T.C.

AKDENİZ ÜNİVERSİTESİ

ELEKTRİKLİ ARAÇLARIN DEĞİŞKEN YOL ŞARTLARI VE MOTOR PARAMETRELERİNDEKİ MOTOR HATASININ DERİN ÖĞRENME İLE TAHMİNİ

Umut KİTİŞ

FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ

ANABİLİM DALI

DOKTORA TEZİ

ARALIK 2025

ANTALYA

T.C.

AKDENİZ ÜNİVERSİTESİ

ELEKTRİKLİ ARAÇLARIN DEĞİŞKEN YOL ŞARTLARI VE MOTOR PARAMETRELERİNDEKİ MOTOR HATASININ DERİN ÖĞRENME İLE TAHMİNİ

Umut KİTİŞ

FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ

ANABİLİM DALI

DOKTORA TEZİ

ARALIK 2025

ANTALYA

Evrak Tarih ve Sayısı: 29.12.2025-851

T.C.

AKDENİZ ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİKLİ ARAÇLARIN DEĞİŞKEN YOL ŞARTLARI VE MOTOR PARAMETRELERİNDEKİ MOTOR HATASININ DERİN ÖĞRENME İLE TAHMİNİ

Umut KİTİŞ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ

ANABİLİM DALI

DOKTORA TEZİ

Bu tez 19/12/2025 tarihinde jüri tarafından Oybirliği ile kabul edilmiştir.

Prof. Dr. Övünç POLAT (Danışman)

Prof. Dr. Ömer Halil ÇOLAK

Doç. Dr. Umut TİLKİ

Dr. Öğr. Üyesi Sıtkı GÜNER

Dr. Öğr. Üyesi Hakan AKTAŞ

Bu belge, güvenli elektronik İmza ile imzalanmıştır.
Evrak sorgulaması https://turkiye.gov.tr/ebd?eK=5543&eD=BSRUTAP6ZP&eS=851 adresinden yapılabilir. (PIN:83303)

ÖZET

ELEKTRİKLİ ARAÇLARIN DEĞİŞKEN YOL ŞARTLARI VE MOTOR PARAMETRELERİNDEKİ MOTOR HATASININ DERİN ÖĞRENME İLE TAHMİNİ

Umut KİTİŞ

Doktora Tezi, Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Övünç POLAT

Aralık 2025; 63 sayfa

Çevre kirliliğinin geri dönülemez seviyelere ulaşması, dünyanın yenilenebilir ve çevre dostu teknolojilere yönelmesine, buna bağlı olarak da petrol bazlı ulaşım araçlarının yerini elektrikli araçlara bırakmaya başlamasına yol açmıştır. Elektrikli araçların petrol bazlı araçlara oranla çok daha düşük karbon salınımı yapması ve ekonomik olarak daha elverişli olması gibi sebeplerden dolayı son yıllarda elektrikli araçlar yaygınlaşmış ve araç piyasasında önemli rol almaya başlamışlardır.

Elektrikli araçlarda kullanılan asenkron motorlarda yol koşullarına ve sıcaklık değişimine bağlı olarak, motor direnç değerlerinde değişim meydana gelir ve bu değişim asenkron motorun verimini etkiler. Aracın bulunduğu yolun yokuş yukarı ya da yokuş aşağı olması, yol yüzey koşulları gibi durumlara göre motorda kararsızlıklar meydana gelecek, kayıplar değişecek ve buna bağlı alarak da sıcaklık değerleri farklılık gösterecektir. Çalışmanın amacı, bu değişimlerin farklı direnç ve termal koşullar için elektrikli araç üzerindeki etkisini hesaplamak ve bu etkileri farklı sinir ağı yapıları kullanarak incelemektir.

Çalışmada, değişen direnç ve termal parametrelerin motor üzerindeki etkilerini gözlemlemek için bir asenkron motor ve termal devresi modellenmiştir. Daha sonra stator sargılarının termal kütlesi değiştirilmiş, değiştirilen termal kütlenin nüve hacmini ve buna bağlı olarak demir kayıplarını etkileyip etkilememesine göre 2 farklı model geliştirilmiştir. Sistemin çıkışları, asenkron motor verimine ve motor sıcaklığına göre başarılı veya başarısız olarak etiketlenmiştir. Sinir ağları için kullanılacak olan veri kümeleri, farklı stator dirençleri ve farklı termal kütleler için sistemin tork ve tork-hız sinyal görüntüleri alınarak oluşturulmuştur. Çalışmada ayrıca, farklı sinir ağı mimarilerinin aynı veriler için performansları değerlendirilmiştir. Oluşturulan verileri sınıflandırmak için probleme özgü tasarlanan CNN ve yine probleme özgü tasarlanan 1DCNN ağ mimarileri ile birlikte, ön eğitimli ağ yapısına sahip olan GoogLeNet kullanılmıştır. Asenkron motor ve termal devrenin modellenmesi MATLAB/Simulink ortamında oluşturulmuştur. Sinir ağları uygulamasında, Spyder IDE aracılığıyla Python programlama dili kullanılmıştır. Veri artırma yöntemi, probleme özgü tasarlanan CNN ve ön eğitimli GoogLeNet ağ yapıları için kullanılırken, k-katlı çapraz doğrulama (k-fold cross validaiton) tüm ağ yapılarına uygulanmıştır. Tüm ağ yapıları farklı katmanlar ve farklı fold sayıları için test edilmiştir.

Çalışmada programa özgü tasarlanan CNN ve 1DCNN ağ yapıları için en yüksek tahmin başarı oranı sırasıyla %86 ve %99'dur.

ANAHTAR KELİMELER: 1DCNN, Arıza Tespiti, Asenkron Motorlar, CNN, Elektrikli Araçlar, GoogLeNet, Python

JÜRİ: Prof. Dr. Övünç POLAT

Prof. Dr. Ömer Halil ÇOLAK

Doç. Dr. Umut TİLKİ

Dr. Öğr. Üyesi Sıtkı GÜNER

Dr. Öğr. Üyesi Hakan AKTAŞ

ABSTRACT

PREDICTION OF FAULT DIAGNOSIS OF ELECTRIC VEHICLES IN VARIABLE ROAD CONDITIONS AND ENGINE PARAMETERS WITH DEEP LEARNING

Umut KİTİŞ

PhD Thesis in Electrical and Electronics Engineering

Supervisor: Prof. Dr. Övünç POLAT

December 2025; 63 pages

The irreversible extent of environmental pollution has led the world to turn toward renewable and eco-friendly technologies and consequently, petroleum-based transportation vehicles have begun to be replaced by electric vehicles. Due to factors such as significantly lower carbon emissions compared to petroleum-based vehicles and greater economic efficiency, electric vehicles have become increasingly widespread in recent years and have started to play an important role in the automotive market.

In asynchronous motors used in electric vehicles, variations in road conditions and temperature, lead to changes in the motor's resistance values, and these changes affect the efficiency of the asynchronous motor. Depending on whether the vehicle is operating on an uphill or downhill road and road surface conditions, the losses occurring in the motor will vary, and accordingly, the motor temperature will change. The aim of the study is to calculate the effect of these changes on the electric vehicle for different resistance and thermal conditions and to examine them using different neural network structures.

In this study, an asynchronous motor and its thermal circuit were modeled to observe the effects of the changing resistance and thermal parameters on the motor. Subsequently, the thermal mass of the stator windings was changed and two different models were developed depending on whether the changed thermal mass affected the core volume and consequently, the iron losses. The system outputs were labeled as Efficient or Inefficient according to the asynchronous motor efficiency and the temperature of the motor. Datasets were created by taking the torque and torque-speed signal images of the system for different stator resistances and different thermal masses. The study also evaluated the performance of different neural network architectures for the same data. To classify the generated data, custom CNN and custom 1DCNN network architectures were used, along with GoogLeNet, which has a pre-trained network structure. MATLAB/Simulink was used to create the model of the asynchronous motor and thermal circuit. Neural networks were created using the Python programming language via Spyder IDE. Data augmentation was employed for the custom CNN and the pre-trained GoogLeNet architectures while k-fold cross validation was applied to all network architectures. All network architectures were tested using different layer configurations and different numbers of folds.

The highest classification accuracies achieved were 86% for the custom CNN and 99% for the custom 1DCNN network architectures.

KEYWORDS: 1DCNN, Asynchronous Motors, CNN, Fault Diagnosis, Electric Vehicles, GoogLeNet, Python

COMMITTEE: Prof. Dr. Övünç POLAT

Prof. Dr. Ömer Halil ÇOLAK

Assoc. Prof. Dr. Umut TİLKİ

Asst. Prof. Dr. Sıtkı GÜNER

Asst. Prof. Dr. Hakan AKTAŞ

ÖNSÖZ

Günümüz dünyasında elektrikli araçların kullanımı, çevre dostu ve ekonomik oluşları gibi nedenlerden dolayı hızla artmış, üreticilerin ve kullanıcıların petrol kaynaklı araçlar yerine elektrikli araçlara yönelmesine neden olmuştur. Elektrikli araçlarda, değişen yol koşulları araç motorunda sıcaklık artışına ve buna bağlı olarak stator direncinin değişimine neden olmakta, bu da elektrikli araçlarda verim düşüşüne sebebiyet vermektedir. Bu çalışmada aracın farklı yol koşullarında maruz kalacağı sıcaklık ve direnç değişimlerinin araca etkisi araştırılmıştır. Çalışmanın amacı, elektrikli araçların değişken yol koşullarında sürücülere daha dengeli ve konforlu bir sürüş sunmasını sağlamak ve ekonomik açıdan daha olumlu sonuçlar elde edilmesine katkıda bulunmaktır.

Bana bu konuda ilk kez çalışma olanağı veren, 2021 yılında kaybettiğimiz danışmanım merhum Dr. Öğr. Üyesi Yavuz ÜSER'e, şu an danışmanlığımı yürüten ve hiçbir zaman desteklerini esirgemeyen Prof. Dr. Övünç POLAT'a (Akdeniz Üniversitesi Mühendislik Fakültesi) teşekkürlerimi sunarım.

Çalışmam süresince beni destekleyen, her zaman yanımda olan ve beni bu günlere getiren annem Hadiye KİTİŞ, babam Hasan KİTİŞ, abim Mehmet Barış KİTİŞ, anneannem Nezahat EROL ve dayım Süleyman EROL'a, desteklerini her zaman hissettiğim arkadaşlarıma çok teşekkür ederim.

İÇİNDEKİLER

ÖZET i
ABSTRACT iii
ÖNSÖZ v
AKADEMİK BEYAN viii
SİMGELER VE KISALTMALAR ix
ŞEKİLLER DİZİNİ xii
ÇİZELGELER DİZİNİ xiv
1. GİRİŞ 1
2. KAYNAK TARAMASI 4
3. MATERYAL VE METOT 14
3.1. Asenkron Motor ve Asenkron Motor Termal Devresinin Birinci Modelinin Oluşturulması 14
3.1.1. Asenkron Motorun Birinci Modelinin Simulink Üzerinde Oluşturulması 14
3.1.2. Asenkron Motor Termal Devresinin Birinci Modelinin Simulink Üzerinde Oluşturulması 18
3.1.3. Birinci Model İçin Termal Kütle Değerlerinin Girilmesi 23
3.1.4. Birinci Model İçin Direnç-Sıcaklık İlişkisinin Kurulması ve Derin Öğrenme Veri Setlerinin Genişletilmesi 24
3.2. Asenkron Motor ve Asenkron Motor Termal Devresinin İkinci Modelinin Oluşturulması 31
3.2.1. İkinci Model İçin Stator Sargılarının Termal Kütlesinin Artırılması 31
3.2.2. Asenkron Motorun İkinci Modelinin Simulink Üzerinde Oluşturulması 36
3.2.3. Asenkron Motor Termal Devresinin İkinci Modelinin Simulink Üzerinde Oluşturulması 37
3.3. Çalışmada Oluşturulan ve Kullanılan Derin Öğrenme Yapıları 37
3.3.1. Evrişimsel Sinir Ağı Yapısı 37
3.3.2. Bir Boyutlu Evrişimsel Sinir Ağı (1DCNN) Yapısı 45
3.3.3. GoogLeNet Yapısı 46
3.4. Veri Arttırma ve Çapraz Doğrulama 46

4. BULGULAR VE TARTIŞMA 49
5. SONUÇLAR 56
6.KAYNAKLAR 59
ÖZGEÇMİŞ

AKADEMİK BEYAN

Doktora Tezi olarak sunduğum “Elektrikli Araçların Değişken Yol Şartları ve Motor Parametrelerindeki Motor Hatasının Derin Öğrenme ile Tahmini” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

19/12/2025

Umut KİTİŞ

SİMGELER VE KISALTMALAR

Simgeler

%	: Yüzde
°	: Derece
Ω	: Ohm
°C	: Derece Celcius
°K	: Derece Kelvin
A	: Kesit Alanı
d	: Özkütle
I	: Akım
I_r	: Rotor Akımı
I_s	: Stator Akımı
i	: Faz Akımı
i_{as}	: A Fazının Stator Akımı
kg	: Kilogram
L	: Uzunluk
m	: Kütle
ρ	: Özdirenç
P_{Cu}	: Bakır Kaybı
P_{Fe}	: Demir Kaybı
P_{loss}	: Toplam Kayıp
P_{Mec}	: Mekanik Güç
P_R	: Gerçek Güç
R	: Direnç
R_{Eski}	: Eski Direnç Değeri

R_r : Rotor Direnci

R_s : Stator Direnci

R_{Yeni} : Yeni Direnç Değeri

T : Tork

T_e : Elektromanyetik Tork

T_m : Mekanik Tork

V : Hacim

V_{Rms} : Gerilimin Ortalama Karekök Değeri

w : Motor Hız Çıkışı

w_{Rpm} : Dakikadaki Motor Dönüş Hızı

$w_{rad/sn}$: Radyan Cinsinden Saniyedeki Dönüş Hızı

Bu tez çalışmasında ondalık ayracı olarak nokta (“.”) kullanılmıştır.

Kısaltmalar

1DCNN : Bir Boyutlu Evrişimsel Sinir Ağı

AC : Alternatif Akım

ANN : Yapay Sinir Ağı

BLDC : Fırçasız Doğru Akım Motoru

CA-CNN : Kanal Dikkat Mekanizmasına Dayalı Evrişimsel Sinir Ağı

CNN : Evrişimsel Sinir Ağı

CRNN : Evrişimsel Yinelemeli Sinir Ağı

DC : Doğru Akım

DNN : Derin Sinir Ağları

FDD : Arıza Tespiti ve Teşhisi

FEA : Sonlu Elemanlar Analizi

FLC : Bulanık Mantık Denetleyicisi

IDE : Entegre Geliştirme Ortamı

IPMSM	: Dahili Kalıcı Mıknatıslı Senkron Motorlar
ITSF	: Sarımlar Arası Kısa Devre Arızaları
LPTN	: Toplu Parametreli Termal Ağlar
LSTM	: Uzun Kısa Süreli Bellek
Nm	: Newton-metre
PMSM	: Kalıcı Mıknatıslı Senkron Motorlar
PSO	: Parçacık Sürü Algoritması
Rad	: Radyan
RBF	: Radyal Baz Fonksiyonu
RMS	: Ortalama Karekök
Rpm	: Dakikadaki Dönüş Sayısı
SCADA	: Merkezi Kontrol ve Veri Toplama Sistemi
SCG	: Ölçekli Eşlenik Gradyan
Sn	: Saniye
SRM	: Anahtarlamalı Relüktans Motoru
STFT	: Kısa Zamanlı Fourier Dönüşümü
SVM	: Uzay Vektör Modülasyonu
SV-PWM	: Uzay Vektör Darbe Genişlik Modülasyonu
TCN	: Zamansal Evrişimsel Ağlar
V2G	: Araçtan Şebekeye
YSA	: Yapay Sinir Ağları

ŞEKİLLER DİZİNİ

Şekil 3.1. Simulink üzerinde kurulan 3 fazlı asenkron motor yapısı 14

Şekil 3.2. Motor çıkış değerlerinin elde edilmesi amaçlı Simulink modeli..... 15

Şekil 3.3. Gerçek güç ve mekanik gücün elde edilmesi amaçlı Simulink modeli 16

Şekil 3.4. Verimlilik ve kayıpların elde edilmesi amaçlı Simulink modeli 17

Şekil 3.5. Demir ve bakır kayıplarının elde edilmesi amaçlı Simulink modeli 17

Şekil 3.6. MATLAB/Simulink üzerinde kurulan asenkron motor devresi..... 18

Şekil 3.7. Fiziksel sinyaller ile Simulink sinyalleri arasında bağlantı kurmaya yarayan Simulink-PS Converter ve PS-Simulink Converter blokları 19

Şekil 3.8. 3 fazlı asenkron motor termal devresi 20

Şekil 3.9. Conductive heat ve convective heat ısı transfer blokları 20

Şekil 3.10. Temperature sensor ve thermal mass blokları 21

Şekil 3.11. Yalıtım sınıfları ve izin verilen maksimum sıcaklık değerleri 21

Şekil 3.12. Stator direncinin 0.8 Ω ve stator sargılarının termal kütlesinin 1.00 kg olduğu durum için stator sargılarının sıcaklığı (79.3 °C)..... 22

Şekil 3.13. Stator direncinin 4.7 Ω ve stator sargılarının termal kütlesinin 1.00 kg olduğu durum için stator sargılarının sıcaklığı (235.5 °C)..... 23

Şekil 3.14. Stator direncinin 0.64 Ω ve stator sargılarının termal kütlesinin 1.25 kg olduğu durum için stator sargılarının sıcaklığı (75.1 °C**)**..... 26

Şekil 3.15. Başarılı olarak etiketlenen durum için tork grafiği 27

Şekil 3.16. Başarısız olarak etiketlenen durum için tork grafiği..... 27

Şekil 3.17. Başarılı olarak etiketlenen durum için tork-hız grafiği..... 28

Şekil 3.18. Başarısız olarak etiketlenen durum için tork-hız grafiği 28

Şekil 3.19. Başarı sınırından alınmış ve başarılı olarak etiketlenen tork grafiği 29

Şekil 3.20. Başarı sınırından alınmış ve başarısız olarak etiketlenen tork grafiği..... 29

Şekil 3.21. Başarı sınırından alınmış ve başarılı olarak etiketlenen tork-hız grafiği..... 30

Şekil 3.22. Başarı sınırından alınmış ve başarısız olarak etiketlenen tork-hız grafiği.... 30

Şekil 3.23. Sistemden alınan örnek tork-hız grafikleri **a)** üzerinde eksen yazıları, grid çizgileri, sayısal değerler bulunan tork-hız grafiği **b)** yapay sinir ağının girişine verilecek olan yazılardan arındırılmış tork-hız grafiği 31

Şekil 3.24. Demir kaybının artırılmasıyla stator direncinin 0.64 Ω ve stator sargılarının termal kütlesinin 1.25 kg olduğu durum için stator sargılarının yeni sıcaklığı (75.5 °C) 33

Şekil 3.25. Demir kaybının artırılmasıyla stator direncinin 4.7 Ω ve stator sargılarının termal kütlesinin 1.25 kg olduğu durum için stator sargılarının yeni sıcaklığı (233.5 °C) 34

Şekil 3.26. Demir kaybının artırılmasıyla stator direncinin 0.8 Ω ve stator sargılarının termal kütlesinin 1.25 kg olduğu durum için stator sargılarının yeni sıcaklığı (79.6 °C) 34

Şekil 3.27. İkinci modele göre güncellenen motor modeli 36

Şekil 3.28. İkinci modele göre güncellenen termal devre 37

Şekil 3.29. Tasarlanan 9 katmanlı evrişimsel sinir ağı yapısı 41

Şekil 3.30. Tasarlanan 14 katmanlı evrişimsel sinir ağı yapısı 42

Şekil 3.31. Veri çoğaltma yöntemlerine ait örnek götüntüler **a)** Orijinal sinyal görüntüsü **b)** Yakınlaştırma komutu uygulanmış sinyal görüntüsü **c)** Genişlik kaydırma komutu uygulanmış sinyal görüntüsü **d)** Yükseklik kaydırma komutu uygulanmış sinyal görüntüsü **e)** Eğim aralığı komutu uygulanmış sinyal görüntüsü 47

Şekil 4.1. CNN ağ yapısında tork sinyali başarılı iken başarılı olarak etiketlenen görüntü (doğru sınıflandırma) 51

Şekil 4.2. CNN ağ yapısında tork sinyali başarılı iken başarısız olarak etiketlenen görüntü (yanlış sınıflandırma) 52

Şekil 4.3. En başarılı ağ yapısına ait doğruluk ve kayıp grafikleri 53

Şekil 4.4. En başarılı ağ yapısına ait karışıklık matrisi 53

ÇİZELGELER DİZİNİ

Çizelge 2.1. Motor arızaları üzerine yapılan çalışmaların özeti ve araştırmacıların kullandığı yöntemler 10

Çizelge 3.1. Termal kütleler için ağırlık ve özgül ısı değerleri 23

Çizelge 3.2. Sistemin verim ve sıcaklık durumuna göre başarı veya başarısızlık durumu 26

Çizelge 3.3. Stator kütlesinin 1.00 kg'dan 1.25 kg'a çıkması durumunda sistem değerlerinde yaşanacak değişim 32

Çizelge 3.4. Birinci model için veri setleri ve içerdikleri toplam veri sayıları 39

Çizelge 3.5. İkinci model için veri setleri ve içerdikleri toplam veri sayıları 40

Çizelge 3.6. 9 katmanlı ağ yapısı için kullanılan değerler 44

Çizelge 3.7. 14 katmanlı ağ yapısı için kullanılan değerler 44

Çizelge 3.8. Veri artırma sonucu modelin gördüğü toplam varyasyonlar 48

Çizelge 4.1. Kullanılan metot, katman sayısı, fold sayısı ve veri setine göre elde edilen doğrulama başarı oranları 49

Çizelge 4.2. İkinci model için farklı iterasyon sayılarına göre başarı oranları 50

Çizelge 4.3. CNN ağ yapısında, ikinci model kullanılarak tork–hız grafiklerinin girdi olarak alındığı 5 fold çapraz doğrulama sonucunda elde edilen yanlış tahminlerin dağılımı 51

Çizelge 4.4. Ön eğitim süreci kaldırılmış GoogLeNet ağ yapısı için başarı oranları 52

1. GİRİŞ

Çevrenin insan etkisi ile doğal olmayan yollardan bozulmasına çevre kirliği denmektedir. Teknolojinin hızla gelişmesiyle ülkelerin sanayileşme süreci hızlanmış, artan nüfus ve teknolojinin ilerlemesiyle birlikte çevre kirliliği de doğru orantılı olarak artmış, artık dünyanın ekolojik dengesinin bozulmasına yol açacak seviyelere dayanmıştır. Günlük yaşamda insanlığın kullandığı çoğu madde çevreyi doğrudan veya dolaylı yollardan tehdit etmekte ve sera gazı salınımlarını artırmaktadır. Çevreyi kirleten bu maddelerin herhangi bir fiziksel unsura (hava, su, toprak) karışması, diğer unsurları da etkilemekte, canlı ve cansız maddelerde uzun ya da kısa vadede tahribata neden olmaktadır. İnsanların doğaya karşı verilen tahribatla ilgili farkındalıklarının artması ile birlikte bu tahribatın önüne geçebilmek için çeşitli önlemler almaya çalışmışlar ve artık geri dönüşüme önem verme, ağaçlandırma, çevre bilinci oluşturma gibi aksiyonlar almaya başlamışlardır.

Giderek artan farkındalık ve alınan aksiyonlar sonucunda insanlar dünyada temiz ve yenilenebilir enerji arayışına girmişlerdir. Özellikle petrol kaynaklı çevre kirliliğinin son derece tahrip edici olması nedeniyle insanlık artık petrol bazlı araçların bırakılması gerektiği görüşünde birleşmeye başlamışlardır. Doğaya verilen zararın zincirleme bir şekilde diğer unsurları da etkileyerek yaşam alanlarına etki edeceğini anlayan insanlık bu bağlamda elektrikli araçlara olan taleplerini artırmaya başlamıştır. Elektrikli araçlar, özellikle çevre dostu ve ekonomik oluşları gibi özellikleri nedeniyle hem kullanıcılar hem de şirketler tarafından tercih edilmeye başlanmış, bu sayılan özellikler sayesinde araç pazarının geleceği haline gelmiştir. Elektrikli araçların çevre dostu özelliklerinin başında egzoz gazı üretmemeleri gelir, bu özellikleri sayesinde petrol bazlı araçlara göre sera gazı salınımı önemli ölçüde düşmektedir. Elektrikli araçların yaygınlaşması çevre sağlığı bakımından da önemli bir adımdır. Özellikle şehir içi ulaşımda kullanılmaları durumunda hava kalitesinin artırılması ve ulaşımda yaşanacak gürültülerin azaltılması bakımından insan sağlığı üzerinde fiziksel ve psikolojik olarak da olumlu etkiler bırakacaktır.

Petrol bazlı araçlar içten yanmalı motorları kullanırken, elektrikli araçlarda içten yanmalı motorlar yerine elektrikli motorlar kullanılır ve bataryayla çalışırlar. Enerji verimliliği, içten yanmalı motorlara oranla daha yüksektir. Çünkü içten yanmalı motorlarda üretilen enerjinin önemli bir kısmı ısı enerjisi yoluyla kaybolur. Elektrikli motorlar ise enerjiyi direkt olarak hareket enerjisine çevirir ve bu nedenle enerji kaybı içten yanmalı motorlara göre daha düşüktür. Ayrıca elektrikli araçlarda kaybolan enerjiyi araca geri kazandırmaya yönelik rejeneratif frenleme sistemi gibi yapılar bulunmaktadır. Rejeneratif frenleme, fren yaparken araçta oluşan kinetik enerjinin elektrik enerjisine çevrildiği ve bataryada depolanmasının sağlandığı bir sistemdir. Bakım masrafı bakımından da elektrikli araçlar yine içten yanmalı motorları kullanan araçlara oranla daha ekonomiktir çünkü daha az parçaya sahiptirler. Elektrikli motorlarda kullanılan asenkron motorların petrol kaynaklı motorlara göre bir diğer avantajı ise daha dayanıklı olmalarıdır. Fırçasız yapıları nedeniyle sürtünme olmadığı için aşınma da diğer tip motorlara göre daha az olacaktır. Elektrikli araçlara olan talep artmaya devam ederken, sürücülerin yol boyunca istikrarlı bir sürüş sağlamaları sektör ve pazar açısından da önem arz etmektedir. Elektrikli araçlarda geçiş süreleri, motor sıcaklığına ve yol durumuna göre değişmektedir, dolayısıyla verimlilik durumunun sürüş konforuyla doğrudan ilişkisi bulunmaktadır. Elektrikli araçlarda yol durumuna göre aracın performansı da önemli ölçüde değişmektedir. Örneğin yokuş yukarı gidilen bir yolda araç motorundaki kayıplar

artacak, bu da sıcaklığın artmasına neden olacaktır. Bu durumda, motor daha dengesiz hale gelecek, aracın yol boyunca yer yer zorlanmasına, sürücünün ise zorlanmayı hissetmesine bağlı olarak konfor durumunun olumsuz etkilenmesine neden olacaktır.

Çalışmanın amacı, daha kararlı ve verimli bir sürüş deneyimi sağlamak ve bunu engelleyebilecek potansiyel arızaları tespit etmektir. Kararlı bir sürüş deneyimi için ise elektrikli aracın, yol boyunca karşılaşacağı zorlu şartlar altında dahi verimini ve sıcaklık değerini kabul edilebilir sınırlar içinde tutmak gerekmektedir. Bu değerlerin dışına çıkıldığında, yani araç yolculuğun belirli bir kısmında aşırı sıcaklıklara veya motorunda yaşanacak bir verim düşüşüne maruz kaldığında aracın tork değerlerinde bir dengesizlik meydana gelir. Bu durum özellikle aracın yokuş yukarı çıkarken ya da sürtünme katsayısı yüksek olan yollarda (çakıllı, molozlu vb.) zorlanmasına neden olur. Bu çalışmada, aracın en uygun çalışma koşullarını bulmak ve buna göre hataları tespit etmek amaçlanmıştır. Aracın verim değerleri, stator direncinin değerine ve sargıların termal kütlesine bağlı olarak hesaplanmıştır. Belirli bir verim ve sıcaklık değerinin altında kalan durumlar başarısız olarak etiketlenirken, hem verim hem de sıcaklık değerinin uygun olduğu koşullar başarılı olarak etiketlenmiştir. Sıcaklık veya verim değerlerinin herhangi birinin istenilen değerlerin altında kalması durumunda sistem başarısız kabul edilmiştir çünkü iki durumdan biri bile gerçekleşirse, bu iki durum dolaylı olarak birbirini de etkileyecek ve araçta performans düşüklüğü yaşanacaktır. Yine buna bağlı olarak sadece her iki değer de istenilen değerin üstünde ise sistem başarılı kabul edilmiştir. Tespit edilen başarılı ve başarısız durumlar için tork ve tork-hız grafikleri alınarak veri kümleri oluşturulmuştur. Daha sonra elde edilen veri kümeleri ile çalışmaya çeşitli yapay sinir ağı yapıları eklenmiştir. Değişen değerlere göre tork ve tork-hız sinyallerinin görüntüleri alınmış ve bu görüntüler başarılı veya başarısız olarak etiketlenmiştir. Bu etiketlenen görüntüler daha sonra CNN, 1DCNN ve GoogLeNet gibi farklı Sinir Ağı yapıları için veri seti olarak kullanılmıştır. Elde edilen sonuçlar, araç performansının ve ömrünün uzamasına katkıda bulunarak ekonomik ve çevre dostu bir dünya yaratılmasına katkıda bulunabilir.

Evrişimsel sinir ağı (Convolutional Neural Network / CNN), görüntü işlemede kullanılan ve görüntülerdeki ayırt edici özellikleri yakalayıp sınıflandıran bir algoritmadır. Farklı tür ve sayıda katmanlardan oluşabilir. Yüz tanıma sistemleri, tıbbi görüntü analizi, otonom araçlar, yüz tanıma sistemleri gibi alanlarda kullanılabilir. Yıllar içinde, farklı kişiler ve şirketler tarafından farklı CNN yapıları oluşturulmuş ve kullanıma sunulmuştur. GoogLeNet ise Google tarafından geliştirilen ve kendi mimarisine sahip, önceden eğitilmiş bir CNN ağ yapısıdır. Inception modüllerini kullanan GoogLeNet'in 22 katmanı vardır. Bu çalışmada Inceptionv3 modülü kullanılmıştır. 1DCNN, tek boyutlu bir evrişimsel sinir ağıdır. Tek boyutlu katmanların kullanıldığı bu ağda, girdiler görüntüler değil, tek boyutlu vektörlerdir. Ham veriler doğrudan 1DCNN'de kullanılabilir. Literatürde, elektrikli araçlar ve bu araçlarda kullanılan asenkron motorların termal devrelerin modellenmesi ve ayrıca asenkron motorlarda hata tespiti kapsamında stator direncinin ölçüldüğü çalışmalar mevcuttur. Bu tez çalışmasında; farklı stator dirençleri ve farklı stator sargısı termal kütleleri kullanılarak farklı boyutlarda veri setleri oluşturulmuş ve farklı tip evrişimli sinir ağı modelleri ile hata tespiti yapılmasına yönelik bir çalışma gerçekleştirilmiştir. Yapılan çalışmayla birlikte ilgili konuda literatüre özgün katkılar sunulmuştur.

