



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



**ASENKRON MOTOR EŞDEĞER DEVRE
PARAMETRELERİNE ETKİ EDEN
FAKTÖRLERİN MAKİNE ÖĞRENME
YÖNTEMLERİ İLE BELİRLENMESİ**

Abdullah Cem AĞAÇAYAK

DOKTORA TEZİ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Haziran-2024
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Abdullah Cem AĞAÇAYAK tarafından hazırlanan “ASENKRON MOTOR EŞDEĞER DEVRE PARAMETRELERİNE ETKİ EDEN FAKTÖRLERİN MAKİNE ÖĞRENME YÖNTEMLERİ İLE BELİRLENMESİ” adlı tez çalışması 13/06/2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Ahmet Afşin KULAKSIZ
(Konya Teknik Üniversitesi)

.....

Danışman

Dr. Öğr. Üyesi Hakan TERZİOĞLU
(Selçuk Üniversitesi)

.....

Üye

Prof. Dr. Ömer AYDOĞDU
(Konya Teknik Üniversitesi)

.....

Üye

Prof. Dr. Cemil SUNGUR
(Konya Teknik Üniversitesi)

.....

Üye

Dr. Öğr. Üyesi Fatih Alpaslan KAZAN
(Selçuk Üniversitesi)

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlüt UYAN
Enstitü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Abdullah Cem AĞAÇAYAK

Tarih:

ÖZET

DOKTORA TEZİ

ASENKRON MOTOR EŞDEĞER DEVRE PARAMETRELERİNE ETKİ EDEN FAKTÖRLERİN MAKİNE ÖĞRENME YÖNTEMLERİ İLE BELİRLENMESİ

Abdullah Cem AĞAÇAYAK

**Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı**

Danışman: Dr. Öğr. Üyesi Hakan TERZİOĞLU

2024, 240 Sayfa

Jüri

Prof. Dr. Ahmet Afşin KULAKSIZ

Prof. Dr. Ömer AYDOĞDU

Prof. Dr. Cemil SUNGUR

Dr. Öğr. Üyesi Hakan TERZİOĞLU

Dr. Öğr. Üyesi Fatih Alpaslan KAZAN

Asenkron motor (ASM) üretim alanlarında yıllardır kullanılmaktadır. Ancak günümüzün gelişen teknolojisi ve üretim alanlarının artarak devam eden talepleri bu motorlar üzerinde yapılan çalışmaların önemini her geçen gün artırmaktadır. ASM'lerin arızalarının erken tespiti ve kontrolü konusunda pek çok çalışma bulunmaktadır. Ama önemli olan maliyetleri her geçen gün artan bu motorların üretim alanlarında kesintisiz kullanımının sağlanması konusunu ön planda tutmaktır. Taleplerin karşılanabilmesi için ASM'lerin uzun süre arızalanmadan verimli kullanılması ve bunun için de matematiksel modellemesinin tam ve doğru bir şekilde yapılması gerekmektedir. Matematiksel modellemenin doğruluğu ise öncelikle ASM'lerin eşdeğer devre parametrelerinin (Equivalent Circuit Parameter, ECP) tüm değişken koşullar altında hatasız belirlenmesine bağlıdır. Literatürde yapılan çalışmalar incelendiğinde çoğunlukla tek değişkenli çalışma koşuluna veya kısıtlı sayıda motor gücüne odaklandıkları görülmektedir. Ayrıca ASM'lerin çalışma süresi parametrelerindeki değişimin tek etken üzerinden incelendiğinde yetersiz olduğu da bir gerçektir. Fakat çalışma koşullarının (motor gücü, yük, rotor hızı vb.) değişkenliği ve çeşitliliği, ASM'lerde matematiksel modellemeyi çok karmaşık bir problem haline getirir. Bu yüzden çalışma koşulları arasında etkisinin en fazla olanların tespiti gereklilik göstermektedir. Böylece modellemenin karmaşıklığından kurtularak basit ve doğruluğunu yükselttiğimiz tam bir analiz gerçekleştirilebilir.

Bu çalışmanın temel yönü, çeşitli değişken giriş parametrelerin ECP'ler üzerindeki etki oranlarını belirleyerek basit ve doğruluğu yükseltilmiş tam bir analiz gerçekleştirmektir. Böylece güç elektroniği araştırmalarının ana alanı olan model öngörülü kontrol (Model Predictive Control, MPC), arıza tespiti ve arıza sonrası onarımda verilerin doğruluğu gibi ASM ile ilgili çeşitli alanlar arasında köprü kurmaktır.

İlk olarak, çağdaş literatüre çok sayıda referansla birlikte ECP tahmini ve arıza tespiti yöntemlerinin kapsamlı bir analizi sunulmuştur. Hem teorik temelleri hem bilgisayar simülasyonlarını hem de deneysel uygulama yönlerini kapsayan bir ASM'nin ECP yöntemi tüm ayrıntılarıyla açıklanmaktadır. Farklı güçleri, farklı rotor hızları ve farklı yük oranlarını içeren etkili bir motor veri yığını elde edilen sistem oluşturularak zorlu ve zaman alan deneyler yapılmış ve Bölüm 3'te ayrıntılı olarak belgelenmiştir.

Ayrıntılı parametre grafikleri ve deneylerdeki değişim oranlarının sunulmasından sonra, bir sonraki odak noktası, bu çalışmanın ikinci ana yönü olarak giriş değişken parametrelerinin, çıkış parametreleri üzerindeki etkinlikleri üzerinde durulmuştur. Burada gerçekleştirilen zorlu ve zaman alan deneylerin tüm verilerine ihtiyaç duymadan Taguchi analiz yönteminde kodlama ile deney kısıtlamasına gidilmiştir. Böylece maliyet, zaman ve laboratuvar ortamı gibi zorluklardan kurtularak daha az deneyle tüm

deneylerde elde edilen sonuçlara yaklaşık sonuçlar elde edildiği gösterilmiştir. Daha sonra odak noktası, bir ASM'nin değişken giriş parametrelerinin tespiti ve çıkış parametreleri üzerindeki etkinliği üzerinde durularak çeşitlilik daraltılmış ve matematiksel modellemenin karmaşıklığı azaltılmıştır. Güç, devir ve yükün her motor parametreleri üzerinde farklı oranlarda etkinlikleri olduğu tespit edilmiştir. Regresyon Analiz yöntemiyle matematiksel bir modelleme ortaya konulmuştur. Giriş parametrelerine sargı sıcaklık ve kaymayı da dahil ederek oluşturulan matematiksel denklemlerin doğruluk oranı (R^2) artırılarak matematiksel modelleme sunulmuştur. Böylece literatürde de değinilen giriş parametrelerindeki çeşitliliğin matematiksel modelleme de zorluk, doğruluktan uzaklaşma ve karmaşıklık oluşturma probleminin üstesinden gelinmiştir.

Son odak noktası, deney düzeneği ile elde edilen parametre veri yığınlarının çokluğu tam analiz için çalışmayı üçüncü ana yönü olarak Yapay Sinir Ağı (Artificial Neural Network, ANN)'ye yönlendirmiştir. Veri analizlerinin tahmin modellemesi için algoritma seçim sürecinde kapsamlı bir değerlendirme gerçekleştirilmiştir. Bu bağlamda, çeşitli yapay öğrenme algoritmaları arasından, ağaç tabanlı modellerin tahmin başarısındaki potansiyelini test etmeye karar verilmiştir. Araştırma ve literatür incelemesinde, özellikle tahmin uygulamalarında ağaç modellerinin tutarlı ve güvenilir sonuçlar verdiği sonucuna ulaşılmıştır. K-en yakın komşu ve Random Forest algoritmaları gibi yapay sinir ağları uygulamalarında, veri setimizde öğrenme sürecindeki zorluklar ve modelin genelleme yeteneğindeki eksiklikler ön plana çıkmıştır. Ağaç tabanlı modellerin uygulaması, bu sorunları büyük ölçüde hafifletirken, özellikle veri seti büyüklüğü arttıkça hesaplama maliyeti ve zamanı konusunda yeni zorluklar ortaya koymuştur. Her ne kadar bu zorluklar mevcut olsa da elde edilen doğruluk oranlarındaki iyileşme, bu maliyet artışını meşru kılacak nitelikteydi. Veri setimizin çeşitliliği ve hacmi arttıkça, modelin doğruluk oranı da istikrarlı bir şekilde yükselmiştir. Uygulanan düzenlemeler ve iyileştirmelerle, modelin verimliliği anlamlı bir biçimde artmıştır. Eşit oranlarda veri dağılımı sağlanması, modelin tahmin doğruluğunda belirgin bir artışa yol açmış, aynı zamanda veri temsiliyetindeki dengesizlikleri minimize etmiştir. Ağaç tabanlı modeller içerisinde Geri Yayılımlı Sinir Ağı (Backpropagation Neural Network, BPNN) algoritması tüm veri setinde yüksek eğitim başarı yüzdesi gösterdiği görülmüştür. Diğer algoritmaların oranları ise gene yüksek ve birbirine yakın gerçekleşmiştir. Bu durum motor parametre analizinde BPNN algoritmasının en uygun algoritma olduğunu göstermiştir. Bu sonuçlar değerlendirildiğinde ASMECP'lerin tahmini için oluşturulacak matematiksel denklemin, etkinliği analizler sonucu belirlenen girişler üzerine kurgulanması gerektiği görülmüştür.

Anahtar Kelimeler: Asenkron Motor, Eşdeğer Devre Parametreleri, Makine Öğrenmesi, Matematiksel Modelleme, Taguchi Analizi.

ABSTRACT

PhD THESIS

DETERMINATION OF FACTORS AFFECTING INDUCTION MOTOR EQUIVALENT CIRCUIT PARAMETERS BY MACHINE LEARNING METHODS

Abdullah Cem AĞAÇAYAK

**Konya Technical University
Institute of Graduate Studies
Department of Electrical and Electronics Engineering**

Advisor: Asst. Prof. Dr. Hakan TERZİOĞLU

2024, 240 Pages

Jury

Prof. Dr. Ahmet Afşin KULAKSIZ

Prof. Dr. Ömer AYDOĞDU

Prof. Dr. Cemil SUNGUR

Asst. Prof. Dr. Hakan TERZİOĞLU

Asst. Prof. Dr. Fatih Alpaslan KAZAN

Induction motor (IM) has been used in production areas for years. However, today's developing technology and the increasing demands of production areas increase the importance of studies on these motors day by day. There are many studies on early detection and control of faults of IMs. However, the important thing is to prioritize the uninterrupted use of these motors, whose costs are increasing day by day, in production areas. In order to meet the demands, IMs must be used efficiently for a long time without malfunctioning, and for this, mathematical modeling must be done precisely and accurately. The accuracy of the mathematical modeling depends primarily on the accurate determination of the Equivalent Circuit Parameter (ECP) of the IMs under all variable conditions. When the studies in the literature are examined, it is seen that they mostly focus on a single variable operating condition or a limited number of motor powers. It is also a fact that the variation in the runtime parameters of IMs is inadequate when analyzed from a single factor. However, the variability and diversity of operating conditions (motor power, load, rotor speed, etc.) make mathematical modeling of IMs a very complex problem. Therefore, it is necessary to identify the most influential operating conditions. In this way, the complexity of modeling can be eliminated and a simple and accurate analysis can be performed.

The main direction of this work is to perform a simple and accurate full analysis by determining the influence ratios of various variable input parameters on ECPs. Thus, bridging various fields related to IM, such as model predictive control (MPC), which is the main area of power electronics research, fault diagnosis and data accuracy in post-failure repair.

First, a comprehensive analysis of ECP prediction and fault detection methods is presented, with numerous references to contemporary literature. The ECP method of an IM is described in full detail, covering both the theoretical foundations, computer simulations and experimental application aspects. Challenging and time-consuming experiments were carried out by building the system to obtain an effective motor data stack including different powers, different rotor speeds and different load ratios and are documented in detail in Chapter 3.

After the presentation of detailed parameter plots and rates of change in the experiments, the next focus is on the effectiveness of the input variable parameters on the output parameters as the second main aspect of this study. Without the need for all the data of the demanding and time-consuming experiments

performed here, the Taguchi analysis method was restricted by coding and experiment restriction. Thus, it is shown that with fewer experiments, approximations to the results obtained in all experiments are obtained by avoiding the difficulties such as cost, time and laboratory environment. The focus is then on the detection of the variable input parameters of an IM and its effectiveness on the output parameters, narrowing the range and reducing the complexity of the mathematical modeling. It was found that power, speed and load have different degrees of influence on each engine parameter. A mathematical modeling is presented by Regression Analysis method. Mathematical modeling is presented by increasing the accuracy ratio (R^2) of the mathematical equations created by including winding temperature and slippage in the input parameters. Thus, the problem of difficulty, inaccuracy and complexity in mathematical modeling due to the diversity in input parameters, which is also mentioned in the literature, has been overcome.

The last focus, the large amount of parameter data obtained with the experimental setup, led the study to Artificial Neural Network (ANN) as the third main direction for full analysis. A thorough evaluation was carried out during the algorithm selection process for the predictive modeling of the data analyses. In this context, among various machine learning algorithms, it was decided to test the potential of tree-based models in forecasting success. The research and literature review concluded that tree models provide consistent and reliable results, especially in forecasting applications. In neural network applications such as K-nearest neighbor and Random Forest algorithms, the difficulties in the learning process and the lack of generalization ability of the model have come to the forefront in our dataset. While the application of tree-based models alleviated these problems to a large extent, it presented new challenges in terms of computational cost and time, especially as the size of the dataset increased. Although these challenges existed, the improvement in accuracy rates achieved justified this cost increase. As the diversity and volume of our dataset increased, the accuracy of the model steadily improved. With the adjustments and improvements implemented, the efficiency of the model increased significantly. Ensuring an even distribution of data led to a significant increase in the prediction accuracy of the model, while at the same time minimizing imbalances in data representation. Among the tree-based models, the Backpropagation Neural Network (BPNN) algorithm showed high training success rates for the entire data set. The rates of other algorithms were also high and close to each other. This shows that the BPNN algorithm is the most suitable algorithm for engine parameter analysis. When these results are evaluated, it is seen that the mathematical equation to be created for the prediction of IMECs should be based on the inputs determined as a result of the activity analysis.

Keywords: Induction Motor, Equivalent Circuit Parameters, Machine Learning, Mathematical Modelling, Taguchi Analysis.

ÖNSÖZ

Bu tez çalışmasının her aşamasında doktora sürecinde desteğini esirgemeyen, bana hem akademik hem iş hem de sosyal hayatta tüm özverileri ve yol göstermelerinden dolayı değerli danışmanım Dr. Öğr. Üyesi Hakan TERZİOĞLU'na sonsuz teşekkür ederim.

Doktora sürecinde desteklerini esirgemeyen, yaptığımız çalışmayı sabırla dinleyip engin deneyimleriyle tavsiyede bulunan değerli Tez İzleme Komitesi hocalarım Prof. Dr. Ömer AYDOĞDU ve Prof. Dr. Cemil SUNGUR'a teşekkür ederim.

Her kararında arkamda duran ailem ve özellikle daima yanımda olan sevgili eşim Ayşin'e ve hayatımıza dahil olarak bize aile olmayı tattıran oğlum Çınar ve kızım Bilge'ye sonsuz teşekkürlerimi sunarım.

Abdullah Cem AĞAÇAYAK
KONYA-2024

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	vi
ÖNSÖZ	viii
İÇİNDEKİLER	ix
SİMGELER VE KISALTMALAR	xi
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	3
3. MATERYAL VE YÖNTEM.....	12
3.1. Asenkron Motor	13
3.1.1. Sincap kafesli rotor (Kısa devre rotor)	14
3.1.2. Sargılı rotor (Bilezikli rotor).....	15
3.1.3. İndüksiyon makine modeli.....	16
3.1.4. Üç fazlı asenkron motorların tam eşdeğer devresi.....	17
3.1.5. Asenkron motorların sadeleştirilmiş eşdeğer devresi	21
3.2. Pano Tasarımı ve Yazılım	25
3.3. Boşta Çalışma	29
3.4. Yükte Çalışma	31
3.4.1. Elektriksel yük	32
3.4.2. Mekanik Yük	34
3.5. Deney Bağlantı Şemaları	40
3.6. Deney Anatomisi	42
3.7. Laboratuvar Deney Sonuçları	45
3.7.1. Boş çalışma deney grafik sonuçları	45
3.7.2. Yüklü çalışma deney grafik sonuçları	48
3.8. Taguchi Metodu	85
3.8.1. Taguchi felsefesi	86
3.8.2. Dayanıklı tasarım	87
3.8.3. Taguchi metodolojisi	89
3.8.4. Kayıp fonksiyonları	90
3.8.5. Performans ölçütleri ve sinyal-gürültü oranları	92
3.8.6. Deneysel tasarım.....	94
3.8.7. Çoklu yanıt değişkeni problemleri için uzantılar.....	95
3.9. Yapay Zeka (Artificial Intelligence, AI)	96
3.9.1. Makine öğrenimi (Machine Learning, ML).....	97
3.9.2. Yapay sinir ağları (Artificial Neural Network, ANN) ile derin öğrenme.....	99
3.9.3. Geri yayımlı sinir ağları (Backpropagation Neural Network, BPNN) algoritması	107
3.9.4. Çok katmanlı algılayıcılar (Multi Layer Perceptron, MLP) algoritması	110
3.9.5. K-en yakın komşular (k-Nearest Neighbors, KNN) algoritması	114

3.9.6. Karar ağaçları ve rastgele karar ormanı (Random Forest, RF) algoritması	116
3.9.7. XGBoost (Extreme Gradient Boosting) gradyan arttırma algoritması	120
3.9.8. Destek vektör makinesi (SVM-SVR)	122
4. ARAŞTIRMA BULGULARI VE TARTIŞMA	128
4.1. Giriş Parametre Optimizasyonu	128
4.1.1. Taguchi analiz uygulaması	128
4.1.2. Regresyon analiz uygulaması	136
4.2. Makine Öğrenimi Uygulaması	140
4.2.1. Gerçek verilerde geri yayımlı sinir ağları (BPNN) algoritma uygulaması	141
4.2.2. Gerçek verilerde çok katmanlı algılayıcılar (MLP) algoritma uygulaması	144
4.2.3. Gerçek verilerde k-en yakın komşu (KNN, k-Nearest Neighbors)	147
4.2.4. Gerçek verilerde rastgele orman algoritması (RF)	150
4.2.5. Gerçek verilerde XGBoost (Extreme Gradient Boosting) algoritması	153
5. SONUÇLAR VE ÖNERİLER	159
5.1.1. Tezin Kısa Bir Özeti	159
5.1.2. Literatüre Yapılan Katkılar	165
KAYNAKLAR	167
EKLER	178

