985	1,68	11.959	1,67	20.944	1,68	132.012	24,73	211.555	29,57	343.567	27,50	140.997	26,42	223.514	31,24	364.511	29,18
80-84	5.517	1,67	8.020	1,70	13.537	1,69	72.308	21,90	120.874	25,64	193.182	24,10	77.825	23,57	128.894	27,34	206.719	25,79
85-89	2.183	1,43	4.219	1,49	6.402	1,47	27.458	18,03	59.331	21,00	86.789	19,96	29.641	19,46	63.550	22,49	93.191	21,43
90+	481	1,11	1.386	1,18	1.867	1,16	6.535	15,02	19.028	16,26	25.563	15,93	7.016	16,12	20.414	17,45	27.430	17,09
Toplam	106.347	0,35	100.537	0,32	206.884	0,33	2.091.518	6,80	3.116.498	10,05	5.208.016	8,43	2.197.865	7,14	3.217.035	10,37	5.414.900	8,77

Tablo 4.6. 2018 yılı yaş grupları, DM tipi ve cinsiyete göre diyabetli kayıt sayısı ve prevalansı (%)

	2018 YILI 15 YAŞ ve ÜSTÜ DİYABET PREVALANS TABLOSU																	
	Tip 1 DM						Tip 2 DM						Toplam (Tip 1 DM + Tip 2 DM)					
	Erkek		Kadın		Tip 1 Toplamı		Erkek		Kadın		Tip 2 Toplamı		Erkek		Kadın		Toplam	
	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.
Yaş Grubu	n	%	N	%	N	%	n	%	n	%	n	%	n	%	n	%	n	%
15-19	4.767	0,14	4.242	0,14	9.009	0,14	6.719	0,20	14.619	0,47	21.338	0,33	11.486	0,35	18.861	0,60	30.347	0,47
20-24	5.048	0,15	4.544	0,14	9.592	0,15	9.082	0,27	34.523	1,08	43.605	0,67	14.130	0,42	39.067	1,22	53.197	0,81
25-29	4.954	0,16	4.804	0,16	9.758	0,16	14.999	0,47	50.444	1,63	65.443	1,04	19.953	0,63	55.248	1,79	75.201	1,20
30-34	5.407	0,17	5.406	0,17	10.813	0,17	33.368	1,04	76.634	2,45	110.002	1,74	38.775	1,21	82.040	2,62	120.815	1,91
35-39	5.875	0,18	5.687	0,17	11.562	0,18	72.540	2,19	126.671	3,89	199.211	3,03	78.415	2,36	132.358	4,06	210.773	3,21
40-44	5.624	0,19	3.744	0,13	9.368	0,16	133.042	4,50	193.165	6,68	326.207	5,58	138.666	4,70	196.909	6,81	335.575	5,74
45-49	5.982	0,22	3.212	0,12	9.194	0,17	215.657	8,08	301.544	11,42	517.201	9,74	221.639	8,30	304.756	11,54	526.395	9,91
50-54	7.348	0,31	4.095	0,18	11.443	0,24	311.905	13,15	430.690	18,49	742.595	15,80	319.253	13,46	434.785	18,67	754.038	16,04
55-59	9.511	0,46	6.226	0,30	15.737	0,38	371.191	17,87	516.853	24,67	888.044	21,28	380.702	18,33	523.079	24,96	903.781	21,66
60-64	11.720	0,69	9.103	0,52	20.823	0,60	383.939	22,69	526.829	30,04	910.768	26,43	395.659	23,38	535.932	30,56	931.591	27,04
65-69	12.506	1,00	11.591	0,85	24.097	0,92	331.154	26,58	460.566	33,71	791.720	30,31	343.660	27,58	472.157	34,56	815.817	31,23
70-74	10.871	1,30	12.435	1,22	23.306	1,26	233.563	27,96	351.095	34,37	584.658	31,49	244.434	29,26	363.530	35,59	607.964	32,74
75-79	8.397	1,56	10.852	1,50	19.249	1,52	147.495	27,32	234.423	32,44	381.918	30,25	155.892	28,88	245.275	33,94	401.167	31,77
80-84	5.074	1,59	7.515	1,58	12.589	1,59	80.425	25,22	136.891	28,83	217.316	27,38	85.499	26,81	144.406	30,41	229.905	28,96
85-89	2.595	1,42	4.380	1,45	6.975	1,44	38.266	20,92	72.246	23,85	110.512	22,74	40.861	22,33	76.626	25,29	117.487	24,18
90+	509	1,08	1.504	1,18	2.013	1,15	8.238	17,48	24.489	19,17	32.727	18,71	8.747	18,56	25.993	20,35	34.740	19,87
Toplam	106.188	0,34	99.340	0,32	205.528	0,33	2.391.583	7,64	3.551.682	11,27	5.943.265	9,46	2.497.771	7,98	3.651.022	11,58	6.148.793	9,79


Tablo 4.7. 2019 yılı yaş grupları, DM tipi ve cinsiyete göre diyabetli kayıt sayısı ve prevalansı (%)

Yaş Grubu	2019 YILI 15 YAŞ ve ÜSTÜ DİYABET PREVALANS TABLOSU																	
	Tip 1 DM						Tip 2 DM						Toplam (Tip 1 DM + Tip 2 DM)					
	Erkek		Kadın		Tip 1 Toplamı		Erkek		Kadın		Tip 2 Toplamı		Erkek		Kadın		Toplam	
	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.
	n	%	N	%	N	%	n	%	n	%	n	%	n	%	n	%	n	%
15-19	5.044	0,15	4.525	0,15	9.569	0,15	8.142	0,25	16.094	0,52	24.236	0,38	13.186	0,41	20.619	0,67	33.805	0,53
20-24	5.428	0,16	4.846	0,15	10.274	0,16	11.346	0,33	41.407	1,28	52.753	0,80	16.774	0,49	46.253	1,43	63.027	0,95
25-29	5.237	0,16	5.285	0,17	10.522	0,17	17.698	0,55	62.301	1,99	79.999	1,26	22.935	0,71	67.586	2,16	90.521	1,42
30-34	5.702	0,18	5.992	0,19	11.694	0,18	38.328	1,19	91.543	2,91	129.871	2,04	44.030	1,37	97.535	3,10	141.565	2,22
35-39	6.077	0,18	6.523	0,20	12.600	0,19	81.789	2,46	144.804	4,44	226.593	3,44	87.866	2,64	151.327	4,64	239.193	3,63
40-44	5.982	0,20	4.409	0,15	10.391	0,17	145.764	4,83	212.210	7,19	357.974	6,00	151.746	5,03	216.619	7,34	368.365	6,17
45-49	6.131	0,22	3.428	0,12	9.559	0,17	239.692	8,64	334.865	12,13	574.557	10,38	245.823	8,87	338.293	12,25	584.116	10,56
50-54	7.180	0,30	3.825	0,17	11.005	0,24	332.510	14,04	449.851	19,49	782.361	16,73	339.690	14,35	453.676	19,66	793.366	16,97
55-59	9.232	0,42	5.780	0,26	15.012	0,34	413.617	18,99	575.870	26,04	989.487	22,54	422.849	19,41	581.650	26,30	1.004.499	22,88
60-64	10.972	0,63	8.109	0,45	19.081	0,54	416.050	23,71	561.532	31,19	977.582	27,50	427.022	24,34	569.641	31,64	996.663	28,04
65-69	11.698	0,90	10.471	0,74	22.169	0,81	369.344	28,38	508.459	35,77	877.803	32,24	381.042	29,28	518.930	36,51	899.972	33,05
70-74	10.464	1,15	11.436	1,03	21.900	1,09	266.787	29,39	398.990	35,98	665.777	33,01	277.251	30,54	410.426	37,01	687.677	34,10
75-79	7.928	1,41	10.130	1,35	18.058	1,38	165.289	29,48	261.943	35,04	427.232	32,66	173.217	30,89	272.073	36,39	445.290	34,04
80-84	4.717	1,46	6.952	1,41	11.669	1,43	89.124	27,53	153.116	31,00	242.240	29,62	93.841	28,99	160.068	32,40	253.909	31,05
85-89	2.589	1,34	4.100	1,35	6.689	1,34	45.238	23,45	80.066	26,30	125.304	25,19	47.827	24,79	84.166	27,64	131.993	26,54
90+	536	1,06	1.537	1,12	2.073	1,10	9.993	19,72	29.027	21,18	39.020	20,79	10.529	20,78	30.564	22,30	41.093	21,89
Toplam	104.917	0,33	97.348	0,30	202.265	0,32	2.650.711	8,32	3.922.078	12,23	6.572.789	10,28	2.755.628	8,65	4.019.426	12,53	6.775.054	10,60

Tablo 4.8. 2020 yılı yaş grupları, DM tipi ve cinsiyete göre diyabetli kayıt sayısı ve prevalansı (%)

Yaş Grubu	2020 YILI 15 YAŞ ve ÜSTÜ DİYABET PREVALANS TABLOSU																	
	Tip 1 DM						Tip 2 DM						Toplam (Tip 1 DM + Tip 2 DM)					
	Erkek		Kadın		Tip 1 Toplamı		Erkek		Kadın		Tip 2 Toplamı		Erkek		Kadın		Toplam	
	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.	Hasta	Prev.
	n	%	n	%	N	%	n	%	n	%	n	%	n	%	n	%	n	%
15-19	5.217	0,16	4.818	0,16	10.035	0,16	8.804	0,27	15.822	0,52	24.626	0,40	14.021	0,44	20.640	0,68	34.661	0,56
20-24	5.807	0,17	5.038	0,15	10.845	0,16	12.755	0,37	44.505	1,37	57.260	0,86	18.562	0,54	49.543	1,52	68.105	1,02
25-29	5.478	0,17	5.486	0,18	10.964	0,17	19.440	0,60	69.558	2,22	88.998	1,40	24.918	0,77	75.044	2,40	99.962	1,57
30-34	5.735	0,18	6.316	0,20	12.051	0,19	40.774	1,27	100.068	3,21	140.842	2,23	46.509	1,45	106.384	3,41	152.893	2,42
35-39	6.151	0,19	6.859	0,21	13.010	0,20	85.188	2,60	150.920	4,71	236.108	3,65	91.339	2,79	157.779	4,93	249.118	3,85
40-44	6.288	0,20	5.226	0,17	11.514	0,18	156.525	4,98	227.441	7,36	383.966	6,16	162.813	5,18	232.667	7,53	395.480	6,34
45-49	6.062	0,22	3.483	0,13	9.545	0,17	249.820	8,96	341.613	12,31	591.433	10,63	255.882	9,18	345.096	12,43	600.978	10,80
50-54	6.783	0,29	3.485	0,15	10.268	0,22	337.834	14,53	447.750	19,82	785.584	17,14	344.617	14,82	451.235	19,97	795.852	17,36
55-59	8.493	0,37	5.121	0,22	13.614	0,30	433.890	19,09	594.076	25,78	1.027.966	22,46	442.383	19,46	599.197	26,00	1.041.580	22,75
60-64	10.095	0,57	7.048	0,39	17.143	0,48	442.327	25,06	589.667	32,59	1.031.994	28,87	452.422	25,63	596.715	32,98	1.049.137	29,35
65-69	10.673	0,76	9.377	0,61	20.050	0,68	395.531	28,27	546.401	35,49	941.932	32,05	406.204	29,03	555.778	36,10	961.982	32,73
70-74	10.027	1,04	10.695	0,91	20.722	0,97	303.387	31,58	448.439	38,30	751.826	35,27	313.414	32,62	459.134	39,21	772.548	36,24
75-79	7.513	1,29	9.224	1,20	16.737	1,23	183.579	31,45	285.100	36,95	468.679	34,58	191.092	32,74	294.324	38,14	485.416	35,81
80-84	4.657	1,37	6.792	1,30	11.449	1,33	101.733	29,94	174.727	33,51	276.460	32,10	106.390	31,31	181.519	34,81	287.909	33,43
85-89	2.269	1,28	3.600	1,24	5.869	1,26	46.500	26,19	82.487	28,52	128.987	27,64	48.769	27,47	86.087	29,77	134.856	28,89
90+	562	1,06	1.606	1,09	2.168	1,08	11.642	21,91	34.387	23,44	46.029	23,03	12.204	22,97	35.993	24,53	48.197	24,12
Toplam	101.810	0,32	94.174	0,29	195.984	0,30	2.829.729	8,81	4.152.961	12,81	6.982.690	10,82	2.931.539	9,12	4.247.135	13,10	7.178.674	11,12

İllere göre diyabet kaba ve yaşa göre ağırlıklandırılmış (age adjusted) prevalansı Tablo 4.9’da verilmiştir. İllere ve yaşa göre ağırlıklandırılmış diyabet prevalansının görsel sunumu Şekil 4.1’de gösterilmiştir. Bu hesaplamalar 2020 yılı sonu verilerine göre yapılmış, Şekil 4.1 buna göre hazırlanmıştır.



Şekil 4.1. İllere göre yaş ağırlıklı (age adjusted) diyabet prevalansı

Tablo 4.9. İl bazında yaş gruplarına göre diyabet prevalansı ve yaş ağırlıklı (age adjusted) prevalans

İLİ	2020 Yılı 15 Yaş ve Üstü Diyabetli Nüfus	2020 Yılı 15 Yaş ve Üstü Toplam Nüfus	Kaba Prevalans (%)	Ağırlıklıkland. Prevalans (%)
ADANA	209.399	1.705.211	12,28	12,37
ADİYAMAN	37.243	451.461	8,25	9,27
AFYONKARAHİSAR	81.439	577.024	14,11	13,03
AĞRI	17.724	350.911	5,05	7,43
AKSARAY	40.790	319.193	12,78	13,00
AMASYA	38.026	274.160	13,87	11,29
ANKARA	486.358	4.495.272	10,82	10,88
ANTALYA	235.142	2.007.114	11,72	11,61
ARDAHAN	4.952	76.208	6,50	5,72
ARTVİN	15.805	141.668	11,16	8,70
AYDIN	130.187	908.473	14,33	12,03
BALIKESİR	142.416	1.034.799	13,76	10,59
BARTIN	26.324	166.263	15,83	12,85
BATMAN	28.310	414.785	6,83	10,52

Tablo 4.9.'un devamı

İLİ	2020 Yılı 15 Yaş ve Üstü Diyabetli Nüfus	2020 Yılı 15 Yaş ve Üstü Toplam Nüfus	Kaba Prevalans (%)	Ağırlıklıkland. Prevalans (%)
BAYBURT	6.147	65.377	9,40	9,18
BİLECİK	23.508	177.217	13,27	11,94
BİNGÖL	11.361	207.193	5,48	6,66
BİTLİS	12.011	238.275	5,04	7,09
BOLU	33.008	258.978	12,75	11,03
BURDUR	31.000	222.060	13,96	11,43
BURSA	279.445	2.440.931	11,45	11,13
ÇANAKKALE	62.559	454.821	13,75	10,97
ÇANKIRI	24.431	158.134	15,45	12,11
ÇORUM	64.985	429.120	15,14	12,17
DENİZLİ	120.560	835.765	14,43	13,20
DİYARBAKIR	82.440	1.203.971	6,85	9,81
DÜZCE	36.481	314.155	11,61	11,03
EDİRNE	50.804	346.501	14,66	11,65
ELAZIĞ	46.650	459.203	10,16	9,95
ERZİNCAN	21.404	188.925	11,33	10,43
ERZURUM	39.402	566.268	6,96	7,54
ESKİŞEHİR	94.660	730.470	12,96	11,64
GAZİANTEP	146.720	1.434.247	10,23	12,89
GİRESUN	55.017	375.774	14,64	11,30
GÜMÜŞHANE	10.550	116.275	9,07	7,94
HAKKÂRİ	6.819	199.996	3,41	6,11
HATAY	130.350	1.206.548	10,80	11,42
IĞDIR	9.118	142.238	6,41	7,79
ISPARTA	57.502	358.963	16,02	14,21
İSTANBUL	1.187.145	12.150.305	9,77	10,87
İZMİR	473.885	3.585.186	13,22	11,87
KAHRAMANMARAŞ	75.486	848.679	8,89	9,59
KARABÜK	30.142	203.809	14,79	12,79
KARAMAN	23.719	199.279	11,90	11,35
KARS	12.302	209.414	5,87	6,54
KASTAMONU	47.071	316.043	14,89	11,20
KAYSERİ	113.725	1.084.241	10,49	10,62
KIRIKKALE	31.951	226.231	14,12	12,33
KIRKLARELİ	45.269	305.585	14,81	12,11
KİRŞEHİR	26.696	195.054	13,69	12,02
KİLİS	11.442	102.039	11,21	12,56
KOCAELİ	176.087	1.536.861	11,46	12,41

Tablo 4.9.'un devamı

İLİ	2020 Yılı 15 Yaş ve Üstü Diyabetli Nüfus	2020 Yılı 15 Yaş ve Üstü Toplam Nüfus	Kaba Prevalans (%)	Ağırlıklıkland. Prevalans (%)
KONYA	204.804	1.718.134	11,92	11,82
KÜTAHYA	65.723	475.992	13,81	11,78
MALATYA	61.593	623.750	9,87	9,55
MANİSA	156.072	1.158.592	13,47	12,05
MARDİN	38.431	570.668	6,73	9,55
MERSİN	188.776	1.441.322	13,10	12,58
MUĞLA	109.300	821.977	13,30	11,34
MUŞ	13.675	272.086	5,03	7,20
NEVŞEHİR	33.751	241.889	13,95	12,57
NİĞDE	33.134	278.263	11,91	11,58
ORDU	80.360	619.325	12,98	10,55
OSMANİYE	50.317	406.226	12,39	12,49
RİZE	33.121	281.819	11,75	10,00
SAKARYA	95.720	820.691	11,66	11,19
SAMSUN	135.112	1.087.302	12,43	10,97
SİİRT	12.820	219.367	5,84	8,83
SİNOP	31.700	180.567	17,56	12,94
SİVAS	64.065	506.296	12,65	11,29
ŞANLIURFA	77.223	1.290.229	5,99	9,13
ŞIRNAK	14.471	343.274	4,22	7,93
TEKİRDAĞ	101.778	852.404	11,94	12,02
TOKAT	60.497	483.321	12,52	10,37
TRABZON	71.591	653.773	10,95	9,41
TUNCELİ	5.747	70.951	8,10	6,94
UŞAK	47.670	300.436	15,87	13,90
VAN	39.888	766.515	5,20	8,06
YALOVA	33.521	221.214	15,15	13,31
YOZGAT	43.518	333.976	13,03	11,13
ZONGULDAK	68.329	489.093	13,97	11,47

4.1.3. Başvuru ve Reçeteler

2019 yılındaki sağlık tesislerine yapılan başvuruların 143.435.375'i, pandeminin etkisi ve raporlu antidiyabetik ilaçların reçetesiz temin edilebilmesine yönelik düzenlemelerle birlikte 2020 yılında 114.682.746'i diyabetli vakalara aittir. Bu başvuruların kliniklere göre dağılımı 2019 ve 2020 yılı için Tablo 4.10'da gösterilmiştir.

Tablo 4.10. 2019 ve 2020 yılı Türkiye geneli 15 yaş ve üzeri diyabetli vaka başvurularının klinik branşlara göre dağılımı

BRANŞLAR	2019 YILI				2020 YILI			
	Branşa Başvuran Tekil Kişi Sayısı	Branşa Başvuru Sayısı	Tüm Başvurular İçindeki Oran (%)	Kişi Başına Düşen Başvuru Sayısı	Branşa Başvuran Tekil Kişi Sayısı	Branşa Başvuru Sayısı	Tüm Başvurular İçindeki Oran (%)	Kişi Başına Düşen Başvuru Sayısı
Aile Hekimliği	6.161.463	49.086.659	34,22	7,97	6.504.192	46.233.768	40,31	7,11
Acil Tıp	4.156.698	17.069.813	11,9	4,11	3.931.200	14.199.475	12,38	3,61
İç Hastalıkları	4.728.139	15.207.782	10,6	3,22	3.701.112	9.848.891	8,59	2,66
Göz Hastalıkları	2.497.428	6.193.342	4,32	2,48	1.799.662	3.797.318	3,31	2,11
Kardiyoloji	2.008.980	5.933.761	4,14	2,95	1.612.827	3.853.758	3,36	2,39
Ağız Diş Sağlığı	1.575.070	5.499.028	3,83	3,49	1.049.472	2.620.189	2,28	2,50
Ortopedi	1.722.039	4.012.252	2,80	2,33	1.268.261	2.679.028	2,34	2,11
FTR	1.343.102	3.704.975	2,58	2,76	905.000	2.092.368	1,82	2,31
Nöroloji	1.431.406	3.435.361	2,40	2,40	1.050.693	2.164.260	1,89	2,06
Genel Cerrahi	1.300.753	3.433.636	2,39	2,64	992.693	2.329.128	2,03	2,35
KBB	1.572.619	2.964.316	2,07	1,88	1.116.547	1.877.481	1,64	1,68
Üroloji	1.085.127	2.867.764	2,00	2,64	792.800	1.822.011	1,59	2,30
Göğüs Hastalıkları	1.194.418	2.827.904	1,97	2,37	926.741	1.831.487	1,60	1,98
Psikiyatri	1.059.253	2.520.823	1,76	2,38	814.137	1.629.005	1,42	2,00
Nefroloji	302.626	2.100.095	1,46	6,94	239.361	2.142.196	1,87	8,95
Jinekoloji	626.936	1.977.977	1,38	3,15	488.515	1.507.981	1,31	3,09
Onkoloji ve Rad. Onk.	183.862	1.942.274	1,35	10,56	175.506	1.949.259	1,70	11,11
Endokrinoloji	665.349	1.784.501	1,24	2,68	484.185	1.070.766	0,93	2,21

Tablo 4.10.'un devamı

BRANŞLAR	2019 YILI				2020 YILI			
	Branşa Başvuran Tekil Kişi Sayısı	Branşa Başvuru Sayısı	Tüm Başvurular İçindeki Oran (%)	Kişi Başına Düşen Başvuru Sayısı	Branşa Başvuran Tekil Kişi Sayısı	Branşa Başvuru Sayısı	Tüm Başvurular İçindeki Oran (%)	Kişi Başına Düşen Başvuru Sayısı
Dermatoloji	917.260	1.695.912	1,18	1,85	609.108	1.003.637	0,88	1,65
Nöroşirürji	676.945	1.540.066	1,07	2,28	490.083	1.023.173	0,89	2,09
Diğer	709.280	1.185.642	0,83	1,67	2.151.272	3.940.011	3,44	1,83
KVC	449.346	1.109.790	0,77	2,47	319.615	726.002	0,63	2,27
Enfeksiyon Hast.	409.983	1.042.380	0,73	2,54	502.558	1.012.721	0,88	2,02
Gastroenteroloji	343.614	956.082	0,67	2,78	266.504	657.028	0,57	2,47
Anesteziyoloji ve R.	505.788	882.211	0,62	1,74	352.885	597.678	0,52	1,69
Lab. ve Görüntüleme	485.622	863.959	0,60	1,78	493.646	869.494	0,76	1,76
Hematoloji	121.171	622.871	0,43	5,14	102.230	518.902	0,45	5,08
Çocuk Klinikleri	67.649	425.068	0,30	6,28	63.034	311.727	0,27	4,95
Plastik Cerrahi	120.804	315.883	0,22	2,61	81.072	196.470	0,17	2,42
Göğüs Cerrahisi	100.081	230.632	0,16	2,30	81.160	175.734	0,15	2,17
Bilinmeyen	1.715	2.616	0,00	1,53	1.232	1.800	0,00	1,46

Diyabetik vakaların başvurdukları kurum türü bilgisi ise 2019 ve 2020 yılları için Tablo 4.11’de verilmiştir.

Tablo 4.11. 2019 ve 2020 yıllarında diyabetik vakaların başvurularının kurum türlerine göre dağılımı

KURUM TÜRÜ	2019 YILI				2020 YILI			
	Toplam Başvuru Sayısı	Başvuran Tekil Kişi Sayısı	Tüm Başvurular Arasındaki Oran (%)	Kişi Başına Düşen Başvuru Sayısı	Toplam Başvuru Sayısı	Başvuran Tekil Kişi Sayısı	Tüm Başvurular Arasındaki Oran (%)	Kişi Başına Düşen Başvuru Sayısı
Aile Sağlığı Merkezi	48.115.629	6.121.319	33,55	7,86	45.388.591	6.470.535	39,58	7,01
Özel Tıp Merkezi	2.639.789	1.042.146	1,84	2,53	2.275.754	984.050	1,98	2,31
Devlet Hastanesi	69.485.138	5.966.734	48,44	11,65	44.183.626	5.618.841	38,53	7,86
Özel Hastane	10.993.997	2.478.889	7,66	4,44	10.229.384	2.524.332	8,92	4,05
Devlet Üniversitesi Hastanesi	8.554.117	1.360.054	5,96	6,29	6.121.628	1.152.332	5,34	5,31
Özel Üniversite Hastanesi	1.477.569	287.275	1,03	5,14	1.230.280	277.802	1,07	4,43
Diğer	1.696.699	255.338	1,18	6,64	2.075.747	242.329	1,81	8,57
Bilinmeyen	472.437	310.763	0,33	1,52	3.177.736	1.994.300	2,77	1,59

Diyabetik vakaların başvuru ve reçete bilgileri Tablo 4.12’de özetlenmiştir. Tablodaki sayılara Bölüm 3.4.9’da anlatılan yöntemlerle yapılan sorgulamalarla elde edilen, diyabet tanı ve/veya reçete ve/veya raporu olmadığı halde diyabetli olduğu kabul edilen vakalar dahil edilmemiştir, çünkü bu vakalara ait antidiyabetik reçete kaydı zaten bulunmamaktadır.

Tablo 4.12. 2016-2020 yıllarında diyabetik vakaların muayene ve reçete bilgileri

(AD: Antidiyabetik, OAD: Oral Antidiyabetik)

Yıl	DM Başvuran Tekil Hasta Sayısı	DM Toplam Başvuru Sayısı	DM Hasta Başına Başvuru Sayısı	DM Hasta Reçete Sayısı	DM Hasta Başına Reçete Sayısı	AD İlaç İçeren Reçete Sayısı	Hasta Başına AD Reçete Sayısı	İnsülin İçeren Reçete Sayısı	Hasta Başına İnsülin Reçete Sayısı	OAD İçeren Reçete Sayısı	*Hasta Başına OAD Reçete Sayısı
2016	4.245.285	70.006.821	16,49	35.221.318	8,30	11.681.063	2,75	2.568.994	0,61	10.004.095	2,36
2017	5.181.951	103.031.271	19,88	55.415.035	10,69	15.822.349	3,05	3.429.845	0,66	13.684.364	2,64
2018	5.878.530	124.372.354	21,16	67.003.292	11,40	18.005.434	3,06	3.794.701	0,65	15.684.592	2,67
2019	6.487.329	143.435.375	22,11	75.903.953	11,70	19.605.386	3,02	3.946.179	0,61	17.234.687	2,66
2020	6.890.450	114.682.746	16,64	56.039.579	8,13	11.269.523	1,64	1.877.933	0,27	10.105.437	1,47

* Hasta başına OAD Reçete Sayısı beklenenden düşüktür. Bunun nedenleri şunlar olabilir; Covid-19 Pandemisi dolayısıyla SGK’nın raporlu ilaçların reçete ettirilmeksizin doğrudan Eczanelerden alınabileceğine dair tebliği nedeniyle 2020 yılı Antidiyabetik İçeren Reçete sayısındaki anlamlı düşüşler dikkati çekmektedir. Reçetelerin daima elektronik reçete olarak düzenlenmesi zorunluluğu olmadığından manuel reçete de düzenlenebilmektedir. Bu reçete kayıtları ile cepten harcama yapmak suretiyle doğrudan eczanelerden alınan ilaçlar bizim üzerinde çalıştığımız sistemlerde kayıt altına alınmamaktadır. Bir başka neden, bazı hastaların ilaçlarını düzenli olarak almıyor olmaları olabilir.

Aşağıdaki Tablo 4.13’de yıllara göre, 15 yaş ve üstü, Diyabet Kaydı Bulunmayan Nüfusun (DKBN) kişi başına düşen başvuru ve reçete sayı ortalamaları kaba şekilde verilmiştir. DKBN, TÜİK tarafından yayımlanan Toplam Nüfustan (TN) Diyabetik Nüfus (DN) çıkarılmak suretiyle elde edilmiştir. Bu tablodaki DN değerlerine, hiçbir diyabet tanısı ya da reçetesi almadığı halde yapılan AKŞ ölçüm sonuçlarına göre DM olarak kabul edilmesi gereken vaka kayıtları bu kez eklenmiştir.

Tablo 4.13. Yıllara göre diyabetik olmayan kişilere ait başvuru ve reçete dağılımı

Yıl	DKBN	Diyabetik Nüfus	Toplam Nüfus	DKBN Kişi Başına Başvuru	DKBN Kişi Başına Reçete
2016	56.478.608	4.410.481	60.889.089	6,60	3,20
2017	56.362.137	5.414.900	61.777.037	8,10	4,50
2018	56.670.760	6.148.793	62.819.553	8,80	5,10
2019	57.167.598	6.775.054	63.942.652	9,19	5,40
2020	57.367.451	7.178.674	64.546.125	6,80	4,00

4.2. İstanbul’a Ait Bulgular

İstanbul iline ait bulgular, Türkiye geneli için elde edilmiş bulgulara benzer şekilde tablolaştırılmış ve aşağıda sunulmuştur.

4.2.1. İstanbul Diyabet Sıklığı

Pandemi öncesi ve pandemi döneminin karşılaştırılmasını da sağlaması bakımından 2019 ve 2020 yılı verilerinin ele alındığı bir dizi çalışma yapılmıştır. Bunlardan ilki yılsonu toplam DM vaka sayısı ve bunların aynı yaş grubundaki toplam nüfusa oranı şeklinde Tablo 4.14’de özetlenmiştir.

Tablo 4.14. 2019 ve 2020 yıllarında kayıt sistemine giren diyabet vakaları ve yıllık prevalans (%)

Yıl	Yılsonu DM sayısı	15 yaş ve üzeri yılsonu nüfus	Prevalans
2019	1.115.545	12.156.241	9,18
2020	1.187.145	12.150.305	9,77

2017 yılında İstanbul’da, DM vakalarının ilçelere göre dağılımı, Şekil-4.2’de görsel olarak sunulmuştur.



Şekil 4.2. İstanbul’da, DM vakalarının ilçelere göre dağılımı yoğunluk skalası haritası
İstanbul, yaş ve cinsiyet gruplarına göre vaka sayıları detayları 2019 (Tablo 4.15), 2020 (Tablo 4.16) yılları için verilmiştir.

Tablo 4.15. İstanbul 2019 yılı yaş grupları, DM tipi ve cinsiyete göre diyabetli kayıt sayısı ve prevalansı (%)

	2019 YILI 15 YAŞ ÜSTÜ DİYABET PREVALANS TABLOSU																				
	TÜİK NÜFUS 2019			Tip 1 DM 2019						Tip 2 DM 2019						Toplam (Tip 1 DM + Tip 2 DM) 2019					
	Erkek	Kadın	Toplam	Erkek		Kadın		Tip 1 Toplamı		Erkek		Kadın		Tip 2 Toplamı		Erkek		Kadın		Toplam	
Yaş Grubu	n	n	n	n	Prev.	n	Prev.	n	Prev.	n	Prev.	n	Prev.	n	Prev.	n	Prev.	n	Prev.	n	Prev.
15-19	563.324	526.181	1.089.505	941	0,17	797	0,15	1.738	0,16	1.670	0,30	3.314	0,63	4.984	0,46	2.611	0,46	4.111	0,78	6.722	0,62
20-24	620.290	597.584	1.217.874	1.023	0,16	866	0,14	1.889	0,16	2.407	0,39	8.358	1,40	10.765	0,88	3.430	0,55	9.224	1,54	12.654	1,04
25-29	665.305	649.164	1.314.469	1.000	0,15	964	0,15	1.964	0,15	3.556	0,53	12.813	1,97	16.369	1,25	4.556	0,68	13.777	2,12	18.333	1,39
30-34	693.476	681.692	1.375.168	1.117	0,16	1.058	0,16	2.175	0,16	7.615	1,10	18.186	2,67	25.801	1,88	8.732	1,26	19.244	2,82	27.976	2,03
35-39	721.320	708.693	1.430.013	1.181	0,16	1.206	0,17	2.387	0,17	16.398	2,27	28.273	3,99	44.671	3,12	17.579	2,44	29.479	4,16	47.058	3,29
40-44	644.655	633.554	1.278.209	1.172	0,18	831	0,13	2.003	0,16	28.843	4,47	41.338	6,52	70.181	5,49	30.015	4,66	42.169	6,66	72.184	5,65
45-49	578.228	567.468	1.145.696	1.193	0,21	592	0,10	1.785	0,16	48.041	8,31	63.973	11,27	112.014	9,78	49.234	8,51	64.565	11,38	113.799	9,93
50-54	453.346	438.690	892.036	1.283	0,28	589	0,13	1.872	0,21	61.032	13,46	78.431	17,88	139.463	15,63	62.315	13,75	79.020	18,01	141.335	15,84
55-59	379.429	381.868	761.297	1.448	0,38	823	0,22	2.271	0,30	68.386	18,02	91.536	23,97	159.922	21,01	69.834	18,41	92.359	24,19	162.193	21,30
60-64	281.093	291.685	572.778	1.552	0,55	1.029	0,35	2.581	0,45	62.372	22,19	85.350	29,26	147.722	25,79	63.924	22,74	86.379	29,61	150.303	26,24
65-69	189.853	215.807	405.660	1.601	0,84	1.278	0,59	2.879	0,71	50.701	26,71	74.634	34,58	125.335	30,90	52.302	27,55	75.912	35,18	128.214	31,61
70-74	125.966	160.274	286.240	1.416	1,12	1.418	0,88	2.834	0,99	37.030	29,40	59.747	37,28	96.777	33,81	38.446	30,52	61.165	38,16	99.611	34,80
75-79	74.215	105.751	179.966	1.125	1,52	1.440	1,36	2.565	1,43	23.348	31,46	40.440	38,24	63.788	35,44	24.473	32,98	41.880	39,60	66.353	36,87
80-84	40.761	69.489	110.250	741	1,82	1.030	1,48	1.771	1,61	12.858	31,54	24.630	35,44	37.488	34,00	13.599	33,36	25.660	36,93	39.259	35,61
85-89	23.911	43.994	67.905	500	2,09	736	1,67	1.236	1,82	6.938	29,02	13.658	31,05	20.596	30,33	7.438	31,11	14.394	32,72	21.832	32,15
90+	7.226	21.949	29.175	128	1,77	336	1,53	464	1,59	1.736	24,02	5.519	25,14	7.255	24,87	1.864	25,80	5.855	26,68	7.719	26,46
Toplam	6.062.398	6.093.843	12.156.241	17.421	0,29	14.993	0,25	32.414	0,27	432.931	7,14	650.200	10,67	1.083.131	8,91	450.352	7,43	665.193	10,92	1.115.545	9,18

Tablo 4.16. İstanbul 2020 yılı yaş grupları, DM tipi ve cinsiyete göre diyabetli kayıt sayısı ve prevalansı (%)

	2020 YILI 15 YAŞ ÜSTÜ DİYABET PREVALANS TABLOSU																				
	TÜİK NÜFUS 2020			Tip 1 DM 2020						Tip 2 DM 2020						Toplam (Tip 1 DM + Tip 2 DM) 2020					
	Erkek	Kadın	Toplam	Erkek		Kadın		Tip 1 Toplamı		Erkek		Kadın		Tip 2 Toplamı		Erkek		Kadın		Toplam	
Yaş Grubu	n	n	n	n	Prev.	n	Prev.	n	Prev.	n	Prev.	n	Prev.	n	Prev.	n	Prev.	n	Prev.	n	Prev.
15-19	552.806	516.228	1.069.034	964	0,17	840	0,16	1.804	0,17	1.711	0,31	3.155	0,61	4.866	0,46	2.675	0,48	3.995	0,77	6.670	0,62
20-24	608.631	586.216	1.194.847	1.076	0,18	866	0,15	1.942	0,16	2.695	0,44	8.958	1,53	11.653	0,98	3.771	0,62	9.824	1,68	13.595	1,14
25-29	654.253	638.074	1.292.327	1.052	0,16	1.006	0,16	2.058	0,16	3.998	0,61	14.092	2,21	18.090	1,40	5.050	0,77	15.098	2,37	20.148	1,56
30-34	675.023	665.501	1.340.524	1.110	0,16	1.136	0,17	2.246	0,17	8.225	1,22	20.034	3,01	28.259	2,11	9.335	1,38	21.170	3,18	30.505	2,28
35-39	696.765	688.315	1.385.080	1.181	0,17	1.253	0,18	2.434	0,18	17.021	2,44	29.319	4,26	46.340	3,35	18.202	2,61	30.572	4,44	48.774	3,52
40-44	664.768	656.982	1.321.750	1.243	0,19	979	0,15	2.222	0,17	31.204	4,69	44.261	6,74	75.465	5,71	32.447	4,88	45.240	6,89	77.687	5,88
45-49	580.879	571.811	1.152.690	1.205	0,21	589	0,10	1.794	0,16	50.778	8,74	66.005	11,54	116.783	10,13	51.983	8,95	66.594	11,65	118.577	10,29
50-54	448.438	432.123	880.561	1.213	0,27	574	0,13	1.787	0,20	63.538	14,17	79.242	18,34	142.780	16,21	64.751	14,44	79.816	18,47	144.567	16,42
55-59	396.979	399.401	796.380	1.377	0,35	733	0,18	2.110	0,26	73.535	18,52	96.740	24,22	170.275	21,38	74.912	18,87	97.473	24,40	172.385	21,65
60-64	285.003	294.499	579.502	1.495	0,52	908	0,31	2.403	0,41	68.098	23,89	89.929	30,54	158.027	27,27	69.593	24,42	90.837	30,84	160.430	27,68
65-69	201.849	232.558	434.407	1.411	0,70	1.140	0,49	2.551	0,59	54.394	26,95	79.806	34,32	134.200	30,89	55.805	27,65	80.946	34,81	136.751	31,48
70-74	133.753	170.415	304.168	1.338	1,00	1.296	0,76	2.634	0,87	41.657	31,14	66.627	39,10	108.284	35,60	42.995	32,15	67.923	39,86	110.918	36,47
75-79	78.180	109.960	188.140	1.031	1,32	1.281	1,16	2.312	1,23	25.726	32,91	43.467	39,53	69.193	36,78	26.757	34,22	44.748	40,69	71.505	38,01
80-84	42.756	73.082	115.838	737	1,72	946	1,29	1.683	1,45	14.341	33,54	27.667	37,86	42.008	36,26	15.078	35,27	28.613	39,15	43.691	37,72
85-89	22.392	42.081	64.473	428	1,91	643	1,53	1.071	1,66	7.110	31,75	13.928	33,10	21.038	32,63	7.538	33,66	14.571	34,63	22.109	34,29
90+	7.555	23.029	30.584	121	1,60	347	1,51	468	1,53	1.933	25,59	6.432	27,93	8.365	27,35	2.054	27,19	6.779	29,44	8.833	28,88
Toplam	6.050.030	6.100.275	12.150.305	16.982	0,28	14.537	0,24	31.519	0,26	465.964	7,70	689.662	11,31	1.155.626	9,51	482.946	7,98	704.199	11,54	1.187.145	9,77

İstanbul özelinde ilçe detayına inilmiştir. İlçelere ve cinsiyete göre T1DM, T2DM ve toplam DM prevalans tablosu 2019 ve 2020 yılı olmak üzere iki yıl için hazırlanmış, 2019 yılı verileri Tablo 4.17’de 2020 yılı verileri Tablo 4.18’de sunulmuştur.

Tablo 4.17. 2019 yılında İstanbul’da ilçeler, yaş grupları, DM tipi ve cinsiyete göre diyabetli kayıt sayısı ve prevalansı (%)

2019																					
	TÜİK NÜFUS 2019			Tip 1 DM						Tip 2 DM						Tip 1 + Tip 2 Genel Toplam					
İLÇE	15 + Erkek	15 + Kadın	Toplam	15+ E	Prev.	15+ K	Prev.	15+ T	Prev.	15+ E	Prev.	15+ K	Prev.	15+ T	Prev.	15+ E	Prev.	15+ K	Prev.	15+ T	Prev.
	n	N	n	n	%	n	%	n	%	n	%	n	%	N	%	n	%	n	%	n	%
ADALAR	7.169	6.367	13.536	28	0,39	5	0,08	33	0,24	908	12,67	1.177	18,49	2.085	15,40	936	13,06	1.182	18,56	2.118	15,65
ARNAVUTKÖY	102.432	96.841	199.273	243	0,24	217	0,22	460	0,23	6.155	6,01	9.541	9,85	15.696	7,88	6.398	6,25	9.758	10,08	16.156	8,11
ATAŞEHİR	165.901	175.786	341.687	563	0,34	462	0,26	1.025	0,30	13.241	7,98	18.386	10,46	31.627	9,26	13.804	8,32	18.848	10,72	32.652	9,56
AVCILAR	175.460	176.086	351.546	508	0,29	410	0,23	918	0,26	12.248	6,98	18.649	10,59	30.897	8,79	12.756	7,27	19.059	10,82	31.815	9,05
BAĞCILAR	282.597	275.246	557.843	718	0,25	621	0,23	1.339	0,24	18.738	6,63	29.986	10,89	48.724	8,73	19.456	6,88	30.607	11,12	50.063	8,97
BAHÇELİEVLER	245.632	241.067	486.699	709	0,29	561	0,23	1.270	0,26	17.747	7,23	28.330	11,75	46.077	9,47	18.456	7,51	28.891	11,98	47.347	9,73
BAKIRKÖY	88.935	104.482	193.417	308	0,35	232	0,22	540	0,28	8.824	9,92	12.055	11,54	20.879	10,79	9.132	10,27	12.287	11,76	21.419	11,07
BAŞAKŞEHİR	166.516	165.693	332.209	352	0,21	292	0,18	644	0,19	9.258	5,56	13.787	8,32	23.045	6,94	9.610	5,77	14.079	8,50	23.689	7,13
BAYRAMPAŞA	110.599	109.834	220.433	301	0,27	312	0,28	613	0,28	9.473	8,57	13.603	12,39	23.076	10,47	9.774	8,84	13.915	12,67	23.689	10,75
BEŞİKTAŞ	72.190	87.402	159.592	212	0,29	183	0,21	395	0,25	5.622	7,79	7.806	8,93	13.428	8,41	5.834	8,08	7.989	9,14	13.823	8,66
BEYKOZ	99.456	102.630	202.086	306	0,31	277	0,27	583	0,29	9.150	9,20	13.468	13,12	22.618	11,19	9.456	9,51	13.745	13,39	23.201	11,48
BEYLİKDÜZÜ	130.675	140.451	271.126	439	0,34	316	0,22	755	0,28	10.987	8,41	15.048	10,71	26.035	9,60	11.426	8,74	15.364	10,94	26.790	9,88
BEYOĞLU	98.598	92.371	190.969	329	0,33	285	0,31	614	0,32	6.640	6,73	10.174	11,01	16.814	8,80	6.969	7,07	10.459	11,32	17.428	9,13
BÜYÜKÇEKMECE	97.758	101.481	199.239	294	0,30	252	0,25	546	0,27	8.648	8,85	11.875	11,70	20.523	10,30	8.942	9,15	12.127	11,95	21.069	10,57
ÇATALCA	31.211	29.390	60.601	87	0,28	81	0,28	168	0,28	2.737	8,77	4.241	14,43	6.978	11,51	2.824	9,05	4.322	14,71	7.146	11,79
ÇEKMEKÖY	99.366	100.409	199.775	303	0,30	258	0,26	561	0,28	6.822	6,87	10.613	10,57	17.435	8,73	7.125	7,17	10.871	10,83	17.996	9,01
ESENLER	175.359	166.380	341.739	393	0,22	391	0,24	784	0,23	10.504	5,99	17.134	10,30	27.638	8,09	10.897	6,21	17.525	10,53	28.422	8,32
ESENYURT	358.994	336.180	695.174	712	0,20	665	0,20	1.377	0,20	15.139	4,22	23.923	7,12	39.062	5,62	15.851	4,42	24.588	7,31	40.439	5,82
EYÜPSULTAN	157.472	159.418	316.890	417	0,26	393	0,25	810	0,26	10.397	6,60	15.780	9,90	26.177	8,26	10.814	6,87	16.173	10,15	26.987	8,52
FATİH	188.360	182.648	371.008	576	0,31	511	0,28	1.087	0,29	14.126	7,50	21.055	11,53	35.181	9,48	14.702	7,81	21.566	11,81	36.268	9,78
GAZİOSMANPAŞA	190.261	190.438	380.699	522	0,27	463	0,24	985	0,26	12.645	6,65	20.155	10,58	32.800	8,62	13.167	6,92	20.618	10,83	33.785	8,87
GÜNGÖREN	117.164	114.650	231.814	362	0,31	249	0,22	611	0,26	9.349	7,98	13.752	11,99	23.101	9,97	9.711	8,29	14.001	12,21	23.712	10,23
KADIKÖY	189.151	236.533	425.684	836	0,44	701	0,30	1.537	0,36	21.138	11,18	30.260	12,79	51.398	12,07	21.974	11,62	30.961	13,09	52.935	12,44
KÂĞITHANE	181.413	177.893	359.306	522	0,29	447	0,25	969	0,27	10.889	6,00	17.089	9,61	27.978	7,79	11.411	6,29	17.536	9,86	28.947	8,06
KARTAL	186.015	193.252	379.267	583	0,31	511	0,26	1.094	0,29	15.120	8,13	22.225	11,50	37.345	9,85	15.703	8,44	22.736	11,76	38.439	10,14
KÜÇÜKÇEKMECE	306.313	308.456	614.769	843	0,28	754	0,24	1.597	0,26	20.256	6,61	31.678	10,27	51.934	8,45	21.099	6,89	32.432	10,51	53.531	8,71
MALTEPE	211.326	214.152	425.478	721	0,34	606	0,28	1.327	0,31	16.883	7,99	25.311	11,82	42.194	9,92	17.604	8,33	25.917	12,10	43.521	10,23
PENDİK	273.216	270.263	543.479	732	0,27	648	0,24	1.380	0,25	20.450	7,48	32.123	11,89	52.573	9,67	21.182	7,75	32.771	12,13	53.953	9,93
SANCAKTEPE	159.988	157.815	317.803	404	0,25	401	0,25	805	0,25	9.793	6,12	15.393	9,75	25.186	7,93	10.197	6,37	15.794	10,01	25.991	8,18
SARIYER	141.918	146.648	288.566	484	0,34	357	0,24	841	0,29	9.854	6,94	13.383	9,13	23.237	8,05	10.338	7,28	13.740	9,37	24.078	8,34
SİLİVRİ	91.243	66.442	157.685	243	0,27	145	0,22	388	0,25	7.808	8,56	9.342	14,06	17.150	10,88	8.051	8,82	9.487	14,28	17.538	11,12
SULTANBEYLİ	121.419	115.743	237.162	270	0,22	243	0,21	513	0,22	7.253	5,97	11.228	9,70	18.481	7,79	7.523	6,20	11.471	9,91	18.994	8,01
SULTANGAZİ	197.922	191.226	389.148	460	0,23	447	0,23	907	0,23	11.266	5,69	18.069	9,45	29.335	7,54	11.726	5,92	18.516	9,68	30.242	7,77
ŞİLE	16.853	15.376	32.229	74	0,44	62	0,40	136	0,42	1.708	10,13	2.425	15,77	4.133	12,82	1.782	10,57	2.487	16,17	4.269	13,25

Tablo 4.17.'nin devamı

2019																					
	TÜİK NÜFUS 2019			Tip 1 DM						Tip 2 DM						Tip 1 + Tip 2 Genel Toplam					
İLÇE	15 + Erkek	15 + Kadın	Toplam	15+ E	Prev.	15+ K	Prev.	15+ T	Prev.	15+ E	Prev.	15+ K	Prev.	15+ T	Prev.	15+ E	Prev.	15+ K	Prev.	15+ T	Prev.
	n	N	n	n	%	n	%	n	%	n	%	n	%	N	%	n	%	n	%	n	%
ŞİŞLİ	116.462	124.101	240.563	383	0,33	286	0,23	669	0,28	8.666	7,44	12.218	9,85	20.884	8,68	9.049	7,77	12.504	10,08	21.553	8,96
TUZLA	104.478	100.183	204.661	258	0,25	290	0,29	548	0,27	7.558	7,23	11.360	11,34	18.918	9,24	7.816	7,48	11.650	11,63	19.466	9,51
ÜMRANİYE	274.572	276.528	551.100	860	0,31	725	0,26	1.585	0,29	19.498	7,10	29.153	10,54	48.651	8,83	20.358	7,41	29.878	10,80	50.236	9,12
ÜSKÜDAR	212.079	228.836	440.915	795	0,37	674	0,29	1.469	0,33	18.170	8,57	27.346	11,95	45.516	10,32	18.965	8,94	28.020	12,24	46.985	10,66
ZEYTİNBURNU	115.925	115.146	231.071	271	0,23	260	0,23	531	0,23	7.263	6,27	11.059	9,60	18.322	7,93	7.534	6,50	11.319	9,83	18.853	8,16
TOPLAM	6.062.398	6.093.843	12.156.241	17.421	0,29	14.993	0,25	32.414	0,27	432.931	7,14	650.200	10,67	1.083.131	8,91	450.352	7,43	665.193	10,92	1.115.545	9,18

Tablo 4.18. 2020 yılında İstanbul’da ilçeler, yaş grupları, DM tipi ve cinsiyete göre diyabetli kayıt sayısı ve prevalansı (%)