Bu çalışmada, elektrikli araçlarda kullanılan asenkron motor devresi ve termal modellemesi MATLAB /Simulink kullanılarak gerçekleştirilmiş, tork ve tork-hız

grafikler alınarak elde edilen veri setleri farklı yapay sinir ağı yapıları için girdi olarak kullanılmıştır. Kullanılan yapay sinir ağları için Spyder IDE aracılığıyla Python programlama dili kullanılmıştır.

2. KAYNAK TARAMASI

İlk çağlardan itibaren makineler insan hayatının önemli bir parçası haline gelmiştir. İlk başlarda makara, kaldıraç, tekerlek gibi basit düzenekler kullanmaya başlayan insanlık, zamanla daha karmaşık mekanizmalar kullanmaya başlamıştır. O dönem kullanılan makineler şu an içinde bulunduğumuz zaman dilimi için her ne kadar ilkel ve basit gibi gözükse de dönemin insanları için büyük kolaylıklar sağlamış ve günümüze kadar ulaşan teknolojik cihazların temellerini atmışlardır. Özellikle 18. yüzyılda Sanayi Devrimi'nin başlamasıyla birlikte gelişim sürecini hızlandıran makineler kendilerini insanlığın merkezine yerleştirmişlerdir. Daha önce bu tür işlerde kullanılan insan ve hayvan gücü yerini buhar gücüyle çalışan makinelere bırakmıştır. Tekstil, tarım gibi alanlarda kullanılan bu makinelerin kullanım alanına, insanların en çok ihtiyaç duyduğu kolaylıklardan birini çözebilmek adına ulaşım alanı da eklenmiştir. İlk başta gemi, lokomotif gibi ulaşım araçlarında kullanılan makineler daha sonra otomobillerde de kullanılmaya başlanmıştır. 20. yüzyılda ise makinelerin gelişimi artmış ve artık sınırlı alanlarda kullanılan makineler hemen her alana yayılmaya başlamıştır. Buharlı makinelere ek olarak içten yanmalı ve elektrikli makinelerin de ortaya çıkmasıyla birçok farklı iş alanı için birçok farklı türde makine üretilmiştir. Makinelerin doğası gereği çeşitli alanlarda kullanılan bu cihazlarda zamanla hatalar meydana gelmiş ve arızalar oluşmuştur. Elektriksel ve elektronik bileşenlerden oluşan hassas sistemler oldukları için, sıcaklık ve ısı değişimleri, kullanım koşulları, çevresel etkiler gibi nedenlerden dolayı oluşabilen bu hatalar da verim düşüşlerine neden olabilmektedir.

İnsanlığın hatalarını çözmek için üzerinde çaba sarf ettiği en önemli makinelerden bir tanesi de asenkron motorlardır. Endüstriyel uygulamalarda en çok tercih edilen motorlardan bir tanesi olması dolayısıyla günümüz sanayisinin vazgeçilmez elemanlarındandır. Karmaşık bir yapıya sahip olmamalarının yanı sıra aynı zamanda dayanıklıdırlar. Basit yapıda olmaları dolayısıyla da bakım masrafları daha düşük ve periyodik bakım ihtiyacı diğer motorlara göre daha azdır. Bu saydığımız nedenlerden dolayı zamansal ve ekonomik olarak avantaj sağlarlar. Düşük maliyetli oldukları için tesislerde tercih edilirler, özellikle çok sayıda motorun çalışması gereken tesislerde asenkron motorlar ön plana çıkar. Aynı zamanda sabit bir hızda çalışmak zorunda olmayışları, hız aralıklarının daha geniş olabilmesi de asenkron motorların öne çıkan en önemli özelliklerinden biridir. Özellikle içten yanmalı motorların artan çevre kirliliği ve ekonomik nedenlerle yerini elektrikli araçlara bırakmaya başlaması ile de asenkron motorların kullanım alanlarından birisi de elektrikli araçlar olmuştur. Araştırmacılar bu avantajlı makinelerin tam performans çalışabilmesini sağlamak ve oluşabilecek muhtemel hataları engelleyebilmek için yıllar içinde elektrikli araçlar ve asenkron motorlarla ilgili çeşitli araştırmalar yapmışlardır. Bu çalışmalarda hem elektrikli araçların hem de asenkron motorların daha etkin çalışmalarını engelleyebilecek hatalara neden olan etkenler araştırılmıştır.

2025 yılında yapılan çalışmamızda (Kitiş ve Polat 2025), stator direnci değişimine göre tek faz akım değerlerinin spektrogramı alınmış, bu veriler verimlilik değerine göre başarılı ve başarısız olarak etiketlemiş ve evrişimli sinir ağı yardımıyla sınıflandırılmıştır. Spektrogram analizinden yararlanan bir diğer makalede (Cheng vd. 2023) Hong Kong şehrinde gürültüye neden olan modifiye edilmiş araçların tespiti amaçlanmıştır. Mevcut teknolojilerin yetersizliğinden bahseden araştırmacılar yeni bir yöntem sunmuşlardır. Ölçüm noktalarından geçen modifiye edilmiş ve yüksek gürültü seviyesine sahip egzozlu

araçlar ile birlikte normal egzoza ve normal gürültü seviyesine sahip araçların tepe ses basınç seviyelerindeki gürültü spektral özellikleri alınmıştır. Yüksek miktarda ses verisinin kullanıldığı çalışmada kısa süreli fourier dönüşümleri kullanılarak bu verilerin spektrogramları alınmış ve elde edilen bu spektrogramlar daha sonra evrişimli sinir ağı tabanlı AlexNet mimarisi için girdi olarak kullanılmıştır. Çalışmada ayrıca YOLO v4 Tiny algoritması ile birlikte nesne tanıma da yapılabilmekte ve farklı araç tipleri de algılanabilmektedir. Elde edilen sonuçlara göre bir aracın modifiyeli egzoza sahip olup olmadığı %96 oranında doğru tahmin edilebilmektedir.

2025 yılında yapılan bir doktora tezinde (Savran 2025) elektrikli araçların toplum için avantajlarından bahsedilmiş, uzun sürüş menzillerinden ve çevreye olan katkılarına değinilmiştir. Çalışmada bataryalı elektrikli araç ile gerçek dünyadaki sürüş verileri alınarak sürücü davranışları modellenmiştir. Yüzey koşullarının araca etkisini gözlemlemek için asfalt yollardan, engebeli yollardan, beton yollardan ve toprak yollardan örnekler alınmıştır. Elde edilen veriler RF, SVM, ANN, LSTM, GRU gibi farklı makine öğrenme algoritmaları için kullanılmış olup performans karşılaştırılması yapılmıştır. Engebeli yollarda aracın en yüksek enerji tüketimine ulaştığını belirten çalışma, beton zeminde ise en düşük enerji tüketiminin gerçekleştiğini ifade etmiştir. Elde edilen sonuçların elektrikli araçların analizleri için önemli katkılar sağlayacağı belirtilmiştir. 2018 yılındaki bir yüksek lisans tezinde ise (Shiferaw 2018) çevresel kirlenme ve küresel ısınmanın en önemli sebeplerinden birinin araçlardan çıkan gazların yarattığı emisyon olduğu vurgulanmıştır. Çalışmada Highway Development and Management Four (HDM-4) emisyon modelleme yazılımı kullanılarak yol geometrisinin ve yol yüzey tiplerinin, gaz emisyonu ve yakıt tüketimi üzerine etkisi incelenmiştir. Çalışma incelenen yol koşullarında yükselti artış ve azılışının emisyon ve yakıt tüketimiyle doğrudan ilişkili olduğu belirtilmiştir. Yolun düz bir yol olmamasının emisyon ve yakıt tüketimini etkilediğini belirten araştırmacı, yolda keskin virajlar olduğu durumda, eğim düşük olsa da en yüksek emisyon salınımı ve benzin tüketimine ulaşıldığını belirtmiştir. Yol virajsız ve düz bir yol olduğunda ise yüksek eğim dahi olsa emisyon salınımının ve yakıt tüketiminin minimumda olacağı belirtilmiştir. Hızın da yine bu değerlerde önemli bir etken olduğundan bahsedilmiştir. Emisyon ve yakıt tüketiminin çakıllı yollara göre asfalt yolda çok daha az olduğuna değinen araştırmacı ilerde emisyon azaltımı ve yol tasarımlarının geliştirilmesi amacıyla çalışmasının yol gösterici olabileceğinden bahsetmiştir.

Yıllar önce araştırmacılar (Chow vd. 1993), motor hatalarını tespit etmek için yapay sinir ağları ile birlikte bulanık mantıktan da yararlanmışlardır. 2022 yılında (Wu vd. 2022) araştırmacılar, elektrikli araçlarda oluşabilecek arızaları, bunlara karşı alınabilecek önlemleri ve hangi kontrol stratejilerinin kullanılması gerektiğini açıklamışlardır. Araştırmacılar ayrıca, bu arızaların aracı nasıl etkileyebileceğinden de bahsetmişlerdir Çalışmada titreşim hatası, rulman hasarı, sıcaklık artışı gibi hatalardan bahsedilmiş olup, simülasyon ve deneysel sonuçlar çalışmanın güvenilirliğini göstermiştir. Aracın yol durumuna ve eğimine bağlı olarak performansını inceleyen pek çok çalışma vardır. 2018 yılında yapılan bir araştırmada (Tan vd. 2018) tekerlek içi motorların, aracın hızlanması ya da yokuş aşağı uzun süre gitmesi gibi durumlarda normal çalışma koşularını sağlamak için daha çok güç çekeceğinden bahsedilmiştir. Buna bağlı olarak kayıpların ve sıcaklığın da artacağı belirtilmiştir. Farklı sürüş döngüleri üzerinde yapılan çalışmalarda stator sargısının en yüksek olduğu zaman 229.49 °C'ye ulaştığını ve

izolasyon limit değerini aştığını belirtmişler. Araştırmacılar makalenin termal soğutma sistemlerinin tasarlanması için kullanılabileceğine değinmişlerdir. Bir diğer araştırmacı (Kunt 2020) farklı yol eğimlerinde elektrikli araçların rejeneratif frenleme performansının modellenmesi üzerine çalışmıştır. Farklı eğim durumlarına göre akülerin şarj durumu, frenleme kayıpları, akü sıcaklıkları ve yakıt tüketimi analiz edilmiştir. Çalışmada elde edilen grafiklerde eğim arttıkça bateri sıcaklığının arttığı görülebilmektedir. Motorlardaki hataları tespit etmek için birçok çalışmada optimizasyon, derin öğrenme ve yapay zekâ kullanılmıştır. 2009 yılında yapılan bir çalışmada (Markovic ve Perriard 2009), fırçasız bir DC (Doğru Akım) motor sonlu elemanlar yöntemi kullanılarak optimize edilmiştir. Evrişimsel Sinir Ağı (CNN) kullanan bazı araştırmacılar (Ince vd. 2016), motor arızalarında erken tespitin öneminden bahsetmiş ve gerçek zamanlı arıza teşhisi üzerinde çalışmışlardır. Bunu yaparken 1 boyutlu evrişimsel sinir ağlarından da (1DCNN) yararlanmışlardır. Deneysel sonuçlar, önerilen yöntemin etkinliğini göstermiş ve gerçek zamanlı motor durum takibi için önemli adımlar atılmıştır. 1DCNN üzerindeki çalışmalar burada bitmemiş, bazı araştırmacılar (Ucar 2025) bu alanda çalışmalarına devam etmiştir. Araştırmacılar, dalgacık dönüşümü entegreli 1DCNN pooling katmanları ile elektrikli araç şarj durumu tahminini iyileştirmek üzerinde çalışmışlardır. Bu çalışmada derin öğrenme yöntemleri, özellikle 1 boyutlu evrişimli sinir ağları kullanılmıştır. Deneysel sonuçlar, önerilen yöntemin geleneksel yönteme göre daha iyi sonuçlar elde ettiğini göstermektedir. 2025 yılında araştırmacılar (Yu vd. 2025), araç sürüş durumu tanıma üzerinde çalışmışlar ve tek boyutlu evrişimsel sinir ağına dayalı bir yöntem kullanmışlardır. Çalışmada, %90'a ulaşan eğitim doğruluğu ile başarılı bir sonuç elde edilmiştir. Başka bir makalede (Basnet vd. 2021), elektrikli araç şarj istasyonlarında kullanılan SCADA sistemlerinin güvenliği incelenmiştir. Fidye Yazılımı Tespiti üzerinde çalışan araştırmacılar, derin sinir ağları (DNN), 1DCNN, LSTM gibi yapıları kullanmışlardır. Çalışmada Çapraz Doğrulama kullanılmış ve ortalama doğruluk %97 olarak belirtilmiştir. 2018 yılında bazı araştırmacılar (Wen vd. 2018), farklı veri kümeleri kullanarak sistem hatalarını tespit etmek üzerine bir çalışma yayınlamışlardır. Çalışmada 3 farklı veri kümesiyle CNN ve Derin Öğrenme teknikleri kullanılmıştır. Sonuçlar, CNN tabanlı veri odaklı hata teşhis yönteminin önemli iyileştirmeler sağladığını göstermiştir.

Başka bir makalede (Meng vd. 2019), hata teşhis sistemlerinin çoğunun ham verilerle çalışmadığı, bunun yerine frekans alanında veya diğer alanlarda çalıştığı belirtilmiştir. Bu doğrultuda, çalışmada ham verilerden yararlanılmıştır. SCG (ölçekli eşlenik gradyan) algoritmasını kullanılmış ve mevcut yöntemlere kıyasla eğitim ve sınıflandırmada çok daha iyi sonuçlar elde edilmiştir. 2019 yılında yayınlanan bir çalışmada (Chen vd. 2019), kalıcı mıknatıslı senkron motorların (PMSM) arızaları ve tespit yöntemleri üzerine bir inceleme sunulmuştur. Mıknatıs hasarı, büyük stator akımlarının neden olduğu hasarlar, yüksek sıcaklıklar, kısa devre akımları gibi hatalardan bahsedilmiştir. Derin öğrenmenin çalışmaya eklenmesi halinde çalışmanın önümüzdeki yıllarda çok daha önemli hale gelebileceğinden bahsedilmiştir. 2021 yılında yayınlanan bir başka makalede (Pasqualotto ve Zigliotto 2021), motor akımlarından alınan veriler, sinir ağları kullanılarak erken arıza teşhisi yapmak için kullanılmıştır. Bu çalışmada Evrişimli Sinir Ağları (CNN) kullanılmış ve çalışma laboratuvar ortamında gerçekleştirilmiştir. Yöntem hem sağlıklı hem de arızalı kalıcı mıknatıslı senkron motorlar (PMSM) üzerinde test edilmiş ve yöntemin etkinliğinden bahsedilmiştir. Bazı araştırmacılar (Wang vd. 2021), arıza tespiti üzerinde çalışmış ve lityum iyon pillerdeki

arıza tespiti üzerine yoğunlaşmışlardır. Çalışmada radyal baz fonksiyonlu (RBF) bir sinir ağı kullanılmıştır. Elektrikli araçlar için ana hata kaynaklarının akım, voltaj ve sıcaklık hataları olduğunu belirten araştırmacılar, bu hataları da oluşturdukları model için girdi olarak kullanmışlardır.

Motorlarda oluşacak sıcaklık hataları da zaman içerisinde birçok araştırmacı tarafından incelemiştir. Çalışmaların birinde (Metwally 2001), asenkron motor boşta ve besleme gerilimi nominal gerilimden biraz daha yüksek olduğu durum için sıcaklık artışı gözlemlenmiştir. Başka bir çalışmada, iki araştırmacı (Specht ve Böcker 2010) dahili kalıcı mıknatıslı senkron motorlar (IPMSM) üzerinde çalışmıştır. Bu motor için bir akı gözlemleyici geliştirmişlerdir. Çalışmada, sıcaklığa bağlı değişimlerin tespiti üzerinde çalışılmıştır. 2012 yılında araştırmacılar (Gouda vd. 2012), MATLAB simülasyon programında bir transformatörün termal modelini oluşturmuş ve transformatörün sıcaklığını hesaplamışlardır. Transformatördeki en sıcak noktayı bulmaya çalışmışlar ve bu çalışmalarında da oldukça başarılı sonuçlar elde etmişlerdir. Bir diğer çalışmada (Abdullah ve Ali 2019), 3 fazlı asenkron motorun termal devresi MATLAB/Simulink programında kurulmuş ve stator sargı sıcaklığı tahmin edilmeye çalışılmıştır. Çalışmada Motor-CAD ve Sonlu Elemanlar Yöntemi kullanılmış, başarılı sonuçlar elde edilmiştir. Termal devre üzerine yapılan çalışmalar bunlarla sınırlı kalmamıştır. Yayınlanan bir makalede (Badran vd. 2012) asenkron bir motorda en sıcak noktayı bulmak amaçlanmıştır. Araştırmacılar, devreyi sıcaklık olarak hangi elemanların etkilediğini ve bu etkilerin seviyesini araştırmışlardır. Ayrıca bakır sargıların yalıtımının değişen koşullara nasıl tepki vereceği üzerinde de çalışmışlardır. Başka bir çalışmada (Şimşek ve Mergen 2009), akım kaynaklı bir elektrik devresinin simülasyonu incelenmiş ve devrenin bir termal modeli oluşturulmuştur. Çalışma, asenkron motor kararlı durumdayken gerçekleştirilmiştir. Araştırmacılar sıcaklık dağılımını belirlemek istemiş ve termal geçiş rejimi üzerinde çalışmışlardır.

Elektrikli araçlardaki olası arızalar üzerinde çalışan araştırmacılar (Lin vd. 2013), bu arızaların çok ciddi sonuçlara yol açabileceğini, hatta insan hayatını tehlikeye atabileceğini belirtmişlerdir. Çalışmada, titreşim, gürültü, tork ve sıcaklık hataları gibi arızalardan bahsedilmiş ve çeşitli arıza teşhis teknikleri de çalışmalarına dahil edilmiştir. Başka bir çalışmada (Gökdere vd. 2006) 2 farklı kontrol algoritması kullanılmıştır. Bu kontrol algoritmaları, elektromekanik aktüatörlerde motor performanslarının kontrolü ve motor ömrünün ayarlanması ile ilgilidir. Motorların termal modelleri oluşturulmuş ve bu çalışmanın yeni çalışmalara öncülük edebileceği belirtilmiştir. Hem akıya hem de sıcaklığa odaklanan çalışmalar da literatürde mevcuttur. 2016 yılında araştırmacılar (Yoneyama ve Akatsu 2016) kalıcı mıknatıslı senkron motor (PMSM) ile ilgili bir çalışma gerçekleştirmiş, hem motor sıcaklığını hem de manyetik akının yoğunluğunu tahmin etmek için kullanılan bir yöntemden bahsetmişlerdir. Motorun termal devresi, manyetik devresi ve diferansiyel denklemleri oluşturulmuş ve sonlu elemanlar analizi (FEA) ile elde edilen sonuçlarla karşılaştırılmıştır. Başka bir çalışmada (Xiao ve Griffo 2020a), yüksek sıcaklıkların motorun ömrünü ciddi şekilde kısaltabileceği vurgulanmış termal direnci bulmak için yinelemeli kalman filtreli bir çevrimiçi tahmin sistemi sunulmuştur. Çalışmada üç düğümlü LPTN (toplu parametreli termal ağlar) kullanılmış ve başarılı sonuçlar elde edilmiştir. Çevrimiçi tahmin çalışmaları bununla sınırlı kalmamış, 2019 yılında yapılan bir çalışmada (Zhu vd. 2019) yine kalıcı mıknatıslı senkron motor (PMSM) için çevrimiçi sıcaklığın tahmini üzerine çalışılmıştır. Basitleştirilmiş bir termal

modelin kullanıldığı çalışmada, farklı tork ve hız koşulları için örnekler alınmış ve sıcaklık %5'ten küçük hatalarla tahmin edilebilmiştir. 2019 yılında araştırmacılar (Xia vd. 2019), asenkron motorun kalkış sırasındaki sıcaklığını bulmayı amaçlamış ve gerçek yapısına dayanarak asenkron motorun 3 boyutlu bir modelini oluşturmuşlardır. Asenkron motoru farklı yüklerde çalıştırmışlar ve sıcaklık artışını gözlemlemişlerdir. Çalışma başarılı olmuş ve gelecekte daha büyük motorlar için de kullanılabileceği belirtilmiştir. Bir yıl sonra araştırmacılar (Sarapulov vd. 2020), MATLAB/Simulink kullanarak doğrusal asenkron motorlar üzerine bir çalışma yayınlamışlardır. Çalışmada, elektromekanik ve termal süreçlerin birbirleriyle ilişkilendirilebileceği ve bu doğrultuda bir matematiksel model oluşturulduğu belirtilmiştir. Geliştirilen modeller birbiri ile etkileşimde olan modellerdir. Termal model, elektromekanik model ve soğutma sistemi modeli oluşturulmuş ve hesaplamalar sonucunda sistem hata oranının çok düşük olduğu görülmüştür.

Ayrıca batarya arızalarına odaklanan çalışmalar da yapılmıştır (Luo 2020). Çalışmada batarya arızaları incelenmiş ve analiz edilmiştir. Arıza tespiti için bir sınıflandırma yöntemi sunulmuştur. Arıza tespiti için sıcaklık, akım ve gerilim gibi değerler kullanılmış olup, modelde yüksek doğruluk elde edilmiştir. Araştırmacılar (Xiao ve Griffo 2020b), kalıcı mıknatıslı senkron makineler (PMSM) için sıcaklık hatasını araştırmış, rotor sıcaklığını izlemiş ve yüksek sıcaklıkların geri döndürülemez hatalara neden olabileceğini belirtmişlerdir. Standart uzay vektör darbe genişlik modülasyonu (SV-PWM) kullanılan çalışmada, akı kuplajının çevrimiçi tahminini sağlayan bir yöntemden bahsedilmiştir. Sonuçların doğrulanması için sonlu elemanlar yönteminden yararlanılmıştır. Bir çalışmada (Nasir 2022), stator ve rotor dirençlerini çevrimiçi tahmini üzerine yoğunlaşılmıştır. Asenkron motorlar üzerinde yapılan çalışmada, elde edilen veriler yardımıyla asenkron motorun sıcaklığının arduino kullanarak tahmin edilmesi amaçlanmıştır. Kullanılan yöntemin başarısı da çalışmada sunulmuştur. Araştırmacılar (Lahari vd. 2022), orta gerilim sürücüsü için yük akımı kullanılarak güç bileşenlerinin termal modellemesi hakkında bir makale yayınlamış ve bu araştırma için MATLAB/Simulink programını kullanmışlardır. Çalışmada transformatör ve invertör gibi yapıların termal davranışları simüle edilmiş ve motordaki termal kayıplar için bir termal model oluşturulmuştur. Termal kayıplar MATLAB/Simulink ortamında modellenmiş ve modellenebilen tüm kayıplar hesaba katılmıştır. Modelin, gerçek zamanlı olarak sıcaklığı tahmininde kullanılabileceği belirtilmiştir. 2022 yılında araştırmacılar (Zhao vd. 2022) otomobil aküleri üzerine bir çalışma yürütmüşlerdir. Otomobillerdeki akülerin güvenliği için bulut tabanlı bir makine öğrenmesi tekniği geliştiren araştırmacılar sıcaklık ve şarj eğrileri kullanılarak bir tahmin gerçekleştirmişlerdir. Yapılan tahmin erken döngüde yapıldığı için, akü hatası meydana gelmeden önce arızanın tespit edilmesini amaçlamışlardır. Çalışmada test ve eğitim doğrulukları göz önüne alındığında oldukça iyi sonuçlar elde edilmiştir.

Bazı çalışmalar (Vavilov vd. 2021), elektrikli araçların çalışabileceği maksimum çalışma koşullarına odaklanmıştır. Elektrikli araçların aşırı ısınmasını önlemek isteyen araştırmacılar, termal modeli en ağır koşullara uyarlayarak çalıştırmışlardır. Çalışmada sincap kafesli bir motor kullanılmış ve çalışma Motor-CAD'de gerçekleştirilmiştir. Deneysel sonuçlar çalışmanın başarısını desteklemiştir. 2019 yılında iki araştırmacı (Park ve Kim 2019), elektrikli araçların dünya için ne kadar önemli hale geldiğini belirterek pazar payları hakkında bilgi verdikleri bir çalışma yayınlamışlardır. Bu kadar önemli hale

gelen elektrikli araçların bataryalarında termal sisteminin yönetiminin de çok önemli olduğunu vurgulayan araştırmacılar, ayrıca bu yönetimin zorlayıcı bir işlem olduğunun da altını çizmişlerdir. Bu zorluğun temel nedeninin araçta fanlar, pompalar ve kompresörler gibi çok sayıda bileşen bulunması olduğunu belirtmişlerdir. Gözetimli öğrenme stratejisi öneren araştırmacılar, yapay sinir ağları (YSA) kullanmışlardır. Çalışmalarının toplam enerji tüketimini azaltmada etkili olduğu verilerle doğrulanırken, batarya sıcaklığını da makul bir aralıkta tutulmuştur.

Yayınlanan başka bir çalışma (Trejo-Chavez vd. 2023) ise asenkron motor tabanlı ekipmanlar üzerinde yürütülmüştür. Asenkron motordaki mekanik hataların incelendiği çalışmada kırık bar hatası, rulman hatası gibi hatalar çalışmaya dahil edilmiş ve termal görüntü analizi ile birlikte çalışmada yer almıştır. Çalışmada ayrıca CNN kullanılmış ve %95 oranında doğruluk elde edilmiştir. Araştırmacıların arıza tespiti için evrişimli sinir ağlarını kullandığı bir başka örnek de 2024 yılında verilmiştir (Ahmad ve Qi 2024). Elektrikli araçlarda arıza tespiti üzerine çalışan araştırmacılar, asenkron motorlarda arıza tespiti yapmak için CNN kullanmışlardır. Geleneksel yöntemlerin genellikle gerçek zamanlı teşhis taleplerini karşılamada başarısız olduğuna dikkat çeken araştırmacılar, CNN ve zamansal evrişimsel ağlar (TCN) kullanan hibrit bir mimari kullanmışlardır. Motor arızalarının tespiti ve sınıflandırılmasında başarılı sonuçlar elde edilmiş ve başarı oranı %92 olarak belirtilmiştir. Elde edilen sonuçlar, çalışmanın erken arıza tespiti ve bakım maliyetlerinin düşürülmesinde önemli bir potansiyele sahip olduğunu göstermiştir. Bazı araştırmacılar (Jiang vd. 2024) en son teknikleri kullanarak stator sargısında meydana gelen arızaları incelemişlerdir. Stator sargısında sarımlar arası kısa devre arızalarını (ITSF) tespit etmeye çalışan araştırmacılar, bu çalışmayı elektrikli araçlar için kalıcı mıknatıslı senkron motorlar (PMSM) üzerinde gerçekleştirmişlerdir. Çalışmada, motor model tabanlı yöntemler, yapay zekâ tabanlı arıza tespit ve teşhis yöntemleri ve sinyal işleme tabanlı tekniklerden bahsedilmiş ve bu yöntemlerin kendi aralarındaki güçlü ve zayıf yönleri belirtilmiştir. 2022 yılında, batarya termal kaçak arıza tahmini üzerine bir çalışma (Li vd. 2022) yayınlanmış ve bu çalışmada elektrikli araçlara odaklanılmıştır. Uzun kısa süreli bellekli sinir ağı (LSTM) ve evrişimli sinir ağlarının birlikte kullanıldığı çalışmada, batarya sıcaklık tahmini için iyi sonuçlar elde edilmiştir. Ortalama hata %0.28 olarak belirtilmiştir.

Blockchain ve derin öğrenme kullanan arıza tespit sistemleri de mevcuttur. Bazı araştırmacılar (Trivedi vd. 2022) bu iki yöntemi kullanılarak elektrikli araçlar için arıza tespiti üzerinde çalışılmıştır. Akü hataları, lastik basınç hatası ve sıcaklık hataları gibi hatalar da çalışmaya dahil edilmiştir. Çalışmada %70 doğruluk elde edilmiştir. Bazı araştırmacılar (Aditya Sai S vd. 2024), çalışmalarına spektrogramları dahil etmiştir. Derin öğrenme ile çalışan araştırmacılar, titreşim değerlerinin spektrogramlarını almışlardır. Araştırmacılar, makalede güç aktarma sistemlerine odaklanmış ve çalışmada 12 adet önceden eğitilmiş ağ kullanılmıştır. Sonuç olarak, doğruluk değerlerinde önemli bir iyileşme elde edilmiştir. 2023 yılında araştırmacılar (Khaneghah vd. 2023), arıza tespiti ve teşhisi (FDD) yönteminden bahsetmiş ve elektrikli araçlarla ilgili son çalışmalar hakkında bilgi vermişlerdir. Çalışmada sağlanan bilgilerin gelecekteki çalışmalara ilham verebileceği belirtilmiştir. Bazı makalelerde (Choudhary vd. 2023), iki tekerlekli elektrikli araçlar üzerine yapılan çalışmalara da yer verilmiştir. Evrişimsel sinir ağı (CNN) ve dalgacık senkron sıkıştırma dönüşümü yöntemi de dahil edilmiş, çalışma bir fırçasız doğru akım (BLDC) hub motoru ve bir orta tahrikli anahtarlamalı relüktans

motoru (SRM) üzerinde gerçekleştirilmiştir. Çalışma sonucunda yüksek doğruluk değerleri elde edilmiştir.

2022'de yayınlanan bir makalede (Yin ve Cen 2022) araştırmacılar evrişimsel sinir ağı ve motor rulman arıza teşhisi yöntemlerini birlikte kullanmışlardır. Kanal dikkat mekanizmasına dayalı evrişimsel sinir ağı (CA-CNN) modelini önermişler ve rulmandan alınan ham titreşim sinyalini girdi olarak kullanmışlardır. Sonuçlar farklı yükler altında ve farklı gürültülere sahip ortamlarda incelenmiştir. Diğer yöntemlere kıyasla yüksek doğruluk elde edilmiştir. Bir diğer çalışmada (Saxena vd. 2023), evrişimsel sinir ağı (CNN) ve yinelemeli sinir ağı (RNN), 3 fazlı asenkron motordaki anormal durumlar için birlikte kullanılmıştır. Evrişimsel yinelemeli sinir ağı (CRNN) yapısı, bu iki yapının birlikte kullanılmasıyla elde edilmiştir. Çalışmada kullanılan yöntemlerin karşılaştırmalı sonuçları, bulanık mantık denetleyicisi (FLC) eklenerek verilmiştir. Evrişimsel yinelemeli sinir ağı yapısının, yapay sinir ağı, yinelemeli sinir ağı ve evrişimsel sinir ağı gibi diğer yöntemlerden daha başarılı olduğu görülmüştür. 2023 yılında, araçtan şebekeye (V2G) şarj istasyonu için yapılan çalışmada (Yang ve Zhu,2023) arıza teşhisi kullanılmıştır. Çalışmada geliştirilmiş bir evrişimli sinir ağı-uzay vektör modülasyonu yapısı kullanılmış ve uzay vektör modülasyonu (SVM) modeli için parçacık sürüsü algoritması (PSO) kullanılmıştır. Çalışma, geleneksel yöntemlerden çok daha iyi sonuçlar vermiştir. 1DCNN (1 boyutlu evrişimsel sinir ağı) üzerine yapılan bazı çalışmalar (Du vd. 2022), otomobil motorlarında arıza teşhisine odaklanmıştır. 1D titreşim sinyalleri, CNN sınıflandırması ve arıza tespiti için kullanılmıştır. Geleneksel yöntemlere kıyasla daha iyi sonuçlar elde edilmiştir. Bazı araştırmacılar (Jung vd. 2023), rotor arıza tespitini incelemiş ve kısa zamanlı fourier dönüşümü (STFT) kullanarak rotordan gelen arıza seslerinin spektrogramlarını elde etmişlerdir. Bu verileri görsel olarak işledikten sonra, evrişimsel sinir ağı (CNN) içeren bir algoritma önermişlerdir. Elde edilen doğruluk değerleri, eğitim ve doğrulama için %99'un üzerindedir.