SİMGELER VE KISALTMALAR

Simgeler

$(I_s)_{Th}$	: Tek Fazlı Thevenin Akımı (Amper-A)
$\partial MSE/\partial_w$	: Hata Fonksiyonunun Ağırlığa Göre Kısmi Türevi
a	: Transformatördeki Dönüştürme Oranı
b	: Bias Terimi
C	: Sonlu Bir Kümedeki Ayrık Sınıfların Sayısı
D	: Veri Kümesi
E_f	: Statora Uygulanan Gerilim (Volt-V)
E_r	: Rotor Çubuklarında İndüklenen Gerilim (Volt-V)
E_r'	: Rotor Sargılarında İndüklenen Gerilimin Stator Devresine Aktarılmış Eşdeğeri (Volt-V)
E_{r0}	: Rotor Dururken Sargılarında İndüklenen Gerilim (Volt-V)
E_s	: Stator Sargılarında İndüklenen Gerilim (Volt-V)
f	: Frekans (Hertz-Hz)
f_{aktiv}	: Aktivasyon Fonksiyonunu Temsil Eder.
I	: Akım (Amper-A)
I_m	: Uyarım (Mıknatıslanma) Reaktansı Üzerinden Geçen Akım (Amper-A)
I_r	: Rotor Akımı (Amper-A)
I_r'	: Rotor Akımının Statora Etkisini İfade Eden Akım (Amper-A)
I_s	: Motorun Çektiği Stator Akımı (Amper-A)
I_u	: Uyarım Akımı (Amper-A)
I_w	: Uyarım Devresi Direnci Üzerinden Geçen Akım (Amper-A)
k	: Bir Orantı Sabiti
k_{w1}	: Stator Sargı Faktörü
k_{w2}	: Rotor Sargı Faktörü
$L_{(y)}$	: Kayıp Fonksiyonu
L_0	: Kayıp Fonksiyonunun Eski Ölçüsü
L_1	: Kayıp Fonksiyonunun Yeni Ölçüsü
n	: Devir Sayısı (Devir/Dakika- d/dk)
n_r	: Rotor Devir Sayısı (Devir/Dakika- d/dk)
n_s	: Stator Devir Sayısı (Devir/Dakika- d/dk)
N	: Gözlem Sayısı (Bir Denemede Test Sayısı)
N_1	: Stator Sarım Sayısı
N_2	: Rotor Sarım Sayısı
p	: Çift Kutup Sayısı
P	: Güç (Watt-W)
P_0	: Boştaki Güç (Watt-W)
r	: Alt Simgeleri Rotor Değişkenini Belirtir
R Kare (R^2)	: Modelin Bağımlı Değişkenin Varyansını Ne Kadar Açıkladığını Gösterir
R_2	: Rotor Devresi Direncinin Stator Devresine Aktarılmış Eşdeğeri (Ohm- Ω)
R_{2y}	: Sıcaklıkla Değişen Yeni Rotor Devresi Direncinin Stator Devresine Aktarılmış Eşdeğeri (Ohm- Ω)
R_{eg}	: Eş Değer Direnç (Ohm- Ω)
R_m	: Uyarım Devresi Direnci (Ohm- Ω)
R_r	: Rotor Devresi Direnci (Ohm- Ω)
R_s	: Stator Sargılarının İç Direnci (Ohm- Ω)

R_{sy}	: Sıcaklıkla Değişen Yeni Stator Sargılarının İç Direnci (Ohm- Ω)
R_{Th}	: Thevenin Eşdeğer Direnci (Ohm- Ω)
R_y	: Motor Milindeki Yükün Stator Terimleri Cinsinden Elektrik Direnci (Ohm- Ω)
s	: Alt Simgeleri Stator Değişkenini Belirtir
s	: Kayma
S	: Standart Sapma
S/N	: En Büyük Değer En İyi Durumu İçin Sinyal/Gürültü Oranı
S_K	: Kritik Kayma
t_1	: İlk Sıcaklık (Santigrat Derece- $^{\circ}C$)
t_2	: Son Sıcaklık (Santigrat Derece- $^{\circ}C$)
T	: Tork (Newton Metre-Nm)
T_e	: Elektromanyetik Tork (Newton Metre-Nm)
T_{load}	: Yükleme Tork (Newton Metre-Nm)
T_y	: Yükleme (Newton Metre-Nm)
V	: Gerilim (Volt-V)
$Var(y)$	: y 'nin Varyansı
V_s	: Stator Gerilimi (Volt-V)
V_{Th}	: Thevenin Gerilimi (Volt-V)
ω_e	: Rotor Açısız Frekansı
ω_i	: Ağırlıklar
ω_m	: Mekanik Hızı
ω_{new}	: Güncellenmiş Ağırlık
ω_{old}	: Güncellenmeden Önceki Ağırlık
X_i	: Giriş Değerleri
X_2	: Rotor Devresi Kaçak Reaktansının Rotor Devresine Aktarılmış Eşdeğeri (Ohm- Ω)
X_{eq}	: Eş Değer Reaktans (Ohm- Ω)
X_m	: Uyartım (Mıknatıslanma) Reaktansı (Ohm- Ω)
X_r	: Rotor Devresi Kaçak Reaktansı (Ohm- Ω)
X_{r0}	: Rotor Dururken Kaçak Reaktansı (Ohm- Ω)
X_s	: Stator Sargılarının Kaçak Reaktansı
X_{Th}	: Thevenin Eşdeğer Reaktansı (Ohm- Ω)
y	: Kalite Özelliğinin Değeri
Y	: Gözlenmiş Değer
Δ	: Yıldız Bağlantı
α	: Bakırın Sıcaklık Katsayısı
α_{oran}	: Öğrenme Oranı (Adım Büyüklüğü)
Δ	: Üçgen Bağlantı
Δt	: Sargı Isısı (Santigrat Derece- $^{\circ}C$)
μ	: y 'nin Ortalaması
τ_{ind}	: Motor Torku (Newton Metre-Nm)
τ_{max}	: Maksimum Tork (Newton Metre-Nm)
Φ	: Güç Faktörü (Power Factor, pf)
Ψ	: Akı (Weber-Wb)

Kısaltmalar

3ASM	: Üç Fazlı Asenkron Motor (3-Phase Asynchronous Motor)
3ASMPE	: Üç Fazlı Asenkron Motor Parametre Tahmini (3-Phase Asynchronous Motor Parameter Estimate)
AC	: Alternatif Akım (Alternative Current)
AdaGrad	: Uyarlanabilir Gradyan Algoritması (Adaptive Gradient)
AI	: Yapay Zeka (Artificial Intelligence)
ANN	: Yapay Sinir Ağı (Artificial Neural Network)
ANOVA	: Varyans Analizi (ANalysis Of VAriance)
ASM	: Asenkron Motor (Asynchronous Motor)
ASMECP	: Asenkron Motor Eşdeğer Devre Parametre (Asynchronous Motor Equivalent Circuit Parameter)
ASMP	: Asenkron Motorların Parametre (Asynchronous Motors Parameter)
BC	: İkili Çapraz Entropi (Binary Cross Entropy Loss)
BPNN	: Geri Yayılımlı Sinir Ağları (Backpropagation Neural Networks)
CC	: Çapraz Entropiye (Cross Entropy)
CFD	: Gelişmiş Hesaplamalı Akışkan Dinamiği (Computational Fluid Dynamics)
CLM	: Kompozit Yük Modellemesi (Composite Load Modeling)
CM	: Yeni Durum İzleme (Condition Monitoring)
CNN	: Evrimsel Sinir Ağı (Convolutional Neural Networks)
DC	: Doğru Akım (Direct Current)
DGA	: Diferansiyel Gelişim Algoritması (Differential Evolution Algorithm)
DL	: Derin Öğrenme (Deep Learning)
DLT	: Çift Yük Testi (Double Load Test)
ECP	: Eşdeğer Devre Parametreleri (Equivalent Circuit Parameter)
EKF	: Genişletilmiş Kalman Filtresi (Extended Kalman Filter)
EMDS	: Elektrik Motoru Tahrikli Sistemler (Electric Motor Driven Systems)
FD	: Arıza Tespiti (Fault Detection)
FEM	: Sonlu Elemanlar Analizi (Finite Element Analysis)
FN	: Yanlış Negatiflerin Karışık Matrisi (False Negatives)
FP	: Yanlış Pozitiflerin Karışık Matrisi (False Positives)
GA	: Genetik Algoritmalar (Genetic Algorithms)
GSA	: Global Duyarlılık Analizi (Global Sentiment Analysis)
IAE	: Uluslararası Enerji Ajansı (International Energy Agency)
IoT	: Endüstriyel Nesnelerin İnterneti (Industrial Internet of Things)
KNN	: K-En Yakın Komşu (K-Nearest Neighbors)
LSL	: Alt Teknik Şart Limiti (Lower Technical Specification Limit)
MAE	: Ortalama Mutlak Hata (Mean Absolute Error)
MCA	: Motor Devresi Analizi (Motor Circuit Analysis),
MCSA	: Motor Akım Sinyal Analizi (Motor Current Signal Analysis)
ML	: Makine Öğrenimi (Machine Learning)
MLP	: Çok Katmanlı Algılayıcılar (Multilayer Perceptrons)
M-LSTM	: Çok Modlu Model Olan Uzun Süreli Kısa Süreli Hafıza (Multi- Long Short Term Memory)
MSE	: Ortalama Karesel Hata (Mean Squared Error)
MVA	: Motor Titreşim Analizi (Motor Vibration Analysis)
PCA	: Ana Bileşen Analizi (Principal Component Analysis)
PCA	: Temel Bileşenler Analizi (Principal Component Analysis)

PLC	: Programlanabilir Mantık Denetleyici (Programmable Logic Controller)
PLS	: Kısmi En Küçük Kareler (Partial Least Squares)
PSO	: Parçacık Sürü Optimizasyonu (Particle Swarm Optimization)
ReLU	: Düzeltilmiş Lineer Ünite (REctified Linear Unit)
RF	: Karar Ağaçları/Rastgele Orman Algoritması (Random Forest)
RMSE	: Karekök Ortalama Hata (Root Mean Squared Error)
RMSProp	: Kök Ortalama Kare Yayılım Algoritması (Root Mean Square Propagation)
SCADA	: Gözetleyici Kontrol ve Veri Toplama Sistemi (Supervisory Control and Data Acquisition)
SGD	: Stokastik Gradyan İnişi (Stochastic Gradient Descent)
SVD	: Tekil Değer Ayrışımı (Singular Value Decomposition)
SVM	: Destek Vektör Makineleri (Support Vector Machine)
SVR	: Destek Vektör Regresyonu (Support Vector Regression)
TN	: Doğru Negatiflerin Karışık Matrisi (True Negatives)
TNM	: Termal Ağ Modelleri (Thermal Network Models)
TP	: Doğru Pozitiflerin Karışık Matrisi (True Positives)
TVPI	: Zamana Göre Değişen Parametre Tanımlama (Time Varying Parameter Identification)
USL	: Üst Teknik Şart Limiti (Upper Technical Specification Limit)
VSD	: Değişken Hızlı Sürücüler (Variable Speed Drives)
XGBoost	: Ekstrem Gradyan Arttırma (Extreme Gradient Boosting)

1. GİRİŞ

Uluslararası Enerji Ajansı (IAE) tarafından yapılan küresel enerji değerlendirmesine göre, elektrik motoru tahrikli sistemler (EMDS'ler) dünya çapında kullanılan elektriğin %53'ünden sorumludur (4E Annual Reports, 2017). EMDS sektöründe elektrik enerjisi tüketiminin %77'si, 375 kW'ın altındaki güç derecesine sahip orta boy motorlardan kaynaklanmaktadır (Waide, 2011). Orta büyüklükteki motorlar arasında kullanılan motorların %80'i asenkron motor (ASM)'dir. Orta ölçekli ASM'lerin ortalama verimliliği, toplam yıllık enerji tüketimi 10500 TWh ve 6800 milyon metrik ton CO₂ emisyonu ile %84'tür (Waide, 2011). Bu veriler ekonomik mobilite otomasyon uygulamalarında ve birincil beslemeli konut elektrik sarf malzemelerinde kullanılan en popüler motorların AC asenkron makineler olduğunu gösterir. ASM'lerin geniş ölçekli kullanımı, onları enerji verimliliğinde iyileştirilmeleri için ideal bir aday haline getirmektedir.

Endüstriyel uygulamalarda yaygın olarak kullanılan asenkron motorların (ASM) temel faydaları; basitlikleri ve sağlam yapıları, rekabetçi fiyatları, minimum servis hizmeti ve bir AC güç kaynağına doğrudan entegrasyonlarıdır. Üç fazlı asenkron motor (3ASM) çoğunlukla, çeşitli endüstriyel üretim alanlarda kullanılmaktadır ve küresel pazarları 2023'te yaklaşık 21,8 milyar ABD\$ tır. 2032 yılında piyasa tahmini ise 42,4 milyar Amerikan dolarıdır (Imargroup Report, 2024; Rajput, 2020). Sonuç olarak, bu kadar yaygın ve küresel piyasaya hakim bir kullanıma sahip olan motorların performansları optimize edilmelidir (Ahmed ve diğ., 2020; Iegorov, 2020).

Üretim alanında önemli bir yeri olan ve tercih edilen sincap kafesli asenkron motorlar üzerinde yıllardır araştırma ve geliştirme çalışmaları yapılmaktadır. Ancak günümüzün gelişen teknolojisi ve üretim alanlarının artarak devam eden talepleri bu motorlar üzerinde yeni yapılan çalışmaların önemini her geçen gün artırmaktadır. ASM'lerin arızalarının erken tespiti ve kontrolü konusunda pek çok çalışma bulunmaktadır (Siddique ve diğ., 2005; Mehrjou ve diğ., 2011). Ama önemli olan maliyetleri her geçen gün artan bu motorların üretim alanlarında kesintisiz kullanımının sağlanması konusunu ön planda tutmaktır. Taleplerin karşılanabilmesi için ASM'lerin uzun süre arızalanmadan verimli kullanılması ve bunun için de matematiksel modellemesinin tam ve doğru bir şekilde yapılması gerekmektedir. Matematiksel modellemenin doğruluğu ise öncelikle Asenkron motor eşdeğer devre parametrelerinin (ASMECP) tüm değişen koşullar altında hatasız belirlenmesine bağlıdır.

ASMECP'lerinin doğru ve hassas belirlenmesi, ASM'lerin hız ve konum kontrolleri gibi uygulamalarda önem arz etmektedir. Bu tür motorların son kontrolü, değişken hızlı sürücüler (VSD) aracılığıyla ya alan odaklı ya da doğrudan tork vektör kontrolüne bağlıdır. VSD ile uygun motor kontrolü ve doğru arıza teşhisi için motor parametrelerinin kesin olarak tahmin edilmesi çok önemlidir (Wang ve diğ., 2020). Asenkron motorların parametre (ASMP) tahminin en düşük hatayla belirlenmesi, doğrusal olmayan dinamik yapılarından dolayı zor bir problemdir. ECP'leri belirlemek hem laboratuvarlarda yüksek maliyetli deneylere ve online takiplere hem de fazla zamana neden olur. Ancak, endüstriyel uygulamalar açısından asenkron motor parametre değerlerinin hızlı, hatasız ve uygun maliyetli bir şekilde belirlenmesi gerekmektedir.

ASMP'leri çevresel etkilere karşı değişkenlik gösterirler. Değişken parametrelere sahip ASM'ler, motor tasarımından bağımsız olarak çalışma modunu değiştirirken rotor parametreleri de değişen motorlardır. ASMP'lerin değişmesine neden olan bir başka etken ise farklı devirlerde, farklı yük oranları altında kullanılmaları, rotor kayma oranının yüke göre değişmesi ve sargılarındaki sıcaklık değişimidir. ASM'lerde güç, yük, kayma ve ısı ile değişen elektrik eşdeğer parametrelerinin modellenmesi enerji tasarrufu ve verimliliği artıracaktır. Bu sürme ve hız kontrol tekniklerinin daha kolay olmasına, böylece mevcut topolojilerden ve malzemelerden yararlanma kolaylığı sağlar. Başka bir deyişle, sürücülerin uygun performansı, motor parametrelerinin kesin bilgisini gerektirir. Yani, sürücü ve kontrol sistemlerini uygulamak için motor parametrelerinin doğru bir şekilde tahmin edilmesinin hayati öneme sahip olduğu söylenebilir. Bu nedenle, ASMP'lerin tahmini, farklı teknikler kullanan birçok araştırmacının dikkatini çekmiştir (Boulghasoul ve diğ., 2020). Vektör kontrollü sürücülerini anlamak ve tasarlamak için, çalışmaya ve güvenliğe yanıt veren asenkron makinesinin uyarlanabilir bir simülasyonunun tanımlanması gerekir (Swami ve Jain, 2021). Her kontrolün olası değişiklikler ve hatalarla karşılaştırılması gerektiğinden, bir motorun uyarlanabilir simülasyonunun gerçek bir fabrikanın taklidi olduğu tartışılmaktadır.

2. KAYNAK ARAŞTIRMASI

Literatürde yapılan çalışmalar incelendiğinde çoğunlukla tek değişkenli çalışma koşuluna veya kısıtlı sayıda motor gücüne odaklanıldığı görülmektedir. Ayrıca ASM'lerin çalışma sürecinde parametrelerindeki değişimin tek etken üzerinden incelendiğinde yetersiz olduğu da bir gerçektir. Fakat çalışma koşullarının (motor tipi, yük, rotor hızı vb.) değişkenliği ve çeşitliliği, ASM'lerde matematiksel modellemeyi çok karmaşık bir problem haline getirir. Bu yüzden çalışma koşulları arasında etkisinin en fazla olanların tespiti gereklilik göstermektedir. Böylece modellemenin karmaşıklığından kurtularak basit ve doğrulunu yükselttiğimiz tam bir analiz gerçekleştirilebilir.