2020																					
İLÇE	TÜİK NÜFUS			Tip 1 DM						Tip 2 DM						Tip 1 + Tip 2 Genel Toplam					
	15+ Erkek	15+ Kadın	15+ Topl.	15+ E	Prev.	15+ K	Prev.	15+ T	Prev.	15+ E	Prev.	15+ K	Prev.	15+ T	Prev.	15+ E	Prev.	15+ K	Prev.	15+ T	Prev.
	n	n	n	n	%	n	%	n	%	n	%	n	%	N	%	n	%	n	%	n	%
ADALAR	7.473	6.825	14.298	26	0,35	5	0,07	31	0,22	948	12,69	1.229	18,01	2.177	15,23	974	13,03	1.234	18,08	2.208	15,44
ARNAVUTKÖY	108.064	102.444	210.508	239	0,22	216	0,21	455	0,22	6.734	6,23	10.278	10,03	17.012	8,08	6.973	6,45	10.494	10,24	17.467	8,30
ATAŞEHİR	165.973	175.007	340.980	536	0,32	447	0,26	983	0,29	14.151	8,53	19.360	11,06	33.511	9,83	14.687	8,85	19.807	11,32	34.494	10,12
AVCILAR	170.872	171.556	342.428	497	0,29	409	0,24	906	0,26	13.321	7,80	20.041	11,68	33.362	9,74	13.818	8,09	20.450	11,92	34.268	10,01
BAĞCILAR	281.490	274.438	555.928	730	0,26	617	0,22	1.347	0,24	20.430	7,26	32.066	11,68	52.496	9,44	21.160	7,52	32.683	11,91	53.843	9,69
BAHÇELİEVLER	236.872	235.809	472.681	681	0,29	529	0,22	1.210	0,26	19.076	8,05	29.828	12,65	48.904	10,35	19.757	8,34	30.357	12,87	50.114	10,60
BAKIRKÖY	87.590	103.466	191.056	302	0,34	225	0,22	527	0,28	9.358	10,68	12.664	12,24	22.022	11,53	9.660	11,03	12.889	12,46	22.549	11,80
BAŞAKŞEHİR	170.705	170.974	341.679	359	0,21	292	0,17	651	0,19	10.218	5,99	14.818	8,67	25.036	7,33	10.577	6,20	15.110	8,84	25.687	7,52
BAYRAMPAŞA	109.061	108.668	217.729	291	0,27	293	0,27	584	0,27	10.149	9,31	14.253	13,12	24.402	11,21	10.440	9,57	14.546	13,39	24.986	11,48
BEŞİKTAŞ	69.559	84.892	154.451	202	0,29	180	0,21	382	0,25	6.023	8,66	8.172	9,63	14.195	9,19	6.225	8,95	8.352	9,84	14.577	9,44
BEYKOZ	99.367	101.747	201.114	296	0,30	269	0,26	565	0,28	9.707	9,77	14.161	13,92	23.868	11,87	10.003	10,07	14.430	14,18	24.433	12,15
BEYLİKDÜZÜ	135.952	146.499	282.451	431	0,32	321	0,22	752	0,27	11.895	8,75	16.215	11,07	28.110	9,95	12.326	9,07	16.536	11,29	28.862	10,22
BEYOĞLU	96.002	89.985	185.987	317	0,33	269	0,30	586	0,32	7.084	7,38	10.684	11,87	17.768	9,55	7.401	7,71	10.953	12,17	18.354	9,87
BÜYÜKÇEKMECE	99.450	103.254	202.704	287	0,29	243	0,24	530	0,26	9.372	9,42	12.798	12,39	22.170	10,94	9.659	9,71	13.041	12,63	22.700	11,20
ÇATALCA	31.566	30.129	61.695	88	0,28	81	0,27	169	0,27	2.951	9,35	4.526	15,02	7.477	12,12	3.039	9,63	4.607	15,29	7.646	12,39
ÇEKMEKÖY	102.740	104.458	207.198	300	0,29	257	0,25	557	0,27	7.423	7,23	11.369	10,88	18.792	9,07	7.723	7,52	11.626	11,13	19.349	9,34
ESENLER	175.359	165.822	341.181	404	0,23	373	0,22	777	0,23	11.466	6,54	18.360	11,07	29.826	8,74	11.870	6,77	18.733	11,30	30.603	8,97
ESENİYURT	359.467	340.353	699.820	720	0,20	671	0,20	1.391	0,20	16.776	4,67	25.990	7,64	42.766	6,11	17.496	4,87	26.661	7,83	44.157	6,31
EYÜPSULTAN	160.069	162.057	322.126	409	0,26	387	0,24	796	0,25	11.126	6,95	16.678	10,29	27.804	8,63	11.535	7,21	17.065	10,53	28.600	8,88
FATİH	165.636	165.602	331.238	537	0,32	464	0,28	1.001	0,30	15.063	9,09	21.936	13,25	36.999	11,17	15.600	9,42	22.400	13,53	38.000	11,47
GAZİOSMANPAŞA	189.503	190.298	379.801	519	0,27	445	0,23	964	0,25	13.647	7,20	21.294	11,19	34.941	9,20	14.166	7,48	21.739	11,42	35.905	9,45
GÜNGÖREN	113.522	111.933	225.455	358	0,32	240	0,21	598	0,27	10.074	8,87	14.508	12,96	24.582	10,90	10.432	9,19	14.748	13,18	25.180	11,17
KADIKÖY	189.352	236.020	425.372	788	0,42	663	0,28	1.451	0,34	22.162	11,70	31.391	13,30	53.553	12,59	22.950	12,12	32.054	13,58	55.004	12,93
KÂĞITHANE	179.837	176.833	356.670	511	0,28	423	0,24	934	0,26	11.669	6,49	17.994	10,18	29.663	8,32	12.180	6,77	18.417	10,41	30.597	8,58
KARTAL	188.366	195.791	384.157	559	0,30	492	0,25	1.051	0,27	16.124	8,56	23.530	12,02	39.654	10,32	16.683	8,86	24.022	12,27	40.705	10,60
KÜÇÜKÇEKMECE	305.816	308.683	614.499	825	0,27	726	0,24	1.551	0,25	21.948	7,18	33.719	10,92	55.667	9,06	22.773	7,45	34.445	11,16	57.218	9,31
MALTEPE	212.209	215.955	428.164	678	0,32	575	0,27	1.253	0,29	18.026	8,49	26.679	12,35	44.705	10,44	18.704	8,81	27.254	12,62	45.958	10,73
PENDİK	280.632	277.929	558.561	719	0,26	642	0,23	1.361	0,24	21.979	7,83	34.263	12,33	56.242	10,07	22.698	8,09	34.905	12,56	57.603	10,31
SANCAKTEPE	168.507	165.855	334.362	387	0,23	392	0,24	779	0,23	10.531	6,25	16.459	9,92	26.990	8,07	10.918	6,48	16.851	10,16	27.769	8,31
SARIYER	136.186	142.000	278.186	468	0,34	349	0,25	817	0,29	10.595	7,78	14.180	9,99	24.775	8,91	11.063	8,12	14.529	10,23	25.592	9,20
SİLİVRİ	94.346	69.080	163.426	241	0,26	142	0,21	383	0,23	8.459	8,97	9.975	14,44	18.434	11,28	8.700	9,22	10.117	14,65	18.817	11,51
SULTANBEYLİ	125.230	119.285	244.515	265	0,21	242	0,20	507	0,21	7.835	6,26	12.139	10,18	19.974	8,17	8.100	6,47	12.381	10,38	20.481	8,38
SULTANGAZİ	200.742	194.024	394.766	464	0,23	450	0,23	914	0,23	12.230	6,09	19.355	9,98	31.585	8,00	12.694	6,32	19.805	10,21	32.499	8,23
ŞİLE	16.816	15.485	32.301	70	0,42	60	0,39	130	0,40	1.813	10,78	2.533	16,36	4.346	13,45	1.883	11,20	2.593	16,75	4.476	13,86
ŞİŞLİ	110.668	118.739	229.407	366	0,33	270	0,23	636	0,28	9.295	8,40	12.840	10,81	22.135	9,65	9.661	8,73	13.110	11,04	22.771	9,93
TUZLA	106.520	102.917	209.437	253	0,24	281	0,27	534	0,25	8.168	7,67	12.074	11,73	20.242	9,66	8.421	7,91	12.355	12,00	20.776	9,92
ÜMRANİYE	277.499	279.614	557.113	836	0,30	716	0,26	1.552	0,28	20.987	7,56	30.915	11,06	51.902	9,32	21.823	7,86	31.631	11,31	53.454	9,59
ÜSKÜDAR	208.508	224.622	433.130	756	0,36	625	0,28	1.381	0,32	19.378	9,29	28.699	12,78	48.077	11,10	20.134	9,66	29.324	13,05	49.458	11,42
ZEYİTNBURNU	112.504	111.227	223.731	267	0,24	256	0,23	523	0,23	7.773	6,91	11.689	10,51	19.462	8,70	8.040	7,15	11.945	10,74	19.985	8,93
TOPLAM	6.050.030	6.100.275	12.150.305	16.982	0,28	14.537	0,24	31.519	0,26	465.964	7,70	689.662	11,31	1.155.626	9,51	482.946	7,98	704.199	11,54	1.187.145	9,77

4.2.2. İstanbul İli Başvurular ve Reçeteler

İstanbul’da tedavi görmüş diyabetli vakaların başvuru branş türlerine göre 2019 ve 2020 yılı başvurularının özeti Tablo 4.19’da gösterilmiştir.

Tablo 4.19. 2019 ve 2020 yılında İstanbul’daki 15 yaş ve üzeri diyabetli vaka başvurularının klinik branşlara göre dağılımı

BRANŞLAR	2019 YILI				2020 YILI			
	Başvuran Tekil Kişi Sayısı	Başvuru Sayısı	Başvurular İçindeki Oran (%)	Kişi Başına Düşen Başvuru Sayısı	Başvuran Tekil Kişi Sayısı	Başvuru Sayısı	Başvurular İçindeki Oran (%)	Kişi Başına Düşen Başvuru Sayısı
Aile Hekimliği	877.735	6.081.408	32,52	6,93	927.849	5.147.624	35,38	5,55
İç Hastalıkları	704.546	2.427.627	12,98	3,45	594.640	1.642.508	11,29	2,76
Acil Tıp	556.806	1.864.034	9,97	3,35	565.427	1.732.360	11,91	3,06
Göz Hastalıkları	383.754	953.659	5,10	2,49	297.885	645.134	4,43	2,17
Kardiyoloji	274.887	810.414	4,33	2,95	236.979	588.318	4,04	2,48
Ağız Diş Sağlığı	198.126	643.810	3,44	3,25	126.490	313.212	2,15	2,48
Fiziksel Tıp ve Rehabilitasyon	187.666	541.576	2,90	2,89	139.748	360.377	2,48	2,58
Genel Cerrahi	196.704	538.201	2,88	2,74	155.209	382.152	2,63	2,46
Ortopedi ve Travmatoloji	241.697	535.398	2,86	2,22	190.654	391.526	2,69	2,05
Nöroloji	185.989	446.981	2,39	2,40	148.103	315.379	2,17	2,13
Kulak Burun Boğaz Hastalıkları	229.683	433.462	2,32	1,89	179.126	302.493	2,08	1,69
Üroloji	150.132	425.832	2,28	2,84	117.439	296.684	2,04	2,53
Kadın Doğum	117.552	373.439	2,00	3,18	95.835	299.495	2,06	3,13
Psikiyatri	141.792	368.455	1,97	2,60	118.814	265.200	1,82	2,23
Göğüs Hastalıkları	151.421	330.521	1,77	2,18	126.978	234.690	1,61	1,85
Endokrinoloji ve Metabolizma Hast	80.898	256.720	1,37	3,17	66.736	178.876	1,23	2,68
Deri ve Zührevi Hastalıkları	126.504	239.415	1,28	1,89	94.689	162.814	1,12	1,72
Beyin ve Sinir Cerrahisi	99.599	220.809	1,18	2,22	74.560	155.844	1,07	2,09

Tablo 4.19.'un devamı

BRANŞLAR	2019 YILI				2020 YILI			
	Başvuran Tekil Kişi Sayısı	Başvuru Sayısı	Başvurular İçindeki Oran (%)	Kişi Başına Düşen Başvuru Sayısı	Başvuran Tekil Kişi Sayısı	Başvuru Sayısı	Başvurular İçindeki Oran (%)	Kişi Başına Düşen Başvuru Sayısı
Nefroloji	41.802	199.184	1,07	4,76	35.664	213.937	1,47	6,00
Kalp ve Damar Cerrahisi	67.968	161.371	0,86	2,37	51.005	115.111	0,79	2,26
Onkoloji ve Radyasyon Onkolojisi	21.236	153.466	0,82	7,23	22.030	195.190	1,34	8,86
Gastroenteroloji	45.525	128.310	0,69	2,82	39.054	97.284	0,67	2,49
Anesteziyoloji ve Reanimasyon	65.285	115.085	0,62	1,76	46.263	77.193	0,53	1,67
Diğer	57.177	112.552	0,60	1,97	48.924	101.954	0,70	2,08
Enfeksiyon Hastalıkları	41.239	105.366	0,56	2,56	70.675	135.015	0,93	1,91
Laboratuvar ve Görüntüleme	53.446	85.531	0,46	1,60	48.196	77.910	0,54	1,62
Hematoloji	12.178	55.808	0,30	4,58	11.567	55.751	0,38	4,82
Plastik, Rekonstrüktif Cerr	16.395	41.883	0,22	2,55	11.635	27.673	0,19	2,38
Göğüs Cerrahisi	14.136	30.075	0,16	2,13	11.735	23.505	0,16	2,00
Çocuk Kliniği	4.044	20.364	0,11	5,04	4.231	15.556	0,11	3,68
Adlanmamış	46	50	0,00	1,09	33	43	0,00	1,30

İstanbul’da tedavi görmüş diyabetik vakaların başvurdukları kurum türü bilgisi ise Tablo 4.20’de verilmiştir.

Tablo 4.20. 2019 ve 2020 yılında İstanbul’daki diyabetli vaka başvurularının kurum türlerine göre dağılımı

KURUM TÜRÜ	2019 YILI				2020 YILI			
	Toplam Başvuru Sayısı	Başvuran Tekil Kişi Sayısı	Tüm Başvurular Arasındaki Oran (%)	Kişi Başına Düşen Başvuru Sayısı	Toplam Başvuru Sayısı	Başvuran Tekil Kişi Sayısı	Tüm Başvurular Arasındaki Oran (%)	Kişi Başına Düşen Başvuru Sayısı
Aile Hekimliği	5.899.783	863.936	31,55	6,83	4.970.507	914.137	34,16	5,44
Özel Tıp Merkezi	6.867	4.321	0,04	1,59	3.807	2.440	0,03	1,56
Devlet Hastanesi	9.458.310	850.747	50,58	11,12	6.420.569	822.682	44,13	7,80
Özel Hastane	448.417	97.164	2,40	4,62	342.351	82.859	2,35	4,13
Devlet Üniversitesi Hastanesi	193.884	48.989	1,04	3,96	242.615	53.707	1,67	4,52
Özel Üniversite Hastanesi	1.564.737	404.275	8,37	3,87	1.575.407	426.051	10,83	3,70
Diğer	561.775	231.194	3,00	2,43	507.547	227.775	3,49	2,23
Bilinmeyen	567.033	130.770	3,03	4,34	488.003	128.767	3,35	3,79

İstanbul’da tedavi görmüş diyabetik vakaların başvuru ve reçete bilgileri Tablo 4.21’de özetlenmiştir.

Tablo 4.21. 2019 ve 2020 yılında İstanbul’daki diyabetli vakaların muayene ve reçete bilgileri

(AD: Antidiyabetik, OAD: Oral Antidiyabetik)

YIL	DM Başvuran Tekil Hasta Sayısı	DM Toplam Başvuru Sayısı	DM Hasta Başına Başvuru Sayısı	DM Hasta Reçete Sayısı	DM Hasta Başına Reçete Sayısı	AD İlaç İçeren Reçete Sayısı	Hasta Başına AD Reçete Sayısı	İnsülin İçeren Reçete Sayısı	Hasta Başına İnsülin Reçete Sayısı	OAD İçeren Reçete Sayısı	Hasta Başına OAD İçeren Reçete Sayısı
2016	585.363	7.568.820	12,93	4.204.799	7,18	1.496.549	2,56	290.941	0,50	1.320.330	2,26
2017	752.369	12.096.328	16,08	6.715.921	8,93	2.054.782	2,73	402.829	0,54	1.823.367	2,42
2018	890.526	15.368.553	17,26	8.545.340	9,60	2.457.637	2,76	473.947	0,53	2.189.433	2,46
2019	1.014.136	18.700.806	18,44	10.119.505	9,98	2.784.005	2,75	517.199	0,51	2.493.640	2,46
2020	1.088.957	14.550.807	13,36	7.421.029	6,81	1.628.904	1,50	253.436	0,23	1.479.886	1,36

* Covid-19 Pandemisi dolayısıyla SGK’nın Raporlu İlaçların Reçete ettirilmeksizin doğrudan eczanelerden alınabileceğine dair tebliği nedeniyle 2020 yılı Antidiyabetik İçeren Reçete sayısındaki anlamlı düşüşler dikkati çekmektedir.

4.3. Diyabetli Olanlar ile Diyabetli Olmayanların Komorbidite Karşılaştırması

Diyabetli vakalarda sıklıkla görülen ve diyabete eşlik eden hastalıkların görülme sıklıklarına hem diyabetli popülasyonda hem de diyabeti olmayan popülasyonda bakılmış ve 2019 yılı prevalans ve Odds Oranı (OO) tabloları oluşturulmuştur. Sorgular yazılırken kullanılan ICD-10 kodları her bir hastalık tablosu içerisine eklenmiştir. Bu tablolar sayıca ve ayrıntılı olarak incelendiğinden Ekler bölümünde verilmiştir. Diyabetli popülasyonda incelenen hastalıklardan; 1) Akut miyokard infarktüsü, 2) Akut miyokard infarktüsü dahil toplam iskemik kalp hastalıkları, 3) Kalp yetmezlikleri, 4) Hipertansiyon, 5) Böbrek hastalıkları, 6) Serebrovasküler hastalıklar, 7) Retinopatiler, 8) Kataraktlar, 9) Lipid metabolizma bozuklukları, 10) Periferik dolaşım bozuklukları ve 11) Nöropatilere ait ayrıntılı tablolar ektedir (Tablo Ek.1 -Tablo Ek.11).

ICD-O3 kodlarına göre tespit edilen malign ve benign neoplazmlar da aynı şekilde Ekler bölümünde verilmiştir (Tablo Ek.12-Tablo Ek.31). Spesifik olarak çalışılan hastalıklar şunlardır; 1) Baş boyun kanserleri, 2) Tiroid kanserleri, 3) Larinks kanserleri, 4) Akciğer kanserleri, 5) Mide kanserleri, 6) Kolon, rektosigmoid ve rektum kanserleri, 7) Karaciğer ve intrahepatik safra kanalları kanserleri, 8) Pankreas kanserleri, 9) Böbrek kanserleri, 10) Mesane kanserleri, 11) Melanomlar, 12) Hodgkin lenfomalar, 13) Non-hodgkin lenfomalar, 14) Meme kanserleri, 15) Uterus kanserleri, 16) Over kanserleri, 17) Prostat kanserleri, 18) Diğer malign neoplazmlar, 19) Toplam Malign Neoplazmlar ve 20) Benign, insitu ve davranış türü belli olmayan neoplazmlar.

Tüm tümörlerin artmış riske sahip olduğu görülmektedir. Pankreas kanseri en yüksek orana sahip 4,02 (3,71-4,36), larenks kanseri en düşük orana sahip olan 1,29 (1,19-1,41) malignite olarak bulunmuştur.

Veriler, Microsoft Excel 2016 ve Jamovi 2.2.5 ile analiz edilmiştir. Ağırlıklandırılmış odds oranlarının hesaplanması ve komorbiditeler için güven aralığı Morris ve Gardner tarafından tanımlanan logit yöntemi ile yapılmış ve özet sonuçlar aşağıdaki Tablo 4.22’de yer almaktadır (Morris & Gardner, 1988).

Tablo 4.22. Diyabetik ve diyabetik olmayan popülasyonda bazı komorbid hastalıkların insidansı

	İnsidans, (1/100.000)						OO	95% CI
	Kadın		Erkek		Toplam			
	DM	Non-DM	DM	Non-DM	DM	Non-DM		
Hiperlipidemiler (E78.0-E78.5)	3,87	1,66	4,85	1,46	4,36	1,56	2,09	2,09-2,10
Kalp Yetmezliği (I50)	0,79	0,44	0,95	0,43	0,87	0,44	1,85	1,83-1,86
İskemik Kalp Hastalıkları (I21, I22, I23, I24, I25)	2,66	1,72	3,01	1,67	1,70	2,84	1,46	1,46-1,47
Kataraktlar (H25-H28)	1,25	0,97	1,20	0,86	1,22	0,91	1,26	1,25-1,27
Nöropatiler (G63.2, G73.0, G99.0, G59.0, E10.4, E11.4, E12.4, E13.4, E14.4)	2,45	0,25	2,63	0,15	2,54	0,20	10,42	10,34-10,50
Nefropati ve Kronik Böbrek Yetmezlikleri (N08.3, N18s, N19, E10.2, E11.2, E12.2, E13.2, E14.2)	0,81	0,25	1,03	0,26	0,92	0,25	2,89	2,86-2,91
Periferik Dolaşım Bozuklukları (I73.9, I78.8, I78.9, E10.5, E11.5, E12.5, E13.5, E14.5)	0,80	0,31	1,03	0,28	0,91	0,29	2,65	2,63-2,68
Retinopatiler (E10.3, E11.3, E12.3, E13.3, E14.3, H35.0, H35.2, H35.6, H35.8, H35.9, H36.0)	1,19	0,24	1,57	0,22	1,38	0,23	4,61	4,57-4,65
Akut MI (I21, I22)	0,75	0,36	1,20	0,53	0,97	0,44	2,04	2,02-2,05

Tablo 4.22. 'nin devamı

	İnsidans, (1/100.000)						OO	95% CI
	Kadın		Erkek		Toplam			
	DM	Non-DM	DM	Non-DM	DM	Non-DM		
Serebrovasküler Hastalıklar (I60, I61, I62, I63, I64, I65, I66, I67, I68, I69)	3,35	2,12	3,27	1,69	3,31	1,91	1,73	1,72-1,73
Hipertansiyon (I10, I15.0, I15.1, I15.2, I15.8, I15.9)	3342,8	1646,6	4217,6	1445,7	3778,7	1546,5	1,72	1,71-1,72
Kanserler								
Baş ve Boyun Bölgesi Kanserleri (C00-C14)	9,8	4,7	19,8	7,4	14,8	6,1	1,80	1,69-1,92
Mide Kanseri (C16)	21,2	10,0	36,0	18,0	28,5	14,0	1,72	1,65-1,79
Kolon, Rektosigmoid ve Rektum Kanserleri (C18-C20)	35,7	16,9	65,7	24,7	50,6	20,8	2,12	2,06-2,19
Karaciğer ve İntrahepatik Safra Kanalları Kanseri (C22)	10,5	4,4	19,1	6,2	14,8	5,3	2,48	2,34-2,64
Pankreas Kanseri (C25)	7,4	2,1	12,8	2,6	10,1	2,3	4,02	3,71-4,36
Larenks Kanseri (C32)	0,9	0,6	9,8	7,2	5,3	3,9	1,29	1,19-1,41
Akciğer Kanseri (C34)	22,1	11,8	91,5	52,1	56,7	31,9	1,57	1,53-1,62
Malign Melanoma (C43)	1,4	0,9	2,5	1,1	1,9	1,0	1,73	1,46-2,05
Meme Kanseri (C50)	108,7	58,2	1,9	0,8	55,5	29,6	1,70	1,65-1,76
Uterus Kanseri (C54)	19,8	8,0	-	-	-	-	2,38	2,22-2,56
Over Kanseri (C56)	9,4	3,4	-	-	-	-	2,26	2,00-2,54
Prostat Kanseri (C61)	-	-	55,7	40,7	-	-	1,35	1,30-1,40

Tablo 4.22.’nin devamı

	İnsidans, (1/100.000)						OO	95% CI
	Kadın		Erkek		Toplam			
	DM	Non-DM	DM	Non-DM	DM	Non-DM		
Böbrek Kanseri (C64)	8,0	3,4	19,0	7,1	13,5	5,3	2,10	1,96-2,24
Mesane Kanseri (C67)	5,6	3,8	41,0	23,2	23,2	13,5	1,61	1,54-1,68
Tiroid Kanseri (C73)	44,0	22,0	20,4	6,4	32,3	14,2	1,84	1,76-1,94
Hodgkin Lenfoma (C81)	7,4	2,3	22,9	3,0	15,2	2,7	2,93	2,66-3,24
Non Hodgkin Lenfoma (C85)	8,6	3,7	21,9	4,9	15,2	4,3	2,28	2,12-2,45
Diğer Malign Tümörler	180,2	74,0	282,2	67,0	231,1	70,5	2,09	2,05-2,13
Toplam Malign Tümörler (C00-C97)	500,7	230,3	722,2	272,4	611,1	251,3	1,87	1,85-1,89
In situ, Benign, ve Davranış Türü Belirsiz Tümörler (D00-D48)	1398,6	862,6	736,2	388,0	1068,5	626,1	1,52	1,51-1,53

4.4. Makine Öğrenmesi İçin Hazırlanan Veri Seti ile Yapılan Analizler

4.4.1. Makine Öğrenmesi Veri Seti Değişkenleri

Üçüncü bölümde ayrıntıları anlatılan veri seti 1 Ocak 2017 tarihinden başlamak üzere diyabet tanı, tedavi ve rapor kaydı bulunan vaka kayıtlarından oluşmaktadır. Bu tarihten 31 Aralık 2020 tarihine kadarki 4 yıllık tarih aralığında, aralarında en az 80 gün olması kaydı ile en az 4 adet HbA1c test sonucu bulunan vakaların test sonuçlarına erişilmiş, bu özelliklere sahip olan 77.724 vaka verisi bulunduğu saptanmış ve bu veri seti çalışmaya esas olarak kullanılmıştır.

Buna göre bu tez çalışması kapsamında elde edilen veri kümesi 77.724 hastanın demografik verisi, tahlil sonuçları, hastalıkları, kullandığı ilaçların etken maddeleri ile ilgili 105 değişkeni içermektedir. Bu değişkenler sırasıyla aşağıda sunulmuştur:

Demografik Nitelikler (2 adet): 'cinsiyet', 'yas'.

Laboratuvar Test Sonuçları (7 Adet): “‘ilk sonuç (HbA1c)', 'azalma oranı (HbA1c)', 'ldl ilk değ r (LDL-Kolesterol İlk Değ r)', 'total kolestrol ilk deger', 'hdl ilk değ r (HDL-Kolesterol İlk Değ r)', 'kreatinin ilk deger', 'trigliserid ilk deger'.

Tanılar (Diyabet ve Diyabete Eşlik Eden Diğ r Hastalıklar 44 Adet): 'enfeksiyon bulasici', 'kanser c00 c97', 'obesite e66', 'tiroid hastaliklari e00 e07', 'bilinmeyen davranisli tumorler d00 d48', 'anemi d50 d64', 'vitamin eksikligi e50 e56', 'lipoprotein met bozukluklar e78', 'kan ve kan yapici organlarin hastaliklari d65 d89', 'endokrin diger e00 e90', 'bipolar duygulanim bozuklugu f31', 'depresyon f32 f33 f92', 'anksiyete bozuklugu f41', 'ruh sagligi f00 f99', 'noropatiler g56 g63', 'diyabetik polinoropati g63 2', 'sinir sistemi hastaliklari g00 g99', 'katarakt h25 h26', 'retinopati h30 h36', 'kirma kusurlari h52', 'sikismis serumen h61 2', 'tinnitus h93 1', 'goz diger h00 h59', 'otitis eksterna h60', 'mastoid cikinti h60 h95', 'hipertansiyon i10', 'iskemik kalp hastaliklari i20 i25', 'kardiyomiyopati i42 i43', 'serebrovaskuler hastaliklar i60 i69', 'dolasim diger i01 i99', 'solunum sistemi hastaliklari j00 j99', 'agiz hastaliklari k00 k14', 'gastro ozofajial refl  k21', 'dispepsi k30', 'sindirim sistemi hastaliklari k00 k93', 'deri ve subkutenoz dokunun hastaliklari l01 l99', 'kas iskelet sistemi bagdokusu hastaliklari m00 m99', 'nefropatiler n00 n16', 'bobrek yetmezligi n17 n19', 'genitouriner diger n00 n99', 'gebelik o10 o16', 'spontan dogum o80', 'sezaryen multible d o81 o84', 'gebelik diger o00 o99'.

Antidiyabetik İlaçlar (21 Adet): 'akarboz', 'dapagliflozin', 'eksenatid', 'gliklazid', 'glimepirid', 'glipizid', 'insulin aspart', 'insulin detemir', 'insulin glarjin', 'insulin glusilin', 'insulin lispro', 'insulin nph', 'insulin reguler', 'linagliptin', 'metformin hcl', 'nateglinid', 'pioglitazon hcl', 'repaglinide', 'saksagliptin', 'sitagliptin', 'vildagliptin'.

Diğ r Grup İlaçlar (31 Adet): 'a01 a07 a09 sindirim sistemi ilaclari', 'a08 antiobesite ilaclari', 'a11 a16 diger sindirim sis ve metabo ilac', 'b hematolojik ilaclar', 'c01 c09 kardiyovaskuler ilaclar', 'c10 lipid modifiye eden ilaclar', 'd dermatolojik ilaclar', 'g01 g02 g04 jinekolojik ve urolojik ilaclar', 'g03 seks hormonlari', 'h1 h3 sistemik hormonlar', 'h4 glukagon', 'h5 kalsiyum homestaz ilaclari', 'j01 j05 entienfektifler', 'j07 asilar', 'l01 antineoplastik ajanlar', 'l02 endokrin tedavi ilaclari', 'l03 immunstimulanlar', 'l04

immunsupresanlar', 'm kas iskelet sistemi ilacları', 'n01 anestezipler', 'n02 analjezikler', 'n03 antiepileptikler', 'n04 anti parkinson ilaclar', 'n05a antipsikotikler', 'n05b anksiyolitikler', 'n06 psikoanaleptikler', 'n07 diger sinir sistemi ilacları', 'p antiparazitik insektisit bocek uzaklastiric ilaclar', 'r solunum sistemi ilacları', 's goz kulak ilacları', 'v cesitli ilaclar'.

4.4.2. Tek Değişkenli Analiz

Makine öğrenmesi için hazırlanan ve 2017 yılında İstanbul'da tedavi görmüş diyabetli vaka kayıtlarından elde edilmiş 77.724 vaka verisine ait 105 ayrı niteliğin açık kaynak kodlu Jamovi 2.2.5 istatistik analiz yazılımı ile analizi yapılmıştır. Her bir niteliğin, 1) Kan Şekeri Kontrol Altında Olan ve 2) Kan Şekeri Kontrol Altında Olmayan gruplara göre etki boyutu ve P değerleri hesaplanarak Tablo 4.23'de özetlenmiştir. Bu analiz sonucuna göre kan şekeri düzeyinin kontrol altında olması durumuna etki eden değişkenler ve etki değerleri şöyledir; İlk HbA1c (1,50), HDL (0,23), Tiroid bezi hastalıkları (0,23), Retinopatiler (0,22), Gliklazid (0,22), İnsülin aspartat (0,35), İnsülin glarjin (0,41).

Tablo 4.23. Tek değişkenli analiz çalışması sonucu özet tablosu

Parametre	Kontrol Altında	Kontrol Altında Olmayan	Etki büyüklüğü	P
İlk HbA1c	6,20 (5,80-6,70)	8,00 (7,00-9,60)	1,50	<0,001
HbA1c azalma	0,0 (0,0-0,1)	0,0 (-0,1-0,1)	0,01	0,222
Cinsiyet				
Kadın	20.464 (%71,1)	31.271 (%63,9)	0,15	<0,001
Erkek	8.327 (%28,9)	17.662 (%36,1)		
Yaş	57 (50-66)	57 (49-65)	0,03	<0,001
LDL	124 (99-151)	121 (96-148)	0,08	<0,001
T-Kolesterol	205 (176-237)	203 (173-235)	0,05	<0,001
HDL	48 (40-56)	45 (38-53)	0,23	<0,001
Kreatinin	0,75 (0,60-0,90)	0,77 (0,65-0,92)	0,04	<0,001
Trigliserid	145 (107-203)	161 (114-232)	0,18	<0,001
Bulaşıcı Enf. Hastalıkları (A00-B99)				
Var	9.271 (%32,2)	16.338 (%33,4)	0,02	<0,001
Yok	19.520 (%67,8)	32.595 (%66,6)		
Malign Kanserler (C00-C99)				
Var	1.322 (%4,6)	1.964 (%4,2)	0,03	<0,001
Yok	27.469 (%95,4)	46.969 (%95,8)		

Tablo 4.23. 'ün devamı

Parametre	Kontrol Altında	Kontrol Altında Olmayan	Etki büyüklüğü	P
Obezite (E65-E68)				
Var	1.922 (%6,7)	1.549 (%4,5)	0,16	<0,001
Yok	26.869 (%93,3)	46.384 (%95,5)		
Tiroid Bezi Hastalıkları (E00-E07)				
Var	9.400 (%32,6)	10.871 (%22,2)	0,23	<0,001
Yok	19.391 (% 67,4)	38.062 (%77,8)		
Benign, Insitu ve Bilinmeyen TM (D00-D48)				
Var	1.611 (%5,6)	2.062 (%4,2)	0,06	<0,001
Yok	27.180 (%94,4)	46.871 (% 95,8)		
Anemiler (D50-D64)				
Var	11.567 (%40,2)	16.736 (%34,2)	0,12	<0,001
Yok	17.224 (%59,8)	32.197 (%65,8)		
Vitamin Eksiklikleri (E50-E56)				
Var	11.580 (%40,2)	16.465 (%33,6)	0,13	<0,001
Yok	17.211 (%59,8)	32.468 (%66,4)		
Lipid Metabolizma Bozuklukları (E78)				
Var	14.846 (%51,6)	27.662 (%56,5)	0,09	<0,001
Yok	13.945 (%48,4)	21.271 (%43,5)		
Kan ve Kan Yapıcı Org. Hastalıkları (D65-D89)				
Var	440 (%1,5)	674 (%1,4)	0,01	0,087
Yok	28.351 (%98,5)	48.259 (%98,6)		
DM Dışı Diğer Endokrin Hastalıkları (E00-E90)				
Var	8.145 (%28,3)	12.180 (%24,9)	0,07	<0,001
Yok	20.646 (%71,7)	36.753 (%75,1)		
Bipolar Duygulanım Bozuklukları (F31)				
Var	588 (%2,0)	756 (%1,5)	0,04	<0,001
Yok	28.203 (%98,0)	48.177 (%98,5)		
Depresyon (F32, F33, F92)				
Var	6.747 (%23,4)	9.652 (%19,7)	0,08	<0,001
Yok	22.044 (%76,6)	39.281 (%80,3)		
Anksiyete Bozuklukları (F41)				
Var	5.411 (%18,8)	7.845 (%16)	0,07	<0,001
Yok	23.380 (%81,2)	41.088 (%84)		
Diğer Ruh Hastalıkları (F31, F32, F33, F41 ve F92 hariç F00-F99)				
Var	1.876 (%6,5)	2.777 (%5,7)	0,03	<0,001
Yok	26.915 (%93,5)	46.156 (%94,3)		
Nöropatiler (G63.2 hariç G56-G63)				
Var	4.197 (%14,6)	7.519 (%15,4)	0,02	0,003
Yok	24.594 (%85,4)	41.414 (%84,6)		

Tablo 4.23. 'ün devamı

Parametre	Kontrol Altında	Kontrol Altında Olmayan	Etki büyüklüğü	P
Diyabetik Nöropatiler (G63.2)				
Var	3.676 (%12,8)	9.799 (%20,0)	0,18	<0,001
Yok	25.115 (%87,2)	39.134 (%80,0)		
Sinir Sisteminin Hastalıkları (G63.2 ve G56-G63 arası hariç G00-G99)				
Var	6.096 (%21,2)	8.848 (%18,1)	0,08	<0,001
Yok	22.695 (%78,8)	40.085 (%81,9)		
Kataraktlar (H25 ve H26)				
Var	1.533 (%5,3)	2.876 (%5,9)	0,02	<0,001
Yok	27.258 (%94,7)	46.057 (%94,1)		
Retinopatiler (H30-H36)				
Var	2.582 (%9,0)	9.290 (%16,9)	0,22	<0,001
Yok	26.209 (%91,0)	40.643 (%83,1)		
Gözün Kırma Kusurları (H52)				
Var	8.512 (%29,6)	13.813 (%28,2)	0,03	<0,001
Yok	20.279 (%70,4)	35.120 (%71,8)		
Sıkışmış Serümenler (H61.2)				
Var	1.706 (%5,9)	2.742 (%5,6)	0,01	0,062
Yok	27.085 (%94,1)	46.191 (%94,4)		
Tinnituslar (H93.1)				
Var	974 (%3,4)	1.512 (%3,1)	0,02	0,025
Yok	27.817 (%96,6)	47.421 (%96,9)		
Gözün Diğer Hastalıkları (H25, H26, H52 ve H30-H36 arasındakiler hariç)				
Var	10.531 (%36,6)	17.434 (%35,6)	0,02	0,008
Yok	18.260 (%63,4)	31.499 (%64,4)		
Otitis Externa (H60)				
Var	1.389 (%4,8)	2.399 (%4,9)	0,00	0,625
Yok	27.402 (%95,2)	46.534 (%95,1)		
Mastoid Çıkıntının Hastalıkları (H60 hariç H60-H95)				
Var	3.634 (%12,6)	5.619 (%11,5)	0,03	<0,001
Yok	25.157 (%87,4)	43.314 (%88,5)		
Hipertansiyon (I10)				
Var	20.842 (%72,4)	36.090 (%73,8)	0,03	<0,001
Yok	7.949 (%27,6)	12.843 (%26,2)		
İskemik Kalp Hastalıkları (I20-I25)				
Var	6.981 (%24,2)	13.951 (%28,5)	0,09	<0,001
Yok	21.810 (%75,8)	34.982 (%71,5)		
Kardiyomiyopatiler (I42-I43)				
Var	22 (%0,1)	46 (%0,1)	0,01	0,423
Yok	28.769 (%99,9)	48.887 (%99,9)		

Tablo 4.23.’ün devamı

Parametre	Kontrol Altında	Kontrol Altında Olmayan	Etki büyüklüğü	p
Serebrovasküler Hastalıklar (I60-I69)				
Var	1.816 (%6,3)	3.151 (%6,4)	0,00	0,468
Yok	26.975 (%93,7)	45.782 (%93,6)		
Diğer Dolaşım Sistemi Hast. (I10, I20-I25 arası, I42, I43, I60-I69 arası tanı kodları hariç I01-I99)				
Var	8.455 (%29,4)	13.591 (%27,8)	0,03	<0,001
Yok	20.336 (%70,6)	35.342 (%72,2)		
Solunum Sistemi Hastalıkları (J00-J99)				
Var	20.664 (%71,8)	33.919 (%69,3)	0,05	<0,001
Yok	8.127 (%28,2)	15.014 (%30,7)		
Ağız Boşluğu Hastalıkları (K00-K14)				
Var	8.019 (%27,9)	13.671 (%27,9)	0,00	0,797
Yok	20.772 (%72,1)	35.262 (%72,1)		
Gastroözofagial Reflüler (K21)				
Var	14.410 (%50,1)	23.403 (%47,8)	0,04	<0,001
Yok	14.381 (%49,9)	25.530 (%52,2)		
Dispepsiler (K30)				
Var	5.984 (%20,8)	8.456 (%17,3)	0,08	<0,001
Yok	22.807 (%79,2)	40.477 (%82,7)		
Sindirim Sistemi Hastalıkları (K00-K14 arası, K21, K30 hariç K00-K93)				
Var	15.612 (%54,2)	25.342 (%51,8)	0,04	<0,001
Yok	13.179 (%45,8)	23.591 (%48,2)		
Cilt ve Ciltaltı Doku Hastalıkları (L00-L99)				
Var	12.549 (%43,6)	20.419 (%41,7)	0,04	<0,001
Yok	16.242 (%56,4)	28.514 (%58,3)		
Kas İskelet ve Bağ Dokusu Hastalıkları (M00-M99)				
Var	22.873 (%79,4)	37.656 (%77,0)	0,06	<0,001
Yok	5.918 (%20,6)	11.277 (%23,0)		
Nefropatiler (N00-N16)				
Var	260 (%0,9)	442 (%0,9)	0,00	0,998
Yok	28.531 (%99,1)	48.491 (%99,1)		
Böbrek Yetmezlikleri (N17-N19)				
Var	2.105 (%7,3)	4.191 (%8,6)	0,04	<0,001
Yok	26.686 (%92,7)	44.472 (%91,4)		
Diğer Genitoüriner Sistem Hastalıkları (N00-N16 arası, N17-N19 arası hariç N00-N99)				
Var	14.704 (%51,1)	22.255 (%45,5)	0,11	<0,001
Yok	14.087 (%48,9)	26.678 (%54,5)		
Gebelikler (O10-O16)				
Var	30 (%0,1)	45 (%0,1)	0,00	0,596
Yok	28.761 (%99,9)	48.888 (%99,9)		

Tablo 4.23.’ün devamı

Parametre	Kontrol Altında	Kontrol Altında Olmayan	Etki büyüklüğü	P
Spontan Doğumlar (O80)				
Var	2 (%0,0)	10 (%0,1)	0,01	0,144
Yok	28.789 (%100,0)	48.923 (%99,9)		
Multipl Gebelikler Sezaryenler (O81-O84)				
Var	24 (%0,1)	48 (%0,1)	0,00	0,514
Yok	28.767 (%99,9)	48.885 (%)		
Gebeliğe Bağlı Diğer Hastalıklar (O10-O16 arası, O80, O81-O84 arası hariç, O00-O99)				
Var	186 (%0,6)	299 (%0,6)	0,00	0,55
Yok	28.605 (%)99,4	48.634 (%99,4)		
Sindirim Sistemi İlaçları (A01, A07, A09)				
Var	10.506 (%36,5)	15.970 (%32,6)	0,08	<0,001
Yok	18.285 (%63,5)	32.963 (%67,4)		
Antiobezite İlaçları (A08)				
Var	105 (%0,4)	75 (%0,2)	0,04	<0,001
Yok	28.686 (%99,6)	48.858 (%99,8)		
Sindirim Sistemi Diğer İlaçları (A11, A16)				
Var	18.590 (%64,6)	29.620 (%60,5)	0,08	<0,001
Yok	10.201 (%35,4)	19.313 (%39,5)		
Hematolojik İlaçlar (B)				
Var	16.007 (%55,6)	27.002 (%55,2)	0,01	0,26
Yok	12.784 (%44,4)	21.931 (%44,8)		
Kardiyovasküler Sistem İlaçları (C01-C09)				
Var	20.555 (%71,4)	34.719 (%71,0)	0,01	0,189
Yok	8.236 (%28,6)	14.214 (%29,0)		
Lipid Düzenleyici İlaçlar (C10)				
Var	12.207 (%42,4)	24.447 (%50,0)	0,15	<0,001
Yok	16.584 (%57,6)	24.486 (%50,0)		
Dermatolojik İlaçlar (D)				
Var	14.788 (%51,4)	24.976 (%51,0)	0,01	0,386
Yok	14.003 (%48,6)	23.957 (%49,0)		
Jinekolojik İlaçlar (G01, G02, G04)				
Var	5.368 (%18,6)	8.172 (%16,7)	0,05	<0,001
Yok	23.423 (%81,4)	40.761 (%83,3)		
Seks Hormonları (G03)				
Var	1.339 (%4,7)	1.662 (%3,4)	0,06	<0,001
Yok	27.452 (%95,3)	47.271 (%96,6)		
Sistemik Hormon Preparatları (H1, H3)				
Var	9.101 (%31,6)	11.391 (%23,3)	0,18	<0,001
Yok	19.690 (%68,4)	37.542 (%76,7)		

Tablo 4.23.’ün devamı

Parametre	Kontrol Altında	Kontrol Altında Olmayan	Etki büyüklüğü	P
Glukagon (H4)				
Var	36 (%0,1)	464 (%0,9)	0,10	<0,001
Yok	28.755 (%99,9)	48.469 (%99,1)		
Hemostaz İlaçları (H5)				
Var	31 (%0,1)	58 (%0,1)	0,00	0,666
Yok	28.760 (%99,9)	48.875 (%99,9)		
Antienfeksiyöz Ajanlar (J01, J05)				
Var	19.270 (%66,9)	32.453 (%66,3)	0,01	0,082
Yok	9.521 (%33,1)	16.480 (%33,7)		
Aşılar (J07)				
Var	2.386 (%8,3)	4.144 (%8,5)	0,01	0,379
Yok	26.405 (%91,7)	44.789 (%91,5)		
Antineoplastik Ajanlar (I01)				
Var	309 (%1,1)	408 (%0,8)	0,02	<0,001
Yok	28.482 (%98,9)	48.525 (%99,2)		
Endokrin Sistem İlaçları (I02)				
Var	212 (%0,7)	273 (%0,6)	0,02	0,002
Yok	28.579 (%99,3)	48.660 (%99,4)		
İmmünstimülanlar (I03)				
Var	25 (%0,1)	43 (0,1%)	0,00	0,962
Yok	28.766 (%99,9)	48.890 (%99,9)		
İmmünsüpresanlar (I04)				
Var	286 (%1,0)	476 (%1,0)	0,00	0,778
Yok	28.505 (%99,0)	48.457 (%99,0)		
Kas İskelet ve Bağ Dokusu İlaçları (M)				
Var	22.624 (%78,6)	36.976 (%75,6)	0,07	<0,001
Yok	6.167 (%21,4)	11.957 (%24,4)		
Anestezikler (N01)				
Var	274 (%1,0)	451 (%0,9)	0,00	0,674
Yok	28.517 (%99,0)	48.482 (%99,1)		
Analjezikler (N02)				
Var	13.820 (%48,0)	22.764 (%46,5)	0,03	<0,001
Yok	14.971 (%52,0)	26.169 (%53,5)		
Antiepileptikler (N03)				
Var	5.038 (%17,5)	8.909 (%18,2)	0,02	0,013
Yok	23.753 (%82,5)	40.024(%81,8)		
Antiparkinson İlaçlar (N04)				
Var	547 (%1,9)	737 (%1,5)	0,03	<0,001
Yok	28.244 (%98,1)	48.196 (%98,5)		

Tablo 4.23.’ün devamı

Parametre	Kontrol Altında	Kontrol Altında Olmayan	Etki büyüklüğü	p
Antipsikotikler (N05A)				
Var	1.781 (%6,2)	2.403 (%4,9)	0,05	<0,001
Yok	27.010 (%93,8)	46.530 (%95,1)		
Anksiyolitikler (N05B)				
Var	1.195 (%4,2)	1.723 (%3,5)	0,03	<0,001
Yok	27.596 (%95,8)	47.210 (%96,5)		
Psikoanaleptikler (N06)				
Var	9.820 (%34,1)	14.411 (%29,5)	0,10	<0,001
Yok	18.971 (%65,9)	34.522 (%70,5)		
Diğer Sinir Sistemi İlaçları (N07)				
Var	2.739 (%9,5)	3.775 (%7,7)	0,06	<0,001
Yok	26.052 (%90,5)	45.158 (%92,3)		
Antiparaziter İlaçlar (P)				
Var	2.996 (%10,4)	4.712 (%9,6)	0,03	<0,001
Yok	25.795 (%89,6)	44.221 (%90,4)		
Solunum Sistemi İlaçları (R)				
Var	19.919 (%69,2)	32.190 (%65,8)	0,07	<0,001
Yok	8.872 (%30,8)	16.743 (%34,2)		
Göz ve Kulak İlaçları (S)				
Var	10.138 (%35,2)	17.068 (%34,9)	0,01	0,349
Yok	18.653 (%64,8)	31.865 (%65,1)		
Çeşitli İlaçlar (V)				
Var	3.258 (%11,3)	5.050 (%10,3)	0,03	<0,001
Yok	25.533 (%88,7)	43.883 (%89,7)		
Akarboz (Kg)	(0,002±0,013)	(0,004±0,016)	0,04	<0,001
Dapagliflozin (Gr)	(0,038±0,295)	(0,155±0,574)	0,12	<0,001
Eksenatid (Gr)	(0,032±0,371)	(0,043±0,436)	0,01	<0,001
Gliklazid (Gr)	(2,530±7,780)	(5,080±10,900)	0,22	<0,001
Glimepirid (Gr)	(0,011±0,110)	(0,022±0,162)	0,02	<0,001
Glipizid (Gr)	(0,002±0,091)	(0,005±0,146)	0,00	<0,001
İnsülin Aspart (1000 U)	(0,405±2,080)	(2,090±4,580)	0,35	<0,001
İnsülin Detemir (1000 U)	(0,306±2,190)	(1,410±4,540)	0,16	<0,001
İnsülin Glarjin (1000 U)	(0,762±3,340)	(3,550±6,660)	0,41	<0,001
İnsülin Glusilin (1000 U)	(0,051±0,571)	(0,306±1,470)	0,09	<0,001
İnsülin Lispro (1000 U)	(0,103±1,050)	(0,524±2,300)	0,11	<0,001
İnsülin NHP (1000 U)	(0,038±0,831)	(0,079±1,230)	0,00	<0,001
İnsülin Regüler (1000 U)	(0,038±0,729)	(0,190±1,770)	0,02	<0,001
Linagliptin (Gr)	(0,038±0,210)	(0,088±0,303)	0,10	<0,001
Metformin (Kg)	(0,400±0,296)	(0,384±0,338)	0,08	<0,001
Nateglinid (Kg)	(0,002±0,015)	(0,004±0,019)	0,04	<0,001

Tablo 4.23.’ün devamı

Parametre	Kontrol Altında	Kontrol Altında Olmayan	Etki büyüklüğü	P
Pioglitazon (Gr)	(0,756±2,680)	(1,050±3,030)	0,09	<0,001
Repaglinid (Gr)	(0,011±0,125)	(0,030±0,217)	0,03	<0,001
Saksagliptin (Gr)	(0,018±0,152)	(0,047±0,234)	0,05	<0,001
Sitagliptin (Gr)	(0,867±4,580)	(2,300±7,200)	0,12	<0,001
Vildagliptin (Gr)	(0,808±4,530)	(1,830±6,630)	0,09	<0,001

4.4.3. Lojistik Regresyon

Aynı veri setindeki 105 değişkenin kan şekeri kontrolü bakımından sonucu nasıl etkilediğini ortaya koymak amacıyla yapılan çok değişkenli analiz sonuçları aşağıdaki Tablo 4.24’de özetlenmiştir. Güven aralığı % 95 alınmak suretiyle elde edilen anlamlı sonuçlar ise şöyledir; İlk HbA1c sonucu (3,59 (3,35-3,68)), Diyabetik Nöropatiler (1,13 (1,07-1,20)), Retinopatiler (1,20 (1,12-1,27)), Multipl Sezaryenler (2,18 (1,14-4,16)), Lipid Düzenleyici İlaçlar (1,07 (1,01-1,14)), Glukagon (1,98 (1,32-2,98)), Akarboz (Kg) (11,70 (3,03-45,49)), Dapagliflozin (Gr) (1,17 (1,12-1,23)), Eksenatid (Gr) (1,08 (1,03-1,13)), Gliklazid (Gr) (1,02 (1,02-1,03)), Glimepirid (Gr) (1,66 (1,44-1,92)), Glipizid (Gr) (1,16 (0,97-1,39)), İnsülin Aspart (1000 U) (1,05 (1,04-1,06)), İnsülin Detemir (1000 U) (1,02 (1,02-1,03)), İnsülin Glarjin (1000 U) (1,04 (1,03-1,04)), İnsülin Glusilin (1000 U) (1,05 (1,03-1,08)), İnsülin Lispro (1000 U) (1,07 (1,06-1,09)), İnsülin Regüler (1000 U) (1,04 (1,02-1,07)), Linagliptin (Gr) (1,13 (1,05-1,22)), Metformin (Kg) (1,14 (1,07-1,21)), Nateglinid (Kg) (8,17 (2,70-24,71)), Repaglinid (Gr) (1,60 (1,40-1,80)), Saksagliptin (Gr) (1,30 (1,17-1,44)), Sitagliptin (Gr) (1,02 (1,02-1,02)), Vildagliptin (Gr) (1,01 (1,01-1,01)), Obezite (0,59 (0,53-0,65)), Tiroid Bezi Hastalıkları (0,86 (0,81-0,92)), Diğer Sinir Sistemi İlaçları 0,89 (0,83-0,96)), Vitamin Eksiklikleri 0,95 (0,91-1,00)), Gözün Kırma Kusurları 0,94 (0,90-0,98)), Diğer Dolaşım Sistemi Hastalıkları 0,95 (0,90-0,99)), Diğer Genitoüriner Sistem Hastalıkları 0,95 (0,91-0,99)), Sindirim Sistemi İlaçları 0,95 (0,91-0,99)), Antipsikotikler 0,90 (0,81-0,99)).