Bu tarihe kadar araştırmacılar, elektrikli araçlarda ve asenkron motorlarda arızaları tespit etmek ve önlemek için çeşitli çalışmalar yürütmüşlerdir. Motor sağlığı için termal hatalar, direnç hataları, batarya hataları ve akı hataları gibi hatalar önlenmeye çalışılmıştır. Bu hataları tespit etmek için yapay zekâ, derin öğrenme veya yapay sinir ağları gibi yapılar çalışmalara dahil edilmiş ve bu yapılar kullanılmıştır. Bugüne kadar yapılan çalışmaların bir özeti aşağıda Çizelge 2.1'de verilmiştir.

Çizelge 2.1. Motor arızaları üzerine yapılan çalışmaların özeti ve araştırmacıların kullandığı yöntemler

Yazarlar	Çalışmanın Konusu	Kullanılan Yöntem	Hata Tipi	Motor Tipi
Ince vd. 2016	Gerçek Zamanlı Motor Hata Tespiti	•1DCNN	•Akım •Titreşim	•3 Fazlı Asenkron Motor

(Devamı arkada)

Çizelge 2.1.'in devamı.

Abdullah ve Ali 2019	Stator Sargılarının Sıcaklık Tahmini	•Sonlu Elemanlar Metodu •Termal Ağ Metodu	•Sıcaklık	•3 Fazlı Asenkron Motor
Wen vd. 2018	Veriye Dayalı Arıza Teşhis Yöntemi	•Derin Öğrenme •CNN	•Titreşim	•Python 3.5'te yazılmış CNN Modelleri
Meng vd. 2019	Dönen Makinelerin Arıza Teşhisi	•SCG Algoritması	•Titreşim	•Asenkron Motor
Park ve Kim 2019	Elektrikli Araçlarda Termal Yönetim	•ANN	•Sıcaklık	•Elektrik Motoru
Xiao ve Griffo 2020a	Termal Dirençlerin Çevrimiçi Tanımlanması	•LPTN	•Sıcaklık	•3 Fazlı PMSM
Pasqualotto ve Zigliotto 2021	Kalıcı Mıknatıslı Senkron Motor Sürücülerinin Durum İzlemesi	•CNN	•Akım	•3 Fazlı PMSM
Basnet vd. 2021	Elektrikli Araç Şarj İstasyonunun SCADA Sisteminde Fidye Yazılımı Algılama	•DNN •CNN •1DCNN	•Şarj Seviyesi	•MATLAB/ Simulink üzerinde simüle edilmiştir
Li vd. 2022	Elektrikli Araçlar İçin Arıza Tespiti	•LSTM-CNN •Temel Bileşen Analizi •Rastgele Bitişik Optimizasyon Yöntemi	•Anormal Isı Üretimi	•Gerçek Hayattan Alınmış Elektrikli Araç Verileri

(Devamı arkada)

Çizelge 2.1.'in devamı.

Trivedi vd. 2022	Elektrikli Araçlar İçin Arıza Tespiti	•Blok Zinciri Yöntemi •Derin Öğrenme •LSTM	•Hava Lastiği Basıncı •Sıcaklık •Pil	•Elektrik Motoru
Yin ve Cen 2022	Motor Rulman Arıza Teşhisi	•CA-CNN	•Rulman	•PMSM
Du vd. 2022	Otomobil Motorlarında Arıza Teşhisi	•1DCNN •Derin Öğrenme	•Titreşim	•Otomobil Motoru
Choudhary vd. 2023	Elektrikli İki Tekerlekli Araçlar İçin Arıza Teşhisi	•CNN	•Titreşim	•BLDC Hub Motoru •SRM
Saxena vd. 2023	Üç Fazlı Bir Endüksiyon Motorunun Anormal Sağlık Durumunun İzleme ve Değerlendirmesi	•CNN •RNN •CRNN	•Isı	•3 Fazlı Asenkron Motor
Yang ve Zhu 2023	V2G Şarj İstasyonunun Arıza Teşhisi	•CNN-SVM •PSO •Dalgacık Paket Dönüşümü	•Akım	•V2G Şarj İstasyonu
Trejo-Chavez vd. 2023	Endüksiyon Motorlarında Mekanik Arızaların Belirlenmesi	•CNN	•Rulman •Kırık Çubuk Arızası	•3 Fazlı Asenkron Motor
Jung vd. 2023	Rotor Hata Tanımlaması	•CNN •STFT •2D Ses Spektrogram Analizi	•Ses	•Taşıyıcı Bant
Ahmad ve Qi 2024	Endüksiyon Motorlarında Arıza Tespiti	•CNN •TCN	•Gerilim •Akım •Hız •Tork	•3 Fazlı Asenkron Motor

(Devamı arkada)

Çizelge 2.1.'in devamı.

Jiang vd. 2024	Elektrikli Araçlar için PMSM'de Arıza Teşhisi	•Yapay Zekâ	•Stator Sargıları Arasındaki Kısa Devre Hataları	•3 Fazlı PMSM
Sai S vd. 2024	Otomobil Kuru Debriyaj Sisteminin Arıza Tespiti	•Önceden Eğitilmiş 12 Ağ Yapısı	•Debriyaj Hataları	•AC Motor
Uçar 2025	Şarj Durumu Tahmini	•Dalgacık Dönüşümü Tabanlı Havuzlama Yöntemi •1DCNN	•Ortalama Karesel Hata	•LG 18650HG2 Batarya
Yu vd. 2025	Araç Sürüş Durumunun Tanımlanması	•1DCNN	•Titreşim Artışı	•Benzinli ve Elektrikli Araçlar

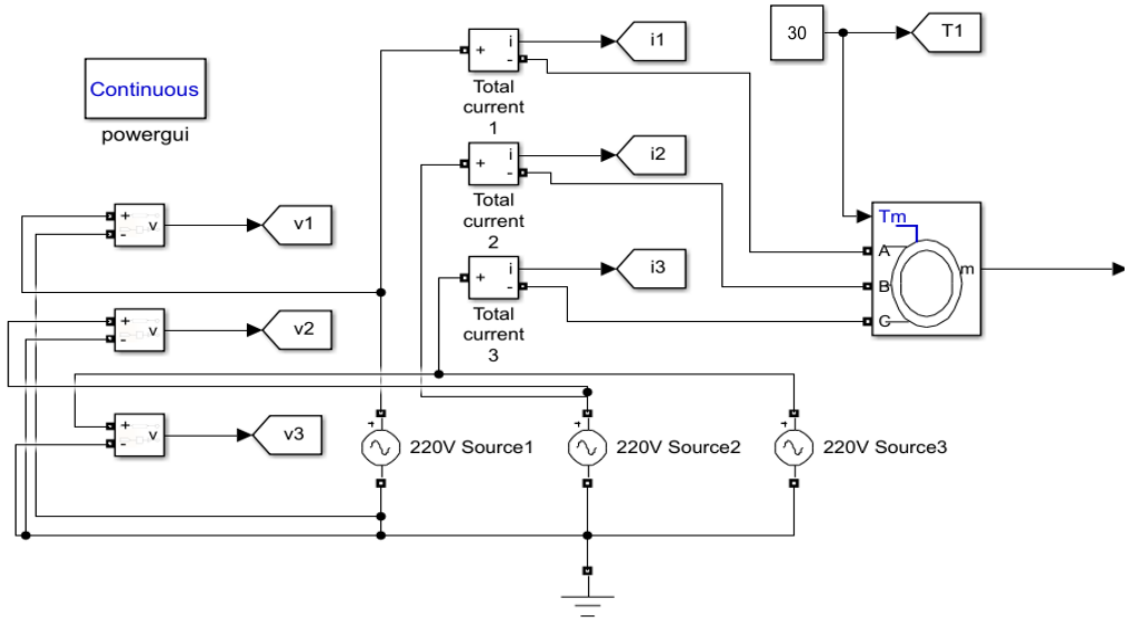
3. MATERYAL VE METOT

3.1. Asenkron Motor ve Asenkron Motor Termal Devresinin Birinci Modelinin Oluşturulması

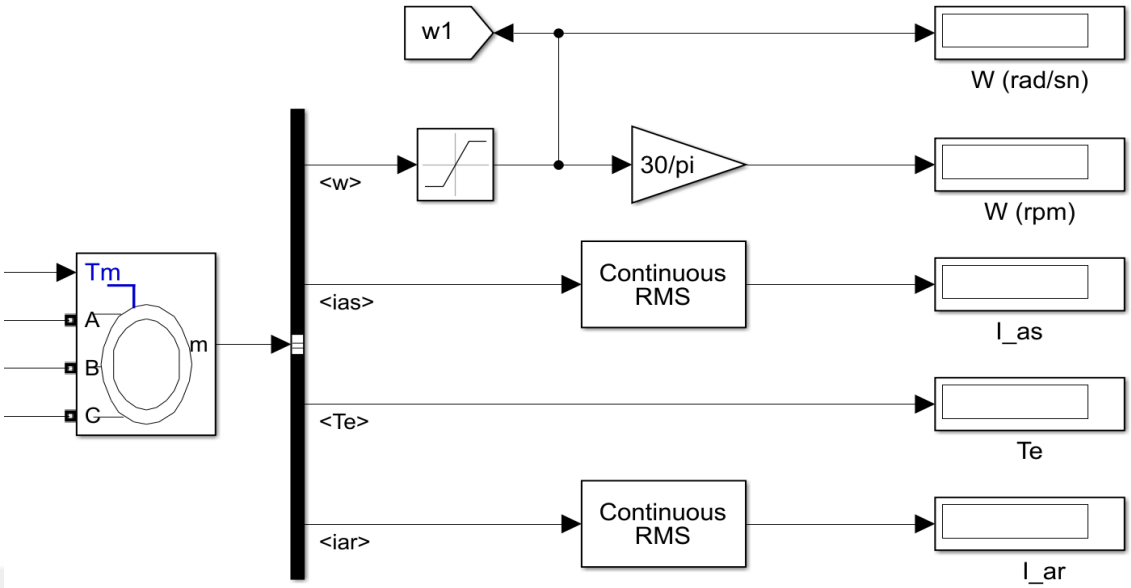
3.1.1. Asenkron Motorun Birinci Modelinin Simulink Üzerinde Oluşturulması

Motor model kurulumu MATLAB/Simulink üzerinde gerçekleştirilmiş olup 3 fazlı bir asenkron motor kullanılmıştır. Motorun A-B-C fazlarına 220 V_{Rms} uygulanmış, fazlar arasındaki faz farkı, ideal bir motorda olması gerektiği gibi 120° olarak seçilmiştir. Motora uygulanan tork 30 N.m'dir ve değeri sabittir. Motor parametreleri ve bunların değişim koşulları ise aşağıda açıklanmıştır.

Motor verimi ve termal devredeki sıcaklık değişimini gözlemlemek için, stator direnç değeri 0.8 Ω'dan 4.7 Ω'a 0.1 Ω'luk aralıklarla artırılmıştır. Çünkü elektrikli aracın zorlu yol koşullarında ilerlemesi aracın motorunu ısıtacak ve dolayısıyla motordaki direnç değerleri değişecektir. Stator direncinin belirli aralıklarla artırılması, aracın gerçek hayattaki değişken yol koşullarında zorlanmasını modelleyerek motorda bir sıcaklık artışı gerçekleştirecek ve motor verimi düşecektir. 3 fazlı asenkron motor Simulink üzerinde kurulmuş olup, yapısı Şekil 3.1'de gösterilmiştir.



Şekil 3.1. Simulink üzerinde kurulan 3 fazlı asenkron motor yapısı



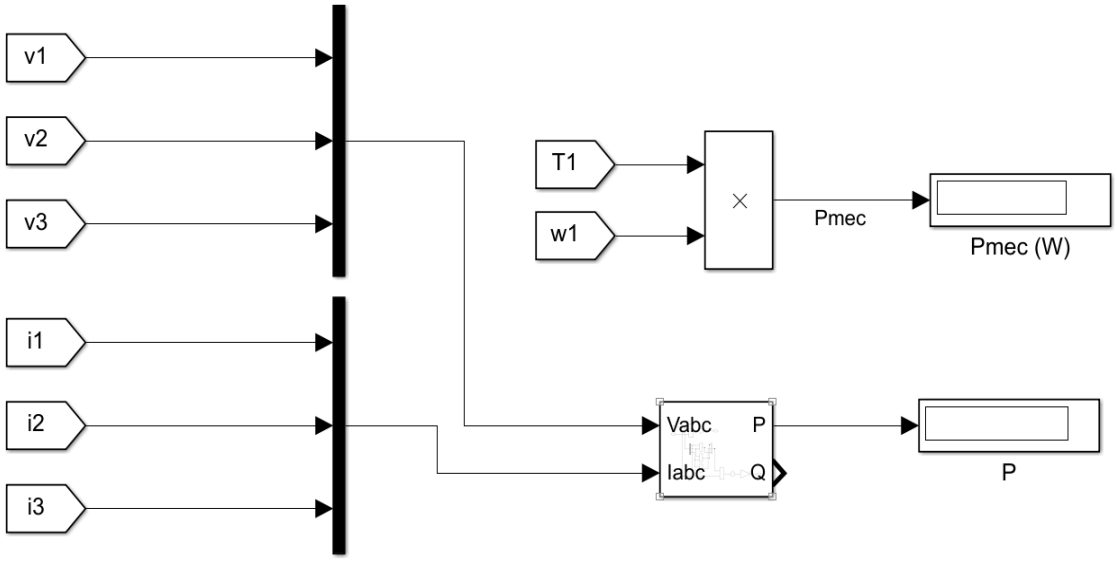
Şekil 3.2. Motor çıkış değerlerinin elde edilmesi amaçlı Simulink modeli

Yukarıda Şekil 3.2'de görüldüğü gibi, Simulink'in çıkışlarında verilen değerleri gözlemlemek için bus selector yapısı kullanılmıştır. Motor çıkışından elde edilen hız değeri rad/sn biçimindedir, ancak rpm dönüşümleri de devam eden hesaplamalarda kullanılmak üzere yapılmıştır. Hız çıkışı *w* olarak adlandırılmış ve akımların RMS (Root Mean Square) değerleri *i* ile gösterilmiştir. Akım değerinin, hangi faza ve hangi motor bileşenine ait olduğu ise alt indislerle belirtilmiştir. Örneğin, A fazının stator akımı i_{as} ile gösterilmiştir. Mekanik tork T_m ile, elektromanyetik tork ise T_e ile gösterilmiştir. Motor çıkışları ve isimleri Şekil 3.3'te verilmiştir.

$$w_{Rpm} = \frac{30}{\pi} \times w_{rad/sn} \tag{3.1}$$

Motorun 1 dakikadaki dönüş hızı formülü yukarıda Denklem 3.1'de verilmiştir. Gerçek güç ve mekanik güç hesaplamaları, bloğa giren akım ve gerilim değerleri kullanılarak yapılmıştır. Mekanik güç formülü ise Denklem 3.2'de verilmiştir.

$$P_{Mec} = T_m \times w \tag{3.2}$$



Şekil 3.3. Gerçek güç ve mekanik gücün elde edilmesi amaçlı Simulink modeli

Simulink üzerinde mekanik güç ve gerçek gücün elde edilişi Şekil 3.3'te gösterilmiştir. Motordaki ana kayıplar 2 başlık altında toplanabilir: Bunlar Bakır Kaybı (P_{Cu}) ve Demir Kaybıdır. (P_{Fe}). Bu nedenle, bakır kaybı ve demir kaybının toplamı, Denklem 3.3'te görüldüğü gibi toplam kaybı (P_{loss}) verecektir. Bir motordaki kayıplar aynı zamanda gerçek güç (P_R) ile mekanik güç (P_{Mec}) arasındaki fark ile de ifade edilebilir. Bu ifade de Denklem 3.4'te görülebilir. Motorun giriş ve çıkış güçleri arasındaki oran bize verimliliği verecektir çünkü giriş ve çıkış arasındaki fark kayıplardan kaynaklanır. Verimlilik hesaplaması aşağıdaki Denklem 3.5'te verilmiştir. Verimlilik ve kayıp ifadelerinin Simulink üzerinde gösterimi Şekil 3.4'te görülebilir.

$$P_{loss} = P_{Fe} + P_{Cu} \tag{3.3}$$

$$P_R - P_{Mec} = P_{loss} \tag{3.4}$$

$$\%\, Verim = \frac{P_{Mec}}{P_{Mec}+P_{loss}} \times 100 = \frac{P_{Mec}}{P_R} \times 100 \tag{3.5}$$

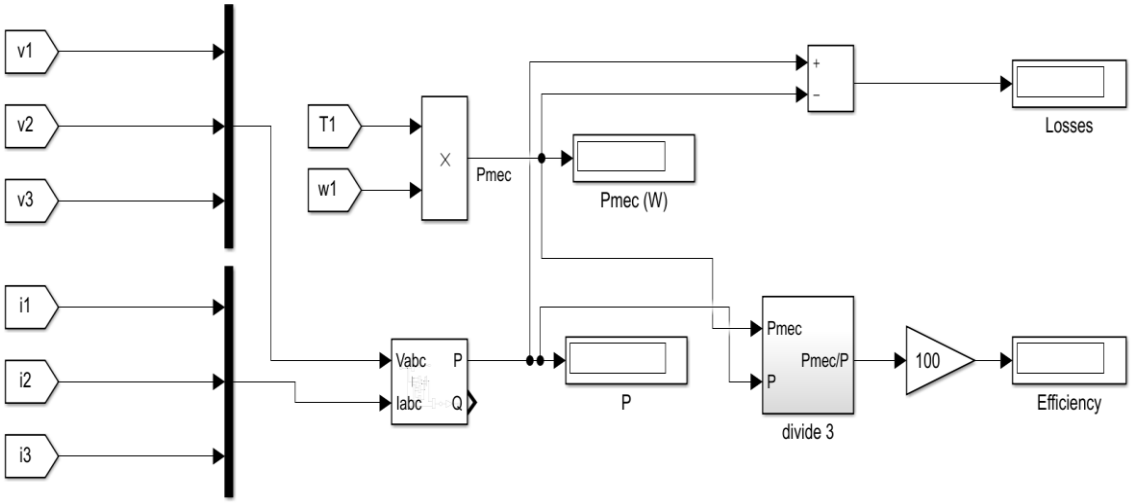
Daha önce toplam kayıpların bakır kayıpları ve demir kayıplarının toplamları olduğunu ifade etmiştik. Bu ifadeden yola çıkarak bakır kayıplarını aşağıda Denklem 3.6 ile ifade edebiliriz.

$$P_{Cu} = P_{loss} - P_{Fe} \tag{3.6}$$

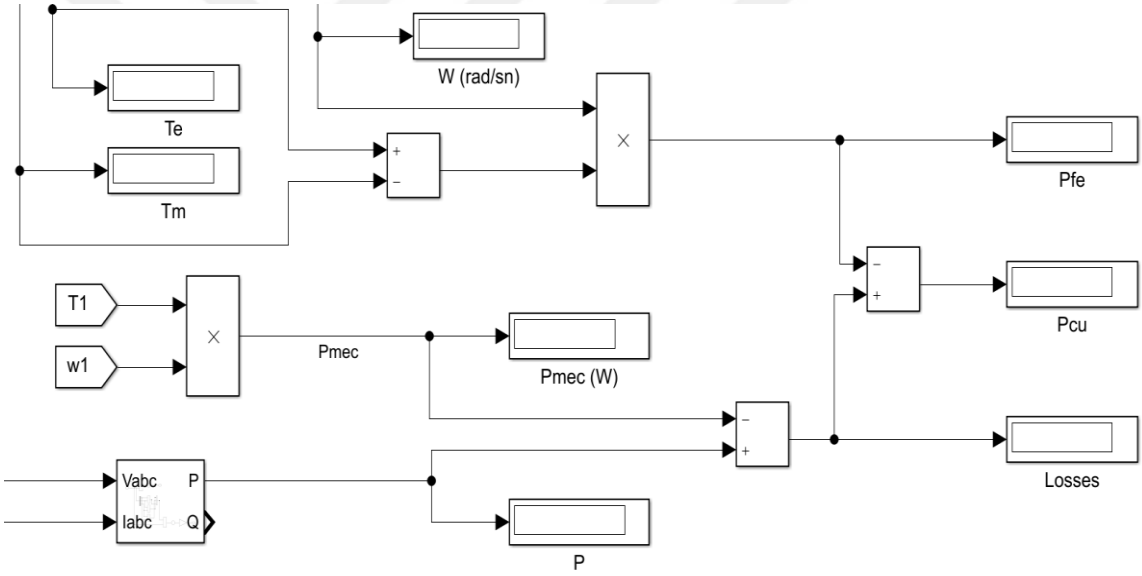
"Optimization Design of a Segmented Halbach Permanent-Magnet Motor Using an Analytical Model" isimli makalede (Markovic ve Perriard 2009) mekanik tork ve elektromanyetik tork ilişkisi Denklem 3.7'deki gibi ifade edilmiştir. Aşağıdaki ifadeden de demir kaybını çekersek Denklem 3.8'deki ifade elde edilir.

$$T_m = T_e - \frac{P_{Fe}}{w} \tag{3.7}$$

$$P_{Fe} = w \times (T_e - T_m) \tag{3.8}$$



Şekil 3.4. Verimlilik ve kayıpların elde edilmesi amaçlı Simulink modeli

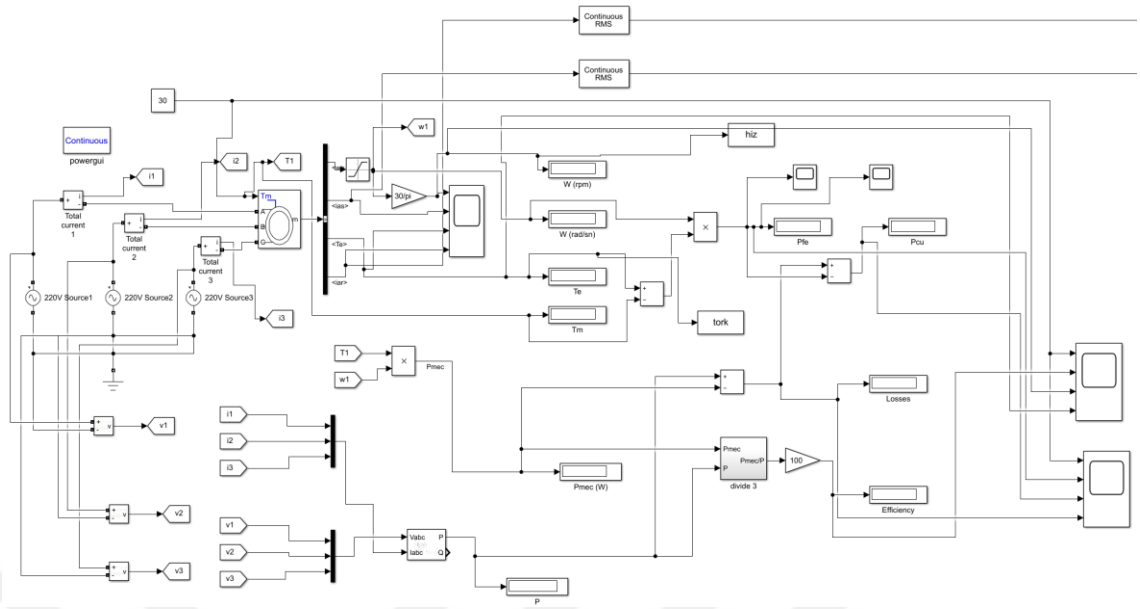


Şekil 3.5. Demir ve bakır kayıplarının elde edilmesi amaçlı Simulink modeli

Denklem 3.8'de elde ettiğimiz demir kaybı ifadesini Denklem 3.6'da yerine yazarsak Denklem 3.9'daki ifadeyi elde edebiliriz. Demir ve bakır kayıplarının Simulink üzerinde elde dilmesi Şekil 3.5'te görülebilir.

$$P_{Cu} = P_{loss} - P_{Fe} = P_{loss} - [w \times (T_e - T_m)] \quad (3.9)$$

Yukarıda açıklanan kayıp hesaplamaları ve verim ifadeleri ile, ileride tork ve tork-hız grafiklerinin verim açısından başarılı mı yoksa başarısız mı olarak etiketleneceği bulunacaktır. Aşağıda Şekil 3.6'da MATLAB/Simulink üzerinde kurulan asenkron motor devresi verilmiştir.



Şekil 3.6. MATLAB/Simulink üzerinde kurulan asenkron motor devresi

3.1.2. Asenkron Motor Termal Devresinin Birinci Modelinin Simulink Üzerinde Oluşturulması

Motor termal devresinin oluşturulmasının temel amacı, motor modelinde stator direnci üzerindeki sıcaklığı simüle edebilmektir. Bunun için, stator direncinde üzerinde oluşan ve ısıya dönüşen kayıpların hesaplanması gerekmektedir. Çünkü stator direncinde oluşacak kayıplar ısı olarak ortaya çıkacaktır. Bu nedenle, stator direnci üzerinde oluşacak ısıyı simüle etmek için sargılarda oluşan bakır kayıplarının hesaplanması gerekir. Çünkü bu kayıplar, sargılardaki temel kayıpları oluşturur. Bakır kayıpları aşağıdaki formülle bulunabilir. Bakır kayıpları, önceki bölümde verilen motor modelindeki formüllerle bulunabileceği gibi, doğrudan kendi formülü kullanılarak da bulunabilir. Termal hesaplamalarda, doğrudan kendi formülü kullanılarak Simulink'teki termal bloğa bağlanmıştır. Bakır kaybı formülü Denklem 3.10'da görülebilir.

$$P_{Cu} = I^2 \times R \tag{3.10}$$

Stator sargılarındaki toplam kayıpları bulabilmek için, stator ve rotor kayıplarını birlikte değerlendirmek gerekir. Çünkü rotor sargılarının neden olduğu sıcaklık, stator sargılarının sıcaklığını da etkileyecektir. Stator sargılarındaki Bakır Kaybını bulmak için, formüldeki I (Akım) değerini I_s (Stator Akımı) ile R (Direnç) değerini de R_s (Stator Direnci) ile değiştirebiliriz. Bu değerler yerine yazıldığında, formül Denklem 3.11'deki gibi olacaktır.

$$(P_{cu})_s = (I_s)^2 \times R_s \tag{3.11}$$

Ancak, kullandığımız asenkron motor 3 fazlı bir asenkron motor olduğu için formülümüzün 3 ile çarpılması gerekmektedir, 3 ile çarpıldığında ise formülün son hali aşağıda Denklem 3.12'deki gibi olacaktır.

$$(P_{cu})_s = 3 \times (I_s)^2 \times R_s \quad (3.12)$$

Aynı şekilde rotor sargılarındaki bakır kaybını bulmak için, formüldeki I (Akım) değerini I_r (Rotor Akımı) ile R (Direnç) değerini ise R_r (Rotor Direnci) ile değiştirebiliriz. Bu değerler yerine yazıldığında ve motorumuzun 3 Fazlı olduğu da dikkate alınırsa formül Denklem 3.13'teki gibi olacaktır.

$$(P_{cu})_r = 3 \times (I_r)^2 \times R_r \quad (3.13)$$

Motordaki toplam bakır kayıpları, statordaki bakır kayıpları ve rotordaki bakır kayıplarının toplamlarından oluşacaktır. Bu ifade göz önüne alındığında Denklem 3.14 ve Denklem 3.15 elde edilir.

$$(P_{cu})_T = (P_{cu})_s + (P_{cu})_r \quad (3.14)$$

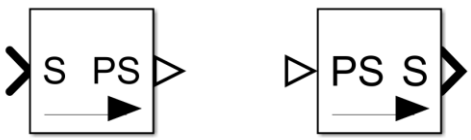
$$(P_{cu})_T = (3 \times (I_s)^2 \times R_s) + (3 \times (I_r)^2 \times R_r) \quad (3.15)$$

Motordaki demir kayıpları ise daha önce ifade edilen Denklem 3.8 kullanılarak elde edilmiştir.

$$P_{Fe} = w \times (T_e - T_m)$$

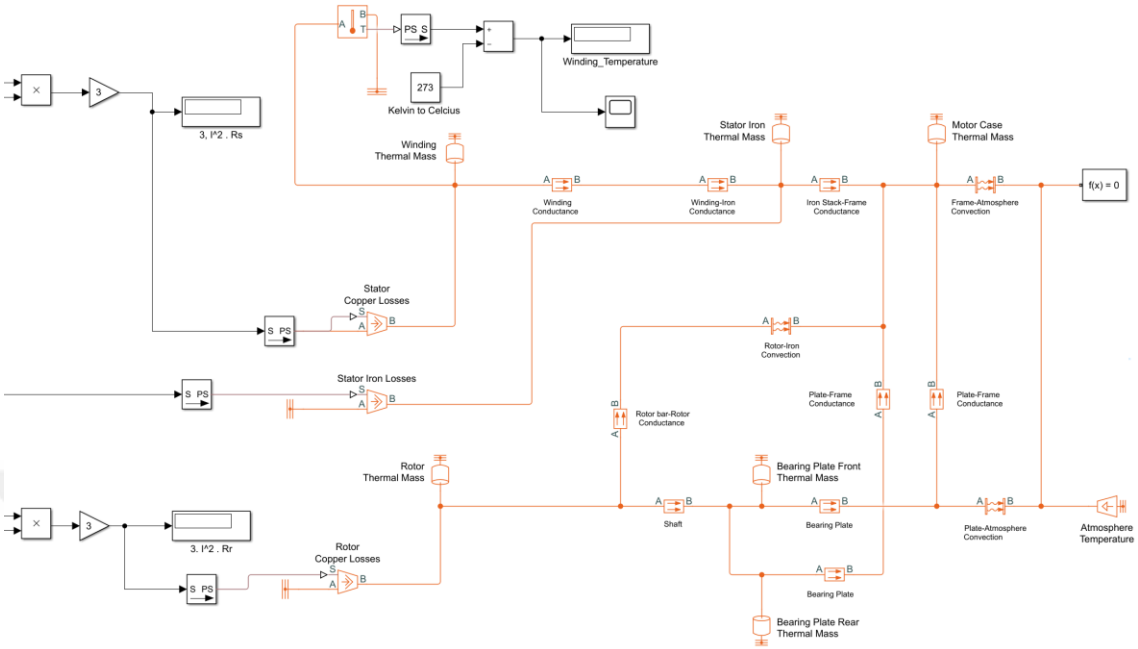
Isıya dönüşen kayıplar bulunduktan sonra, motor termal devresinin oluşturulması amaçlanmıştır. Asenkron motor termal devresinin Simulink üzerinde oluşturulabilmesi için literatürdeki makaleler (Abdullah ve Ali, 2019) ve MATLAB Resmî Web Sitesi'ndeki termal modeller incelenmiştir.