Endüstriyel uygulamalarda kullanılan birçok motor, aşırı yük aralığında koruma için elektromekanik veya termal cihazlara güvenir, ancak termal aşırı ısınma ve döngü, termal yıpranmanın hızlanmasına neden olan sargı yalıtımını bozar (Sang-Bin ve diğ., 2002). Isı transfer işleminin analizi genellikle idealleştirilmiş bir makine geometrisi seçilerek gerçekleştirilir. Daha sonra dikkatli bir şekilde temel unsurlara bölünür ve bir düğüm, termal direnç, termal kapasite ve bir ısı kaynağı ile karakterize edilir. Temel unsurları açıklarken, makine yapımı ve kullanılan malzemelerin termal özellikleri hakkında çok şey bilinmelidir. Makinenin birkaç parçaya dikkatli bir şekilde bölünmesi matematiksel modellemede daha iyi bir sonuç verir. Ancak hesaplama görevinde büyük bir karmaşıklık ortaya çıkarır. Bu durum bilgisayar simülasyonu ve yazılım geliştirmede zorluk çıkardığı için basitleştirilmiş bir model önerileri yapılır (Krause ve Thomas, 1965). Piyasada toplu parametre modeli olarak adlandırılan termal ağ modelleri (TNM), elektrikli makinelerdeki sıcaklık artışının belirlenmesi için termal modellerin incelenmesinde benimsenen şemalardan biridir. Toplu parametreler tamamen boyutsal bilgilerden, tasarımda kullanılan malzemelerin ısı özelliklerinden ve sabit ısı transfer katsayılarından elde edilir. Bu, çeşitli çevresel etkilere yüksek düzeyde uyarlanabilirlik anlamına gelir. Bu toplu düzenlemeden kaynaklanan parametre değerlerinin hesaplamaları, nispeten karmaşıktır. Makineyi tam olarak matematiksel olarak tanımlar ve motor koruması da dahil olmak üzere birçok uygulamada çevrimiçi sıcaklık izleme ile termal denklem setleriyle sonuçlanır (Liao ve diğ., 1999; Okoro, 2005; Mellor ve diğ., 1985, 1988, 1991; Roberts, 1986). Bugün akış sisteminin karmaşık termal modellemesini geliştirmek için modern çözüm yöntemleri içeren genel amaçlı gelişmiş hesaplamalı akışkan dinamiği (CFD) paketleri piyasada yer almaktadır. Bu paket kodları karmaşık termal modelleme durumlarında akış sistemini geliştirmeye odaklanan teknolojiyle

tasarlanmışlardır. Yaklaşık olarak tahmin edilen parametreler olan ASM'nin eşdeğer termal devresinin analizine odaklanıldığında, nispeten düşük hassasiyetli bir yöntemle sahip oluruz. Bu yöntemin sakıncası, stator sargısının veya rotor sargısının sıcaklık artışını tahmin eden termal model için yalnızca bir termal kaynak ve yalnızca bir termal direncin kullanılması gerçeğinden anlaşılmaktadır (Boys ve Miles; 1994). Yalnızca üreticinin veri sayfasına dayanan eşdeğer devre parametrelerinin tahmini için başlangıçta, eşdeğer devrenin nominal motor parametreleri ve bilinmeyen değişkenleri, Thevenin yaklaşımı kullanılarak boyutsuz ifadelerde birleştirilir. Böylece yöntem basitleştirilmeye çalışılır (Rajput ve diğ., 2020).

Eşdeğer devredeki manyetik doyumluk, yüzey katmanı etkisi ve sıcaklığın etkisini doğru bir şekilde değerlendirerek ECP'leri hesaplamak için sonlu elemanlar analizi (FEM) dahil analitik ve sayısal tabanlı yaklaşımlar kullanılır (Ling ve diğ., 2014; Boglietti ve diğ., 2008; Boldea ve Nasar, 2010; Agamloh ve diğ., 2017; Feyzi ve Parker, 1997; Batos ve diğ., 1997; Alain ve diğ., 2003). Manyetik doyumluk, motor mıknatıslanma endüktansı üzerindeki yüzey katmanı etkisi, rotor kaçak endüktansı, rotor direnci, giriş akımı, tork ve kayma ölçümleri gibi girişleri çok amaçlı bir genetik algoritma kullanılarak yaklaşık olarak elde edilmeye çalışıldığında karmaşık bir EC modellemesi ile karşılaşmaktadır (Kumar ve diğ., 2014). Bu karmaşık modellemeyi geliştirmek açısından manyetik doyumlukun yanı sıra yüzey katmanı etkisi ve sıcaklığı da dikkate alarak doğru bir tahmin için diferansiyel evrim algoritmasına dayalı bir metodoloji önerilmektedir (Silva ve diğ., 2020; Maleki ve diğ., 2019). Üç boyutlu FEM kullanılarak stator çekirdeğindeki kararlı hal ısı akışını ve demir kayıpları belirleme yönünde çalışmalar da mevcuttur (Armor, 1980). Ancak, bu yaklaşımlarda motor geometrileri ve boyutları hakkında derin bir bilgi gereklidir. Son zamanlarda, bu sorunu çözmek için evrimsel algoritmalar başarıyla kullanılmıştır. Çevrim içi parametre tahminleri maliyetli olması, çalışmaları tahmini ve üretici verileri arasındaki hatayı en aza indirecek bir parçacık sürüsü optimizasyon tekniği aracılığıyla çevrimdışı bir parametre tahmini çözümü sunmaya itmiştir (Zhang, 2023). Motorun çalışma performansını iyileştirmek için üç fazlı asenkron motorun torkunun FEM simülasyonu ile beraber Taguchi yöntemi uygulanarak artırıldığı ve optimize edildiği belirtilir (Lin, 2020). Altı fazlı ASM tasarımı için, Taguchi yöntemi ve iki fazlı çok amaçlı optimizasyonla sonlu elemanlar analizi de sunulmaktadır. Yüksek performans üzerine yapılan çok amaçlı optimizasyon tasarımı, daha düşük başlatma akımı, daha düşük kayıplar, daha düşük giriş gücü, daha yüksek verimlilik, daha yüksek çıkış torku ve daha yüksek güç faktörü elde

ettiği vurgulanmıştır (Toren ve Mollahasanoğlu, 2021). Üç fazlı bir asenkron motorun stator ve rotor direnç parametrelerini, bilinen parametre değerleri ile Taguchi yöntemini kullanarak optimize etme üzerine de çalışmalar yapılmıştır. ANOVA ile doğrulama deneyleri ile optimal tasarım parametrelerinin doğrulanması yapılarak istatistiksel veriler ortaya konulmuştur. Elde edilen düşük direnç değerleri makine performansı üzerinde etkili olan makine nominal güç değeri açısından önemlidir (Cao ve diğ. 2023). Bir başka motor çeşidi olan ve genellikle son zamanlarda elektrikli araçlarda kullanılan kalıcı mıknatıslı senkron motorun tasarımı üzerine ise Taguchi yöntemi destekli polinom, Metamodelleme ve Genetik Algoritma tabanlı optimizasyon tekniği uygulanmıştır. Önerilen modelleme, bu motorların ön tasarımları için hızlı ve doğru çözümlerin elde edilmesinde etkili olduğu belirtilmektedir (He ve diğ., 2020; Gope ve Goel, 2021; Verma ve diğ., 2022)).

Çeşitli motor arızalarını inceleyerek, simüle edilmiş bir motorun sonuçlarını arızalı veya arızasız olarak karşılaştırmak, frekans alanını daha iyi anlayarak analiz etmek ve titreşimlerin temel nedenini belirlemek için MATLAB dinamik simülasyonlar ile hesaplanan Taguchi yöntemi kullanılabilir (Costa ve diğ., 2023). Teknolojik alanın gündeminde olan elektrikli araçların tekerlek içi sabit mıknatıslı senkron motorun üzerine yapılan çalışmada ise, tork dalgalanması ve büyük vuruş torkunun neden olduğu motor performansındaki bozulma sorununu çözmek için, Taguchi yöntemiyle motorun manyetik kutbu ve ortogonal optimize edilmiştir (Chen ve diğ., 2024).

Çalışma koşullarının çeşitliliği ile parametre üzerindeki etkenlerin sayısı ve oranlarındaki değişkenlik, oldukça fazla veri yığınının analiz edilmesi gerekliliğini doğurmaktadır. Endüstriyel Nesnelerin İnterneti (IoT) ve veri odaklı teknikler, bilgisayar ağlarına bağlı makinelerden yüksek miktarda veri toplanmasını ve yüksek makine verilerini kullanılabilir bilgilere dönüştürmesini sağlayarak üretimde devrim yapmaktadırlar (Senanayaka ve diğ., 2017; Choqueuse ve Benbouzid, 2015; Henao ve diğ., 2014). Modern üretim sisteminin önemli bir bileşeni olan makine FD, yüksek veri analizini tamamen benimsemiştir. Geleneksel fizik tabanlı modellerde yukarıdan aşağıya modelleme yöntemi kullanılmaktadır (Filippetti ve diğ., 2013; Toliyat ve diğ., 2012; Heising, 2007). Bu modellemeye karşılaştırıldığında, veriye dayalı makine parametre izleme sistemleri, belirli arızaların meydana gelmesinde, enerjinin verimli kullanımında, sürücülerin etkin kontrolü ile çalışma koşullarının ve kalan faydalı ömrün tahminleri için yeni bir aşağıdan yukarıya çözüm paradigması sunar (Singh, 2003).

Hepimizin bildiği gibi, değişken yük altında, çeşitli çevre şartlarındaki çalışma koşulları; karmaşık dinamik sistemlerin modellenmesini çok zorlaştırarak, fiziksel ve elektriksel modellemelerin oluşturulmasını engellemektedir (Zhang ve diğ., 2010; Benbouzid, 2000). Bu fizik ve elektriksel tabanlı modellemelerin çoğu, etkinliklerini ve esnekliklerinin artmasını sağlayacak çevrim içi ölçülen verilerle güncellenemez. Öte yandan, sensörlerin, sensör ağlarının ve bilgi işlem sistemlerinin önemli ölçüde gelişmesiyle, veriye dayalı makine parametreleri ile makine sağlığı izleme modelleri giderek daha çekici hale gelmektedir. Son birkaç yılda, elektrikli makineler ve sürücüler için yeni durum izleme (CM) şema tasarımı konu araştırmalarında ilerlemeler olmuştur. Özellikle, doğrusal olmama sorununu ve ASM'lerle ilgili diğer ilişkili faktörleri ele almak için çok sayıda yaklaşım geliştirilmiştir (Nandi ve diğ. 2005; Siddique ve diğ., 2005; Riera ve diğ., 2015; Karmakar ve diğ., 2016). Arıza tespiti (FD) ve CM alanlarındaki eğilimler ve ilerlemeler çoğunlukla yapay zeka (AI) uygulamasına odaklanmaktadır. Bu durum AI tekniklerinin, motor devresi analizi (MCA), motor akım sinyal analizi (MCSA) veya motor titreşim analizi (MVA) ile, elektrik motoru teşhis sistemlerinde önemli bir rol oynadığını göstermektedir (Henao ve diğ., 2014; Benbouzid, 2000; Bellini ve diğ., 2008). AI yöntemleri; genetik algoritmalar (GA), makine öğrenimi (ML), derin öğrenme (DL), diferansiyel evrim algoritması (DGA), parçacık sürü optimizasyon algoritması (PSO) vb. olarak belirtilebilir. AI yöntemlerinin yükselişi ve ilerlemesi, yüksek verimli paralel hesaplamalara olanak tanıyan donanım platformlarının geliştirilmesi, sensör üretim maliyetinde düşüş ve toplanan verilerdeki artışla birlikte, veri odaklı metodolojiler artık akademik ve endüstriyel topluluk tarafından ilgi çekici olmakta ve araştırılmaktadır. Veriye dayalı yöntemler, özellik tanılama için büyük miktarda veri kullanan yöntemlerdir. Yöntemler istatistiksel, ML ve DL gibi farklı kategorilerde gruplandırılabilir. İstatistiksel analiz yöntemleri arasında Ana Bileşen Analizi (PCA) ve Kısmi En Küçük Kareler (PLS) bulunmaktadır (Yin ve diğ., 2014). ML yöntemleri büyük miktarda veri için uygundur, ancak genellikle özellikleri vurgulamak ve daha fazla özellik çıkarmak için sinyal işleme teknikleriyle birleştirilir. Motor tanılamada kullanılan yaygın ML yöntemleri başlıca bileşen analizi (PCA) (Malhi ve Gao, 2004), Hilbert-Huang Dönüşüm ve Destek Vektör Makinesi (SVM) (Wang ve diğ., 2013), k-Nearest Neighbors (KNN) ile Hilbert-Huang Dönüşümü (Shen ve diğ., 2015) ve Tekil Değer Ayırması (SVD) olarak sıralanabilir (Nandi, 2005).

Genetik algoritmada, ZIP (empedans, akım ve güç) yük ve ASM'li kompozit (birleşik) yük modellemesi (CLM) için derin öğrenme temelli, zamana göre değişen

parametre tanımlama (TVPI) modeli geliştirilmiştir. Çok modlu model olan uzun- kısa süreli hafıza (M-LSTM) derin öğrenme yöntemi, sistem çapında ölçümler göz önüne alındığında, CLM'nin her zaman değişen parametrelerini tahmin etmek için kullanılır. Giriş verilerindeki farklı durum modlarından faydalanarak, zamana göre değişen yük parametrelerini doğru bir şekilde tahmin etme metodunu içerir (Cui ve diğ., 2019). Ölçülen ve eşdeğer devre model parametreleri arasındaki hataları en aza indirerek üç fazlı asenkron motorlar parametre tahmini (3ASMPE) ile başa çıkmak için modern optimizasyon teknikleri ele alınmaktadır. En küçük kareler ve tekrarlanan en küçük kareler metodu gibi geleneksel matematiksel optimizasyon teknikleri, 3ASMPE'de başarıyla test edilmiştir (Debbabi ve diğ., 2020). Son yıllarda, 3ASMPE için meta-sezgisel (bulgusal) optimizasyon yöntemleri uygulanmıştır. Bu yöntemler, ilk tahmin, modellerin yüksek doğrulukta olmaması, çok değişkenli problemler vb. gibi geleneksel optimizasyon yöntemlerinin eşlik ettiği dezavantajların üstesinden gelir. Endüktif makinelerde deneysel yükleri işlemek için bir GA kullanılması önerilmektedir. Test verilerinden motor parametrelerinin tahmin etme ilkesi, GA tabanlı bir teknik kullanılarak gösterilir. Matematiksel denklemden tahmin edilen hız ve tork parametreleri deneysel bulgularla karşılaştırıldığında her ikisi de güçlü bir bağlantı sergileyerek matematiksel denklemin geçerliliğini ve iyileştirme için genetik algoritma yöntemini kanıtlar (Elnaghi ve diğ., 2019). Literatürde, GA gibi 3ASMPE konularını tartışan farklı algoritmalar bulunmaktadır (Rabtis ve Kladass, 2019). GA'lar arasında PSO en popüler olanlarındandır.

DL yaklaşımlarındaki çoğu çalışma, özellik mühendisliği veya sinyal koşullandırmaya ihtiyaç duymadan genel sistem doğruluğunu artırmak için yarı denetimli ağları ve "transfer öğrenmeyi" içerir (Pan ve Yang, 2009). Bu tür modelleri açıklamak için, ağı eğitimiyle FD'nin etkili olabileceği önemli durum göstergelerini tespit ederek özellik haritalarını görselleştirmek mümkündür (Palmieri ve diğ., 2020). Bu stratejiler, verilerdeki durağan olmama nedeniyle şu anda emekleme aşamalarında olsa da sinyallerin önceden işlenmesi gerekliliğini koruyor.

3ASMPE, yapay arı kolonisi optimizasyonu kullanılarak farklı yükleme koşullarında motor voltajı, giriş gücü, giriş akımı, hız ve çıkış gücü ölçülerek ele alınan araştırmalarda mevcuttur (Aminu, 2019). Ancak bu yöntemi kullanan araştırmacılar, stator direncinin bilindiğini (R_s) ve stator ile anılan rotorun kaçak reaktansının ($X_s=X_2$) eşit olduğunu varsaymıştır. Bu nedenle, optimize edici için bilinmeyen değişkenler

3ASMPE tek kafesli model için 6 (R_s , R_2 , R_m , X_s , X_2 , ve X_m) yerine 4'e (R_2 , R_m , $X_s=X_2$, ve X_m) düşürülür ve motor verimini azaltan çıkış gücünün ölçülmesi gereklidir.

Birçok kararlı algoritma, yer verdikleri eşdeğer topolojilerin birinden veya her ikisinden türetilen uyarlanabilir bir asenkron makinesi simülasyonu içerir. Tek kafesli bir asenkron makine, makul bir başlangıç torku artışı sunar. Bununla birlikte, tek kafes tasarımı sıklıkla hatalıdır. Bu tür sorunlar çift kafesli veya daha derin çubuk rotor tasarımı kullanılarak çözülebilir. Fakat bu seferde veri eksikliği, genellikle çift kafesli ve daha derin çubuk tasarımlarının kullanımını sınırlar. Tek kafesli tasarımın tork-kayma özelliğini geliştirmek, bu durumlar için basitleştirilmiş bir çözümdür (Duan ve diğ., 2021; Shepard, 2021).

Yüksüz ve kilitli rotor koşulları altında motor çalıştırılarak stator üzerinde iki karmaşık empedans okuması veya dört değişken izlenebilir. Bu tür karşılaştırılabilir sistemlerde beş değişken sağlamak yetersizdir. Bu genellikle mıknatıslanma endüktansının rotor endüktansı ile aynı olacak şekilde rastgele ayarlanmasıyla düzeltilir (Tang ve diğ., 2021).

Klasik asenkron makinesi modeli sadece bakır kaybını dikkate alır. Demir kaybını dikkate alan T-tipi eşdeğer devreye dayalı olarak, 3 fazlı ASM'nin ECP'lerini doğru bir şekilde ölçmek ve analiz etmek için rotorsuz test ve çift yük testinden (DLT) oluşan etkili bir belirleme yöntemi önerilmiştir. DLT'nin kilit noktası, yük değişmeden önce ve sonra maksimum gerilimin (U_m) biraz değişmesini sağlayarak rotor kolunun voltajı neredeyse sabit tutmaktır. Kayma çok küçük olduğundan, R_2/s kilitli rotor testinde ölçülen R_2 'nin 20–50 katıdır ve ayrıca X_2 'den çok daha büyüktür, bu nedenle rotor kaçak manyetik alanı DLT'de genel olarak değişmemiş olarak kabul edilir. Bunlar, rotor kaçak reaktansının X_2 ' ölçümünde önemlidir (Chen ve Bi, 2022).