Tablo 4.24. Çok deęişkenli analiz çalışması sonucu özet tablosu

Deęişken	p	Odds Oranı	95% Güven Aralığı
İlk HbA1c Sonucu	< ,001	3,59	(3,51 - 3,68)
HbA1c Azalma Oranı	< ,001	0,02	(0,02 - 0,02)
Yaş	< ,001	0,99	(0,99 - 1,00)
LDL	0,009	1,00	(1,00 - 1,00)
T-Kolesterol	0,082	1,00	(1,00 - 1,00)
HDL	< ,001	0,99	(0,99 - 1,00)
Kreatinin	0,741	1,00	(0,98 - 1,03)
Trigliserid	0,067	1,00	(1,00 - 1,00)
Cinsiyet	0,247	1,03	(0,98 - 1,08)
Bulaşıcı Enf. Hastalıkları (A00-B99)	0,131	1,04	(0,99 - 1,09)
Malign Kanserler (C00-C99)	0,981	1,00	(0,90 - 1,10)
Obezite (E65-E68)	< ,001	0,59	(0,53 - 0,65)
Tiroid Bezi Hastalıkları (E00-E07)	< ,001	0,86	(0,81 - 0,92)
Benign, Insitu ve Bilinmeyen TM (D00-D48)	0,872	0,99	(0,91 - 1,09)
Anemiler (D50-D64)	0,123	1,04	(0,99 - 1,08)
Vitamin Eksiklikleri (E50-E56)	0,041	0,95	(0,91 - 1,00)
Lipid Metabolizma Bozuklukları (E78)	0,161	0,96	(0,90 - 1,02)
Kan ve Kan Yapıcı Org. Hastalıkları (D65-D89)	0,800	0,98	(0,84 - 1,15)
DM Dışı Diğer Endokrin Hastalıkları (E00-E90)	0,624	0,99	(0,95 - 1,03)
Bipolar Duygulanım Bozuklukları (F31)	0,788	0,98	(0,84 - 1,15)
Depresyon (F32, F33, F92)	0,788	0,99	(0,93 - 1,06)
Anksiyete Bozuklukları (F41)	0,308	1,03	(0,97 - 1,10)
Diğer Ruh Hastalıkları (F00-F99)	0,724	0,98	(0,90 - 1,07)
Nöropatiler (G63.2 hariç G56-G63)	0,170	0,96	(0,90 - 1,02)
Diyabetik Nöropatiler (G63.2)	< ,001	1,13	(1,07 - 1,20)
Sinir Sisteminin Hastalıkları (G63.2 ve G56-G63 arası hariç G00-G99)	0,182	0,96	(0,91 - 1,02)
Kataraktlar (H25 ve H26)	0,779	0,99	(0,91 - 1,08)
Retinopatiler (H30-H36)	< ,001	1,20	(1,12 - 1,27)
Gözün Kırma Kusurları (H52)	0,007	0,94	(0,90 - 0,98)
Sıkışmış Serümenler (H61.2)	0,234	1,05	(0,97 - 1,14)
Tinnituslar (H93.1)	0,203	1,08	(0,96 - 1,20)
Gözün Diğer Hastalıkları (H25, H26, H52 ve H30-H36 arasındakiler hariç)	0,834	1,00	(0,95 - 1,07)
Otitis Externa (H60)	0,139	1,07	(0,98 - 1,18)
Mastoid Çıkıntının Hastalıkları (H60 hariç H60-H95)	0,826	1,00	(0,95 - 1,07)
Hipertansiyon (I10)	0,082	1,06	(0,99 - 1,14)
İskemik Kalp Hastalıkları (I20-I25)	0,041	1,05	(1,00 - 1,11)
Kardiyomiyopatiler (I42-I43)	0,951	0,98	(0,50 - 1,90)

Tablo 4.24.’ün devamı

Değişken	P	Odds Oranı	95% Güven Aralığı
Serebrovasküler Hastalıklar (I60-I69)	0,660	0,98	(0,90 - 1,07)
Diğer Dolaşım Sistemi Hastalıkları (I10, I20-I25 arası, I42, I43, I60-I69 arası tanı kodları hariç I01-I99)	0,020	0,95	(0,90 - 0,99)
Solunum Sistemi Hastalıkları (J00-J99)	0,206	1,04	(0,98 - 1,10)
Ağız Boşluğu Hastalıkları (K00-K14)	0,882	1,00	(0,96 - 1,05)
Gastroözofagial Reflüler (K21)	0,699	0,99	(0,95 - 1,03)
Dispepsiler (K30)	0,082	0,96	(0,91 - 1,01)
Sindirim Sistemi Hastalıkları (K00-K14 arası, K21, K30 hariç K00-K93)	0,736	0,99	(0,95 - 1,04)
Cilt ve Ciltaltı Doku Hastalıkları (L00-L99)	0,150	0,96	(0,92 - 1,01)
Kas İskelet ve Bağ Dokusu Hastalıkları (M00-M99)	0,535	1,02	(0,96 - 1,08)
Nefropatiler (N00-N16)	0,670	0,96	(0,78 - 1,17)
Böbrek Yetmezlikleri (N17-N19)	0,057	1,08	(1,00 - 1,16)
Diğer Genitoüriner Sistem Hastalıkları (N00-N16 arası, N17-N19 arası hariç N00-N99)	0,028	0,95	(0,91 - 0,99)
Gebelikler (O10-O16)	0,960	0,99	(0,55 - 1,77)
Spontan Doğumlar (O80)	0,104	4,05	(0,75 - 21,94)
Multipl Sezaryenler (O81-O84)	0,018	2,18	(1,14 - 4,16)
Gebeliğe Bağlı Diğer Hastalıklar (O10-O16 arası, O80, O81-O84 arası hariç, O00-O99)	0,297	1,15	(0,88 - 1,51)
Sindirim Sistemi İlaçları (A01, A07, A09)	0,029	0,95	(0,91 - 0,99)
Antiobezite İlaçları (A08)	0,306	0,80	(0,52 - 1,23)
Sindirim Sistemi Diğer İlaçları (A11, A16)	0,472	1,02	(0,97 - 1,07)
Hematolojik İlaçlar (B)	0,442	1,02	(0,97 - 1,07)
Kardiyovasküler Sistem İlaçları (C01-C09)	0,088	0,94	(0,88 - 1,01)
Lipid Düzenleyici İlaçlar (C10)	0,022	1,07	(1,01 - 1,14)
Dermatolojik İlaçlar (D)	0,801	0,99	(0,94 - 1,05)
Jinekolojik İlaçlar (G01, G02, G04)	0,059	0,95	(0,90 - 1,00)
Seks Hormonları (G03)	0,398	1,05	(0,94 - 1,16)
Sistemik Hormon Preparatları (H1, H3)	0,681	0,99	(0,93 - 1,05)
Glukagon (H4)	< ,001	1,98	(1,32 - 2,98)
Hemostaz İlaçları (H5)	0,882	0,96	(0,56 - 1,66)
Antienfeksiyöz Ajanlar (J01, J05)	0,631	1,01	(0,97 - 1,06)
Aşılar (J07)	0,236	0,96	(0,89 - 1,03)
Antineoplastik Ajanlar (I01)	0,483	0,93	(0,76 - 1,14)
Endokrin Sistem İlaçları (I02)	0,486	0,92	(0,71 - 1,17)
İmmünstimülanlar (I03)	0,641	0,85	(0,44 - 1,66)
İmmünsüpresanlar (I04)	0,333	1,10	(0,91 - 1,34)
Kas İskelet ve Bağ Dokusu İlaçları (M)	0,989	1,00	(0,95 - 1,06)
Anestezikler (N01)	0,256	1,12	(0,92 - 1,38)
Analjezikler (N02)	0,321	1,02	(0,98 - 1,06)

Tablo 4.24.’ün devamı

Değişken	P	Odds Oranı	95% Güven Aralığı
Antiepileptikler (N03)	0,809	0,99	(0,93 - 1,06)
Antiparkinson İlaçlar (N04)	0,143	0,89	(0,77 - 1,04)
Antipsikotikler (N05A)	0,032	0,90	(0,81 - 0,99)
Anksiyolitikler (N05B)	0,978	1,00	(0,90 - 1,11)
Psikoanaleptikler (N06)	0,281	0,96	(0,90 - 1,03)
Diğer Sinir Sistemi İlaçları (N07)	0,003	0,89	(0,83 - 0,96)
Antiparaziter İlaçlar (P)	0,871	1,00	(0,94 - 1,08)
Solunum Sistemi İlaçları (R)	0,223	0,97	(0,91 - 1,02)
Göz ve Kulak İlaçları (S)	0,385	0,97	(0,91 - 1,04)
Çeşitli İlaçlar (V)	0,435	0,97	(0,91 - 1,04)
Akarboz (Kg)	< ,001	11,70	(3,03 - 45,49)
Dapagliflozin (Gr)	< ,001	1,17	(1,12 - 1,23)
Eksenatid (Gr)	0,003	1,08	(1,03 - 1,13)
Gliklazid (Gr)	< ,001	1,02	(1,02 - 1,03)
Glimepirid (Gr)	< ,001	1,66	(1,44 - 1,92)
Glipizid (Gr)	0,115	1,16	(0,97 - 1,39)
İnsülin Aspart (1000 U)	< ,001	1,05	(1,04 - 1,06)
İnsülin Detemir (1000 U)	< ,001	1,02	(1,02 - 1,03)
İnsülin Glarjin (1000 U)	< ,001	1,04	(1,03 - 1,04)
İnsülin Glusilin (1000 U)	< ,001	1,05	(1,03 - 1,08)
İnsülin Lispro (1000 U)	< ,001	1,07	(1,06 - 1,09)
İnsülin NHP (1000 U)	0,527	1,00	(0,99 - 1,03)
İnsülin Regüler (1000 U)	< ,001	1,04	(1,02 - 1,07)
Linagliptin (Gr)	0,002	1,13	(1,05 - 1,22)
Metformin (Kg)	< ,001	1,14	(1,07 - 1,21)
Nateglinid (Kg)	< ,001	8,17	(2,70 - 24,71)
Pioglitazon (Gr)	0,004	1,01	(1,00 - 1,02)
Repaglinid (Gr)	< ,001	1,60	(1,40 - 1,80)
Saksagliptin (Gr)	< ,001	1,30	(1,17 - 1,44)
Sitagliptin (Gr)	< ,001	1,02	(1,02 - 1,02)
Vildagliptin (Gr)	< ,001	1,01	(1,01 - 1,01)

Yapılan istatistik analizler sonucu kan şekerinin kontrol altına girmeyeceğini gösteren en önemli değişkenler aşağıdaki Tablo 4.25’de özetlenmiştir. LR’de istatistiksel olarak anlamlı olmayan değişkenler tabloya alınmamıştır.

LR’de anlamlı olan, fakat odds oranı 1,1’in altında olan şu değişkenler tabloya alınmamıştır: Vitamin Eksiklikleri (E50-E56), Gözün Kırma Kusurları (H52), Diğer

Dolaşım Sistemi Hastalıkları (I10, I20-I25 arası, I42, I43, I60-I69 arası tanı kodları hariç I01-I99), Sindirim Sistemi İlaçları (A01, A07, A09), Lipid Düzenleyici İlaçlar (C1).

LR’de anlamlı olan fakat etki büyüklüğü 0,1’den az olan şu numerik değişkenler tabloya alınmamıştır: HbA1c azalma, Yaş, LDL, Akarboz, Exenatid, Glimepirid, Insulin Glusilin, Insulin Regüler, Metformin, Nateglinid, Pioglitazon, Repaglinid, Saxagliptin, Vildagliptin.

Tablo 4.25. Tek değişkenli ve çok değişkenli analizler özet tablosu

Değişken	Tek Değişkenli				Çok Değişkenli	
	Kontrol Altında	Kontrol Altında Değil	Etki Büyüklüğü*	p	Odds Oranı (%95 GA)	p
İlk HbA1c	6,20 (5,80-6,70)	8,00 (7,00-9,60)	1,5	<0,001	3,59 (3,51-3,68)	<,001
HDL	48 (40-56)	45 (38-53)	0,23	<0,001	0,99 (0,99-1,00)	<,001
Obezite (E65-E68)						
Var	1.922 (%6,7)	1.549 (%4,5)	0,16	<0,001	0,59 (0,53-0,65)	<,001
Yok	26.869 (%93,3)	46.384 (%95,5)				
Tiroid Bezi Hastalıkları (E00-E07)						
Var	9.400 (%32,6)	10.871 (%22,2)	0,23	<0,001	0,86 (0,81-0,92)	<,001
Yok	19.391 (% 67,4)	38.062 (%77,8)				
Diyabetik Nöropatiler (G63.2)						
Var	3.676 (%12,8)	9.799 (%20,0)	0,18	<0,001	1,13 (1,07-1,20)	<,001
Yok	25.115 (%87,2)	39.134 (%80,0)				
Retinopatiler (H30-H36)						
Var	2.582 (%9,0)	9.290 (%16,9)	0,22	<0,001	1,20 (1,12-1,27)	<,001
Yok	26.209 (%91,0)	40.643 (%83,1)				

Tablo 4.25.'in devamı

Değişken	Tek Değişkenli				Çok Değişkenli	
	Kontrol Altında	Kontrol Altında Değil	Etki Büyüklüğü*	p	Odds Oranı (%95 GA)	p
Multipl Gebelikler Sezaryenler (O81-O84)						
Var	24 (%0,1)	48 (%0,1)	0,00	0,514	2,18 (1,14-4,16)	0,018
Yok	28.767 (%99,9)	48.885 (%99,9)				
Glukagon (H4)						
Var	36 (%0,1)	464 (%0,9)	0,10	<0,001	1,98 (1,32-2,98)	< ,001
Yok	28.755 (%99,9)	48.469 (%99,1)				
Antipsikotikler (N05A)						
Var	1.781 (%6,2)	2.403 (%4,9)	0,05	<0,001	0,90 (0,81-0,99)	0,032
Yok	27.010 (%93,8)	46.530 (%95,1)				
Diğer Sinir Sistemi İlaçları (N07)						
Var	2.739 (%9,5)	3.775 (%7,7)	0,06	<0,001	0,89 (0,83-0,96)	0,003
Yok	26.052 (%90,5)	45.158 (%92,3)				
Dapagliflozin (1 Gr/Yıl)	(0,038±0,295)	(0,155±0,574)	0,12	<0,001	1,17 (1,12-1,23)	< ,001
Gliklazid (1 Gr/Yıl)	(2,530±7,780)	(5,080±10,900)	0,22	<0,001	1,02 (1,02-1,03)	< ,001
Insulin Aspart (1000U/Yıl)	(0,405±2,080)	(2,090±4,580)	0,35	<0,001	1,05 (1,04-1,06)	< ,001
Insulin Detemir (1000U/Yıl)	(0,306±2,190)	(1,410±4,540)	0,16	<0,001	1,02 (1,02-1,03)	< ,001
Insulin Glarjin (1000U/Yıl)	(0,762±3,340)	(3,550±6,660)	0,41	<0,001	1,04 (1,03-1,04)	< ,001

Tablo 4.25.’in devamı

Değişken	Tek Değişkenli				Çok Değişkenli	
	Kontrol Altında	Kontrol Altında Değil	Etki Büyüklüğü*	p	Odds Oranı (%95 GA)	p
Insulin Lispro (1000U/Yıl)	(0,103±1,050)	(0,524±2,300)	0,11	<0,001	1,07 (1,06-1,09)	<,001
Linagliptin (1Gr/Yıl)	(0,038±0,210)	(0,088±0,303)	0,10	<0,001	1,13 (1,05-1,22)	0,002
Sitagliptin (1Gr/Yıl)	(0,867±4,580)	(2,300±7,200)	0,12	<0,001	1,02 (1,02-1,02)	<,001

*Cohen d’ye transforme edilmiştir.

4.4.4. Makine Öğrenmesi ile Gerçekleştirilmiş Olan Görevler

01.01.2017 ve 31.12.2020 tarihleri arasındaki en az 4 adet HbA1c sonucu, yatayda (X eksen) 01.01.2017 tarihi 0 kabul edilecek şekilde ve her gün için X değeri 1 artacak şekilde (0 gün – 1461 gün), düşeyde (Y eksen) % birimi ile çalışılmış HbA1c sonuçları üzerinde, Oracle Database 11g Enterprise Edition Release 11.2.0.4.0 kullanılarak regr_slope fonksiyonu ile lineer regresyon hesabı yapılmış, elde edilen eğim (slope) değerleri 1.000 ile çarpılarak çalışmaya dahil edilmiştir.

Tez çalışması kapsamında diyabet hastalarının sağlık kayıtlarından elde edilen veri kümeleri üzerinden aşağıdaki görevleri yerine getirecek MÖ modellerinin geliştirilmesi amaçlanmıştır:

Kontrol Grubu Tahminleme

- Kontrol altında olmayan kan şekeri (KG1): Hastanın HbA1c değerleri 7’nin üstünde ve azalmıyor.
- Düzensiz kan şekeri (KG2): Hastanın HbA1c sonuçları arasında 7’nin altında ve üstünde değerleri var.
- Kan şekeri kontrol altında olanlar (KG3): Hastanın tüm HbA1c değerleri 7’nin altında veya son 2 değeri 7’nin altında.

- Azalan kan şekeri (KG4): Hastanın 1 Ocak 2017’den itibaren elde edilen ilk HbA1c değeri 7’nin üstünde ama takip eden HbA1c değerleri azalıyor ve/veya 6,5’in altına inmiş. (Bir önceki ölçüme göre 0,1’den az azalmış ise bu azalma kabul edilmemiştir.)

Trend Analizi

- Kan şekeri azalma eğiliminde
- Kan şekeri düzenli
- Kan şekeri artma eğiliminde

Belirtilen bu görevler ayrı ayrı ele alınmış olup veri kümesindeki bağımlı nitelikler bunlar üzerinden değerlendirilmiştir.


Bu veri setinin kullanılması ile kontrol grubu sınıflandırma ve trend analizi olmak üzere iki amacı gerçekleştirecek MÖ modellerinin araştırması yapıldığından veri kümesinde bağımsız değişken olarak değerlendirilecek olan nitelikler farklılık göstermektedir. Bu nitelikler ve dağılımı Tablo 4.26’da sunulmuştur. Bu dağılımda kontrol grubu ve trend analizine denk gelen sınıfların sayısının veri kümesindeki toplam kayıt sayısı ile eşdeğer olduğu görülmektedir. Kontrol grubu ve trend analizi, veri setindeki tüm kayıtların dikkate alınması ile gerçekleştirilmiştir.

Tablo 4.26. Veri kümesi nitelikleri

Bağımlı Nitelik	VS
Toplam Kayıt Sayısı	77.724
Kontrol Grubu	KG1: 19.356 KG2: 13.097 KG3: 28.791 KG4: 16.480 Toplam: 77.724
Trend Analizi	Artan: 51.028 Azalan: 26.696 Toplam: 77.724

Veri setindeki nitelikler üzerinde yapılan korelasyon katsayısı ölçümleri doğrultusunda kontrol grubu ve trend bağımlı niteliklerinin herhangi bir bağımsız nitelikten doğrudan ilişkili olmadığı sonucuna varılmıştır. Bağımsız değişkenlerin içerisinde sürekli değer

alanlar Şekil 4.3’de ve Şekil 4.4’deki dağılıma sahiptir. Şekil 4.3’deki nitelikler bağımsız değişkenler içerisinde kayan noktalı sayılar ile değişen değer alırken Şekil 4.4’deki nitelikler tamsayı değer almaktadır.



Şekil 4.3. Kayan nokta tipi sürekli değer alan bağımsız değişkenlerin dağılım grafikleri



Şekil 4.4. Tamsayı tipi sürekli değer alan bağımsız değişkenlerin dağılım grafikleri

4.4.5. Deneyi Yapılan Makine Öğrenmesi Yöntemleri

Bu tez çalışmasında kontrol grubu tahminleme ve trend analizi olmak üzere iki görevin MÖ yöntemleri ile gerçekleştirilmesi yapılmıştır. Bu başlık altında, tez kapsamında yapılan deneysel çalışmalar sonucunda en iyi performans gösterdiği tespit edilmiş olan üç MÖ yönteminin teknik detayları sunulacaktır. Bu yöntemlerin uygulama alanı gözetimli öğrenmenin bir türü olan sınıflandırmadır. Buna göre, veri noktaları (bağımsız değişkenlerle temsil edilen girdi nitelikleri) ve bağımlı değişken niteliğindeki sonuç etiketleri her bir veri noktası için modele girdi olarak verilmekte, bunun sonucu olarak modelden bu girdi niteliklerinin çıktı sınıf etiketi ile ilişkisinin öğrenilmesi beklenmektedir. Model, eğitim kümesini kullanarak çeşitli algoritmalar yardımıyla girdi ile çıktı sınıf etiketi arasında bir ilişki öğrenir. Modelin, bu ilişkiyi ne ölçüde öğrenebildiği, modelin eğitim süresince görmediği veri ile değerlendirilmesi yani test edilmesi sonucunda mümkün olur. En iyi performans gösteren ilk üç model şunlardır:

- a) Çok Katmanlı Tam Bağlı Yapay Sinir Ağı:** Çok Katmanlı Tam Bağlı Yapay Sinir Ağı (Multi Layer Fully Connected Neural Network, NN)
- b) Rastgele Orman:** Rastgele Orman (Random Forest, RF)
- c) Aşırı Gradyan Artırma:** (eXtreme Gradient Boosting, XGB)

4.4.6. Kontrol Grubu Tahminleme Üzerine Yapılan Çalışmalar

Kontrol grubu tahminleme üzerine yapılan çalışmaların her birinde veri kümesi kontrol gruplarını 4 sınıflı (KG1, KG2, KG3, KG4) sınıflandırma ve 2 sınıflı sınıflandırma (KG3 ve diğer kontrol grupları olmak üzere) üzerinde ikili sınıflandırma yapılmıştır.

4.4.6.1. Kontrol Grubu Tahminlemede Parametre Etkisinin İncelenmesi

MLP, RO ve XGBoost makine öğrenmesi yöntemlerinin gerçekleştirilmesiyle dört sınıflı ve iki sınıflı senaryolar ayrı ayrı değerlendirilmiştir.

4.4.6.2. Kontrol Grubu Tahminleme

Hastalara ait laboratuvar sonuçları üzerinden kontrol grubunun tespit edilmesine yönelik karar verme algoritması üçüncü bölümde ayrıntılı olarak sunulmuştur. Bu kontrol grupları, MÖ modeli açısından sınıf etiketlerini temsil etmektedir ve bu etiketlerin varlığı problemin gözetimli öğrenme olarak ele alınmasını sağlamıştır.

Bu modellerin performansının ölçülmesinde 5 katlı çapraz geçerleme yapılmış ve elde edilen performans değerlerinin ortalaması Tablo 4.27’de sunulmuştur. Bu tabloda her kontrol grubu için anma, duyarlılık, F ölçütü ve doğruluk değerleri gösterilmektedir. Çok sınıflı performans ölçümlerinin makro-ortalama değerleri ise Tablo 4.29’da görülmektedir. Burada, daha büyük veri kümesinden elde edilen performansın veri kümesinin alt kümelerine doğru küçüldükçe azaldığını söylemek mümkündür. Algoritmalar özelinde değerlendirildiğinde ise yöntemlerin birbirleri ile rekabet edebilir performans sergiledikleri görülmektedir. Ancak XGBoost’un tüm sınıfları birbirinden ayırmada daha başarılı olduğu söylenebilmektedir. Bu bulgu doğruluk değerleri üzerinden görülmez ancak anma ve duyarlılığı birlikte değerlendiren F ölçütü açısından diğer modellere nazaran belirgin artışlar olduğu söylenebilir. Çünkü burada bir sınıfın performans değerinin çok yüksek tutulması değil tüm sınıfların dengeli bir şekilde makul ölçüt değerine ulaşması asıl hedeftir. Makro-ortalama değerleri tek başına göz önüne alındığında muhtemel dengesiz performans dağılımı gizli kalmaktadır. Bu değerlerin tek başına değerlendirilmesi yanıltıcı olabileceğinden Tablo 4.27 ve Tablo 4.29 birlikte değerlendirilmektedir.

Tablo 4.27. Dört sınıflı kontrol grubu sınıflandırıcı performans değerleri

	MLP	MLP	MLP	MLP	RO	RO	RO	RO	XGB	XGB	XGB	XGB
	KG1	KG2	KG3	KG4	KG1	KG2	KG3	KG4	KG1	KG2	KG3	KG4
R	0,21	0,21	0,84	0,19	0,56	0,24	0,82	0,34	0,50	0,30	0,78	0,38
P	0,41	0,62	0,72	0,57	0,41	0,49	0,74	0,44	0,42	0,40	0,75	0,41
F	0,52	0,30	0,78	0,28	0,48	0,32	0,78	0,38	0,45	0,34	0,77	0,39
A	0,57				0,56				0,54			

Problemin kontrol grubu etiketlerinin atanması esnasında kontrol altında olan hastalar ve kontrol altında olmayan hastaların yanında dalgalı (düzensiz) ve azalan kan şekeri olmak üzere iki soyut sınıf daha bulunmaktadır. Bu sınıflar bazı durumlarda kontrol altında olanlar, bazı durumlarda da kontrol altında olmayanlar içerisinde değerlendirilebilmektedir. Bu sebeple bu kontrol grupları arasında net bir ayırım yapılamamaktadır. Bu duruma bağlı olarak bu tez çalışmasında kan şekeri kontrol altında olan hastalar (KG3) da diğer üç kontrol grubundan ayrıştırılmaya çalışılmış ve bu sayede ikili sınıflandırma problemi olarak değerlendirilecek olan senaryo üretilmiştir. Bu

senaryonun MÖ yöntemleri ile gerçekleştirilmesi sonucunda üretilmiş olan performans değerleri Tablo 4.28’de sunulmuştur.

Kan şekeri kontrol altında olan (KG3) hastaların bir sınıf, diğer kontrol gruplarının ise bir diğer sınıf olarak değerlendirildiği senaryoda ise MÖ yöntemleri başabaş performans sergilemektedir. Burada kontrol altında olan hastaların belirlenmesinde %77 F ölçütü değerine erişilebildiği gözlenmiştir. Bu sınıflandırmadaki doğruluk değerleri ise %85 noktasındadır.

Tablo 4.28. İki sınıflı kontrol grubu sınıflandırıcı performans değerleri

	KG3 ve diğer kontrol grupları					
	MLP	MLP	RO	RO	XGB	XGB
	Diğer	KG3	Diğer	KG3	Diğer	KG3
R	0,90	0,73	0,91	0,71	0,92	0,72
P	0,85	0,82	0,84	0,83	0,85	0,83
F	0,88	0,77	0,88	0,76	0,88	0,77
A	0,84		0,84		0,84	

Tablo 4.27’de sağ bölümde kontrol grubu tespitini iki sınıflı sınıflandırıcı olarak ele alan 5 katlı çapraz geçirme deneylerinden elde edilen makro ortalama performans değerleri sunulmuştur. Önceki senaryoda olduğu gibi bu değerlerin tek başına değerlendirilmesi halinde ortalama hesabından kaynaklı yanıltıcı bulgular elde edilebilir. Bu sebeple makro ortalama değerleri Tablo 4.28’de sunulmuş olan performans ölçüm değerlerini tamamlayıcı niteliktedir.

Tablo 4.29. Dört sınıflı ve iki sınıflı kontrol grubu sınıflandırıcılar için makro-ortalama performans değerleri

Makro-ortalama performans değerleri	4 sınıflı sınıflandırma			KG3 ve diğer kontrol grupları		
	MLP	RO	XGB	MLP	RO	XGB
R	0,49	0,49	0,49	0,82	0,81	0,82
P	0,58	0,52	0,50	0,84	0,84	0,84
F	0,47	0,49	0,49	0,83	0,82	0,82

4.4.7. Trend Analizi Üzerine Yapılan Çalışmalar

01.01.2017 ve 31.12.2020 tarihleri arasında en az 4 adet HbA1c sonucu olan hastaların HbA1c sonuçları, yatayda (X eksen) 01.01.2017 tarihi 0 kabul edilecek şekilde ve her gün için X değeri 1 artacak şekilde (0 gün – 1461 gün), düşeyde (Y eksen) yüzde birimi ile çalışılmış HbA1c sonuçları, Oracle Database 11g Enterprise Edition Release 11.2.0.4.0 kullanılarak regr_slope fonksiyonu ile lineer regresyon hesabı yapılmış ve elde edilen eğim (slope) değerleri 1.000 ile çarpılarak çalışmaya dahil edilmiştir. Bu değerler veri kümesinde bir kolon olarak saklanmakta ancak bağımsız değişkenler içerisinde değerlendirilmediği için model girdisi olarak kullanılmamaktadır. Esasında bu değer kan şekerinin artış eğiliminde mi azalış eğiliminde mi olduğunu belirtmek adına üretilmiş olup bağımlı değişken niteliğindedir. Bir başka ifadeyle kan şekerinin hangi trendde değişmekte olduğunu belirlemede kullanılabilecek olan bir sonuç niteliğidir. Burada üretilen slope değerleri veri kümesine bağımlı olarak $[-\infty, +\infty]$ aralığında değer alabilmektedir (1.000 ile çarpılmış bir değer olduğundan). Veri kümesinde hangi kayıtların kan şekerinin artan eğiliminde olduğunu, hangilerinin azalan eğiliminde olduğunu tespit etmek için bir eşik değere ihtiyaç duyulmuştur. Bu eşit değer sürekli değer alan bu niteliği sınıf etiketlerine tekabül edecek şekilde kategorize etmektedir.

Yapılan ilk çalışmalarda slope değerinin üç kategoriye ayrılması planlanmıştır. Bu kategoriler azalan, durağan ve artan olarak değerlendirilmiştir. Bunun için iki eşit değere ihtiyaç duyulmuş ve bu eşit değerler empirik olarak her veri kümesine en uygun, en yüksek performansı sunan değerler olarak çoklu deneyler sonucunda tanımlanmıştır. Buna göre -3'ün altında slope değeri olanlar azalan, +1 değerinin üzerindeki ise artan kan şekerini işaret etmektedir. Arada kalan kısımdaki hastaların kan şekeri trendi durağan olarak kabul edilmiştir.

Bu üç sınıflı yaklaşımın yanında kan şekerinin artan-azalan olmasına yönelik olarak iki sınıflı bir sınıf etiketi ataması da yapılmıştır. Bunun için gerekli olan eşik değere yine çoklu deneyler sonucunda karar verilmiş ve tüm veri kümeleri için $[0, -5]$ aralığındaki eşik değerinin model performanslarında çok büyük değişim yaratmadığı ancak bu aralığın dışında performans değerlerinin çoğu durumda olumsuz etkilendiği görülmüştür. Bu durumdan yola çıkılarak -5 değeri eşik kabul edilmiştir ve bu değer altındaki slope

değerlerinin trend etiketi azalan; üstündeki slope değerlerinin trend etiketi ise artan olarak kabul edilmiştir.

Gerçekleştirilen üç sınıflı ve iki sınıflı trend analizinin performans ölçümleri yine 5 katlı çapraz geçerleme ile doğruluk, anma, duyarlılık, F ölçütü değerleriyle yapılmış bu değerler Tablo 4.30’da sunulmuştur. Buna göre üç sınıflı trend analizi yapan deneylerde MÖ modellerinin performans değerleri birbirine oldukça yakındır ancak iki sınıflı trend analizi için geliştirilen modeller içerisinde XGBoost belirgin bir şekilde öne geçmiştir.

Tablo 4.30. Trend analizi performans ölçüm sonuçları

	Üç sınıflı trend analizi									İki sınıflı trend analizi					
	MLP	MLP	MLP	RO	RO	RO	XGB	XGB	XGB	MLP	MLP	RO	RO	XGB	XGB
	Azalan	Durağan	Artan	Azalan	Durağan	Artan	Azalan	Durağan	Artan	Azalan	Artan	Azalan	Artan	Azalan	Artan
R	0,65	0,62	0,36	0,57	0,69	0,31	0,59	0,60	0,41	0,54	0,83	0,47	0,87	0,53	0,86
P	0,53	0,52	0,53	0,56	0,51	0,50	0,56	0,53	0,50	0,62	0,78	0,66	0,76	0,66	0,78
F	0,58	0,57	0,43	0,57	0,59	0,38	0,57	0,56	0,45	0,58	0,80	0,55	0,81	0,59	0,82
A	0,53			0,52			0,53			0,73		0,73		0,75	

Tablo 4.31’de trend analizi için yapılan deneylerin makro ortalama değerleri haricen verilmiştir. Tablo 4.31’de Tablo 4.30’daki bulguları destekler şekilde gerek iki sınıflı gerekse üç sınıflı trend analizinde XGBoost modelin en başarılı model olduğu görülmektedir. Üç sınıflı modellerde modellerin performans değerleri birbirine daha yakındır ancak iki sınıflı trend analizi için geliştirilen modeller içerisinde XGBoost en başarılı ölçüm sonuçlarına erişmiştir.


Tablo 4.31. Trend analizi makro-ortalama performans ölçüm sonuçları

	Üç sınıflı trend analizi			İki sınıflı trend analizi		
	MLP	RO	XGB	MLP	RO	XGB
R	0,54	0,52	0,53	0,68	0,67	0,69
P	0,53	0,53	0,53	0,70	0,71	0,72
F	0,53	0,51	0,53	0,69	0,68	0,70

4.4.8. Kontrol Grubu Tahmini ve Trend Analizi Seri Modeli

Bu tez çalışmasında kontrol grubu tahminleme problemine kan şekeri kontrol altında olan hastaların sınıflandırılması ve kontrol altında olmayan hastaların kan şekeri trendlerinin tespit edilmesi olmak üzere iki adımda yaklaşılmıştır. Buna göre bu iki amacı gerçekleştirmek adına iki MÖ modelinin seri bağlı olarak modellenmesi yapılmıştır. Şekil 4.5’de önerilen modelin mimarisine yer verilmiştir. Burada x_i veri kümesindeki i indeksli girdi bağımsız değişkenini temsil etmektedir. İlk olarak kontrol grubu modeli ile kontrol altında olan hastalar diğer hastalardan ayrılır ve kontrol altında olmayan hastalar trend analizine tabi tutularak kan şekerinin artma veya azalma eğiliminde olduğu ikili sınıflandırma yaklaşımı ile tespit edilir.

Önerilen seri bağlı modelde her bir alt model deneylerindeki performans değerlendirmesinden elde edilen bulgular ışığında XGBoost olarak belirlenmiştir. Bu modelin eğitiminde veri kümelerinin her biri %75 eğitim, %25 test olmak üzere iki alt kümeye ayrılmıştır. Bu veri ayrıştırmada tabaka örnekleme yapılmış bu sayede orijinal veri kümesindeki sınıf etiketlerinin dağılımı eğitim ve test kümelerinde korunmuştur.



Şekil 4.5. Kontrol grubu tahmini ve trend analizi seri bağlı makine öğrenmesi modeli

Tablo 4.32’de kontrol grubu sınıflandırıcı ve ardından işletilen trend sınıflandırıcı modellerinin gerçekleştirimi sonucunda elde edilen karmaşıklık matrisleri sunulmuştur. Her bir karmaşıklık matrisinde [0,0] lokasyonundaki bilgi doğru negatif adedini, [0,1] lokasyonundaki bilgi yanlış pozitif adedini, [1,0] lokasyonundaki bilgi yanlış negatif adedini ve [1,1] lokasyonundaki bilgi doğru pozitif adedini göstermektedir. Veri akışı, spesifik olarak şu şekilde açıklanabilir: Tablo 4.32’de tahmin edilen sonucu diğer kontrol grubuna dahil olanlar (VS için 9001 + 1532 hasta) trend bilgisinin tespiti için bir sonraki XGBoost modele gönderilmektedir. Ardından burada tespit edilen hasta kayıtları (kontrol altında olmayanlar) trend analizine tabi tutulmaktadır. Bu sürecin yine bir sınıflandırma problemi olarak değerlendirilmesinin sonucu olarak önerilen modelin performans analizinde yine doğruluk, anma, duyarlılık ve F ölçüt değerleri kullanılmıştır ve Tablo 4.33’deki değerleri elde edilmiştir. Ancak bu değerler iki modelin ayrı ayrı performans ölçüm değerleridir.

Tablo 4.32. Kontrol grubu ve trend analizi seri modelinin her bir alt modülünün test için ayrılan veri kümelerindeki performansının karmaşıklık matrisi gösterimi

	Kontrol Grubu			Trend Grubu	
	Tahmin edilen			Tahmin edilen	
Sınıf etiketi	Diğer	KG3	Sınıf etiketi	Azalan	Artan
Diğer	9001	786	Azalan	2755	2513
KG3	1532	4226	Artan	1479	8798

Tablo 4.33. Kontrol grubu ve trend analizi seri modelinin her bir alt modülünün test için ayrılan veri kümelerindeki performansı

Ölçüt	Kontrol Grubu		Trend Analizi	
	Diğer	KG3	Azalan	Artan
R	0,90	0,72	0,64	0,68
P	0,84	0,81	0,66	0,67
F	0,87	0,76	0,65	0,68
A	0,83		0,67	

Önerilen seri bağılı modelin topyekün değerlendirilebilmesi için doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif değerlerinin tespit edilmesi gerekmektedir. Burada doğru pozitifler ve yanlış pozitifler sırasıyla ardışık iki modelin doğru pozitiflerinin ve yanlış pozitiflerinin toplamı kadardır. Doğru negatifler ve yanlış negatifler ise sırasıyla trend analizi modelinin doğru negatifleri ve yanlış negatifleri sayısına tekabül etmektedir. Bu hesaplama göre Tablo 4.34’de önerilen seri MÖ modelinin performans değerleri sunulmaktadır. Buna göre modelin veri kümesinde F ölçüt değerinin %85’e erişebildiği gözlenmektedir.

Tablo 4.34. Kontrol grubu ve trend analizi seri modelinin test için ayrılan veri kümelerindeki performansı

R	P	F	TNR	A
0,90	0,80	0,85	0,46	0,77

Aynı veri seti ile yapılan Logistik Regresyon analizinin sonuçları ile MÖ modelleri ile yakın sonuçlar vermektedir. Kontrolsüz kan şekeri olan DM vakalarının tahminine yönelik performans metrikleri karşılaştırmasını içeren sonuçları Tablo 4.35’de özetlenmiştir. Algoritmalar yakın performanslar göstermektedir. XGB'nin en yüksek ROC AUC'ye sahip olduğunu gözlemlenmiştir. Ancak güven aralığı hem LR hem de MLP ile örtüşmektedir. Ayrıca tanı anında sadece HbA1c seviyesinin öngörücü performans da incelenmiştir. ROC AUC'si 0,856'dır (0,853-0,859, %95 GA), duyarlılık 0,80'dir ve özgüllük %6,9 kesme seviyesinde 0,79'dur.

Tablo 4.35. Kontrolsüz kan şekeri olan DM hastalarının tahminine yönelik modellerin performans metrikleri

(LR: Lojistik Regresyon, MLP: Multilayer Perseptron, RO: Random Forest, XGB: Extreme Gradient Boosting, ROC AUC: Receiver Operating Characteristic Area Under Curve, GA: Güven Aralığı, PPV: Positive Predictive Value, Pozitif Öngörü Değeri)

Ölçüt	LR	MLP	RO	XGB
ROC AUC (95% GA)	0,889 (0,883-0,894)	0,887 (0,884- 0,892)	0,878 (0,873-0,883)	0,895 (0,890-0,899)
Duyarlılık (Recall)	0,85	0,91	0,93	0,92
Seçicilik	0,78	0,73	0,68	0,72
PPV (Precision)	0,87	0,85	0,83	0,85
F-Skoru	0,86	0,88	0,88	0,88
Doğruluk	0,82	0,84	0,84	0,85

5. TARTIŞMA

Diyabeti önleme ve tedavi sorumluluğu yakın geçmişte sağlık sektöründe iken, bilgi ve iletişim teknolojilerinin sağlık sisteminde yer bulmasıyla birlikte bilişim sektörü de önemli sorumluluklar üstlenmekte ve böylece diyabet interdispliner bir alanın ortak ilgi alanı haline gelmektedir. Diyabet hastalığı kendisi ve neden olduğu diğer kronik hastalıklar nedeniyle bireyi etkilerken diğer taraftan toplumsal sağlık göstergelerini olumsuz yönlü değiştiren, sağlık sistemine ek yükler getiren, sağlık finansmanı açısından da ülke yönetimlerinin çözümlemesi gereken çok boyutlu bir sağlık sorunu olmaya devam etmektedir. Genetik, sosyolojik, ekonomik, kültürel ve coğrafi yapılar hastalığın seyrini ve görülme sıklığını etkilemektedir. Küresel insan sağlığı problemlerinin en önemlilerinden biri olan diyabet hastalığının ve neden olduğu diğer hastalıkların olumsuz etkilerinin önlenmesi için tüm dünya ülkeleri, olanakları ölçüsünde çalışmalar yapmaktadır.

5.1. Anahtar Bulgular

Bu tez çalışması kapsamında elde edilen veriler 2020 yılı için Türkiye'de DM prevalansının %11,12 olduğunu göstermektedir. Kadınlarda %13,10; Erkeklerde %9,12 olmak üzere prevalans, kadınlarda erkeklere göre daha yüksek olarak bulunmuştur. 2020 yılı verilerimize göre diyabetin en çok etkilediği yaş grubu 60-64 yaş aralığındakiler olup 1.049.137 vakanın da %57'sini kadınlar oluşturmaktadır. Kadınların sağlık sistemine başvurusunun daha yüksek olması bu sonucu doğruyor olabilir (Tablo 4.1). Diyabeti olanlar, diyabetik olmayanlara göre sağlık kuruluşlarını daha sık ziyaret etmektedir. 2019 yılında kişi başına diyabetli vaka başvuru sayısı ortalaması 15,5 iken bu sayı diyabetli olmayanlar için 9,5'tir. Diyabetliler için daha fazla reçete yazılmaktadır. 2019 yılında diyabetli vaka başına 7,9 reçete kaydı varken diyabetli olmayan vaka başına reçete kaydı 4,5'tir. Antidiyabetik içeren ortalama reçete sayısı 2,88'dir.

Istanbul'da 2020 yılı verilerine göre diyabet prevalansı %9,77 olarak bulunmuştur. Türkiye genelinde olduğu gibi kadınlarda prevalans erkeklere oranla yüksek olup %11,54'tür. Erkeklerde ise 7,98'dir. DM hasta başına başvuru sayısı ortalaması 2019 yılı için 18,44; Reçete sayısı 9,98; Antidiyabetik içeren reçete sayısı 2,75'tir.

Bu çalışma kapsamında incelediğimiz komorbiditelerin tamamı için diyabetlilerde, diyabeti olmayanlara göre anlamlı farklılıklar tespit edilmiştir. Yaşa ve cinsiyete göre ağırlıklandırılmış odss oranları hesaplanmış, en yüksek 10,42 ile Nöropati, en düşük 1,26 ile Katarakt sonucuna ulaşılmıştır. Kanserler için hesaplanan odds oranları bakımından en yüksek 4,02 ile pankreas, 1,29 ile larenks kanserleri bulunmuştur.

Kan şekeri kontrol durumu tahminine yönelik makine öğrenmesi çalışması için İstanbul'da tedavi görmüş ve aradığımız koşulları sağlayan 77.724 diyabetli vaka kaydı bulunmuştur. Bu vakaların 28.791 (%37)'sinde kan şekeri düzeyi kontrol altındadır. 105 değişkenli veri seti ile yaptığımız makine öğrenmesi modellerinden XGB 0,895 ROC AUC ve 0,890-0,899 güven aralığı ile en başarılı yöntem olarak tesbit edilmiştir. LR, MLP, RO, yöntemleri sırası ile 0,889 (0,883-0,894), 0,887 (0,884- 0,892), 0,878 (0,873-0,883) sonuçlarını vermiştir.

5.2. Türkiye Diyabet Epidemiyolojisi

Yaptığımız sorgulamalarda 15 yaş ve üzeri yılsonu DM vaka sayısı ve % prevalans değerleri şu şekilde bulunmuştur; e-Nabız kapsayıcılığı da dikkate alınarak 2016 yılında 4.410.481 (7,24), 2017 yılında 5.414.900 (8,77), 2018 yılında 6.148.793 (9,79), 2019 yılında 6.775.054 (10,60), 2020 yılında 7.178.674 (11,12). Bu değerler Türkiye'de yapılan diğer araştırmalarla benzerlik göstermektedir. Örneğin 2018 yılında yapılan meta-analizde yanlışlık riski düşük bir grupta rastgele etkiler (random effects) modellemesi ile DM kaba prevalansı %13,5 (%95 GA: %11,6–%15,5) olarak hesaplanmıştır (Yılmaz et al., 2018).

Başka araştırmalarda da ifade edildiği üzere, her zaman teşhis edilmemiş bir diyabetli grubu vardır. Bu grubun tamamı olmasa bile bir bölümünü tespit edebilmek için 2020 yılı kayıtları arasında Bölüm 3.4.9'da anlatılan yöntemlerle yaptığımız sorgulamalar sonucunda diyabet tanı ve/veya reçete ve/veya raporu olmadığı halde diyabetli olduğu var sayılan 310.663 vaka kaydı tespit edilmiştir. Bu sayı diyabet hastalarının %4,3'ünü oluşturmaktadır. Erkekler arasında teşhis edilmemiş diyabet vakası muhtemelen daha fazladır.

2020 yılı verileri esas alınarak kaba prevalans değerleri bakımından yapılan değerlendirme sonuçlarına göre, kaba prevalansın en yüksek olduğu ilk 10 il Sinop

(17,56), Isparta (16,02), Uşak (15,87), Bartın (15,83), Çankırı (15,45), Yalova (15,15), Çorum (15,14), Kastamonu (14,89), Kırklareli (14,81) ve Karabük (14,79)'tür. Yaş ağırlıklı prevalansa bakıldığında ise ilk 10 il Isparta (14,21), Uşak (13,9), Yalova (13,31), Denizli (13,20), Afyonkarahisar (13,03), Aksaray (13,00), Sinop (12,94), Gaziantep (12,89), Bartın (12,85) ve Karabük (12,79) şeklinde değişmektedir. Kaba prevalansı en düşük il Hakkâri (3,41) yaş ağırlıklı prevalansı en düşük il Ardahan (5,72) olarak bulunmuştur. Bu sonuçları açıklayabilecek verimiz olmamakla birlikte illerde yaşayan nüfusun sağlık hizmetine erişimi, beslenme alışkanlıkları yol gösterici olabilir, duruma özel bir araştırma yapılabilir. İl bazlı farklılık nedenlerini ortaya koyabilecek bir çalışma bulunmamaktadır.