Simüle edilen rotor kayıpları, termal devredeki rotor sargılarının bulunduğu konuma karşılık gelen yerden devreye eklenmiş, yine aynı şekilde stator demir ve bakır kayıpları da devre üzerinde stator sargılarının bulunduğu konumdan devreye eklenmiştir. Termal devre bloklarına motor kayıplarının direkt olarak bağlanması, Simulink üzerinde motor devresi ile termal devre arasında bir uyumsuzluk meydana getirecektir. Bu iki simülasyon bloğu doğrudan birbirine eklenemediği için uyuşmazlığı gidermek adına "Simulink-PS Converter" bloğu kullanılmıştır. Bu blok, simulink sinyallerini fiziksel sinyallere dönüştürmek için kullanılır. Aynı uyuşmazlık, termal devrenin çıkışındaki grafikleri görmek için kullanacağımız “Scope” bloğunda da meydana gelmektedir. Bu sefer de fiziksel sinyalleri Simulink sinyallerine dönüştürmek üzere "PS-Simulink Converter" bloğunu kullanmamız gerekecektir. Bu sinyaller aşağıda Şekil 3.7’de gösterilmiştir.



Şekil 3.7. Fiziksel sinyaller ile Simulink sinyalleri arasında bağlantı kurmaya yarayan Simulink-PS Converter ve PS-Simulink Converter blokları

Dönüştürme işlemleri sonucunda, 3 fazlı asenkron motorun termal devresi oluşturulmuş, genel görünümü Şekil 3.8'de gösterilmiştir.



Şekil 3.8. 3 fazlı asenkron motor termal devresi

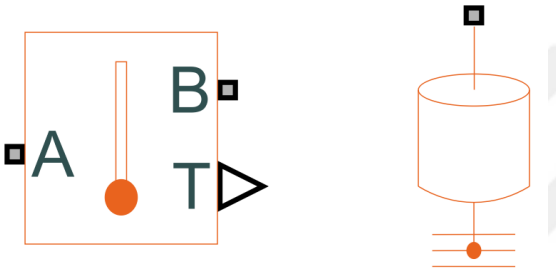
Isıl devre oluşturulurken fiziksel ısı transferini doğru bir şekilde modellemek için Simulink'te "Conductive Heat Transfer" bloğu kullanılmıştır. Motorun hava ile teması bulunan yerlerde ise "Convective Heat Transfer" bloğu kullanılmıştır. "Conductive Heat Transfer" bloğu, ısı transferinin cismin bir tarafından diğer tarafına iletimini modellemek için kullanılmıştır. Bu iletim çeşidinde ısı transferi madde molekülleri arasında doğrudan temas yoluyla gerçekleşir. Örneğimizde, katı durumdaki motor elemanlarının ısıl modellemesi için kullanılmıştır. "Convective Heat Transfer" bloğu ise, akışkanların oluşturacağı (sıvı veya gaz) ısı transferini modellemek için kullanılmıştır. Çalışmamızda, termal modelimizde katı malzeme ile hava (gaz) arasında gerçekleşen transfer modellemesinde bu bloktan yararlanılmıştır. Oluşturduğumuz termal devrede bu bloklar, elektriksel devrelerdeki direnç rolündedir ve ısı akışına ne kadar direnç gösterileceği bu bloklarla belirlenir. Yararlanılan bu bloklar aşağıda Şekil 3.9'da gösterilmiştir.



Şekil 3.9. Conductive heat ve convective heat ısı transfer blokları

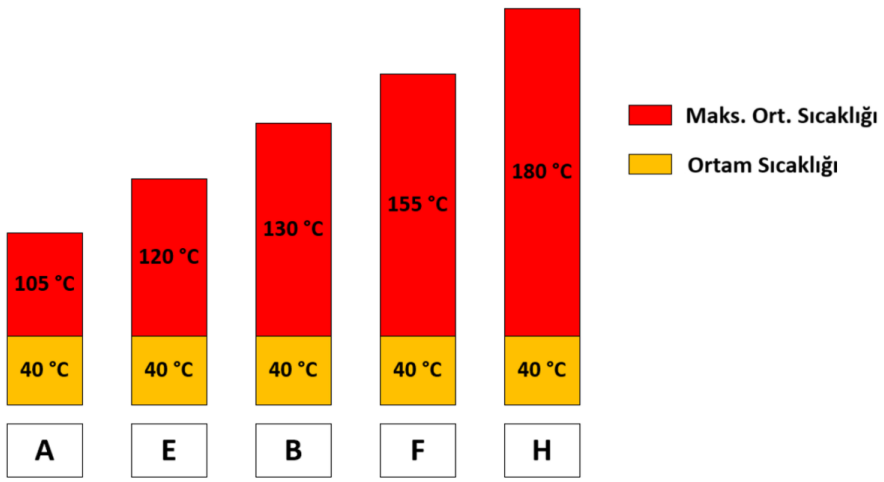
Termal devremizde hava modellemeleri sırasında, hava sıcaklığı Simulink'teki "Temperature Source" bloğu kullanılarak 313 °K olarak ayarlanmıştır. 313 °K kullanılmasının nedeni, motor yalıtım sınıflarının tanımlanmasında ortam sıcaklığının 40

°C olarak kabul edilmesi ve 40 °C'nin Kelvin eşdeğerinin 313 °K olmasıdır. Ortam sıcaklığının 25 °C yerine 40 °C olarak belirlenmesinin nedeni motor yapısının kapalı bir alan olmasına bağlı olarak sıcaklık artışına daha müsait olmasıdır. Ayrıca 40 °C zorlayıcı ortam koşullarını da daha iyi yansıtacaktır. Genellikle Simulink'teki derece değerleri °K olarak kullanıldığı için. °C cinsinden değerleri hesaplanmış ve Kelvin eşdeğerini bulmak için 273 eklenmiştir. Aynı şekilde sistem çıktıları gözlemlenmek istendiğinde de Celcius değeri görmek daha uygun ve anlaşılır olacağı için bu durumlarda da Kelvin değerlerinden 273 çıkarılmıştır. Sıcaklık değerlerini görmek için Simulink'teki "Temperature sensor" bloğu kullanılmıştır. “Thermal mass” (Termal kütle) bloğu ise, termal elemanların kütle değerlerini girmek için kullanılmıştır. Aynı zamanda termal kütle bloğu bir maddenin ısı kapasitesini temsil eder ve bizim devremizde elektrik devrelerindeki kapasitans rolündedir. “Temperature sensor” ve “thermal mass” blokları aşağıda Şekil 3.10’da gösterilmiştir.



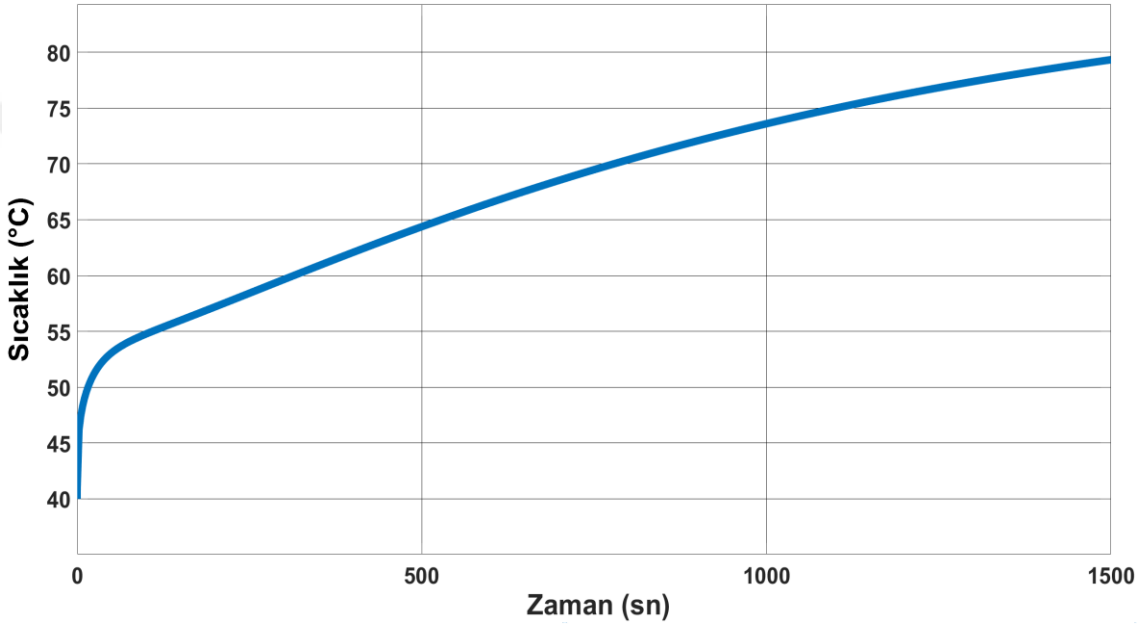
Şekil 3.10. Temperature sensor ve thermal mass blokları

Literatür taramalarında, motorlar için çeşitli yalıtım sınıfları olduğu ve yalıtımın hasar görmeden dayanabileceği maksimum sıcaklığın bu yalıtım sınıflarına göre belirlendiği bilgisine ulaşılmıştır. Elektrikli araçlarda kullanılan motorlarda genellikle H tipi yalıtım sınıfına sahip motorların kullanıldığı görülmüştür (Asgari vd. 2024). Birçok araştırmacı termal modelleme üzerine yaptıkları çalışmalarda da elektrikli araçlarda kullanılan asenkron motorlarda H tipi yalıtım sınıfı kullanmışlardır. (Ulu vd. 2017) Yalıtım sınıfları ve izin verilen maksimum sıcaklık değerleri Şekil 3.11’de gösterilmiştir.

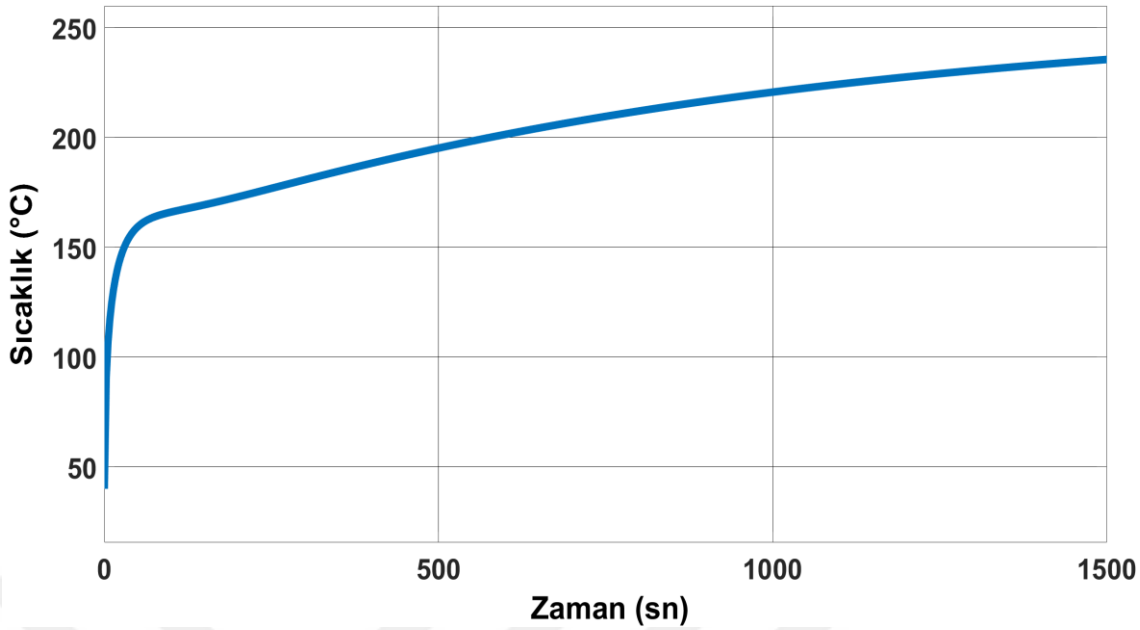


Şekil 3.11. Yalıtım sınıfları ve izin verilen maksimum sıcaklık değerleri

3 fazlı asenkron motorumuzdaki sıcaklık artışı, motor verimliliğine ve dolayısıyla kayıplara bağlı olarak değişmektedir. Sistemimizdeki bu sıcaklık artışı, stator direncinin değişimi ile gözlemlenmektedir. 1500 saniye boyunca minimum ve maksimum sıcaklıkların bulunabilmesi için, stator direnci önce alınan örnekler arasında aracın sıcaklığının en düşük, dolayısıyla da verimin en yüksek olacağı değer olan 0.8 Ω'a, ardından alınan örnek değerler arasında sıcaklığın en yüksek, dolayısıyla verimin de en düşük olacağı değer olan 4.7 Ω'a ayarlanmıştır. Ardından alınan değerlere bağlı olarak stator sargılarının sıcaklığı elde edilmiş, 1500 saniye boyunca sargıların sıcaklık örnekleri Şekil 3.12 ve Şekil 3.13'te gösterilmiştir. Bu işlem sırasında stator sargılarımızın termal kütlesi 1.00 kg olarak alınmıştır. Aşağıda stator sargılarımızın termal kütlesinin 1.00 kg olduğu durum için stator sargılarının sıcaklığı 0.8 Ω ve 4.7 Ω değerleri için Şekil 3.12 ve Şekil 3.13'te verilmiştir.



Şekil 3.12. Stator direncinin 0.8 Ω ve stator sargılarının termal kütlesinin 1.00 kg olduğu durum için stator sargılarının sıcaklığı (79.3 °C)



Şekil 3.13. Stator direncinin 4.7 Ω ve stator sargılarının termal kütlesinin 1.00 kg olduğu durum için stator sargılarının sıcaklığı (235.5 °C)

3.1.3. Birinci Model İçin Termal Kütle Değerlerinin Girilmesi

Yapılacak termal kütle hesaplamalarında MATLAB/Simulink programına girilmesi gereken değerler arasında simülasyona dahil edilecek termal kütlenin ağırlığı ve özgül ısısı gibi değerler gerekmektedir. Bakırdan yapılan malzemeler için özgül ısı 385 $J.Kg^{-1}.K^{-1}$ alınırken, demir için bu değer 451 $J.Kg^{-1}.K^{-1}$ alınmış, alüminyum için ise 900 $J.Kg^{-1}.K^{-1}$ alınmıştır.

Termal kütle ağırlıkları ile ilgili doğru hesaplamalar yapılabilmesi için literatür taramalarından yararlanılmıştır. 2020 yılında yapılan Materials for lightweight electric motors – a review isimli çalışmada (Gnanaraj vd. 2020) bir elektrikli motorun parçalarının yaklaşık ağırlığı yüzdesel olarak verilmiş olup, istenilen değerler girileceğinde bu çalışmadaki değerlerden de yararlanılmıştır. Termal kütle parçalarına göre girilen ağırlık ve özgül ısılar aşağıda Çizelge 3.1'de verilmiştir.

Çizelge 3.1. Termal kütleler için ağırlık ve özgül ısı değerleri

Termal Devre Elemanı	Ağırlık (kg)	Özgül Isı ($J.Kg^{-1}.K^{-1}$)
Stator Sargıları	1	385
Stator Nüvesi	12	451
Motor İskeleti	6.4	900
Ön Rulman	0.367	420
Arka Rulman	0.367	420
Rotor Ağırlığı	6	451

3.1.4. Birinci Model İçin Direnç-Sıcaklık İlişkisinin Kurulması ve Derin Öğrenme Veri Setlerinin Genişletilmesi

Şimdiye kadar yapılan çalışmalarda, sistemin termal devresi oluşturulmuş, sistemin kabul edilebilir sınır değerler içinde çalışabilmesi için sıcaklık ve verim değerleri belirlenmiş ve bu değerler CNN ağımız için başarılı veya başarısız olarak etiketlenecek verilerin belirlenmesinde sınır değerler olarak kullanılmıştır. Ancak bu değişiklikler, stator sargılarının termal kütlesi sabit (1.00 kg) kabul edilerek yapılmış, stator direnci kademeli olarak artırılmış ve sıcaklık sınır değerinin aşılıp aşılmadığının kontrol edilmiştir. Daha sonra yukarıda da bahsedildiği gibi verilerimiz başarılı veya başarısız olarak etiketlenerek veri setlerimiz oluşturulmuştur. Bu kez, stator sargılarının termal kütlesi 1.00 kg'dan 1.25 kg'a çıkarılmış ve stator sargılarının termal kütlesinin 1.25 kg olduğu durum için verilerin başarılı ve başarısız olarak etiketlenme durumları güncellenerek 1.00 kg termal kütlesi için oluşturulan veri setlerine eklenmiştir. Şu ana kadar Tork grafikleri üzerinden elde edilen ve her iki termal kütle verilerinin de içinde bulunduğu veri setimize ek olarak tüm işlemlerin tork grafiği yerine tork-hız grafikleri kullanılarak yapıldığı 2. bir veri seti de oluşturulmuştur.

Özetle içerisinde 1.00 kg ve 1.25 kg stator sargısı termal kütlelerine göre alınmış ve limit sınırlara göre başarılı veya başarısız olarak etiketlenen verilerin bulunduğu 2 farklı veri setimiz vardır. Ancak 1.25 kg stator direnç termal kütlesi için başarılı ve başarısız olarak etiketlenen durumları belirlemek için yeni stator direnç değerlerinin bilinmesi gerekir çünkü verim değerlerini ve sıcaklığın ilişkili olduğu temel değerimiz stator direncidir. Termal kütlenin değişmesi de fiziksel açıdan bakıldığı zaman direnç değerinde de bir değişime neden olacaktır. Bunun için Kütle ve Stator Direnci arasında bir ilişki elde edilmelidir. Bundan sonra, 0.1 Ω aralıklarla artırılan stator direnç değerleri yeni değerlerine dönüştürülecek ve tekrar kullanılacaktır.

Hesaplamalara direnç ve özdirenç arasındaki denklemlerle başlanmış ve aralarındaki ilişki Denklem 3.16'te verilmiştir.

$$R = \rho \times \frac{L}{A} \tag{3.16}$$

Verilen denklemde R: Direnç, ρ: Özdirenç, L: Uzunluk, A: Kesit Alanı'dır. Yararlanılacak başka bir denklem de aşağıda Denklem 3.17'de verilmiştir.

$$m = d \times V \tag{3.17}$$

Denklem 3.17'de, kütle ile yoğunluk (özkütle) arasındaki eşitlik verilmiştir. Bu denklemde m: Kütle, d: Yoğunluk, V: Hacim değerleridir.

Hacim ve kesit alanı arasındaki ilişki de Denklem 3.18'de verilmiştir. Eşitlikte, V: Hacim, A: Kesit Alanı, L: Uzunluk'tur.

$$V = A \times L \tag{3.18}$$

Denklem 3.17 ile Denklem 3.18'nin birleştirilmesiyle Denklem 3.19 elde edilir. Denklem 3.19 ifadesinde kesit alanı tek başına bırakılacak olursa da Denklem 3.20 elde edilir.

$$m = d \times A \times L \tag{3.19}$$

$$A = \frac{m}{d \times L} \tag{3.20}$$

Son olarak, Denklem 3.20 ile Denklem 3.16 birleştirilirse, kütle ile direnç değeri arasındaki ilişki ortaya çıkacaktır. Bu ifade Denklem 3.21'de görülebilir.

$$R = \frac{\rho \times L^2 \times d}{m} \tag{3.21}$$

Daha anlaşılabilir olması bakımından ifadenin açık hali aşağıda verilmiştir.

$$Direnç = \frac{\text{Özdirenç} \times Uzunluk^2 \times \text{Özkütle}}{Kütle}$$

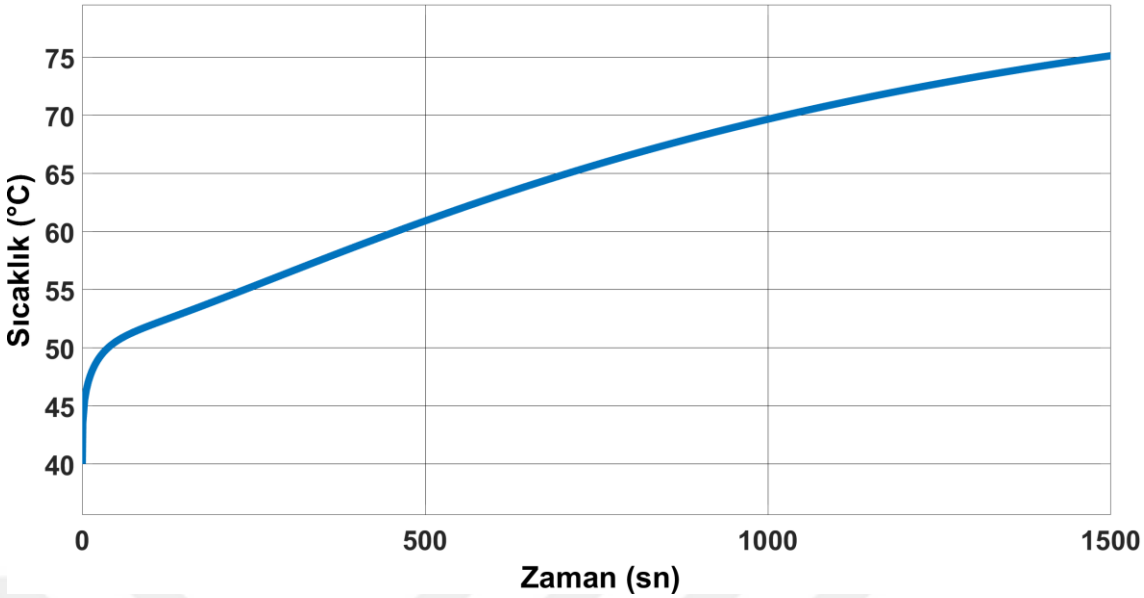
Görüldüğü gibi bir telin özdirenci, uzunluğu ve yoğunluğu sabit tutulup kütlesi artırıldığında, direnç değeri kütle artışıyla aynı oranda azalacaktır. Çalışmamızda özdirenç, uzunluk ve yoğunluk sabit kabul edilmiştir. Gerçek hayatta, bu değerler sabitken kütlenin artırılması telin kalınlığının artırılması anlamına gelmektedir. Stator sargılarının termal kütlesi 1.00 kg'dan 1.25 kg'a çıkarıldığında, direnç değerleri de aynı oranda değişecektir. Bu değişim Denklem 3.22 ile ifade edilmiştir.

$$R_{Yeni} = R_{Eski} \times \frac{1.00}{1.25} \tag{3.22}$$

Bir örnek verilmesi gerekirse, yukarıdaki eşitliğe göre 1.00 kg termal kütlesi bulunan ve 1,6 Ω değerindeki bir direnç, termal kütlesi 1.25 kg'a çıkarıldığında 1.28 Ω değerine düşecektir.

$$1.6\ \Omega \times \frac{1.00}{1.25} = 1.28\ \Omega$$

Stator sargılarının termal kütlesinin 1.00 kg olduğu durum için alınan en düşük direnç numunesi 0.8 Ω iken, motor tarafından üretilecek minimum sıcaklık değeri de 73.5°C'ye denk gelmekteydi. Ancak stator sargılarının termal kütlesinin 1.25 kg'a çıkarılmasıyla, sargılarda oluşacak minimum direnç değeri de 0.8 Ω değerinden 0.64 Ω değerine düşecektir. Elde edilen 0.64 Ω değeri yapılan çalışmada elde edilmiş en düşük stator direnci olacağı gibi aynı zamanda motorun oluşturacağı en düşük sıcaklık da bu direnç değerinde meydana gelecektir. Stator direncinin 0.64 Ω ve stator termal devresinin 1.25 kg olduğu durum için stator sargılarının sıcaklığı aşağıda Şekil 3.14'te verilmiştir. Stator sargılarının termal kütlesinin 1.25 kg'a çıkarılmasıyla oluşan yeni direnç değerinde ölçülen sıcaklık 75.1°C'dir.



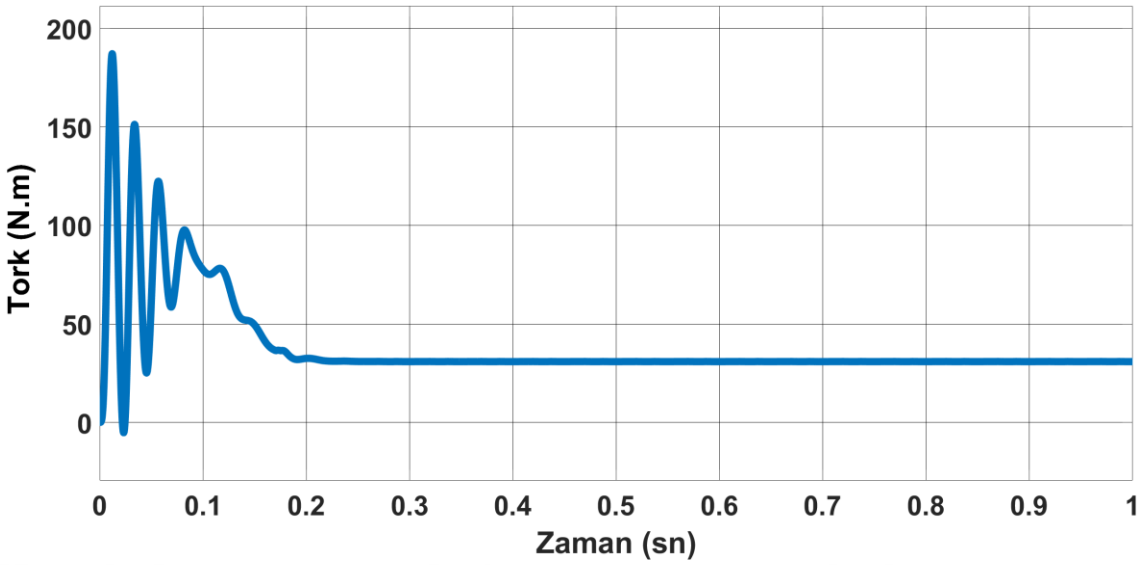
Şekil 3.14. Stator direncinin 0.64 Ω ve stator sargılarının termal kütlesinin 1.25 kg olduğu durum için stator sargılarının sıcaklığı (75.1 °C**)**

Sistemin verimlilik ve sıcaklık değerlerine göre sınır değerleri aşağıda Çizelge 3.2'de gösterilmiştir. Gösterilen bu sınır değerlerine göre sistemin başarı veya başarısızlık durumu belirlenecektir.

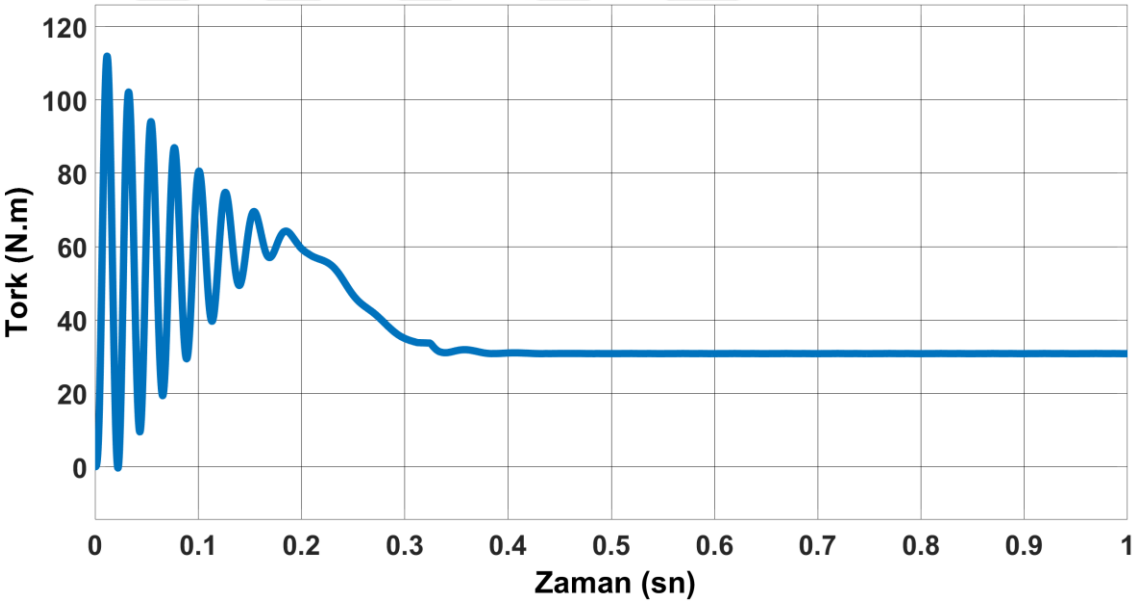
Çizelge 3.2. Sistemin verim ve sıcaklık durumuna göre başarı veya başarısızlık durumu

Verimlilik Durumu	Sıcaklık Durumu	Başarı Durumu
%80'den az	180°C'den büyük	Başarısız
%80'den az	180°C'den küçük	Başarısız
%80'den büyük	180°C'den büyük	Başarısız
%80'den büyük	180°C'den küçük	Başarılı

Başarılı ve başarısız olarak etiketlenen sistemler için Tork grafikleri Şekil 3.15 ve Şekil 3.16'da gösterilmiştir.