3ASMPE'yi zaman alan ölçümlerini kullanarak tahmin etmek için Kalman filtresine dayalı birçok yöntem literatürde sunulmaktadır (Gashtil ve diğ., 2019). Makine çalışma koşulları değiştiğinde, doğrusal olmayan bir sistem haline gelir. Genişletilmiş Kalman filtresi (EKF), doğrusal olmayan bir sistem için rastgele bir gözlemdir. EKF ses üreteçleri, ölçüm ve simülasyon hatalarını hesaba katar (Yıldız ve diğ., 2020). Ancak bu yöntemler optimal değildir ve ilk durum tahmininden etkilenirler. Global duyarlılık analizi (GSA), optimize edilmiş parametrelerdeki belirsizliğin başlangıç, maksimum ve tam yük koşullarında motor performansının varyansı üzerindeki etkilerini tahmin etmek için etkili bir yöntemdir (Al ve diğ., 2019; El-Hameed ve diğ., 2020; Elkholy ve diğ., 2022).

Sonuç olarak değişken parametrelere sahip ASM'ler, motor tasarımından bağımsız olarak çalışma modunu değiştirirken rotor parametreleri de değişen motorlardır. Aynı güce sahip geleneksel asenkron motorlar karşılaştırıldığında, bu tür motorlar elektromanyetik ve özellikle termal geçici akımlarla eşleşen durumda daha uzun süre kalabilirler. Bu tür modlarda, bir elektrik makinesinin bazı elemanları aşırı ısınabilir, bu da motor momentini düşürerek, çok sayıda elektriksel, manyetik ve termal parametrenin değişmesine neden olur. Buna karşılık, parametrelerde bir değişiklik, makinenin çalışma akımlarının yoğunluğunu etkiler ve böylece motor kayıplarını değiştirir. Bunun yanı sıra parametre tahmininde sadece ısıyı baz almak modellemenin eksik yapılmasına neden olacaktır. Isının yanında güç (P), yük (T_y), kayma (s) ve motor milinin dönme devride (n) motor parametrelerinin etkileyen önemli bir kavram olarak karşımıza çıkmaktadır. Bir elektrikli makinenin, izin verilen maksimum sıcaklık, en iyi yük ve devir aralığında çalışmasıyla, yüksek verimlilikle gerekli performansı sergilediğinde iyi tasarlanmış olduğu söylenir.

Literatür taramasından şu sonuca varılabilir:

- 1) Tasarım aşamasındaki motorda ölçüm veya eşdeğer devre tabanlı yöntemlerin kullanılması mümkün değildir.
- 2) Analitik veya FEM tabanlı yöntemler tasarım aşamasında kullanılabilir, ancak önceden kurulmuş bir motora uygulanamaz çünkü tam geometri ve malzeme verileri mevcut olmayabilir.
- 3) Parçacık sürüşü optimizasyon tekniği aracılığıyla çevrimdışı bir parametre tahmini bize sunmaktadır. Ama bu da zamanla sıcaklık, yük gibi çevresel faktörlerin etkilerini online olarak tahmin edemez.
- 4) Elektriksel parametreler çok amaçlı bir genetik algoritma kullanılarak yaklaşık olarak elde edilebilir. Fakat bu yöntem karmaşık bir EC modellemesi içermektedir.
- 5) Sadece termal eşdeğer parametresi gibi tek çevresel etkenle yapılan tahminler sınırlı ve yetersiz kalmaktadır.

Bu nedenle, aşağıdaki özelliklere sahip kapsamlı bir elektriksel parametrelerin matematiksel modeline ihtiyaç vardır:

- 1) Kullanımı basit;
- 2) Kapsamlı matematik modellemesi ile hali hazırda var olan bir motor için olduğu kadar tasarım aşamasında veya tamir aşamasında kullanılabilir olması;
- 3) Farklı güçlerde, yük altında, çalışma devrinde, sargı sıcaklıklarında ve rotor kayma oranına göre motorların ECP'si doğru ve kısa sürede belirlenebilmesine.

4) Motor parametrelerinin değişkenliğini doğru tespit etmek için çevresel etkenlerin parametre üzerindeki etkenlik oranını tespit ederek matematiksel modelleme yapılması.

5) Yapay zeka tabanlı yöntemler ile parametre veri analizi geliştirerek doğru, basit bir modelleme sunmak.

Bu tez çalışmasında asenkron motorların en büyük sorunlarından birisi olan çalışma şartlarına göre değişkenlik gösteren ECP'lerin hatasız ve basit bir modellemeyle tespiti amaçlanmıştır. ASM'ların oldukça yaygın kullanılması, çalışma şartlarının da değişkenliğini artırmakta bu da parametrelerde doğrusal olmayan bir değişkenlik içermesine neden olmaktadır. Ayrıca laboratuvar ortamında tüm gerçek deneyleri yapmak maliyet ve zaman almaktadır. Çevrim içi veri analizi de oldukça maliyetli ve her yerde kullanıma uygun değildir. Tüm koşulların parametre üzerindeki etkileri içeren bir modelleme oldukça karmaşık ve doğruluk oranı düşük olacağından parametreler üzerinde etkisi en fazla olan koşulların tespit edilmesi gereklidir. Bu tespitin Taquchi yöntemiyle analizi mümkündür. Koşulların değişkenliği oldukça fazla deneyin yanında veri yığını da oluşturmaktadır. Veri yığınının fazlalığı tespit sonuçlarının ve modellemenin doğruluk oranını artırırken işlenerek analiz edilmesi için yapay zeka tekniklerinde faydalanılmak zorunda kalınmaktadır. Çalışmada veri yığınlarının analizi için yapay zekanın alt kolu olan makine öğrenimi metodu kullanılmıştır. Böylece bugüne kadar yapılan asenkron motorun matematiksel modellemesine birden fazla çevre koşullarının etkinlik oranlarıyla ortaya konarak farklı motor güçleri, farklı yük oranları, farklı rotor devri, farklı sargı sıcaklığı ve rotor kayma oranını içeren oldukça kapsamlı ve doğruluğu yüksek yeni bir modelleme yaklaşımı getirildi.

Bu amaçla parametre ve performans değişimlerinin incelenmesi ve belirlenmesi için 5 farklı güçteki 0,75kW-1.5kW-2kW-4kW ve 5.5kW'lık motorlar 375d/dk-750d/dk-1125d/dk-1500d/dk gibi farklı devirlerde %25-%50-%75 ve %100 yük altında çalışma deneyleri yapıldı. Eşdeğer devre parametrelerinin belirlendiği bu deneylerde motorların ısısının değişimi ve bunun sonucu olarak motorun çektiği akım (I_s), gerilim (V_s), tork(T), güç (P), devir (n), sargı ısısı (Δt), güç faktörü (ϕ), frekans (f), kayma (s), stator sargılarının iç direnci (R_s), rotor devresi direncinin stator devresine aktarılmış eşdeğeri (R_2), stator sargılarının kaçak reaktansı (X_s), rotor devresi kaçak reaktansının rotor devresine aktarılmış eşdeğeri (X_2), uyartım devresi direnci (R_m) ve boş çalışmadaki uyartım reaktansı (X_m) parametreleri ölçülmüş ve hesaplanmıştır. Elde edilen veriler tez içerisinde

grafiksel olarak yer verilirken bahsedilen yöntem, analizler ve yapay sinir ağıları ile hatasız, doğruluğu yüksek ve basit bir matematiksel modelleme ortaya kondu.



3. MATERYAL VE YÖNTEM

Bu çalışmada, asenkron motorların farklı güçlerde, rotor devirlerinde, yük oranlarında, sargı sıcaklıklarında ve kayma değerlerinde elektriksel eşdeğer devre parametrelerinin doğru tahmin edilerek matematiksel modellenmesi hedeflenmiştir. Oluşturulan deney düzeneğinde asenkron motor olarak 0,75kW-1,5kW-2,2kW-4kW ve 5,5kW gücünde asenkron motorlar kullanıldı. Maksimum rotor devirleri 1500 d/dk olan bu motorlar 375-750-1125 ve 1500 d/dk çalıştırılarak, her motor her devirde %0(Yüksüz)-%25-%50-%75 ve %100 oranlarında yüklendi ve parametrelerdeki değişim oranları analiz edildi. Bu deneylerde her motoru 90 dk boyunca enerji altında tutarak ölçülen ve hesaplanan veriler 2 sn'de bir Excel formatında kayıt altına alındı. Her deneyden 2700 satır, giriş ve çıkış verilerinin toplamı 15 sütundan oluşan veri bankası oluşturuldu. Bu şartlar göz önünde tutularak boşa ve yükte çalışma deneyleri toplam 100 ana deney gerçekleştirildi. Böylece oldukça fazla analiz edebilecek 4.050.000 veri yığını oluştu.

Motorların çalışma koşullarında değişkenlik gösteren eşdeğer devre parametrelerinin analizi için birkaç analiz yöntemi uygulandı. Parametrelerin grafiksel değişimleri çizdirilerek parametreler üzerinde etkili olan giriş değişkenleri ortaya konularak tespit edildi. Çok fazla deney ve parametre olması tüm grafiklerin bu çalışmada yer verilmesini mümkün kılmadığı için diğer analiz yöntemlerinde etkinliği ve yeterliliği ortaya konan deneylerdeki parametre grafiklerine çalışmada yer verilmiştir.



Elde edilen veri yığınının büyüklüğü her yöntemin analizini mümkün kılmaması ve her parametrenin değişkenlikleri doğrusallık göstermemesi çalışmada farklı analiz yöntemlerinin kullanılmasına itmiştir. Bu analiz yöntemlerinden biri Taguchi yöntemidir. Taguchi yöntemiyle yüklü çalışma için planlanan 64 deneyden 16'sının verileriyle analiz gerçekleştirilebileceği oluşturulan kodlamayla ortaya konmuştur. Ayrıca yine Taguchi yöntemi kullanarak motorların giriş değişkenliklerini sınırlandırılarak çıkış parametreleri üzerinde en fazla etkili olanlar belirlendi. Böylece matematiksel modelleme doğruluktan ve kullanım kolaylığından uzaklaştıracak olan motor giriş değişkenlerindeki çeşitlilik oranı azaltılarak, matematiksel modellemenin basitlik ve doğruluk oranı (R^2) artırılmıştır. Bunlar tablolar halinde tez içinde sunulmaktadır.

Veri bankasının genişliği modellemenin doğruluğunu artırmaktadır. Ne kadar çok veri üzerine analiz yapılırsa o kadar yüksek doğrulukta matematiksel bir modelleme elde edilir. Bu yüzden veri yığınlarını kolaylıkla hatasız işleyebilmek adına yüksek verileri

rahatlıkla analiz edebilmek için ‘Makine Öğrenimi’ metodu kullanılmıştır. Bu metot ile elde edilen sonuçlar Bölüm 3’te ayrıntılı verilmektedir. Yaptığımız farklı analiz metotları çalışmayı sağlam temeller üstüne oturtturarak geçerliliğini ortaya koymuştur.


3.1. Asenkron Motor

ASM’ler; direkt bir fazlı veya üç fazlı alternatif akım şebekesinden beslenebilmesi, dayanıklı, bakım gerektirmeyen yapısı ve düşük maliyetleri sebebiyle hem sanayide hem de ev aletlerinde oldukça fazla kullanılan motor türü haline gelmiştir. Dünyada üretilen enerjinin %70 civarındaki kısmının ASM’ler tarafından tüketiliyor olması bu motorların kullanım sıklığını ve önemini göstermektedir. Şekil 3.1’de bir ASM’nin parça ve kesit halinde iç yapısı gösterilmiştir.



Şekil 3.1.Üç fazlı ve kısa devre rotorlu bir ASM yapısının; (a) Ana parçaları b) Kesiti (Zeybek, 2023)

ASM'ler genel hatlarıyla elektriksel olarak en önemli iki parçası stator ve rotor olarak iki kısımdan meydana gelir. Diğer parçaları mekaniksel yardımcı parçalarıdır. Bu yüzden asenkron motor üzerinde elektriksel bir modelleme ve verimlilik artırımı gerçekleştirilecekse stator ve rotor üzerinde yapılan çalışmalar öncelikli olmalıdır. ASM'lerin duran kısmı olan stator, sargılardan oluşmaktadır. Bu sargılardan sargı grupları oluşturularak aralarında 120° faz farkı olan 3 fazlı şebeke gerilimi ile sargı gruplarından akım dolaşması sonucu etrafında manyetik bir alan ve kutuplaşma oluşur. Rotor manyetik alan ve kutuplaşma etkisiyle dönme gerçekleştirir. Şekil 3.2'de asenkron makine enerji altındayken oluşan manyetik akı aktivasyonu görülmektedir.




Şekil 3.2. Manyetik akı aktivasyonu (Volt Elektrik Motorları) (Zeybek, 2023)

ASM'nin dönen kısmına rotor adı verilir. Sincap kafesli (kısa devre rotor) ve sargılı tip (bilezikli rotor) olmak üzere iki çeşit rotor yapısı vardır.

3.1.1. Sincap kafesli rotor (Kısa devre rotor)

Rotor, ince silisyumlu saçların kesilerek sıkıştırılarak paketlenmesinden sonra, üzerine belli açılarla açılmış kanalların içine eritilmiş alüminyum dökülerek üretilir. Rotorun her iki tarafında, bu alüminyum rotor çubuklarını kısa devre eden halkalar bulunur. Bu halkaların uçlarındaki küçük kanatçıklar pervane görevi görerek motorun dışı gibi içinde de hava sirkülasyonu oluşturur. Böylece motor içinde ısıнын uzaklaştırılması

sağlanır. Bazı büyük motorlarda kanallara iletimin daha iyi olarak güç ve verimi artırmak için bakır çubuklar yerleştirilir.



(a)



(b)

Şekil 3.3. (a) Sincap kafesin içi boş hali (b) Sincap kafesli rotor

3.1.2. Sargılı rotor (Bilezikli rotor)

Saçları paketlenerek silindir haline getirilen rotorun üzerindeki oluklara 3 fazlı alternatif akım sargısı yerleştirilir. Aralarında 120° faz farkı bulunan üç fazlı sargılar yıldız ya da üçgen bağlandıktan sonra elde edilen üç sargı ucu, mile yalıtılarak yerleştirilen Şekil 3.4-a'da görüldüğü gibi üç adet bileziğe bağlanır ve böylece bilezikli rotor elde edilir.



(a)




(b)



(c)

Şekil 3.4. (a) Bilezikli rotor (b) Bilezikli rotorun statora yerleştirilmesi (c) Bilezikli asenkron motor

Rotor sargılarının yıldız ya da üçgen bağlantısına ait bağlantı şeması Şekil 3.5'te verilmiştir.



Şekil 3.5. Sargı uçlarının bileziklere bağlanması, (a) Yıldız, (b) Üçgen bağlantı (Holtz, 2006)

Rotoru sargılı asenkron motorlarda her bilezik, milden ve diğer bileziklerden yalıtılmıştır. Dönen kısma akım, bileziklere basan fırçaların içindeki kömür aracılığı ile sargılara uygulanır. Bilezikli rotorlu da denilen bu tip motorlarda devir sayısı, rotor devresindeki dirençlerle kolayca ayarlanabilmektedir.

3.1.3. İndüksiyon makine modeli

Bir ASM'nin modeli, Denklem 3.1- Denklem 3.6'da ifade edildiği gibi, durum uzayı denklemleri aracılığıyla tamamen tanımlanabilir. ASM'nin dinamik temsili için, aşağıdaki denklemlerin uyarlandığı temel kaynaklar şunlardır (Holtz, 1994,1995,2002; Sarıoğlu ve diğ., 2003).

$$V_s = R_s I_s + \frac{d\Psi_s}{dt} \quad (3.1)$$

$$V_r = R_r I_r + \frac{d\Psi_r}{dt} - j\omega_e \Psi_r \quad (3.2)$$

$$\Psi_s = L_s I_s + L_m I_r \quad (3.3)$$

$$\Psi_r = L_m I_s + L_r I_r \quad (3.4)$$

$$T_e = \frac{3}{2} \text{plm}(\Psi_s^* \cdot I_s) \quad (3.5)$$


$$J \frac{d\omega_m}{dt} = T_e - T_{load} \quad (3.6)$$

Durum-uzay denklemlerinde V , I ve Ψ sırasıyla gerilim, akım ve akı anlamına gelmektedir. s ve r alt simgeleri stator ve rotor değişkenlerini belirtmek için kullanılır. T_e

ve T_{load} elektromanyetik ve yük torklarını, ω_e rotor açısal frekansını, ω_m mekanik hızı, p kutup çifti sayısını temsil eder. Rotor açısal frekansı mekanik hızın p katıdır (Denk. 3.7).

$$\omega_e = p \cdot \omega_m \quad (3.7)$$


Durum-uzay denklemleri ASM davranışını tanımlamak için yeterli olsa da bu denklemlerin eşdeğer devre şeklinde görsel temsili daha anlaşılırdır ve Şekil 3.6'da gösterilmiştir.



Şekil 3.6. ASM eşdeğer devre

3.1.4. Üç fazlı asenkron motorların tam eşdeğer devresi

ASM'lerin elektriksel tam eşdeğer devresi üç kısımda incelenebilir. Birinci kısım motora enerji uygulanan stator kısmıdır (Şekil 3.7-a). Stator sargılarında indüklenen gerilim E_s ile nüve üzerinde, zamana bağlı olarak değişken bir manyetik akı oluşturur. Bu manyetik akının büyük miktarı stator ve rotor demir nüve üzerinden devresini tamamlar. Stator ile rotor arasında hava boşluğu ve manyetik alanla oluşan devre uyartım devresi olarak adlandırılır. Bu devre bir faz stator eşdeğer devresinde paralel bir kol olarak konumlandırılır. Paralel kol stator akımını, uyartım akımı (I_u) ve rotor akımının statora etkisini ifade eden (I_r') olarak ikiye böler. Uyartım devresi rotor nüvesini ifade eden R_m direnci ile mıknatıslanma reaktansından (X_m) paralel bağlı olarak oluşur. Burada I_u akımı direnç ve reaktans üzerinden geçen I_w ve I_m olarak iki akıma ayrılır (Şekil 3.7-b). Asenkron motorlar dönen transformatörler olarak da adlandırılır. Statorda oluşan E_s gerilimi rotor çubuklarında bir gerilim indüklenmesine (E_r) sebep olur. İndüklenen bu gerilim Şekil 3.7-c'de görüldüğü gibi rotor devresinin R_r direnci ve X_r kaçak reaktansından I_r rotor akımının geçmesini sağlar.