Diyabetli vakaların en çok başvurduğu klinik branşlar, pandemi öncesi ve pandemi dönemi başlangıcı itibariyle karşılaştırma olanağı sunması bakımından 2019 ve 2020 yılları için karşılaştırılmıştır. 15 yaş üstü nüfus dikkate alınmıştır. 2019 yılındaki sağlık tesislerine yapılan başvuruların 143.435.375'i, pandeminin etkisi ve raporlu antidiyabetik ilaçların reçetesiz temin edilebilmesine yönelik düzenlemelerle birlikte 2020 yılında 114.682.746'i diyabetli vakalara aittir. Buna göre 2019 yılında en çok başvuru alan ilk 10 branş Aile Hekimliği (%34,22), Acil Tıp (%11,9), İç Hastalıkları (%10,6), Göz Hastalıkları (%4,32), Kardiyoloji (%4,41), Ağız Diş Sağlığı (%3,83), Ortopedi (%2,8), FTR (%2,58), Nöroloji (%2,4) ve Genel Cerrahi (%2,39)'dir. 2020 yılı için Aile Hekimliği (%40,31), Acil Tıp (%12,38), İç Hastalıkları (%8,59), Diğer (%3,44), Kardiyoloji (%3,36), Göz Hastalıkları (%3,31), Ortopedi (%2,34), Ağız Diş Sağlığı (%2,28), Genel Cerrahi (%2,03) ve Nöroloji (%1,89)'dir. Başvurulan branşlar genel olarak değişmemiş olmakla birlikte toplam başvuru sayısı 2020 yılında %20 civarında azalmıştır. Başvurulan branşlar arasında "diğer" olarak gruplanmış olan branşlar normal dönemlerde görece daha az başvuru alan klinik mikrobiyoloji, yoğun bakım gibi branşlar ile hekim sayısının az olduğu romatoloji, algoloji gibi yan dal uzmanlıklarının toplamından oluşmaktadır.

15 yaş ve üzeri yaş grupları dikkate alındığında diyabetik vakaların sağlık tesislerine başvuruları 2016 yılında 70.006.821, 2017'de 103.031.271, 2018'de 124.372.354, 2019'da 143.435.375 ve 2020'de 114.682.746 olarak gerçekleşmiştir. Buna göre kişi başına başvuru sayıları da hesaplanmış ve aynı sıra ile kişi başına başvuru sayısı 16,49;

19,88; 21,16; 22,11 ve 16,64 olarak gerçekleşmiştir. Aynı yaş grubundaki diyabet kaydı olmayan nüfusa ait başvuru sayıları 2016 yılında 6,60; 2017’de 8,10; 2018’de 8,80; 2019’da 9,19 ve 2020’de 6,80 olarak hesaplanmıştır. Kabaca, diyabetik vakalara ait başvuru sayıları diyabetik olmayan nüfusa göre 2 katıdır. 2020 yılındaki azalmanın nedenini Covid-19 pandemisinin oluşturduğu düşünülmektedir zira pandeminin başlangıç dönemi olan 2020 yılı başlarında bulaşı azaltmak için ağız ve diş sağlığı, kulak burun boğaz hastalıkları, göz hastalıkları gibi branşlarda rutin çalışmalar asgariye indirilmiştir. Randevusu olmayanlar, kronik hastalığı olanlar ve yaşlıların yaşamı tehdit eden acil problemleri haricinde sağlık tesislerine gidilmemesi önerilmiştir. Aşı uygulamalarının başlamasıyla birlikte 2021 yılında bu önerilere son verilmiştir.

Diyabetli vaka başvuruları 2019 ve 2020 yılı için sağlık tesisi türlerine göre tasnif edilmiştir. 2019 yılında sırasıyla başvuru oranları; Devlet Hastanesi (%48,44), Aile Sağlığı Merkezi (%33,55), Özel Hastane (%7,66), Devlet Üniversitesi Hastanesi (%5,96), Özel Tıp Merkezi (%1,84), Diğer (%1,18), Özel Üniversite Hastanesi (%1,03), Bilinmeyen (%0,33)’dir. 2020 yılında bu sıralama şu şekilde değişmiştir; Aile Sağlığı Merkezi (%39,58), Devlet Hastanesi (%38,53), Özel Hastane (%8,92), Devlet Üniversitesi Hastanesi (%5,34), Bilinmeyen (%2,77), Özel Tıp Merkezi (%1,98), Diğer (%1,81), Özel Üniversite Hastanesi (%1,07). “Bilinmeyen” olarak etiketlenmiş grup normal dönemlerde doğrudan rutin klinik muayene hizmetine açık olmayan, daha çok özellikli birinci basamak sağlık hizmetleri sunulan toplum sağlığı merkezleri, toplum ruh sağlığı merkezleri, dispanserler, ilçe sağlık müdürlükleri ile kurum tabiplikleri gibi tesislerdir. Bu tesisler kendi hizmetlerinin yanında pandemiyle mücadele çalışmalarına da katılmışlardır. Başvurular hem 2019 hem 2020 yılı için ağırlıklı olarak kamu sağlık tesislerine yapılmış, pandemi öncesinde ilk sırayı devlet hastaneleri alırken pandemi döneminde ulaşılabilirliğin görece kolay olmasına bağlı olduğunu tahmin ettiğimiz aile sağlığı merkezleri ilk sırayı almıştır.

Başvuruların ne kadarının reçete yazımı ile sonlandığı incelenmiştir. İçeriğinde antidiyabetik ilaç olup olmadığına bakılmaksızın yazılan reçete sayıları bakımından yapılan karşılaştırma sonuçları ise şöyledir; 15 yaş ve üzeri diyabetik hastalarda kişi başına reçete sayısı 2016 yılında 8,30; 2017’de 10,69; 2018’de 11,40; 2019’da 11,70 ve

2020'de 8,13 adet reçetedir. Antidayetik içeriyor olma koşuluna göre bakıldığında bu sayılar aynı sırayla 2,75; 3,05; 3,06; 3,02 ve 1,64 olarak hesaplanmıştır. Diyabet kaydı bulunmayan nüfus için ise bu sayılar 2016 yılında 3,20; 2017'de 4,50; 2018'de 5,10; 2019'da 5,40 ve 2020'de 4,00 olarak hesaplanmıştır.

Beklendiği gibi, diyabet hastaları diyabetik olmayan popülasyona göre sağlık hizmetlerine daha sık başvurmakta ve daha fazla reçete yazılmaktadır. Aynı durum diğer ülkelerde de görülmektedir. İrlanda'da 2018 yılında yapılan bir araştırmaya göre, diyabetli kişilerin son 12 ayda aile hekimi ziyareti ortalaması 5,8 iken diyabeti olmayanlar arasında bu sayı 3,8 olarak bulunmuştur.. ABD tahminlerine göre, yetişkin popülasyonda diyabet prevalansının %9,7 olmasına rağmen, tüm reçetelerin %27,4'ü ve tüm hasta ziyaretlerinin yaklaşık %20'si (yılda diyabetli kişi başına 11,8 ziyaret) diyabetli kişiler tarafından yapılmaktadır (O'Neill et al., 2018). Ayrıca, diyabet kliniklerine yapılan ziyaretler hariç tutulduğunda bile, diyabetli kişiler arasında, kontrol deneklerine kıyasla ayakta hastanede bakım hizmeti kullanımının daha yüksek olduğu gösterilmiştir (Sparring et al., 2012).

Uluslararası Diyabet Federasyonu (IDF) 2045 yılına kadar tüm dünyada 700 milyon yetişkinin diyabetli olacağını tahmin etmektedir. Türkiye'ye dair 2045 yılı vaka sayısı tahmini 13,4 milyon olarak açıklanmıştır (Hong Sun et al., 2022). Türkiye için yaş ağırlıklı prevalans değerlerine yer verilmiş olan atlasta 2021 yılı için %14,5'lik prevalans ile Türkiye, DM ile başa çıkmak zorunda olan ilk beş ülke arasında gösterilmiştir (<https://diabetesatlas.org/en/sections/worldwide-toll-of-diabetes.html>, Erişim Tarihi: 21.10.2021).

Uluslararası verilere göre 70 yaşına kadar erkeklerde diyabet prevalansı biraz daha fazla olup ileri yaşlarda hastalığın ağırlığı kadın tarafına kaymaktadır. Ancak verilerimizde diyabet tüm yaş gruplarında kadınlarda daha yüksektir. Kadınlarda prevalans %13,10 iken erkeklerde %9,12 olup Türk kadınlarında yaklaşık %4 daha yüksek prevalans göstermektedir. Obezite, T2DM için ana risk faktörlerinden biridir ve bu durumu kısmen açıklayabilir (Apovian et al., 2019). Türkiye'de obezite oranı ($VKİ \geq 30$) kadınlarda %39 iken bu oran erkeklerde %24,6'dır. Ancak STEPS çalışmasına göre bilinmeyen vakalar dahil diyabet prevalansı erkeklerde %16,3 iken kadınlarda %18,3'tür (S. Üner et al, 2018). Verilerimizdeki cinsiyet farklılığının sadece obezite ile açıklanamayacağı görülmektedir.

Diğer faktör, erkeklerin sağlık hizmetine başvuru sayısının daha az olması olabilir. Sağlık sistemine başvuranların yaklaşık %60'ının kadın olduğu görülmektedir. Bu durum aynı zamanda erkeklerde muhtemelen daha fazla teşhis edilmemiş diyabet vakası varlığı sonucunu da doğurabilir.

5.3. İstanbul Diyabet Epidemiyolojisi

Çalışmada Türkiye geneli epidemiyolojik incelemelerin bir benzeri İstanbul ili için ayrıca yapılmıştır. 15 yaş ve üzeri 2019 yılsonu nüfusu 12.156.241, DM kaydı bulunan vaka sayısı 1.115.545, prevalans %9,38'dir. 2020 yılsonu nüfusu 12.150.305, DM kaydı bulunan vaka sayısı 1.187.145, prevalans %9,77 olarak hesaplanmıştır. Prevalans değerleri Türkiye ortalamasının biraz altında seyretmektedir.

2019 yılı verilerine göre İstanbul'da DM sıklığı en fazla 55-59 yaş grubunda 162.193 vaka ile 2020 yılı verilerine göre ise yine aynı yaş grubunda 172.385 vaka ile en yüksektir. 2020 yıl DM vakalarının %59'u kadın olarak bulunmuştur. Türkiye geneli için bu değer %57'dir. Bu oran 2019 yılı için de yaklaşık olarak aynıdır.

2019 yılı için vaka sayılarının en yüksek olduğu ilk 10 İlçe Adalar (53.531), Arnavutköy (52.935), Ataşehir (50.236), Avcılar (50.063), Bağcılar (47.347), Bahçelievler (46.985), Bakırköy (43.521), Başakşehir (40.439), Bayrampaşa (38.439) ve Beşiktaş (36.268)'tir. En düşük ilçe Zeytinburnu (18.853)'dur. Prevalans değerleri itibariyle sıralama yapıldığında ise durum değişmekte Adalar (15,65), Şile (13,25), Kadıköy (12,44), Çatalca (11,79), Beykoz (11,48), Silivri (11,12), Bakırköy (11,07), Bayrampaşa (10,75), Üsküdar (10,66) ve Büyükçekmece (10,57) olarak karşımıza çıkmaktadır. En düşük ilçe Esenyurt (5,82)'tur.

2020 yılı için vaka sayılarının en yüksek olduğu ilk 10 İlçe Pendik (57.603), Küçükçekmece (57.218), Kadıköy (55.004), Bağcılar (53.843), Ümraniye (53.454), Bahçelievler (50.114), Üsküdar (49.458), Maltepe (45.958), Esenyurt (44.157) ve Kartal (40.705)'dir. En düşük vaka sayısı 2.208 ile bu kez Adalar ilçesi olmuştur. Adalarda yerleşik nüfusun düşüklüğü ve nüfusun çoğunlukla ileri yaş grubunda olması, bunun nedeni olabilir. Coğrafi yapısı, taşıdığı kültürel özellikleri sebebiyle çok fazla geçici nüfusa ev sahipliği yapmakta olduğundan hem vaka sayıları hem prevalans Adalar

ilçesinde diğer ilçelere göre değişkenlik göstermektedir. Prevalans değerleri itibariyle sıralama yapıldığında ise durum değişmekte Adalar ilçesi bu kez ilk sıraya yükselmektedir. Adalar (15,44), Şile (13,86), Kadıköy (12,93), Çatalca (12,39), Beykoz (12,15), Bakırköy (11,80), Silivri (11,51), Bayrampaşa (11,48), Fatih (11,47) ve Üsküdar (11,42)'dir. En düşük prevalans yine Esenyurt (6,31) olarak bulunmuştur. Prevalans değerlerinin zamana ve ilçelere göre değişkenliğinin bir nedeni ise Türkiye genelinde olduğu gibi nüfusun hareketliliği olabilir ki ilçeler arası bu hareketliliğin herhangi bir ilde de yüksek olabileceği akılda tutulmalıdır.

İstanbul'da 2019 yılında 15 yaş ve üzeri diyabetli vakalara ait gerçekleşen herhangi bir sağlık tesisine başvuru toplamı 18.700.806'dır. En fazla sayıda başvurunun gerçekleştiği ilk 10 branş Aile Hekimliği (%32,56), İç Hastalıkları (%12,98), Acil Tıp (%9,97), Göz Hastalıkları (%5,10), Kardiyoloji (%4,33), Ağız Diş Sağlığı (%3,44), Fiziksel Tıp ve Rehabilitasyon (%2,90), Genel Cerrahi (%2,88), Ortopedi ve Travmatoloji (%2,86) ve Nöroloji (%2,39)'dir. 2020 yılı toplam başvuru sayısı 2019 yılına göre azalmış, 14.550.808 olarak bulunmuştur. Aile Hekimliği yine ilk sırada yer almaktadır. Branşlara göre başvuru oranları en yüksek ilk 10 branş; Aile Hekimliği (%35,38), Acil Tıp (%11,91), İç Hastalıkları (%11,29), Göz Hastalıkları (%4,43), Kardiyoloji (%4,04), Ortopedi ve Travmatoloji (%2,69), Genel Cerrahi (%2,63), Fiziksel Tıp ve Rehabilitasyon (%2,48), Nöroloji (%2,17) ve Kulak Burun Boğaz Hastalıkları (%2,08)'dir. Türkiye geneli ile karşılaştırıldığında başvuruların gerçekleştirildiği branşlar itibariyle anlamlı bir fark bulunmadığı söylenebilir.

2019 yılında İstanbul'daki diyabet vakalarının başvurulmuş sağlık tesisi türüne göre dağılımı oransal olarak büyükten küçüğe Devlet Hastanesi (%50,58), Aile Hekimliği (%31,55), Özel Üniversite Hastanesi (%8,37), Bilinmeyen (%3,03), Diğer (%3,00), Özel Hastane (%2,4), Devlet Üniversitesi Hastanesi (%1,04), Özel Tıp Merkezi (%0,04)'dir. Bu dağılım 2020 için Devlet Hastanesi (%44,13), Aile Hekimliği (%34,16), Özel Üniversite Hastanesi (%10,83), Diğer (%3,49), Bilinmeyen (%3,35), Özel Hastane (%2,35), Devlet Üniversitesi Hastanesi (%1,67), Özel Tıp Merkezi (%0,03) şeklinde bulunmuştur. Türkiye genelinde de en çok başvurulmuş sağlık tesisleri bu yıllar için benzerlik göstermekte, en çok aile hekimliği ve devlet hastaneleri olmak üzere kamu

sağlık tesisleri başı çekmektedir. Burada da “Diğer” olarak anılan sağlık tesisleri kurum tabiplikleri, toplum sağlığı merkezleri gibi birinci basamak sağlık tesisleridir. “Bilinmeyen” olarak etiketlenen sağlık tesisleri ise veri kayıt ve gönderim hatasından kaynaklı olarak tespiti yapılamamış olanlardır.

İstanbul’da yaşayan DM’li 15 yaş ve üzeri nüfusun herhangi bir sağlık tesisine başvuru sayıları yıllar itibariyle 2016 yılında 7.568.820, 2017’de 12.096.328, 2018’de 15.368.553, 2019’da 18.700.806 ve 2020’de 14.550.807’dir. Buna göre 2020 yılı diyabetli vakaların Türkiye genelindeki başvurularının yaklaşık %13’ü İstanbul’daki hastalara aittir. Bu oran kabaca 2019 yılı için %13, 2018 için %12, 2017 için %12, 2016 için %11 civarındadır.

DM’li vaka başına reçete sayıları 2016 yılından 2020’ye sırasıyla 7,18; 8,93; 9,60; 9,98 ve 6,81’dir. Bu reçeler içerisinde herhangi bir antidiyabetik ilaç içeren reçete sayısı aynı sıra ile 2,56; 2,73; 2,76; 2,75 ve 1,50 olarak hesaplanmıştır. Yine 2020 yılındaki düşüş dikkati çekmekte olup Türkiye geneli reçete sayılarındaki düşüşe neden olan faktörler burada da geçerliğini korumaktadır. İstanbul’daki diyabetli vakalar için yazılan toplam reçete sayıları yıllar itibariyle Türkiye ortalamasından biraz düşüktür. Türkiye genelinde DM vaka başına yazılan reçete sayısı 2016 yılında 8,30 iken İstanbul için bu sayı 7,18; 2020 yılı için 8,13’e karşılık 6,81’dir. Bu farkı açıklayabilecek verimiz bulunmamaktadır.

5.4. Komorbidite İncelemeleri

Diyabet kendisi kadar neden olduğu diğer kronik hastalıklar itibariyle de önemli bir sağlık sorunudur. Çalışmamızda diyabetin neden olduğu ya da diyabetle birlikte en sık görülen hastalıklar da incelenmiştir. Diyabet hastaları ile ilgili diğer komplikasyonların tahminine dayalı çalışmalar planlanırken, hangi parametrelerin bu istatistiksel modellerde yer alması gerektiğine dair çok büyük bir olasılık evreni ile karşılaşılmıştır. Fakat ne Türkiye’de ne de Dünya literatüründe diyabete bağlı ve birlikte seyreden komplikasyonların tanı, ilaç ve laboratuvar tetkik verilerini kullanarak değerlendirme çalışmaları yeterli büyüklükte değildir. Bu durumda parametrelerin seçimi de sürekli bir deneme yanılma ile uzun uğraşlar getireceğinden dolayı, çalışmamızın temeli diyabet hastalarının genel profili, eşlik eden hastalık durumlarını incelemek şeklinde oluşturulmuştur.

Yapılan bu çalışma ile anonimleştirilmiş e-Nabız verileri kullanılarak erken teşhis modelleri gibi koruyucu sağlık hizmetleri politikalarının geliştirilebileceği ön görülmüştür.

Komorbiditeler arasındaki nedensel ilişkiyi açığa çıkarmak için hangi hastalığın önce ortaya çıktığı, diğerinin kaç yıl sonra ortaya çıktığını bilmek nedensel ilişkiler konusunda mantık yürütmek için yardımcı olabilir. Çalışmamızda, geriye dönük uzun süreli veri eksikliği nedeniyle diyabet komplikasyonların komorbiditeler olarak incelendi. Genel tıp bilgisinden incelediğimiz komorbiditelerin büyük oranda diyabet komplikasyonu olduğunu söylemek mümkündür, ancak bu oranı net olarak bilmek mümkün değildir.

İncelediğimiz hastalıklar içinde nöropatinin diyabetlilerde 10,42 kat yüksek olduğunu gördük. Retinopati ise 4.61 kat daha fazladır. Bu durum, Türkiye'deki diyabetli popülasyonunda kan şekeri kontrolünün iyi olmadığını ve bunun bir halk sağlığı sorunu olarak algılanması gerektiğini göstermektedir. Hipertansiyon, kardiyovasküler ve serebrovasküler hastalıklar diyabetli bireylerde diğer bireylere göre 1,5-2 kat fazla görülmektedir.

Diyabette en sık ortaya çıkan komplikasyonlar diyabetik nefropati, retinopati, nöropati, diyabetik koma, kardiyovasküler hastalıklar gibi yaşamı ve yaşam kalitesini tehdit eden durumlardır. T1DM'li hastaların ayrıca Hashimoto tiroiditi, Graves hastalığı, Addison hastalığı, Çölyak hastalığı, Vitiligo, Otoimmün hepatit, Myastenia gravis ve Pernisiyöz anemi gibi diğer otoimmün bozukluklara da yatkın olduğu bilinmektedir (ADA, 2016). Diyabetli bir hastada en sık görülen kalp ve dolaşım sistemine ait ilk iki tanı, kalp yetmezliği ve periferik arter hastalığıdır (Shah et al., 2015).

Diyabetle birlikte sık görülen hastalıklar incelenirken kanser tanıları ICD-O3 kodlama ve sınıflandırma sistemine göre patoloji veri paketleri ile gelen kayıtlardan sorgulanmıştır. Diğer tanımlar ise ICD-10 kodlama ve sınıflandırma sistemine göre muayene veri paketleri ile gelen kayıtlardan sorgulanmıştır. Bu hastalıkların hem diyabetli hem de diyabetli olmayan nüfus karşılaştırmaları tablolar halinde Ekler bölümünde verilmiştir. Pandemi etkisinin olmadığı, hastaların sağlık tesislerine ulaşmakta çekince duymadığı geriye doğru en yakın tarih olması sebebiyle 2019 yılı esas alınmış, yine 15 yaş ve üzeri yaş gruplarına

bakılmış, diyabeti olan ve olmayan gruplar arasındaki odds oranları her bir hastalık için hesaplanmış, yaşa ve cinsiyete göre ağırlıklandırılmış özeti 4. Bölümde Tablo 4.22’de sunulmuştur.

En yaygın malignite türlerinin insidansı, diyabetik olmayan popülasyona kıyasla diyabetli kişilerde yüksek bulunmuştur. Odds Oranı (OO) 1,29 (larenks kanseri) ile 4,02 (pankreas kanseri) arasında değişmektedir ve diyabetli bir kişide herhangi bir malignite varlığı için OO 1,87 (1,85-1,89)' olarak hesaplanmıştır. In situ veya iyi huylu tümörler veya belirsiz veya bilinmeyen davranışlı neoplazmalar da hesaplanan OO değeri 1,52 (1,51-1,53) gibi yüksek orana sahiptir. OO, insidans çok düşük olduğunda RR'ye çok yakındır, bu nedenle sonuçlarımız literatürdeki RR’ler ile karşılaştırmak için pratik olarak aynı kabul edilebilirler (Zhang & Yu, 1998).

Karaciğer, kolon, pankreas, meme, endometrium, yumurtalık, böbrek, mesane, tiroid ve Hodgkin olmayan lenfoma gibi bazı tümörlerin diyabette yüksek risk taşıdığı biliniyordu. Bu çalışmada, tüm bu tümörler açısından DM’liler, literatürde bildirilen risklerden daha yüksek riske sahip olarak bulunmuştur.

Literatürde dudak, ağız boşluğu ve farenks kanserleri, mide, larenks, akciğer kanserleri, malign melanom, Hodgkin hastalığı gibi bazı malignitelerin risksiz veya minimal risk artışı olduğu bildirilmiştir (Ramos-Garcia et al., 2021). Verilerimizde tüm bu tümörler bakımından risk artmış olup, aralarındaki minimum risk 1,29'dur. Ek olarak, toplam malignite insidansı 1,87 (1,85-1,89) OO ile yüksek olarak değerlendirilebilir. İn situ lezyonların, iyi huylu tümörlerin ve belirsiz veya bilinmeyen davranışlı neoplazmaların OO değeri 1,52'dir (1,51-1,53). Literatürde prostat kanseri diyabetik kişilerde bizim bulduğumuz sonuca göre daha düşüktür, ancak bu çalışmada 1,35 (1,30-1,40) olasılık oranı ile artmış bir risk belirlenmiştir (Waters et al., 2009).

Veri kümemizde daha yüksek tümör riski bulmamızın nedenleri arasında, genetik veya çevresel etkilerden kaynaklı bir fark olduğu düşünülebilir. Bu çalışma bağlamında her bir malignite türünü araştırmak pratik olmadığı için, bu artan risklerin nedeni gelecekteki araştırmalarda çalışılacak alanlardan birisi olabilir. Hem diyabetik hem de diyabetik olmayan grupların sayısı yüksek olduğundan, güven aralıkları çok dardır ve önceki

alışmalarda řüpheli sonuçlar ortaya koyan bazı tümörlerde belirgin risk artışı görölmüřtür. Daha önceki alışmalarda daha düşük risk gösteren prostat kanseri, bizim alışmamızda daha yüksek riske sahiptir. Bu farklılığın nedeni, Türkiye ile ilgili bazı genetik veya çevresel faktörler olabilir.

Diyabet ve kanser arasındaki ilişki tıp biliminin titizlikle alıştığı konular arasındadır. Örneğin, spesifik olarak T2DM hastaları arasında kanser riskinin değeriendirildiğı 2007-2013 yılları arasında takip edilen 330.000 hastada her iki cinsiyette de karaciğer, kolon, pankreas, böbrek ve özellikle erkeklerde prostat, kadınlarda ise akciğer ve mide için kanser insidansı artmış olarak bulunmuřtur (Wang et al., 2015). 3,9 milyondan fazla sayıdaki T1DM hastaları arasında sağıklı nüfusa göre kanser insidansına bakılan alışmada her iki cinside karaciğer, pankreas, mide ve böbrek kanserlerinde artış bulunmuřtur. Kadınlarda yumurtalık ve tiroid kanserleri, erkeklerde kolon kanserlerinde oransal yükseklik ortaya konmuřtur. Kadınlarda meme kanseri ve melanom, erkeklerde prostat kanseri için beklenenden düşük bir insidans ortaya ıkmuřtır (Carstensen et al., 2016). Bizim bulgularımızın da benzer olduğı söylenebilir. Üzerinde alıştığımız kanser dışı hastalıklar açısından değeriendirildiğinde sorguladığımız ICD-10 tanı kodları erevesinde diyabetli olan grupta diyabet kaydı bulunmayanlara oranla Nöropati en fazla karşılaşılan patoloji iken ICD-O3 kodlarına göre sorguladığımız kanserler arasında Pankreas kanserleri en fazla karşılaşılan hastalık olarak tespit edilmiştir. Sorguladığımız tüm hastalıklar bakımından elde ettiğimiz sonuçlar, literatürle uyumlu olarak diyabetli grupların daha yüksek risk altında olduğunu göstermektedir.

Ařağıda ayrıntıları verilen kısıtlılıklarımız erevesinde diyabetik nüfusta, diyabet kaydı bulunmayan nüfusa oranla yař ve cinsiyete göre ağırlıklandırılmış odds oranları diyabetlilerin en ok Nöropati açısından dezavantajlı olduğunu göstermiştir. Maligniteler arasında ise Pankreas kanserleri başı ekmektedir.

5.5. Makine Öğrenmesi alışmaları

Elektronik sağılık kayıt sistemlerini ülke genelinde tam anlamıyla kullanmaya başlamayı başarmış nadir ülkelerden birisi olmamız, bu denli büyük bir veri tabanı üzerinde alışmış olmamız, bu alışmayı önemli ölçüde farklı kılmaktadır.

Aşağıda sözü edilen kısıtlılıklar çerçevesinde bu tezin ana amacı, mevcut elektronik sağlık kayıt sistemindeki diyabetli vaka kayıtları üzerinden, hastaların geleceğe yönelik kan şekeri düzeylerinin tahmin edilmesi, böylelikle hem hastalara hem klinisyenlere yol gösterici sonuçlar üretilmesidir.

Bazı diyabetik hastalar tedaviye iyi yanıt verir ve takiplerde normal HbA1c seviyeleri görülür. Öte yandan bazı diyabetli hastaların kan şekeri seviyeleri kontrol edilememekte ve yüksek HbA1c seviyeleri gözlenmektedir. Bu sorun, uygun olmayan ilaçlardan veya genetik, antidiyabetik ilaçlara uyumsuzluk veya diyet gibi hastayla ilgili faktörlerden kaynaklanabilir. Her durumda, her doktor, o spesifik hasta için uygun önlemleri almak için hastasının gelecekteki olası HbA1c profilini bilmek ister.

Doğaldır ki makine öğrenmesi algoritmalarının çalışabilmesi için nitelikli ve tam veriye ihtiyaç vardır. İstanbul ilindeki verilerin kalitesi operasyonel nedenlerden dolayı daha iyi olduğundan MÖ çalışmalarında sadece bu ile ait kayıtlar kullanılmıştır. İstanbul'da gerçekleştirilen testler sadece Abbott, Roche ve Beckman cihaz ve kitleri ile çalışıldığından, farklı cihaz sonuçları arasında öngörülebilir bir varyansa sahip olmak için MÖ algoritmalarımızda sadece İstanbul verilerini kullanmayı tercih edilmiştir.

Kan şekeri düzeyinin uzun dönemli durumu hakkında en iyi fikir veren, ulaşılması en kolay biyobelirteçlerden olan HbA1c, bu çalışmanın temel parametresidir. Ancak sağlıklı ölçüm sonuçlarına ihtiyaç vardır. Hem nüfus büyüklüğü ve yapısı itibarıyla hem de il genelinde uzun yıllardır aynı LBYS'nin çalıştırılmakta olduğu tespitiyle İstanbul ili seçilmiş, 2015 yılından başlamak üzere tüm HbA1c, AKŞ, OGTT, LDL, HDL, VLDL, Trigliserid, Total Kolesterol, Mikroalbumin, ALT, AST, ALP sonuçlarına bakılmıştır.

Kritik değişkenimiz olan HbA1c, kırmızı kan hücrelerinin ortalama ömrünü ve önceki 6-12 hafta boyunca ortalama kan şekeri düzeylerini yansıtan önemli bir parametredir. HbA1c ölçümü, açlık gerekmediğinden hem hekim hem laboratuvar hem de hasta tarafı için iyi bir testtir. Kan şekeri düzeyinin uzun dönemdeki ortalama düzeyini göstermesi bakımından ayrıca değerlidir. HbA1c daha stabildir, kan örneğinin alınması anından test zamanına kadar daha iyi korunur, daha az spesifik saklama gereksinimleri vardır (ADA, 2015)

Çalışmamızda vaka sayısının yüksekliğini sağlamak ve ileriye dönük HbA1c ölçüm sonuçlarını olabildiğince uzun bir zaman periyodunda izleyerek makine öğrenmesi başarımını artırmak için 1 Ocak 2017 tarihinden başlamak üzere İstanbul'daki tüm yaş gruplarında diyabet tanı, tedavi ve rapor kaydı bulunan vakalar MÖ çalışmalarımızda incelemeye dahil edildi. Bu tarihten 31 Aralık 2020 tarihine kadarki 4 yıllık zaman aralığında, aralarında en az 80 gün olması kaydı ile en az 4 adet HbA1c test sonucu bulunan vakaların HbA1c tetkik sonuçları ayrıştırıldı. Aradığımız özelliklere sahip 77.724 vaka tespit edildi. Değişken değerlerinin doğruluk ve tamlığını sağlamak için yaptığımız analiz, değişken sayısının azalmasına neden oldu. Veri setimizde 105 değişken ile sınırlı kaldı. Vaka sayısı milyon seviyesinde olmasına rağmen çalışmamızın koşullarının gerektirdiği, aradığımız özelliklere sahip kayıt sayısı ve değişken sayısı düşüktür. Bu sorun benzer çalışmalarda da gözlenmektedir. Örneğin HbA1c takibinin düzenli yapılmasının diyabetli hastaların sağlık tesisine mükerrer başvuru sayısındaki değişimine etkisinin incelendiği bir çalışma 1999-2008 yılları arasında toplam 150 hastaneye ait diyabet vaka kayıtları ile yapılmıştır. Toplam vaka sayısı 17.880.231 düzeyinde olmasına karşın aranan kriterleri karşılayan vaka sayısı 70.000 ile sınırlı kalmıştır (Strack et al., 2014). Elektronik tıbbi kayıtlara dayalı büyük veri kullanarak MÖ ile diyabet hastalarında diyabete bağlı böbrek hastalığı gelişmesini tahmin etmek için yapılan çalışmada 858.660 kayıt arasından aranan kriterleri sağlayan kayıt sayısı 64.059 olarak bulunmuştur (Makino et al., 2019).

MÖ için kayıtlarımızdan elde edilen HbA1c ölçüm sonuçlarına göre vakalar önce dört gruba ayrılmış, bu gruplar üzerinde yapılan analizlerde tatmin edici sonuçlar elde edilemeyince kan şekeri kontrol altında olanlar (son iki HbA1c %7'den küçük) ve kontrol altında olmayanlar şeklinde iki grup üzerinde çalışılmıştır.

Elde edilen değişkenlerin kan şekeri düzeyine etkisini anlamak için öncelikle tek değişkenli ve çok değişkenli istatistiksel analiz çalışmaları yapılmıştır. Bu çalışmalara başlamadan önce kullanılmış olan oral antidiyabetik ilaçların mg cinsinden olan toplam doz miktarları içerdiği etken madde miktarlarının büyüklüğüne göre gr ve kg'a (metformin ve akarboz) çevrilerek analiz süreci kolaylaştırılmak istenmiştir. Bu değerler makine öğrenmesi sürecinde ise olduğu gibi bırakılmıştır. Tek değişkenli analiz

çalışmasının sonunda her bir değişkenin, Kan Şekeri Kontrol Altında Olan ve Kan Şekeri Kontrol Olmayan gruplara göre etki boyutu ve P değerleri hesaplanarak Tablo 4.23’de özetlenmiştir. Bu analiz sonucuna göre kan şekeri düzeyinin kontrol altında olması durumuna etki eden değişkenler ve etki değerleri şöyledir; İlk HbA1c Sonucu (1,50), HDL (0,23), Tiroid bezi hastalıkları (0,23), Retinopatiler (0,22), Gliklazid (0,22), İnsülin aspartat (0,35), İnsülin Glarjin (0,41).

Daha sonra aynı veri setindeki 105 değişkenin kan şekeri kontrolü bakımından sonucu nasıl etkilediğini ortaya koymak amacıyla yapılan çok değişkenli analiz sonuçları Tablo 4.24’de, en önemli değişkenler Tablo 4.25’te özetlenmiştir. Çalışılan veri setinde kan şekeri kontrol grubunu tahmin etmekte anlamlı değişkenlerden laboratuvar tetkik sonuçları arasında İlk HbA1c sonucu ve HDL bulunmuştur. Hastalarda Obezite, Tiroid bezi hastalıkları, Diyabetik nöropatiler, Retinopatiler, Multiple gebelik tanılarının varlığı anlamlı değişkenler olarak karşımıza çıkmıştır. Kullanılan ilaçlar açısından ise Glukagon, Antipsikotikler, diğer sinir sistemi ilaçları varlığı anlamlı değişkenler arasındadır. Dapagliflozin, İnsülin Aspart, İnsülin Detemir, İnsülin Glarjin, İnsülin Lispro, Linagliptin, Sitagliptin yıllık kullanılan doz miktarları anlamlı değişkenler olarak bulunmuştur.

Bu çalışmada, 2017 yılında diyabet tanısı alan ve 2020 yılına kadar ortalama üç yıllık takip süresinde HbA1c ölçüm sonuçları bulunan kişilerin verilerinin üç yıllık tedaviden sonra %63’ünün kontrolsüz kan şekere sahip olduğu gözlemlenmiştir. Kontrolsüz kan şekerinin sağlık üzerinde ciddi etkileri olduğundan bu oran önemli bir halk sağlığı sorununu yansıtmaktadır.

Analizimize göre glisemik kontrolün en önemli belirleyicisi tanı anındaki HbA1c düzeyidir. Glisemik kontrol altındaki diyabetiklerde ilk HbA1c ortancası %6,20 (%5,80-%6,70) iken, kontrolsüz diyabetlilerde bu değer %8,00 (%7,00-9,60) olarak bulundu. LR, 3,59 (3,51-3,68) oranını vermiştir. Yani HbA1c’deki her %1’lik artış, kontrolsüz kan şekeri olma olasılığını 3,59 kat artırmaktadır. Glisemik kontrolün tahmini üzerine Parigi ve arkadaşlarının yaptığı çalışma da glisemik kontrolün en önemli belirleyicilerinin HbA1c ve açlık kan şekeri olduğunu göstermiştir (Del Parigi et al., 2019).

Uyguladığımız algoritmalar arasında XGB'nin performansı en yüksek ROC AUC'ye (0,895; 0,890-0,899: CI) sahiptir. Bununla birlikte, XCB'nin güven aralığı hem LR (0,889; 0,883-0,894) hem de MLP'nin (0,887; 0,884- 0,892) ile örtüşmektedir. Bizim sonucumuz, en iyi ROC AUC'si 0,75 olan Wang ve arkadaşlarının bulduğu sonuçlardan daha iyi görünmektedir ve 0,81 doğruluk elde eden Del Parigi ve arkadaşlarının çalışmasından daha iyi olan 0,85 doğruluğu göstermiştir (Del Parigi et al., 2019; J. Wang et al., 2020). Wang ve arkadaşlarının çalışmasının kesitsel olması; Del Parigi ve arkadaşlarının takip süresinin bir yıl olmasına karşın bu çalışmadaki üç yıllık izlemimiz farkın nedenleri arasında olabilir.

Nihai amacımız makine öğrenmesi temelli klinik karar destek sistemleri ile hekimlere yardımcı olmak olsa da, tek bir değer hekimlerin ancak günlük uygulamada daha dikkatli olmalarına yardımcı olabilir.

Kesitsel olmalarına rağmen, sonuçlarımızı önceki bazı çalışmalarla karşılaştırmak yardımcı olabilir. Koroner arter hastalığı öyküsü (Shah et al., 2021); Miyokard enfarktüsü öyküsü (Wang et al., 2021) ve hipertansiyon (Al-Sarem et al., 2022) kontrolsüz kan şekeri ile ilişkilendirilmiştir, ancak veri setimizde benzer ilişkiler gözlemlenmemiştir. Çalışma kapsamındaki vakalar yeni teşhis edildiğinden bu tür komplikasyonların gelişmesi için yeterli zamanı olmadığı düşünülmektedir. Verilerimiz tanıdan sonraki bir yıl ile sınırlıdır. Ancak bir çalışmada olduğu gibi kontrolsüz vakalarda daha fazla diyabetik nöropati ve retinopati gözlemlenmiştir (Wang et al., 2021).

Çalışmalar ayrıca fazlaca reçete edilen antidiyabetik ilaçların kontrolsüz kan şekerinin bir göstergesi olduğunu göstermektedir (Al-Sarem et al., 2022; Shah et al., 2021; Wang et al., 2021). Veri setimiz, artan dapagliflozin, gliklazid, insülin aspart, insülin detemir, insülin glarjin, insülin lispro, linagliptin ve sitagliptin dozlarının kontrolsüz kan şekerinin öngörücüleri olduğunu göstermektedir. Bu durumun basit açıklaması, zor durumlarda yoğun bir antidiyabetik ilaç kullanılması gerekliliğidir, ancak sorun daha karmaşık olabilir ve daha fazla araştırmayı gerektirir.

Kanser öyküsünün daha düşük kontrolsüz kan şekeri riski ile ilişkili olduğu bildirilmiştir (Shah et al., 2021), ancak bu çalışmada kullanılan veri seti böyle bir ilişki ortaya koymamıştır.

Al-Sarem ve arkadaşlarının çalışmalarında, daha iyi glisemik kontrolü olan hastaların total kolesterolü daha yüksek bulunmuştur (Al-Sarem et al., 2022). Veri setimizde, daha iyi glisemik kontrole sahip hastaların total kolesterolü daha yüksek bulunmamış olmakla birlikte total kolesterolün bir bileşeni olan HDL'nin daha yüksek olduğu görülmüştür. HDL, karmaşık mekanizmalar yoluyla T2DM'nin başlangıcını ve ilerlemesini etkileyebilir ve HDL hedefli tedavi de çalışılmaktadır.

Çalışmamız ayrıca obezitenin varlığı ile glisemik kontrol olasılığının arttığını göstermektedir. Ne yazık ki, büyük bir popülasyona sahip Ontario çalışması, obezite verilerini içermemektedir (Shah et al., 2021). Al-Sarem ve arkadaşları obezitesi olan kişilerde kontrolsüz kan şekeri riskinin arttığını bildirirken (Al-Sarem et al., 2022), başka bir çalışma, HbA1c ile ağırlık veya bel çevresi arasında hiçbir ilişki olmadığını bildirmektedir (Goecks et al., 2020). Amerika Birleşik Devletleri'nde 44.723 hasta ile yapılan bir çalışmada, sonuçlar normal kilolu bireylerle karşılaştırıldığında, VKİ ≥ 25 olan kişilerin son HbA1c ≥ 7 'ye sahip olma olasılığının %24 daha fazla olduğunu göstermiştir (OO 1,24; %95 CI 1,14- 1,35) (Boye et al., 2021). Bu sonuç bizim bulgularımız ile çelişmektedir, ancak veri setimizde obezite, sağlık profesyonelleri tarafından kodlanmış klinik bir obezite teşhisi anlamına gelmektedir. Bu, muhtemelen glisemik kontrolün elde edilmesine de yardımcı olan bir klinik tedavi protokolünü yansıtmaktadır.

Çalışmadaki bir diğer bulgu da kan şekeri kontrol altında olanlarda tiroid hastalıklarının (%32,6) kontrol altında olmayanlara göre (%22,2) yüksek oranda görülmesidir. Diyabetik kişilerde tiroid fonksiyon bozukluklarının yüksek prevalansı iyi bilinmektedir ve daha önce %4 ila %20 arasında bir artış bildirilmiştir (Biondi et al., 2019). Yakın zamanda Mısır'da yapılan bir çalışmada T2DM'de tiroid disfonksiyonu prevalansı %29 olarak bildirilmiştir (Elgazar et al., 2019). Hem hipotiroidi hem de hipertiroidinin glukoz metabolizması üzerinde olumsuz etkileri vardır (J. Wang et al., 2020). Kişinin elektronik sağlık kaydında tiroid hastalığı kodunun bulunması olası bir tedaviyi gösterir ve bu da tiroid hastalığı tanısı olan kişilerde daha iyi glisemik kontrolü açıklayabilir.

Çalışmamızda, kan şekeri düzeyinin tahmin edilmesinde doğrudan ya da dolaylı olarak sonuca etki edebilecek boy, kilo, günlük fiziksel aktivite ve diyet değişkenlerine ait veriler ya hiç bulunmadığı ya da istenilen nitelik ve nicelikte olmadığı için kullanılamamıştır. Bu problem ESK tabanlı büyük veri çalışmalarının çoğunda karşılaşılan bir problemdir. Örneğin Nagaraj ve arkadaşları da elde ettikleri sonuçlara ($AUC \geq 0,80$) rağmen, HbA1c yanıtını tahmin eden sistemlerinin henüz klinik kullanıma hazır olmadığını, insülin dozu ve rejimi, diğer ilaç değişiklikleri, ilaç uyumu ve yaşam tarzı gibi değişkenlerin sonucu değiştirebileceğini, bulguları doğrulamak için önerilen modelin başka bir veri kümesi üzerinde de doğrulanması gerektiğini, sonuçlarının, ilaç yanıtını tahmin etmede makine öğrenim potansiyelinden yararlanmak isteyen araştırmalara rehberlik etmek için önemli kavram kanıtı olduğunu, insülin tedavisinde hassas tıp için bir basamak teşkil edebileceğini bildirmişlerdir (Nagaraj et al., 2019).

5.6. Kısıtlılıklar

Yüksek mortalite ve morbiditeye neden olan diyabet hastalığını ve komplikasyonlarını önlemek amacıyla sayılamayacak kadar çok araştırma yapılmaktadır. Benzer nedenlerle bu tezin ana konusu diyabet olarak belirlenmiştir. Araştırmanın yürütülmesinde hali hazırda ulaşılabilir ve en güvenilir kaynağın e-Nabız veri tabanı olduğu düşünülerek gerekli izin prosedürü tamamlanmış ve Etik Kurul onayının alınmasını takiben ilk olarak epidemiyolojik incelemelere başlanmıştır. Ancak e-Nabız sisteminin 4 Nisan 2015 tarihinde kullanıma alınmış olması sebebiyle toplumun tamamını kapsayıcılığı bakımından bir kısıtlılık da söz konusudur. Kapsayıcılığı artırmak için incelemelere 2016 yılına ait verilerden başlanmıştır.

Yaptığımız epidemiyolojik incelemeler sırasında hemen her ülkede karşılaşılabilecek veri kalitesi, veri standardizasyonu, kayıt prosedürlerindeki farklılıklardan kaynaklanan sorunlar, kayıt sistemlerinin ağırlıklı olarak hizmetin finansmanına odaklı olması, insidans hesaplama, kapsayıcılık, diyabet tipinin belirlenmesindeki gri alanlar bu çalışmada da yaşanan problemler arasındadır.

Çalışmamızın ana kısıtlılığı gerçek hayattaki elektronik sağlık kayıtlarının kullanılmasıdır. Gürültü, elektronik sağlık kayıtlarının doğal bir bileşenidir. Kayıp veriler

ve hatalı kodlarla karşılaşmak mümkündür. Yine ana kısıtlılıklardan birisi hastanın reçeteli ilaçlarını gerçek hayatta kullanıp kullanmadığı bilgisinin eksikliğidir.

Veri kalitesine olumsuz yansıyan önemli faktörlerden birisi, verilerin ödeme odaklı olarak kayıt altına alınmasıdır. Olası bir tanının ekarte edilmesi için yapılacak tetkiklerin tanı ile uyumlu olmaması halinde ödeyici kurum tetkik giderlerini karşılamadığı için yapılacak tetkike uygun olası tanı kayıtları sisteme işlenmekte, olası tanı ekarte edilmiş olsa bile çoğu kez sistemde kayıtlı olarak kalmaktadır. Bu tuzaklardan kaçınmaya çalışmış olsak da tümüyle kurtulduğumuzu söyleyemeyiz.

Büyük verinin sağlayacağı en önemli avantaj, tedaviyi kişiye özelleştirmek için büyük bir potansiyel sunmasıdır (Xie et al., 2018). Büyük veri bu potansiyeli sunmasına rağmen insanda hastalıkların bireysel değişken etki ve sonuçları, sağlıkta veri kalite ve güvenilirliğinin önemi ve buna bağlı problemler, sağlık hizmeti verilerinin heterojenliği, kişisel veri gizliliği, destekleyici politikaların yetersizliği, vb nedenlere bağlı olarak tıpta büyük veri kullanımı çalışmaları beklenenden azdır (Gubbi et al., 2019). Büyük verinin diyabet hastalığını incelemek için kullanılması ile ilgili önemli bir derleme 2015 yılında yayımlanmıştır (Bellazzi et al., 2015). Bu derlemede, diyabet verisinin değişik kaynaklardan toplanması nedeniyle ortaya çıkabilecek veri bütünlüğü sorunlarından, mahremiyet sorunlarından, veri analizi için yeni yöntemler geliştirilmesi gerektiğinden söz edilmektedir. Bundan beş yıl sonra, 2020 yılında yayımlanan bir derlemede, benzer şekilde farklı veri setlerini entegre etmenin zorluğundan, yapılandırılmamış verilerin yönetilmesi ile ilgili problemlerden ve bu tip çalışmalarda bilgilendirilmiş onam almanın pratikteki zorluklarından söz edilmektedir (Rumbold et al., 2020). Bahsedilen bu kısıtlılıkların neredeyse tamamı bu çalışma için de geçerlidir.

Yıllara göre toplam nüfus verilerine TÜİK'ten ulaşılmıştır. Bu nüfus esas alınarak 2016 ve 2020 yılları arasındaki e-Nabız kapsayıcılık oranları elde edilmiş, buna göre kapsayıcılık oranı sırasıyla 2016 yılı için %91,0, 2017 yılı için %94,8, 2018 yılı için %96,6, 2019 yılı için %97,7 ve 2020 yılı için %99,1 olarak hesaplanmıştır. Kapsayıcılığı bir örnek ile anlatmak gerekirse toplam nüfusa göre 2020 yılında hayatta olanların %99,1'inin e-Nabız'da en az bir sağlık kaydı bulunmaktadır. e-Nabız sisteminin 15 yaş ve üstü nüfusun oldukça büyük bir bölümünü kapsadığı ve 2016'da sadece %9'unu,

2020'de ise %0,9'unu dışarıda bıraktığı tespit edilmiştir. Dolayısıyla, mevcut verilerin temsil yeteneğinin yüksek olduğu söylenebilir. Birçok araştırmada olduğu gibi bu çalışmada da 15 yaş ve üzeri nüfus ile beşerli yaş gruplamaları esas alınmış ve böylelikle karşılaştırma yapabilme olanağı sağlanmıştır.

Diyabetli vakaların sağlık sisteminde oluşturduğu yük bu tez çalışması kapsamında net olarak ortaya konulmamıştır. Çünkü yaptığımız incelemeler, bu hastalara yapılan muayene, tetkikler ve reçete ile sınırlıdır. Yatışı yapılan, bir başka ifadeyle yatırılmasını gerektirecek düzeyde sağlık problemleri olan vakalar için yapılan işlemler araştırılmamıştır. Dolayısıyla bu çalışmanın, diyabetin sağlık sistemi üzerindeki yükünün çoğunluğunu ziyaretler ve reçeteler olarak gösterdiğini ifade edebiliriz. Diğer taraftan tanısı konmamış hastaların görece olarak hastalığın erken evresinde olmaları ve diyabete bağlı sağlık sorunları ve komplikasyonlarının daha az olması beklendiğinden diyabet açısından ele alınmamıştır. Yatan hasta günlerinin ve prosedürlerinin ayrıntılı bir analizi, hastalığın yükü hakkında daha bilgilendirici olabilir.