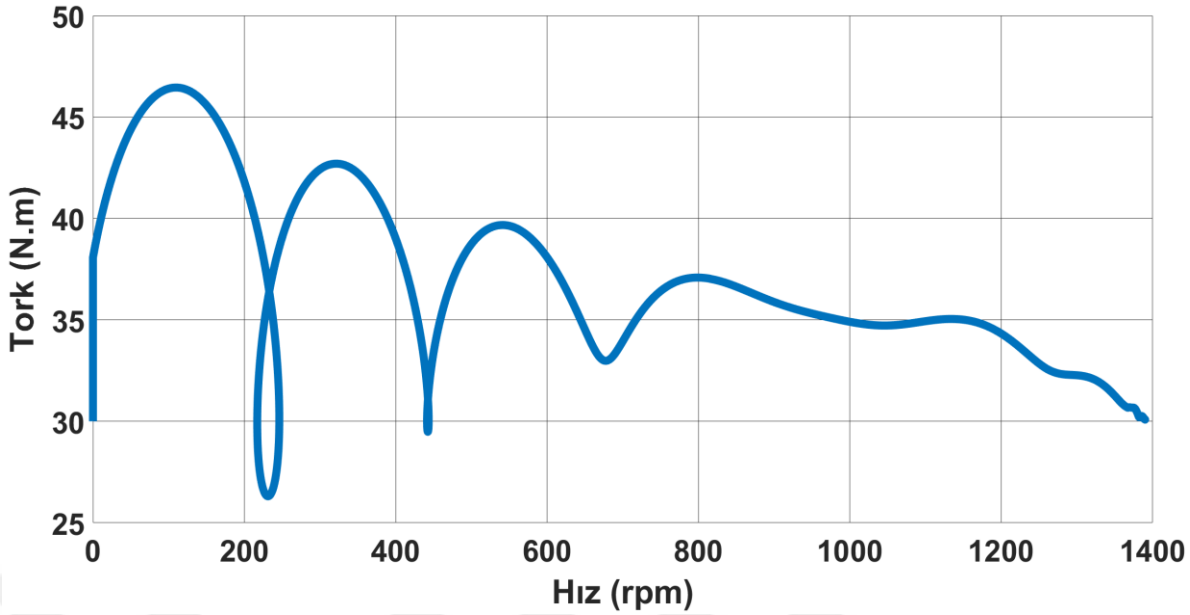


Şekil 3.15. Başarılı olarak etiketlenen durum için tork grafiği

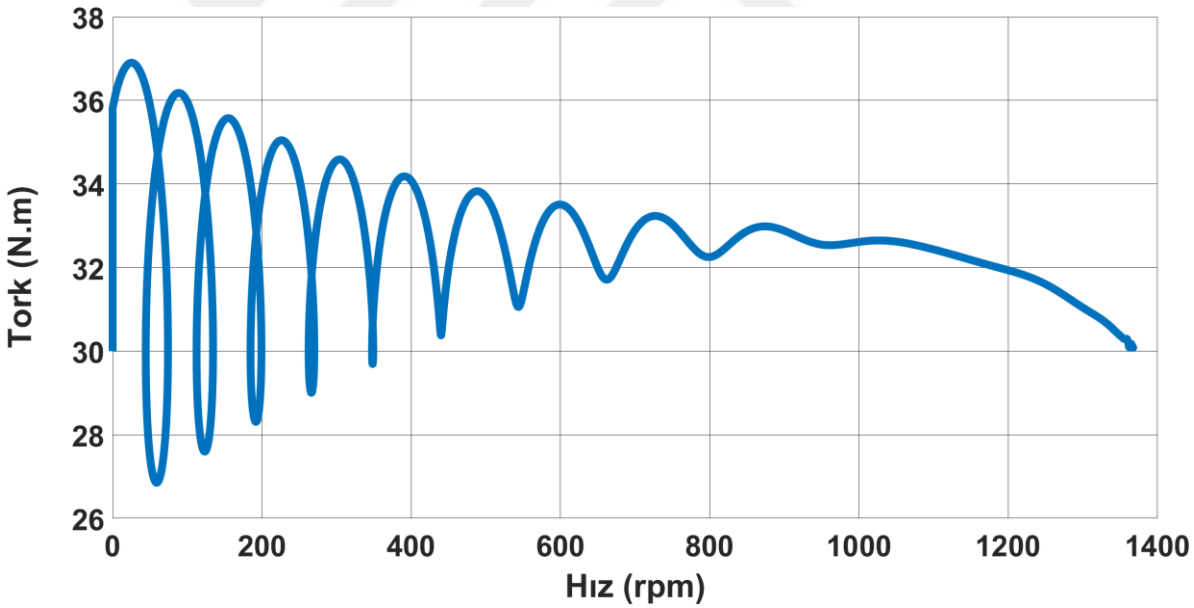


Şekil 3.16. Başarısız olarak etiketlenen durum için tork grafiği

Doğruluk oranı ve yapay sinir ağlarına olan etkilerinin karşılaştırılması için, Tork grafiği yerine Tork-Hız grafiklerinin kullanıldığı, başka bir veri setinin oluşturulduğu daha önce bahsedilmişti. Bu doğrultuda tork-hız grafikleri için başarılı ve başarısız olarak etiketlenen görseller Şekil 3.17 ve Şekil 3.18'de görülebilir.



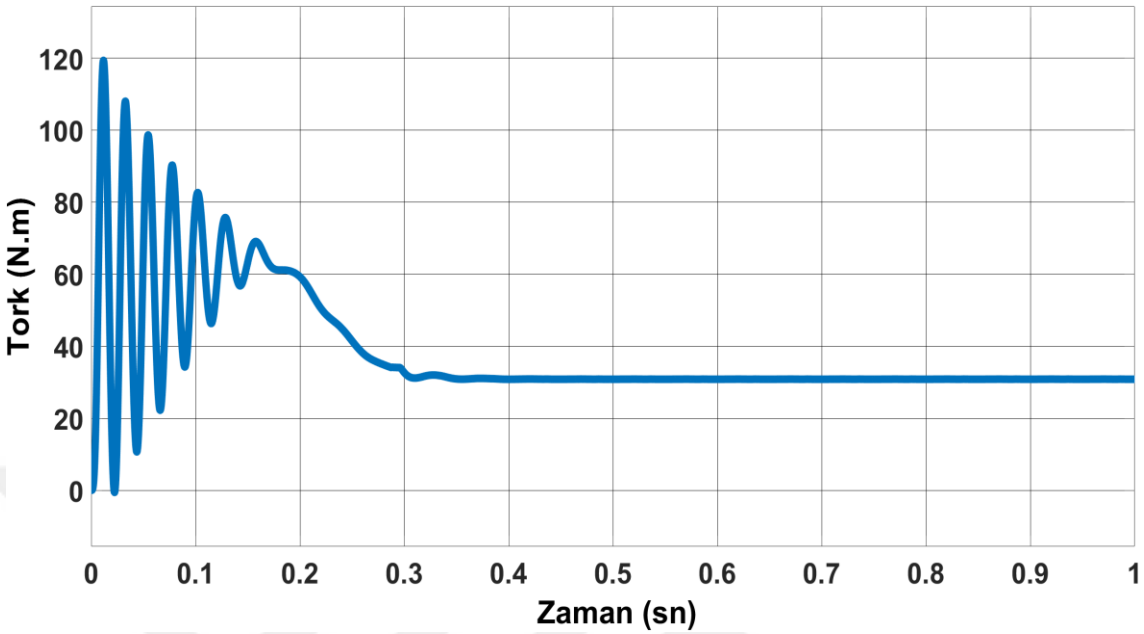
Şekil 3.17. Başarılı olarak etiketlenen durum için tork-hız grafiği



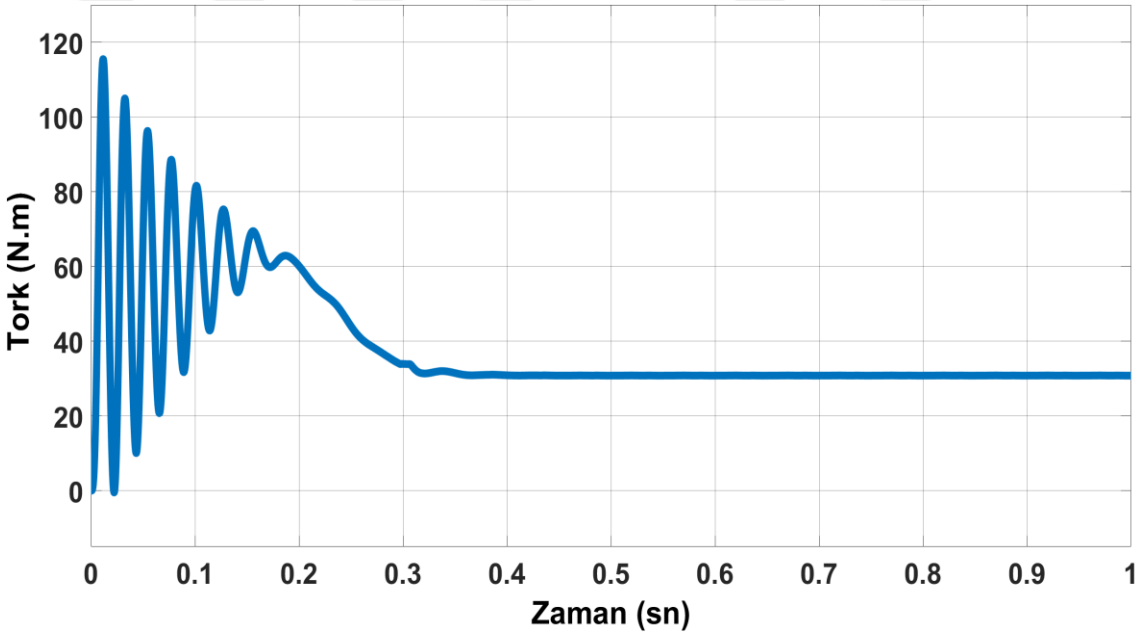
Şekil 3.18. Başarısız olarak etiketlenen durum için tork-hız grafiği

Başarılı ve başarısız olarak belirlenen grafiklerdeki farkları net olarak gösterebilmek adın Şekil 3.15, Şekil 3.16 ve Şekil 3.17, Şekil 3.18'te gösterilen grafikler sistemin en başarılı ve en başarısız olduğu noktalara yakın yerlerden elde edilmiştir. Ancak her zaman sistemin başarılı ve başarısız olduğu noktalar bu kadar net belirlenememektedir. Yapay sinir ağlarına ihtiyaç duyulmasındaki nedenlerden biri de budur. Aşağıda başarılı ve başarısız durumların birbirine yakın olduğu durumlar için Şekil

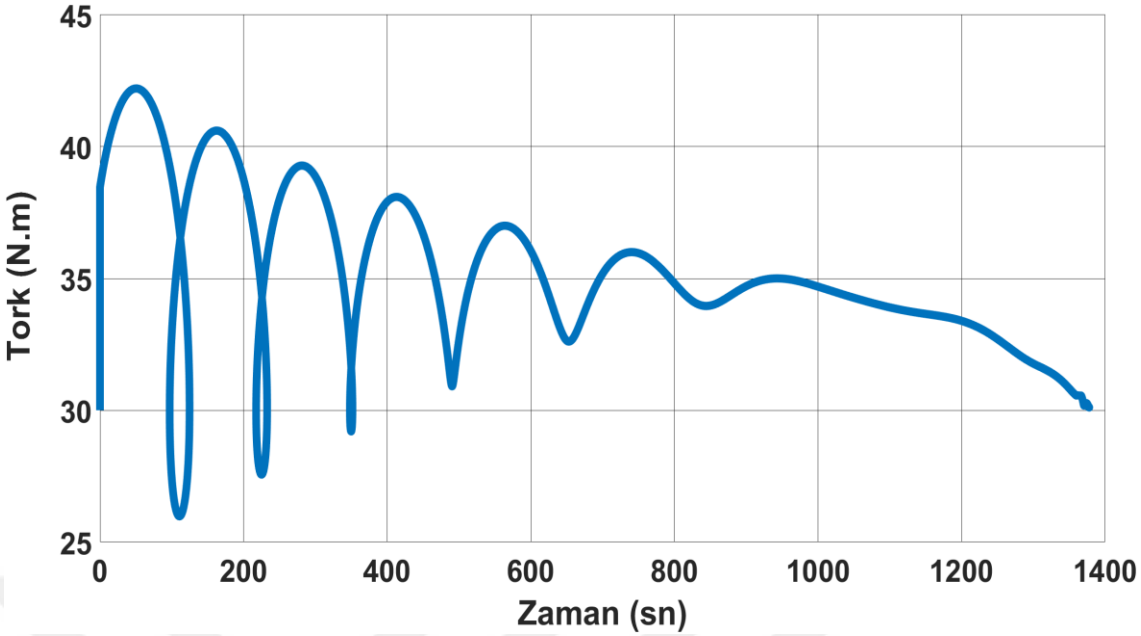
3.19 ve Şekil 3.20'de sınırdan alınmış örnek tork grafikleri verilirken Şekil 3.21 ve Şekil 3.22'de sınırdan alınmış tork-hız grafikleri verilmiştir.



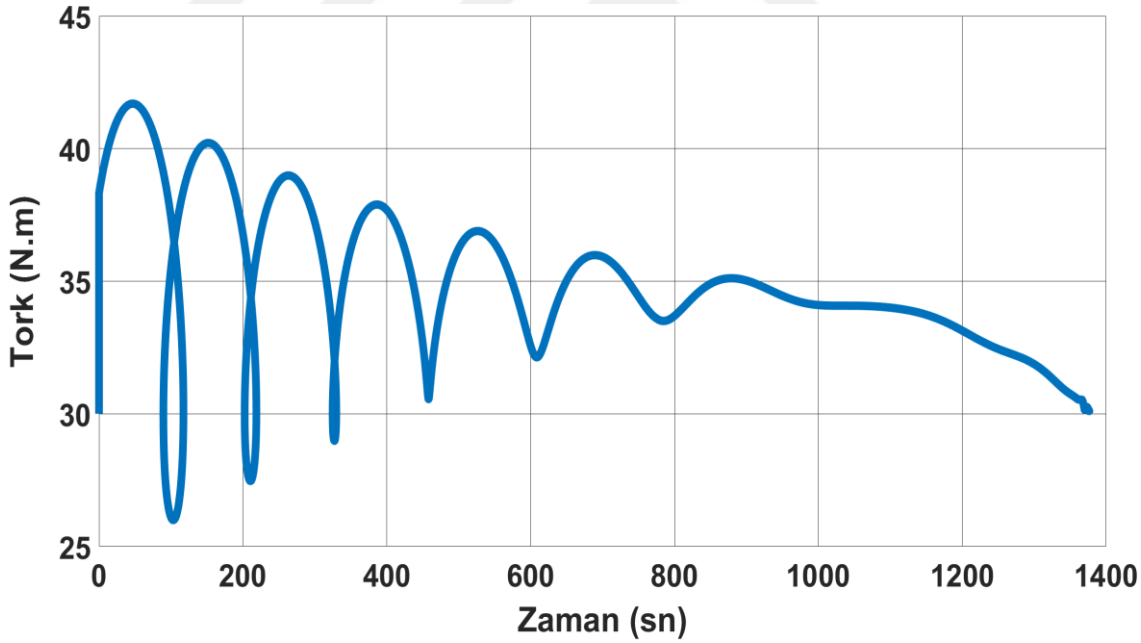
Şekil 3.19. Başarı sınırından alınmış ve başarılı olarak etiketlenen tork grafiği



Şekil 3.20. Başarı sınırından alınmış ve başarısız olarak etiketlenen tork grafiği

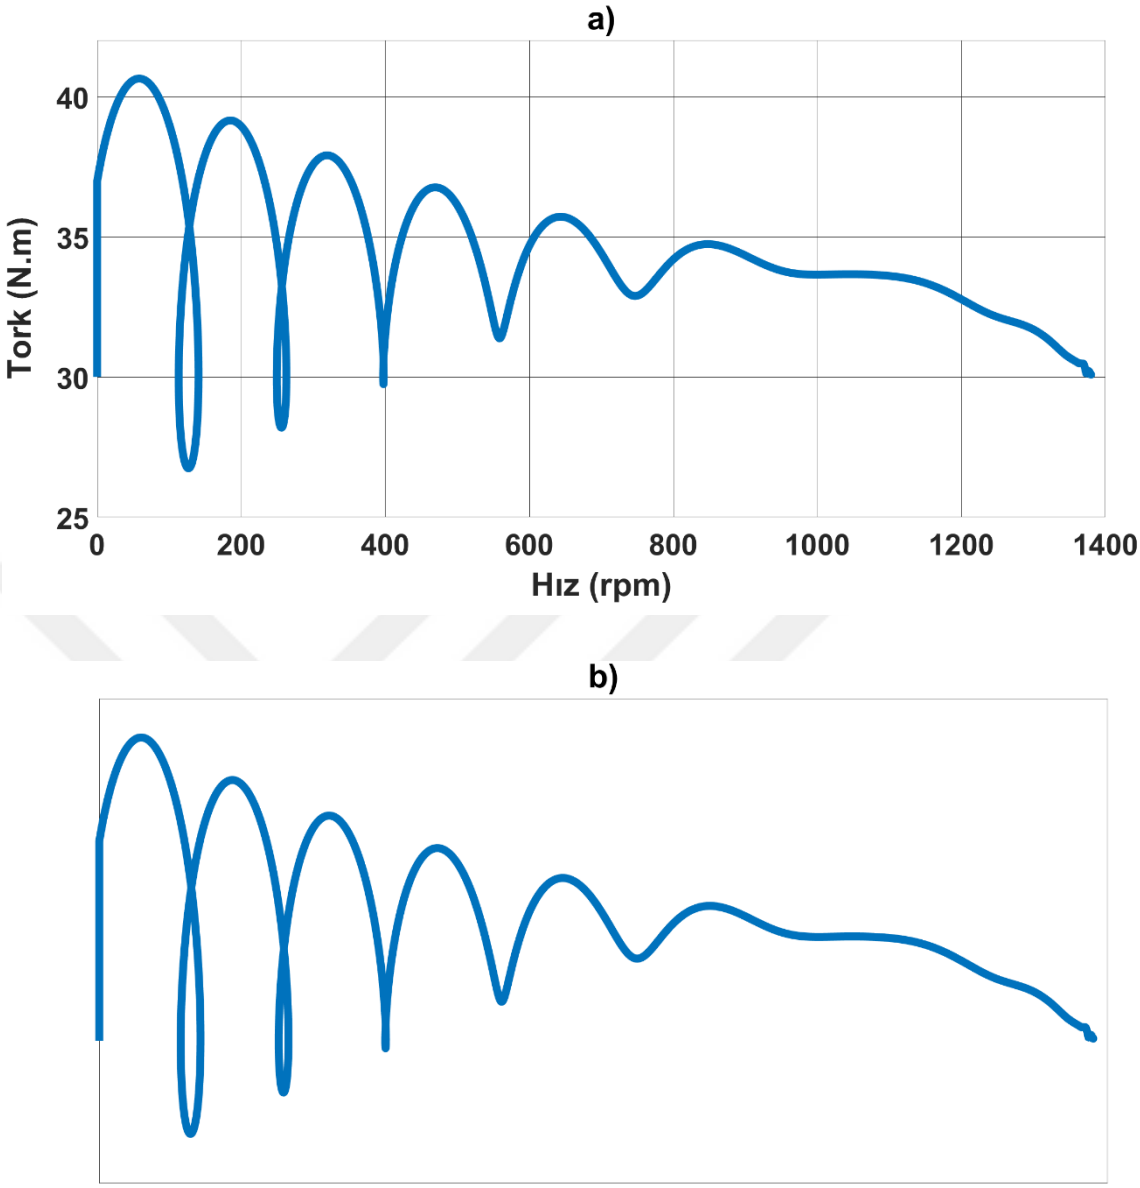


Şekil 3.21. Başarı sınırından alınmış ve başarılı olarak etiketlenen tork-hız grafiği



Şekil 3.22. Başarı sınırından alınmış ve başarısız olarak etiketlenen tork-hız grafiği

Görüldüğü gibi iki grafik neredeyse aynı gözükmesine ve farkın gözle ayırt edilememesine rağmen farklı etiket değerlerine sahiptirler. Ayrıca kullanacağımız yapay sinir ağlarının grafiğe odaklanması ve diğer etkenlerden etkilenmemesi için grafiklerdeki eksen yazıları, grid çizgileri, sayılar, başlıklar gibi unsurların grafikten çıkarılması gerekmektedir. Aşağıda tork Şekil 3.23'te tork-hız grafiği üzerinden sinir ağının girişine verilecek örnek bir görüntü gösterilmiştir.



Şekil 3.23. Sistemden alınan örnek tork-hız grafikleri **a)** üzerinde eksen yazıları, grid çizgileri, sayısal değerler bulunan tork-hız grafiği **b)** yapay sinir ağının girişine verilecek olan yazılardan arındırılmış tork-hız grafiği

3.2. Asenkron Motor ve Asenkron Motor Termal Devresinin İkinci Modelinin Oluşturulması

3.2.1. İkinci Model İçin Stator Sargılarının Termal Kütlesinin Artırılması

Buraya kadar yapılan çalışmalarda stator sargılarının termal kütlesinin 1.00 kg ve 1.25 kg olarak kabul edildiği durumlar için veri setleri oluşturulmuştur. Ancak stator sargılarının termal kütlesinin 1.25 kg kabul edilmesi durumunda ortaya çıkacak tel kalınlığının, sarılı bulunduğu nüveye etkisi analiz edilmemiş ya da başka bir deyişle ihmal edilmiştir. Stator sargılarının termal kütlesinin 1.00 kg'dan 1.25 kg'a çıkması durumunda

tel kalınlığı artacak, buna bağlı olarak sarım sayısının sabit kalması durumunda nüve büyüklüğü artacaktır. Nüve büyüklüğünün arttığı durum için ise demir kayıplarında artış meydana gelecektir. Demir kayıplarının artması durumunda sistem verimi değişecek ve buna bağlı olarak Tork değerlerinde de düşüş meydana gelecektir. Stator sargılarının termal kütlesinin 1.00 kg'dan 1. 25 kg'a çıkması durumunda sistemde yaşanacak değişim aşağıdaki Çizelge 3.3'te verilmiştir.

Çizelge 3.3. Stator kütlesinin 1.00 kg'dan 1.25 kg'a çıkması durumunda sistem değerlerinde yaşanacak değişim.

Sistem Değişkeni	Sistem Değişkeninde Yaşanacak Değişim
Tel Kalınlığı	Artar
Nüve Boyutu	Artar
Demir Kaybı	Artar
Tork	Azalır
Verim	Azalır

İlk olarak stator sargılarının termal kütlesinin 1.25 kg'a çıkacağı durum için tel kalınlığının hangi seviyede artacağı hesaplanmalıdır. Daha önce kullanılan Denklem 3.17 aşağıda verilmiştir.

$$m = d \times V$$

Bu ifadeden yola çıkarak, bakır özkütlesinin sabit kalması durumunda kütlesi artarsa hacmi de kültesinin arttığı oranda artacaktır. Bu ifade aşağıda Denklem 3.23'te ifade edilmiştir.

$$1.25 \times m = d\ (sabit) \times (1.25 \times V) \tag{3.23}$$

Hacmin arttığı durum için ise tel uzunluğunun sabit kaldığı kabul edilirse bu kez kesit alanı hacimle aynı oranda artacaktır. Bu ifadeyi elde etmek için önce Denklem 3.18'i hatırlamamız gerekmektedir, bu nedenle ilgili denklem aşağıda tekrar belirtilmiştir.

$$V = A \times L$$

Daha sonra istenilen artış oranını elde edilişi ve matematiksel ifadesi Denklem 3.24'te belirtilmiştir.

$$1.25 \times V = (1.25 \times A) \times L\ (sabit) \tag{3.24}$$

Sonuç olarak uzunluğun ve özkütlenin sabit kabul edildiği durum için kütlede yaşanacak artış, aynı oranda kalınlığı da etkileyecektir.

Yapılan hesaplamalarda stator sargılarının uzunluğu sabit kabul edilmiştir, bu da sarım sayısının sabit kabul edildiği anlamına gelmektedir. Sarım sayısının sabit kabul edildiği durum için stator sargılarında yapılacak büyüme aynı oranda nüve büyümesine de neden olacaktır. Sarım sayısı ile tel kalınlığı çarpımı yaklaşık olarak nüve uzunluğunu verecektir. Bu ifade Denklem 3.25'te ifade edilmiştir.

$$Sarım\ sayısı\ \times\ Tel\ Kalınlığı \approx Nüve\ Uzunluğu \tag{3.25}$$

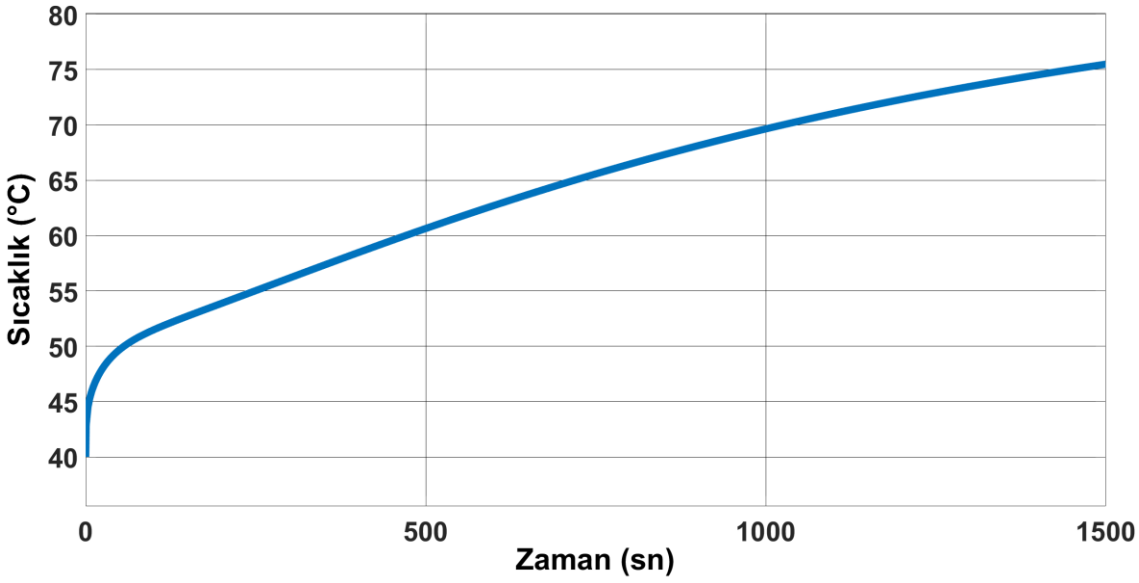
İfadeden yola çıkarak tel kalınlığındaki artış oranında nüvenin büyüyeceği kabulü yapılabilir. Bu kabul de denklem 3.26'da ifade edilmiştir.

$$Sarım\ sayısı \times (1.25 \times Tel\ Kalınlığı)\ \approx 1.25 \times Nüve\ Uzunluğu \tag{3.26}$$

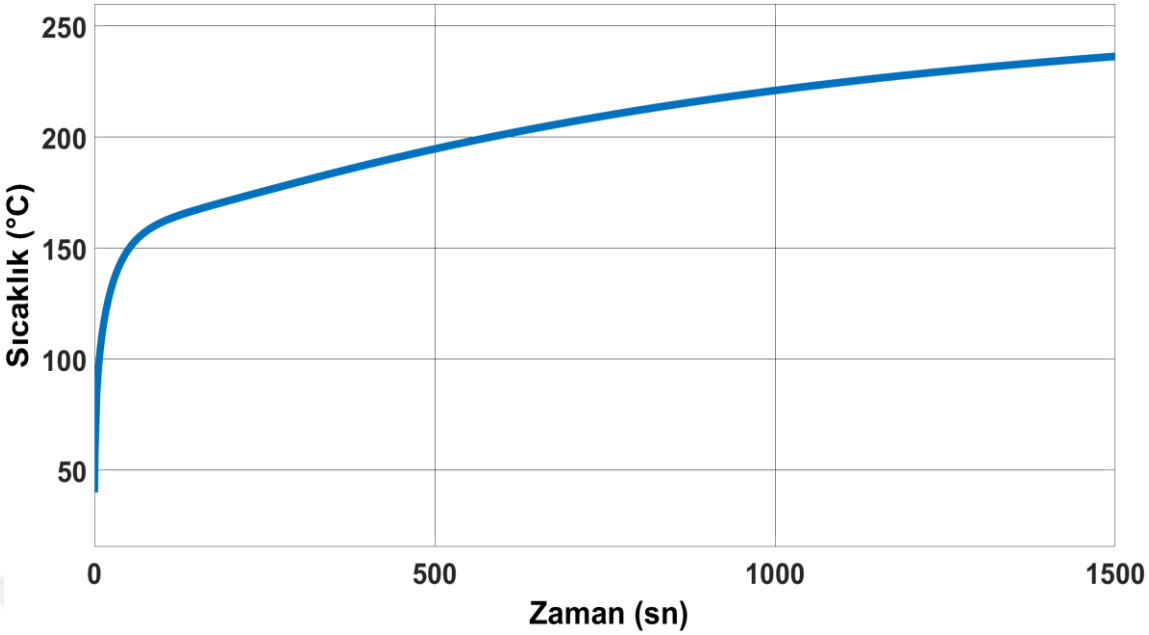
Nüve uzunluğundaki artışın, nüve boyutunu ve demir kaybını artıracaktır. Nüve boyutunun (hacminin) ve demir kaybının artışının nüve uzunluğu ile aynı oranda arttığı kabul edilmiş, bu kabul aşağıda Denklem 3.27'de gösterilmiştir.

$$1.25 \times Nüve\ Uzunluğu \approx 1.25 \times Nüve\ Hacmi \approx 1.25 \times Demir\ Kaybı \tag{3.27}$$

Demir kaybının artmasıyla ile sistemin verimi düşmüş aynı zamanda da sıcaklık değerlerinde değişim yaşanmıştır. Dolayısıyla veri setlerini sınıflandırmak için kullanacağımız sınır değerleri değişmiştir. Bu da başarılı veya başarısız olarak etiketlenecek verilerin sınıflandırılmasını etkilemiştir. Aşağıda Şekil 3.24 ve Şekil 3.25'te stator sargılarının termal kütlesi 1.25 kg iken sistemin en düşük ve en yüksek direnç değerleri için demir kaybının artırılmasıyla elde edilmiş yeni sıcaklık grafikleri verilmiştir.

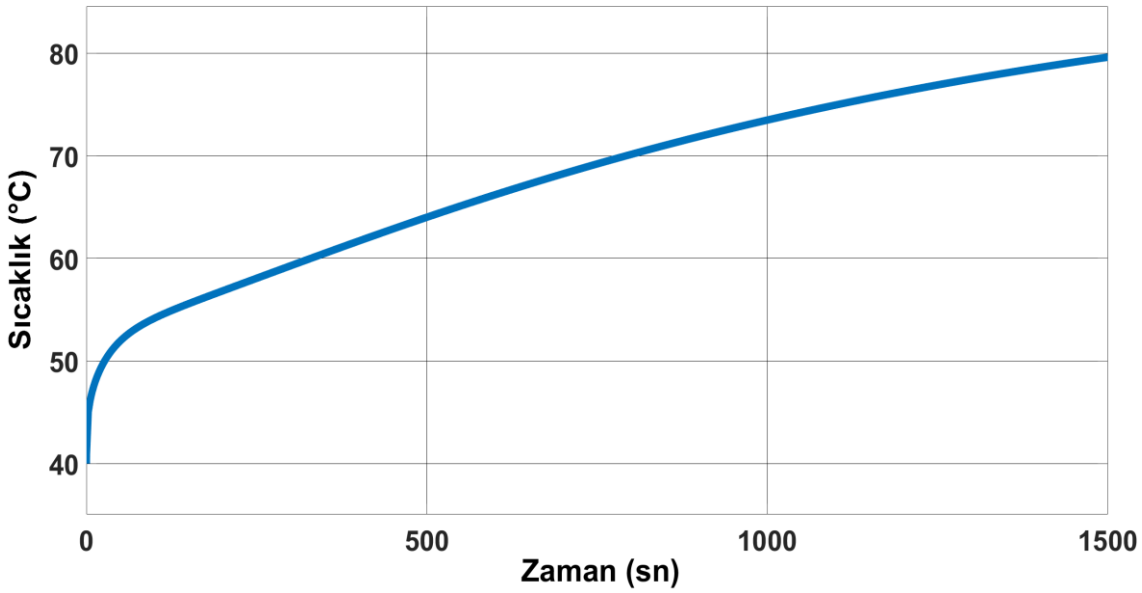


Şekil 3.24. Demir kaybının artırılmasıyla stator direncinin 0.64 Ω ve stator sargılarının termal kütlesinin 1.25 kg olduğu durum için stator sargılarının yeni sıcaklığı (75.5 °C)



Şekil 3.25. Demir kaybının artırılmasıyla stator direncinin 4.7 Ω ve stator sargılarının termal kütlesinin 1.25 kg olduğu durum için stator sargılarının yeni sıcaklığı (233.5 °C**)**

Daha önce sistemin en düşük sıcaklığının stator direncinin 1.25 kg olduğu durum için gerçekleşeceğini öngörmüş ve bunun üzerine hesaplamalarımızı yapmıştık. Ancak nüve hacminin büyümesinin hesaba katılmadığı durumda için 0.8 Ω için sıcaklık değeri 79.3 °C iken nüve hacminin büyümesini hesaba kattığımız zaman bu sıcaklık 79.6 °C'ye yükselmiştir. Sistemin 0.8 Ω için yeni sıcaklık değeri aşağıda Şekil 3.26'te verilmiştir.