Şekil 3.7. Bir faz (a) stator (b) manyetik (c) rotor eşdeğer devresi

ASM'nin statoruna alternatif bir gerilim (E_f) uygulandığı zaman sargılardan geçen akım (I_s) stator sargı direnci (R_s) ve stator kaçak reaktansı (X_s) olmak üzere iki adet parametre meydana getirir. Stator sargılarının iç direnci R_s , kaçak reaktans X_s 'ye seri bağlanır. Bu parametreler üzerinde harcanan enerjiden geriye kalan stator sargılarında indüklenen gerilime ise (E_s) denir.

$$E_s = E_f - I_s \cdot (R_s + jX_s) \quad (3.8)$$

$$X = 2\pi \cdot f \cdot L \quad (3.9)$$

Asenkron motorların rotor parametrelerinin üzerinde en büyük etken kayma (s) parametresidir. Kayma değeri bu parametrelerin motor çalışırken değişimine neden olmaktadır. Burada rotor dururken sargılarında indüklenen gerilim (E_{r0}) ve kaçak reaktansı (X_{r0}) kayma ile çarparsak Denklem 3.10 ile Denklem 3.11'de olduğu gibi motorun çalışma anındaki anlık kayma değerine göre E_r ve X_r değerlerini elde ederiz.

$$E_r = s \cdot E_{r0} \quad (3.10)$$

$$X_r = s \cdot X_{r0} \quad (3.11)$$


Kayma, stator devir sayısı (n_s) ile rotor devir sayısı (n_r) parametreleriyle hesaplanmaktadır. Denklem 3.12- Denklem 3.14'te bu denklemler verilmiştir.

$$s = \frac{n_s - n_r}{n_s} = \frac{\omega_s - \omega_r}{\omega_s} \quad (3.12)$$

$$n_s = \frac{120 f}{2p} \text{ d / dk} \quad (3.13)$$

$$\omega_s = \frac{120 f}{2p} \cdot \frac{2\pi}{60} \text{ rad / s} \quad (3.14)$$

Stator, uyarım ve rotor devresini birleştirecek Şekil 3.8'de görüldüğü gibi asenkron motorun bir faz eşdeğer devresi elde edilir.



Şekil 3.8. Asenkron motorun bir faz eşdeğer devresi

Şekil 3.8'deki eşdeğer devrende hem elektrik hem de manyetik devre birleşimi görülmektedir. Hesaplamalar yapılabilmesi için bu devrenin sadeleştirilerek tamamen elektriksel devreye dönüştürülmesi gerekmektedir. Bu sadeleştirme için rotor devresine ait parametreler stator devresine aktarılmalıdır. Manyetik devrede aktarılma yapılabilmesi için Denklem 3.15 kullanılır.

$$a = \frac{N_1 \cdot k_{w1}}{N_2 \cdot k_{w2}} \quad (3.15)$$

Asenkron motor dönen bir transformatöre benzetilebilir. Bu yüzden transformatörlerin dönüşüm mantığı burada da geçerlidir. Transformatördeki dönüştürme oranını asenkron motorlara uygularsak Denklem 3.15'teki a denklemiyle karşılaşırız. Bu denklemdeki N_1 stator sarım sayısı, N_2 rotor sarım sayısı, k_{w1} stator faktörü ve k_{w2} rotor sargı faktörünü ifade etmektedir. Dönüştürme oranının diğer parametreler olan; rotor sargılarında indüklenen gerilimin stator devresine aktarılmış eşdeğeri (E_r') ve rotor devresi kaçak reaktansının rotor devresine aktarılmış eşdeğeri ile arasındaki ilişki Denklem 3.16- Denklem 3.19'da olduğu gibi ifade edilir.


$$E_r' = a \cdot E_r \quad (3.16)$$

$$R_2 = a^2 \cdot R_r \quad (3.17)$$

$$X_2 = a^2 \cdot X_r \quad (3.18)$$

$$I_r' = \frac{I_r}{a} \quad (3.19)$$

Denklemler kullanılarak rotor devresi statora aktarıldığında elde edilen eşdeğer devre Şekil 3.9'da görülmektedir.



Şekil 3.9. Asenkron motorun rotor direncinin ikiye ayrılması ile oluşan tam eşdeğer devre

Şekil 3.9'da R_y , motor milindeki yükün stator terimleri cinsinden elektrik direnci (Ohm) ifade etmektedir. Tam eşdeğer devresine göre parametreler tekrar Denklem 3.20-Denklem 3.22'de formülleştirilir.

$$E_f = E_r' + I_s \cdot (R_s + jX_s) \quad (3.20)$$

Kirşof'un akımlar kanununa göre; düğüm noktasına giren akım çıkan akımların toplamına eşittir.


$$I_s = I_u + I_r' \quad (3.21)$$

$$I_u = I_w + I_m \quad (3.22)$$

3.1.5. Asenkron motorların sadeleştirilmiş eşdeğer devresi

Gerçek eşdeğer devredeki devre çözümünü azaltmak için gerçek eşdeğer devredeki sonuçlara yakın sonuçlar veren sadeleştirilmiş bir YAKLAŞIK EŞDEĞER DEVRE geliştirilmiştir.

Sadeleştirilmiş eşdeğer devrede uyartım kolu öne taşınarak parametre hesaplamaları kolaylaştırılır. Uyartım kolu parametreleri R_m ve X_m diğer devre parametreleri olan R_s , R_2 , X_s ve X_2 'den oldukça yüksek olduğu için üzerinden geçen uyartım akımı I_u ve bileşenleri olan I_w ve I_m oldukça düşük olacaktır. Bu yüzden uyartım kolunu eşdeğer devrenin giriş kısmına almak parametre değerlerinde önemli bir fark oluşturmaz. Şekil 3.10'da sadeleştirilmiş eşdeğer devre verilmiştir.



Şekil 3.10. Asenkron motorun sadeleştirilmiş bir faz eşdeğer devresi


Şekil 3.10'daki yaklaşık eşdeğer devresine göre,

$$R_{eq} = R_s + R_2 \quad (3.23)$$

$$X_{eq} = X_s + X_2 \quad (3.24)$$

$$E_f = I_s \cdot (R_{eq} + R_y + jX_{eq}) \quad (3.25)$$

Literatürde kullanılan bir diğer basitleştirilmiş eşdeğer devresi Şekil 3.11'de Thevenin eşdeğer devresidir.



Şekil 3.11. Asenkron motorun Thevenin eşdeğer devresi

İlk olarak, eşdeğer devrenin bilinmeyen değişkenleri, nominal motor parametreleri ile uygun şekilde boyutsuz ifadeler halinde birleştirilir. Thevenin yaklaşımı, bilinmeyen değişkenlerin sayısını ve denklemlerin sırasını azaltan boyutsuz değişkenlerin başarılı bir kombinasyonuna izin verir. Şekil 3.11 genel eşdeğer T devresinin Thevenin eşdeğer devresini göstermektedir. Şekil 3.11'in elemanları V_{Th} Thevenin gerilimi, R_{Th} giriş Thevenin eşdeğer direnci, X_{Th} giriş Thevenin eşdeğer reaktansı ve $(I_s)_{Th}$ giriş tek fazlı Tevenin akımı olarak tanımlanır. T-devresinin Thevenin devresine dönüşümü aşağıdaki formül ile ifade edilir (Rajput, 2020):

$$V_{Th} \simeq E_f \cdot \frac{X_m}{X_s + X_m} \quad (3.26)$$

$$X_{Th} \simeq X_1 \quad (3.27)$$

$$R_{Th} \simeq R_s \cdot \left(\frac{X_m}{X_s + X_m} \right)^2 \quad (3.28)$$

Thevenin devresi ve hesaplanan besleme gerilimi kullanılarak, ana motor parametreleri: motor torku (τ_{ind}), maksimum tork (τ_{max}), kritik kayma (S_K) olarak yazılır.

$$\tau_{ind} = \frac{3V_{Th}^2 R_2 / s}{\omega_s \left[\left(R_{Th} + (R_2 / s) \right)^2 + (V_{Th} + X_2)^2 \right]} \quad (3.29)$$

$$\tau_{max} = \frac{3V_{Th}^2}{2\omega_s \left[R_{Th} + \sqrt{R_{Th}^2 + (V_{Th} + X_2)^2} \right]} \quad (3.30)$$

$$S_K = \frac{R_2}{\sqrt{\left[(R_{Th} + R_2)^2 + (V_{Th} + X_2)^2\right]}} \quad (3.31)$$

Tüm bunlar Denklem 3.36- Denklem 3.39 eşdeğer devrenin parametrelerini belirlemek için önemli bir rol oynamaktadır.

Üç boyutsuz değişkenli bir eşdeğer devrenin parametrelerini belirlemek için aşağıdaki boyutsuz denklemler uygulanmıştır:

$$Y_1 = \frac{X_m}{X_s + X_m} \quad (3.32)$$

$$Y_2 = \frac{R_2}{R_s} \quad (3.33)$$

$$Y_3 = \frac{X}{R_s} \quad (3.34)$$

Burada daha önce kanıtlanmış olan $X_1 = X_2$ ifadesi benimsenmekte ve X olarak yeniden adlandırılmaktadır (Rajput, 2020):

$$X_{Th} = X_s = X_2 = X \quad (3.35)$$

R_s , R_2 , X ve X_s aşağıdaki denklemler kullanılarak hesaplanabilir.

$$R_s = \frac{\left(Y_1^2 + \sqrt{Y_1^4 + 4Y_3^2}\right)}{Y_1^2 \left(\left(2/3\right)\left(\tau_{\max} \omega_s / E_f^2\right)\right)} \quad (3.36)$$

$$R_2 = R_s \cdot Y_2 \quad (3.37)$$

$$X = R_s \cdot Y_3 \quad (3.38)$$

$$X_m = X \cdot \frac{Y_1}{1 - Y_1} \quad (3.39)$$


Bu tez çalışmasında 0,75-1,5-2,2-4 ve 5,5kW gücünde asenkron motorlar laboratuvar deneylerinde asenkron motorun sadeleştirilmiş bir faz eşdeğer devresi baz

alınmış, sargı sıcaklığı ve kayma etkisi de dahi edilerek incelenmiştir. Böylece bahsedilen klasik parametre tahmini deneyleri ile önerilen yöntemler karşılaştırılmıştır. Bu motorların üzerindeki fabrika verilerinden oluşan etiket değerleri Çizelge 3.1'de verilmiştir.

Çizelge 3.1. Asenkron motor etiket değerleri

Smb	Açıklama	Değer	Değer	Değer	Değer	Değer
kW	Motor Güç Değeri	0,75	1,5	2,2	4	5,5
V	Nominal Voltaj	400 V	400 V	400 V	400 V	400 V
I	Nominal Akım	1,9A	3,6A	4,85A	8,2A	10,8A
Φ	Güç Faktörü	0,75	0,73	0,78	0,81	0,84
d/dk	Rotor Devir Sayısı	1435	1450	1445	1450	1455
2P	Çift Kutup Sayısı	4	4	4	4	4
Rs	Stator Direnci	20,1 Ω	8,6 Ω	3,65 Ω	5,67 Ω	8 Ω
Klemens Bağlantısı		λ	λ	λ	Δ	Δ

Deneylerde kullanılan tüm motorların sargı ısınısını ölçmek için sargılarının arasına Pt1000 ısı sensörü yerleştirilmiştir. Şekil 3.12'de bir motora yerleştirilme örneği görülüyor.



Şekil 3.12. ASM sargı arasına PT1000 ısı sensörünün yerleştirilmesi

Isı sensörünün uçları motor klemensinde çıkartılarak sürücüye bağlanacak şekilde montajlanmıştır. Sensörden gelen veriler ile motorun farklı güç, yük ve devirde sargılarındaki ısı değişimleri anlık ölçülerek özellikle ısının motor parametrelerin üzerindeki etkisi ortaya çıkarıldı.

3.2. Pano Tasarımı ve Yazılım

Motor kontrol panosu güç analizörünün bulunduğu ölçüm panosu üzerinden şebekeye bağlandı.



Şekil 3.13. Ölçüm panosu


Motor kontrol panosunun dış tasarımında HMI KTP700 dokunmatik ekran bulunmaktadır. Bu ekrandan deney başlangıcında ve hız kontrol cihazına motor tanımlarken kullanılan motor etiket verilerinin girişini deney süresi, rotor devir sayısı ve kayıt alınan saniye aralığı bilgileri girilmektedir. Deney esnasında adaptif olarak online parametre takibi yapılabilmektedir. Ayrıca parametrelerin grafiksel gösterimlerine dokunmatik ekran üzerinden ulaşılır. Şekil 3.14’te motor kontrol panosunun dış tasarımı görülüyor.



Şekil 3.14. Motor kontrol panosunun dış tasarımı


Sistem; projelendirme yazılımı, kontrolörler ve HMI üniteleri arasında kolay bağlantı ve haberleşme için PROFINET portuna da sahiptir. Ayrıca siemens scalance xb008 ethernet 5 portlu switch mevcuttur.

Şekil 3.15'te HMI KTP700 dokunmatik ekran üzerinde yapılan yazılımla; U, I, n, T, P, f, pf ve Δt hem anlık görüntülenebilmekte hem de ekranın sol tarafına üzerine girilen deney kayıt süresi arasındaki en son hafızaya kaydedilen bilgiler görülmektedir. Alt en sağdaki MOTOR ETİKET VERİLERİ görsel butonu seçildiğinde farklı bir sayfa açılmakta ve motor etiket bilgileri girilmektedir.




Şekil 3.15. HMI dokunmatik ana

Şekil 3.16’da görüldüğü gibi açılan sayfada girdiğimiz bu motor bilgilerinin daha sonra PARAMETRE YAZ-KALICI OLARAK KAYIT ve MOTOR TANIMLA görsel butonlarına sırayla basarak hem bilgilerin PLC ve sürücü hafızasına kaydedilmesi sağlanmakta hem de sürücünün motora sinyal göndererek anlık motor verilerini ölçmesi ve tanınması sağlanmaktadır.



Şekil 3.16. HMI dokunmatik ekran motor etiket verileri giriş sayfası


Motor etiket verilerinin girildiği görsel butonun bir yanında MOTOR GÜNCEL GRAFİK’lerinin (U, I, n, T, P, f, pf ve Δt) onun yanında da HESAPLANAN GRAFİK’lerin (R_s , R_2 , R_m , X_s , X_2 , X_m) verildiği sayfalar açılmaktadır. Burada motordan anlık ölçülen ve hesaplanan parametrelerin grafikleri ayrı ayrı sayfalarda yer almaktadır. Şekil 3.17’de bu sayfalar gözükmemektedir.



Şekil 3.17. HMI dokunmatik ekran motor güncel grafik gösterim sayfaları

Ekranın sol altında ise TEST 'in devri, süresi (dk cinsinden) ve veri kayıt süresi (sn) cinsinden girilen bilgiler ve TEST BAŞLATMA/DURDURMA görsel butonu bulunmaktadır.

Tia Portal V15.1 programı ile HMI dokunmatik ekran üzerinde yapılan yazılımdan bazı örnekler Şekil 3.18'te görülmektedir.



Şekil 3.18. HMI dokunmatik ekran ve PLC üzerinde yapılan yazılımın görsel resimleri

Motor kontrol panosunun iç tasarımında; hız kontrol cihazı, PLC, ethernet switch ve güç kaynağından oluşmaktadır. Oluşturulan panonun içinde sürücü olarak 6SL3244-0BB12-1FA0 SINAMICS G120 kontrol ünitesi, S7-1200 CPU-1212C 8DI/6DO/2AI giriş ve çıkışlara sahip Siemens PLC mevcuttur.



(a)



(b)

Şekil 3.19. Kontrol panosundaki (a) Sürücü (b) PLC

Kontrol malzemelerinin pano içindeki yerleşim tasarımı Şekil 3.20’de görülüyor.



Şekil 3.20. Motor kontrol panosunun iç tasarımı

3.3. Boşta Çalışma


Tüm motorlar (0,75-1,5-2,2-4-5,5kW) farklı rotor devirlerinde (375-750-1125-1500 d/dk) yüksüz olarak çalıştırılmıştır. Motorların millerine bağlanan 1024 puls’lik enkoder ile rotor devirleri, sıcaklık sensörü ile sargı ısıları ölçülmüştür. Böylece 20 deney gerçekleştirilerek 810.000 parametre verisi ölçülmüş, hesaplanmış ve kayıt altına alınmıştır. Motorların enkoder bağlantısıyla boşta çalıştırılma deney resimleri Şekil 3.21-3.23’tedir.



Şekil 3.21. 0,75kW gücündeki motorun miline enkoder bağlantısı ve boşta çalışma deneyleri




Şekil 3.22. 2,2kW gücündeki motorun miline enkoder bağlantısı ve boşta çalışma deneyleri




Şekil 3.23. 5,5kW gücündeki motorun miline enkoder bağlantısı ve boşa çalışma deneyleri

3.4. Yükte Çalışma

Tüm motorlar (0,75-1,5-2,2-4-5,5 kW) farklı rotor devirlerinde (375-750-1125-1500 d/dk) farklı yük oranlarında (%25-%50-%75-%100) yüksüz olarak çalıştırılmıştır. Motorların millerine enkoder ile rotor devirleri, sıcaklık sensörü ile sargı ısıları ölçülmüştür. Böylece 80 deney gerçekleştirilerek 3.240.000 parametre verisi ölçülmüş, hesaplanmış ve kayıt altına alınmıştır. Motorları yüklemek için elektriksel ve mekanik olmak üzere iki yük çeşidinden faydalanılmıştır. Şekil 3.24 ve Şekil 3.25'te motorların elektriksel yük oluşturan kompunt generatörlere ve mekanik yük bağlantı şemaları görülmektedir.



Şekil 3.24. Asenkron motorun doğru akım motoru ile mekanik bağlantısı yan perspektif görüntüsü




Şekil 3.25. Asenkron motorun doğru akım motoru ile mekanik bağlantısı açısall perspektif görüntüsü

3.4.1. Elektriksel yük

Tasarlanan yüklerde elektriksel yük olarak kompunt generatörlerden faydalanılmıştır. Asenkron motorlar elektriksel olarak DC kompunt generatörler ile yüklenmiştir.