Türkiye'de bir hekim genellikle en fazla üç aylık ilaç miktarını tek defada reçete edebilmektedir. Bu nedenle, DM hastalarının genellikle yılda ortalama dört antidiyabetik reçetesi olmalıdır. Verilerimiz, DM hastalarının yetersiz ilaç tedavisi aldığını düşündürecek şekilde antidiyabetik reçetesi yazıldığını göstermektedir (Tablo 4.12). Hasta başına OAD reçete sayısı özellikle 2020 yılında beklenenden çok düşüktür. Bunun nedenleri şunlar olabilir; Covid-19 Pandemisi dolayısıyla SGK'nın raporlu ilaçların reçete ettirilmeksizin doğrudan eczanelerden alınabileceğine dair tebliği ilk neden olarak değerlendirilebilir. Reçetelerin daima elektronik reçete olarak düzenlenmesi zorunluluğu olmadığından manuel reçete de düzenlenebilmektedir. Bu reçete kayıtları ile cepten harcama yapmak suretiyle doğrudan eczanelerden alınan ilaçlar bizim üzerinde çalıştığımız sistemlerde kayıt altına alınmamaktadır. Bir başka neden, bazı hastaların ilaçlarını düzenli olarak almıyor olmaları olabilir.

İlaçlara dair diğer bir kısıtlılığımız ise çalışmaya dahil edilen vakaların hangilerinin ulusal ya da uluslararası tedavi rehberlerine göre tedavi gördüklerini bilmiyor olmamızdır.

Sistemimizde diyabet tanısının ilk kanıtı 2017 yılında hayatta olan bir kişinin 2017 yılında ilk kez diyabet tanısı almış olmasıdır. Ancak 2015 öncesi veriler sistemimizde mevcut olmadığından “yeni tanı almış” diyabet hastalarımızın bir kısmı gerçekten yeni tanı almış olmayabilirler. Ayrıca düzenli HbA1c testi yaptırmayan hastaların glisemik kontrol durumu hakkında bilgimiz bulunmamaktadır. Kan şekerleri düzenli olabilir ve takip ihtiyacı hissetmeyebilirler veya sağlıklarını önemsemeyebilirler ve glisemik kontrolleri çok kötü olabilir.

Bu çalışma, ulusal bir elektronik sağlık kayıt sistemi üzerinde yapılacak sınırlılıklara sahiptir. Bu tür veritabanları gürültülüdür, insan faktörü veya iş akışı sorunları, hatta kasıtlı bazı yanlış veriler söz konusu olabilmektedir. Teknik sorunlardan dolayı kayıp veya hatalı veriler olabilir. Bu çalışmada da tüm bu sorunları ve daha fazlası gözlemlenmiş, bu nedenle bazı hatalı veriler çalışma dışı bırakılmış, bazıları düzeltilmiş, bazıları ihmal edilmiştir. Bu analiz sırasında gözlemlediğimiz problemleri çözüme kavuşturmak üzere teknik çalışmaları yapılmış, yakın gelecekte uygulanacak yeni düzenlemeler planlanmıştır. Her halükârda, sonuçlarımız mükemmel olmaktan uzaktır ve bu sonuçların gerçeğin kusurlu bir görünümü olduğunun farkında olunmalıdır.

Bu çalışmanın bir diğer kısıtlılığı, sonuçlarımızda diyabet tipinin belirlenme metodudur. Metodu belirlemek için ICD kodları ile diyabetin tipini veya geçmiş çalışmalarda önerilen yöntemler sorgulanmış (Ke et al., 2020; Spratt et al., 2017; Weerahandi et al., 2020). Ancak bu yöntemlerle güvenilir T1DM veya T2DM prevalansı elde edilememiştir. Mevcut verilerimizle gerçek Tip 1 ve Tip 2 ayrımını yapmak olası değildir. Buna rağmen diyabet tipini belirleme metodumuzun ayrıntılarını Bölüm 3.5.2’de Diyabet Tipi Belirleme Kriterleri başlığı altında ayrıntılı olarak anlatılan şekilde, kesin klinik tanıyı ifade etmemekle birlikte belirlediğimiz kriterlere göre yaptığımız tip belirleme çalışmasının sonuçlarına göre 2020 yılında her iki cins için toplam sayının yaklaşık %2,7’si T1DM’dir. T1DM hasta sayısı beklenen prevalans değerine göre düşük çıkmaktadır. Çünkü T1DM olarak işaretlenen hastalarda oral antidiyabetik reçete kaydı bulunmamasında hassas davranılmıştır. Yani, T2DM’li bir vakanın şans eseri T1DM grubunda olmamasını sağlamak istenmiştir. Fakat bu, aynı zamanda bazı T1DM’lilerin T2DM grubuna kaymasına sebep olmuştur. Bunu yapmanın amacı az sayıdaki T1DM’liler

arasına T2DM'lilerin karışması halinde yapılacak modellemelerde T1DM popülasyonunda ciddi sapmalara neden olma olasılığını ortadan kaldırmaktır. Fakat az sayıdaki T1DM popülasyonu 7 milyona yakın T2DM grubunda o kadar büyük bir etkiye neden olmayacaktır.

Diyabetin tipinin belirlenmesi problemini hemen tüm ülkeler yaşamaktadır. Örneğin Zimmet ve arkadaşları, diyabetin tiplere göre insidansını belirleyebilmek için aynı bireylerin belirli bir süre boyunca tekrarlanan testlerle izlenmesi gerektiğini, bu tür çalışmaların genellikle risk ve nedensel faktörleri belirlemeye yönelik araştırmalar için yürütüldüğünü, klinik olarak teşhis edilen T1DM veya T2DM insidansının, güçlü kayıt sistemi olan topluluklarda veya ülkelerde zaman içinde ancak belirlenebileceğini, bu tür çalışmaların nadir olduğunu ve şu anda ekonomik gelişmişlik bakımından önde olan birkaç ülke ile sınırlı olduğunu, ancak gelecekte elektronik tıbbi kayıt sistemlerinin geliştirilmesiyle daha yaygın hale gelebileceğini ifade etmişlerdir (Zimmet et al., 2016).

Sadece diyabetin tipini belirlemeye yönelik yapılmış bir araştırmada yazarlar probleme işaret ederek makalenin temel amacını, diyabetin tipini tahmin etmek için diyabet veri setinden MÖ yoluyla doğru tahminler elde etmek üzere uygun makine öğrenme modelini ortaya çıkarmak olarak bildirmişlerdir. Bu tahmin için RO, DVM, CART (Classification and Regression Trees), LDA (Latent Dirichlet Allocation) ve k-NN gibi farklı makine öğrenme algoritmalarını ele almışlardır. Bu algoritmaların seçilmesinin nedenini, doğruluk, kesinlik, kappa değeri, geri çağırma, duyarlılık ve özgüllük gibi çeşitli ölçütlere dayalı en iyi tahmin algoritmasını belirlemek, farklı makine öğrenme algoritmalarını analiz etmek ve karşılaştırmak olarak açıklamışlardır. Bu çalışmanın sonucunda, RO algoritmasının sonuçları doğru tahmin ettiği ve verileri en doğru şekilde sınıflandırdığı gösterilmiştir. RO algoritması LDA, DVM, CART ve k-NN ile karşılaştırıldığında daha iyi doğruluk sağlamış, doğruluk değeri 0,99 olarak ve diğer tüm algoritmalar arasında en iyisi seçilmiştir. Bu algoritmanın kappa değeri 0,99 kesinlik değeri 1 ve geri çağırma değeri 1 olarak tespit edilmiştir (Kumar & Pranavi, 2017).

Makine öğrenmesi çalışmalarımız HbA1c düzeyi üzerine kuruludur. Ancak HbA1c üzerinden yapılan çalışmaların bazı dezavantajları da vardır. Kan şekeri düzeyinin uzun zaman aralığındaki değişimini en iyi şekilde göstermesine karşın iki ölçüm arasında geçen

sürenin de doğru şekilde kayıt altında tutulması gerekir. İngiltere'de yapılan bir çalışmada yaklaşık yarım milyon HbA1c ölçümü incelenmiş ve ölçümlerin %21'inin olması gerekenden daha sık, %30'unun ise olması gerekenden daha az yapıldığı bulunmuştur (Driskell et al., 2012). Kan şekeri düzeyi kontrolünde önemli bir bozulma ile ilişkili olduğundan, HbA1c'nin kılavuzların dışında uygun olmayan şekilde izlenmesi, diyabet kontrolünde önemli bir zorluktur. Testlerin olması gerekenden daha kısa veya uzun aralıklarla tekrarlanması önemli bir sorundur (Loh et al., 2011).

HbA1c ölçüm sonucuna göre karar vermek her zaman doğru bir yaklaşım olmayabilir. Hipertansiyon, kalıtsal sferositoz ve kolesistektomi, splenektomi, hemodiyaliz tedavisi gören hastalar, yakın geçmişte kan kaybı ya da transfüzyonu, eritropoietin tedavisi gibi klinik durumlar yanlış sonuçlara götürebilir (O'Keeffe et al., 2016).

Çalışmamız, Türkiye'nin ulusal elektronik sağlık kayıt sisteminden elde edilen verilere dayanmaktadır ve bu sistem özellikle diyabet veya kanser kayıt sistemi olarak tasarlanmamıştır. Verileri günlük operasyonel bir veritabanından çıkardık ve hatalar içerebilir. Ek olarak, veri tabanında bazı veriler olmayabilir, bu nedenle az da olsa bazı diyabet veya kanser tanıları çalışmaya dahil edilememiş olabilir.. Öte yandan T1DM ve T2DM, farklı tümörler üzerinde farklı riskler getirebilir, ancak veri setimizde diyabet tipini kesin olarak ayırt edememe kısıtından dolayı sonuçlar, T1DM ve ağırlıklı olarak T2DM'nin bir karışımıdır.

6. SONUÇ ve ÖNERİLER

Ülkeler için önemli bir halk sağlığı sorunu, bireyler için yaşam kalitesi ve süresi sorunu yaratan diyabetin önlenmesi, ortaya çıkmasının geciktirilmesi, neden olduğu diğer hastalıkların önüne geçilmesi ortak amacıyla sayılamayacak kadar çok araştırma yapılmakta olduğu gözlenmektedir. Diyabet, sadece tıp biliminin sorumluluğuna bırakılamayacak kadar ciddi bir hastalıktır. Kan şekeri düzeyini sürekli olarak ölçmek üzere üretilen cihazlar, besin öğelerinin görüntülerini işlemek suretiyle alınan kalori miktarını hesaplayan sistemler, giyilebilir sensörlerle günlük fiziksel aktiviteleri kaydeden uygulamalar ve dijital insülin pompaları gibi pek çok sistem sürekli olarak veri üretmektedir. Bu sayede büyük veriden bahsetmek mümkün hale geldiği gibi bilişim dünyasına da sorumluluklar düşmekte, bu durum tıp bilişimi alanının önemini ortaya çıkarmaktadır.

Kimliksizleştirilmiş büyük verinin Kamu yararına ve belirli koşullar altında araştırmacıların kullanımına sunulması halinde sağlık ve bilişim ekiplerinin birlikte çalışma motivasyonu artacağı gibi sağlık bilişimi alanının gelişimine de katkı sağlayabilir. Anonimize büyük verinin kullanıma açılması için kesin prosedürlere, hukuki düzenlemelere ve teknik geliştirmelere ihtiyaç vardır.

Elektronik ortamda geliştirilen klinik karar destek sistemlerinin ve yapay zekâ çözümlerinin geliştirme sürecinde, alan uzmanlarının deneyim ve bilgilerinin dikkate alınması ve sistemlerin sağlık hizmeti sunumunu kolaylaştırıcı bir role sahip olması halinde bu sistemlerin direncin aksine katılımı teşvik edeceği, sonuç olarak sağlık profesyonellerinin sadece iş yapış biçimlerinin değişeceğini söyleyebiliriz. Bu değişim elbette tıp biliminin de değişimini tetikleyecek, yeni hastalık tanımlamaları, yeni tanı ve tedavi teknikleri ve yaklaşımları ortaya çıkacaktır.

Elektronik sağlık kayıtları ve teknolojik ürünleri kullanan ve yapay zekâ modellerini içeren çalışmalar bize göre henüz yolun başındadır. Diyabetin tüm klinik formları için risk faktörlerini belirlemek, gelişimini önlemek, geciktirmek, hastalanmış olanların yaşam kalitesini korumak, optimum tedavi seçeneğini belirlemek ve tedavi maliyetlerini

düşürmek amacıyla daha çok sayıda araştırma yapılmalıdır. Elektronik ortamda tutulan sağlık kayıtlarının istatistiksel analizlerinin yanı sıra, oluşan büyük veriler kullanılarak MÖ modelleri ile diyabeti ve diyabetin neden olduğu klinik problemleri önleme amacına hizmet edilmelidir. Benzer ya da eşdeğer yazılımların, kodlama ve sınıflandırma sistemlerinin geniş alanlarda kullanılmıyor olması, tanı ve tedavi yaklaşımlarındaki farklılıklar, hastalığın tanı, tedavi ve takibinde standart prosedürlerin olmayışı, hukuki ve etik düzenlemelerdeki boşluklar ya da yetersizlikler gibi pek çok nedene bağlı olarak MÖ çalışmalarındaki kısıtlılıklar söz konusudur. Bu kısıtlılıkların aşılmasına çalışılması tüm Dünya vatandaşları için doğrudan ya da dolaylı olarak gerekli ve önemlidir.

Tanı ve tedavi süreçleri pek çok hastalık için kaba bilgiler ışığında devam ettirilirken diyabetin takip ve tedavisinin kişiye özel olarak düzenlenmesini zorlayan faktörler söz konusudur. Örneğin boy, kilo, rezerv pankeas fonksiyonu, insülin direnci, beslenme alışkanlıkları, yani öğün sayısı ve içeriği, uyku süresi, genetik özellikler, günlük aktivite, antidiyabetik ilaçların yan etkileri, tedaviye uyum, mevcut diğer hastalıklar, kullanılan diğer ilaçlar gibi parametreler takip ve tedavide bireysel tıp yaklaşımını zorunlu kılmaktadır. Diğer yandan kan şekerinin kontrol altında tutulmasındaki en etkili değişkenlerin ortaya konması gerekmektedir ki bu çalışmanın sınırlıkları içerisinde olmak üzere en etkili değişkenler belirlenmeye çalışılmıştır. Değişkenlerin çoğunluğu düzenli takip gerektirmektedir. Bu takiplerin yapılabilmesi için hastalara daha güçlü şekilde giyilebilir cihaz, akıllı cihaz desteklerinin sağlanması gerekmektedir. Sağlık profesyonelleri ile hasta iletişimini güçlendirmek için Türkiye’de sağlıklı hayat merkezi adı ile hizmete katılan sağlık tesislerinde hastalığa özel yetiştirilmiş yardımcı sağlık personelinin görevlendirilmesi ve donanımı özelleştirilmiş kliniklerin konuşlandırılması başarıyı artırıcı role sahip olabilir. Sağlık profesyonellerinin cihazlardan elde edilen verileri, gözlemsel verileri, tedavi verilerini, klinik ve laboratuvar verilerini yapay zekâ tabanlı bir analizden geçirerek karar desteği sunan bir araçtan yardım alması, hasta lehine bir sonuç üretebileceği gibi zaman da kazandırabilir.

Elektronik sağlık kayıt sistemlerinin ödeyici kurumların taleplerine göre şekillendirilmesi, sistemlerdeki iş kurallarının bu yönde geliştirilmesi, bazı durumlarda veri kalitesine olumsuz yansiyabilir. Fatura odaklı sağlık kayıt sistemleri, mevcut verilerden klinik karar

destek sistemlerinin üretilmesinde engelleyici bir etki yaratabilir. Yapılacak çalışmalarda bu faktörün göz önünde bulundurulması ve hatalardan kaçınılması gerekir.

Laboratuvar tetkik verileri sistemde tetkik adı, SUT kodu ve LOINC kodları ile tutulmaktadır. Aynı tetkik birden fazla teknikle çalışılabilmekte, referans değerleri, sonuç değerleri ve ölçüm birimleri hastaneden hastaneye farklılık gösterebilmekte ve bu şekilde gönderilmektedir. Bu, analizi zorlaştıran klasik bir büyük veri sorunu olarak bizim de karşımıza çıkmıştır. İlaç verileri sistemde ilaç etken madde adı, ticari adı, Barkod, QR Kod ve ATC kolları ile tutulmaktadır. Bu nedenle, laboratuvar tetkik verilerinin analizinde olduğu gibi ilaç verilerinin analizinde de güçlüklerle karşılaşmıştır. Bu problemlerin çözümü için tedarikçiler, ödeyici kurumlar, hizmeti sunan ve alan tarafların uygulama birliği sağlamaları, süreç ile birlikte kodlama ve sınıflandırma sistemlerinin standardize edilmesi faydalı olacaktır.

Bu tez çalışması sırasında sağlık tesislerinden veri gönderimi ve e-Nabız veri tabanına alınması sırasındaki iş kuralları gözden geçirilmiş ve bazı ek düzenlemeler yapılmıştır. Veri kalitesinin önemi hakkında tüm paydaşlarda farkındalık yaratmaya yönelik ek tedbirlerin alınması iyi sonuçlar doğurabilir. Türkiye, sağlık sektöründe kurduğu bilişim alt yapısı ile birçok dünya ülkesinin önüne geçmiştir. Bundan sonraki aşamada veri kalitesini artırmaya odaklanılmalı, çok paydaşlı sağlık sorumluluğu yaklaşımı ile bu sorunların üstesinden gelinmelidir. Çünkü bu kadar büyük veritabanlarının bilim camiasına bilgi sağlama yeteneğine sahip olduğuna inanıyoruz. Ancak, düşük veri kalitesi bu tür veritabanlarında önemli bir sorundur. Büyük sistemlerde veri kalitesini ve kapsamını iyileştirmek için sürekli bir çaba harcanmalıdır. Öte yandan DM gibi hastalıkların komplikasyonları on yıllar içinde geliştiği için verilerin standardize edilmiş olarak tutulması hastalık ve komplikasyonlarının oluşturduğu hasarların uzun dönem izlenmesi ve önlemlerin alınması bakımından da önemlidir.

Üzerinde çalıştığımız veri seti boy, kilo, beslenme, fiziksel aktivite, stres düzeyi, sigara tüketimi, alkol tüketimi gibi verileri barındırmadığından, nitelik ve niceliği bakımından yeterli düzeyde veriye erişim mümkün olmadığından MÖ modeli ile ortaya koyabildiğimiz kan şekeri kontrol düzeyi tahmin modeli de aynı oranda kısıtlılıklara ve güvenilirliğe sahiptir. Yaptığımız analiz ve deneyler ışığında bu çalışmanın en önemli

özelliği makine öğrenmesi başarımını artırmak, nitelik ve niceliği yüksek bir veri seti elde etmek için gösterdiğimiz çabalar sonunda bulduğumuz sonuçların, bu alanda yapılmakta ve/veya yapılacak olan diğer araştırmalar için yol gösterici olması olabilir. Araştırma sayısı arttıkça elde edilen sonuçlara olan güvenin de artacağı ve bilişim teknolojilerinin diyabetin takip ve tedavisinde kendisine daha çok yer bulacağı söylenebilir. Giderek artan miktardaki genomik veriler ile birleştğinde bireysel bakım ve tedavi başarısı daha da güçlenecektir.

Elektronik sağlık kayıtlarının, büyük veri ve bilgi teknolojilerinin yardımıyla daha iyi sağlık hizmeti sunmaya yardımcı olma potansiyeline sahip olduğuna inanıyoruz. Sağlıkta veri kalitesinin sürekli iyileştirilmesi, daha fazla bilimsel sorunu çözmek için yüksek hacimli, yüksek kaliteli ve boylamsal verileri analiz etmemize ve sağlık profesyonellerini desteklemek için daha iyi bilgi araçları tasarlamamıza izin verecektir.

Analiz sonuçlarımız, başlangıç HbA1c seviyesinin gelecekteki glisemik kontrolün en önemli belirleyicisi olduğunu göstermektedir. HbA1c 6,9 ve üzerinde ise, kötü glisemik kontrol riski konusunda hekim alarına geçmelidir. Tanı anında düşük HDL, klinik obezite tanısının olmaması, tiroid hastalıklarının olmaması, diyabetik nöropati veya retinopatinin varlığı ve tanının ilk yılındaki yoğun antidiyabetik rejimlerin tümü, daha az önemli olsalar da, gelecekte kötü glisemik kontrolün işaretleridir.

Makine Öğrenmesi çalışmaları bakımından sonuç olarak, XGB glisemik kontrolü tahmin etmek için en iyi yöntemdir ve RO, MLP ve LR'nin buna yakın performansa sahip olduğu bulunmuştur.

KAYNAKLAR

Abadi DJ, Carney D, Cetintemel U, Cherniack M, Convey C, Lee S, et al. Aurora: a new model and architecture for data stream management. the VLDB Journal. 2003;12(2):120-39.

Abhari S, Niakan Kalhori SR, Ebrahimi M, Hasannejadasl H, Garavand A. Artificial Intelligence Applications in Type 2 Diabetes Mellitus Care: Focus on Machine Learning Methods. *hir*. 2019;25(4):248-61.

Abràmoff MD, Lavin PT, Birch M, Shah N, Folk JC. Pivotal trial of an autonomous AI-based diagnostic system for detection of diabetic retinopathy in primary care offices. *NPJ digital medicine*. 2018;1(1):1-8.

Abudawood M. Diabetes and cancer: A comprehensive review. *J Res Med Sci*. 2019;24.

ADA (American Diabetes Association). Screening for diabetes. *Diabetes care*. 2002;25(Supplement 1):S21

ADA (American Diabetes Association). Standards of medical care in diabetes—2015 abridged for primary care providers. *Clinical diabetes: a publication of the American Diabetes Association*. 2015;33(2):97.

ADA (American Diabetes Association). 2. Classification and Diagnosis of Diabetes. *Diabetes Care*. 2016;40(Supplement 1):S11-S24.

ADA (American Diabetes Association). 8. Pharmacologic approaches to glycemic treatment: standards of medical care in diabetes—2018. *Diabetes care*. 2018;41(Supplement 1):S73-S85.

Ahlqvist E, Storm P, Karajamaki A, Martinell M, Dorkhan M, Carlsson A, et al. Novel subgroups of adult-onset diabetes and their association with outcomes: a data-driven cluster analysis of six variables. *Lancet Diabetes & Endocrinology*. 2018;6(5):361-9.

Ahuja AS. The impact of artificial intelligence in medicine on the future role of the physician. *PeerJ*. 2019;7:e7702.

Akhtar M, Taha NM, Nauman A, Mujeeb IB, Al-Nabet ADMH. Diabetic Kidney Disease: Past and Present. *Adv Anat Pathol*. 2020;27(2):87-97.

Al-Sarem M, Saeed F, Alkhamash EH, Alghamdi NS. An Aggregated Mutual Information Based Feature Selection with Machine Learning Methods for Enhancing IoT Botnet Attack Detection. *Sensors-Basel*. 2022;22(1).

Alashqar A, El Ouweini H, Gornet M, Yenokyan G, Borahay MA. Cardiometabolic profile of women with uterine leiomyoma: a cross-sectional study. *Minerva obstetrics and gynecology*.

Ali SM, Giordano R, Lakhani S, Walker DM. A review of randomized controlled trials of medical record powered clinical decision support system to improve quality of diabetes care. *International journal of medical informatics*. 2016;87:91-100.

Alwafi H, Wei L, Naser AY, Mongkhon P, Tse G, Man KK, et al. Trends in oral anticoagulant prescribing in individuals with type 2 diabetes mellitus: a population-based study in the UK. *BMJ open*. 2020;10(5):e034573.

Alyass A, Turcotte M, Meyre D. From big data analysis to personalized medicine for all: challenges and opportunities. *BMC medical genomics*. 2015;8(1):1-12.

Amadou A, Freisling H, Jenab M, Tsilidis KK, Trichopoulou A, Boffetta P, et al. Prevalent diabetes and risk of total, colorectal, prostate and breast cancers in an ageing population: meta-analysis of individual participant data from cohorts of the CHANCES consortium. *Brit J Cancer*. 2021;124(11):1882-90.

Anderson JP, Parikh JR, Shenfeld DK, Ivanov V, Marks C, Church BW, et al. Reverse engineering and evaluation of prediction models for progression to type 2 diabetes: an application of machine learning using electronic health records. *Journal of diabetes science and technology*. 2016;10(1):6-18.

Angehrn Z, Haldna L, Zandvliet AS, Berglund EG, Zeeuw J, Amzal B, et al. Artificial Intelligence and Machine Learning Applied at the Point of Care. *Frontiers in Pharmacology*. 2020;11.

Apovian CM, Okemah J, O'Neil PM. Body Weight Considerations in the Management of Type 2 Diabetes. *Adv Ther*. 2019;36(1):44-58.

Bak JCG, Serne EH, Kramer MHH, Nieuwdorp M, Verheugt CL. National diabetes registries: do they make a difference? *Acta Diabetol*. 2021;58(3):267-78.

Bakırarar, B., Yüksel, C. and Yavuz, Y. (2022), "Prediction of new prescription requirements for diabetes patients using big data technologies", *Journal of Health Research*, Vol. 36 No. 2, pp. 334-344. <https://doi.org/10.1108/JHR-05-2020-0136>

Bakker L, Aarts J, Uyl-de Groot C, Redekop W. Economic evaluations of big data analytics for clinical decision-making: a scoping review. *Journal of the American Medical Informatics Association*. 2020;27(9):1466-75.

Bangalore S, Breazna A, DeMicco DA, Wun C-C, Messerli FH, Committee TS, et al. Visit-to-visit low-density lipoprotein cholesterol variability and risk of cardiovascular outcomes: insights from the TNT trial. *Journal of the American College of Cardiology*. 2015;65(15):1539-48.

Bansal D, Bhansali A, Kapil G, Undela K, Tiwari P. Type 2 diabetes and risk of prostate cancer: a meta-analysis of observational studies. *Prostate Cancer P D*. 2013;16(2):151-8.

Bao CP, Yang XL, Xu WL, Luo HB, Xu ZL, Su C, et al. Diabetes mellitus and incidence and mortality of kidney cancer: A meta-analysis. *J Diabetes Complicat*. 2013;27(4):357-64.

Bar-Or A, Healey J, Kontothanassis L, Van Thong J, editors. *BioStream: a system architecture for real-time processing of physiological signals*. The 26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society; 2004: IEEE.

Bellazzi R, Dagliati A, Sacchi L, Segagni D. Big Data Technologies: New Opportunities for Diabetes Management. *J Diabetes Sci Technol*. 2015;9(5):1119-25.

Ben QW, Xu MJ, Ning XY, Liu J, Hong SY, Huang W, et al. Diabetes mellitus and risk of pancreatic cancer: A meta-analysis of cohort studies. *Eur J Cancer*. 2011;47(13):1928-37.

Berkol A, Karayegen G, Tartan E, Ekici Y, Kara G, Eser Z. A Model for Diabetic Blood Glucose Prediction Based on Electroencephalography Signals Using Deep Learning. *Frontiers in Human Neuroscience*. 2018;12.

Bernardini M, Morettini M, Romeo L, Frontoni E, Burattini L. Early temporal prediction of Type 2 Diabetes Risk Condition from a General Practitioner Electronic Health Record: A Multiple Instance Boosting Approach. *Artificial Intelligence in Medicine*. 2020;105:101847.

Bertram MY, Vos T. Quantifying the duration of pre-diabetes. *Australian and New Zealand journal of public health*. 2010;34(3):311-4.

Biondi B, Kahaly GJ, Robertson RP. Thyroid Dysfunction and Diabetes Mellitus: Two Closely Associated Disorders. *Endocr Rev*. 2019;40(3):789-824.

Bishop CM. Pattern recognition. *Machine learning*. 2006;128(9).

Boulton AJ, Vileikyte L, Ragnarson-Tennvall G, Apelqvist J. The global burden of diabetic foot disease. *The Lancet*. 2005;366(9498):1719-24.

Boye KS, Lage MJ, Thieu V, Shinde S, Dhamija S, Bae JP. Obesity and glycemic control among people with type 2 diabetes in the United States: A retrospective cohort study using insurance claims data. *J Diabetes Complicat*. 2021;35(9).

Bradley PS. Implications of Big Data Analytics on Population Health Management. *Big Data*. 2013;1(3):152-9.

Brill AL, Wisinski JA, Cadena MT, Thompson MF, Fenske RJ, Brar HK, et al. Synergy between Gαz deficiency and GLP-1 analog treatment in preserving functional β-cell mass in experimental diabetes. *Molecular endocrinology*. 2016;30(5):543-56.

Caballero-Ruiz E, García-Sáez G, Rigla M, Villaplana M, Pons B, Hernando ME. A web-based clinical decision support system for gestational diabetes: Automatic diet prescription and detection of insulin needs. *International journal of medical informatics*. 2017;102:35-49.

Cakir AT, Sel G, Balci S, Harma M, Harma MI. Evaluation of HPV, smear and colposcopy results in patients with diabetes. *Diabetes Metab Syndr*. 2022;16(1).

Cantrell RA, Alatorre CI, Davis EJ, Zarotsky V, Le Nestour E, Carter GC, et al. A review of treatment response in type 2 diabetes: assessing the role of patient heterogeneity. *Diabetes, Obesity and Metabolism*. 2010;12(10):845-57.

Carstensen B, Read SH, Friis S, Sund R, Keskimäki I, Svensson A-M, et al. Cancer incidence in persons with type 1 diabetes: a five-country study of 9,000 cancers in type 1 diabetic individuals. *Diabetologia*. 2016;59(5):980-8.

Castillo JJ, Mull N, Reagan JL, Nemr S, Mitri J. Increased incidence of non-Hodgkin lymphoma, leukemia, and myeloma in patients with diabetes mellitus type 2: a meta-analysis of observational studies. *Blood*. 2012;119(21):4845-50.

Casu A, Kanapka LG, Foster NC, Hirsch IB, Laffel LM, Shah VN, et al. Characteristics of adult- compared to childhood-onset type 1 diabetes. *Diabetic Med*. 2020;37(12):2109-15.

Cebioglu M, Schild HH, Golubnitschaja O. Diabetes mellitus as a risk factor for cancer: stress or viral etiology? *Infectious Disorders-Drug Targets (Formerly Current Drug Targets-Infectious Disorders)*. 2008;8(2):76-87.

Cerf ME. Beta cell dysfunction and insulin resistance. *Front Endocrinol*. 2013;4:37.

Chan JC, Malik V, Jia W, Kadowaki T, Yajnik CS, Yoon K-H, et al. Diabetes in Asia: epidemiology, risk factors, and pathophysiology. *Jama*. 2009;301(20):2129-40.

Chang C-M, Hsieh C-J, Huang J-C, Huang I-C. Acute and chronic fluctuations in blood glucose levels can increase oxidative stress in type 2 diabetes mellitus. *Acta Diabetol*. 2012;49(1):171-7.

Chauhan S, Kerr A, Keogh B, Nolan S, Casey R, Adelfio A, et al. An Artificial-Intelligence-Discovered Functional Ingredient, NRT_N0G5IJ, Derived from *Pisum sativum*, Decreases HbA1c in a Prediabetic Population. *Nutrients*. 2021;13(5):1635.

Chen R-C, Jiang HQ, Huang C-Y, Bau C-T. Clinical Decision Support System for Diabetes Based on Ontology Reasoning and TOPSIS Analysis. *Journal of Healthcare Engineering*. 2017;2017:4307508.

Chen T, Guestrin C, editors. Xgboost: A scalable tree boosting system. *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*; 2016.

Chen Y, Wu F, Saito E, Lin YS, Song M, Luu HN, et al. Association between type 2 diabetes and risk of cancer mortality: a pooled analysis of over 771,000 individuals in the Asia Cohort Consortium. *Diabetologia*. 2017;60(6):1022-32.

Cichosz SL, Johansen MD, Hejlesen O. Toward big data analytics: review of predictive models in management of diabetes and its complications. *Journal of diabetes science and technology*. 2016;10(1):27-34.

Cleveringa FG, Gorter KJ, Van Den Donk M, Rutten GE. Combined task delegation, computerized decision support, and feedback improve cardiovascular risk for type 2 diabetic patients: a cluster randomized trial in primary care. *Diabetes care*. 2008;31(12):2273-5.

Contreras I, Vehi J. Artificial Intelligence for Diabetes Management and Decision Support: Literature Review. *Journal of Medical Internet Research*. 2018;20(5).

Control CfD, Prevention. Self-reported prediabetes and risk-reduction activities--United States, 2006. *MMWR Morbidity and mortality weekly report*. 2008;57(44):1203-5.

Costantino S, Paneni F, Battista R, Castello L, Capretti G, Chiandotto S, et al. Impact of glycemic variability on chromatin remodeling, oxidative stress, and endothelial dysfunction in patients with type 2 diabetes and with target HbA1c levels. *Diabetes*. 2017;66(9):2472-82.

Currie CJ, Peters JR, Tynan A, Evans M, Heine RJ, Bracco OL, et al. Survival as a function of HbA1c in people with type 2 diabetes: a retrospective cohort study. *The Lancet*. 2010;375(9713):481-9.

Dagliati A, Marini S, Sacchi L, Cogni G, Teliti M, Tibollo V, et al. Machine Learning Methods to Predict Diabetes Complications. *J Diabetes Sci Technol*. 2018;12(2):295-302.

Dankwa-Mullan I, Rivo M, Sepulveda M, Park Y, Snowdon J, Rhee K. Transforming diabetes care through artificial intelligence: the future is here. *Population health management*. 2019;22(3):229-42.

de Boer IH, Rue TC, Hall YN, Heagerty PJ, Weiss NS, Himmelfarb J. Temporal trends in the prevalence of diabetic kidney disease in the United States. *Jama*. 2011;305(24):2532-9.

Debray J, Chrétien J, Gueniot M, Hardouin J, Himbert J, Pichot P, et al., editors. A new concept of preventive medicine using automatic data processing by computer. II. Application to diseases and risks of the digestive apparatus and to cardiovascular diseases and risks. *Annales de medecine interne*; 1969.

Del Parigi A, Tang W, Liu D, Lee C, Pratley R. Machine Learning to Identify Predictors of Glycemic Control in Type 2 Diabetes: An Analysis of Target HbA1c Reduction Using Empagliflozin/Linagliptin Data. *Pharmaceutical Medicine*. 2019;33(3):209-17.

Dixon BE, Alzeer AH, Phillips EOK, Marrero DG. Integration of Provider, Pharmacy, and Patient-Reported Data to Improve Medication Adherence for Type 2 Diabetes: A Controlled Before-After Pilot Study. *JMIR Med Inform*. 2016;4(1):e4.

Driskell OJ, Holland D, Hanna FW, Jones PW, Pemberton RJ, Tran M, et al. Inappropriate requesting of glycated hemoglobin (Hb A1c) is widespread: assessment of prevalence, impact of national guidance, and practice-to-practice variability. *Clinical chemistry*. 2012;58(5):906-15.

Eddy DM, Schlessinger L. Archimedes: a trial-validated model of diabetes. *Diabetes care*. 2003;26(11):3093-101.

El-Serag HB, Hampel H, Javadi F. The association between diabetes and hepatocellular carcinoma: A systematic review of epidemiologic evidence. *Clin Gastroenterol H*. 2006;4(3):369-80.

Elgazar EH, Esheba NE, Shalaby SA, Mohamed WF. Thyroid dysfunction prevalence and relation to glycemic control in patients with type 2 diabetes mellitus. *Diabetes Metab Syndr*. 2019;13(4):2513-7.

Ellahham S. Artificial Intelligence: The Future for Diabetes Care. *American Journal of Medicine*. 2020;133(8):895-900.

Emani CK, Cullot N, Nicolle C. Understandable Big Data: A survey. *Comput Sci Rev*. 2015;17:70-81.

Erickson SC, Le L, Zakharyan A, Stockl KM, Harada AS, Borson S, et al. New-onset treatment-dependent diabetes mellitus and hyperlipidemia associated with atypical antipsychotic use in older adults without schizophrenia or bipolar disorder. *Journal of the American Geriatrics Society*. 2012;60(3):474-9.

Fong S, Mohammed S, Fiaidhi J, Kwoh CK. Using causality modeling and Fuzzy Lattice Reasoning algorithm for predicting blood glucose. *Expert systems with applications*. 2013;40(18):7354-66.

Fong S, Zhang Y, Fiaidhi J, Mohammed O, Mohammed S. Evaluation of Stream Mining Classifiers for Real-Time Clinical Decision Support System: A Case Study of Blood Glucose Prediction in Diabetes Therapy. *BioMed Research International*. 2013;2013:274193.

Forlenza GP, Pinhas-Hamiel O, Liljenquist DR, Shulman DI, Bailey TS, Bode BW, et al. Safety evaluation of the MiniMed 670G system in children 7–13 years of age with type 1 diabetes. *Diabetes technology & therapeutics*. 2019;21(1):11-9.

Friberg E, Orsini N, Mantzoros CS, Wolk A. Diabetes mellitus and risk of endometrial cancer: a meta-analysis. *Diabetologia*. 2007;50(7):1365-74.

Garg SK, Rewers AH, Akturk HK. Ever-increasing insulin-requiring patients globally. Mary Ann Liebert, Inc. 140 Huguenot Street, 3rd Floor New Rochelle, NY 10801 USA; 2018. p. S2-1-S2-4.

Garg SK, Weinzimer SA, Tamborlane WV, Buckingham BA, Bode BW, Bailey TS, et al. Glucose outcomes with the in-home use of a hybrid closed-loop insulin delivery system in adolescents and adults with type 1 diabetes. *Diabetes technology & therapeutics*. 2017;19(3):155-63.

Ge ZM, Ben QW, Qian JB, Wang YM, Li YM. Diabetes mellitus and risk of gastric cancer: a systematic review and meta-analysis of observational studies. *Eur J Gastroen Hepat*. 2011;23(12):1127-35.

Georga, Eleni I. et al. “Data mining for blood glucose prediction and knowledge discovery in diabetic patients: The METABO diabetes modeling and management system.” 2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society (2009): 5633-5636.

Ghoddusi Johari M, Dabaghmanesh MH, Zare H, Safaeian AR, Abdollahifard G. Smart Diabetic Screening and Managing Software, A Novel Decision Support System. *Journal of biomedical physics & engineering*. 2018;8(3):289-304.

Goecks J, Jalili V, Heiser LM, Gray JW. How Machine Learning Will Transform Biomedicine. *Cell*. 2020;181(1):92-101.

Gonder-Frederick L, Zrebiec J, Bauchowitz A, Lee J, Cox D, Ritterband L, et al. Detection of hypoglycemia by children with type 1 diabetes 6 to 11 years of age and their parents: a field study. *Pediatrics*. 2008;121(3):e489-e95.

Gubbi S, Hamet P, Tremblay J, Koch CA, Hannah-Shmouni F. Artificial Intelligence and Machine Learning in Endocrinology and Metabolism: The Dawn of a New Era. *Front Endocrinol.* 2019;10(185).

Guerrero-Romero F, Simental-Mendía LE, González-Ortiz M, Martínez-Abundis E, Ramos-Zavala MG, Hernández-González SO, et al. The product of triglycerides and glucose, a simple measure of insulin sensitivity. Comparison with the euglycemic-hyperinsulinemic clamp. *The Journal of Clinical Endocrinology & Metabolism.* 2010;95(7):3347-51.

Guzman Gómez GE, Burbano Agredo LE, Martínez V, Bedoya Leiva OF. Application of Artificial Intelligence Techniques for the Estimation of Basal Insulin in Patients with Type I Diabetes. *International Journal of Endocrinology.* 2020;2020:7326073.

Hamet P, Tremblay J. Artificial intelligence in medicine. *Metabolism.* 2017;69:S36-S40.

Haneef R, Fuentes S, Fosse-Edorh S, Kab S, Cosson E, Gallay A. Use of Artificial Intelligence for Public Health Surveillance: A case study to develop a Machine Learning-algorithm to estimate the incidence of Diabetes Mellitus in France. 2021.

Hang Y, Fong S, editors. An experimental comparison of decision trees in traditional data mining and data stream mining. 2010 6th International Conference on Advanced Information Management and Service (IMS); 2010: IEEE.

Harris MI, Eastman RC. Early detection of undiagnosed diabetes mellitus: a US perspective. *Diabetes/metabolism research and reviews.* 2000;16(4):230-6.

Harrison C. 'Big data' deal for diabetes clinical trial modelling DEAL WATCH. *Nature Reviews Drug Discovery.* 2012;11(11).

Heald AH, Livingston M, Malipatil N, Becher M, Craig J, Stedman M, et al. Improving type 2 diabetes mellitus glycaemic outcomes is possible without spending more on medication: Lessons from the UK National Diabetes Audit. *Diabetes Obesity & Metabolism.* 2018;20(1):185-94.

Holbrook A, Thabane L, Keshavjee K, Dolovich L, Bernstein B, Chan D, et al. Individualized electronic decision support and reminders to improve diabetes care in the community: COMPETE II randomized trial. *Cmaj*. 2009;181(1-2):37-44.

Hosseini MM, Zargoush M, Alemi F, Kheirbek RE. Leveraging machine learning and big data for optimizing medication prescriptions in complex diseases: a case study in diabetes management. *Journal of Big Data*. 2020;7(1):26.

<https://www.kaggle.com>. Pima Indians Diabetes Database (PIDD). In: <https://www.kaggle.com>, editor. 2016.

Huang ES, Brown SE, Ewigman BG, Foley EC, Meltzer DO. Patient perceptions of quality of life with diabetes-related complications and treatments. *Diabetes care*. 2007;30(10):2478-83.

Huang G, Huang G-B, Song S, You K. Trends in extreme learning machines: A review. *Neural Networks*. 2015;61:32-48.

Huang G-B, Wang DH, Lan Y. Extreme learning machines: a survey. *International journal of machine learning and cybernetics*. 2011;2(2):107-22.

Huang W, Ren HB, Ben QW, Cai QC, Zhu W, Li ZS. Risk of esophageal cancer in diabetes mellitus: a meta-analysis of observational studies. *Cancer Cause Control*. 2012;23(2):263-72.

Hung AM, Roumie CL, Greevy RA, Liu X, Grijalva CG, Murff HJ, et al. Kidney function decline in metformin versus sulfonylurea initiators: assessment of time-dependent contribution of weight, blood pressure, and glycemic control. *Pharmacoepidemiology and drug safety*. 2013;22(6):623-31.

Hunt J, Siemieniczuk J, Gillanders W, LeBlanc B, Rozenfeld Y, Bonin K, et al. The impact of a physician-directed health information technology system on diabetes outcomes in primary care: a pre-and post-implementation study. *Journal of Innovation in Health Informatics*. 2009;17(3):165-74.

Huxley R, Ansary-Moghaddam A, de Gonzalez AB, Barzi F, Woodward M. Type-II diabetes and pancreatic cancer: a meta-analysis of 36 studies. *Brit J Cancer*. 2005;92(11):2076-83.

Iancu I, Mota M, Iancu E, editors. Method for the analysing of blood glucose dynamics in diabetes mellitus patients. 2008 IEEE international conference on automation, quality and testing, robotics; 2008: IEEE.

IDF (International Diabetes Federation). Guideline for management of postmeal glucose in diabetes. *Diabetes research and clinical practice*. 2014;103(2):256-68.

Indu R, Adhikari A, Maisnam I, Basak P, Sur TK, Das AK. Polypharmacy and comorbidity status in the treatment of type 2 diabetic patients attending a tertiary care hospital: An observational and questionnaire-based study. *Perspect Clin Res*. 2018;9(3):139-44.

Ishwaran H, Kogalur UB, Blackstone EH, Lauer MS. Random survival forests. *The annals of applied statistics*. 2008;2(3):841-60.

Ismail-Beigi F, Moghissi E, Tiktin M, Hirsch IB, Inzucchi SE, Genuth S. Individualizing glycemic targets in type 2 diabetes mellitus: implications of recent clinical trials. *Annals of internal medicine*. 2011;154(8):554-9.

Itoh H, Hayashi K, Miyashita K. Pre-emptive medicine for hypertension and its prospects. *Hypertens Res*. 2019;42(3):301-5.

Jacobson AM, Braffett BH, Cleary PA, Gubitosi-Klug RA, Larkin ME, group DEr. The long-term effects of type 1 diabetes treatment and complications on health-related quality of life: a 23-year follow-up of the Diabetes Control and Complications/Epidemiology of Diabetes Interventions and Complications cohort. *Diabetes care*. 2013;36(10):3131-8.

Jiang Y, Ben QW, Shen H, Lu WQ, Zhang Y, Zhu J. Diabetes mellitus and incidence and mortality of colorectal cancer: a systematic review and meta-analysis of cohort studies. *Eur J Epidemiol*. 2011;26(11):863-76.

Jing W, Jin G, Zhou XY, Zhou YQ, Zhang YJ, Shao CH, et al. Diabetes mellitus and increased risk of cholangiocarcinoma: a meta-analysis. *Eur J Cancer Prev.* 2012;21(1):24-31.

Kahn M. Diabetes Data Set. Online: <https://archive.ics.uci.edu/ml/>; 1994.

Kauhl BS, J. Krafft, T. Keste, A. Moskwyn, M.. Do the risk factors for type 2 diabetes mellitus vary by location? A spatial analysis of health insurance claims in Northeastern Germany using kernel density estimation and geographically weighted regression. *International Journal of Health Geographics.* 2016;15(1).

Kaur R. Predicting Diabetes by adopting Classification Approach in Data Mining. *JOIV: International Journal on Informatics Visualization.* 2019;3(2-2).

Kavakiotis I, Tsave O, Salifoglou A, Maglaveras N, Vlahavas I, Chouvarda I. Machine Learning and Data Mining Methods in Diabetes Research. *Computational and Structural Biotechnology Journal.* 2017;15:104-16.

Ke CV, Stukel TA, Luk A, Shah BJR, Jha P, Lau E, et al. Development and validation of algorithms to classify type 1 and 2 diabetes according to age at diagnosis using electronic health records. *Bmc Med Res Methodol.* 2020;20(1).

Kengne AP, Beulens JW, Peelen LM, Moons KG, van der Schouw YT, Schulze MB, et al. Non-invasive risk scores for prediction of type 2 diabetes (EPIC-InterAct): a validation of existing models. *The lancet Diabetes & endocrinology.* 2014;2(1):19-29.

Khan A, Petropoulos IN, Ponirakis G, Malik RA. Visual complications in diabetes mellitus: beyond retinopathy. *Diabetic Med.* 2017;34(4):478-84.

Kim D-J. Summary of the American diabetes association standards of medical care in diabetes 2012. *The Journal of Korean Diabetes.* 2012;13(1):7-14.

Kim SM, Lee G, Choi S, Kim K, Jeong SM, Son JS, et al. Association of early-onset diabetes, prediabetes and early glycaemic recovery with the risk of all-cause and cardiovascular mortality. *Diabetologia.* 2020;63(11):2305-14.

Kim YT, Chung HJ, Park BR, Kim YY, Lee JH, Kang DR, et al. Risk of Cardiovascular Disease and Chronic Kidney Disease According to 2017 Blood Pressure Categories in Diabetes Mellitus. *Hypertension*. 2020;76(3):766-75.

Kingma DP, Ba J. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*. 2014.

Koren G, Nordon G, Radinsky K, Shalev V. Identification of repurposable drugs with beneficial effects on glucose control in type 2 diabetes using machine learning. *Pharmacology Research & Perspectives*. 2019;7(6).

Krentz AJ, Bailey CJ. Oral antidiabetic agents - Current role in type 2 diabetes mellitus. *Drugs*. 2005;65(3):385-411.

Kulikowski CA, Weiss SM. Representation of expert knowledge for consultation: the CASNET and EXPERT projects: Routledge; 2019.

Kumar PS, Pranavi S, editors. Performance analysis of machine learning algorithms on diabetes dataset using big data analytics. 2017 International Conference on Infocom Technologies and Unmanned Systems (Trends and Future Directions) (ICTUS); 2017 18-20 Dec. 2017.

Larsson SC, Mantzoros CS, Wolk A. Diabetes mellitus and risk of breast cancer: A meta-analysis. *Int J Cancer*. 2007;121(4):856-62.

Larsson SC, Orsini N, Brismar K, Wolk A. Diabetes mellitus and risk of bladder cancer: a meta-analysis. *Diabetologia*. 2006;49(12):2819-23.

Larsson SC, Orsini N, Wolk A. Diabetes mellitus and risk of colorectal cancer: A meta-analysis. *J Clin Oncol*. 2005;23(22):4679-87.

Leahy JL, Aleppo G, Fonseca VA, Garg SK, Hirsch IB, McCall AL, et al. Optimizing Postprandial Glucose Management in Adults With Insulin-Requiring Diabetes: Report and Recommendations. *Journal of the Endocrine Society*. 2019;3(10):1942-57.

Lee EY, Lee YH, Yi SW, Shin SA, Yi JJ. BMI and All-Cause Mortality in Normoglycemia, Impaired Fasting Glucose, Newly Diagnosed Diabetes, and Prevalent Diabetes: A Cohort Study. *Diabetes Care*. 2017;40(8):1026-33.

Lee JY, Jeon I, Kim JW, Song YS, Yoon JM, Park SM. Diabetes Mellitus and Ovarian Cancer Risk A Systematic Review and Meta-Analysis of Observational Studies. *Int J Gynecol Cancer*. 2013;23(3):402-12.

Lee S, Ybarra N, Jeyaseelan K, Faria S, Kopek N, Brisebois P, et al. Bayesian network ensemble as a multivariate strategy to predict radiation pneumonitis risk. *Medical Physics*. 2015;42(5):2421-30.

Lee S, Zhou J, Wong WT, Liu T, Wu WKK, Wong ICK, et al. Glycemic and lipid variability for predicting complications and mortality in diabetes mellitus using machine learning. *BMC Endocrine Disorders*. 2021;21(1):94.

Lee SJ, Stijacic-Cenzer I, Barnhart C, McClymont K, Steinman MA. Changing patterns of glucose-lowering medication use in VA nursing home residents with diabetes, 2005 to 2011. *Journal of the American Medical Directors Association*. 2015;16(10):898. e9-. e14.

Lehmann ED, Chatu SS, Hashmy SH. Retrospective pilot feedback survey of 200 users of the AIDA version 4 educational diabetes program. 2—Qualitative feedback data. *Diabetes Technology & Therapeutics*. 2006;8(5):602-8.