Şekil 3.26. Demir kaybının artırılmasıyla stator direncinin 0.8 Ω ve stator sargılarının termal kütlesinin 1.25 kg olduğu durum için stator sargılarının yeni sıcaklığı (79.6 °C)

Ancak 4.7 Ω için bakıldığında nüve ağırlık artışı yapılmamış modelde, yani birinci modelimizde sıcaklık değeri 235.5 °C'ye ulaşırken, nüve ağırlığının artırıldığı model olan ikinci modelimizde sıcaklık 233.5 °C ölçülmüştür. Yani nüve kütlesinin arttığı her durum için sıcaklığın da arttığı doğrusal bir ilişki kurulamamaktadır. Bu durum, sistemin artan kayıplarla birlikte doğrusal bir yapıdan uzaklaşarak ısıl kütle ve ısı yayılım mekanizmalarına duyarlı bir davranış sergilediğini düşündürmektedir. Düşük kütleli nüve, düşük stator dirençlerinde ısınmaya karşı daha dayanıklı iken, yüksek stator dirençlerine çıkıldığında ve sıcaklık değerleri yükseldiğinde, yüksek kütleye sahip nüvenin sıcaklık bakımında daha avantajlı olduğu görülmüştür. Aynı stator direnç değerleri için, bakır kaybı yaklaşık olarak aynı kabul edilirse, kütlesi artırılmış nüvede, normal sıcaklık değerlerinde, kütle artışına bağlı olarak demir kayıplarının artması, buna bağlı olarak da sıcaklığın daha yüksek değerlere ulaşması beklenmektedir. Ancak yüksek stator direncinin neden olacağı yüksek sıcaklık bölgelerine çıkıldığında düşük kütleli nüveye sahip modelin daha dezavantajlı hale geldiği görülmüştür çünkü ısıl birikimin, kütle artışı yapılmamış nüvede çok daha hızlı gerçekleşeceği kanısına varılmıştır. Buna ek olarak, aynı malzemeden yapılmış ve daha yüksek kütleye sahip nüvenin genellikle daha geniş bir yüzey alanına sahip olması, soğutma açısından ısı transferini kolaylaştırarak termal performansın üzerinde olumlu bir etki yaratacağı düşünülebilir.

Aynı durum için sistemin tork değerleri de değişecektir. Demir kaybının artması ile birlikte torkta da düşüş meydana gelecektir. Nüvenin hacim artışının hesaba katılmadığı durumlda Tork değeri 30.73 N.m iken, nüve hacim artışının hesaba katılması ile birlikte Tork değeri 30.7 N.m değerine düşmüştür.

İkinci model için sistemde kayıplar ve sıcaklık değerleri değişeceğinden birinci model ile aynı direnç değerlerinde elde edilecek verim ve sıcaklık değerleri farklı olacaktır. Bu da sınır değerler içerisinde kalacak ve başarılı veya başarısız olarak etiketlenecek verileri etkileyecektir. Sınır Değerleri içerisinde veya dışarısında kalan verilerin değişmesinden dolayı, veri setlerimiz de değişecek hatta veri sayımız artacaktır. Daha önce direnç – termal ağırlık ilişkisini sadece direnç değerlerinin azaltılması ile ilişkilendirdiğimiz için bazı örnek alımlarında aynı direnç değerleri elde edilebilmekteydi. Örneğin 0.1 Ω aralıklarla artırdığımız dirençlerimizde artış sırasında kendi arzumuzla 1.2 Ω direncini seçerek örnek alıyor ve sistem sonucumuzu da başarılı veya başarısız olarak etiketliyorduk. Ancak örnek alınırken yine 0.1 Ω artım aralıklarına denk gelen 1.6 Ω direnci de stator sargılarının termal kütlesi 1.25 kg'a çıkarıldığında Denklem 3.22 deki gibi %25 oranında küçülerek 1.2 Ω direncine karşılık geliyordu, bu nedenle bir veriyi 2 kez yazmamak adına tek bir örneklem alınıyordu.

Ancak nüve ağırlığının sisteme dahil edilmesi ile direnç – termal ağırlık ilişkisi sadece direnç değerlerinin azalması ile ilgili kalmayacak, aynı zamanda nüve ağırlığı ve buna bağlı olarak demir kayıplarının da yeniden modellenmesi ile ilişkilendirilecektir. Yani ilk durum düşünüldüğünde, sistemimiz kendi içinde etkileşime giren, değişimlerin diğer elemanları da etkilediği bir sisteme evrilmiştir denilebilir. Veri üretimi sırasında bilinçli olarak alınan 1.2 Ω değeri ile stator sargı kütlesinin artırılmasıyla 1.6 Ω seviyesinden 1.2 Ω seviyesine düşen direnç değerleri, değer olarak aynı gözükse de sisteme etkisi farklı olacak, farklı sıcaklık ve verim değerleri üreteceklerdir.

3.2.2. Asenkron Motorun İkinci Modelinin Simulink Üzerinde Oluşturulması

Yapılan hesaplamalar sonucu motor modeli üzerinde yeni hesaplanacak olan demir kayıplarının ve verim değerlerin gösterilmesi gerekmektedir. Bu nedenle birinci modelde kurulan motor modelinde demir kayıplarının hesaplandığı kısma bir katsayı eklenmiş ve katsayı 1.25 olarak belirlenmiştir. Yeni demir kaybı ve eski demir kaybı arasındaki denklem aşağıda Denklem 3.28'de verilmiştir.

$$(P_{Fe})_{Yeni} = 1.25 \times (P_{Fe})_{Eski} \tag{3.28}$$

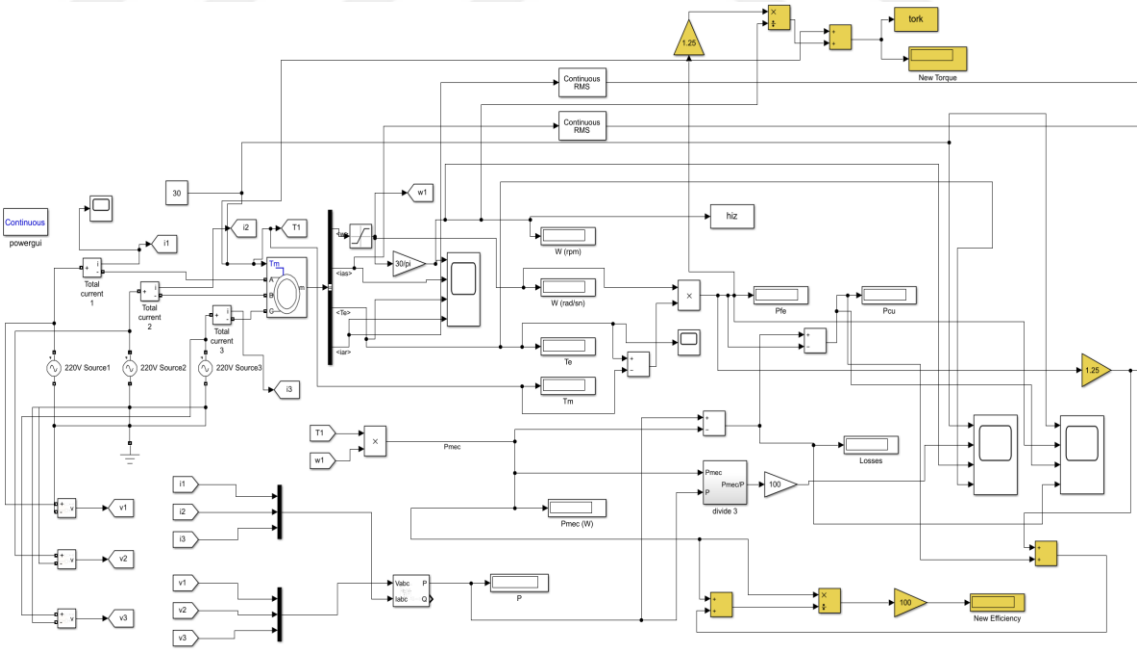
Denklem 3.7 yeni demir kaybı kullanılarak tekrar hesaplanmış ve kayıplara eklenmiş, ardından yeni verim değerleri hesaplanmıştır. Yeni demir kayıpları kullanılarak güncellenen denklem aşağıda Denklem 3.29'da gösterilmiştir.

$$T_m = T_e - \frac{(P_{Fe})_{Yeni}}{w} \tag{3.29}$$

Yeni demir kayıpları ile birlikte verim formülü de güncellenmiş, güncellenen verim formülü Denklem 3.30'da gösterilmiştir.

$$\%\, Verim = \frac{P_{Mec}}{P_{Mec}+P_{Cu}+(P_{Fe})_{Yeni}} \times 100 \tag{3.30}$$

Bu hesaplamalara bağlı olarak Simulink'te kurulan motor devresi güncellenmiş güncellenen devre şekil 3.27'te gösterilmiştir. Güncellenen kısımlar motor modelinde sarı renkte gösterilmiştir.



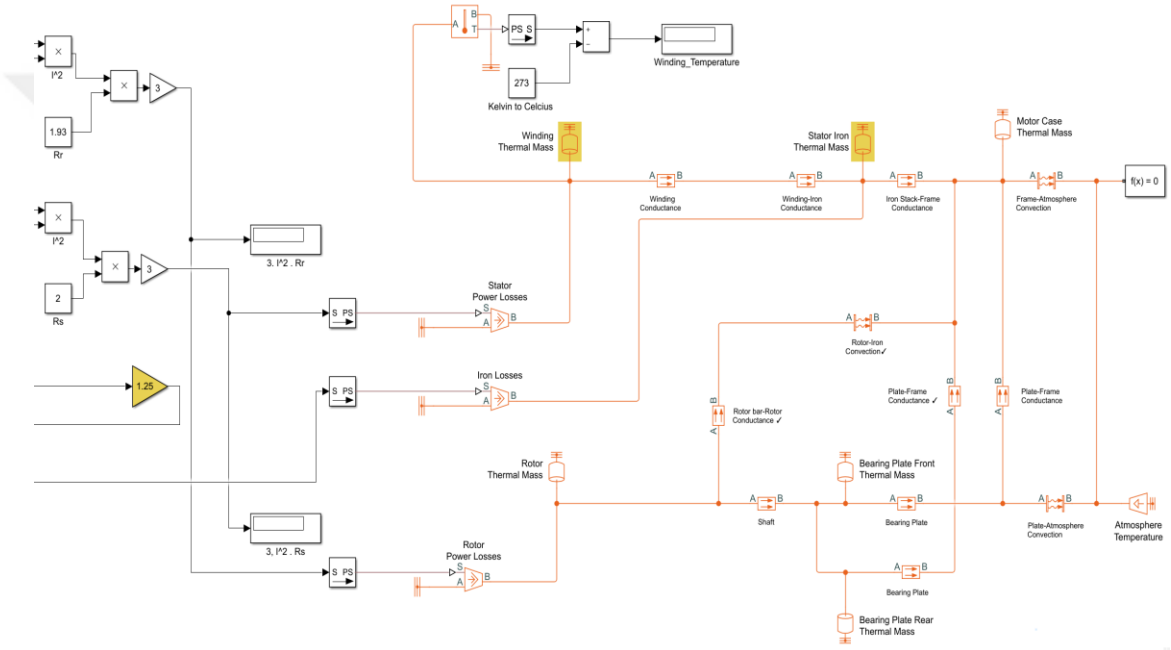
Şekil 3.27. İkinci modele göre güncellenen motor modeli

3.2.3. Asenkron Motor Termal Devresinin İkinci Modelinin Simulink Üzerinde Oluşturulması

İkinci model için termal devrede değişmesi gereken önemli kısımlar termal devreye girecek olan demir kayıplarının 1.25 ile çarpılması ve nüve kütlesinin yine 1.25 ile çarpılmasıdır.

Daha önce Çizelge 3.1'de verilen değerlerin güncellenmesi ve 1.25 ile çarpılması gerekmektedir. Stator sargılarının eski ağırlığı 1 kg iken yeni ağırlığı 1.25 kg olmuştur. Stator nüvesinin ağırlığı ise 12 kg'dan 15 kg ağırlığına çıkmıştır.

Buna bağlı olarak kurulan yeni termal devre aşağıda Şekil 3.28'de verilmiştir. Kütlesi değiştirilen devre elemanları ve eklenen 1.25 katsayısı sarı renkte gösterilmiştir.



Şekil 3.28. İkinci modele göre güncellenen termal devre

3.3. Çalışmada Oluşturulan ve Kullanılan Derin Öğrenme Yapıları

Çalışmada aynı veriler kullanılarak CNN, 1DCNN ve GoogLeNet derin öğrenme yapıları karşılaştırılmıştır. CNN ve 1DCNN için kullanılacak ağ mimarileri probleme özgü ve sıfırdan oluşturulmuştur. Bu ağ yapılarıyla kıyaslayabilmek için de önceden eğitilmiş GoogLeNet ağ yapısı da çalışmaya eklenmiştir.

3.3.1. Evrişimsel Sinir Ağı Yapısı

Çalışmanın amacı, çeşitli derin öğrenme teknikleri kullanarak stator direncinin ve termal parametrelerin elektrikli araçlarda verimlilik kaybını önlemek ve sürüş sırasında stabiliteyi korumak üzerindeki etkisini tespit etmektir. Bu amaçla, motor modeli ve motorun termal devresi MATLAB/Simulink üzerinde oluşturulmuştur. İlk olarak, motorun verimlilik değerleri ile birlikte stator sargılarının sıcaklık değerleri hesaplanmış ve ardından hem 1.00 kg hem de 1.25 kg ağırlığındaki stator sargısı termal kütlelerine

sahip motorlardan tork ve tork-hız grafikleri alınmıştır. Elde edilen grafikler, verimlilik ve sıcaklık değerlerin her ikisi de istenilen değer aralıklarında ise başarılı olarak, bunlardan biri veya her ikisi de istenen değer aralıklarının dışında ise başarısız olarak etiketlenmiştir. Belirlenen sınır değerler, verimlilik için %80 ve sıcaklık için 180 °C olarak kabul edilmiştir. Bu sınır değerler literatür taramalarından elde edilmiştir. Motordan alınan tork ve tork-hız grafikleri etiketlenerek hem 1.00 kg hem de 1.25 kg ağırlığındaki stator sargıları termal kütleleri için veri kümeleri oluşturulmuştur. Bu veri kümeleri daha sonra Evrişimsel Sinir Ağı (CNN) ve GoogLeNet için kullanılmıştır. 1DCNN ağ yapısında kullanabilmesi için ise grafik verilerinin MATLAB/Workspace çalışma alanı ortamına aktarılması ve .xlsx uzantılı olarak kaydedilmesi gerekmiştir. Çalışmada kullanılan sinyaller incelendiğinde sinyallerdeki ayırt edici farkın yaklaşık olarak 1 saniye içinde oluştuğu, daha sonra ise sinyalin kararlı duruma geçtiği görülmüştür. Bu nedenle alınan örnekler sinyallerin ilk 1 saniyelik zaman aralığından elde edilmiştir.

Evrişimsel sinir ağı (CNN), görüntü işlemede kullanılan ve görüntülerdeki ayırt edici özellikleri yakalayıp sınıflandıran bir algoritmadır. Farklı tür ve sayıda katmanlardan oluşabilmektedir. Yıllar içinde, farklı kişiler ve şirketler tarafından farklı CNN yapıları oluşturulmuş ve başkalarının kullanımına sunulmuştur. GoogLeNet de Google tarafından geliştirilen ve kendi mimarisine sahip, önceden eğitilmiş bir CNN yapısıdır. Inception modüllerini kullanan GoogLeNet'in 22 katmanı vardır. Bu çalışmada da Inceptionv3 modülü kullanılmıştır. 1DCNN, tek boyutlu bir evrişimsel sinir ağıdır. Tek boyutlu katmanların kullanıldığı bu ağda, girdiler görüntüler değil, tek boyutlu vektörlerdir. Ham veriler doğrudan 1DCNN'de kullanılabilir.

Çalışmada tork ve tork-hız grafiklerinden alınan 2 farklı veri seti bulunmakta olup, bu veri setleri 2 gruba ayrılmıştır. Sistemin düzgün çalışabileceği sınırlar içinde kalan sistem yapısından alınan görüntüler başarılı, sınırların dışında kalan sistem yapısından alınan görüntüler ise başarısız olarak etiketlenmiştir. Veri setleri her zamanki gibi eğitim veya test verisi olarak ayrılmamış, bunun yerine çapraz doğrulama uygulanmıştır.

Birinci ve ikinci modellerimiz her ikisi için de stator sargılarının termal kütlesinin 1.00 kg alındığı durumda 20 başarılı ve 20 başarısız görüntü bulunmaktadır. Stator sargılarının termal kütlesinin 1.00 kg + 1.25 kg alındığı durum için ise sınır değerleri değiştiği ve verilerin etiket değerleri farklılaştığı için birinci modelimizde 42 başarılı ve 30 başarısız olmak üzere 72 görüntü bulunurken, ikinci modelimizde 48 başarılı ve 32 başarısız görüntü bulunmaktadır. Çizelge 3.4’te birinci model için veri setleri ve içerdikleri toplam veri sayıları verilmiştir. Çizelge 3.5’te ise ikinci model için veri setleri ve içerdikleri toplam veri sayıları verilmiştir.

Çizelge 3.4. Birinci model için veri setleri ve içerdikleri toplam veri sayıları

Ağ Mimarisi	Veri Seti Türü	Veri Durumu	Örnek sayısı	Giriş Veri Boyutu	Veri Seti Toplam Boyutu
Evrişimli Sinir Ağı (Giriş verisi görüntü)	Tork	Başarılı	42	300 x 300	6.480.000
		Başarısız	30	300 x 300	
	Tork-Hız	Başarılı	42	300 x 300	6.480.000
		Başarısız	30	300 x 300	
GoogLeNet (Giriş verisi görüntü)	Tork	Başarılı	42	300 x 300	6.480.000
		Başarısız	30	300 x 300	
	Tork-Hız	Başarılı	42	300 x 300	6.480.000
		Başarısız	30	300 x 300	
1 Boyutlu Evrişimli Sinir Ağı (Giriş verisi 1 boyutlu zaman serisi)	Tork	Başarılı	42	10.500 x 1	966.000
		Başarısız	30	17.500 x 1	
	Tork-Hız	Başarılı	42	21.000 x 1	2.022.000
		Başarısız	30	38.000 x 1	

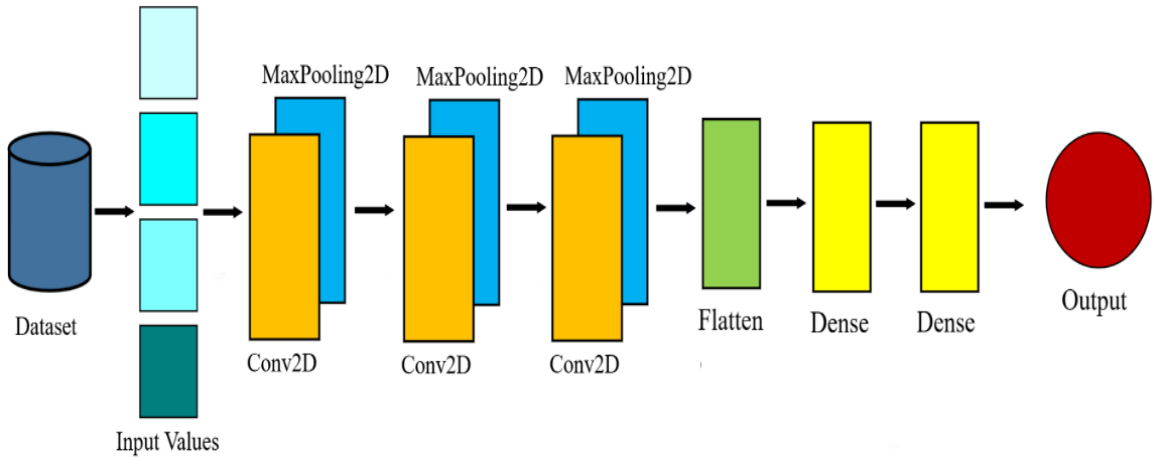
Çizelge 3.5. İkinci model için veri setleri ve içerdikleri toplam veri sayıları

Ağ Mimarisi	Veri Seti Türü	Veri Durumu	Veri Sayısı	Giriş Veri Boyutu	Veri Seti Toplam Boyutu
Evrişimli Sinir Ağı (Giriş verisi görüntü)	Tork	Başarılı	48	300 x 300	7.200.000
		Başarısız	32	300 x 300	
	Tork-Hız	Başarılı	48	300 x 300	7.200.000
		Başarısız	32	300 x 300	
GoogLeNet (Giriş verisi görüntü)	Tork	Başarılı	48	300 x 300	7.200.000
		Başarısız	32	300 x 300	7.200.000
	Tork-Hız	Başarılı	48	300 x 300	7.200.000
		Başarısız	32	300 x 300	
1 Boyutlu Evrişimli Sinir Ağı (Giriş verisi 1 boyutlu zaman serisi)	Tork	Başarılı	48	10500 x 1	1.112.000
		Başarısız	32	19000 x 1	
	Tork-Hız	Başarılı	48	21000 x 1	2.224.000
		Başarısız	32	38000 x 1	

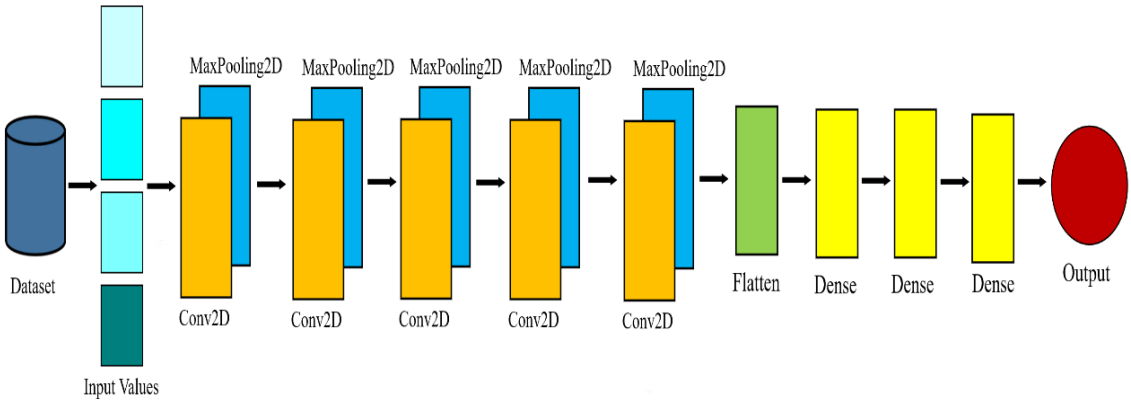
1DCNN yapısında, grafiklerdeki ham verileri kullanabilmek için önce MATLAB/Workspace ortamına aktarılmaları gerekmektedir. Daha sonra veriler .xlsx uzantılı bir Excel dosyası olarak kaydedilerek Python programlama dilinin tanıyabileceği bir formata dönüştürülecektir. 1DCNN ağ yapısında, çapraz doğrulama sütun sütun yapılır. Toplam sütun sayısının fold sayısına bölünmesiyle elde edilen yan yana sütunlar sırasıyla doğrulama kümesi, geri kalan sütunlar ise eğitim kümesi olarak kullanılmıştır. Yani tıpkı CNN yapısında olduğu gibi, tüm sütunlar ağın çalışması sırasında doğrulama

ve eğitim kümesi olarak kullanılmıştır. Ayrıca bir .xlsx dosyasında farklı boyutta sütunlar varsa bu boyutlar dosya içerisindeki en düşük boyutlu veriye göre kısatılmıştır. Yani .xlsx dosyasındaki her sütun en sonunda aynı uzunluktadır. CNN'de, farklı katmanlara sahip 2 farklı ağ yapısı kullanılmış ve sonuçlar her biri için ayrı ayrı test edilmiştir. Ayrıca çalışmanın güvenilirliğini artırmak için her ağ yapısı 2 farklı fold sayısı için test edilmiştir. En yüksek başarıyı elde etmek için çalışmada farklı ağ yapıları denenmiştir. CNN yapısı için Conv2D, MaxPooling2D, Flatten, Dense gibi katmanlar kullanılırken, 1DCNN yapısında Conv1D gibi tek boyutlu ağlar için özelleşmiş katmanlar kullanılmıştır. CNN için kullanılan ağ yapıları Şekil 3.29 ve Şekil 3.30'da gösterilmiştir. Aşırı uyumu (Overfitting) önlemek için Dropout katmanı da kullanılmıştır. Dropout katmanı ile istenilen yüzdeye bağlı olarak bazı nöronlar unutulur ve bu sayede bir seyreltilme işlemi gerçekleştirilir. Bu sayede ağ modeli, belirli bir nörona aşırı bağımlı olmaz ve overfitting engellenmiş olur. 1DCNN'de ise yukarıda da belirtildiği gibi 2D yerine 1D için tasarlanmış katmanlar kullanılmıştır. Örneğin, 1DCNN için Conv2D yerine Conv1D kullanılmıştır.

Conv2D katmanı, evrişimli sinir ağlarında kullanılan en önemli katmanlardan biridir ve özellikle görüntü işlemede kullanılır. Görüntü işlemede kullanılacak ağ mimarisinin temel yapı taşlarından biri olarak kabul edilir. Conv2D katmanı kayan bir pencere ile evrişim gerçekleştirir ve böylece görüntünün tüm noktalarını tarar. Veri setlerinde kullanılan görüntüler 2 boyutlu olduğu için bu katman da yükseklik ve genişlik girdisini kullanarak bir işlem gerçekleştirir ve sonucunda da bir adet tensör oluşturur. Pencere boyutları değişebilir, belirli bir ölçekte kullanılmak zorunda değildir. Örneğin 3x3 veya 4x4 olabilir. Bu kayan pencerelere "filter" veya "kernel" denir ve modelin öğreneceği ağırlıklar bu sayede hesaplanır.



Şekil 3.29. Tasarlanan 9 katmanlı evrişimsel sinir ağı yapısı



Şekil 3.30. Tasarlanan 14 katmanlı evrişimsel sinir ağı yapısı

Genellikle, Maxpooling katmanı Conv2D katmanından sonra gelir ve önceki katmanda elde edilen bilgilerin boyutunu küçültmek için kullanılır. Ayrıca, boyutu küçültürken önemli ayrıntıları koruyarak önceki görüntünün tanınmasını sağlar. Maxpooling katmanı da aynı Conv2D katmanı gibi görüntüyü tarar ancak bu sefer taradığı alanlardaki en yüksek değeri alarak o bölgedeki en baskın özelliği ön plana çıkarır. Böylelikle taranan görüntüdeki önemli bilgileri koruyarak o bölgedeki karakteristiği bozmaz ancak parametre sayısını hesaplama yükünü önemli ölçüde azaltır. Bu nedenle de veri boyutunu da yine önemli ölçüde küçültür. Maxpooling yukarıda sayılan nedenlerden dolayı derin öğrenme mimarilerinin en önemli katmanları arasında bulunur ve genellikle görüntü veya video tanıma uygulamalarında yaygın olarak kullanılır. Konvolüsyon ve Pooling katmanları genellikle çok boyutlu veriler üretir ve bu veriler üzerinde çalışır. Ancak, bu çıktıların Dense (tam bağlantılı) katmanlarına aktarılabilmesi için tek boyutlu bir vektöre dönüştürülmesi gerekir çünkü Dense katmanı girdi olarak tek boyutlu tensörler bekler. Flatten (Düzleştirme) katmanının temel amacı da bu verileri tek boyutlu bir vektöre dönüştürmektedir. Flatten katmanı basit ama çok önemli bir katmandır çünkü bir sinir ağının özellik çıkarma kısmı ile sınıflandırma kısmı arasında köprü görevi görmektedir. Dense katmanı ise tam bağlı katmanlardan biridir ve derin öğrenmenin temel parçalarından biridir. Bu katmanda nöronlar kendin önceki tüm nöronlarla bağlantılıdır. Model öğrenimi, çıktı ve girdi katmanları arasındaki nöronlar kullanılarak Dense katmanları aracılığıyla gerçekleştirilir. Dense katmanı kendinden önceki tüm nöronların ağırlıklarını alarak bunlara bir aktivasyon fonksiyonu uygular ve sonucu diğer katmanlara aktarır.

Geliştirilen evrişimli sinir ağı mimarilerinin karakteristik özelliklerini sıralayacak olursak ilk olarak giriş boyutlarından bahsedebiliriz. CNN ağ yapısı için 9 Katmanlı evrişimsel sinir ağı giriş boyutu 300 x 300 x 3 olarak belirlenirken 1DCNN için bu boyut [veri sayısı] x 1 şeklinde olacaktır. CNN ağ yapısı için 300 x 300 rakamları piksel sayılarını belirtmektedir. İfadenin sonunda bulunan x 3 ifadesi ise kanal sayısını belirtmektedir. Kullanılan ağın 3 kanallı yani RGB (Red-Green-Blue) görüntüleri kullanabildiğini göstermektedir. Bu da ağın renkli görüntüler ile çalışabileceğini belirtir. 300 x 300 ifadesindeki 300 çarpanları ise görüntünün yüksekliği ve görüntünün genişliğidir. 9 katmanlı mimarilerde 3 adet Conv2D/Conv1D katmanı kullanılmıştır. İlk Conv katmanının filtre sayısı 16'dır. İkinci Conv katmanının filtre sayısı 32 iken son Conv katmanının filtre sayısı 64'tür. Tüm Conv katmanlarının filtre boyutları 3 x 3 olarak

belirlenmiştir. Daha sonra Maxpooling katmanları kullanılmış ve bu katmanların pooling boyutu da 2 x 2 olarak belirlenmiştir. Ağ yapısında Flatten katmanından sonra 2 Dense katmanı kullanılmış olup kullanılan ilk Dense katmanının nöron sayısı 128'dir. Çıkış katmanındaki Dense katmanının nöron sayısı ise 1'dir. Çıkış katmanında 1 nöron kullanılmasının nedeni, problemde ikili sınıflandırma yapıldığı içindir. 9 katmanlı yapılarda ister 2 Boyutlu Evrişimli Sinir Ağı ister 1 Boyutlu Evrişimli Sinir Ağı yapısı olsun ikinci Conv ve Maxpooling katmanlarından sonra 0.1 oranında Dropout katmanı kullanılmıştır. Dropout oranı, nöronların o oranda geçici olarak devre dışı bırakıldığını göstermektedir. Örneğin Dropout (0.1) olarak verildiyse buradaki 0.1 oranı eğitim sırasında, nöronların %10'unun rastgele olacak şekilde devre dışı bırakıldığını gösterir ki bu da aşırı öğrenmeyi engellemek için kullanılmıştır. Diğer bir Dropout ise çıkış katmanından önce kullanılmıştır ve oranı 0.3'tür.