Kompunt generatörlerin elektriksel bağlantı şeması ise Şekil 3.26'da görölmektedir. Bu generatörler dışarıdan DC bir varyak ile uyarılarak endüvileri etrafıdan manyetik alan oluşturulur. Nüvenin motorlar tarafından çevirilmesi sonucu generatörlerin ürettikleri enerjinin bir yük üzerinde harcanması gerekmektedir. Böylece motor elektriksel olarak yüklenebilecektir.



Şekil 3.26. Generatör, varyak ve yükün elektriksel bağlantı şeması

Kompunt DC generatör motora kaplin yardımıyla bağlanmış ve dışarıda paralel sargılarına ayarlı Varyak ile DC enerji vererek motora yük uygulama ayarı yapılmıştır. Dinamo ayarlı bir DC Varyak ile yüklenerek motorun çektiği akıma göre motorlar %100, %75, %50 ve %25 yük oranlarında yüklenmektedir. Çalışmada kullanılan kompunt

generatör etiket verileri Çizelge 3.2’de görülmektedir.

Çizelge 3.2. Motor ve kompunt generatör etiket verileri

Teknik Özellikleri	Genr.1	Genr.2	Genr.3
Güç (kW)	1.5	1.5	2.2
Güç (Hp)	2	2	3
Gerilim (V)	200	200	220
Akım (A)	7.5	7.5	10
Mil Devri (d/dk)	3000	3000	1500

Kompunt generatörler 200 VDC ayarlı 7,5 A akıma dayanıklı ayarlı bir varyak ile beslenmektedir. Generatörün ürettiği enerji yük üzerinde harcanarak motorun yüklenmesi sağlanır. Şekil 3.27 ve 3.28’de deney düzeneğinin elektriksel bir yük altında bağlantısı görülmüyor.



Şekil 3.27. 0,75kW gücündeki motora elektriksel yükün bağlanarak oluşturulan deney düzeneği




Şekil 3.28. 2,2kW gücündeki motora elektriksel ve mekanik yükün bağlanarak oluşturulan deney düzeneği

Generatörler tam devirlerinde yüksek verimle çalışabilmektedirler. Ayrıca sargıları ısındıkça verimleri de düşmektedir. Yapılan çalışmada farklı oranlardaki rotor devirleri içeren ve uzun süreli (90 dk) deneyler olması nedeniyle birebir motor gücünü karşılayan kompunt generatörler bile 4 kW ve 5,5 kW'lık motorlarımızı %50 üzerinde yükleyemedi. Bu yüzden elektriksel yükün yanında mekanik bir yük tasarımı ile tüm deneyler gerçekleştirildi.


3.4.2. Mekanik Yük

Motorlar tüm yük oranlarında yüklenebilmesi için elektriksel yüke yardımcı bir mekaniksel yük tasarımı gerçekleştirildi. Mekaniksel yükün parçaları Şekil 3.29'da görülmektedir. Tasarlanan mekanik sistem, SOLIDWORK Simulator programı ile analizi gerçekleştirilmiştir. Böylece sistem üzerinde mekaniksel açıdan bir değişimin etkilerinin (gerilim ve gerinim), balatanın maruz kalacağı farklı aşınma bölgeleri tespiti sağlanabilmektedir. Oluşabilecek hataların önceden müdahalesi ile mekanik yükün sisteme bağlı yeterliliği ortaya konuldu.



Şekil 3.29. (a) Tasarlanan mekanik yük bileşenleri (b) Mekanik parçaların birleştirilerek rotora bağlantısı (c) Mekanik fren diskin balata sıkma ayağına bağlantısı

Simülasyon işleminde yapısal analiz gerçekleştirilmiş, yapı üzerindeki geometrik farklılık dikkate alınarak homojen bir mesh dağılımı yapılmıştır. Sistemin analizinde güvenilir sonuca ulaşma açısından küçük parçalı oluşturulan mesh yapısı Şekil 3.30'da görülmüyor.



Şekil 3.30. Mesh modeli

Analizde sıcaklık yükleri dahil edilerek, 298 Kelvin sıfır gerilim sıcaklığı olarak belirlendi. Mekanik yükün malzeme özelliği olarak, AISI1020 karbon çeliği seçilmiştir.

Mekanik özellik olarak,

Akma mukavemeti : $3,51571e^{+08}$ N/m²

Gerilme mukavemeti : $4,20507e^{+08}$ N/m²


Elastik modül : $2e^{+11}$ N/m²

Poisson oranı : 0,29

Termal genleşme katsayısı: $1,5e^{-05}$ Kelvin

olarak belirtildi.


Bu özelliklere göre analiz edilen yük modeli ve yükleme durumları Şekil 3.31’de görülmektedir.



Şekil 3.31. Yük modeli


Tasarlanan mekanik yükün maruz kalacağı maksimum kuvvet olarak, 5,5 kW’lık motoru tam yük altında 1500 d/dk rotor hızında çalıştırıldı. Böylece bu kuvvete dayanabilecek bir tasarım, tüm yük oranı ve devirlere dayanabileceği bilinmektedir. Deney sonucu elde edilen verilerden Torkun ortalaması olarak 33 Nm güç olduğu bulundu. Analiz programında bu tork oranı üzerinden yaparak mekanik yükün verdiği analiz verilerinin sonuçları değerlendirilmiştir.

Analiz sonuçlarına göre Şekil 3.32’de mekanik yük tasarımının gerilim testi sonucunda maksimum von Mises değeri $1,202e^{+08}$ N/m² gözlemlenmiştir. Sistemin Akma Mukavemeti $3,516e^{+08}$ N/m² dikkate alındığında yapının 3 katı bir oranda olduğu bu da sistemin güvenilir olduğunu göstermektedir.




Şekil 3.32. Mekanik yük stres analiz sonuçları

Şekil 3.33'te mekanik yüke kuvvetin etki alanı ve oranı, renk dağılımı ve değerleri ile görülmektedir. En çok kuvvete maruz kalan bölge kırmızı ile gösterilirken biraz daha az kuvvete maruz kalan sarı, en az kuvvetle karşılaşan bölge mavi renk ile belirlenmiştir.



Şekil 3.33. Mekanik yük yer değiştirme analiz sonuçları

Şekil 3.34'te tasarımın gerinim analize göre eşdeğer gerinim maksimum $4,996 \times 10^{-4}$ de dayanım gösterirken tasarlanan yük sistemi $9,992 \times 10^{-5}$ oranının altında mavi renk koduyla çıkmıştır. Bu tek yönlü çekme ya da baskı testlerinde uygulanan gerilim miktarına bağlı olarak malzemede oluşan ortalama gerinimin nasıl değiştiğini ve oldukça az olduğunu gösterir. Yapısal analiz değerlendirmesi sistemin mekaniksel açısından güvenilir olduğunu desteklemektedir.




Şekil 3.34. Mekanik yük gerinim analiz sonuçları

Şekil 3.35'te 220 mm çapında 60 mm kalınlığı olan bir döküm disk tasarlandı. Diskin çapı motor ebatlarına ve yapılan analiz sonucuna dayanarak kararlaştırıldı. Diskin etrafı esnek 2 mm saca perçinlemiş bir balata ile sarılmıştır. Bu balata çalışma esnasında titreşim etkisiyle diskten kurtulmaması için diskten iki tarafında 2 mm'lik dairesel saclar vidalanmıştır. Böylece motor çalışırken disk sağa-sola kayması önlenmiştir. Diski saran balatanın sıkma oranını ayarlamak için 5mm kalınlıktan oluşan bir metal ayak tasarımı gerçekleştirildi. Bu ayak motor tablasına sabitlenerek sacın ucuna monte edilen vidalarla balatanın sıkılması sağlanmaktadır.



Şekil 3.35. Asenkron motor miline bağlanan mekanik yük disk

Balata belli oranda sıkıldıktan sonra motorun yükleneceği oran kompant generatöre uygulanan DC varyak ile hassas ayarlanmaktadır. Mekanik yükün gerçek bağlantı resimleri Şekil 3.36'da verilmiştir.




Şekil 3.36. Asenkron motor miline bağlanan mekanik yük ile motorun deney setine bağlantısı

Disk çapı motor ebatlarına göre tercih edilmiştir. Diski mümkün oldukça büyük seçilmesi sürtümde yüzeyinin artırmasına böylece daha az sıkıştırma kuvvetiyle daha fazla frenleme yapılması sağlanmıştır.

Elektriksel ve mekanik yükün çeşitli motorlara bağlanarak oluşturulan deney düzeneğinin resimleri Şekil 3.37’de görülmektedir.




Şekil 3.37. 4kW ve 5,5kW’lık motorlarda elektriksel ve mekanik yükün deney düzeneği bağlantısı



Şekil 3.39. Deney SCADA bağlantı şeması.

Dokunmatik ekran kullanıcının hem dışardan deney başlangıç şartlarını yani motor etiket bilgileri (motor gücü, nominal akım, nominal gerilim, nominal rotor devri, çift kutup sayısı, Δ/Δ çalışma, stator direnci), deney çalışma süresi, parametrelerin kayıt zaman aralığı ve çalışma devir oranı bilgilerinin girilmesini sağlar. Böylece bu ekranla deney çalışma anında gerekli olan verilerin hem PLC hem de sürücüye girilmesi sağlanmış olunur. Ayrıca bu ekranda parametrelerin anlık verilerin sayısal durumlarını ve grafiklerini de takip edebilmekteyiz. Sürücü tarafından gelen parametrelerle PLC tarafından hesaplanan parametreler Excel formatında bilgisayara kaydedilmektedir.

Tasarım ve eşdeğer devre parametrelerinin hesaplanmasında kullanılan algoritma Şekil 3.40'ta görülüyor. Programa giriş değerleri olarak en başta, parametre hesapları istenen motorun etiket değerleri (güç, gerilim, akım, güç katsayısı, Δ/Δ çalışma) bilgileri sisteme dokunmatik ekran üzerinden girilmektedir. Motor etiket değerleri sürücü tarafından motor tanıma prosedüründen geçirilerek kontrol edilir. Eğer bu değerler eşit veya birbirine yakın değerde değilse veya motor stator sargı sıcaklık verisi gelmiyorsa tasarım birinci adıma geri döner ve bütün değerlerin tekrar girilmesi istenir. Eğer veriler eşitse test süresi veri kayıt hızını, motorun dönme devri (çalışma frekansını) girerek dokunmatik ekran üzerinden testi başlatabiliriz. Sürücü test başlatıldıktan sonra, enkoderden motorun dönme verisini karşılaştırarak deneyi devam ettirir veya veri gelişinde bir sorun varsa çalışmayı sonlandırır.



Şekil 3.40. Tasarım ve eşdeğer devre parametrelerinin hesaplanmasında kullanılan algoritma

Bu akış diyagramına göre, deney süresince sürücüden gelen; gerilim (U), akım (I), tork (T), güç (P), rotor devir (n), sıcaklık (Δt), kayma (s), güç faktörü (ϕ) ve frekans (f) parametreleri, plc yazılımı ile motora ait bütün eş değer devre parametreleri (R_s , R_2 , R_m , X_s , X_2 , X_m) hesaplanarak programdan elde edilir. Sürücü tarafında ölçülen ve PLC tarafından hesaplanarak elde edilen bu parametreler hem dokunmatik ekranda veri ve grafik olarak gösterilir, hem de Excel formatında bilgisayara kaydedilir.


Bütün basamaklar başarıyla tamamlanırsa, eşdeğer devre parametreleri, kayma, kayıplar ve verim gibi değerler hesaplanır. Bütün değerler uygun ise motorun işletme karakteristik eğrileri çizilir ve nominal çalışma noktaları bulunur.

3.6. Deney Anatomisi

Farklı güçteki motorun (0,75-1,5-2,2-4 ve 5,5kW) boşa ve farklı yük (%25-%50-%75 ve %100) altında farklı rotor devrinde (375-750-1125 ve 1500) deney planlaması yapıldı. Böylece endüstriyel üretim merkezlerinin her alanında kullanılan asenkron motorun çeşitli çalışma koşulları altında elektriksel parametrelerindeki değişim tespiti hedeflenmiştir.

Farklı güçteki motorlar ile deney sonuçlarının ve sonrasında elde edilen matematiksel modellemenin geçerliliği, tutarlılığı ve doğruluğu kesinleştirildi. Literatürde yapılan çalışmalar ayrı ayrı bu etken koşullara değinmiş olsalar da bu kadar

geniş çeşidi içeren koşulları bir arada ortaya konan matematiksel modelleme ortaya konulmamıştır. Ne kadar çok koşul altında farklı motor çalıştırılır ve sonucunda elde edilen veri yığınları ANN algoritmalarıyla analiz edilirse doğruluğu o kadar kesin ve geçerli matematiksel bir modelleme elde edilir. Bu amaçla planlanan deney topolojisi Şekil 3.41’de verilmiştir.



Şekil 3.41. Planlanan deney topolojisi

Deney topolojisinde KLASİK DENEYLER normal literatürde kabul gören motorların eşdeğer devre parametrelerinin tespitinde kullanılan “Stator direncin bulunması, Boşta çalışma ve Kilitli rotor” deneylerini içermektedir. SİSTEM DENEYLERİN’de ise motor boşta farklı rotor devrilerinde deney düzeneğinde yapılan deneylerdir.

Testin başında motor etiket değerleri (Nominal motor gerilimi, Nominal motor akımı, Nominal motor güç faktörü, Maksimum motor hızı ve motor kutup sayısı) ve motor stator sargı direnci SCADA sistemine girilir. Test sırasında ölçülen giriş parametrelerine (gerilim, akım, tork, güç, güç faktörü, frekans ve stator sargı sıcaklığı) göre çıkış parametre (R_s , R_2 , R_m , X_s , X_2 , X_m) değerleri hesaplanmıştır.

Parametre hesaplamalarında “Asenkron Motorlar” başlığı altında verilen formüllere ek olarak sıcaklığın ve kaymanın etkisini içeren formüllerde kullanılmıştır. Bu formüller kısaca Denklem 3.40 ile Denklem 3.57 arasında değinilmiştir;

$$R_S = 1.5 R \quad (1.2 - 1.5) \quad (3.40)$$

$$R_{Sy} = R_S [1 + \alpha(t_2 - t_1)] \quad (3.41)$$

$\alpha = 0.0039$ (bakırın sıcaklık katsayısı)

ASM kayma,

$$s = \frac{n_S - n_r}{n_S} = \frac{\omega_S - \omega_r}{\omega_S} \quad (3.42)$$

$$\omega_S = \frac{n_S \pi}{180} \quad (3.43)$$

$$n_S = \frac{120 f}{2\pi} \quad (3.44)$$

$$T_m = \frac{3}{\omega_S} \frac{R_2}{s} I_S^2 \quad (3.45)$$

$$I_S = \frac{E_f}{\sqrt{(R_S + R_2)^2 + (X_S + X_2)^2}} \quad (3.46)$$

$$R_2 = \frac{T_m \omega_S s}{3 I_S^2} \quad (3.47)$$

$$R_{2y} = \left(\frac{P_S}{3 I_S^2} - R_{Sy} \right) s = \frac{P_m s}{3(1-s) I_S^2} = \frac{T_m \omega_r s}{3(1-s) I_S^2} \quad (3.48)$$

$$R_{eq} = R_S + R_{2y} \quad (3.49)$$

$$X_{eq} = \sqrt{\frac{E_f^2}{I_S^2} - R_{eq}} \quad (3.50)$$

$$X_S = X_2 = \frac{X_{eq}}{2} \quad (3.51)$$

Yaklaşık eşdeğer devreden;

P_0 : Boştaki Güç

$$P_0 = \sum P_{fe} \quad (3.52)$$

$$\frac{P_0}{3} = \frac{E_f^2}{R_m} \Rightarrow R_m = \frac{3E_f^2}{P_0} \quad (3.53)$$

$$I_w = \frac{E_f}{R_m} \quad (3.54)$$

$$I_u = I - I_s \quad (3.55)$$

$$I_u = \sqrt{I_w^2 + I_m^2} \Rightarrow I_m = \sqrt{I_w^2 - I_u^2} \quad (3.56)$$


$$X_m = \frac{E_f}{I_m} \quad (3.57)$$

3.7. Laboratuvar Deney Sonuçları


Laboratuvar ortamında hazırlanan deney düzeneği ile planlanan 100 deney gerçekleştirilmiştir. Her bir deney sonucunda 15 giriş ve çıkış parametrelerin oluşturduğu toplamda 1500 parametre değişimi mevcuttur. Deney süresince parametrelerin değişim oranları grafiksel olarak çizdirilerek incelenmiştir.

3.7.1. Boş çalışma deney grafik sonuçları


Veri hesaplaması için yapılan yazılımın doğruluğu adına deney düzeneği (sistem) parametre sonuçları ile literatürde kabul edilen klasik deneylerin (boşta ve kilitli rotor deneyleri) parametre verileri karşılaştırıldı. Sistem ile yapılan boşta çalışma deneyler ile klasik deney (Kilitli rotor ve boşta çalışma) sonuçları Şekil 3.42-3.46'da verilmiştir. Deneyler sonucu parametre değişimlerinin grafiklerinden anlaşıldığı üzere sistem deney parametre değişimleriyle klasik deneylerdeki hesaplamalar sonucu elde edilen parametrelerin değişim oranları oldukça yakın ve uyumlu çıkmaktadır. Bu durum yapılan sistemin tutarlı çalıştığını gösterir.




Şekil 3.42. 0,75 kW Sistem ile klasik deneylerin (a) R_s parametre (b) R_2 parametre (c) R_m parametre (d) $X_s = X_2$ parametre (e) X_m parametre grafiklerin karşılaştırılması




Şekil 3.43. 1,5 kW Sistem ile klasik deneylerin (a) R_s parametre (b) R_2 parametre (c) R_m parametre (d) $X_s = X_2$ parametre (e) X_m parametre grafiklerin karşılaştırılması



Şekil 3.44. 2,2 kW Sistem ile klasik deneylerin (a) R_s parametre (b) R_2 parametre (c) R_m parametre (d) $X_s = X_2$ parametre (e) X_m parametre grafiklerin karşılaştırılması



Şekil 3.45. 4 kW Sistem ile klasik deneylerin (a) R_s parametre (b) R_2 parametre (c) R_m parametre (d) $X_s = X_2$ parametre (e) X_m parametre grafiklerin karşılaştırılması



Şekil 3.46. Sistem ile klasik deneylerin (a) R_s parametre (b) R_2 parametre (c) R_m parametre (d) $X_s = X_2$ parametre (e) X_m parametre grafiklerin karşılaştırılması

3.7.2. Yüklü çalışma deney grafik sonuçları

Tüm motorlar farklı devir (375, 750, 1125, 1500 d/dk) altında farklı yüklerdeki (%0, %25, %50, %75, %100) deneylerde PLC yazılımı üzerinden hesaplanan (R_s , R_2 , R_m , X_s , X_2 , X_m) değer ile giriş değişkenleri (Akım, Güç ve Tork), sistemden ölçülen (Akım, Güç, Tork) değerlerle bir tablo şeklinde karşılaştırılarak aralarındaki fark yüzdeleri belirlendi.