Li H, Luo M, Zheng J, Luo J, Zeng R, Feng N, et al. An artificial neural network prediction model of congenital heart disease based on risk factors: a hospital-based case-control study. *Medicine*. 2017;96(6).

Li HT, Qian J. Association of diabetes mellitus with thyroid cancer risk A meta-analysis of cohort studies. *Medicine*. 2017;96(47).

Li J, Huang J, Zheng L, Li X. Application of Artificial Intelligence in Diabetes Education and Management: Present Status and Promising Prospect. *Frontiers in public health*. 2020;8:173-.

Lian C, Li H, Denoeux T, Chen H, Robinson C, Vera P, et al. Cancer Therapy Outcome Prediction Based On Dempster-Shafer Theory and PET Imaging. *Medical Physics*. 2015;42(6):3549-.

Lin C, Singh H, Kar R, Raza U. What are Predictors of Medication Change and Hospital Readmission in Diabetic Patients? : Berkeley; 2018.

Lindblad P, Chow WH, Chan J, Bergstrom A, Wolk A, Gridley G, et al. The role of diabetes mellitus in the aetiology of renal cell cancer. *Diabetologia*. 1999;42(1):107-12.

Lindström J, Tuomilehto J. The diabetes risk score: a practical tool to predict type 2 diabetes risk. *Diabetes care*. 2003;26(3):725-31.

Ling SH, San PP, Nguyen HT. Non-invasive hypoglycemia monitoring system using extreme learning machine for Type 1 diabetes. *ISA Transactions*. 2016;64:440-6.

Loh TP, Tan KML, Saw S, Sethi SK. Glycated haemoglobin: what is the diagnostic yield at shortened testing intervals? *Diabetes research and clinical practice*. 2011;94(2):e40-e2.

Lv ZQ, Guo YJ. Metformin and Its Benefits for Various Diseases. *Front Endocrinol*. 2020;11.

Maguire J, V. Dhar. Comparative effectiveness for oral anti-diabetic treatments among newly diagnosed type 2 diabetics: Data-driven predictive analytics in healthcare. *Health Systems*. 2013;2:73-92.

Maher RL, Hanlon J, Hajjar ER. Clinical consequences of polypharmacy in elderly. *Expert opinion on drug safety*. 2014;13(1):57-65.

Maia JX, de Sousa LAP, Marcolino MS, Cardoso CS, da Silva JLP, Alkmim MBM, et al. The impact of a clinical decision support system in diabetes primary care patients in a developing country. *Diabetes technology & therapeutics*. 2016;18(4):258-63.

Makaram P, Owens D, Aceros J. Trends in nanomaterial-based non-invasive diabetes sensing technologies. *Diagnostics*. 2014;4(2):27-46.

Makino M, Yoshimoto R, Ono M, Itoko T, Katsuki T, Koseki A, et al. Artificial intelligence predicts the progression of diabetic kidney disease using big data machine learning. *Scientific Reports*. 2019;9.

Marr B. The 5 V's of Big Data Internet. *Data Science Central*. 2015.

Mercaldo F, Nardone V, Santone A. Diabetes Mellitus Affected Patients Classification and Diagnosis through Machine Learning Techniques. *Knowledge-Based and Intelligent Information & Engineering Systems*. 2017;112:2519-28.

Miao ZF, Xu H, Xu YY, Wang ZN, Zhao TT, Song YX, et al. Diabetes mellitus and the risk of gastric cancer: a meta-analysis of cohort studies. *Oncotarget*. 2017;8(27):44881-92.

Miller KM, Xing D, Tamborlane WV, Bergenstal RM, Beck RW. Challenges and future directions of the T1D Exchange Clinic Network and registry. *J Diabetes Sci Technol*. 2013;7(4):963-9.

Morris JA, Gardner MJ. Calculating Confidence-Intervals for Relative Risks (Odds Ratios) and Standardized Ratios and Rates. *Brit Med J*. 1988;296(6632):1313-6.

Nagaraj SB, Sidorenkov G, van Boven JFM, Denig P. Predicting short- and long-term glycated haemoglobin response after insulin initiation in patients with type 2 diabetes mellitus using machine-learning algorithms. *Diabetes, Obesity and Metabolism*. 2019;21(12):2704-11.

Navarro-González D, Sánchez-Íñigo L, Pastrana-Delgado J, Fernández-Montero A, Martinez JA. Triglyceride–glucose index (TyG index) in comparison with fasting plasma glucose improved diabetes prediction in patients with normal fasting glucose: The Vascular-Metabolic CUN cohort. *Preventive medicine*. 2016;86:99-105.

Newell A, Simon HA. Current developments in complex information processing: Rand Corporation; 1956.

Nguyen HT, Ghevondian N, Nguyen ST, Jones TW, editors. Detection of hypoglycemic episodes in children with type 1 diabetes using an optimal Bayesian neural network algorithm. 2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society; 2007: IEEE.

Nimri R, Battelino T, Laffel LM, Slover RH, Schatz D, Weinzimer SA, et al. Insulin dose optimization using an automated artificial intelligence-based decision support system in youths with type 1 diabetes. *Nature medicine*. 2020;26(9):1380-4.

Ninomiya T, Perkovic V, De Galan BE, Zoungas S, Pillai A, Jardine M, et al. Albuminuria and kidney function independently predict cardiovascular and renal outcomes in diabetes. *Journal of the American Society of Nephrology*. 2009;20(8):1813-21.

Noble D, Mathur R, Dent T, Meads C, Greenhalgh T. Risk models and scores for type 2 diabetes: systematic review. *Bmj*. 2011;343.

O'Neill KN, McHugh SM, Tracey ML, Fitzgerald AP, Kearney PM. Health service utilization and related costs attributable to diabetes. *Diabetic Med*. 2018;35(12):1727-34.

O'Connor PJ, Sperl-Hillen JM, Rush WA, Johnson PE, Amundson GH, Asche SE, et al. Impact of electronic health record clinical decision support on diabetes care: a randomized trial. *The Annals of Family Medicine*. 2011;9(1):12-21.

O'Keefe DT, Maraka S, Rizza RA. HbA1c in the Evaluation of Diabetes Mellitus. *JAMA*. 2016;315(6):605-6.

Ogurtsova K, Fernandes JDD, Cavan D, Makaroff LE, Grp IA. Global Estimates of Undiagnosed Diabetes in Adults for the 2015 IDF Diabetes Atlas: A Revision of the Methodology. *Diabetes*. 2016;65:A405-A.

Olivera AR, Roesler V, Iochpe C, Schmidt MI, Vigo Á, Barreto SM, et al. Comparison of machine-learning algorithms to build a predictive model for detecting undiagnosed diabetes-ELSA-Brasil: accuracy study. *Sao Paulo Medical Journal*. 2017;135:234-46.

Pedersen SP, Hejlesen OK, Cavan D. DiasNet: a diabetes advisory system for communication and education via the internet. *IMIA Yearbook of Medical Informatics* 2003: Quality of Health Care: The Role of Informatics: Schattauer; 2003. p. 607-18.

Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B, Grisel O, et al. Scikit-learn: Machine Learning in Python. *J Mach Learn Res*. 2011;12:2825-30.

Peker M, Sasar A, Ozkaraca O, Akcay G. Estimation of HbA1c value using artificial neural networks. *Global Journal of Computer Sciences: Theory and Research*. 2017;7(1):1-7.

Petersmann A, Muller-Wieland D, Muller UA, Landgraf R, Nauck M, Freckmann G, et al. Definition, Classification and Diagnosis of Diabetes Mellitus. *Exp Clin Endocrinol Diabetes*. 2019;127(S 01):S1-S7.

Porumb M, Stranges S, Pescape A, Pecchia L. Precision Medicine and Artificial Intelligence: A Pilot Study on Deep Learning for Hypoglycemic Events Detection based on ECG. *Scientific Reports*. 2020;10(1).

Qi L, Qi XL, Xiong HY, Liu Q, Li JX, Zhang Y, et al. Type 2 Diabetes Mellitus and Risk of Malignant Melanoma: A Systematic Review and Meta-Analysis of Cohort Studies. *Iran J Public Health*. 2014;43(7):857-66.

Rajkomar A, Dean J, Kohane I. Machine learning in medicine. *New England Journal of Medicine*. 2019;380(14):1347-58.

Rajput DS, Basha SM, Xin Q, Gadekallu TR, Kaluri R, Lakshmana K, et al. Providing diagnosis on diabetes using cloud computing environment to the people living in rural areas of India. *Journal of Ambient Intelligence and Humanized Computing*. 2021.

Ramos-Garcia P, Roca-Rodriguez MD, Aguilar-Diosdado M, Gonzalez-Moles MA. Diabetes mellitus and oral cancer/oral potentially malignant disorders: A systematic review and meta-analysis. *Oral Dis*. 2021;27(3):404-21.

Razavian N, Blecker S, Schmidt AM, Smith-McLallen A, Nigam S, Sontag D. Population-Level Prediction of Type 2 Diabetes From Claims Data and Analysis of Risk Factors. *Big Data*. 2015;3(4):277-87.

Riazi H, Larijani B, Langarizadeh M, Shahmoradi L. Managing diabetes mellitus using information technology: a systematic review. *Journal of Diabetes & Metabolic Disorders*. 2015;14(1):1-9.

Riddle MC. Basal glucose can be controlled, but the prandial problem persists—it's the next target! *Diabetes Care*. 2017;40(3):291-300.

Rigla M, Garcia-Saez G, Pons B, Hernando ME. Artificial Intelligence Methodologies and Their Application to Diabetes. *J Diabetes Sci Technol*. 2018;12(2):303-10.

Rish I, editor An empirical study of the naive Bayes classifier. *IJCAI 2001 workshop on empirical methods in artificial intelligence*; 2001.

Robertson G, Lehmann ED, Sandham W, Hamilton D. Blood glucose prediction using artificial neural networks trained with the AIDA diabetes simulator: a proof-of-concept pilot study. *Journal of Electrical and Computer Engineering*. 2011;2011.

Rodríguez-Rodríguez I, Chatzigiannakis I, Rodríguez J-V, Maranghi M, Gentili M, Zamora-Izquierdo M-Á. Utility of big data in predicting short-term blood glucose levels in type 1 diabetes mellitus through machine learning techniques. *Sensors-Basel*. 2019;19(20):4482.

Roever L, Tse G, Biondi-Zoccai G. Variability of metabolic parameters and risk of heart failure: Can it be a marker of incident heart failure? *International journal of cardiology*. 2019;293:183-4.

Romero-Aroca P, Valls A, Moreno A, Sagarra-Alamo R, Basora-Gallisa J, Saleh E, et al. A Clinical Decision Support System for Diabetic Retinopathy Screening: Creating a Clinical Support Application. *Telemedicine and e-Health*. 2018;25(1):31-40.

Rothstein MA. Ethical issues in big data health research: Currents in contemporary bioethics. *Journal of Law, Medicine & Ethics*. 2015;43(2):425-9.

Ruan Y, Bellot A, Moysova Z, Tan GD, Lumb A, Davies J, et al. Predicting the Risk of Inpatient Hypoglycemia With Machine Learning Using Electronic Health Records. *Diabetes Care*. 2020;43(7):1504-11.

Rumbold JMM, O'Kane M, Philip N, Pierscioneck BK. Big Data and diabetes: the applications of Big Data for diabetes care now and in the future. *Diabet Med*. 2020;37(2):187-93.

Rumbold JMM, Pierscioneck B. The effect of the general data protection regulation on medical research. *Journal of medical Internet research*. 2017;19(2):e47.

Rutscher A, Salzsieder E, Thierbach U, Fischer U, Albrecht G. KADIS—a computer-aided decision support system for improving the management of type-I diabetes. *Exp Clin Endocr Diab*. 1990;95(01):137-47.

Saeedi P, Petersohn I, Salpea P, Malanda B, Karuranga S, Unwin N, et al. Global and regional diabetes prevalence estimates for 2019 and projections for 2030 and 2045: Results from the International Diabetes Federation Diabetes Atlas. *Diabetes research and clinical practice*. 2019;157:107843.

Sağlık Bakanlığı. Türkiye Sağlık Bilgi Sistemi Eylem Planı. 2004. <https://sbu.saglik.gov.tr/Ekutuphane/kitaplar/SDPturk.pdf>, Erişim Tarihi: 30.09.2021

Salzsieder E, Vogt L, Kohnert KD, Heinke P, Augstein P. Model-based Decision support in Diabetes Care. *Computer Methods and Programs in Biomedicine*. 2011;102(2):206-18.

San PP, Ling SH, Nguyen HT, editors. Deep learning framework for detection of hypoglycemic episodes in children with type 1 diabetes. 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC); 2016 16-20 Aug. 2016.

Schmid D, Behrens G, Jochem C, Keimling M, Leitzmann M. Physical activity, diabetes, and risk of thyroid cancer: a systematic review and meta-analysis. *Eur J Epidemiol*. 2013;28(12):945-58.

Schmidt AM. Highlighting Diabetes Mellitus: The Epidemic Continues. *Arteriosclerosis Thrombosis and Vascular Biology*. 2018;38(1):E1-E8.

Selvi RT, Muthulakshmi I. Modelling the map reduce based optimal gradient boosted tree classification algorithm for diabetes mellitus diagnosis system. *Journal of Ambient Intelligence and Humanized Computing*. 2021;12(2):1717-30.

Seyhan AA, Carini C. Are innovation and new technologies in precision medicine paving a new era in patients centric care? *Journal of translational medicine*. 2019;17(1):1-28.

Shah AD, Langenberg C, Rapsomaniki E, Denaxas S, Pujades-Rodriguez M, Gale CP, et al. Type 2 diabetes and incidence of cardiovascular diseases: a cohort study in 1·9 million people. *The lancet Diabetes & endocrinology*. 2015;3(2):105-13.

Shah BR, Lipscombe LL, Booth GL. Glycemic Control Among People With Diabetes in Ontario: A Population-Based Cross-Sectional Study. *Can J Diabetes*. 2021;45(4):313-8.

Shah VN, Laffel LM, Wadwa RP, Garg SK. Performance of a factory-calibrated real-time continuous glucose monitoring system utilizing an automated sensor applicator. *Diabetes technology & therapeutics*. 2018;20(6):428-33.

Shaw JE, Sicree RA, Zimmet PZ. Global estimates of the prevalence of diabetes for 2010 and 2030. *Diabetes research and clinical practice*. 2010;87(1):4-14.

Shi H-l, Luo S-q. MR image denoising based on nearly shift-insensitive and nonredundancy discrete wavelet transform. *Chinese Journal of Tissue Engineering Research*. 2010;14(52):9739.

Shortliffe EH, editor *Mycin: A knowledge-based computer program applied to infectious diseases*. Proceedings of the Annual Symposium on Computer Application in Medical Care; 1977: American Medical Informatics Association.

Sim LLW, Ban KHK, Tan TW, Sethi SK, Loh TP. Development of a clinical decision support system for diabetes care: A pilot study. *PloS one*. 2017;12(2):e0173021.

Siriwardena LN, Wickramasinghe WS, Perera KD, Marasinghe RB, Katulanda P, Hewapathirana R. A review of telemedicine interventions in diabetes care. *Journal of telemedicine and telecare*. 2012;18(3):164-8.

Sneha N, Gangil T. Analysis of diabetes mellitus for early prediction using optimal features selection. *Journal of Big data*. 2019;6(1):1-19.

Sohn M, Talbert J, Blumenschein K, Moga DC. Atypical antipsychotic initiation and the risk of type II diabetes in children and adolescents. *Pharmacoepidemiology and drug safety*. 2015;24(6):583-91.

Song X, Waitman LR, Yu ASL, Robbins DC, Hu Y, Liu M. Longitudinal Risk Prediction of Chronic Kidney Disease in Diabetic Patients Using a Temporal-Enhanced Gradient Boosting Machine: Retrospective Cohort Study. *Jmir Medical Informatics*. 2020;8(1):95-113.

Spänig S, Emberger-Klein A, Sowa J-P, Canbay A, Menrad K, Heider D. The virtual doctor: An interactive clinical-decision-support system based on deep learning for non-invasive prediction of diabetes. *Artificial intelligence in medicine*. 2019;100:101706.

Sparring V, Nystrom L, Ostman J, Wahlstrom R, Burstrom K, Jonsson PM. Changing healthcare utilization patterns in diabetes mellitus: case-control studies 1 year and 8 years after diagnosis. *Diabetic Med*. 2012;29(6):784-91.

Spratt SE, Pereira K, Granger BB, Batch BC, Phelan M, Pencina M, et al. Assessing electronic health record phenotypes against gold-standard diagnostic criteria for diabetes mellitus. *Journal of the American Medical Informatics Association*. 2017;24(E1):E121-E8.

Srivastava SP, Goodwin JE. Cancer Biology and Prevention in Diabetes. *Cells-Basel*. 2020;9(6).

Stephens TN, Joerin A, Rauws M, Werk LN. Feasibility of pediatric obesity and prediabetes treatment support through Tess, the AI behavioral coaching chatbot. *Translational behavioral medicine*. 2019;9(3):440-7.

Stevens RJ, Roddam AW, Beral V. Pancreatic cancer in type 1 and young-onset diabetes: systematic review and meta-analysis. *Brit J Cancer*. 2007;96(3):507-9.

Strack B, DeShazo JP, Gennings C, Olmo JL, Ventura S, Cios KJ, et al. Impact of HbA1c Measurement on Hospital Readmission Rates: Analysis of 70,000 Clinical Database Patient Records. *Biomed Research International*. 2014;2014.

Strain WD, Paldanius PM. Diabetes, cardiovascular disease and the microcirculation. *Cardiovasc Diabetol*. 2018;17.

Sudharsan B, Peeples M, Shomali M. Hypoglycemia Prediction Using Machine Learning Models for Patients With Type 2 Diabetes. *Journal of Diabetes Science and Technology*. 2015;9(1):86-90.

Sul Gi K. Big data in healthcare hype and hope. *CDE*. 2013:122-5.

Sun H, Saeedi P, Karuranga S, Pinkepank M, Ogurtsova K, Duncan BB, et al. IDF Diabetes Atlas: Global, regional and country-level diabetes prevalence estimates for 2021 and projections for 2045. *Diabetes research and clinical practice*. 2022;183:109119.

Sun H, Saeedi P, Karuranga S, Pinkepank M, Ogurtsova K, Duncan BB, et al. IDF Diabetes Atlas: Global, regional and country-level diabetes prevalence estimates for 2021 and projections for 2045. *Diabetes Research and Clinical Practice*. 2022;183.

Sun J, Sow D, Hu J, Ebadollahi S, editors. A system for mining temporal physiological data streams for advanced prognostic decision support. 2010 IEEE International Conference on Data Mining; 2010: IEEE.

Sunkaria RK, Kumar V, Saxena SC, Singhal AM. An ANN-based HRV classifier for cardiac health prognosis. *Int J Electron Healthc*. 2014;7(4):315-30.

Swerdlow AJ, Laing SP, Qiao Z, Slater SD, Burden AC, Botha JL, et al. Cancer incidence and mortality in patients with insulin-treated diabetes: a UK cohort study. *Brit J Cancer*. 2005;92(11):2070-5.

Takahashi E, Moriyama K, Yamakado M, Grp NDD. Relationship between Hb and HbA1c in Japanese adults: An analysis of the 2009 Japan Society of Ningen Dock database. *Diabetes Research and Clinical Practice*. 2014;104(3):E64-E8.

Tarumi S, Takeuchi W, Chalkidis G, Rodriguez-Loya S, Kuwata J, Flynn M, et al. Leveraging Artificial Intelligence to Improve Chronic Disease Care: Methods and Application to Pharmacotherapy Decision Support for Type-2 Diabetes Mellitus. *Methods Inf Med*. 2021;60(S 01):e32-e43.

Taylor R. Insulin resistance and type 2 diabetes. *Diabetes*. 2012;61(4):778-9.

Telle-Hansen VH, Holven KB, Ulven SM. Impact of a healthy dietary pattern on gut microbiota and systemic inflammation in humans. *Nutrients*. 2018;10(11):1783.

Theodoridis S, Pikrakis A, Koutroumbas K, Cavouras D. Introduction to pattern recognition: a matlab approach: Academic Press; 2010.

Thompson D, Baranowski T. Chatbots as extenders of pediatric obesity intervention: an invited commentary on “Feasibility of Pediatric Obesity & Pre-Diabetes Treatment Support through Tess, the AI Behavioral Coaching Chatbot”. *Translational behavioral medicine*. 2019;9(3):448-50.

Tian T, Zhang LQ, Ma XH, Zhou JN, Shen J. Diabetes Mellitus and Incidence and Mortality of Gastric Cancer: A Meta-Analysis. *Exp Clin Endocr Diab*. 2012;120(4):217-23.

Torrent-Fontbona F. Adaptive basal insulin recommender system based on Kalman filter for type 1 diabetes. *Expert Systems with Applications*. 2018;101:1-7.

Toscano CM, Zhuo X, Imai K, Duncan BB, Polanczyk CA, Zhang P, et al. Cost-effectiveness of a national population-based screening program for type 2 diabetes: the Brazil experience. *Diabetology & metabolic syndrome*. 2015;7(1):1-11.

Tse G, Lai ETH, Tse V, Yeo JM. Molecular and electrophysiological mechanisms underlying cardiac arrhythmogenesis in diabetes mellitus. *Journal of diabetes research*. 2016;2016.

Tsugawa Y, Mukamal KJ, Davis RB, Taylor WC, Wee CC. Should the hemoglobin A1c diagnostic cutoff differ between blacks and whites? A cross-sectional study. *Annals of internal medicine*. 2012;157(3):153-9.

Tuomilehto J, Lindström J, Eriksson JG, Valle TT, Hämäläinen H, Ilanne-Parikka P, et al. Prevention of type 2 diabetes mellitus by changes in lifestyle among subjects with impaired glucose tolerance. *New England Journal of Medicine*. 2001;344(18):1343-50.

Üner S, Balcılar M, Ergüder T (Eds.), National household health survey – Prevalence of noncommunicable disease risk factors in Turkey 2017 (STEPS), World Health Organization Country Office in Turkey, Ankara (2018))

Vinik AI, Nevoret M-L, Casellini C, Parson H. Diabetic neuropathy. *Endocrinology and Metabolism Clinics*. 2013;42(4):747-87.

Vu GT, Tran BX, McIntyre RS, Pham HQ, Phan HT, Ha GH, et al. Modeling the Research Landscapes of Artificial Intelligence Applications in Diabetes (GAP(RESEARCH)). *International Journal of Environmental Research and Public Health*. 2020;17(6).

Wadwa RP, Laffel LM, Shah VN, Garg SK. Accuracy of a factory-calibrated, real-time continuous glucose monitoring system during 10 days of use in youth and adults with diabetes. *Diabetes technology & therapeutics*. 2018;20(6):395-402.

Wang J, Wang MY, Wang H, Liu HW, Lu R, Duan TQ, et al. Status of glycosylated hemoglobin and prediction of glycemic control among patients with insulin-treated type 2 diabetes in North China: a multicenter observational study. *Chinese Med J-Peking*. 2020;133(1):17-24.

Wang JQ, Li J, Wen CD, Liu Y, Ma HS. Predictors of poor glycemic control among type 2 diabetes mellitus patients treated with antidiabetic medications A cross-sectional study in China. *Medicine*. 2021;100(43).

Wang M, Hu R-Y, Wu H-B, Pan J, Gong W-W, Guo L-H, et al. Cancer risk among patients with type 2 diabetes mellitus: a population-based prospective study in China. *Scientific reports*. 2015;5(1):1-7.

Wang P, Kang DH, Cao W, Wang Y, Liu ZW. Diabetes mellitus and risk of hepatocellular carcinoma: a systematic review and meta-analysis. *Diabetes-Metab Res*. 2012;28(2):109-22.

Wang Y, Li P, Tian Y, Ren J, Li J. A Shared Decision-Making System for Diabetes Medication Choice Utilizing Electronic Health Record Data. *IEEE Journal of Biomedical and Health Informatics*. 2017;21(5):1280-7.

Wang Y, Liu X, Yan P, Bi Y, Liu Y, Zhang ZJ. Association between type 1 and type 2 diabetes and risk of non-Hodgkin's lymphoma: A meta-analysis of cohort studies. *Diabetes Metab*. 2020;46(1):8-19.

Washio M, Mori M, Khan M, Sakauchi F, Watanabe Y, Ozasa K, et al. Diabetes mellitus and kidney cancer risk: The results of Japan Collaborative Cohort Study for Evaluation of Cancer Risk (JACC study). *Int J Urol*. 2007;14(5):393-7.

Wasylewicz A, Scheepers-Hoeks A. Clinical decision support systems. *Fundamentals of clinical data science*. 2019:153-69.

Waters KM, Henderson BE, Stram DO, Wan P, Kolonel LN, Haiman CA. Association of Diabetes With Prostate Cancer Risk in the Multiethnic Cohort. *Am J Epidemiol*. 2009;169(8):937-45.

Watson HJ. Tutorial: Big Data Analytics: Concepts, Technologies, and Applications. *Communications of the Association for Information Systems*. 2014;34.

Weerahandi HM, Horwitz LI, Blecker SB. Diabetes Phenotyping Using the Electronic Health Record. *J Gen Intern Med*. 2020;35(12):3716-8.

Weerasinghe K, Scahill SL, Pauleen DJ, Taskin N. Big data analytics for clinical decision-making: Understanding health sector perceptions of policy and practice. *Technological Forecasting and Social Change*. 2022;174:121222.

Weizenbaum J. ELIZA a computer program for the study of natural language communication between man and machine. *Communications of the ACM*. 1966;9(1):36-45.

Wilkinson MJ, Nathan AG, Huang ES. Personalized Decision Support in Type 2 Diabetes Mellitus: Current Evidence and Future Directions. *Current Diabetes Reports*. 2013;13(2):205-12.

Woldaregay AZ, Årsand E, Walderhaug S, Albers D, Mamykina L, Botsis T, et al. Data-driven modeling and prediction of blood glucose dynamics: Machine learning applications in type 1 diabetes. *Artificial Intelligence in Medicine*. 2019;98:109-34.

WoodMichael A, ShulmanDorothy I, ForlenzaGregory P, BodeBruce W, BuckinghamBruce A, KaisermanKevin B, et al. In-clinic evaluation of the MiniMed 670G system “suspend before low” feature in children with type 1 diabetes. *Diabetes technology & therapeutics*. 2018.

Worsley PR, Whatling G, Barrett D, Holt C, Stokes M, Taylor M. Assessing changes in subjective and objective function from pre- to post-knee arthroplasty using the Cardiff Dempster-Shafer theory classifier. *Comput Methods Biomech Biomed Engin*. 2016;19(4):418-27.

Xie F, Chan JC, Ma RC. Precision medicine in diabetes prevention, classification and management. *Journal of diabetes investigation*. 2018;9(5):998-1015.

Yaël B, Pérol J, Dignat-George F. Managing Samples With Implausibly High Mean Cell Hemoglobin Concentration (Mchc) Values By Using Red Blood Cell (Rbc) And

Hemoglobin (Hgb) Values Obtained By Fluorescence Flow Cytometry. *Clinical Chemistry and Laboratory Medicine*. 2015;53.

Yamazaki D, Hitomi H, Nishiyama A. Hypertension with diabetes mellitus complications. *Hypertens Res*. 2018;41(3):147-56.

Yan PF, Wang YB, Yu X, Liu Y, Zhang ZJ. Type 2 diabetes mellitus and risk of head and neck cancer subtypes: a systematic review and meta-analysis of observational studies. *Acta Diabetol*. 2021;58(5):549-65.

Yang X, Lai SJ, Chang HF, Wen YP, Yu DW, Dong Z, et al. Artificial Intelligence-Based Diagnosis of Diabetes Mellitus: Combining Fundus Photography with Traditional Chinese Medicine Diagnostic Methodology. *Biomed Research International*. 2021;2021.

Yap MH, Chatwin KE, Ng C-C, Abbott CA, Bowling FL, Rajbhandari S, et al. A New Mobile Application for Standardizing Diabetic Foot Images. *Journal of Diabetes Science and Technology*. 2017;12(1):169-73.

Yi ZH, Luther Y, Xiong GH, Ni YL, Yun F, Chen J, et al. Association between diabetes mellitus and lung cancer: Meta-analysis. *Eur J Clin Invest*. 2020;50(10).

Yilmaz MB, Kilickap M, Abaci A, Barcin C, Bayram F, Karaaslan D, et al. Temporal changes in the epidemiology of diabetes mellitus in Turkey: A systematic review and meta-analysis. *Turk Kardiyoloji Dernegi Arsivi-Archives of the Turkish Society of Cardiology*. 2018;46(7):546-55.

Yuan MJ. Watson and healthcare, How natural language processing and semantic search could revolutionize clinical decision support. IBM developerWorks, IBM Corporation. 2011.

Zaccardi F, Davies MJ, Khunti K. The present and future scope of real-world evidence research in diabetes: What questions can and cannot be answered and what might be possible in the future? *Diabetes Obesity & Metabolism*. 2020;22:21-34.

Zarkogianni K, Litsa E, Mitsis K, Wu P, Kaddi CD, Cheng C, et al. A Review of Emerging Technologies for the Management of Diabetes Mellitus. *IEEE Transactions on Biomedical Engineering*. 2015;62(12):2735-49.

Zendehdel K, Nyren O, Ostenson CG, Adami HO, Ekbom A, Ye WM. Cancer incidence in patients with type 1 diabetes mellitus: A population-based cohort study in Sweden. *J Natl Cancer I*. 2003;95(23):1797-800.

Zhang AMY, Wellberg EA, Kopp JL, Johnson JD. Hyperinsulinemia in Obesity, Inflammation, and Cancer (vol 45, pg 285, 2021). *Diabetes Metab J*. 2021;45(4):622-.

Zhang DY, Li N, Xi YZ, Zhao Y, Wang TT. Diabetes mellitus and risk of ovarian cancer. A systematic review and meta-analysis of 15 cohort studies. *Diabetes Research and Clinical Practice*. 2017;130:43-52.

Zhang HM, Feng QW, Niu YX, Su Q, Wang X. Thyroid Nodules in Type 2 Diabetes Mellitus. *Curr Med Sci*. 2019;39(4):576-81.

Zhang J, Yu KF. What's the relative risk? A method of correcting the odds ratio in cohort studies of common outcomes. *Jama-J Am Med Assoc*. 1998;280(19):1690-1.

Zhang JJ, Jia JP, Shao Q, Wang YK. Diabetes mellitus and risk of pancreatic cancer in China: A meta-analysis based on 26 case-control studies. *Prim Care Diabetes*. 2019;13(3):276-82.

Zhang Y, Fong S, Fiaidhi J, Mohammed S. Real-time clinical decision support system with data stream mining. *Journal of biomedicine and biotechnology*. 2012;2012.

Zhang Y, Guo S-L, Han L-N, Li T-L. Application and Exploration of Big Data Mining in Clinical Medicine. *Chinese Med J-Peking*. 2016;129(6):731-8.

Zhou XZ, Menche J, Barabasi AL, Sharma A. Human symptoms-disease network. *Nature Communications*. 2014;5.

Zhu T, Li K, Chen J, Herrero P, Georgiou P. Dilated recurrent neural networks for glucose forecasting in type 1 diabetes. *Journal of Healthcare Informatics Research*. 2020;4(3):308-24.

Zhu ZW, Wang XJ, Shen ZJ, Lu YL, Zhong S, Xu C. Risk of bladder cancer in patients with diabetes mellitus: an updated meta-analysis of 36 observational studies. *Bmc Cancer*. 2013;13.

Zimmet P, Alberti KG, Magliano DJ, Bennett PH. Diabetes mellitus statistics on prevalence and mortality: facts and fallacies. *Nature Reviews Endocrinology*. 2016;12(10):616-22.



Tablo Ek.1. 2019 yılındaki akut miyokard infarktüsü vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Akut Miyokard İnfarktüsü (ICD -10: I21, I22)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
15-19	21	0,16	29	0,14	50	0,15	1.850	0,06	1.878	0,06	3.728	0,06	2,79	1,82	4,30	2,29	1,59	3,31	2,50	1,89	3,31
20-24	55	0,33	90	0,19	145	0,23	3.278	0,10	3.057	0,10	6.335	0,10	3,38	2,59	4,42	2,03	1,65	2,50	2,39	2,02	2,81
25-29	95	0,41	153	0,23	248	0,27	4.381	0,14	3.430	0,11	7.811	0,12	3,05	2,49	3,74	2,02	1,72	2,38	2,20	1,94	2,50
30-34	301	0,68	253	0,26	554	0,39	6.232	0,20	3.966	0,13	10.198	0,16	3,50	3,12	3,93	1,99	1,76	2,26	2,39	2,20	2,61
35-39	768	0,87	573	0,38	1.341	0,56	8.593	0,27	4.779	0,15	13.372	0,21	3,31	3,08	3,57	2,47	2,26	2,69	2,67	2,52	2,82
40-44	1.794	1,18	1.163	0,54	2.957	0,80	10.555	0,37	5.452	0,20	16.007	0,29	3,24	3,08	3,40	2,70	2,54	2,88	2,82	2,71	2,94
45-49	3.665	1,49	2.430	0,72	6.095	1,04	13.268	0,53	6.431	0,27	19.699	0,40	2,87	2,76	2,97	2,72	2,59	2,85	2,64	2,56	2,72
50-54	6.063	1,78	4.051	0,89	10.114	1,27	15.305	0,75	6.560	0,35	21.865	0,56	2,39	2,32	2,46	2,54	2,44	2,64	2,28	2,23	2,33
55-59	8.460	2,00	6.356	1,09	14.816	1,47	16.485	0,94	7.359	0,45	23.844	0,70	2,15	2,10	2,21	2,44	2,36	2,52	2,11	2,07	2,15
60-64	9.561	2,24	7.676	1,35	17.237	1,73	15.255	1,15	6.981	0,57	22.236	0,87	1,97	1,92	2,02	2,39	2,32	2,47	2,01	1,97	2,05
65-69	9.605	2,52	8.919	1,72	18.524	2,06	13.016	1,41	6.952	0,77	19.968	1,10	1,80	1,76	1,85	2,25	2,18	2,32	1,90	1,86	1,94
70-74	7.968	2,87	8.816	2,15	16.784	2,44	10.192	1,62	7.304	1,05	17.496	1,32	1,80	1,75	1,86	2,08	2,01	2,14	1,88	1,84	1,92
75-79	5.656	3,27	7.225	2,66	12.881	2,89	8.354	2,16	7.254	1,53	15.608	1,81	1,53	1,48	1,59	1,76	1,70	1,82	1,62	1,58	1,66
80-84	3.514	3,74	4.993	3,12	8.507	3,35	5.978	2,60	6.789	2,03	12.767	2,26	1,46	1,40	1,52	1,55	1,50	1,61	1,50	1,46	1,54
85-89	1.918	4,01	2.720	3,23	4.638	3,51	4.644	3,20	5.369	2,44	10.013	2,74	1,26	1,20	1,33	1,34	1,28	1,40	1,29	1,25	1,34
90+	367	3,49	907	2,97	1.274	3,10	1.380	3,44	2.733	2,57	4.113	2,81	1,01	0,90	1,14	1,16	1,08	1,25	1,11	1,04	1,18
Total	59.811	2,17	56.354	1,40	116.165	1,71	138.766	0,48	86.294	0,31	225.060	0,39	4,63	4,59	4,68	4,61	4,56	4,66	4,41	4,38	4,45
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			2,04	2,02	2,05

Tablo Ek.2. 2019 yılındaki akut ve kronik iskemik kalp hastalığı vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

İskemik Kalp Hastalığı (ICD -10: I21, I22, I23, I24, I25)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. N	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
15-19	88	0,67	96	0,47	184	0,54	6.240	0,19	5.745	0,19	11.985	0,19	3,48	2,82	4,30	2,48	2,03	3,04	2,87	2,48	3,32
20-24	156	0,93	296	0,64	452	0,72	10.406	0,31	9.574	0,30	19.980	0,30	3,04	2,59	3,56	2,14	1,90	2,40	2,36	2,15	2,60
25-29	290	1,26	534	0,79	824	0,91	12.570	0,39	11.427	0,37	23.997	0,38	3,27	2,90	3,67	2,12	1,95	2,32	2,39	2,23	2,57
30-34	897	2,04	1.003	1,03	1.900	1,34	18.660	0,59	14.861	0,49	33.521	0,54	3,52	3,29	3,77	2,12	1,99	2,26	2,51	2,40	2,63
35-39	2.298	2,62	2.443	1,61	4.741	1,98	28.091	0,87	21.804	0,70	49.895	0,79	3,07	2,94	3,20	2,32	2,23	2,42	2,55	2,48	2,63
40-44	5.243	3,46	5.226	2,41	10.469	2,84	36.127	1,26	28.209	1,03	64.336	1,15	2,80	2,72	2,89	2,37	2,30	2,44	2,52	2,46	2,57
45-49	10.025	4,08	11.397	3,37	21.422	3,67	45.135	1,79	39.363	1,62	84.498	1,71	2,34	2,29	2,39	2,11	2,07	2,16	2,19	2,16	2,23
50-54	16.054	4,73	19.288	4,25	35.342	4,45	50.741	2,50	44.759	2,41	95.500	2,46	1,93	1,90	1,97	1,79	1,76	1,83	1,85	1,83	1,87
55-59	21.471	5,08	28.425	4,89	49.896	4,97	54.860	3,12	50.284	3,09	105.144	3,11	1,66	1,63	1,69	1,61	1,59	1,64	1,63	1,61	1,65
60-64	22.649	5,30	30.759	5,40	53.408	5,36	50.662	3,82	46.785	3,80	97.447	3,81	1,41	1,39	1,43	1,44	1,42	1,47	1,43	1,41	1,45
65-69	20.648	5,42	29.721	5,73	50.369	5,60	42.457	4,61	42.007	4,66	84.464	4,63	1,18	1,16	1,21	1,24	1,23	1,26	1,22	1,21	1,23
70-74	15.150	5,46	23.742	5,78	38.892	5,66	31.316	4,97	35.117	5,03	66.433	5,00	1,11	1,08	1,13	1,16	1,14	1,18	1,14	1,12	1,15
75-79	9.349	5,40	15.877	5,84	25.226	5,67	22.241	5,74	26.653	5,60	48.894	5,67	0,94	0,91	0,96	1,04	1,02	1,07	1,00	0,98	1,02
80-84	4.925	5,25	9.146	5,71	14.071	5,54	13.795	6,00	19.731	5,91	33.526	5,95	0,87	0,84	0,90	0,97	0,94	0,99	0,93	0,91	0,95
85-89	2.571	5,38	4.771	5,67	7.342	5,56	9.492	6,54	13.550	6,15	23.042	6,31	0,81	0,78	0,85	0,92	0,89	0,95	0,88	0,85	0,90
90+	568	5,39	1.702	5,57	2.270	5,52	2.802	6,98	6.580	6,18	9.382	6,40	0,76	0,69	0,83	0,90	0,85	0,95	0,86	0,82	0,90
Total	132.382	4,80	184.426	4,59	316.808	4,68	435.595	1,50	416.449	1,48	852.044	1,49	3,32	3,30	3,34	3,19	3,17	3,21	3,24	3,23	3,26
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			1,46	1,46	1,47

Tablo Ek.3. 2019 yılındaki kalp yetmezliği vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Yaş Grubu	Kalp Yetmezliği (ICD -10: I50)																				
	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde									
15-19	23	0,17	6	0,03	29	0,09	458	0,01	378	0,01	836	0,01	12,37	8,13	18,80	2,35	1,05	5,27	6,47	4,47	9,37
20-24	27	0,16	32	0,07	59	0,09	562	0,02	468	0,01	1.030	0,02	9,68	6,58	14,25	4,71	3,29	6,74	5,97	4,59	7,76
25-29	58	0,25	65	0,10	123	0,14	624	0,02	693	0,02	1.317	0,02	13,07	9,98	17,11	4,25	3,29	5,48	6,48	5,39	7,80
30-34	92	0,21	105	0,11	197	0,14	953	0,03	924	0,03	1.877	0,03	6,98	5,63	8,65	3,55	2,90	4,34	4,62	3,99	5,35
35-39	299	0,34	248	0,16	547	0,23	1.691	0,05	1.495	0,05	3.186	0,05	6,53	5,78	7,39	3,41	2,98	3,90	4,56	4,17	5,00
40-44	757	0,50	630	0,29	1.387	0,38	2.864	0,10	2.380	0,09	5.244	0,09	5,01	4,62	5,43	3,35	3,07	3,66	4,03	3,80	4,28
45-49	1.979	0,81	1.624	0,48	3.603	0,62	4.881	0,19	3.714	0,15	8.595	0,17	4,19	3,98	4,42	3,14	2,96	3,33	3,57	3,43	3,71
50-54	4.058	1,19	3.310	0,73	7.368	0,93	7.420	0,37	5.077	0,27	12.497	0,32	3,29	3,17	3,42	2,68	2,56	2,80	2,90	2,82	2,99
55-59	6.766	1,60	6.417	1,10	13.183	1,31	10.564	0,60	7.159	0,44	17.723	0,52	2,69	2,60	2,77	2,53	2,44	2,62	2,53	2,47	2,58
60-64	9.219	2,16	9.124	1,60	18.343	1,84	12.803	0,96	8.892	0,72	21.695	0,85	2,27	2,21	2,33	2,24	2,17	2,30	2,19	2,15	2,24
65-69	10.689	2,81	11.861	2,29	22.550	2,51	13.667	1,49	10.758	1,19	24.425	1,34	1,91	1,87	1,96	1,94	1,89	1,99	1,89	1,86	1,93
70-74	9.859	3,56	12.675	3,09	22.534	3,28	13.618	2,16	12.771	1,83	26.389	1,99	1,67	1,63	1,72	1,71	1,67	1,75	1,67	1,64	1,70
75-79	7.952	4,59	11.091	4,08	19.043	4,28	12.749	3,29	13.857	2,91	26.606	3,08	1,41	1,37	1,46	1,42	1,38	1,45	1,40	1,38	1,43
80-84	5.109	5,44	7.911	4,94	13.020	5,13	10.023	4,36	13.320	3,99	23.343	4,14	1,26	1,22	1,31	1,25	1,22	1,29	1,25	1,22	1,28
85-89	2.942	6,15	4.864	5,78	7.806	5,91	8.347	5,75	11.203	5,09	19.550	5,35	1,07	1,03	1,12	1,14	1,11	1,19	1,11	1,08	1,14
90+	696	6,61	1.902	6,22	2.598	6,32	2.793	6,96	6.458	6,07	9.251	6,31	0,95	0,87	1,03	1,03	0,97	1,08	1,00	0,96	1,05
Total	60.525	2,20	71.865	1,79	132.390	1,95	104.017	0,36	99.547	0,35	203.564	0,36	6,26	6,20	6,33	5,11	5,06	5,16	5,58	5,54	5,62
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			1,85	1,83	1,86

Tablo Ek.4. 2019 yılındaki hipertansiyon vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Hpertansiyon (ICD -10: I10, I15.0, I15.1, I15.2, I15.8, I15.9)																						
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı									
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam			
	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL	
	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde										
15-19	302	2290,31	357	1731,41	659	1949,42	3.086	95,20	588	19,24	3.674	58,34	24,60	21,83	27,72	91,56	80,22	104,50	34,06	31,33	37,03	
20-24	332	1979,25	714	1543,68	1.046	1659,61	3.902	115,59	5.442	170,84	9.344	142,42	17,45	15,58	19,54	9,16	8,47	9,91	11,83	11,10	12,62	
25-29	680	2964,90	1.437	2126,18	2.117	2338,68	6.243	194,02	8.950	292,57	15.193	242,05	15,72	14,51	17,03	7,40	7,00	7,83	9,87	9,43	10,33	
30-34	1.635	3713,38	2.650	2716,97	4.285	3026,88	11.624	365,84	14.108	463,45	25.732	413,60	10,50	9,96	11,07	6,00	5,75	6,26	7,52	7,27	7,77	
35-39	4.404	5012,18	5.848	3864,48	10.252	4286,08	22.061	681,55	26.089	839,21	48.150	758,79	7,69	7,44	7,95	4,75	4,61	4,89	5,86	5,73	5,99	
40-44	8.563	5642,98	10.863	5014,80	19.426	5273,57	33.864	1181,93	40.438	1479,15	74.302	1327,05	5,00	4,88	5,12	3,52	3,44	3,59	4,14	4,07	4,21	
45-49	14.991	6098,29	19.309	5707,77	34.300	5872,12	44.825	1773,83	60.051	2478,96	104.876	2118,95	3,60	3,53	3,67	2,38	2,34	2,42	2,88	2,85	2,92	
50-54	20.261	5964,56	23.512	5182,55	43.773	5517,38	52.076	2567,99	60.001	3236,09	112.077	2887,09	2,41	2,37	2,45	1,63	1,61	1,66	1,96	1,94	1,99	
55-59	23.592	5579,30	25.593	4400,07	49.185	4896,47	54.499	3104,29	56.449	3463,36	110.948	3277,15	1,84	1,82	1,87	1,28	1,26	1,30	1,52	1,50	1,54	
60-64	21.868	5121,05	21.011	3688,46	42.879	4302,26	48.263	3635,69	44.846	3644,16	93.109	3639,76	1,43	1,41	1,45	1,01	1,00	1,03	1,19	1,18	1,20	
65-69	16.940	4445,70	16.049	3092,71	32.989	3665,56	37.081	4029,10	33.896	3756,33	70.977	3894,06	1,11	1,09	1,13	0,82	0,80	0,83	0,94	0,93	0,95	
70-74	10.678	3851,38	10.160	2475,48	20.838	3030,20	25.522	4047,26	23.495	3362,98	49.017	3687,61	0,95	0,93	0,97	0,73	0,71	0,75	0,82	0,80	0,83	
75-79	5.769	3330,50	5.558	2042,83	11.327	2543,74	16.276	4200,50	15.366	3231,34	31.642	3666,47	0,79	0,76	0,81	0,62	0,61	0,64	0,69	0,67	0,70	
80-84	2.847	3033,86	2.813	1757,38	5.660	2229,15	9.410	4093,24	9.829	2943,43	19.239	3412,25	0,73	0,70	0,77	0,59	0,57	0,62	0,65	0,63	0,67	
85-89	1.297	2711,86	1.367	1624,17	2.664	2018,29	5.875	4048,62	6.290	2855,12	12.165	3329,07	0,66	0,62	0,70	0,56	0,53	0,60	0,60	0,57	0,62	
90+	260	2469,37	508	1662,09	768	1868,93	1.603	3993,03	3.142	2951,20	4.745	3236,48	0,61	0,53	0,70	0,56	0,51	0,61	0,57	0,53	0,62	
Total	134.419	4877,98	147.749	3675,87	282.168	4164,81	376.210	1292,55	408.980	1457,43	785.190	1373,49	3,92	3,89	3,94	2,58	2,56	2,60	3,12	3,11	3,13	
Yaş ve Cinsiyete Göre Ağıqlılandırılmıř Odss Oranı																				1,72	1,71	1,72

Tablo Ek.5. 2019 yılındaki nefropatiler ve kronik böbrek yetmezliği vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Nefropati ve Kronik Böbrek Yetmezlikleri (ICD -10: N08.3, N18s, N19, E10.2, E11.2, E12.2, E13.2, E14.2)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
15-19	106	0,80	139	0,67	245	0,72	1.081	0,03	1.058	0,03	2.139	0,03	24,29	19,89	29,68	19,60	16,41	23,40	21,49	18,82	24,53
20-24	106	0,63	173	0,37	279	0,44	1.457	0,04	1.502	0,05	2.959	0,05	14,73	12,08	17,95	7,96	6,80	9,32	9,85	8,71	11,14
25-29	154	0,67	235	0,35	389	0,43	1.479	0,05	1.532	0,05	3.011	0,05	14,70	12,45	17,36	6,96	6,07	7,99	8,99	8,09	10,00
30-34	231	0,52	322	0,33	553	0,39	1.775	0,06	1.765	0,06	3.540	0,06	9,44	8,22	10,83	5,71	5,07	6,43	6,89	6,30	7,54
35-39	528	0,60	557	0,37	1.085	0,45	2.310	0,07	2.338	0,08	4.648	0,07	8,47	7,70	9,31	4,91	4,47	5,38	6,22	5,82	6,64
40-44	1.005	0,66	1.007	0,46	2.012	0,55	2.822	0,10	2.709	0,10	5.531	0,10	6,76	6,29	7,27	4,71	4,38	5,06	5,55	5,28	5,85
45-49	1.982	0,81	1.890	0,56	3.872	0,66	3.392	0,13	3.235	0,13	6.627	0,13	6,05	5,72	6,39	4,20	3,97	4,45	4,98	4,78	5,18
50-54	3.358	0,99	3.216	0,71	6.574	0,83	3.970	0,20	3.336	0,18	7.306	0,19	5,09	4,86	5,33	3,96	3,77	4,16	4,43	4,29	4,58
55-59	5.208	1,23	5.450	0,94	10.658	1,06	5.004	0,29	4.118	0,25	9.122	0,27	4,36	4,20	4,54	3,73	3,59	3,89	3,97	3,86	4,08
60-64	7.126	1,67	7.140	1,25	14.266	1,43	6.168	0,46	4.431	0,36	10.599	0,41	3,64	3,51	3,76	3,51	3,38	3,65	3,49	3,40	3,58
65-69	8.422	2,21	9.053	1,74	17.475	1,94	7.099	0,77	5.097	0,56	12.196	0,67	2,91	2,82	3,00	3,13	3,02	3,24	2,94	2,87	3,01
70-74	8.051	2,90	9.322	2,27	17.373	2,53	7.628	1,21	6.061	0,87	13.689	1,03	2,44	2,37	2,52	2,66	2,57	2,74	2,49	2,44	2,55
75-79	6.221	3,59	7.883	2,90	14.104	3,17	7.580	1,96	6.562	1,38	14.142	1,64	1,87	1,80	1,93	2,13	2,06	2,20	1,96	1,92	2,01
80-84	3.926	4,18	5.342	3,34	9.268	3,65	6.158	2,68	6.274	1,88	12.432	2,20	1,59	1,52	1,65	1,80	1,74	1,87	1,68	1,63	1,73
85-89	2.327	4,87	3.119	3,71	5.446	4,13	5.070	3,49	5.319	2,41	10.389	2,84	1,41	1,34	1,49	1,56	1,49	1,63	1,47	1,42	1,52
90+	517	4,91	1.073	3,51	1.590	3,87	1.773	4,42	2.802	2,63	4.575	3,12	1,12	1,01	1,24	1,35	1,25	1,45	1,25	1,18	1,32
Total	49.268	1,79	55.921	1,39	105.189	1,55	64.766	0,22	58.139	0,21	122.905	0,21	8,16	8,07	8,26	6,80	6,72	6,88	7,32	7,26	7,38
Yaş ve Cinsiyete Göre Ağırlandırılmış Odss Oranı																			2,89	2,86	2,91