Kullanılan 14 katmanlı ağ yapılarında ise 5 adet Conv2D/Conv1D katmanı kullanılmıştır. CNN için 9 Katmanlı ağ yapılarına benzer şekilde 14 Katmanlı evrişimsel sinir ağı yapısı için de giriş boyutu 300 x 300 x 3 olarak belirlenirken yine 1DCNN için giriş boyutu [veri sayısı] x 1 şeklindedir. 9 katmanlı yapıya ek olarak 14 katmanlı yapıda 5 adet Conv katmanı kullanılmıştır. Birinci Conv katmanında 16 filtre varken, ikinci Conv katmanında 32, üçüncü ve dördüncü Conv katmanında 64 filtre vardır. Son Conv katmanında ise 128 filtre vardır. Conv katmanlarının filtre boyutu yine 3 x 3 iken yine her katmandan sonra Maxpooling katmanı gelmiştir. Maxpooling katmanlarının pooling boyutu yine 2 x 2'dir. Bu kez yine Flatten katmanından sonra 3 adet Dense katmanı kullanılmış olup, ilk Dense katmanının nöron sayısı 128 iken ikinci Dense katmanının nöron sayısı 64'tür. Çıkış katmanındaki Dense katmanının nöron sayısı ise yine önceki ağ yapısına benzer şekilde 1'dir. Ağ yapısında katman sayısı fazla olduğu için Dropout kullanımı da artırtılmış bu kez 4 adet Dropout katmanı ağ yapısına eklenmiştir. İkinci ve dördüncü Conv/Maxpooling katmanlarından sonra eklenen Dropout katmanlarının oranı 0.3 iken ilk ve ikinci Dense katmanlarından sonra Dropout kullanılmış olup oranları sırasıyla 0.4 ve 0.5'tir.

Kullanılan ağ yapılarında optimizer olarak "Adam" (Adaptive Moment Estimation) kullanılmış olup learning rate (öğrenme oranı) 0.001 olarak belirlenmiştir. Batch size 32 olarak belirlenirken tüm ağ yapılarında Epoch sabit alınmış olup epoch değeri 100'dür. Ara katmanlarda aktivasyon fonksiyonu olarak ReLu kullanılırken çıkış katmanında Sigmoid aktivasyon fonksiyonu kullanılmıştır.

Aşağıda 9 Katmanlı ve 14 Katmanlı ağ yapısı için kullanılan giriş değeri, filtre ve nöron sayıları ve aktivasyon fonksiyonu gibi özelliklerin bir özeti Çizelge 3.6 ve Çizelge 3.7'de verilmiştir.

Çizelge 3.6. 9 katmanlı ağ yapısı için kullanılan değerler

Katman Türü	Filtre / Nöron Sayısı	Filtre Boyutu	Pooling Boyutu	Aktivasyon Fonksiyonu
Conv	16	3 x 3	-	ReLu
Maxpoling	-	-	2 x 2	-
Conv	32	3 x 3	-	ReLu
Maxpoling	-	-	2 x 2	-
Dropout (0.1)	-	-	-	-
Conv	64	3 x 3	---	ReLu
Maxpoling	-	-	2 x 2	-
Flatten	-	-	-	-
Dense	128	-	-	ReLu
Dropout (0.3)	-	-	-	-
Dense	1	-	-	Sigmoid

Çizelge 3.7. 14 katmanlı ağ yapısı için kullanılan değerler

Katman Türü	Filtre / Nöron Sayısı	Filtre Boyutu	Pooling Boyutu	Aktivasyon Fonksiyonu
Conv	16	3 x 3	-	ReLu
Maxpoling	-	-	2 x 2	-
Conv	32	3 x 3	-	ReLu
Maxpoling	-	-	2 x 2	-
Dropout (0.3)	-	-	-	-
Conv	64	3 x 3	-	ReLu

(Devamı arkada)

Çizelge 3.7.'nin devamı.

Maxpoling	-	-	2 x 2	-
Conv	64	3 x 3	-	ReLu
Maxpoling	-	-	2 x 2	-
Dropout (0.3)	-	-	-	-
Conv	128	3 x 3	-	ReLu
Maxpoling	-	-	2 x 2	-
Flatten	-	-	-	-
Dense	128	-	-	ReLu
Dropout (0.4)	-	-	-	-
Dense	64	-	-	ReLu
Dropout (0.5)	-	-	-	-
Dense	1	-	-	Sigmoid

3.3.2. Bir Boyutlu Evrişimsel Sinir Ağı (1DCNN) Yapısı

Bir boyutlu evrişimsel sinir ağları, iki boyutlu evrişimsel sinir ağları gibi geleneksel görüntü tanıma mantığı yerine 1 boyutlu metin, ses ya da zaman serisi gibi sinyalleri işlemek için tasarlanmıştır. 1DCNN'de, girdi olarak görüntü yerine ham veriler kullandığından, ağ yapısı direkt olarak veri girişleriyle çalışabilir ve girdi zaman serisi olduğu için bu seriye ait veriler de seri içinde rakamsal olarak bulunabilir. Bu dataların ağa direkt olarak verilmesi de ağın örüntüyü tanımasını çok daha kolay hale getirmektedir. Ayrıca ağ bu şekilde ardışık verileri de işleyebilmekte ve ardışık veriler arasında kurduğu bağıntı ile tanıma ve başarı oranını da artırabilmektedir. Kullanılan ağın mimarisi sıfırdan tasarlanmış olup, önceden eğitilmiş ağ yapıları kullanılmamıştır.

1DCNN yapısını oluşturmak için, MATLAB üzerinden yapılan simülasyonun "To Workspace" bloğu ile Workspace ortamına aktarılması ve ardından .xlsx uzantısına dönüştürülmesi gerekmektedir. Aktarılan veriler daha sonra bir Excel tablosuna dönüştürülecek ve Basarili.xlsx ve Basarisiz.xslx olarak kaydedilmiştir. Daha sonra boyut uyuşmazlığını kaldırmak için sütun uzunlukları en düşük boyutlu sütuna göre kısaltılmıştır. 1DCNN yapısı hem tork hem de tork-hız veri setleri için kullanılmıştır.

3.3.3. GoogLeNet Yapısı

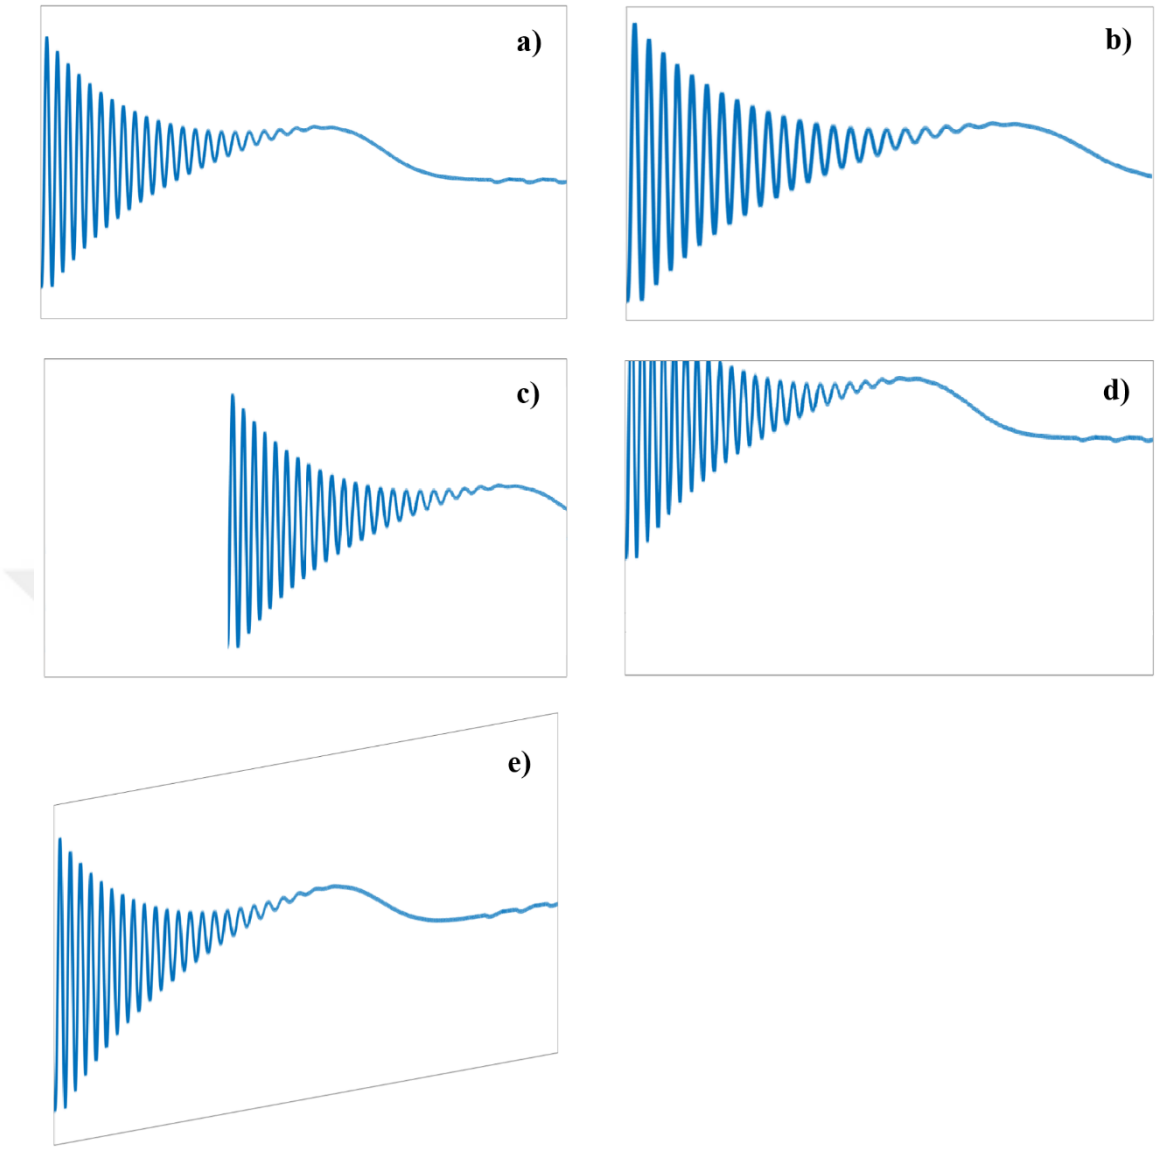
GoogLeNet, Google tarafından geliştirilmiş ön eğitimli bir modeldir. (Barber ve Oueslati 2024) Model ağırlıkları belirlenmiş bir öğrenme modeli olduğu için başarı oranı da yüksektir. Görüntü sınıflandırma uygulamalarında kullanılmak üzere tasarlanan bu derin öğrenme yapısı "Inception" modülleri içeren özel bir mimari kullanmaktadır. Daha önce hazırlanmış ve eğitilmiş milyonlarca görüntü ve binlerce sınıf içeren bu yapı sayesinde model en baştan eğitilmeye gerek duymadan öğrenme işlemini gerçekleştirebilmektedir.

CNN ve 1DCNN ağlarının yapısı sıfırdan oluşturulmuş ve önceden eğitilmiş bir ağ yapısı kullanılmamıştır. Ön eğitimli ağ yapılarının veri seti üzerinde nasıl çalıştığını görebilmek için de GoogLeNet ağ yapısı kullanılmış ve diğer derin öğrenme teknikleriyle karşılaştırılmıştır. GoogLeNet, Inception-v3 (Aljuaid vd. 2022) ağ yapısını kullandığı için, kendi katmanları ve ağırlıklarıyla sıfırdan kurulan bir ağ yapısına göre daha iyi sonuçlar elde edebilmektedir. Ayrıca, sistemin ağırlıkları değiştirilebilir ve gerekirse ek katmanlar eklenebilir.

3.4. Veri Arttırma ve Çapraz Doğrulama

Veri artırma, mevcut görüntülerin çeşitli işlemler uygulanarak (Kırpma, kaydırma, yakınlaştırma vb.) sentetik kopyalarının oluşturulması ile birlikte veri setini büyütmeye yarayan bir işlemdir. Çalışmada kullanılan veri kümelerimiz de görüntü içerdiği için, veri artırma işlemi gerçekleştirilmiş ve bu veri artırımı için ImageDataGenerator komutu kullanılmıştır. Görüntüler üzerinde Width Shift (Genişlik Kaydırma), Height Shift (Yükseklik Kaydırma), Shear Range (Eğim Aralığı) ve Zooming (Yakınlaştırma) gibi komutlar ile veri artırımı işlemleri gerçekleştirilmiştir. 1DCNN ağ yapısında ise girdi olarak görüntü kullanılmadığı ve doğrudan ham verilerle çalışıldığı için veri arttırma kullanılmamıştır. Veri artırım işlemlerinde 0.4 oranı tercih edilmiştir. Yani yukarıda belirtilen işlemler bir resme %40 oranında uygulanmaktadır. Örneğin bir resme %40 oranında zooming (yakınlaştırma) yapılırsa yaklaşık olarak 1.4 kat büyütülmüş görüntü veri olarak kullanılabilecektir.

Çapraz doğrulama, makine öğrenmesini nesnel ve doğru bir şekilde değerlendirmek için kullanılan bir yöntemdir. Bu yöntemde, veri kümesindeki görüntüler fold sayısına bölünür ve her fold işleminde sırasıyla doğrulama ve eğitim kümeleri değiştirilir. Örneğin, 50 görüntü içeren bir veri kümesinde fold sayısını 5 olarak alırsak, her foldda 10 görüntü olacak ve ilk fold döngüsünde, ilk 10 görüntü doğrulama (validaiton) verisi, kalan 40 görüntü ise eğitim verisi olacaktır. İkinci fold döngüsünde ise ikinci 10 görüntü doğrulama verisi, diğer 40 görüntü eğitim verisi olacaktır. Böylece tüm görüntüler sırasıyla eğitim ve doğrulama verisi olarak kullanılmış ve daha güvenilir sonuçlar elde edilmiş olacaktır. Aşağıda Şekil 3.31'de uygulanan veri çoğaltma yöntemlerine ait görüntüler verilmiştir.



Şekil 3.31. Veri çoğaltma yöntemlerine ait örnek görüntüler **a)** Orijinal sinyal görüntüsü **b)** Yakınlaştırma komutu uygulanmış sinyal görüntüsü **c)** Genişlik kaydırma komutu uygulanmış sinyal görüntüsü **d)** Yükseklik kaydırma komutu uygulanmış sinyal görüntüsü **e)** Eğim aralığı komutu uygulanmış sinyal görüntüsü

1DCNN'de sütunlar, belirlenen fold sayısına göre bölünür ve eğitim–doğrulama sütunları bu bölünmeye göre belirlenir. Örneğin, 30 sütundan oluşan bir 1DCNN veri setine 10 katlı çapraz doğrulama uygulanırsa, ilk 3 sütun doğrulama seti olarak, kalan 27 sütun ise eğitim seti olarak kullanılır. Daha sonra diğer 3 sütun doğrulama seti olarak alınır ve kalan 27 sütun tekrar eğitim seti olarak kullanılır. Eğer 5 fold belirtilirse, aynı işlem bu kez her fold için 6 sütun olacak şekilde yapılır. Tork-hız grafiğinde ise tork ve hız değerleri tabloda yan yana sütunlar olarak girilmiştir. Çapraz doğrulama sırasında bu iki sütun tek bir sütun gibi değerlendirilmiştir. Aynı işlemler bu durum için yeniden uygulanmıştır.

Veri artırma işleminde bir görüntünün farklı varyasyonları eğitim boyunca ağa sunulmuştur. Eğitim süresince model sınırlı örnek sayısına rağmen farklı varyasyonlara maruz bırakılmaktadır. Aşağıdaki tabloda 5 fold ve 10 fold içim modelin gördüğü toplam varyasyonlar Çizelge 3.8'de verilmiştir.

Çizelge 3.8. Veri artırma sonucu modelin gördüğü toplam varyasyonlar

Uygulanan Fold Sayısı	Toplam Veri	Eğitim Verisi	Epoch sayısı	Varyasyon Sayısı (1 Fold İçin)
5 Fold	72	58	100	5800
10 Fold	72	65	100	6500
5 Fold	80	64	100	6400
10 Fold	80	72	100	7200

4. BULGULAR VE TARTIŞMA

Çalışmalar sonucunda CNN, 1DCNN ve GoogLeNet ağ yapıları test edilmiştir. Veri artırma işlemi sadece CNN ve GoogLeNet ağ yapılarına uygulanırken, çapraz doğrulama işlemi 3 ağ yapısına da uygulanmıştır. Yapılan işlemler sonucunda 3 farklı ağ yapısı için, farklı katmanlar, farklı fold sayıları, farklı veri setleri ve iki farklı model denenerek başarı oranları elde edilmiştir. Ağ eğitimleri sırasında epoch değeri 100, batch değeri 32 ve öğrenme oranı 0.001 olup tüm ağ yapıları için aynı değerler kullanılmıştır. Elde edilen sonuçlar Çizelge 4.1'de gösterilmiştir.

Çizelge 4.1. Kullanılan metot, katman sayısı, fold sayısı ve veri setine göre elde edilen doğrulama başarı oranları

Kullanılan Metot	Katman Sayısı	Fold Sayısı	Veri Seti	1. Model İçin Başarı Oranı	2. Model İçin Başarı Oranı
CNN	9	5	Tork	%61	%65
CNN	9	10	Tork	%63	%62
CNN	14	5	Tork	%65	%70
CNN	14	10	Tork	%64	%64
GoogLeNet	-	5	Tork	%90	%91
GoogLeNet	-	10	Tork	%96	%92
1DCNN	9	5	Tork	%99	%99
1DCNN	9	10	Tork	%99	%98
1DCNN	14	5	Tork	%99	%99
1DCNN	14	10	Tork	%98	%97
CNN	9	5	Tork-Hız	%72	%80
CNN	9	10	Tork-Hız	%69	%68
CNN	14	5	Tork-Hız	%86	%83
CNN	14	10	Tork-Hız	%66	%69

(Devamı arkada)

Çizelge 4.1.'in devamı.

GoogLeNet	-	5	Tork-Hız	%97	%95
GoogLeNet	-	10	Tork-Hız	%97	%96
1DCNN	9	5	Tork-Hız	%99	%99
1DCNN	9	10	Tork-Hız	%97	%99
1DCNN	14	5	Tork-Hız	%96	%96
1DCNN	14	10	Tork-Hız	%97	%96

Çalışmada sırasında ağ yapılarının başarı oranını objektif bir şekilde test edebilmek için batch değeri, epoch değeri, öğrenme oranı ya da katmanlardaki nöron sayıları gibi değerler sabit tutulmuştur. 100 Epoch kullanılan çalışmada epoch sayısı artırılırsa nasıl bir sonuca ulaşılacağı araştırılmış ve ağ yapılarından bazılarına epoch sayısı 200'e çıkarılarak ağ tekrar eğitilmiştir. Epoch sayısı modelin veri üzerindeki eğitim döngüsünün sayısıdır, epoch sayısı arttıkça model veriler üzerinde tekrar eğitim gerçekleştirir. Epoch sayısının artması her zaman başarının da artıracağı anlamına gelmese de bizim ağ yapımızda başarı oranını artırmaktadır. Çünkü her epochta eğitim verisi tekrar görülür ve modelimizde epoch sayısı arttıkça ağ yapısı veriyi tekrar tekrar görerek farklılıkları daha iyi anlayabilmektedir. Ağ yapılarımızda kullanılan 100 Epoch ile kıyaslanabilmesi amacıyla epoch sayısı 200'e çıkarılmış ve sonuçlar aşağıda Çizelge 4.2'de verilmiştir.

Çizelge 4.2. İkinci Model için farklı iterasyon sayılarına göre başarı oranları

Kullanılan Metot	**Katman Sayısı**	**Fold Sayısı**	**Veri Seti**	**100 Epoch İçin Başarı Oranı (2. Model)**	**200 Epoch İçin Başarı Oranı**
CNN	9	5	Tork-Hız	%80	%88
CNN	9	10	Tork-Hız	%68	%80
CNN	9	10	Tork	%62	%77
CNN	14	5	Tork	%70	%74
1DCNN	14	5	Tork-Hız	%96	%97

CNN ağ yapısına bakıldığında elde edilen en yüksek başarı oranının %86 olduğu görülür. Ancak alınan farklı örneklerde yine bu bölümün ileriki paragraflarında değinilecek nedenlerden dolayı başarının %61'lere kadar düştüğü gözlemlenmiştir. Bu tez

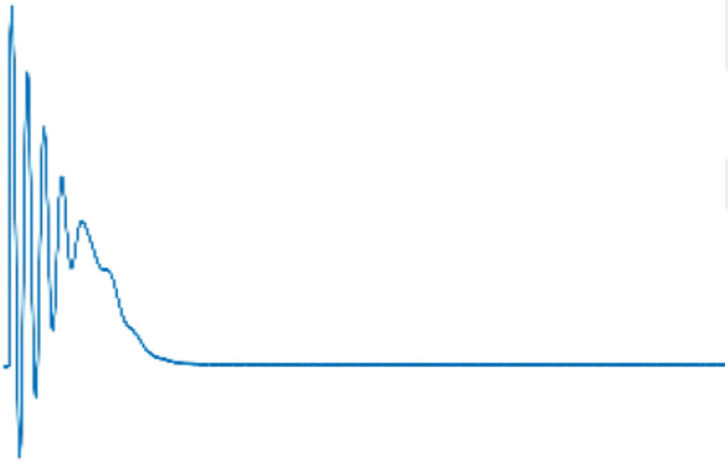
çalışmasında kullanılan evrişimli sinir ağı yapısının katmanları ve mimarisi sıfırdan yapılmış olup, ileride kıyaslanacak diğer ağ yapıları gibi önceden eğitilmiş ağ yapısı kullanılmamıştır. Katman sayıları, giriş değeri büyüklükler, filtre boyutları, aktivasyon fonksiyonları gibi değişkenler ağ yapısına uygun olarak belirlenmeye çalışılmıştır. Böylelikle önceden eğitilmemiş ve probleme özgü modellenen bir ağ yapısının olabilecek en iyi şekilde problemi anlaması ve öğrenmesi amaçlanmıştır. Bu ağa aynı zamanda özgün bir değer de vermektedir. Kullanılan veri setimiz, sıfırdan kurulan bir ağ yapısı tarafından kullanıldığında %86 başarı oranı oldukça iyi bir değerdir. Veri çoğaltma işlemi de bu oranı elde etmede etkili olmuştur. En düşük oran olan %61 ise farklı veri setlerinin ve fold sayılarının da başarıyı etkileyebileceğini göstermektedir. Aşağıda Şekil 4.3 ve Şekil 4.4'te CNN ağ yapısına ait doğru ve yanlış tahmin edilmiş görüntülerden birer örnek verilmiştir. Yapılan analizler sonucu ağ yapısının yanlış tahminleri daha çok veri artırımı uygulanmamış görüntülerden yaptığı sonucuna varılmıştır ki bu da veri artırımı yapılmış görüntüler üzerinden modelin daha iyi eğitildiği anlamına gelmektedir. Bir ağ yapısında veri artırma işlemi uygulanmamış görüntülerden elde edilen yanlışlar ile veri artırma işlemi uygulanmış görüntülerden edilen yanlışların bazıları aşağıda Çizelge 4.3'te gösterilmiştir.

Çizelge 4.3. CNN ağ yapısında, ikinci model kullanılarak tork–hız grafiklerinin girdi olarak alındığı 5 fold çapraz doğrulama sonucunda elde edilen yanlış tahminlerin dağılımı.

Fold Numarası	**Veri artırma işlemi uygulanmamış görüntülerden yapılan yanlış tahmin sayısı**	**Veri artırma işlemi ugyulanmış görüntülerden yapılan yanlış tahmin sayısı**
1. Fold	0	5
2. Fold	8	3
3. Fold	4	1
4. Fold	8	2
5. Fold	2	5



Şekil 4.1. CNN ağ yapısında tork sinyali başarılı iken başarılı olarak etiketlenen görüntü (doğru sınıflandırma)



Şekil 4.2. CNN ağ yapısında tork sinyali başarılı iken başarısız olarak etiketlenen görüntü (yanlış sınıflandırma)

Ancak bu oran GoogLeNet ağ yapısı ile %97'ye yükselmiştir. GoogLeNet ağ yapısı ile elde edilmiş en düşük başarı oranı ise %90'dır. Bu ağ oranının daha başarılı olmasında etkili en önemli faktör GoogLeNet ağ yapısının ön eğitimli bir ağ modeli kullanıyor olmasıdır. Bu ağ modeli daha önce milyonlarca veri ile eğitilmiştir ve verdiğiniz veri setindeki farklılıkları kolayca tanımlayabilir. Çünkü zaten kenar, şekil veya doku gibi birçok parametre hafızasındadır. Hazır mimari kullanılan bu yapıda eğitim süreci sıfırdan başlamaz ve önceden eğitilmiş ağırlıklarla birlikte gelir. Veri setimiz görece çok büyük olmadığı için, evrişimli sinir ağı modelinden alınan verimden daha fazlası GoogLeNet ağ yapısından alınabilmiştir. Böylelikle görece devasa boyutlarda olmayan veri setlerinin de önceden eğitilmiş ağ yapıları kullanılarak başarı oranının artırılabileceği de görülmüştür. İstenirse bu mimarinin son katmanları yeniden eğitilebilir ya da ağırlıklarına müdahale edilebilir.

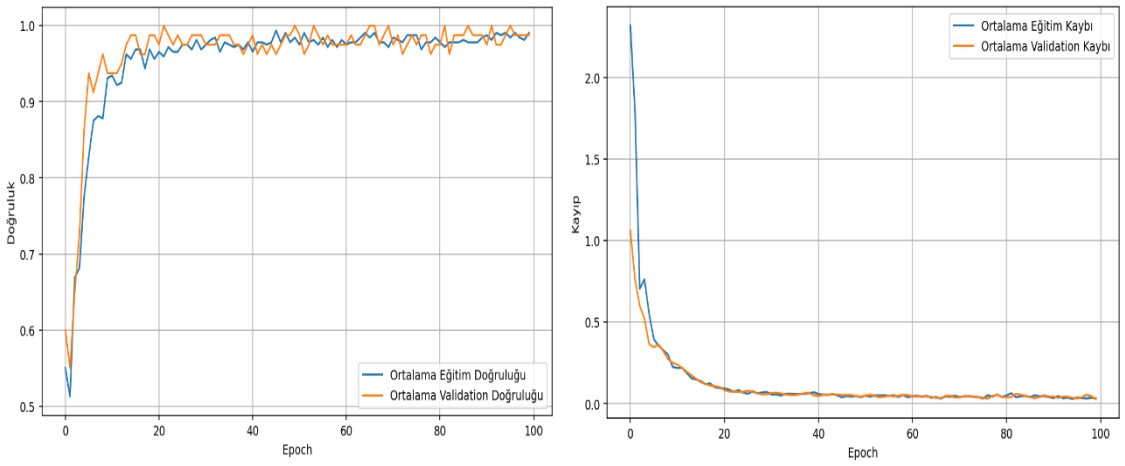
Ancak GoogLeNet ağ yapısı çok büyük bir ağ yapısı olduğu için, ön eğitim ve hali hazırda kullandığı katsayı değerleri kaldırıldığında, devasa boyutta olmayan veri setlerine karşı normal bir evrişimli sinir ağından daha başarısız sonuçlar verebilmektedir. Çünkü kullanılan veri seti, büyük boyutlu ağ yapısının eğitilmesi için gereken koşulları sağlayamayabilir. Aşağıda ön eğitim süreci ve önceden hesaplanmış ağırlıkları kaldırılmış bir GoogLeNet ağının ikinci modelimizdeki veriler kullanılarak eğitildiği durum için doğrulama başarı oranları aşağıda Çizelge 4.4'te verilmiştir.

Çizelge 4.4. Ön eğitim süreci kaldırılmış GoogLeNet ağ yapısı için başarı oranları

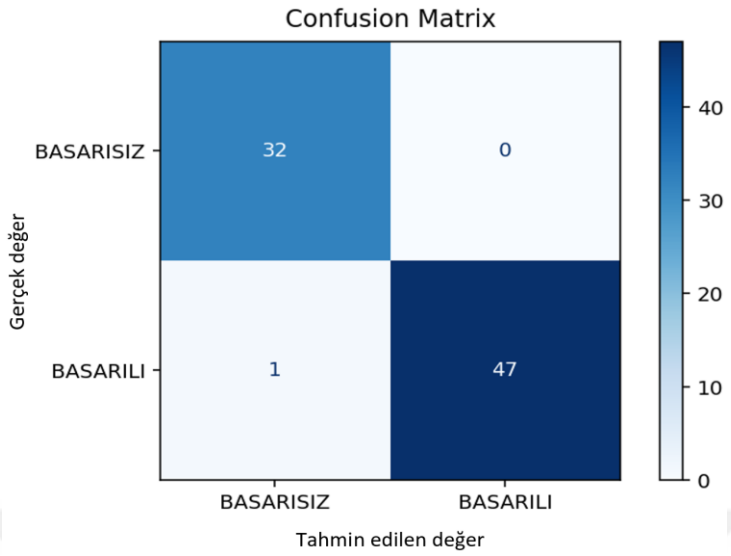
Kullanılan Metot	Fold Sayısı	Veri Seti	Ön Eğitim Uygulanmış Başarı Oranı	Ön Eğitim Uygulanmamış Başarı Oranı
GoogLeNet	5	Tork	%91	%60
GoogLeNet	10	Tork	%92	%60
GoogLeNet	5	Tork-Hız	%95	%45
GoogLeNet	10	Tork-Hız	%96	%50

En yüksek başarı oranımız ise %99 ile 1DCNN ağ yapısı için elde edilmiştir. 1DCNN ağ yapısında evrişim tek eksen boyunca yapılır. Tek eksene bağlı olarak alınan örnekler için ağ yapısı tekrarlamaları ve paternleri daha çabuk ve doğru şekilde yakalayabilmektedir. Ağ gerçek örüntüleri öğrenir. İşlem yükü diğer ağ yapılarına göre daha az olduğu için daha kararlı bir eğitim süreci yürütülebilir. Direkt olarak ham veri kullanıldığı için 2 boyutlu evrişimsel sinir ağında olabileceği gibi gereksiz verilerle ağ boşuna meşgul edilmemiş olur. Bu nedenle işlem hızı da diğer parametrelerin aynı olduğu durumlarda, 2 boyutlu evrişimsel sinir ağlarına göre daha yüksektir.

Aşağıda Şekil 4.1 ve Şekil 4.2'de en iyi başarı oranına sahip olan 5 fold ve 9 katmanlı ağ yapısının kullanıldığı ve tork-hız grafiklerinin girdi olarak verildiği, yaklaşık olarak %99 başarı oranı ile en başarılı ağ yapısı olan 1DCNN için confusion matrix (karışıklık matrisi), eğitim ve kayıp grafikleri verilmiştir.



Şekil 4.3. En başarılı ağ yapısına ait doğruluk ve kayıp grafikleri



Şekil 4.4. En başarılı ağ yapısına ait karışıklık matrisi

Matris değerlerine baktığımızda model gerçekten başarılı olan 48 görüntünün 47'sinde başarılı sınıflandırma yapmış yalnızca 1 görüntüyü yanlış etiketlendirmiştir. 32 Başarısız görüntünün tamamını ise doğru sınılandırmıştır. Bu da modelin sınıflandırmadaki başarısını göstermektedir.