Çizelge 3.3'te görüldüğü gibi değerler arasındaki fark oldukça az çıkmaktadır. Çoğu değerlerin farkı %1'in altında olduğu ve en yüksek fark değeri %7 civarında görülmüştür. Bu farkın büyük kısmı da hesaplamalardaki yuvarlamalar arasındaki farklılıklardan kaynaklanmıştır. Bu durum yükte çalışmanın da sistemin verileriyle tutarlı ve uyumlu olduğunu gösterir.

Yapılan deneylerde parametre değişimleri görselleştirmek adına grafik halinde düzenlenmiştir. Deneyde 90 dk boyunca motor çalıştırılmıştır. Her 2 sn'de bir veri alınarak her bir parametre için 2700 veri ve bir deneyden 15 parametrenin (U , I , T , P , n , Δt , Q , f , s , R_s , R_2 , R_m , X_s , X_2 ve X_m) verisi kayıt altına alınmıştır.


Çizelge 3.3. Farklı güçlerdeki motorların farklı hız ve yük altındaki verileri

P _{mot} KW	HIZ d/dk	YÜK		ELEKTRİKSEL BÜYÜKLÜKLER										
				Ölç. Gerilim (V)	Ölç. Akım (A)	Hesp. Akım (A)	Akım (%)	Ölç. Güç (W)	Hesp. Güç (W)	Güç (%)	Ölç. Tork	Hesp. Tork	Tork (%)	
0,75	375	25	BAŞ.	105,58	1,31	1,26	3,55	68,3	70,82	3,69	1,76	1,74	1,39	
			ORT.	105,87	1,33	1,26	4,9	172,08	177	2,86	4,38	4,38	0,01	
	750	50	BAŞ.	206,35	1,33	1,33	0,2	52,11	54,55	4,68	0,66	0,66	0,05	
			ORT.	206,78	1,51	1,46	3,46	309,19	308,95	0,07	3,94	3,94	0,03	
	1125	75	BAŞ.	301,84	1,74	1,81	4,01	167,43	171,19	2,25	1,42	1,42	0,05	
			ORT.	301,99	1,69	1,68	0,92	663,98	672,46	1,28	5,64	5,64	0,04	
	1500	100	BAŞ.	109,55	1,42	1,4	1,31	31,26	32,72	4,68	0,8	0,8	0,05	
			ORT.	110,13	1,4	1,36	3,06	134,53	129,95	3,41	3,42	3,43	0,08	
	1,5	375	50	BAŞ.	107,13	2,86	2,92	2,01	100,07	102,92	2,85	2,55	2,55	0,05
				ORT.	107,53	2,83	2,78	1,59	91,61	95,34	4,07	2,33	2,33	0,02
750		25	BAŞ.	204,59	2,75	2,8	1,85	47,12	49,44	4,93	0,69	0,66	3,91	
			ORT.	204,84	2,77	2,73	1,57	46,45	48,64	4,73	0,6	0,59	0,97	
1125		100	BAŞ.	301,85	2,71	2,69	0,47	154,14	160,8	4,32	1,31	1,31	0,05	
			ORT.	301,96	2,9	2,78	4,16	767,32	791,68	3,17	6,51	6,52	0,08	
1500		75	BAŞ.	390,88	2,44	2,6	6,35	223,13	232,3	4,11	1,42	1,42	0,41	
			ORT.	399,99	2,74	2,84	3,74	736,95	734,14	0,38	4,69	4,69	0,18	
2,2		375	25	BAŞ.	101	2,62	2,66	1,54	27,2	28,53	2,46	1,75	2,09	1,62
				ORT.	106,74	3,03	3,14	3,5	550,24	590,11	7,22	5,59	5,61	0,25
	750	50	BAŞ.	200	3,89	4,12	6,01	70,93	74,28	6,89	9,8	8,51	1,52	
			ORT.	201,17	3,59	3,71	3,24	690,33	730,75	7,09	8,44	8,47	0,39	
	1125	75	BAŞ.	287	2,56	2,57	0,31	300,21	320,05	6,65	1,74	2,34	2,58	
			ORT.	298,43	4,18	4,23	1,17	730,74	730,72	0,08	11,63	11,66	0,24	
	1500	100	BAŞ.	379	5,05	5,12	1,41	750,49	790,22	5,26	19,5	20,7	5,8	
			ORT.	379,67	4,9	4,96	1,19	820,21	830,96	0,79	19,42	19,46	0,2	
	4	375	75	BAŞ.	106,5	6,5	6,17	5,09	36,09	35,97	0,33	2,28	2,29	0,33
				ORT.	107,04	6,34	6,64	4,67	174,43	176,73	1,32	4,44	4,49	1,3
750		100	BAŞ.	204,16	5,89	5,77	2,04	435,6	439,87	0,98	7,06	7,13	0,97	
			ORT.	204,46	5,77	5,52	4,42	431,74	437,49	1,33	5,43	5,51	1,31	
1125		25	BAŞ.	302,45	5,52	5,78	4,72	207,88	205,74	1,03	1,76	1,78	1,02	
			ORT.	302,54	5,65	5,6	0,79	159,02	159,88	0,54	1,32	1,32	0,54	
1500		50	BAŞ.	380,92	4,56	4,69	2,88	106,78	105,3	1,39	2,11	2,14	1,37	
			ORT.	383,91	4,82	4,93	2,3	1047,55	1047,73	0,58	6,7	6,74	0,58	
5,5		375	100	BAŞ.	382,41	5,05	5,21	3,21	134,05	138,76	3,51	0,85	0,88	3,39
				ORT.	383,9	5,19	5,18	0,25	214,89	210,57	2,01	1,37	1,4	1,97
	750	75	BAŞ.	302,25	6,31	6,16	2,39	252,99	241,36	4,6	2,1	2,19	4,4	
			ORT.	302,26	5,95	5,82	2,07	151,2	153,16	1,3	1,28	1,29	1,28	
	1125	50	BAŞ.	203,83	6,11	6,12	0,08	118,95	118,19	0,64	0,83	0,84	0,64	
			ORT.	204,01	6,17	6,14	0,52	92,33	96,1	4,09	1,19	1,24	3,93	
	1500	25	BAŞ.	104,72	6,46	6,5	0,58	55,17	56,86	3,06	1,4	1,45	2,97	
			ORT.	105	6,69	6,44	3,68	46,89	45,97	1,97	1,18	1,21	1,93	


Düzenlenen bu grafiklerde bazı parametrelerdeki salınım daha net anlaşılması için hareketli ortalama yöntemiyle 60 veride bir ortalama olarak grafik oluşturulmuştur. Motorlarda devir ayarı gerilim ve frekans ayarlanarak sürücü üzerinden gerçekleştirilmiştir. Farklı yük altında çalışmaları ise nominal çektikleri akım oranlanarak şebekeden akım çekmeleri sağlanmıştır.




Şekil 3.47. 0,75 kW Motorun 375 d/dk devirde yüksüz ve tüm yüklerde parametrelerin değişimi



Şekil 3.48. 0,75 kW Motorun 750 d/dk devirde yüksüz ve tüm yüklerde parametrelerin değişimi




Şekil 3.49. 0,75 kW Motorun 1125 d/dk devirde yüksüz ve tüm yüklerde parametrelerin değişimi




Şekil 3.50. 0,75 kW Motorun 1500 d/dk devirde yüksüz ve tüm yüklerde parametrelerin değişimi


Bu deney grubunda 0,75 kW motor 375-750-1125 ve 1500 devirde çalıştırılmıştır. Her devirde %0 (1,3A) - %25 (1,45A) - %50 (1,6A) - %75 (1,75A) - %100 (1,9A) yüklenerek sıcaklık, devir ve yük ile parametrelerin değişimi gözlemlenmiştir. R_s , R_2 ve s parametreleri sıcaklıkla beraber artış göstermektedir. R_s yük arttıkça daha fazla değer göstermiştir. R_2 parametresi devir düştükçe ve yük arttıkça daha yüksek değerler göstermiştir. R_m , X_m , $X_s=X_2$ parametreleri salınım göstermektedir. R_m parametresi yük ve salınımı düşmektedir. X_m parametresi yük arttıkça değeri düşerken devir arttıkça değeri yükselmiştir. $X_s=X_2$ parametresi devir arttıkça değeri yükselmiştir.




Şekil 3.51. 1,5 kW Motorun 375 d/dk devirde yüksüz ve tüm yüklerde parametrelerin değişimi



Şekil 3.52. 1,5 kW Motorun 750 d/dk devirde yüksüz ve tüm yüklerde parametrelerin değişimi



Şekil 3.53. 1,5 kW Motorun 1125 d/dk devirde yüksüz ve tüm yüklerde parametrelerin değişimi




Şekil 3.54. 1,5 kW Motorun 1500 d/dk devirde yüksüz ve tüm yüklerde parametrelerin değişimi


Bu deney grubunda 1,5 kW motor 375-750-1125 ve 1500 devirde çalıştırılmıştır. Her bir devirde %0 (2,5A)- %25 (2,75A) - %50 (3A) - %75 (3,25A) - %100 (3,5A) yüklenerek sıcaklık, devir ve yük ile parametrelerin değişimi gözlemlenmiştir. R_s ve R_2 parametreleri sıcaklıkla beraber artış göstermektedir. R_s 'nin yük arttıkça daha fazla değer göstermiştir. R_2 parametresi devir düştükçe ve yük arttıkça daha yüksek değerler göstermiştir. R_m , X_m , $X_s=X_2$ parametreleri salınım göstermektedir. R_m , X_m , $X_s=X_2$ parametreleri yük arttıkça değeri ve salınımı düşerken devir arttıkça değeri yükselmiştir.




Şekil 3.55. 2,2 kW Motorun 375 d/dk devirde yüksüz ve tüm yüklerde parametrelerin değişimi



Şekil 3.56. 2,2 kW Motorun 750 d/dk devirde yüksüz ve tüm yüklerde parametrelerin değişimi




Şekil 3.57. 2,2 kW Motorun 1125 d/dk devirde yüksüz ve tüm yüklerde parametrelerin değişimi




Şekil 3.58. 2,2 kW Motorun 1500 d/dk devirde yüksüz ve tüm yüklerde parametrelerin değişimi


Bu deney grubunda 2,2 kW motor 375-750-1125 ve 1500 devirde çalıştırılmıştır. Her bir devirde %0 (2,8A)-%25 (3,3A)-%50 (3,8A)-%75 (4,3A)-%100 (4,8A) yüklenerek sıcaklık, devir ve yük ile parametrelerin değişimi gözlemlenmiştir. R_s ve R_2 parametreleri sıcaklıkla beraber artış göstermektedir. R_s 'nin değeri devir arttıkça azalırken, yük arttıkça daha fazla değer göstermiştir. R_2 parametresi devir düştükçe ve yük arttıkça daha yüksek değerler göstermiştir. R_m , X_m , $X_s = X_2$ parametreleri salınım göstermektedir. R_m değeri yük arttıkça salınım artıyor kararsızlık artıyor. X_m , $X_s = X_2$ parametreleri yük ve devir arttıkça değeri yükselmiştir.




Şekil 3.59. 4 kW Motorun 375 d/dk devirde yüksüz ve tüm yüklerde parametrelerin değişimi



Şekil 3.60. 4 kW Motorun 750 d/dk devirde yüksüz ve tüm yüklerde parametrelerin değişimi




Şekil 3.61. 4 kW Motorun 1125 d/dk devirde yüksüz ve tüm yüklerde parametrelerin değişimi




Şekil 3.62. 4 kW Motorun 1500 d/dk devirde yüksüz ve tüm yüklerde parametrelerin değişimi


Bu deney grubunda 4 kW motor 375-750-1125 ve 1500 devirde çalıştırılmıştır. Her bir devirde %0(5A)-%25 (5,8A)-%50(6,6A)-%75(7,4A)-%100(8,2A) yüklenerek sıcaklık, devir ve yük ile parametrelerin değişimi gözlemlenmiştir. R_s ve R_2 parametreleri sıcaklıkla beraber artış göstermektedir. R_s 'nin değeri yük arttıkça daha fazla değer göstermiştir. R_2 parametresi devir ve yük arttıkça daha yüksek değerler göstermiştir. R_m , X_m , $X_s=X_2$ parametreleri salınım göstermektedir. $X_s=X_2$ parametreleri yük arttıkça ve devir arttıkça değeri yükselmiştir. R_m , X_m devir arttıkça salınım azalmıştır, değerleri artmıştır.




Şekil 3.63. 5,5 kW Motorun 375 d/dk devirde yüksüz ve tüm yüklerde parametrelerin değişimi



Şekil 3.64. 5,5 kW Motorun 750 d/dk devirde yüksüz ve tüm yüklerde parametrelerin değişimi



Şekil 3.65. 5,5 kW Motorun 1125 d/dk devirde yüksüz ve tüm yüklerde parametrelerin değişimi




Şekil 3.66. 5,5 kW Motorun 1500 d/dk devirde yüksüz ve tüm yüklerde parametrelerin değişimi

Bu deney grubunda 5,5 kW motor 375-750-1125 ve 1500 devirde çalıştırılmıştır. Her bir devirde %0(5,8A)-%25(7,05A)-%50(8,30A)-%75(9,55A)-%100(10,8A) yüklenerek sıcaklık, devir ve yük ile parametrelerin değişimi gözlemlenmiştir. R_s ve R_2 parametreleri sıcaklıkla beraber artış göstermektedir. R_s 'nin değeri yük arttıkça daha fazla değer göstermiştir. R_2 parametresi devir ve yük arttıkça daha yüksek değerler göstermiştir. R_m , X_m , $X_s=X_2$ parametreleri salınım göstermektedir. X_m ve $X_s=X_2$ parametreleri devir ve yük arttıkça değer artmıştır, ayrıca devirle salınım da artmıştır. R_m parametreleri yük ve devir arttıkça değer ve salınım artmıştır.


Yapılan deneylerde tüm motorların her bir parametresi kendi içerisinde değerlendirildiğinde aynı karakteristik özellik sergilediği gözlemlenmiştir. Parametrelerden R_s ve R_2 parametreleri sıcaklıkla beraber artış göstermektedir. Her iki parametre devir yükseldiğinde ve devirlerdeki motor yükü arttıkça daha fazla değer göstermiştir. Bu durum motorlarda devir ve yük arttıkça şebeken çekilen akımın artması; böylece akımın, motor sargı sıcaklıkları üzerindeki etkisinin de artmasından kaynaklandığı düşünülmektedir.

Sıcaklık artışı sargı dirençlerinde artışa bu durumda motorlarda bobin dirençlerinin ve kayıplarında artışına neden olmaktadır. R_m , X_m , X_s , X_2 parametreleri salınım göstermektedir. Bu parametreler yüksüzken daha fazla salınım ve değer oynaması görülürken motorun yükü arttıkça salınım oranlarında ve parametre değerlerinde bariz düşüklük olmuştur. Ayrıca motor devirlerinde artışın bu parametreler üzerinde çok etkisi olduğunu gözlemlendi. Motor devrinin etkisi X_s , X_2 parametreleri üzerinde görülmüştür. Devir arttıkça sargılardaki endüktif reaktans değerlerinde de artış gözlemlenmektedir. Bu duruma hem devirle beraber artan frekansın hem de sargı sıcaklık artışının sargı endüktif reaktans değerlerinde ve motor kayıplarında artışa neden olmuştur. Kaymanın da parametreler üzerinde etkisi olduğu bilinmesine rağmen grafiklerde net görülememektedir. Kaymanın etkinliği Bölüm 3'teki analizlerde daha net ortaya konulmuştur.


Her parametrede sıcaklığa, motor devrine ve yüke bağlı olarak değişimler gözlemlendi. Bu değişim oranları parametreden parametreye ve deney koşullarına göre farklılık göstermektedir. Yüke göre parametre değişim oranlarındaki % farklılıklar grafiklerde daha ayrıntılı incelenecek olursa;




(a)



(b)




(c)




(d)


Şekil 3.67. 0,75 kW Motorun farklı devirlerde yük 'e göre R_s , R_2 , X_s , X_2 parametre değişimi (a) 375 d/dk grafiği (b) 750 d/dk grafiği (c) 1125 d/dk grafiği (d) 1500 d/dk grafiği




(a)



(b)




(c)




(d)


Şekil 3.68. 1,5 kW Motorun farklı devirlerde yük 'e göre R_s , R_2 , X_s , X_2 parametre değişimi (a) 375 d/dk grafiği (b) 750 d/dk grafiği (c) 1125 d/dk grafiği (d) 1500 d/dk grafiği




(a)



(b)




(c)




(d)


Şekil 3.69. 2,2 kW Motorun farklı devirlerde yük 'e göre R_s , R_2 , X_s , X_2 parametre değişimi (a) 375 d/dk grafiği (b) 750 d/dk grafiği (c) 1125 d/dk grafiği (d) 1500 d/dk grafiği




(a)



(b)




(c)



(d)


Şekil 3.70. 4 kW Motorun farklı devirlerde yük 'e göre R_s , R_2 , X_s , X_2 parametre değişimi (a) 375 d/dk grafiği (b) 750 d/dk grafiği (c) 1125 d/dk grafiği (d) 1500 d/dk grafiği




Şekil 3.71. 5,5 kW Motorun farklı devirlerde yük 'e göre R_s , R_2 , X_s , X_2 parametre değişimi (a) 375 d/dk grafiği (b) 750 d/dk grafiği (c) 1125 d/dk grafiği (d) 1500 d/dk grafiği

Tüm motorların devir ve yükle %'lik değişim oranlarına bakıldığında R_s , R_2 , X_s , X_2 parametrelerinin devir arttıkça %'lik değişimlerinde de artış gözlemlenmiştir. Bobin dirençlerinde (R_s , R_2) daha fazla ve birbirleriyle uyumlu değişim görülürken endüktif reaktanslarda (X_s , X_2) daha az değişim oranı görüldü.