Tablo Ek.6. 2019 yılındaki serebrovasküler hastalık vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Serebrovasküler Hastalıklar (ICD -10: I60, I61, I62, I63, I64, I65, I66, I67, I68, I69)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
15-19	55	0,42	79	0,38	134	0,40	3.361	0,10	3.413	0,11	6.774	0,11	4,04	3,09	5,27	3,44	2,75	4,30	3,70	3,11	4,39
20-24	102	0,61	199	0,43	301	0,48	4.904	0,15	5.928	0,19	10.832	0,17	4,21	3,45	5,12	2,32	2,01	2,67	2,90	2,59	3,25
25-29	201	0,88	351	0,52	552	0,61	6.319	0,20	8.492	0,28	14.811	0,24	4,49	3,90	5,17	1,88	1,69	2,09	2,59	2,38	2,82
30-34	377	0,86	681	0,70	1.058	0,75	8.389	0,26	10.975	0,36	19.364	0,31	3,26	2,94	3,62	1,94	1,80	2,10	2,41	2,27	2,57
35-39	960	1,09	1.418	0,94	2.378	0,99	11.197	0,35	14.634	0,47	25.831	0,41	3,18	2,98	3,40	2,00	1,89	2,11	2,46	2,36	2,56
40-44	2.241	1,48	2.928	1,35	5.169	1,40	13.488	0,47	17.599	0,64	31.087	0,56	3,17	3,03	3,32	2,11	2,03	2,20	2,55	2,47	2,63
45-49	5.357	2,18	7.073	2,09	12.430	2,13	18.196	0,72	24.022	0,99	42.218	0,85	3,07	2,98	3,17	2,13	2,08	2,19	2,53	2,48	2,58
50-54	11.128	3,28	13.958	3,08	25.086	3,16	25.194	1,24	29.149	1,57	54.343	1,40	2,69	2,63	2,75	1,99	1,95	2,03	2,30	2,27	2,33
55-59	20.590	4,87	25.284	4,35	45.874	4,57	35.520	2,02	38.077	2,34	73.597	2,17	2,48	2,44	2,52	1,90	1,87	1,93	2,15	2,13	2,18
60-64	30.257	7,09	35.668	6,26	65.925	6,61	44.534	3,35	43.374	3,52	87.908	3,44	2,20	2,16	2,23	1,83	1,80	1,85	1,99	1,97	2,01
65-69	39.389	10,34	46.292	8,92	85.681	9,52	51.734	5,62	50.114	5,55	101.848	5,59	1,94	1,91	1,96	1,67	1,64	1,69	1,78	1,76	1,79
70-74	38.990	14,06	51.298	12,50	90.288	13,13	53.209	8,44	56.613	8,10	109.822	8,26	1,78	1,75	1,80	1,62	1,60	1,64	1,68	1,66	1,69
75-79	32.164	18,57	45.734	16,81	77.898	17,49	51.149	13,20	59.353	12,48	110.502	12,80	1,50	1,48	1,52	1,42	1,40	1,44	1,44	1,43	1,46
80-84	21.389	22,79	34.001	21,24	55.390	21,81	40.896	17,79	55.871	16,73	96.767	17,16	1,36	1,34	1,39	1,34	1,32	1,36	1,35	1,33	1,36
85-89	12.103	25,31	19.970	23,73	32.073	24,30	32.068	22,10	45.306	20,57	77.374	21,17	1,19	1,17	1,22	1,20	1,18	1,22	1,19	1,18	1,21
90+	2.837	26,94	7.392	24,19	10.229	24,89	10.187	25,38	24.124	22,66	34.311	23,40	1,08	1,03	1,14	1,09	1,06	1,12	1,08	1,06	1,11
Total	218.140	7,92	292.326	7,27	510.466	7,53	410.345	1,41	487.044	1,74	897.389	1,57	6,01	5,98	6,04	4,44	4,42	4,46	5,11	5,09	5,13
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			1,73	1,72	1,73

Tablo Ek.7. 2019 yılındaki retinopati vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Retinopatiler (ICD -10: E10.3, E11.3, E12.3, E13.3, E14.3, H35.0, H35.2, H35.6, H35.8, H35.9, H36.0)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
15-19	160	1,21	184	0,89	344	1,02	1.368	0,04	1.252	0,04	2.620	0,04	29,09	24,68	34,30	21,97	18,81	25,66	24,70	22,06	27,65
20-24	226	1,35	280	0,61	506	0,80	1.841	0,05	1.492	0,05	3.333	0,05	25,03	21,78	28,76	13,00	11,44	14,77	15,92	14,50	17,49
25-29	274	1,19	379	0,56	653	0,72	1.885	0,06	1.779	0,06	3.664	0,06	20,63	18,16	23,43	9,69	8,67	10,83	12,44	11,44	13,52
30-34	492	1,12	528	0,54	1.020	0,72	2.336	0,07	1.950	0,06	4.286	0,07	15,36	13,93	16,94	8,49	7,71	9,35	10,53	9,83	11,27
35-39	968	1,10	1.065	0,70	2.033	0,85	2.976	0,09	2.572	0,08	5.548	0,09	12,10	11,25	13,02	8,56	7,97	9,20	9,80	9,31	10,31
40-44	2.286	1,51	2.023	0,93	4.309	1,17	3.253	0,11	3.191	0,12	6.444	0,12	13,46	12,75	14,20	8,07	7,63	8,53	10,27	9,88	10,68
45-49	4.356	1,77	4.412	1,30	8.768	1,50	3.940	0,16	4.017	0,17	7.957	0,16	11,55	11,06	12,06	7,96	7,62	8,30	9,46	9,18	9,76
50-54	6.384	1,88	7.503	1,65	13.887	1,75	4.235	0,21	4.609	0,25	8.844	0,23	9,15	8,80	9,52	6,75	6,50	7,00	7,80	7,60	8,01
55-59	8.815	2,08	11.327	1,95	20.142	2,01	5.339	0,30	6.163	0,38	11.502	0,34	6,98	6,75	7,22	5,23	5,07	5,40	6,00	5,87	6,14
60-64	9.795	2,29	12.737	2,24	22.532	2,26	6.215	0,47	6.902	0,56	13.117	0,51	4,99	4,83	5,15	4,06	3,94	4,18	4,49	4,39	4,59
65-69	9.470	2,49	12.721	2,45	22.191	2,47	6.580	0,71	6.963	0,77	13.543	0,74	3,54	3,43	3,65	3,23	3,14	3,33	3,38	3,31	3,45
70-74	7.049	2,54	10.135	2,47	17.184	2,50	5.998	0,95	5.831	0,83	11.829	0,89	2,72	2,62	2,81	3,01	2,91	3,11	2,85	2,79	2,92
75-79	4.192	2,42	6.206	2,28	10.398	2,34	4.585	1,18	4.604	0,97	9.189	1,06	2,07	1,99	2,16	2,39	2,30	2,48	2,22	2,16	2,29
80-84	1.928	2,05	2.912	1,82	4.840	1,91	2.765	1,20	3.017	0,90	5.782	1,03	1,72	1,62	1,83	2,03	1,93	2,14	1,88	1,80	1,95
85-89	762	1,59	1.126	1,34	1.888	1,43	1.524	1,05	1.731	0,79	3.255	0,89	1,53	1,40	1,67	1,71	1,59	1,85	1,61	1,53	1,71
90+	94	0,89	322	1,05	416	1,01	316	0,79	647	0,61	963	0,66	1,14	0,90	1,43	1,74	1,52	1,99	1,55	1,38	1,74
Total	57.251	2,08	73.860	1,84	131.111	1,94	55.156	0,19	56.720	0,20	111.876	0,20	11,17	11,04	11,31	9,24	9,14	9,34	10,06	9,98	10,15
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			4,61	4,57	4,65

Tablo Ek.8. 2019 yılındaki katarakt vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Kataraktlar (ICD -10: H25, H26, H27, H28)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
15-19	22	0,17	36	0,17	58	0,17	954	0,03	787	0,03	1.741	0,03	5,68	3,72	8,67	6,79	4,86	9,49	6,22	4,78	8,08
20-24	34	0,20	33	0,07	67	0,11	1.424	0,04	924	0,03	2.348	0,04	4,81	3,42	6,76	2,46	1,74	3,48	2,97	2,33	3,79
25-29	58	0,25	82	0,12	140	0,15	1.548	0,05	1.144	0,04	2.692	0,04	5,27	4,05	6,85	3,25	2,59	4,06	3,61	3,05	4,28
30-34	81	0,18	137	0,14	218	0,15	1.887	0,06	1.469	0,05	3.356	0,05	3,10	2,48	3,87	2,91	2,45	3,47	2,86	2,49	3,28
35-39	235	0,27	238	0,16	473	0,20	2.798	0,09	2.239	0,07	5.037	0,08	3,10	2,71	3,54	2,19	1,91	2,50	2,49	2,27	2,74
40-44	624	0,41	658	0,30	1.282	0,35	4.258	0,15	3.788	0,14	8.046	0,14	2,77	2,55	3,02	2,20	2,02	2,39	2,43	2,29	2,57
45-49	1.713	0,70	1.945	0,57	3.658	0,63	7.554	0,30	7.145	0,29	14.699	0,30	2,34	2,22	2,47	1,95	1,86	2,06	2,12	2,04	2,19
50-54	4.261	1,25	5.142	1,13	9.403	1,19	13.096	0,65	11.432	0,62	24.528	0,63	1,95	1,89	2,02	1,85	1,79	1,91	1,89	1,84	1,93
55-59	9.096	2,15	11.708	2,01	20.804	2,07	21.866	1,25	20.021	1,23	41.887	1,24	1,74	1,70	1,79	1,65	1,61	1,69	1,69	1,66	1,72
60-64	14.842	3,48	19.297	3,39	34.139	3,43	31.705	2,39	29.494	2,40	61.199	2,39	1,47	1,44	1,50	1,43	1,40	1,45	1,45	1,43	1,47
65-69	18.915	4,96	25.730	4,96	44.645	4,96	37.235	4,05	36.759	4,07	73.994	4,06	1,24	1,22	1,26	1,23	1,21	1,25	1,23	1,22	1,25
70-74	16.189	5,84	24.123	5,88	40.312	5,86	33.712	5,35	36.409	5,21	70.121	5,28	1,10	1,08	1,12	1,14	1,12	1,15	1,12	1,10	1,13
75-79	10.270	5,93	16.002	5,88	26.272	5,90	23.931	6,18	28.495	5,99	52.426	6,07	0,96	0,93	0,98	0,98	0,96	1,00	0,97	0,95	0,98
80-84	4.901	5,22	8.166	5,10	13.067	5,15	13.482	5,86	18.145	5,43	31.627	5,61	0,88	0,86	0,91	0,94	0,91	0,96	0,91	0,89	0,93
85-89	2.101	4,39	3.474	4,13	5.575	4,22	7.689	5,30	10.608	4,82	18.297	5,01	0,82	0,78	0,86	0,85	0,82	0,89	0,84	0,81	0,86
90+	298	2,83	1.009	3,30	1.307	3,18	1.704	4,24	4.271	4,01	5.975	4,08	0,66	0,58	0,74	0,82	0,76	0,88	0,77	0,73	0,82
Total	83.640	3,04	117.780	2,93	201.420	2,97	204.843	0,70	213.130	0,76	417.973	0,73	4,42	4,38	4,45	3,94	3,92	3,97	4,16	4,14	4,18
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			1,26	1,25	1,27

Tablo Ek.9. 2019 yılındaki lipid metabolizma bozukluğu vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Lipid Metabolizma Bozuklukları (ICD -10: E78.0, E78.1, E78.2, E78.3, E78.4, E78.5)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
15-19	268	2,03	373	1,81	641	1,90	5.033	0,16	7.299	0,24	12.332	0,20	13,34	11,78	15,10	7,70	6,93	8,55	9,85	9,09	10,67
20-24	519	3,09	988	2,14	1.507	2,39	8.710	0,26	13.643	0,43	22.353	0,34	12,34	11,28	13,50	5,07	4,75	5,42	7,17	6,80	7,55
25-29	968	4,22	1.544	2,28	2.512	2,78	14.290	0,44	18.213	0,60	32.503	0,52	9,88	9,24	10,56	3,90	3,70	4,11	5,48	5,26	5,71
30-34	2.318	5,26	2.949	3,02	5.267	3,72	23.880	0,75	24.155	0,79	48.035	0,77	7,34	7,02	7,67	3,90	3,75	4,05	4,97	4,82	5,11
35-39	5.207	5,93	5.802	3,83	11.009	4,60	34.687	1,07	32.544	1,05	67.231	1,06	5,82	5,64	5,99	3,77	3,66	3,88	4,51	4,41	4,60
40-44	9.618	6,34	10.294	4,75	19.912	5,41	40.996	1,43	38.584	1,41	79.580	1,42	4,66	4,56	4,77	3,49	3,41	3,56	3,96	3,90	4,03
45-49	15.352	6,25	19.073	5,64	34.425	5,89	46.143	1,83	49.084	2,03	95.227	1,92	3,58	3,51	3,65	2,89	2,84	2,94	3,19	3,15	3,23
50-54	20.042	5,90	26.635	5,87	46.677	5,88	47.487	2,34	52.757	2,85	100.244	2,58	2,61	2,57	2,66	2,13	2,10	2,16	2,36	2,33	2,39
55-59	23.384	5,53	31.640	5,44	55.024	5,48	47.330	2,70	51.043	3,13	98.373	2,91	2,11	2,08	2,15	1,78	1,75	1,81	1,94	1,92	1,96
60-64	22.319	5,23	28.836	5,06	51.155	5,13	40.144	3,02	40.773	3,31	80.917	3,16	1,77	1,74	1,80	1,56	1,53	1,58	1,66	1,64	1,68
65-69	19.111	5,02	25.146	4,85	44.257	4,92	31.822	3,46	32.581	3,61	64.403	3,53	1,47	1,45	1,50	1,36	1,34	1,38	1,41	1,39	1,43
70-74	13.135	4,74	18.575	4,53	31.710	4,61	21.854	3,47	23.989	3,43	45.843	3,45	1,39	1,35	1,42	1,33	1,31	1,36	1,35	1,33	1,37
75-79	7.697	4,44	11.444	4,21	19.141	4,30	13.969	3,61	16.588	3,49	30.557	3,54	1,24	1,21	1,28	1,21	1,19	1,24	1,22	1,20	1,25
80-84	3.907	4,16	6.141	3,84	10.048	3,96	7.972	3,47	10.435	3,12	18.407	3,26	1,21	1,16	1,26	1,24	1,20	1,28	1,22	1,19	1,25
85-89	1.694	3,54	2.940	3,49	4.634	3,51	4.666	3,22	6.192	2,81	10.858	2,97	1,11	1,04	1,17	1,25	1,20	1,31	1,19	1,15	1,23
90+	294	2,79	925	3,03	1.219	2,97	1.024	2,55	2.431	2,28	3.455	2,36	1,10	0,96	1,25	1,34	1,24	1,44	1,27	1,19	1,35
Total	145.833	5,29	193.305	4,81	339.138	5,01	390.007	1,34	420.311	1,50	810.318	1,42	4,11	4,09	4,14	3,32	3,30	3,34	3,66	3,65	3,68
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			2,09	2,09	2,10

Tablo Ek.10. 2019 yılındaki periferik dolaşım bozukluğu vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Periferik Dolaşım Bozuklukları (ICD -10: I73.9, I78.8, I78.9, E10.5, E11.5, E12.5, E13.5, E14.5)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
15-19	38	0,29	61	0,30	99	0,29	790	0,02	1.010	0,03	1.800	0,03	11,86	8,56	16,43	8,98	6,93	11,63	10,27	8,39	12,58
20-24	76	0,45	134	0,29	210	0,33	1.570	0,05	2.361	0,07	3.931	0,06	9,78	7,77	12,32	3,92	3,29	4,66	5,58	4,85	6,41
25-29	130	0,57	272	0,40	402	0,44	2.112	0,07	3.568	0,12	5.680	0,09	8,68	7,27	10,37	3,46	3,06	3,92	4,92	4,45	5,45
30-34	265	0,60	490	0,50	755	0,53	2.970	0,09	4.738	0,16	7.708	0,12	6,47	5,71	7,34	3,24	2,95	3,56	4,32	4,01	4,66
35-39	706	0,80	893	0,59	1.599	0,67	3.781	0,12	5.542	0,18	9.323	0,15	6,93	6,39	7,51	3,32	3,10	3,57	4,57	4,34	4,82
40-44	1.447	0,95	1.479	0,68	2.926	0,79	4.368	0,15	5.651	0,21	10.019	0,18	6,31	5,94	6,69	3,32	3,13	3,52	4,47	4,29	4,65
45-49	2.788	1,13	2.931	0,87	5.719	0,98	5.206	0,21	6.695	0,28	11.901	0,24	5,56	5,31	5,82	3,15	3,02	3,29	4,10	3,97	4,23
50-54	4.600	1,35	4.540	1,00	9.140	1,15	6.330	0,31	6.724	0,36	13.054	0,34	4,38	4,22	4,55	2,78	2,67	2,88	3,45	3,36	3,55
55-59	6.749	1,60	6.891	1,18	13.640	1,36	7.749	0,44	7.615	0,47	15.364	0,45	3,66	3,54	3,78	2,55	2,47	2,64	3,02	2,95	3,09
60-64	8.135	1,91	7.836	1,38	15.971	1,60	8.313	0,63	7.087	0,58	15.400	0,60	3,08	2,99	3,18	2,41	2,33	2,49	2,69	2,63	2,75
65-69	8.119	2,13	8.172	1,57	16.291	1,81	8.244	0,90	6.667	0,74	14.911	0,82	2,41	2,34	2,48	2,15	2,08	2,22	2,24	2,19	2,29
70-74	6.678	2,41	7.051	1,72	13.729	2,00	7.058	1,12	5.786	0,83	12.844	0,97	2,18	2,11	2,26	2,09	2,02	2,17	2,09	2,04	2,14
75-79	4.371	2,52	5.029	1,85	9.400	2,11	5.515	1,42	4.824	1,01	10.339	1,20	1,79	1,72	1,87	1,84	1,77	1,91	1,78	1,73	1,83
80-84	2.499	2,66	3.055	1,91	5.554	2,19	3.745	1,63	3.671	1,10	7.416	1,32	1,65	1,57	1,74	1,75	1,67	1,84	1,68	1,62	1,74
85-89	1.139	2,38	1.608	1,91	2.747	2,08	2.580	1,78	2.601	1,18	5.181	1,42	1,35	1,26	1,45	1,63	1,53	1,74	1,48	1,41	1,55
90+	212	2,01	514	1,68	726	1,77	690	1,72	1.259	1,18	1.949	1,33	1,17	1,01	1,37	1,43	1,29	1,59	1,33	1,22	1,45
Total	47.952	1,74	50.956	1,27	98.908	1,46	71.021	0,24	75.799	0,27	146.820	0,26	7,24	7,16	7,32	4,74	4,69	4,79	5,75	5,71	5,80
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			2,65	2,63	2,68

Tablo Ek.11. 2019 yılındaki nöropati vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Nöropatiler (ICD -10: G63.2, G73.0, G99.0, G59.0, E10.4, E11.4, E12.4, E13.4, E14.4)																						
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı									
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam			
	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL	
	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde										
15-19	149	1,13	183	0,89	332	0,98	254	0,01	409	0,01	663	0,01	145,85	119,06	178,68	66,90	56,17	79,69	94,20	82,54	107,52	
20-24	295	1,76	384	0,83	679	1,08	481	0,01	840	0,03	1.321	0,02	125,61	108,58	145,32	31,74	28,12	35,82	54,08	49,28	59,34	
25-29	416	1,81	586	0,87	1.002	1,11	930	0,03	1.318	0,04	2.248	0,04	63,90	56,88	71,78	20,29	18,40	22,37	31,24	28,99	33,67	
30-34	897	2,04	1.108	1,14	2.005	1,42	1.472	0,05	2.046	0,07	3.518	0,06	44,87	41,27	48,78	17,08	15,88	18,39	25,39	24,03	26,83	
35-39	2.156	2,45	2.676	1,77	4.832	2,02	2.145	0,07	3.323	0,11	5.468	0,09	37,93	35,72	40,29	16,82	15,98	17,71	23,91	22,99	24,86	
40-44	4.489	2,96	5.483	2,53	9.972	2,71	2.739	0,10	4.192	0,15	6.931	0,12	31,86	30,37	33,42	16,91	16,24	17,61	22,45	21,77	23,15	
45-49	8.221	3,34	11.404	3,37	19.625	3,36	3.603	0,14	5.787	0,24	9.390	0,19	24,23	23,30	25,21	14,57	14,11	15,04	18,29	17,84	18,75	
50-54	12.110	3,57	18.239	4,02	30.349	3,83	3.876	0,19	6.611	0,36	10.487	0,27	19,30	18,62	20,02	11,71	11,38	12,04	14,68	14,36	15,02	
55-59	15.717	3,72	24.623	4,23	40.340	4,02	4.505	0,26	7.272	0,45	11.777	0,35	15,01	14,51	15,51	9,86	9,61	10,13	11,99	11,74	12,24	
60-64	15.832	3,71	25.085	4,40	40.917	4,11	4.413	0,33	6.599	0,54	11.012	0,43	11,54	11,16	11,94	8,54	8,31	8,78	9,90	9,69	10,11	
65-69	14.630	3,84	23.578	4,54	38.208	4,25	4.195	0,46	6.317	0,70	10.512	0,58	8,72	8,42	9,03	6,75	6,57	6,94	7,64	7,48	7,81	
70-74	10.694	3,86	18.407	4,48	29.101	4,23	3.434	0,54	5.444	0,78	8.878	0,67	7,33	7,05	7,62	5,98	5,80	6,16	6,57	6,42	6,73	
75-79	6.554	3,78	11.351	4,17	17.905	4,02	2.915	0,75	4.340	0,91	7.255	0,84	5,19	4,96	5,42	4,73	4,56	4,90	4,94	4,81	5,08	
80-84	3.245	3,46	6.001	3,75	9.246	3,64	1.711	0,74	2.964	0,89	4.675	0,83	4,78	4,50	5,07	4,35	4,16	4,55	4,52	4,36	4,68	
85-89	1.326	2,77	2.565	3,05	3.891	2,95	1.096	0,76	1.644	0,75	2.740	0,75	3,75	3,46	4,06	4,18	3,93	4,45	4,02	3,83	4,22	
90+	241	2,29	741	2,42	982	2,39	246	0,61	640	0,60	886	0,60	3,80	3,18	4,54	4,11	3,69	4,57	4,03	3,67	4,41	
Total	96.972	3,52	152.414	3,79	249.386	3,68	38.015	0,13	59.746	0,21	97.761	0,17	27,89	27,56	28,22	18,47	18,30	18,65	22,31	22,14	22,48	
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			10,42	10,34	10,50	

Tablo Ek.12. 2019 yılındaki baş boyun kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Baş ve Boyun Bölgesi Kanserleri (ICD-O3: Topografi Kodu C00-C14 aralığı alt kırımları, Davranış kodu /3)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
15-19	3	22,75	1	4,85	4	11,83	21	0,65	20	0,65	41	0,65	35,13	10,48	117,79	7,41	0,99	55,23	18,18	6,51	50,75
20-24	2	11,92	4	8,65	6	9,52	29	0,86	30	0,94	59	0,90	13,88	3,31	58,18	9,18	3,24	26,07	10,59	4,57	24,52
25-29	2	8,72	2	2,96	4	4,42	21	0,65	42	1,37	63	1,00	13,36	3,13	56,99	2,16	0,52	8,90	4,40	1,60	12,10
30-34	4	9,08	5	5,13	9	6,36	44	1,38	44	1,45	88	1,41	6,56	2,36	18,26	3,55	1,41	8,94	4,49	2,26	8,93
35-39	12	13,66	12	7,93	24	10,03	78	2,41	71	2,28	149	2,35	5,67	3,09	10,41	3,47	1,88	6,40	4,27	2,78	6,58
40-44	26	17,13	17	7,85	43	11,67	102	3,56	79	2,89	181	3,23	4,81	3,13	7,40	2,72	1,61	4,59	3,61	2,59	5,04
45-49	43	17,49	38	11,23	81	13,87	173	6,85	100	4,13	273	5,52	2,56	1,83	3,57	2,72	1,87	3,95	2,51	1,96	3,22
50-54	82	24,14	40	8,82	122	15,38	196	9,67	90	4,85	286	7,37	2,50	1,93	3,23	1,82	1,25	2,64	2,09	1,69	2,58
55-59	117	27,67	68	11,69	185	18,42	228	12,99	115	7,06	343	10,13	2,13	1,71	2,66	1,66	1,23	2,24	1,82	1,52	2,17
60-64	149	34,89	83	14,57	232	23,28	235	17,70	95	7,72	330	12,90	1,97	1,61	2,42	1,89	1,41	2,53	1,80	1,53	2,13
65-69	132	34,64	87	16,77	219	24,33	245	26,62	116	12,86	361	19,81	1,30	1,05	1,61	1,30	0,99	1,72	1,23	1,04	1,45
70-74	112	40,40	94	22,90	206	29,96	194	30,76	86	12,31	280	21,06	1,31	1,04	1,66	1,86	1,39	2,49	1,42	1,19	1,70
75-79	91	52,54	61	22,42	152	34,14	146	37,68	90	18,93	236	27,35	1,39	1,07	1,81	1,18	0,86	1,64	1,25	1,02	1,53
80-84	42	44,76	37	23,12	79	31,11	80	34,80	82	24,56	162	28,73	1,29	0,89	1,87	0,94	0,64	1,39	1,08	0,83	1,42
85-89	19	39,73	26	30,89	45	34,09	67	46,17	52	23,60	119	32,57	0,86	0,52	1,43	1,31	0,82	2,10	1,05	0,74	1,48
90+	3	28,49	12	39,26	15	36,50	7	17,44	30	28,18	37	25,24	1,63	0,42	6,32	1,39	0,71	2,72	1,45	0,79	2,64
Total	839	30,45	587	14,60	1.426	21,05	1.866	6,41	1.142	4,07	3.008	5,26	4,75	4,38	5,15	3,59	3,25	3,96	4,00	3,76	4,26
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			1,80	1,69	1,92

Tablo Ek.13. 2019 yılındaki tiroid kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Tiroid Kanseri (ICD-O3: Topografi Kodu C73 ve alt kırılımları, Davranış Kodu /3)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
15-19	1	7,58	1	4,85	2	5,92	19	0,59	84	2,75	103	1,64	12,94	1,73	96,67	1,76	0,25	12,67	3,62	0,89	14,66
20-24	3	17,88	18	38,92	21	33,32	64	1,90	241	7,57	305	4,65	9,43	2,96	30,03	5,15	3,19	8,31	7,17	4,61	11,16
25-29	5	21,80	20	29,59	25	27,62	84	2,61	405	13,24	489	7,79	8,35	3,39	20,59	2,24	1,43	3,50	3,55	2,37	5,30
30-34	10	22,71	43	44,09	53	37,44	117	3,68	571	18,76	688	11,06	6,17	3,23	11,77	2,35	1,72	3,21	3,39	2,56	4,48
35-39	16	18,21	98	64,76	114	47,66	169	5,22	871	28,02	1.040	16,39	3,49	2,09	5,82	2,31	1,88	2,85	2,91	2,40	3,53
40-44	49	32,29	143	66,01	192	52,12	217	7,57	895	32,74	1.112	19,86	4,26	3,13	5,81	2,02	1,69	2,41	2,63	2,25	3,06
45-49	50	20,34	242	71,54	292	49,99	221	8,75	828	34,18	1.049	21,19	2,33	1,71	3,16	2,09	1,81	2,42	2,36	2,07	2,69
50-54	78	22,96	297	65,47	375	47,27	202	9,96	688	37,11	890	22,93	2,31	1,78	2,99	1,76	1,54	2,02	2,06	1,83	2,33
55-59	109	25,78	312	53,64	421	41,91	192	10,94	537	32,95	729	21,53	2,36	1,86	2,98	1,63	1,42	1,87	1,95	1,73	2,19
60-64	110	25,76	237	41,61	347	34,82	170	12,81	319	25,92	489	19,12	2,01	1,58	2,56	1,61	1,36	1,90	1,82	1,59	2,09
65-69	81	21,26	169	32,57	250	27,78	162	17,60	296	32,80	458	25,13	1,21	0,92	1,58	0,99	0,82	1,20	1,11	0,95	1,29
70-74	49	17,67	96	23,39	145	21,09	71	11,26	116	16,60	187	14,07	1,57	1,09	2,26	1,41	1,07	1,85	1,50	1,21	1,86
75-79	15	8,66	43	15,80	58	13,03	30	7,74	81	17,03	111	12,86	1,12	0,60	2,08	0,93	0,64	1,34	1,01	0,74	1,39
80-84	4	4,26	19	11,87	23	9,06	23	10,00	31	9,28	54	9,58	0,43	0,15	1,23	1,28	0,72	2,26	0,95	0,58	1,54
85-89	4	8,36	6	7,13	10	7,58	11	7,58	15	6,81	26	7,12	1,10	0,35	3,47	1,05	0,41	2,70	1,06	0,51	2,21
90+	0	0,01	2	6,54	2	4,87	0	0,00	4	3,76	4	2,73	3,81	0,00	NA	1,74	0,32	9,51	1,78	0,33	9,74
Total	584	21,19	1.746	43,44	2.330	34,39	1.752	6,02	5.982	21,32	7.734	13,53	3,52	3,21	3,87	2,04	1,93	2,15	2,54	2,43	2,66
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			1,84	1,76	1,94

Tablo Ek.14. 2019 yılındaki larenks kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Larenks Kanseri (ICD-O3: Topografi Kodu C32 ve alt kırılımları, Davranış kodu /3)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
15-19	0	0,01	0	0,00	0	0,01	0	0,00	2	0,07	2	0,03	245,84	0,00	NA	0,07	0,00	NA	0,19	0,00	NA
20-24	0	0,01	0	0,00	0	0,00	2	0,06	0	0,00	2	0,03	0,10	0,00	NA	68,87	0,00	NA	0,10	0,00	NA
25-29	0	0,00	0	0,00	0	0,00	1	0,03	2	0,07	3	0,05	0,14	0,00	NA	0,02	0,00	NA	0,05	0,00	NA
30-34	1	2,27	1	1,03	2	1,41	6	0,19	1	0,03	7	0,11	12,03	1,45	99,91	31,21	1,95	499,01	12,56	2,61	60,45
35-39	2	2,28	0	0,00	2	0,84	18	0,56	3	0,10	21	0,33	4,09	0,95	17,64	0,01	0,00	NA	2,53	0,59	10,78
40-44	2	1,32	1	0,46	3	0,81	33	1,15	6	0,22	39	0,70	1,14	0,27	4,77	2,10	0,25	17,47	1,17	0,36	3,78
45-49	14	5,70	7	2,07	21	3,60	92	3,64	15	0,62	107	2,16	1,56	0,89	2,74	3,34	1,36	8,20	1,66	1,04	2,66
50-54	61	17,96	9	1,98	70	8,82	199	9,81	20	1,08	219	5,64	1,83	1,37	2,44	1,84	0,84	4,04	1,56	1,20	2,05
55-59	112	26,49	5	0,86	117	11,65	280	15,95	24	1,47	304	8,98	1,66	1,33	2,07	0,58	0,22	1,53	1,30	1,05	1,61
60-64	149	34,89	11	1,93	160	16,05	362	27,27	17	1,38	379	14,82	1,28	1,06	1,55	1,40	0,65	2,98	1,08	0,90	1,30
65-69	149	39,10	14	2,70	163	18,11	304	33,03	12	1,33	316	17,34	1,18	0,97	1,44	2,03	0,94	4,39	1,04	0,86	1,26
70-74	112	40,40	4	0,97	116	16,87	220	34,89	15	2,15	235	17,68	1,16	0,92	1,45	0,45	0,15	1,37	0,95	0,76	1,19
75-79	47	27,13	4	1,47	51	11,45	131	33,81	9	1,89	140	16,22	0,80	0,58	1,12	0,78	0,24	2,52	0,71	0,51	0,97
80-84	22	23,44	2	1,25	24	9,45	68	29,58	5	1,50	73	12,95	0,79	0,49	1,28	0,83	0,16	4,30	0,73	0,46	1,16
85-89	8	16,73	1	1,19	9	6,82	28	19,30	2	0,91	30	8,21	0,87	0,40	1,90	1,31	0,12	14,43	0,83	0,39	1,75
90+	2	19,00	0	0,00	2	4,87	6	14,95	0	0,00	6	4,09	1,27	0,26	6,30	3,48	0,00	NA	1,19	0,24	5,89
Total	681	24,71	59	1,47	740	10,92	1.750	6,01	133	0,47	1.883	3,29	4,11	3,76	4,49	3,10	2,28	4,21	3,32	3,05	3,61
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			1,29	1,19	1,41

Tablo Ek.15. 2019 yılındaki akciğer kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Akciğer Kanseri (ICD–03: Topografi Kodu C34 ve alt kırılımları, Davranış kodu /3)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde									
15-19	4	30,34	1	4,85	5	14,79	21	0,65	15	0,49	36	0,57	46,84	16,08	136,48	9,88	1,31	74,81	25,88	10,15	65,95
20-24	2	11,92	3	6,49	5	7,93	28	0,83	16	0,50	44	0,67	14,38	3,42	60,35	12,91	3,76	44,32	11,83	4,69	29,84
25-29	5	21,80	3	4,44	8	8,84	44	1,37	29	0,95	73	1,16	15,95	6,32	40,22	4,68	1,43	15,37	7,60	3,66	15,77
30-34	6	13,63	5	5,13	11	7,77	51	1,61	46	1,51	97	1,56	8,49	3,64	19,79	3,39	1,35	8,54	4,98	2,67	9,30
35-39	16	18,21	17	11,23	33	13,80	89	2,75	93	2,99	182	2,87	6,62	3,89	11,28	3,76	2,24	6,30	4,81	3,32	6,97
40-44	37	24,38	33	15,23	70	19,00	184	6,42	125	4,57	309	5,52	3,80	2,67	5,41	3,33	2,27	4,89	3,44	2,66	4,46
45-49	145	58,99	77	22,76	222	38,01	484	19,15	223	9,21	707	14,28	3,08	2,56	3,71	2,47	1,91	3,20	2,66	2,29	3,09
50-54	392	115,40	127	27,99	519	65,42	1.076	53,06	294	15,86	1.370	35,29	2,18	1,94	2,44	1,77	1,43	2,17	1,85	1,68	2,05
55-59	832	196,76	241	41,43	1.073	106,82	1.933	110,10	427	26,20	2.360	69,71	1,79	1,65	1,94	1,58	1,35	1,85	1,53	1,43	1,65
60-64	1.248	292,26	322	56,53	1.570	157,53	2.516	189,53	411	33,40	2.927	114,42	1,54	1,44	1,65	1,69	1,46	1,96	1,38	1,30	1,46
65-69	1.447	379,75	293	56,46	1.740	193,34	2.419	262,84	359	39,78	2.778	152,41	1,45	1,36	1,54	1,42	1,22	1,66	1,27	1,20	1,35
70-74	1.074	387,37	293	71,39	1.367	198,79	1.920	304,47	326	46,66	2.246	168,97	1,27	1,18	1,37	1,53	1,31	1,79	1,18	1,10	1,26
75-79	643	371,21	184	67,63	827	185,72	1.096	282,85	221	46,47	1.317	152,61	1,31	1,19	1,45	1,46	1,20	1,77	1,22	1,12	1,33
80-84	197	209,93	71	44,36	268	105,55	459	199,66	110	32,94	569	100,92	1,05	0,89	1,24	1,35	1,00	1,82	1,05	0,90	1,21
85-89	62	129,63	24	28,52	86	65,15	159	109,57	40	18,16	199	54,46	1,18	0,88	1,59	1,57	0,95	2,61	1,20	0,93	1,54
90+	4	37,99	3	9,82	7	17,03	17	42,35	9	8,45	26	17,73	0,90	0,30	2,67	1,16	0,31	4,29	0,96	0,42	2,21
Total	6.114	221,87	1.697	42,22	7.811	115,29	12.496	42,93	2.744	9,78	15.240	26,66	5,18	5,02	5,34	4,32	4,07	4,59	4,33	4,21	4,45
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			1,57	1,53	1,62

Tablo Ek.16. 2019 yılındaki mide kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Mide Kanseri (ICD-O3: Topografi Kodu C16 ve alt kırılımları, Davranış kodu /3)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
15-19	0	0,00	2	9,70	2	5,92	4	0,12	16	0,52	20	0,32	0,01	0,00	NA	18,53	4,26	80,59	18,63	4,35	79,71
20-24	1	5,96	3	6,49	4	6,35	14	0,41	18	0,57	32	0,49	14,38	1,89	109,33	11,48	3,38	38,97	13,01	4,60	36,80
25-29	2	8,72	8	11,84	10	11,05	40	1,24	34	1,11	74	1,18	7,02	1,70	29,03	10,65	4,93	23,01	9,37	4,84	18,14
30-34	6	13,63	16	16,40	22	15,54	62	1,95	71	2,33	133	2,14	6,98	3,02	16,15	7,03	4,09	12,10	7,27	4,63	11,42
35-39	22	25,04	17	11,23	39	16,30	135	4,17	114	3,67	249	3,92	6,00	3,83	9,42	3,06	1,84	5,10	4,16	2,97	5,82
40-44	39	25,70	33	15,23	72	19,55	175	6,11	146	5,34	321	5,73	4,21	2,97	5,96	2,85	1,96	4,16	3,41	2,64	4,40
45-49	81	32,95	69	20,40	150	25,68	296	11,71	180	7,43	476	9,62	2,81	2,20	3,60	2,75	2,08	3,62	2,67	2,22	3,21
50-54	145	42,69	125	27,55	270	34,03	408	20,12	219	11,81	627	16,15	2,12	1,76	2,56	2,33	1,87	2,91	2,11	1,83	2,43
55-59	318	75,20	156	26,82	474	47,19	566	32,24	252	15,46	818	24,16	2,33	2,03	2,68	1,73	1,42	2,12	1,95	1,74	2,19
60-64	372	87,11	193	33,88	565	56,69	679	51,15	275	22,35	954	37,29	1,70	1,50	1,93	1,52	1,26	1,82	1,52	1,37	1,69
65-69	419	109,96	212	40,85	631	70,11	639	69,43	253	28,04	892	48,94	1,58	1,40	1,79	1,46	1,21	1,75	1,43	1,29	1,59
70-74	340	122,63	225	54,82	565	82,16	549	87,06	249	35,64	798	60,03	1,41	1,23	1,61	1,54	1,28	1,84	1,37	1,23	1,52
75-79	214	123,54	170	62,48	384	86,24	442	114,07	216	45,42	658	76,24	1,08	0,92	1,28	1,38	1,13	1,68	1,13	1,00	1,28
80-84	111	118,29	91	56,85	202	79,56	236	102,66	165	49,41	401	71,12	1,15	0,92	1,44	1,15	0,89	1,49	1,12	0,94	1,32
85-89	46	96,18	43	51,09	89	67,43	135	93,03	98	44,48	233	63,76	1,03	0,74	1,44	1,15	0,80	1,64	1,06	0,83	1,35
90+	7	66,48	19	62,16	26	63,27	26	64,77	50	46,96	76	51,84	1,03	0,45	2,37	1,32	0,78	2,25	1,22	0,78	1,91
Total	2.123	77,04	1.382	34,38	3.505	51,73	4.406	15,14	2.356	8,40	6.762	11,83	5,09	4,84	5,36	4,10	3,83	4,38	4,38	4,20	4,56
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			1,72	1,65	1,79

Tablo Ek.17. 2019 yılındaki kolon, rektosigmoid ve rektum kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre dağılımı

Kolon, Rektosigmoid ve Rektum Kanseri (ICD-O3: Topografi Kodu C18-C20 aralığı ve alt kırımları, Davranış kodu /3)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
15-19	0	0,00	1	4,85	1	2,96	31	0,96	29	0,95	60	0,95	0,00	0,00	NA	5,11	0,70	37,52	3,11	0,43	22,41
20-24	5	29,81	2	4,32	7	11,11	38	1,13	28	0,88	66	1,01	26,49	10,42	67,30	4,92	1,17	20,65	11,04	5,07	24,07
25-29	5	21,80	5	7,40	10	11,05	56	1,74	50	1,63	106	1,69	12,53	5,02	31,28	4,53	1,81	11,35	6,54	3,42	12,51
30-34	10	22,71	10	10,25	20	14,13	91	2,86	85	2,79	176	2,83	7,93	4,13	15,24	3,67	1,91	7,07	4,99	3,15	7,93
35-39	25	28,45	30	19,82	55	22,99	169	5,22	139	4,47	308	4,85	5,45	3,58	8,30	4,43	2,99	6,58	4,74	3,56	6,31
40-44	63	41,52	59	27,24	122	33,12	241	8,41	234	8,56	475	8,48	4,94	3,74	6,52	3,18	2,39	4,23	3,90	3,20	4,76
45-49	155	63,05	129	38,13	284	48,62	373	14,76	322	13,29	695	14,04	4,27	3,54	5,15	2,87	2,34	3,52	3,46	3,02	3,98
50-54	284	83,61	219	48,27	503	63,40	494	24,36	377	20,33	871	22,44	3,43	2,97	3,97	2,37	2,01	2,81	2,83	2,53	3,15
55-59	478	113,04	354	60,86	832	82,83	790	45,00	460	28,22	1.250	36,92	2,51	2,24	2,82	2,16	1,88	2,48	2,24	2,06	2,45
60-64	735	172,12	435	76,36	1.170	117,39	967	72,84	457	37,14	1.424	55,67	2,37	2,15	2,60	2,06	1,80	2,35	2,11	1,95	2,28
65-69	753	197,62	433	83,44	1.186	131,78	954	103,66	438	48,54	1.392	76,37	1,91	1,73	2,10	1,72	1,51	1,96	1,73	1,60	1,87
70-74	610	220,02	452	110,13	1.062	154,43	781	123,85	412	58,97	1.193	89,75	1,78	1,60	1,98	1,87	1,63	2,14	1,72	1,59	1,87
75-79	404	233,23	277	101,81	681	152,93	549	141,69	364	76,55	913	105,79	1,65	1,45	1,87	1,33	1,14	1,56	1,45	1,31	1,60
80-84	200	213,13	178	111,20	378	148,87	306	133,11	301	90,14	607	107,66	1,60	1,34	1,92	1,23	1,03	1,49	1,38	1,22	1,57
85-89	105	219,54	107	127,13	212	160,61	179	123,35	189	85,79	368	100,71	1,78	1,40	2,27	1,48	1,17	1,88	1,60	1,35	1,89
90+	15	142,46	34	111,24	49	119,24	33	82,20	49	46,02	82	55,93	1,73	0,94	3,19	2,42	1,56	3,75	2,13	1,50	3,04
Total	3.847	139,61	2.725	67,80	6.572	97,00	6.052	20,79	3.934	14,02	9.986	17,47	6,72	6,46	7,00	4,84	4,61	5,08	5,56	5,39	5,73
Yaş ve Cinsiyete Göre Ağıqlandırılmış Odss Oranı																			2,12	2,06	2,19

Tablo Ek.18. 2019 yılındaki karaciğer ve intrahepatik safra yolları kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Karaciğer ve İntrahepatik Safra Kanalları Kanseri (ICD-O3: Topografi Kodu C22 ve alt kırılımları, Davranış kodu /3)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
15-19	0	0,00	0	0,00	0	0,00	7	0,22	3	0,10	10	0,16	0,00	0,00	NA	0,00	0,00	NA	0,00	0,00	NA
20-24	0	0,00	1	2,16	1	1,59	6	0,18	8	0,25	14	0,21	0,00	0,00	NA	8,61	1,08	68,84	7,44	0,98	56,55
25-29	2	8,72	0	0,00	2	2,21	13	0,40	16	0,52	29	0,46	21,59	4,87	95,66	0,00	0,00	NA	4,78	1,14	20,04
30-34	2	4,54	6	6,15	8	5,65	14	0,44	25	0,82	39	0,63	10,31	2,34	45,36	7,49	3,07	18,26	9,02	4,21	19,29
35-39	10	11,38	11	7,27	21	8,78	41	1,27	35	1,13	76	1,20	8,99	4,50	17,94	6,46	3,28	12,71	7,33	4,52	11,89
40-44	19	12,52	16	7,39	35	9,50	53	1,85	65	2,38	118	2,11	6,77	4,01	11,43	3,11	1,80	5,37	4,51	3,09	6,57
45-49	34	13,83	46	13,60	80	13,70	76	3,01	89	3,67	165	3,33	4,60	3,07	6,89	3,70	2,59	5,28	4,11	3,15	5,37
50-54	89	26,20	73	16,09	162	20,42	144	7,10	89	4,80	233	6,00	3,69	2,83	4,81	3,35	2,46	4,57	3,40	2,78	4,16
55-59	184	43,51	109	18,74	293	29,17	204	11,62	137	8,41	341	10,07	3,75	3,07	4,57	2,23	1,73	2,87	2,90	2,48	3,39
60-64	234	54,80	133	23,35	367	36,82	291	21,92	159	12,92	450	17,59	2,50	2,11	2,97	1,81	1,44	2,28	2,09	1,82	2,40
65-69	250	65,61	140	26,98	390	43,33	256	27,82	127	14,07	383	21,01	2,36	1,98	2,81	1,92	1,51	2,44	2,06	1,79	2,38
70-74	188	67,81	106	25,83	294	42,75	190	30,13	102	14,60	292	21,97	2,25	1,84	2,75	1,77	1,35	2,32	1,95	1,66	2,29
75-79	99	57,15	85	31,24	184	41,32	129	33,29	81	17,03	210	24,33	1,72	1,32	2,23	1,83	1,35	2,49	1,70	1,39	2,07
80-84	37	39,43	44	27,49	81	31,90	64	27,84	66	19,76	130	23,06	1,42	0,94	2,12	1,39	0,95	2,04	1,38	1,05	1,83
85-89	19	39,73	8	9,51	27	20,46	24	16,54	24	10,89	48	13,14	2,40	1,32	4,39	0,87	0,39	1,94	1,56	0,97	2,50
90+	0	0,00	0	0,00	0	0,00	5	12,45	7	6,57	12	8,18	0,00	0,00	NA	0,00	0,00	NA	0,00	0,00	NA
Total	1.167	42,35	778	19,36	1.945	28,71	1.517	5,21	1.033	3,68	2.550	4,46	8,13	7,53	8,77	5,26	4,79	5,77	6,44	6,07	6,83
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			2,48	2,34	2,64

Tablo Ek.19. 2019 yılındaki pankreas kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Pankreas Kanseri (ICD-O3: Topografi Kodu C25 ve alt kırılımları, Davranış kodu /3)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
15-19	0	0,00	0	0,00	0	0,00	4	0,12	4	0,13	8	0,13	NA	NA	NA	NA	NA	NA	NA	NA	NA
20-24	0	0,01	1	2,16	1	1,59	3	0,09	5	0,16	8	0,12	NA	NA	NA	13,77	1,61	117,91	13,03	1,63	104,05
25-29	1	4,36	1	1,48	2	2,21	6	0,19	6	0,20	12	0,19	23,38	2,82	194,25	7,54	0,91	62,66	11,56	2,59	51,64
30-34	1	2,27	0	0,00	1	0,71	18	0,57	17	0,56	35	0,56	4,01	0,54	30,03	NA	NA	NA	1,26	0,17	9,17
35-39	5	5,69	3	1,98	8	3,34	14	0,43	20	0,64	34	0,54	13,16	4,74	36,53	3,08	0,92	10,37	6,24	2,89	13,48
40-44	15	9,88	11	5,08	26	7,06	32	1,12	29	1,06	61	1,09	8,85	4,79	16,34	4,79	2,39	9,58	6,48	4,09	10,25
45-49	34	13,83	31	9,16	65	11,13	44	1,74	37	1,53	81	1,64	7,94	5,08	12,43	6,00	3,72	9,67	6,80	4,91	9,42
50-54	63	18,55	45	9,92	108	13,61	58	2,86	43	2,32	101	2,60	6,49	4,54	9,27	4,28	2,82	6,50	5,23	3,99	6,86
55-59	133	31,45	100	17,19	233	23,20	75	4,27	52	3,19	127	3,75	7,36	5,55	9,77	5,39	3,85	7,54	6,18	4,98	7,68
60-64	148	34,66	88	15,45	236	23,68	108	8,14	72	5,85	180	7,04	4,26	3,33	5,46	2,64	1,93	3,61	3,37	2,77	4,09
65-69	140	36,74	101	19,46	241	26,78	107	11,63	47	5,21	154	8,45	3,16	2,46	4,07	3,74	2,64	5,28	3,17	2,59	3,88
70-74	127	45,81	97	23,63	224	32,57	73	11,58	66	9,45	139	10,46	3,96	2,97	5,28	2,50	1,83	3,42	3,12	2,52	3,85
75-79	75	43,30	73	26,83	148	33,24	55	14,19	49	10,30	104	12,05	3,05	2,15	4,32	2,60	1,81	3,74	2,76	2,15	3,55
80-84	30	31,97	36	22,49	66	25,99	30	13,05	25	7,49	55	9,75	2,45	1,48	4,06	3,00	1,80	5,00	2,67	1,86	3,81
85-89	5	10,45	14	16,63	19	14,39	15	10,34	12	5,45	27	7,39	1,01	0,37	2,78	3,05	1,41	6,60	1,95	1,08	3,50
90+	1	9,50	2	6,54	3	7,30	2	4,98	3	2,82	5	3,41	1,91	0,17	21,03	2,32	0,39	13,90	2,14	0,51	8,96
Total	778	28,23	603	15,00	1381	20,38	644	2,21	487	1,74	1131	1,98	12,76	11,50	14,17	8,65	7,67	9,74	10,31	9,53	11,15
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			4,02	3,71	4,36