Veri Setlerine baktığımız zaman, başarı oranlarının birbirlerinden farklı olduğunu gözlemleyebiliriz. Tork-hız veri setindeki başarının, tork veri setine göre daha yüksek olduğundan bahsedilebilir. Özellikle evrişimli sinir ağı yönünden analiz edilecek sonuçlarda bu fark daha belirgin olarak görülebilir. Bunun nedeni tork-hız veri setinin gerek veri gerekse grafik olarak daha karakteristik bir özelliğe sahip olması olarak gösterilebilir. Daha karakteristik grafiklere sahip görüntü örnekleri, aynı zamanda ağ yapısı için fark edilmesi daha kolay örnekleri ifade eder. Bu nedenle başarılı ve başarısız durumlar arasındaki fark daha belirgin olacak ve ağ yapısı diğer veri setlerine oranla daha başarılı bir sınıflandırma yapabilecektir.

Fold sayılarına bakıldığında veri seti kadar başarı farkı yaratmamakla birlikte, 5 fold çapraz doğrulama kullanılan ağ yapılarında başarının daha yüksek olduğunu söylemek yanlış olmaz. Ortalamaları alındığı zaman da 5 fold çapraz doğrulamanın, 10 fold çapraz doğrulamadan biraz daha yüksek bir başarı oranı elde ettiği görülmüştür. Özellikle bazı durumlarda 10 fold çapraz doğrulamanın başarı oranı, 5 fold çapraz doğrulamanın başarı oranından yüksek olsa da 5 fold çapraz doğrulama ortalama olarak bakıldığında, 10 fold çapraz doğrulamadan çok daha yüksek bir başarı oranı yakalamıştır. Bunun nedeni fold sayısı arttıkça fold başına düşen eğitim veri setinin daha küçük olması ve modelin eğitim aşaması sırasında daha az veri kullanabilmesidir.

Katman sayılarına bakıldığında ve ortalamaları alındığında yine çok büyük farklar olmasa da 14 katmanlı ağ yapısının başarısının, 9 katmanlı ağ yapısının başarısına oranla daha fazla olduğu söylenebilir. Bunun nedeni farklı ağ yapılarının ve katmanlarının, modelin başarı oranında direkt olarak etkili olmasından kaynaklanır. Yüksek katman

sayısının her zaman yüksek başarı anlamına gelmediğinin de unutulmaması gerektiğini hatırlatarak, tezde kullanılan ağ yapıları içerisinde 14 katmanlı ağ yapısının model öğrenmesinde daha iyi sonuçlar verdiği söylenebilir. Bunun nedeni katman sayısı arttıkça tezde kullanılan veri setleri için modelin yapıyı daha iyi anlayabilmesi ve daha anlamlı çıkarımlar yapabilme kapasitesini artırabilmesidir. Katman sayısı düşük yani görece daha basit modellere sahip evrişimli sinir ağları karmaşık çıkarımlardan ziyade daha çok kenar veya doku gibi modellemeleri öğrenebilirken, katman sayısı artırıldıkça evrişimli sinir ağları çıkarım yapabilme kapasitelerini artırarak şekiller ve desenler gibi yapıları da öğrenebilecek seviyeye gelebilir. Ayrıca katman sayısının artırılması model ağırlıklar da artacak ve bu artış da yine modelin öğrenme kapasitesini artıracaktır.

Sonuçlara bakıldığında ön eğitim sürecine dahil olmayan evrişimli sinir ağlarında başarı diğer ağ yapılarına göre düşük gibi görünse de bu durumuyla bile başarılı sayılabilir. Çünkü en yüksek tahmin başarı oranı olan %86, ön eğitim yapmayan bir ağ yapısı için gayet yeterli bir başarı oranıdır. Ön eğitim sürecine girmiş GoogLeNet ise doğal olarak sıfırdan kurulan bir evrişimli sinir ağı modeline göre daha başarılı konumdadır. Bunu da en yüksek başarı oranı olan %97 ile göstermiştir. Ancak ön eğitim süreci kaldırılmış bir GoogLeNet ağ yapısı yüksek boyutu nedeniyle tezde kullanılan veri setleri tarafından yeterli düzeyde eğitlememiştir ve ön eğtimi kaldırılmış bir GoogLeNet ağ yapısında başarı oranı %45'lere kadar düşmüştür. Ancak En yüksek başarı 1DCNN ağ yapısında aittir. Gerektirdiği düşük işlem gücü sayesinde ağ daha kararlı bir eğitim süreci geçirebilir ve verilere tek boyut üzerinden evrişim uyguladığı için daha iyi öğrenebilir.

5. SONUÇLAR

Küresel ısınma ve petrol kaynaklı üretimin artmasından dolayı günümüzde çevre kirliliği ciddi boyutlara ulaşmıştır. Özellikle içten yanmalı motorların kullanımından kaynaklanan sera gazının yarattığı olumsuz etkiler ve insanlar tarafından bu olumsuz etkilere olan farkındalığın artması ile birlikte elektrikli araçlara verilen önem her geçen gün artmaktadır. Bu ilginin artması ile birlikte yatırımcılar ve araba üreticileri bu sektöre doğru yönelmektedirler. Elektrikli araçlara duyulan ilgi hem bireysel hem de sektörel anlamda her geçen gün artmaktadır. Elektrikli araçların tercih edilmesindeki en büyük etkenlerden birisi çevre dostu olması olsa da tercih edilmesine sebep olan birçok etken vardır. Bunlardan en önemlileri konforlu, sessiz yapılarının yanı sıra aynı zamanda ekonomik olmalarıdır. Elektrikli araçlar geleneksel içten yanmalı motorların çalışması sırasında oluşturdukları gürültü ve sarsıntıya karşın daha sessiz bir yapıya sahiplerdir ve bu da kullanıcı için konfor düzeyini artırmaktadır. Elektrikli araçlar düşük maliyetleriyle de kullanıcı dostudur. İçten yanmalı motorlara kıyasla tüketimi minimize eden elektrikli araçlar kullanıcı ekonomisine de bu sayede katkıda bulunmaktadır. Elektrikli araçlarda kullanılan asenkron motorların ve dolayısıyla da bütün elektrikli araç sisteminin verimli çalışabilmesi için ise bazı teknik parametrelerin hatasız olarak çalışabilmesi gerekmektedir. Çevre koşulları gereği elektrikli araçlar her zaman düz ve pürüzsüz yollardan gitmeyecek, zaman zaman belirli bir eğime sahip ve aracı zorlayabilecek yollardan da geçecektir. İşte böyle durumlarda elektrikli araç içinde bulunan asenkron motorun anahtarlama sürelerinde kararsızlıklar oluşabilmektedir. Bu kararsızlıklar da motorun performansını ve dolayısıyla sistemin verimini etkileyebilmektedir. Kararsızlıklardan olumsuz etkilenen araç değişken yol koşullarında zorlanabilmekte ve buna bağlı olarak kullanıcı konforunu da olumsuz etkileyebilmektedir.

Yapılan bu tez çalışmasında, elektrikli araçlarda kullanılan asenkron motorlar ve asenkron motorların termal devresi simüle edilmiş, buradan elde edilen veri setleri evrişimli sinir ağı yapılarında kullanılmıştır. Elde edilen veri setleri kullanılarak evrişimli sinir ağları aracılığıyla elektrikli araçların farklı yol koşullarında meydana gelen verim düşüşlerini ve elektrikli araçlarda kullanılan asenkron motorlarda meydana gelecek motor kararsızlıklarını tespit etmek amaçlanmıştır. Bu kararsızlıkların tespit edilmesi ve önüne geçilmesi durumunda ileride sürücülerin değişken yol koşullarında daha kararlı bir sürüş deneyimi yaşaması mümkün kılınabilecektir. Bu da ekonomik olarak daha olumlu sonuçlar doğuracaktır. Çünkü araç her zorlandığında veya motorda kararsızlık yaşandığında, sistemin verimi düşmekte ve bu olay sırasında motor normalde harcadığı enerjiden daha fazla enerji harcamak zorunda kalmaktadır. Aynı zamanda anahtarlama sürelerindeki kararsızlıklar ortadan kalkacağı için kullanıcı daha konforlu bir sürüş deneyimi yaşayacaktır. Sıcaklık ve verim hatalarının tespiti ve bu hataların giderilmesi ile birlikte asenkron motorların anahtarlama sürelerindeki düzensizlikler giderilecek ve sürücü tarafından hissedilen zorlanma ortadan kalkacaktır.

Tez çalışmasından çıkarılan sonuçlar, elektrikli araçlarla evrişimli sinir ağlarının birleştirilmesinin ileride çok büyük ve yararlı katkıları olabileceğini göstermektedir. Evrişimli sinir ağlarının yapılan tez çalışmasına benzer şekilde asenkron motorlara, dolayısıyla elektrikli araçlara entegre edilebilmesi durumunda yol tutuşundan motor verimliliğine kadar birçok alanda çevresel ve ekonomik gelişmeler yaşanacaktır. Kayıpların azalması boşa harcanan enerjiyi azaltacak, buna bağlı olarak araç verimi ve

ömrü artacaktır. Elektrikli araçlar şimdikinden daha ekonomik, konforlu ve çevre dostu konuma gelecektir.

Yapılan tez çalışmasında kullanılan evrişimli sinir ağlarınında bazı değişkenler sabit tutulurken bazı değişkenlerinin de farklı sayıda ve şekilde kullanılmıştır. Çalışmada epoch sayısı, batch sayısı, öğrenme oranı, aktivasyon fonksiyonu gibi parametreler sabit tutulmuştur. Bunun nedeni incelenmek istenen farklı evrişimli sinir ağı yapılarının daha net ve değişkenlerden bağımsız olarak gözlemlenmek istenmesidir. Geliştirilme amacıyla değişiklik yapılabilecek alanlardan biri, yapılan tezde sinir ağı yapıları arasındaki farkların daha rahat görülebilmesi için sabit bırakılan bazı parametrelerin farklı değerlerde alınmasıdır. Örneğin öğrenme oranının kullanılacak ağ yapısına bağlı olarak değiştirilmesi başarı oranını artırabilir. Aynı şekilde epoch sayısının değiştirilmesi de önemli bir etki yaratacaktır, tez çalışmasında da bu değişimin yaratacağı farkı gösterebilmek adına epoch sayısının artırılmasının etkisi de incelenmiştir. Farklı aktivasyon fonksiyonlarının denenmesi ise yine başarı oranında önemli bir faktördür. Bu değerlerin artması her zaman daha yüksek bir başarı oranı alınacağı anlamına gelmez. Yüksek ama ağ yapısına uymayan değerlerin verilmesi, ağ başarısını artırmayacağı gibi olumsuz etki yaratarak başarı oranını daha da düşürebilir. Daha önce bahsedildiği gibi nasıl çok sayıda katman her zaman daha iyi başarı oranı anlamına gelmiyorsa, aynı şekilde epoch sayısının, öğrenme oranının ya da ağ mimarisine bağlı herhangi bir değerin artırılması da her zaman daha iyi bir başarı oranı alınacağı anlamına gelmez. Önemli olan, bu değerleri belirlerken ağ mimarisini, veri sayısını ve ağ yapısına bağlı değişkenleri göz önüne alarak bu değerleri verebilmektir.

Geliştirilmesi gereken ve eğer geliştirilirse daha olumlu sonuçlar alınabilecek etkenlerden biri de veri sayısının artırılmasıdır. Çünkü ağ yapıları büyük, küçük veya farklı parametreli olsa bile öğrenmek için veriye ihtiyaç duyar ve bu da öğrenmesini direkt olarak etkiler. 100 görüntü ile öğrenebilen bir ağ yapısına 1000 görüntü verildiği taktirde, istenilen paterni veya desenleri çok da yüksek oranda öğrenebilecektir. İleride yapılacak çalışmalarda veri setlerindeki veri sayıları daha da artırılırsa başarı oranı da artırılabilir. Çalışmanın farklı motor tipleri ve farklı ağ mimarileri için denenmesi de çalışmanın geliştirilebilirliği açısından önemlidir. Çalışmanın farklı yapılara entegre edilmesi, daha kapsamlı ve yaygın bir model oluşturulmasına yardımcı olacaktır. Yapılan çalışmanın kapsamının artırılması, örneğin yol boyunca karşılaşılacak spontane olayların simülasyona eklenmesi ile daha gerçekçi bir sonuç elde edilecektir.

Özellikle sürüş sırasında yüksek sıcaklıklara çıkılması ve buna bağlı olarak direnç değerlerinin artması sürücünün sürüş sırasında araçta zorlanma hissetmesine neden olur, bunun temel nedeni artan direnç nedeniyle motor torkunun değişmesi ve dolayısıyla aracın çekiş performansının düşmesidir. Bu tezde tespit edilen hataları kontrol edebilecek bir sistem tasarlanması durumunda, sadece stator direnci ve sıcaklık kontrolü sağlanmış olmayacak aynı zamanda dolaylı olarak tork kontrolü de yapılabilecektir. Bu kontrolün yapılması araç performansını artıracağı gibi, sürücünün de daha temiz bir sürüş gerçekleştirmesini sağlayacak böylece kullanıcı memnuniyeti de artacaktır.

Ayrıca çalışmanın MATLAB ortamında gerçekleştirilmesi de ileride yapılacak çalışmalar açısından önem arz etmektedir. Kontrol odaklı bir program olan MATLAB üzerinde PID (Oran-İntegral-Türev) kontrol, vektör kontrol ya da adaptif kontrol gibi pekçok kontrol mekanizması kullanılarak, tez çalışması geliştirilebilir, gerçek zamanlı

uygulamalara aktarılabilir. Bu uygulamalar mevcut modelle birleştirilebilir ve akıllı algoritmalarla gerçek zamanlı tork, sıcaklık, direnç kontrolü üzerine çalışmalar geliştirilebilir.

Aynı şekilde motor hatalarına yeni analizlerin eklenmesi, örneğin titreşim hataları, kısa devre hataları, ses hataları gibi hatalar eklenerek de çalışmanın kapsamı genişletilip daha gerçekçi bir simülasyon yaratılabilir. Yukarıdaki önerilerin gerçekleştirilmesi ve geliştirilmesi durumunda dünyadaki elektrikli araç piyasasında ve enerji tasarrufunda önemli adımlar atılacaktır. Özellikle bu kararsızlıkların tespiti sonrası önleme aşamasına geçilirse sürüş konforunun üst seviyeye taşınmasının yanı sıra ekonomik olarak da insanlara katkı sağlanacak, boşa harcanan enerjinin azaltılmasıyla birlikte de dolaylı olarak çevreye olan katkı artırılacaktır.

6.KAYNAKLAR

Abdullah, A. and Ali, A. 2019. Estimation of Stator Winding Temperature of a Three-Phase Induction Motor. *Iraqi Journal of Computers, Communucations, Control & System Engineering (IJCCCE),* 19 (2): 9-17.

Ahmad, S. and Qi, J. 2024. A Comprehensive Methodology for CNN Based Fault Identification in Induction Motors – A Case Study for EV's. Research Square. https://doi.org/10.21203/rs.3.rs-4523236/v1

Aljuaid, A., Almohaya, M. and Anwar, M. 2022. An Early Detection of Oral Epithelial Dysplasia Based on GoogLeNet Inception-v3, 2022 IEEE/ACM Conference on Connected Health: Applications, Systems and Engineering Technologies (CHASE), pp.172-173, 17-19 November, Arlington, VA, USA.

Asgari, A., Hanisch, L.V., Anspach, J., Franzki, J., Kahn, M., Kurrat, M. and Henke, M. 2024. Reliability of Insulation Systems and Its Impact on Electric Machine Design for Automotive and Aviation Applications. *Energies 2025*, 18(1), 92.

Badran, O., Sarhan, H. and Alomour, B. 2012. Thermal Performance Analysis Of İnduction Motor. *International Journal of Heat and Technology,* 30(1): 75-88.

Barber, F.B.N. and Oueslati, A.E. 2024. Human exons and introns classification using pre-trained Resnet-50 and GoogleNet models and 13-layers CNN model. *Journal of Genetic Engineering and Biotechnology,* 22(1): 100359.

Basnet, M., Poudyal, S., Ali, M.H. and Dasgupta, D. 2021. Ransomware Detection Using Deep Learning in the SCADA System of Electric Vehicle Charging Station, 2021 IEEE PES Innovative Smart Grid Technologies Conference - Latin America (ISGT Latin America), pp. 1-5, 15-17 Eylül, Lima, Peru.

Chen, Y., Liang, S., Li, W., Liang, H. and Wang, C. 2019. Faults and Diagnosis Methods of Permanent Magnet Synchronous Motors: A Review. *Applied Sciences*, 9(10): 2116.

Cheng, W.K. et al. 2023. Spectrogram-based classification on vehicles with modified loud exhausts via convolutional neural networks. *Applied Acoustics,* Volume 205, 109254.

Choudhary, A., Mian, T. Fatima, S. and Panigrahi. B.K. 2023 Fault Diagnosis of Electric Two-Wheeler Under Pragmatic Operating Conditions Using Wavelet Synchrosqueezing Transform and CNN. *IEEE Sensors Journal*, 23(6): 6254-6263.

Chow, M., Sharpe, R.N. and Hung, J.C. 1993. On The Application And Design Of Artificial Neural Networks For Motor Fault Detection - Part 1. *IEEE Transactions on Industrial Electronics*, 40(2): 189-196.

Du, C., Zhong, R., Zhuo, Y., Zhang, X., Yu, F., Li, F., Rong, Y. and Gong Y. 2022. Research on fault diagnosis of automobile engines based on the deep learning 1D-CNN method. *Engineering Research Express*, 4(1).

Gnanaraj, S.D., Gundabattini, E. and Singh, R.R. 2020. Materials for lightweight electric motors – a review. *IOP Conference Series: Materials Science and Engineering*, 906: 012020.

Gouda, O.E., Amer, G.M. and Salem.W.A.A. 2012. Predicting Transformer Temperature Rise and Loss of Life in The Presence Of Harmonic Load Currents. *Ain Shams Engineering Journal*, 3(2): 113-121.

Gökdere, L.U., Bogdanov, A., Chiu, S., Keller, K. and Via, J. 2006. Adaptive Control of Actuator Lifetime, IEEE Aerospace Conference, pp. 11, 4-11 March. Big Sky, Montana, USA.

Ince, T., Kiranyaz, S., Eren, L., Askar, M. and Gabbouj, M. 2016. Real-Time Motor Fault Detection by 1-D Convolutional Neural Networks. *IEEE Transactions On Industrial Electronics*, 63(11): 7067-7075.

Jiang, Y., Ji, B., Zhang, J., Yan, J. and Li, W. 2024. An Overview of Diagnosis Methods of StatorWinding Inter-Turn Short Faults in Permanent-Magnet Synchronous Motors for Electric Vehicles. *World Electr. Veh. J*. 15(4), 165.

Jung, H., Choi, S. and Lee, B. 2023. Rotor Fault Diagnosis Method Using CNN- Based Transfer Learning with 2D Sound Spectrogram Analysis. *Electronics 2023*, 12(3), 480.

Khaneghah, M.Z., Alzayed, M. and Chaoui, H. 2023. Fault Detection and Diagnosis of the Electric Motor Drive and Battery System of Electric Vehicles. *Machines 2023*, 11(7), 713.

Kitis, U. and Polat, Ö. 2025. Estimation of the effect of changing resistance parameters on engine efficiency in electrical vehicles with convolutional neural network. *Engineering Computations 2025,* 1-17.

Kunt, M.A. 2020. Advisor Based Modelling of Regenerative Braking Performance of Electric Vehicles at Different Road Slopes. *Internatıonal Journal Of Automotıve Scıence And Technology,* 4(2): 98-104.

Li, D., Liu, P., Zhang, Z., Zhang, L., Deng, J. Wang, Z., Dorrell, D.G., Li, W. and Sauer, D. U. 2022. Battery Thermal Runaway Fault Prognosis in Electric Vehicles Based on Abnormal Heat Generation and Deep Learning Algorithms. *IEEE Transactıons On Power Electronics*, 37(7): 8513-8525.

Lin, F., Chau, K.T., Chan, C.C. and Chunhua, L. 2013. Fault Diagnosis of Power Components in Electric Vehicles. *Journal of Asian Electric Vehicles,* 11(2):1659-1666.

Luo, H. 2020. Study on Fault Diagnosis Model of Electric Vehicle based on Learning Algorithm. IOP Conference Series: Materials Science and Engineering, 750(1): 012184, 27-29 December, Shenyang, China.

Markovic, M. and Perriard, Y. 2009. Optimization Design of a Segmented Halbach Permanent-Magnet Motor Using an Analytical Model. *IEEE Transactions On Magnetics*, 45(7): 2955-2960.

Meng, Z., Guo, X., Pan, Z., Sun, D. and Liu, S. 2019. Data Segmentation and Augmentation Methods Based on Raw Data Using Deep Neural Networks Approach for Rotating Machinery Fault Diagnosis. *IEEE Access*, 7: 79510 - 79522.

Metwally H.M.B. 2001. Loadless Full Load Temperature Rise Test For Three Phase Induction Motors. *Energy Conversion and Management,* 42(5): 519-528.

Misak, H.E., Asmatulu, R., O'Malley, M., Jurak, E. and Mall, S. 2014. Functionalization of carbon nanotube yarn by acid treatment. *International Journal of Smart and Nano Materials,* 5(1): 34-43.

Nasir, B.A. 2022. Sensor-less Monitoring of Induction Motor Temperature with an Online Estimation of Stator and Rotor Resistances Taking the Effect of Machine Parameters Variation into account. *International Journal of Engineering Trends and Technology,* 70(6): 54-62.

Park, J. And Kim, Y. 2019. Supervised-Learning-Based Optimal Thermal Management in an Electric Vehicle. *IEEE Access*, 8: 1290- 1302.

Pasqualotto, D. and Zigliotto, M. 2021. A Comprehensive Approach To Convolutional Neural Networks-Based Condition Monitoring Of Permanent Magnet Synchronous Motor Drives. *IET Electric Power Applications,*15(7): 947-962.

Sai S., A, Sridharan, N.V., Chakrapani, G., and Sugumaran, V. 2024. Deep learning based fault detection of automobile dry clutch system using spectrogram plots. *Engineering Research Express*, 6(2), id.025221.

Sarapulov, F.N., Goman, V. and Trekin, G.E. 2020. Temperature Calculation For Linear Induction Motor in Transport Application With Multiphysics Approach, IOP Conference Series Materials Science and Engineering, 966(1), 18-19 June, Nizhny Tagil, Russia.

Savran, E. 2025. Yeni Nesil Elektrikli Taşıtlarda Enerji Verimli Sürüş Analizleri. Phd Thesis, Bursa Uludağ Üniversitesi, Bursa, 99 p.

Saxena, A., Kumar, R., Rawat, A.K., Majid, M., Singh, J., Devakirubakaran, S. and Singh, G.K. 2023. Abnormal Health Monitoring and Assessment of a Three-Phase Induction Motor Using a Supervised CNN-RNN-Based Machine Learning Algorithm. *Mathematical Problems in Engineering,* 2023: 1-8.

Shiferaw, S. 2018. Impact Of Road Geometry and Road Surface Types on Fuel Consumption and Greenhouse Gas Emissions: A Case Study on Two Gravel Roads and Three Asphalt Roads in Dıfferent Areas of Ethiopia. Msc Thesis, Addis Ababa University, Addis Ababa, 112 p.

Soundarya Lahari, P., Shriam, S. and Mohanrajan, S. R. 2022. Thermal Modelling of Power Components using Load Current for a Medium Voltage Drive in Simulink Platform. 2nd International Conference on Intelligent Technologies (CONIT), pp. 1-6, 24-26 June, Hubli, India.

Specht, A. and Böcker, J. 2010. Observer for the Rotor Temperature of IPMSM, Proceedings of 14th International Power Electronics and Motion Control Conference EPE-PEMC 2010, pp. T4-12-T4-15, 06-08 September, Ohrid, Macedonia.

Şimşek, F. and Mergen, F. 2009. 3 Fazlı Asenkron Motorda Sıcaklık Artışı ve Dağılımının Elektriksel Benzeşim ve Sonlu Elemanlar Yöntemi ile Hesaplanması, Elektrik-Elektronik-Bilgisayar ve Biyomedikal Mühendisliği 13. Ulusal Kongresi ve Fuarı, 23-26 Aralık, Ankara, Türkiye.

Tan, D., Xue, H., Yang, K., Li, A. and Wang, H. 2018. Study on the Thermal Characteristics of In-Wheel Motor Drive System Based on Driving Cycles. *IEEE Access,* 7: 14463 – 14471.

Trejo-Chavez, O., Cruz-Albarran, I.A., Resendiz-Ochoa, E., Salinas-Aguilar, A., Morales-Hernandez, L.A., Basurto- Hurtado, J.A. and Perez-Ramirez, C.A. 2023. A CNN-Based Methodology for Identifying Mechanical Faults in Induction Motors Using Thermography. *Machines 2023*, 11(7), 752.

Trivedi, M., Kakkar, R., Gupta, R., Agrawal, S., Tanwar, S., Niculescu, V.-C., Rabocca, M.S., Alqahtani, F., Saad, A. and Tolba, A. 2022. Blockchain and Deep Learning-Based Fault Detection Framework for Electric Vehicles. *Mathematics 2022*, 10(19), 3626.

Ucar, K. 2025. "Improving electric vehicle state of charge estimation with wavelet transform-integrated 1D-CNN pooling layers", *Journal of Energy Storage,* 117: id.116202

Ulu, C., Korman, O. and Kömürgöz, G. 2017. Electromagnetic and thermal analysis/design of an induction motor for electric vehicles, 8th International Conference on Mechanical and Aerospace Engineering (ICMAE), pp. 6-10, 22-25 July, Prague, Czech Republic.

Vavilov, V., Nurieva, A., Zhuravlev, D., Zherebtsov, A., Bakirov, A., Gulin, A., Yushkova, O. and Garipov, I. 2021. Verification of the Thermal Model of an Asynchronous Traction Motor, 2021 International Conference on Electrotechnical Complexes and Systems (ICOECS), pp. 145-149, 16-18 November, Ufa, Russian Federation.

Wang, J., Zhang, S. and Hu, X. 2021. A Fault Diagnosis Method for Lithium-Ion Battery Packs Using Improved RBF Neural Network. *Frontiers in Energy Research*, 9:702139.

Wen, L., Li, X., Gao, L. and Zhang, Y. 2018. A New Convolutional Neural Network-Based Data-Driven Fault Diagnosis Method. *IEEE Transactions On Industrial Electronics*, 65(7): 5990 – 5998.

Wu, C., Sehab, R., Akrad, A. and Morel, C. 2022. Fault Diagnosis Methods and Fault Tolerant Control Strategies for the Electric Vehicle Powertrains. *Energies 2022,* 15(13), 4840.

Xia, Y., Xu, Y., Ai, M. and Liu, J. 2019. Temperature Calculation of an Induction Motor in the Starting Process. *IEEE Transactions On Applied Superconductivity*, 29(2): 1-4.

Xiao, S. and Griffo, A. 2020a. Online Thermal Parameter Identification For Permanent Magnet Synchronous Machines. *IET Electric Power Applications*, 14(12): 2340-2347.

Xiao, S. and Griffo, A. 2020b. PWM-Based Flux Linkage And Rotor Temperature Estimations For Permanent Magnet Synchronous Machines. *IEEE Transactions On Power Electronics*, 35(6): 6061-6069.

Yang, Y. and Zhu, W. 2023. Research Based on Improved CNN-SVM Fault Diagnosis of V2G Charging Pile. *Electronics 2023*, 12(3), 655.

Yin, J. and Cen, G. 2022. Intelligent Motor Bearing Fault Diagnosis Using Channel Attention-Based CNN. *World Electr. Veh. J. 2022*, 13(11), 208.

Yoneyama, K. and Akatsu, K. 2016. Operating Point Estimation for Permanent Magnet of Electric Motor under Load-condition, 19th International Conference on Electrical Machines and Systems (ICEMS), pp. 1-6, 13-16 November, Chiba, Japan.

Yu, F., Zhuo, Y., Xing, X., Yang, X., Chen, G.and Du, C. 2025. Vehicle Driving State Recognition and Test Analysis Using Vehicle Body Attitude Measurement and One-Dimensional Convolutional Neural Network. *International Journal of Automotive and Mechanical Engineering,* 22 (2): 12267-12280.

Zhao, J., Ling, H., Wang, J., F. Burke, A., and Lian, Y. 2022. Data-Driven Prediction Of Battery Failure For Electric Vehicles. *iScience 25*. 25(4), 104172.

Zhu, Y., Xiao, M., Lu, K., Wu, Z. and Tao, B. 2019. A Simplified Thermal Model and Online Temperature Estimation Method of Permanent Magnet Synchronous Motors. *Applied Sciences,* 9(15), 3158.

ÖZGEÇMİŞ

Umut KİTİŞ

ÖĞRENİM BİLGİLERİ

Doktora 2020-2026	Akdeniz Üniversitesi Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Antalya
Yüksek Lisans 2017-2020	Akdeniz Üniversitesi Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Antalya
Yüksek Lisans (ERASMUS+) 2019	AGH University of Science and Technology Faculty of Computer Science, Electronics and Telecommunications, Krakow
Lisans 2013-2017	Akdeniz Üniversitesi Mühendislik fakültesi, Elektrik-Elektronik Mühendisliği, Antalya

MESLEKİ VE İDARİ GÖREVLER

Müdür Yardımcısı 2024-Devam Ediyor	Akdeniz Üniversitesi Teknik Bilimler Meslek Yüksekokulu, Antalya
Öğretim Görevlisi 2023-Devam Ediyor	Akdeniz Üniversitesi Teknik Bilimler Meslek Yüksekokulu, Elektrik ve Enerji Bölümü, Elektrik Programı, Antalya

(Devamı arkada)

Araştırma Görevlisi 2021-2023	Alanya Alaaddin Keykubat Üniversitesi Rafet Kayış Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği, Antalya
Kurum Dışı Öğretim Elemanı 2020	Akdeniz Üniversitesi Mühendislik fakültesi, Elektrik-Elektronik Mühendisliği, Antalya

ESERLER

Ulusal bilimsel toplantılarda sunulan ve bildiri kitaplarında basılan bildiriler

1- Kitiş, U. ve Üser, Y. 2018. Değişken Eğimli Durumlarda Elektrikli Araçların Performans Analizi. 4. INES International Academic Research Congress, 30 Ekim - 3 Kasım, Antalya.

2- Acar, H.C., Kitiş, U., Üser, Y. ve Atak, B. 2018. PID Parametrelerinin Analitik ve Yapay Sinir Ağları Kullanarak Ayarlama Yöntemleri. IV UMTEB, 7 - 9 Aralık, Antalya.

3- Kitiş, U. ve Üser, Y. 2019. Stability of Electric Vehicles in Variable Moments By Using a Lyapunov Type Observator. IMASCON 2019, 1 - 3 Kasım, Kocaeli.

Uluslararası hakemli dergilerde yayımlanan makaleler

1- Kitiş, U ve Üser, Y. 2021. Determination and Control of the Instant Moment Need of Electric Vehicles in Variable Road Conditions With a Lyapunov-based Flux Observer. *Electrica,* 21(3): 428-443.

2- Kitiş, U ve Polat, Ö. 2025. Estimation of the effect of changing resistance parameters on engine efficiency in electrical vehicles with convolutional neural network. *Engineering Computations,* 1-17.