Tablo Ek.20. 2019 yılındaki böbrek kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Böbrek Kanseri (ICD-O3: Topografi Kodu C64 ve alt kırılımları, Davranış kodu /3)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
15-19	2	15,17	1,00	4,85	3,00	8,87	0,00	0,00	5,00	0,16	5,00	0,08	NA	0,00	NA	29,64	3,46	253,76	111,77	26,71	467,68
20-24	0	0,01	1,00	2,16	1,00	1,59	7,00	0,21	10,00	0,31	17,00	0,26	0,03	0,00	NA	6,89	0,88	53,80	6,13	0,82	46,02
25-29	0	0,00	3,00	4,44	3,00	3,32	20,00	0,62	18,00	0,59	38,00	0,61	0,01	0,00	NA	7,54	2,22	25,61	5,48	1,69	17,74
30-34	5	11,36	3,00	3,08	8,00	5,65	45,00	1,42	16,00	0,53	61,00	0,98	8,02	3,18	20,20	5,85	1,71	20,08	5,76	2,76	12,04
35-39	12	13,66	9,00	5,95	21,00	8,78	94,00	2,90	43,00	1,38	137,00	2,16	4,70	2,58	8,58	4,30	2,10	8,82	4,07	2,57	6,44
40-44	26	17,13	15,00	6,92	41,00	11,13	119,00	4,15	65,00	2,38	184,00	3,29	4,13	2,70	6,31	2,91	1,66	5,11	3,39	2,41	4,75
45-49	58	23,59	24,00	7,09	82,00	14,04	189,00	7,48	88,00	3,63	277,00	5,60	3,16	2,35	4,23	1,95	1,24	3,07	2,51	1,96	3,21
50-54	99	29,14	39,00	8,60	138,00	17,39	210,00	10,36	92,00	4,96	302,00	7,78	2,81	2,22	3,57	1,73	1,19	2,52	2,24	1,83	2,74
55-59	156	36,89	85,00	14,61	241,00	23,99	241,00	13,73	89,00	5,46	330,00	9,75	2,69	2,20	3,29	2,68	1,99	3,60	2,46	2,08	2,91
60-64	177	41,45	86,00	15,10	263,00	26,39	267,00	20,11	97,00	7,88	364,00	14,23	2,06	1,70	2,49	1,92	1,43	2,56	1,85	1,58	2,17
65-69	175	45,93	96,00	18,50	271,00	30,11	266,00	28,90	108,00	11,97	374,00	20,52	1,59	1,31	1,92	1,55	1,17	2,03	1,47	1,26	1,72
70-74	113	40,76	82,00	19,98	195,00	28,36	157,00	24,90	93,00	13,31	250,00	18,81	1,64	1,29	2,09	1,50	1,12	2,02	1,51	1,25	1,82
75-79	80	46,18	48,00	17,64	128,00	28,75	114,00	29,42	53,00	11,15	167,00	19,35	1,57	1,18	2,09	1,58	1,07	2,34	1,49	1,18	1,87
80-84	26	27,71	22,00	13,74	48,00	18,90	53,00	23,05	23,00	6,89	76,00	13,48	1,20	0,75	1,92	2,00	1,11	3,58	1,40	0,98	2,01
85-89	9	18,82	6,00	7,13	15,00	11,36	14,00	9,65	14,00	6,35	28,00	7,66	1,95	0,84	4,51	1,12	0,43	2,92	1,48	0,79	2,78
90+	0	0,01	5,00	16,36	5,00	12,17	2,00	4,98	3,00	2,82	5,00	3,41	0,00	0,00	NA	5,81	1,39	24,30	3,57	1,03	12,33
Total	938	34,04	525,00	13,06	1463,00	21,59	1798,00	6,18	817,00	2,91	2615,00	4,57	5,51	5,09	5,96	4,49	4,02	5,01	4,72	4,43	5,03
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			2,10	1,96	2,24

Tablo Ek.21. 2019 yılındaki mesane kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Mesane Kanseri (ICD-03: Topografi Kodu C67 ve alt kırılımları, Davranış kodu /3)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
15-19	0	0,01	0	0,00	0	0,01	3	0,09	2	0,07	5	0,08	0,08	0,00	NA	0,07	0,00	NA	0,07	0,00	NA
20-24	1	5,96	1	2,16	2	3,17	9	0,27	6	0,19	15	0,23	22,36	2,83	176,52	11,48	1,38	95,35	13,88	3,17	60,70
25-29	2	8,72	0	0,00	2	2,21	12	0,37	4	0,13	16	0,25	23,38	5,23	104,49	0,01	0,00	NA	8,67	1,99	37,71
30-34	4	9,08	0	0,00	4	2,83	33	1,04	12	0,39	45	0,72	8,75	3,10	24,69	0,00	0,00	NA	3,91	1,41	10,86
35-39	3	3,41	4	2,64	7	2,93	56	1,73	17	0,55	73	1,15	1,97	0,62	6,31	4,83	1,63	14,37	2,54	1,17	5,52
40-44	16	10,54	4	1,85	20	5,43	101	3,53	27	0,99	128	2,29	2,99	1,77	5,07	1,87	0,65	5,34	2,38	1,48	3,80
45-49	47	19,12	15	4,43	62	10,61	219	8,67	32	1,32	251	5,07	2,21	1,61	3,02	3,36	1,82	6,20	2,09	1,59	2,76
50-54	129	37,98	25	5,51	154	19,41	333	16,42	70	3,78	403	10,38	2,31	1,89	2,83	1,46	0,92	2,30	1,87	1,55	2,25
55-59	317	74,97	43	7,39	360	35,84	608	34,63	83	5,09	691	20,41	2,17	1,89	2,48	1,45	1,00	2,10	1,76	1,55	1,99
60-64	471	110,30	67	11,76	538	53,98	842	63,43	92	7,48	934	36,51	1,74	1,55	1,95	1,57	1,15	2,16	1,48	1,33	1,64
65-69	656	172,16	88	16,96	744	82,67	958	104,09	122	13,52	1.080	59,25	1,66	1,50	1,83	1,25	0,95	1,65	1,40	1,27	1,53
70-74	600	216,41	86	20,95	686	99,76	894	141,77	99	14,17	993	74,70	1,53	1,38	1,69	1,48	1,11	1,97	1,34	1,21	1,47
75-79	395	228,04	79	29,04	474	106,45	692	178,59	111	23,34	803	93,05	1,28	1,13	1,45	1,24	0,93	1,66	1,14	1,02	1,28
80-84	232	247,23	44	27,49	276	108,70	418	181,83	90	26,95	508	90,10	1,36	1,16	1,60	1,02	0,71	1,46	1,21	1,04	1,40
85-89	119	248,81	30	35,64	149	112,88	288	198,47	56	25,42	344	94,14	1,25	1,01	1,55	1,40	0,90	2,19	1,20	0,99	1,45
90+	16	151,96	8	26,17	24	58,40	52	129,53	30	28,18	82	55,93	1,17	0,67	2,06	0,93	0,43	2,03	1,04	0,66	1,65
Total	3.008	109,16	494	12,29	3.502	51,69	5.518	18,96	853	3,04	6.371	11,14	5,76	5,51	6,02	4,04	3,62	4,52	4,64	4,45	4,84
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			1,61	1,54	1,68

Tablo Ek.22. 2019 yılındaki melanom vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Melanoma (ICD–O3: Topografi kodu C44, Morfoloji kodu 8720/3)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde									
15-19	0	0,01	0	0,00	0	0,01	0	0,00	3	0,10	3	0,05	245,84	0,00	NA	0,05	0,00	NA	0,12	0,00	NA
20-24	0	0,01	0	0,00	0	0,00	3	0,09	5	0,16	8	0,12	0,07	0,00	NA	0,01	0,00	NA	0,03	0,00	NA
25-29	1	4,36	1	1,48	2	2,21	8	0,25	9	0,29	17	0,27	17,54	2,19	140,23	5,03	0,64	39,70	8,16	1,88	35,31
30-34	0	0,00	2	2,05	2	1,41	5	0,16	14	0,46	19	0,31	0,01	0,00	NA	4,46	1,01	19,62	4,63	1,08	19,86
35-39	2	2,28	0	0,00	2	0,84	16	0,49	15	0,48	31	0,49	4,60	1,06	20,03	0,00	0,00	NA	1,71	0,41	7,15
40-44	2	1,32	2	0,92	4	1,09	25	0,87	20	0,73	45	0,80	1,51	0,36	6,38	1,26	0,29	5,40	1,35	0,49	3,76
45-49	5	2,03	6	1,77	11	1,88	22	0,87	13	0,54	35	0,71	2,34	0,88	6,17	3,30	1,26	8,70	2,66	1,35	5,24
50-54	10	2,94	6	1,32	16	2,02	27	1,33	13	0,70	40	1,03	2,21	1,07	4,57	1,89	0,72	4,96	1,96	1,10	3,49
55-59	15	3,55	7	1,20	22	2,19	25	1,42	14	0,86	39	1,15	2,49	1,31	4,73	1,40	0,57	3,47	1,90	1,13	3,21
60-64	31	7,26	13	2,28	44	4,41	28	2,11	15	1,22	43	1,68	3,44	2,06	5,74	1,87	0,89	3,93	2,63	1,73	4,00
65-69	23	6,04	14	2,70	37	4,11	31	3,37	16	1,77	47	2,58	1,79	1,04	3,07	1,52	0,74	3,12	1,59	1,04	2,45
70-74	11	3,97	11	2,68	22	3,20	35	5,55	19	2,72	54	4,06	0,71	0,36	1,41	0,99	0,47	2,07	0,79	0,48	1,29
75-79	13	7,51	11	4,04	24	5,39	19	4,90	22	4,63	41	4,75	1,53	0,76	3,10	0,87	0,42	1,80	1,13	0,69	1,88
80-84	6	6,39	12	7,50	18	7,09	19	8,26	18	5,39	37	6,56	0,77	0,31	1,94	1,39	0,67	2,89	1,08	0,62	1,90
85-89	6	12,55	6	7,13	12	9,09	9	6,20	12	5,45	21	5,75	2,02	0,72	5,68	1,31	0,49	3,49	1,58	0,78	3,22
90+	0	0,01	1	3,27	1	2,44	3	7,47	7	6,57	10	6,82	0,00	0,00	NA	0,50	0,06	4,04	0,36	0,05	2,79
Total	125	4,54	92	2,29	217	3,20	275	0,94	215	0,77	490	0,86	4,80	3,89	5,93	2,99	2,34	3,81	3,74	3,19	4,38
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			1,73	1,46	2,05

Tablo Ek.23. 2019 yılındaki hodgkin lenfoma vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına insidans ve odss oranları göre dağılımı

Hodgkin Lenfoma (ICD-O3: Ayrıntıları Bölüm 3'te verilmiştir.)																						
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı									
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam			
	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL	
	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde										
15-19	6	45,50	4	19,40	10	29,58	45	1,39	46	1,51	91	1,44	32,79	13,99	76,88	12,89	4,64	35,81	20,48	10,66	39,35	
20-24	5	29,81	4	8,65	9	14,28	49	1,45	63	1,98	112	1,71	20,54	8,18	51,56	4,37	1,59	12,01	8,37	4,24	16,50	
25-29	5	21,80	3	4,44	8	8,84	53	1,65	43	1,41	96	1,53	13,24	5,29	33,12	3,16	0,98	10,18	5,78	2,81	11,89	
30-34	10	22,71	3	3,08	13	9,18	53	1,67	47	1,54	100	1,61	13,62	6,93	26,77	1,99	0,62	6,40	5,71	3,21	10,18	
35-39	11	12,52	5	3,30	16	6,69	37	1,14	28	0,90	65	1,02	10,95	5,59	21,47	3,67	1,42	9,50	6,53	3,78	11,29	
40-44	14	9,23	4	1,85	18	4,89	41	1,43	32	1,17	73	1,30	6,45	3,51	11,83	1,58	0,56	4,46	3,75	2,24	6,28	
45-49	25	10,17	18	5,32	43	7,36	49	1,94	20	0,83	69	1,39	5,25	3,24	8,49	6,44	3,41	12,18	5,28	3,61	7,73	
50-54	25	7,36	12	2,65	37	4,66	38	1,87	17	0,92	55	1,42	3,93	2,37	6,51	2,88	1,38	6,04	3,29	2,17	4,99	
55-59	32	7,57	14	2,41	46	4,58	36	2,05	22	1,35	58	1,71	3,69	2,29	5,94	1,78	0,91	3,49	2,67	1,82	3,94	
60-64	23	5,39	15	2,63	38	3,81	28	2,11	16	1,30	44	1,72	2,55	1,47	4,43	2,03	1,00	4,10	2,22	1,44	3,42	
65-69	15	3,94	14	2,70	29	3,22	27	2,93	12	1,33	39	2,14	1,34	0,71	2,52	2,03	0,94	4,39	1,51	0,93	2,44	
70-74	12	4,33	8	1,95	20	2,91	19	3,01	7	1,00	26	1,96	1,44	0,70	2,96	1,95	0,71	5,36	1,49	0,83	2,66	
75-79	11	6,35	12	4,41	23	5,17	8	2,06	11	2,31	19	2,20	3,08	1,24	7,65	1,91	0,84	4,32	2,35	1,28	4,31	
80-84	3	3,20	5	3,12	8	3,15	11	4,78	5	1,50	16	2,84	0,67	0,19	2,39	2,09	0,60	7,21	1,11	0,48	2,59	
85-89	2	4,18	0	0,00	2	1,52	2	1,38	2	0,91	4	1,09	3,03	0,43	21,54	0,00	0,00	NA	1,38	0,25	7,56	
90+	0	0,01	0	0,00	0	0,00	1	2,49	0	0,00	1	0,68	0,00	0,00	NA	3,48	0,00	NA	0,01	0,00	NA	
Total	199	7,22	121	3,01	320	4,72	497	1,71	371	1,32	868	1,52	4,23	3,59	4,99	2,28	1,85	2,80	3,11	2,74	3,54	
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			3,93	3,42	4,52	

Tablo Ek.24. 2019 yılındaki non hodgkin lenfoma vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Non-Hodgkin Lenfoma (ICD-O3: Ayrıntıları Bölüm 3'te verilmiştir.)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde									
15-19	1	7,58	2	9,70	3	8,87	25	0,77	20	0,65	45	0,71	9,83	1,33	72,59	14,82	3,46	63,42	12,42	3,86	39,97
20-24	5	29,81	2	4,32	7	11,11	28	0,83	13	0,41	41	0,62	35,95	13,88	93,11	10,60	2,39	46,96	17,77	7,97	39,62
25-29	9	39,24	3	4,44	12	13,26	36	1,12	27	0,88	63	1,00	35,09	16,90	72,85	5,03	1,53	16,58	13,21	7,12	24,49
30-34	8	18,17	7	7,18	15	10,60	42	1,32	36	1,18	78	1,25	13,75	6,45	29,28	6,07	2,70	13,64	8,45	4,86	14,69
35-39	24	27,31	4	2,64	28	11,71	82	2,53	48	1,54	130	2,05	10,78	6,84	17,00	1,71	0,62	4,75	5,71	3,80	8,60
40-44	24	15,82	21	9,69	45	12,22	81	2,83	58	2,12	139	2,48	5,60	3,55	8,82	4,57	2,77	7,53	4,92	3,52	6,89
45-49	45	18,31	36	10,64	81	13,87	102	4,04	81	3,34	183	3,70	4,54	3,19	6,44	3,18	2,15	4,71	3,75	2,89	4,87
50-54	59	17,37	39	8,60	98	12,35	143	7,05	99	5,34	242	6,23	2,46	1,82	3,34	1,61	1,11	2,33	1,98	1,57	2,51
55-59	87	20,57	59	10,14	146	14,53	156	8,89	91	5,58	247	7,30	2,32	1,78	3,01	1,82	1,31	2,52	1,99	1,62	2,44
60-64	124	29,04	82	14,40	206	20,67	149	11,22	105	8,53	254	9,93	2,59	2,04	3,28	1,69	1,26	2,25	2,08	1,73	2,50
65-69	125	32,80	99	19,08	224	24,89	160	17,39	86	9,53	246	13,50	1,89	1,49	2,38	2,00	1,50	2,67	1,84	1,54	2,21
70-74	92	33,18	98	23,88	190	27,63	132	20,93	110	15,74	242	18,21	1,59	1,21	2,07	1,52	1,16	1,99	1,52	1,26	1,84
75-79	83	47,92	82	30,14	165	37,05	109	28,13	96	20,19	205	23,75	1,70	1,28	2,27	1,49	1,11	2,00	1,56	1,27	1,92
80-84	36	38,36	42	26,24	78	30,72	54	23,49	46	13,78	100	17,74	1,63	1,07	2,49	1,91	1,25	2,89	1,73	1,29	2,33
85-89	16	33,45	9	10,69	25	18,94	40	27,57	31	14,07	71	19,43	1,21	0,68	2,17	0,76	0,36	1,60	0,97	0,62	1,54
90+	1	9,50	5	16,36	6	14,60	5	12,45	11	10,33	16	10,91	0,76	0,09	6,53	1,58	0,55	4,56	1,34	0,52	3,42
Total	739	26,82	590	14,68	1.329	19,62	1.344	4,62	958	3,41	2.302	4,03	5,81	5,31	6,35	4,30	3,88	4,76	4,87	4,55	5,21
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			2,29	2,14	2,46

Tablo Ek.25. 2019 yılındaki meme kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Meme Kanseri (ICD-O3: Topografi Kodu C50 ve alt kırılımları, Davranış kodu /3)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
15-19	0	0,01	1	4,85	1	2,96	2	0,06	4	0,13	6	0,10	0,12	0,00	NA	37,06	4,14	331,56	31,08	3,75	257,95
20-24	0	0,01	4	8,65	4	6,35	2	0,06	52	1,63	54	0,82	0,10	0,00	NA	5,30	1,92	14,65	7,71	2,79	21,30
25-29	0	0,00	14	20,71	14	15,47	1	0,03	207	6,77	208	3,31	0,14	0,00	NA	3,06	1,78	5,26	4,67	2,72	8,02
30-34	1	2,27	69	70,74	70	49,45	0	0,00	643	21,12	643	10,34	72164,96	0,00	NA	3,35	2,61	4,30	4,79	3,74	6,13
35-39	2	2,28	204	134,81	206	86,12	10	0,31	1.388	44,65	1.398	22,03	7,37	1,61	33,63	3,02	2,61	3,50	3,91	3,38	4,53
40-44	4	2,64	348	160,65	352	95,56	10	0,35	2.249	82,26	2.259	40,35	7,55	2,37	24,08	1,95	1,75	2,19	2,37	2,12	2,65
45-49	6	2,44	603	178,25	609	104,26	12	0,47	2.458	101,47	2.470	49,90	5,14	1,93	13,70	1,76	1,61	1,92	2,09	1,91	2,28
50-54	7	2,06	745	164,21	752	94,79	12	0,59	1.958	105,60	1.970	50,75	3,48	1,37	8,85	1,56	1,43	1,69	1,87	1,72	2,03
55-59	12	2,84	1.042	179,15	1.054	104,93	27	1,54	1.690	103,69	1.717	50,72	1,85	0,93	3,64	1,73	1,60	1,87	2,07	1,92	2,24
60-64	16	3,75	1.036	181,87	1.052	105,55	31	2,34	1.366	111,00	1.397	54,61	1,60	0,88	2,93	1,64	1,51	1,78	1,93	1,79	2,09
65-69	13	3,41	869	167,46	882	98,00	30	3,26	1.024	113,48	1.054	57,83	1,05	0,55	2,01	1,48	1,35	1,62	1,70	1,55	1,85
70-74	11	3,97	701	170,80	712	103,54	21	3,33	725	103,77	746	56,12	1,19	0,57	2,47	1,65	1,48	1,83	1,85	1,67	2,05
75-79	4	2,31	399	146,65	403	90,50	15	3,87	487	102,41	502	58,17	0,60	0,20	1,80	1,43	1,25	1,64	1,56	1,37	1,77
80-84	8	8,53	218	136,19	226	89,01	9	3,91	317	94,93	326	57,82	2,18	0,84	5,64	1,44	1,21	1,71	1,54	1,30	1,82
85-89	2	4,18	92	109,31	94	71,22	8	5,51	157	71,26	165	45,15	0,76	0,16	3,57	1,53	1,19	1,98	1,58	1,22	2,03
90+	1	9,50	24	78,52	25	60,84	0	0,00	84	78,90	84	57,30	3813,16	0,00	NA	1,00	0,63	1,57	1,06	0,68	1,66
Total	87	3,16	6.369	158,46	6.456	95,29	190	0,65	14.809	52,77	14.999	26,24	4,84	3,75	6,23	3,01	2,92	3,10	3,63	3,53	3,74
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			1,70	1,65	1,76

Tablo Ek.26. 2019 yılındaki uterus kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Uterus Kanseri (ICD-O3: Topografi Kodu C54 ve alt kırılımları, Davranış kodu /3)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
15-19	0	0,01	0	0,00	0	0,01	0	0,00	3	0,10	3	0,05	245,84	0,00	NA	0,05	0,00	NA	0,12	0,00	NA
20-24	0	0,01	0	0,00	0	0,00	0	0,00	10	0,31	10	0,15	201,24	0,00	NA	0,01	0,00	NA	0,02	0,00	NA
25-29	0	0,00	3	4,44	3	3,32	0	0,00	30	0,98	30	0,48	140,30	0,00	NA	4,53	1,38	14,83	6,94	2,12	22,72
30-34	0	0,00	7	7,18	7	4,95	0	0,00	54	1,77	54	0,87	72,16	0,00	NA	4,05	1,84	8,89	5,70	2,59	12,52
35-39	0	0,00	14	9,25	14	5,85	0	0,00	90	2,90	90	1,42	36,84	0,00	NA	3,20	1,82	5,61	4,13	2,35	7,25
40-44	0	0,00	32	14,77	32	8,69	0	0,00	156	5,71	156	2,79	18,88	0,00	NA	2,59	1,77	3,79	3,12	2,13	4,56
45-49	0	0,00	92	27,20	92	15,75	0	0,00	215	8,88	215	4,34	10,28	0,00	NA	3,06	2,40	3,91	3,63	2,84	4,63
50-54	0	0,00	168	37,03	168	21,18	0	0,00	290	15,64	290	7,47	5,97	0,00	NA	2,37	1,96	2,86	2,84	2,34	3,43
55-59	0	0,00	265	45,56	265	26,38	0	0,00	320	19,63	320	9,45	4,15	0,00	NA	2,32	1,97	2,73	2,79	2,37	3,29
60-64	0	0,00	297	52,14	297	29,80	0	0,00	244	19,83	244	9,54	3,11	0,00	NA	2,63	2,22	3,12	3,12	2,64	3,70
65-69	0	0,00	298	57,43	298	33,11	0	0,00	231	25,60	231	12,67	2,42	0,00	NA	2,24	1,89	2,66	2,61	2,20	3,10
70-74	0	0,00	182	44,34	182	26,47	0	0,00	150	21,47	150	11,28	2,27	0,00	NA	2,07	1,66	2,56	2,35	1,89	2,91
75-79	0	0,00	79	29,04	79	17,74	0	0,00	76	15,98	76	8,81	2,24	0,00	NA	1,82	1,33	2,49	2,01	1,47	2,76
80-84	0	0,00	45	28,11	45	17,72	0	0,00	41	12,28	41	7,27	2,45	0,00	NA	2,29	1,50	3,50	2,44	1,60	3,72
85-89	0	0,00	9	10,69	9	6,82	0	0,00	23	10,44	23	6,29	3,03	0,00	NA	1,02	0,47	2,21	1,08	0,50	2,34
90+	0	0,01	4	13,09	4	9,74	0	0,00	4	3,76	4	2,73	3,81	0,00	NA	3,48	0,87	13,93	3,57	0,89	14,26
Total	0	0,00	1.495	37,19	1.495	22,07	0	0,00	1.937	6,90	1.937	3,39	10,56	0,00	NA	5,39	5,04	5,77	6,51	6,09	6,97
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			2,38	2,22	2,56

Tablo Ek.27. 2019 yılındaki over kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Over Kanserleri (ICD-O3: Topografi Kodu C56 ve alt kırılımları, Davranış kodu /3)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
15-19	0	0,01	1	4,85	1	2,96	0	0,00	18	0,59	18	0,29	245,84	0,00	NA	8,23	1,10	61,69	10,36	1,38	77,53
20-24	0	0,01	4	8,65	4	6,35	0	0,00	21	0,66	21	0,32	201,24	0,00	NA	13,12	4,50	38,22	19,83	6,81	57,78
25-29	0	0,00	2	2,96	2	2,21	0	0,00	25	0,82	25	0,40	140,30	0,00	NA	3,62	0,86	15,29	5,55	1,31	23,42
30-34	0	0,00	6	6,15	6	4,24	0	0,00	56	1,84	56	0,90	72,16	0,00	NA	3,34	1,44	7,76	4,71	2,03	10,93
35-39	0	0,00	9	5,95	9	3,76	0	0,00	57	1,83	57	0,90	36,84	0,00	NA	3,24	1,61	6,55	4,19	2,07	8,46
40-44	0	0,00	37	17,08	37	10,04	0	0,00	90	3,29	90	1,61	18,88	0,00	NA	5,19	3,54	7,61	6,25	4,26	9,16
45-49	0	0,00	46	13,60	46	7,88	0	0,00	133	5,49	133	2,69	10,28	0,00	NA	2,48	1,77	3,46	2,93	2,10	4,10
50-54	0	0,00	70	15,43	70	8,82	0	0,00	129	6,96	129	3,32	5,97	0,00	NA	2,22	1,66	2,97	2,66	1,98	3,55
55-59	0	0,00	62	10,66	62	6,17	0	0,00	104	6,38	104	3,07	4,15	0,00	NA	1,67	1,22	2,29	2,01	1,47	2,75
60-64	0	0,00	88	15,45	88	8,83	0	0,00	74	6,01	74	2,89	3,11	0,00	NA	2,57	1,89	3,50	3,05	2,24	4,16
65-69	0	0,00	61	11,75	61	6,78	0	0,00	64	7,09	64	3,51	2,42	0,00	NA	1,66	1,17	2,35	1,93	1,36	2,74
70-74	0	0,00	33	8,04	33	4,80	0	0,00	55	7,87	55	4,14	2,27	0,00	NA	1,02	0,66	1,57	1,16	0,75	1,79
75-79	0	0,00	14	5,15	14	3,14	0	0,00	21	4,42	21	2,43	2,24	0,00	NA	1,17	0,59	2,29	1,29	0,66	2,54
80-84	0	0,00	13	8,12	13	5,12	0	0,00	12	3,59	12	2,13	2,45	0,00	NA	2,26	1,03	4,95	2,41	1,10	5,27
85-89	0	0,00	0	0,00	0	0,00	0	0,00	4	1,82	4	1,09	3,03	0,00	NA	0,00	0,00	NA	0,00	0,00	NA
90+	0	0,01	3	9,82	3	7,30	0	0,00	3	2,82	3	2,05	3,81	0,00	NA	3,48	0,70	17,26	3,57	0,72	17,67
Total	0	0,00	449	11,17	449	6,63	0	0,00	866	3,09	866	1,51	10,56	0,00	NA	3,62	3,23	4,06	4,38	3,90	4,90
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			2,26	2,00	2,54

Tablo Ek.28. 2019 yılındaki prostat kanseri vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Prostat Kanseri (ICD-O3: Topografi Kodu C61 ve alt kırılımları, Davranış kodu /3)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
15-19	0	0,01	0	0,00	0	0,01	0	0,00	0	0,00	0	0,00	245,84	0,00	NA	148,22	0,00	NA	186,30	0,00	NA
20-24	0	0,01	0	0,00	0	0,00	0	0,00	0	0,00	0	0,00	201,24	0,00	NA	68,87	0,00	NA	104,10	0,00	NA
25-29	0	0,00	0	0,00	0	0,00	1	0,03	0	0,00	1	0,02	0,14	0,00	NA	45,26	0,00	NA	0,14	0,00	NA
30-34	0	0,00	0	0,00	0	0,00	1	0,03	0	0,00	1	0,02	0,07	0,00	NA	31,21	0,00	NA	0,09	0,00	NA
35-39	2	2,28	0	0,00	2	0,84	5	0,15	0	0,00	5	0,08	14,74	2,86	75,96	20,54	0,00	NA	10,62	2,06	54,70
40-44	2	1,32	0	0,00	2	0,54	20	0,70	0	0,00	20	0,36	1,89	0,44	8,08	12,62	0,00	NA	1,52	0,36	6,50
45-49	28	11,39	0	0,00	28	4,79	113	4,47	0	0,00	113	2,28	2,55	1,68	3,85	7,16	0,00	NA	2,10	1,39	3,18
50-54	135	39,74	0	0,00	135	17,02	405	19,97	0	0,00	405	10,43	1,99	1,64	2,42	4,09	0,00	NA	1,63	1,34	1,98
55-59	386	91,29	0	0,00	386	38,43	1.050	59,81	0	0,00	1.050	31,01	1,53	1,36	1,72	2,80	0,00	NA	1,24	1,10	1,39
60-64	880	206,08	0	0,00	880	88,29	1.747	131,60	0	0,00	1.747	68,29	1,57	1,45	1,70	2,16	0,00	NA	1,29	1,19	1,40
65-69	1.209	317,29	0	0,00	1.209	134,34	2.148	233,39	0	0,00	2.148	117,85	1,36	1,27	1,46	1,74	0,00	NA	1,14	1,06	1,22
70-74	986	355,63	0	0,00	986	143,38	1.829	290,04	0	0,00	1.829	137,60	1,23	1,14	1,33	1,70	0,00	NA	1,04	0,96	1,13
75-79	636	367,17	0	0,00	636	142,83	1.160	299,37	0	0,00	1.160	134,41	1,23	1,11	1,35	1,75	0,00	NA	1,06	0,96	1,17
80-84	256	272,80	0	0,00	256	100,82	601	261,43	0	0,00	601	106,59	1,04	0,90	1,21	2,09	0,00	NA	0,95	0,82	1,09
85-89	97	202,81	0	0,00	97	73,49	345	237,75	0	0,00	345	94,41	0,85	0,68	1,07	2,62	0,00	NA	0,78	0,62	0,97
90+	14	132,97	0	0,00	14	34,07	54	134,51	0	0,00	54	36,83	0,99	0,55	1,78	3,48	0,00	NA	0,92	0,51	1,67
Total	4.631	168,06	0	0,00	4.631	68,35	9.479	32,57	0	0,00	9.479	16,58	5,17	4,99	5,35	6,98	0,00	NA	4,12	3,98	4,27
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			1,35	1,30	1,40

Tablo Ek.29. 2019 yılındaki diğer malignite vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Diğer Malign Kanserler (ICD-O3: Lenfomalar ile tablolarda verilen Malign Solid Tümörler hariç tümü, davranış kodu /3)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde									
15-19	61	462,61	37	179,45	98	289,90	380	11,72	290	9,49	670	10,64	39,64	30,24	51,98	18,94	13,45	26,68	27,33	22,10	33,79
20-24	66	393,47	42	90,80	108	171,36	557	16,50	444	13,94	1.001	15,26	23,94	18,54	30,91	6,52	4,75	8,95	11,25	9,22	13,72
25-29	72	313,93	65	96,17	137	151,35	646	20,08	606	19,81	1.252	19,95	15,68	12,29	20,01	4,86	3,76	6,28	7,60	6,37	9,06
30-34	102	231,66	104	106,63	206	145,52	735	23,13	934	30,68	1.669	26,83	10,04	8,16	12,35	3,48	2,84	4,26	5,43	4,70	6,28
35-39	157	178,68	193	127,54	350	146,33	831	25,67	1.347	43,33	2.178	34,32	6,97	5,88	8,27	2,95	2,53	3,43	4,27	3,81	4,78
40-44	210	138,39	384	177,27	594	161,25	927	32,35	1.647	60,24	2.574	45,97	4,28	3,69	4,97	2,95	2,64	3,29	3,51	3,21	3,84
45-49	398	161,91	694	205,15	1.092	186,95	1.129	44,68	1.995	82,36	3.124	63,12	3,63	3,24	4,07	2,49	2,29	2,72	2,97	2,77	3,18
50-54	677	199,30	981	216,23	1.658	208,98	1.477	72,83	1.997	107,71	3.474	89,49	2,74	2,50	3,00	2,01	1,86	2,17	2,34	2,21	2,48
55-59	1.044	246,90	1.435	246,71	2.479	246,79	2.029	115,57	2.032	124,67	4.061	119,95	2,14	1,99	2,31	1,98	1,85	2,12	2,06	1,96	2,17
60-64	1.363	319,19	1.610	282,63	2.973	298,30	2.113	159,17	1.848	150,17	3.961	154,84	2,01	1,88	2,15	1,88	1,76	2,02	1,93	1,84	2,02
65-69	1.501	393,92	1.639	315,84	3.140	348,90	2.105	228,72	1.661	184,07	3.766	206,62	1,73	1,61	1,84	1,72	1,60	1,84	1,69	1,61	1,77
70-74	1.180	425,61	1.255	305,78	2.435	354,09	1.709	271,01	1.354	193,81	3.063	230,43	1,57	1,46	1,69	1,58	1,46	1,71	1,54	1,46	1,62
75-79	791	456,65	841	309,11	1.632	366,50	1.212	312,79	999	210,08	2.211	256,20	1,46	1,34	1,60	1,47	1,34	1,61	1,43	1,34	1,53
80-84	364	387,89	444	277,38	808	318,22	749	325,81	642	192,26	1.391	246,71	1,19	1,05	1,35	1,44	1,28	1,63	1,29	1,18	1,41
85-89	168	351,27	177	210,30	345	261,38	421	290,12	385	174,76	806	220,57	1,21	1,01	1,45	1,20	1,01	1,44	1,19	1,04	1,35
90+	19	180,45	50	163,59	69	167,91	87	216,71	153	143,71	240	163,70	0,83	0,51	1,37	1,14	0,83	1,57	1,03	0,78	1,34
Total	8.173	296,59	9.951	247,57	18.124	267,51	17.107	58,77	18.334	65,33	35.441	61,99	5,06	4,93	5,19	3,80	3,70	3,89	4,32	4,25	4,40
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			2,09	2,05	2,13

Tablo Ek.30. 2019 yılındaki toplam malignite vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Toplam Malign Neoplazmlar																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	Komorb. Hast. n	İnsidans Yüzbinde	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
15-19	78	591,54	52	252,19	130	384,56	562	17,34	564	18,45	1.126	17,88	34,32	27,06	43,52	13,70	10,31	18,20	21,59	18,00	25,89
20-24	90	536,54	90	194,58	180	285,59	839	24,85	970	30,45	1.809	27,57	21,70	17,45	26,98	6,40	5,16	7,95	10,38	8,91	12,11
25-29	111	483,98	133	196,79	244	269,55	1.042	32,38	1.553	50,77	2.595	41,34	15,01	12,34	18,27	3,88	3,25	4,63	6,53	5,73	7,45
30-34	170	386,10	287	294,25	457	322,82	1.317	41,45	2.672	87,78	3.989	64,12	9,35	7,97	10,97	3,36	2,97	3,79	5,05	4,58	5,56
35-39	321	365,33	630	416,32	951	397,59	1.844	56,97	4.379	140,86	6.223	98,07	6,43	5,71	7,24	2,96	2,73	3,22	4,07	3,80	4,35
40-44	548	361,13	1.160	535,50	1.708	463,67	2.361	82,40	5.923	216,65	8.284	147,95	4,39	4,00	4,82	2,48	2,33	2,64	3,14	2,98	3,31
45-49	1.168	475,14	2.173	642,34	3.341	571,98	3.594	142,22	6.829	281,91	10.423	210,59	3,35	3,14	3,58	2,29	2,18	2,40	2,73	2,62	2,83
50-54	2.335	687,39	3.020	665,67	5.355	674,97	5.422	267,37	6.485	349,76	11.907	306,72	2,58	2,46	2,71	1,91	1,83	1,99	2,21	2,14	2,28
55-59	4.332	1024,48	4.357	749,08	8.689	865,01	8.440	480,75	6.449	395,67	14.889	439,79	2,14	2,07	2,22	1,90	1,83	1,97	1,98	1,92	2,03
60-64	6.230	1458,94	4.796	841,93	11.026	1106,29	10.533	793,46	5.662	460,09	16.195	633,09	1,85	1,79	1,91	1,84	1,77	1,91	1,76	1,71	1,80
65-69	7.088	1860,16	4.627	891,64	11.715	1301,71	10.811	1174,69	4.972	550,99	15.783	865,91	1,59	1,55	1,64	1,62	1,56	1,69	1,51	1,47	1,55
70-74	5.617	2025,96	3.823	931,47	9.440	1372,74	8.794	1394,55	3.984	570,25	12.778	961,30	1,46	1,41	1,51	1,64	1,57	1,71	1,43	1,40	1,47
75-79	3.601	2078,90	2.462	904,90	6.063	1361,58	5.907	1524,47	2.987	628,14	8.894	1030,58	1,37	1,32	1,43	1,44	1,37	1,52	1,33	1,28	1,37
80-84	1.574	1677,31	1.323	826,52	2.897	1140,96	3.180	1383,26	1.979	592,64	5.159	915,01	1,22	1,14	1,29	1,40	1,30	1,50	1,25	1,19	1,31
85-89	687	1436,43	558	662,98	1.245	943,23	1.745	1202,53	1.116	506,57	2.861	782,94	1,20	1,10	1,31	1,31	1,18	1,45	1,21	1,13	1,29
90+	83	788,30	172	562,75	255	620,54	300	747,29	447	419,86	747	509,52	1,06	0,83	1,35	1,34	1,13	1,60	1,22	1,06	1,41
Total	34.033	1235,04	29.663	737,99	63.696	940,15	66.691	229,13	56.971	203,02	123.662	216,31	5,44	5,37	5,52	3,65	3,60	3,71	4,38	4,34	4,42
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			1,87	1,85	1,89

Tablo Ek.31. 2019 yılındaki benign, insitu ve davranışı bilinmeyen neoplazm vakalarının diyabetik ve diyabetik olmayan popülasyonda cinsiyet ve yaş gruplarına göre insidans ve odss oranları dağılımı

Benign, İnsitu ve Davranışı Bilinmeyen Neoplazmlar (ICD-O3: Tüm topografilerde, davranış kodu/0/1/2 olan benign neoplazmlar)																					
Yaş Grubu	2019 Diyabetes Mellituslu						2019 Diyabetes Mellitusu Olmayan						Odss Oranı								
	Erkek		Kadın		Toplam		Erkek		Kadın		Toplam		Erkek			Kadın			Toplam		
	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	Komorb. Hast.	İnsidans	OO	95% LL	95% UL	OO	95% LL	95% UL	OO	95% LL	95% UL
	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde	n	Yüzbinde									
15-19	62	470,20	117	567,44	179	529,51	4.667	143,97	7.261	237,59	11.928	189,40	3,28	2,55	4,21	2,40	2,00	2,88	2,81	2,42	3,25
20-24	85	506,74	509	1100,47	594	942,45	7.012	207,73	15.312	480,69	22.324	340,25	2,45	1,97	3,03	2,30	2,11	2,52	2,79	2,57	3,02
25-29	135	588,62	1.001	1481,08	1.136	1254,96	7.711	239,64	22.980	751,21	30.691	488,96	2,46	2,08	2,92	1,99	1,86	2,12	2,59	2,44	2,75
30-34	291	660,91	1.625	1666,07	1.916	1353,44	8.570	269,72	29.105	956,11	37.675	605,57	2,46	2,19	2,77	1,76	1,67	1,85	2,25	2,15	2,36
35-39	586	666,92	2.710	1790,82	3.296	1377,97	10.025	309,71	34.326	1104,17	44.351	698,92	2,16	1,99	2,35	1,63	1,57	1,70	1,99	1,92	2,06
40-44	1.061	699,19	4.381	2022,44	5.442	1477,34	9.839	343,40	34.539	1263,38	44.378	792,60	2,04	1,92	2,18	1,61	1,56	1,67	1,88	1,82	1,93
45-49	1.738	707,01	6.961	2057,68	8.699	1489,26	9.484	375,30	33.113	1366,93	42.597	860,64	1,89	1,80	1,99	1,52	1,48	1,56	1,74	1,70	1,78
50-54	2.712	798,37	7.457	1643,68	10.169	1281,75	9.492	468,07	21.366	1152,35	30.858	794,90	1,71	1,64	1,79	1,43	1,40	1,47	1,62	1,58	1,66
55-59	3.999	945,73	7.484	1286,68	11.483	1143,16	10.195	580,71	15.074	924,85	25.269	746,39	1,63	1,58	1,70	1,40	1,36	1,44	1,54	1,50	1,57
60-64	4.786	1120,79	6.581	1155,29	11.367	1140,51	9.272	698,47	10.363	842,09	19.635	767,56	1,61	1,56	1,67	1,38	1,33	1,42	1,49	1,46	1,53
65-69	4.778	1253,93	5.461	1052,36	10.239	1137,70	7.926	861,21	7.414	821,61	15.340	841,61	1,46	1,41	1,52	1,28	1,24	1,33	1,36	1,32	1,39
70-74	3.557	1282,95	3.632	884,93	7.189	1045,40	5.707	905,01	4.730	677,03	10.437	785,19	1,42	1,36	1,48	1,31	1,25	1,37	1,33	1,30	1,38
75-79	2.082	1201,96	2.078	763,77	4.160	934,22	3.478	897,60	2.796	587,97	6.274	726,99	1,34	1,27	1,42	1,30	1,23	1,38	1,29	1,24	1,34
80-84	924	984,64	904	564,76	1.828	719,94	1.778	773,41	1.481	443,51	3.259	578,02	1,28	1,18	1,38	1,27	1,17	1,39	1,25	1,18	1,32
85-89	361	754,80	361	428,91	722	547,00	895	616,77	748	339,53	1.643	449,62	1,23	1,08	1,39	1,26	1,11	1,43	1,22	1,12	1,33
90+	67	636,34	83	271,56	150	365,03	174	433,43	274	257,36	448	305,57	1,47	1,11	1,95	1,06	0,83	1,35	1,20	0,99	1,44
Total	27.224	987,94	51.345	1277,42	78.569	1159,68	106.225	364,96	240.882	858,40	347.107	607,17	2,72	2,69	2,76	1,49	1,48	1,51	1,92	1,91	1,94
Yaş ve Cinsiyete Göre Ağırlıklandırılmış Odss Oranı																			1,52	1,51	1,53

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı	Mustafa Mahir	Uyruğu	T.C.
Soyadı	ÜLGÜ	Tel no	
Doğum Tar.		e-posta	

Eğitim Bilgileri

Mezun olduğu kurum		Mezuniyet yılı
Lise	Sultandağı Lisesi	1984
Lisans	Anadolu Üniversitesi Tıp Fakültesi	1992
Yüksek Lisans	Gazi Üniversitesi Sosyal Bilimler Enstitüsü Hastane İşletmeciliği	2005
Doktora		

İş Deneyimi

Görevi	Kurum	Süre (yıl-yıl)
Tabip	Şirvan Merkez Sağlık Ocağı SİİRT	1992-1993
Tabip	Yunus Emre Sağlık Ocağı ESKİŞEHİR	1994-1995
Tabip	Çubuk Sağlık Grup Başkanlığı ANKARA	1996-1997
Tabip	T.C.S.B. Bilgi İşlem Daire Bşk.lığı	1998-2011
Daire Bşk. V.	T.C.S.B. Sağlık Bilgi Sist. Genel Müdürlüğü	2012-2013
Genel Md. V.	T.C.S.B. Sağlık Bilgi Sist. Genel Müdürlüğü	2014- Halen

Yabancı Dilleri	Sınav türü	Puanı
İngilizce	YÖKDİL	60.00

Yayınlar ve Bildiriler:

Birinci S., Ulgu M.M., at all, "Conducting risk assessments and case detection in online environments in the scope of fight with COVID-19: A good practice example diabetes: A cross-sectional study", Vol: 9(2), 183-187, 2022, doi.org/10.14744/nci.2022.92979, North Clin Istanbul

Sebik N., Feyzioğlu B., Ülgü M., "COVID-19 Pandemisinde Türkiye’de Tele Sağlık Hizmetleri”, XIII. Tıp Bilişimi Kongresi, 24-27 Mart 2021, Ankara

Kose I., Rayner J., Birinci S., Ulgu M.M., at all, "Adoption rates of electronic health records in Turkish Hospitals and the relation with hospital sizes", 2020, doi.org/10.1186/s12913-020-05767-5, BMC Health Service Research

İşleyen F., Ulgu M.M., "Data Transfer Model for HIS and Developers Opinions in Turkey. Studies in Health Technology and Informatics", 2020; 270:557-561. doi:10.3233/SHTI200222

İşleyen F., Başara B.B., Ülgü M.M., "Uluslararası Hastalık sınıflandırılmasında Yeni Revizyon: ICD-11", XII. Tıp Bilişimi Kongresi, 15-16 Kasım 2019, Ankara

İşleyen F., Yıldırım M.A., Muş E., Aydın Ş., Ülgü M.M., "Hastanelerde Veri Aktarım Süreçlerinde Kullanılabilecek Veri Modeli Geliştirilmesi ve Türkiye’de HBYS Yazılımlarının Modele Uyumluları", XI. Tıp Bilişimi Kongresi, 16-17 Kasım 2018, Ankara

Kiciman M., Ulgu M.M., Nisanci C., "A Significant Project Of Health Transformation Program "Centralized Doctor Appointment System", Poster, XI. Tıp Bilişimi Kongresi, 2018, Ankara

İşleyen F., Şenol U., Özmen M., Dicle O., Yıldırım M.A., Muş E., Aydın Ş., Ülgü M.M., "Bütünleşik Radyoloji Raporu Standardı", X. Tıp Bilişimi Kongresi, 13-14 Ekim 2017, Antalya

Ülgü M.M., Gürel Gökçay Ö., Büyük Veri ve Açık Veri Analitiği: Yöntemler ve Uygulamalar, Sağlık Bakanlığında Büyük Veri Çalışmaları (Kitap Bölümü), Grafiker Yayınları, 2017, Ankara

Ülgü M.M., “Sağlık Bakanlığında Kişisel Verilerin Toplanması, Saklanması, İşlenmesi ve Paylaşılması Neden ve Nasıl Yapılıyor?” Türk Dış Hekimleri Birliği Eğitim Dizisi-18, 2013, Ankara

Gokcen H., Ulgu M.M., Demirel N., “Analysing Interactions of Risk Factors According to Risk Levels for Hemodialysis Patients in Turkey: A Data Mining Application”, GUJS, Gazi University Journal of Science, 2011, Ankara

Ulgu M.M., Aldas C.N., “Development and Implementation of an Enterprise Resource Management System in Ministry of Health of Turkey”, The International e-Health 2011, IADIS, Telemedicine and Health Ict Forum, 2011, Luxemburg

Ulgu M.M., “Process of Development of Hospital Information Systems in Turkey”, EH 2011, IADIS, e-Health 2011, General Conference, 2011, Rome, Italy

Ulgu M.M., “Republic of Turkey Ministry of Health Telemedicine Project”, MCCSIS 2011, IADIS, Multi Conference on Computer Science and Information Systems, Albert Ludwigs Universty, 2011, Freiburg, Germany

Goktas B., Ulgu M.M., “Determination of Job Satisfaction Levels of Midwives and Nurses”, ATINER, IX. International Health Economics Conference, 2010, Athens, Greece

Esatoglu E., Goktas B., Ulgu M.M., “Health Technology Assesment: A European Collaboration” Poster: ISPOR 13th Annual European Congress 2010, Prague, Czech Republic

Keser L, Ülgü M.M., Er C., Elektronik Sağlık Kayıtları ve Özel Hayatın Gizliliği, İstanbul Bilgi Üniversitesi Yayınları, 2009, İstanbul

Ülgü M.M., “Elektronik Sağlık Kayıtları ve Mahremiyet”, Ankara Barosu Dergisi, 2009, Ankara

Göktaş B., Ülgü M.M., “Devlet Hastanelerinde Bilgi Sistemlerinin Yönetimi”, SHY2009, VII. Uluslararası Sağlık ve Hastane Yönetimi Kongresi, 2009, Girne, K.K.T.C.

Göktaş B., Ülgü M.M., “Hastane Bilgi Sistemlerinin Yönetimi”, Sağlık ve Hastane İdaresi Kongresi 2008, Antalya

Ülgü M.M., Göktaş B., “Devlet Hastanelerindeki Bilgi Sistemleri ve Dış Kaynak Kullanımı”, SHY2007, Uluslararası Sağlık ve Hastane Yönetimi Kongresi, 2007, Lefkoşa, K.K.T.C.

Tengilimoğlu D., Ulgu M.M., Oztürk Y., “Comparison of Computing Capability and Information System Abilities of State Hospitals Owned by Ministry of Labor and Social Security and Ministry of Health”, 2006, JMS Journal of Medical Systems

Ülgü M.M., Yüksek Lisans Tezi, Hastane Bilgi Sistemleri-Döner Sermaye İlişkisi, Gazi Üniversitesi Sosyal Bilimleri Enstitüsü, 2005, Ankara