Tüm motorların yükle %'lik değişim oranlarında paralel kolu temsil eden parametreleri grafiklerle daha ayrıntılı incelenecek olursa;




(a)



(b)




(c)




(d)


Şekil 3.72. 0,75 kW Motorun farklı devirlerde yük 'e göre R_m , X_m parametre değişimi (a) 375 d/dk grafiği (b) 750 d/dk grafiği (c) 1125 d/dk grafiği (d) 1500 d/dk grafiği




(a)



(b)




(c)




(d)


Şekil 3.73. 1,5 kW Motorun farklı devirlerde yük 'e göre R_m , X_m parametre değişimi (a) 375 d/dk grafiği (b) 750 d/dk grafiği (c) 1125 d/dk grafiği (d) 1500 d/dk grafiği




(a)



(b)




(c)




(d)


Şekil 3.74. 2,2 kW Motorun farklı devirlerde yük 'e göre R_m , X_m parametre değişimi (a) 375 d/dk grafiği (b) 750 d/dk grafiği (c) 1125 d/dk grafiği (d) 1500 d/dk grafiği




(a)



(b)




(c)



(d)

Şekil 3.75. 4 kW Motorun farklı devirlerde yük 'e göre R_m , X_m parametre değişimi (a) 375 d/dk grafiği (b) 750 d/dk grafiği (c) 1125 d/dk grafiği (d) 1500 d/dk grafiği



Şekil 3.76. 5,5 kW Motorun farklı devirlerde yük 'e göre R_m, X_m parametre değişimi (a) 375 d/dk grafiği (b) 750 d/dk grafiği (c) 1125 d/dk grafiği (d) 1500 d/dk grafiği


Tüm motorların yükle %'lik değişim oranlarına bakıldığında paralel kolu temsil eden parametrelerin salınım gösterdiği görülmektedir.

R_m parametresinin yükle beraber %'lik değişim oranları gözlemlenmiştir. Yük arttıkça motordaki demir kaybını temsil eden R_m parametresinin salınımı azalmakta ve değişim %'de oranı da düşmektedir. Düşük devirlerde mıknatıslanma reaktansı X_m parametresi yükten daha fazla etkilendiği görülmüştür. Deneyin başlangıç ve bitiş verilerindeki değişim %'leri, düşük yüklerde (%25-%50) daha fazlayken, yüksek yüklerde (%75-%100) değişim oranı azalmıştır. Tüm motorların yükle %'lik değişim oranlarına bakıldığında R_s, R₂, X_s, X₂ parametrelerinin yük arttıkça %'lik değişimlerin de artış gözlemlenmiştir. Düşük yük oranlarında (%25-%50) 0,75kW-1,5kW ve 2,2kW'lık motorların R_s, R₂ parametreleri başlangıç ve bitiş değerlerinde daha fazla değişim göstermiştir. Yüksek yük oranlarında (%75-%100) motor gücü arttıkça parametre değişim oranlarında düzenli artış görülmektedir. Bobin dirençlerinde (R_s, R₂) daha fazla ve birbirleriyle uyumlu değişim görülürken, endüktif reaktanslarda (X_s, X₂) daha az değişim oranı görüldü. Motorların yükle beraber sargı sıcaklıklarındaki değişim aralığının artması parametrelerdeki değişiminde artmasına neden olmuştur.


Tüm motorların aynı yük altındaki parametre yüzdelik değişimleri grafiksel olarak;




Şekil 3.77. 375 d/dk farklı yük oranlarının tüm motorlara göre R_s , R_2 , X_s , X_2 parametre değişimi (a) %0 yük grafiği (b) %25 yük grafiği (c) %50 yük grafiği (d) %75 yük grafiği (e) %100 yük grafiği




(a)




(b)



(c)



(d)



(e)

Şekil 3.78. 750 d/dk farklı yük oranlarının tüm motorlara göre R_s , R_2 , X_s , X_2 parametre değişimi (a) %0 yük grafiği (b) %25 yük grafiği (c) %50 yük grafiği (d) %75 yük grafiği (e) %100 yük grafiği



Şekil 3.79. 1125 d/dk farklı yük oranlarının tüm motorlara göre R_s , R_2 , X_s , X_2 parametre değişimi (a) %0 yük grafiği (b) %25 yük grafiği (c) %50 yük grafiği (d) %75 yük grafiği (e) %100 yük grafiği




Şekil 3.80. 1500 d/dk farklı yük oranlarının tüm motorlara göre R_s , R_2 , X_s , X_2 parametre değişimi (a) %0 yük grafiği (b) %25 yük grafiği (c) %50 yük grafiği (d) %75 yük grafiği (e) %100 yük grafiği


Tüm motorların yükle %'lik değişim oranlarında R_s , R_2 , X_s , X_2 parametreleri yük arttıkça %'lik değişimleri artmaktadır. Düşük yüklerde (%25-%50) 0,75kW-1,5kW ve 2,2kW'lık motorların R_s , R_2 parametreleri başlangıç ve bitiş değerlerinde daha fazla değişim göstermiştir. Yüksek yüklerde (%75-%100) motor gücü arttıkça R_s , R_2 parametreleri başlangıç ve bitiş değerlerinin değişim oranlarında artış görülmektedir. Bu

durum motorların nominal akım ve gerilimdeki çalışma koşuluna göre tasarlandıkları için yük ve devir arttıkça parametreler değişim oranlarının da daha düzenli olduğunu göstermektedir.


Tüm motorların yükle %'lik değişim oranlarında paralel kolu temsil eden parametreleri grafiklerle daha ayrıntılı incelenecek olursa;




Şekil 3.81. 375 d/dk farklı yük oranlarının tüm motorlara göre R_m , X_m parametre değişimi (a) %0 yük grafiği (b) %25 yük grafiği (c) %50 yük grafiği (d) %75 yük grafiği (e) %100 yük grafiği




(a)




(b)



(c)




(d)



(e)

Şekil 3.82. 750 d/dk farklı yük oranlarının tüm motorlara göre R_m , X_m parametre değişimi (a) %0 yük grafiği (b) %25 yük grafiği (c) %50 yük grafiği (d) %75 yük grafiği (e) %100 yük grafiği



Şekil 3.83. 1125 d/dk farklı yük oranlarının tüm motorlara göre R_m , X_m parametre değişimi (a) %0 yük grafiği (b) %25 yük grafiği (c) %50 yük grafiği (d) %75 yük grafiği (e) %100 yük grafiği



Şekil 3.84. 1500 d/dk farklı yük oranlarının tüm motorlara göre R_m , X_m parametre değişimi (a) %0 yük grafiği (b) %25 yük grafiği (c) %50 yük grafiği (d) %75 yük grafiği (e) %100 yük grafiği

Tüm motorların yükle %'lik değişim oranlarına bakıldığında paralel kolu temsil eden parametrelerin salınım gösterdiği görülmektedir.

R_m parametresi yüksüzken salınımı fazla olmaktadır. Yük arttıkça motordaki demir kaybını temsil eden R_m parametresinin salınımı azalmakta ve değişim %'de düşmektedir.


Düşük devirlerde mıknatıslanma reaktansı X_m parametresi yükten daha fazla etkilendiği görülmüştür. X_m parametresi tüm devirlerin %75 yüklerinde R_m parametresine uyumlu değişim göstermiştir.

3.8. Taguchi Metodu

Ürünlerin tasarlanması, üretilmesi ve satılması için gereken sürenin azaltılması ürünlerde üretim, işletme, müşteriye karşı sorumluluk maliyetlerinin azaltılmasına neden olmaktadır. Sonuç olarak, tasarım aşamasında önceden ARGE yapılarak harcanan zaman, çaba ve kaynaklar, ürünün ömrü boyunca genel maliyetinde tasarrufu sağlar. Fakat her ürün ve süreçlerinde farklı etkenlerden dolayı değişkenlikler mevcuttur. Japon bilim adamı Genichi Taguchi, bu değişkenliği göz önünde bulundurarak bahsedilen maliyetleri azaltmak için çevrim dışı bir kalite iyileştirme metodolojisi ortaya koymuştur.

Ürün ve hizmetlere ilişkin arzu edilen kalite özelliklerinde değişiklik, izlenebilen ve belirli seviyelere ayarlanabilen kontrol edilebilir faktörlerin seviyeleri ile seviyeleri ölçülse bile kontrol edilemeyen veya gürültü faktörlerinin seviyelerindeki ayarlar nedeniyle ortaya çıkmaktadır.

Taguchi yöntemi, gürültü faktörlerine nispeten duyarsız olan sağlam bir ürün/süreç üretecek kontrol edilebilir faktörlerin ayarlarını belirlemeyi amaçlamaktadır (Taguchi ve Wu, 1979; Taguchi, 1986; Taguchi ve diğ., 2000). Sinyal-gürültü (S/N) oranları olarak tanımlanan belirli performans ölçütlerini maksimize ederek bu amaçla ulaşır. Bu tür S/N oranlarının işlevsel formülasyonu, seçilen kalite özelliğinin niteliğine göre belirlenir. Bu özellik “küçük daha iyidir, büyük daha iyidir veya hedef en iyidir” olmak üzere üç türden biri olabilir. Taguchi'nin yaklaşımı, yalnızca S/N oranını en üst düzeye çıkarmakla kalmayıp, aynı zamanda kalite karakteristiğinin ortalama yanıtını uygun olduğunda hedef değere yakın hale getiren kontrol edilebilir faktörlerin en iyi ayarlarını bulmaya çalışır (Nair, 1992). Taguchi, kalite karakteristiğinin istenen normdan sapmasının ek maliyet veya kalite kaybına yol açacağını varsayar. Bu nedenle kalite özelliğinin niteliğine bağlı olarak, uygun kalite kaybı fonksiyonları oluşturulur ve bunlar daha sonra sinyal-gürültü oranları gibi performans ölçütlerini tanımlamak için kullanılır.



Şekil 3.85. Eski ve yeni kayıp fonksiyonu ölçümlerinin karşılaştırılması (Mitra, 2016)

Analiz için veri toplamak ve optimum faktör seviyelerini belirlemek amacıyla gözlem tasarımında deneyin maliyeti göz önünde bulundurulur. Kontrol edilebilir faktörlerin seviyeleri, etkilerin bağımsız olarak tahmin edilmesini elde eden ortogonal diziler temelinde seçilir. Kontrol edilemeyen ya da gürültü faktörlerinin seviyeleri de ortogonal diziler temelinde seçilerek seçilen kontrol edilebilir faktörlerin her bir ayarı için tekrarlamaya rolü görür. Doğrulama çalışmaları tipik olarak analizlerden sonra gerçek çalışma koşulları altında kontrol edilebilir faktörlerin seçilen optimum seviyelerini doğrulamak için gerçekleştirilir.

3.8.1. Taguchi felsefesi


Kalitenin tanımı ürünün teknik şartnamesine uygunluğu ile ilgilidir. Bu bağlamda, kalite karakteristiği tanımlanan teknik şartlar dahilinde olduğu sürece herhangi bir kayıp söz konusu değildir (Nair, 1992). Şekil 3.85'te, müşteri hedef değeri ve iki taraflı alt teknik şart limiti (LSL) ile üst teknik şart limiti (USL), yalnızca karakteristik sırasıyla ilgili spesifikasyon limitinin altında veya üstünde olduğunda bir kayıp (L_0) gerçekleştirilmiştir. LSL'nin hemen üstünde ürünün kalite kaybı sıfırken, LSL'nin hemen altında L_0 bir kayıp olur. Kaybın bu adım fonksiyonunu gerekçelendirmek zordur (Mitra, 2016). Taguchi'ye göre kalite bir ürünün üretimden çıkarak müşteriye sevk edildiği andan itibaren topluma verdiği kayıp olarak tarif edersek, kalite karakteristiği hedef değerden her saptığında ekonomik bir kayıp olduğu görülecektir. Şekil 3.85'te L_1 olarak gösterilen bu kayıp

fonksiyonun özelliği hedeften sapma ile doğrusal olmayan (karesel) bir ilişki içinde olmasıdır. Kayıplar, müşteri şikâyet yönetimi, garanti ve diğer maddi maliyetlerin yanında kaybedilen fırsatlar ve maddi olmayan zararlardan kaynaklanabilir. Hedeften en ufak sapma bile sistemde sürekli iyileştirme ortamı oluşturarak kayba neden olacaktır.


3.8.2. Dayanıklı tasarım

Taguchi yönteminin temelini kontrol edilemeyen ve gürültü parametrelerine dayanıklı ve etkilenmeyen bir ürün veya süreç tasarımı oluşturmaktadır. Ürünün tasarımında veya geliştirilmesinde gürültü faktörlerinin seviyeleri kontrol edilebilse de ürünün kullanımı sırasında kontrol edilemezler. Ürüne göre değişen çevresel etkilerin oluşturduğu (ASM'lerde yük, sıcaklık, kayma vb.) bu gürültü faktörlerinin etkileri tamamen ortadan kaldırılamaz. Bu yüzden dayanıklı ve iyi bir tasarım için, kontrol faktörlerin veya parametrelerin ayarlarını, motorlar için istenen kalite karakteristiğindeki değişimi en aza indirecek şekilde belirlenmesine bağlıdır. Gürültü faktörlerin etkilerinin azaltarak, kontrol edilebilir faktörlerin seviyelerini hedeflenen değere yakın bir kalite karakteristiği seçilmesiyle dayanıklı bir tasarım elde edilir. Yani istenen bir hedef değer etrafında yanıt değişkeninde en az varyasyonu veren kontrol parametresi değerlerinin bir kombinasyonunu bulmak dayanıklı bir tasarımın kavramını oluşturmaktadır.

Şekil 3.86 ve 3.87 bu kavramı göstermektedir. Bir asenkron motor eşdeğer devre parametre (ASMECP) tahmininde parametrelerin yanıt değişkeni (Y) ve bir kontrol parametresinin de motor sargı sıcaklık değeri (Δt) olduğunu varsayalım. Ayrıca, bir gürültü faktörü de motor milindeki yük (T_y) olabilir. İstenen hedef ECP değeri (Y_0) olarak gösterilmektedir. Sıcaklık değerini t_0 olarak ayarlarsak, bu istenen hedefe ulaşabileceğimizi, ancak pratikte ECP değerindeki değişikliklerden kaynaklanan değer değişkenliğinin oldukça yüksek olacağı unutulmamalıdır. Öte yandan, sıcaklık değeri t_1 'de tutulursa, bu değer etrafında sıcaklık değerinde değişiklikler olsa bile, ECP değerindeki değişkenlik minimum olacaktır. Ancak, ortalama ECP değeri (Y_1) istenen Y_0 hedefinden oldukça uzak olacaktır. Bu nedenle, kontrol parametrelerinin optimum seviyelerini belirlemek için iki adımlı bir prosedür gerekebilir. İlk adımda, Y'deki değişkenliği en aza indirmek için sıcaklık seviyesini t_1 'de olacak şekilde seçilir. Ardından ECP değeri üzerinde doğrusal bir etkiye sahip olacak ancak ECP değerinin değişkenliği üzerinde minimum bir etkiye sahip olacak bir kontrol parametresi bulunması gerekir.



Şekil 3.86. Taguchi yönteminde dayanıklı tasarım (Mitra, 2016)




Şekil 3.87. Taguchi yönteminde ayar parametresi (Mitra, 2016)

Frekansın (F) böyle bir faktör olduğunu ve ECP üzerindeki etkisinin Şekil 3.87'de gösterildiğini varsayalım. Motorlarda değişken frekanslarda çalıştırıldığında, ECP'nin frekans sayısıyla böyle bir ilişkiye sahip olması oldukça mümkündür. Böyle bir parametre ayar parametresi olarak bilinir. Bir frekans f_0 seçerek, istenen bir Y_0 hedefine ulaşılabilir. Böylece, dayanıklı tasarım prosedüründe yanıt değişkenindeki değişkenliği azaltabilir ve istenen bir hedef değere ulaşması sağlanabilir.

3.8.3. Taguchi metodolojisi

Taguchi, kontrol parametrelerinin ayarlarını ve tolerans aralıklarını belirlemek için üç aşamalı bir tasarım sürecini savunmaktadır (Nair, 1992; Byrne ve Taguchi, 1987; Kackar, 1985). İlk aşama sistem tasarımı olarak bilinir. Bu aşamada, bilimsel ve mühendislik ilkeleri ve önceki deneyimler, ürünün istenen hedeflere ulaşmak için ürün özelliklerini, süreç özelliklerini veya teknik parametreleri seçmek için kullanılır. Kontrol parametreleri, istenen hedeflere ulaşmak için gösterdikleri kabiliyetlerine göre seçilir. Örneğin, amaç bir ASM enerji tüketimini en aza indirmekse veya verimini artırmaksa, belirli ayarlara sahip uygun bir sıcaklık, yük kontrol sistemi dahil edilebilir. İkinci aşama parametre tasarımı olarak bilinir. Bu Şekil 3.86 ve 3.87’de açıklandığı gibi, yanıt değişkeninin değişkenliğini azaltarak uygun olduğunda hedef yanıt seviyesine ulaşacak kontrol parametrelerinin optimum ayarlarının belirlenmesini içerir. Taguchi ise hem yanıt değişkenindeki varyasyonu hem de istenen hedef değerini dikkate alan uygun bir S/N oranının formüle edilmesini önerir. S/N oranları için ifadeler, yanıt değişkeninin biçimine bağlı olarak daha küçük daha iyidir, daha büyük daha iyidir veya hedef en iyidir olarak belirlenir (Phadke, 1989). S/N oranları için ifadelerde, sinyal (S) sırasıyla ortalamanın karesini veya istenen hedefi temsil ederken, gürültü (N) yanıt değişkenindeki varyansı temsil eder. Bu oranlar, kalite karakteristiği türündeki tüm durumlar için S/N oranının maksimize edilecek şekilde oluşturulur. Şekil 3.88 parametre tasarımının iki aşamalı prosedürünü görmekteyiz. İlk aşamada, S/N oranını maksimize eden a ve b seviyeleri arasında tutabilen optimum parametre seviyeleri bulunur. İkinci aşamada, yanıt değişkenliği üzerinde çok az etkisi olan ayar kontrol parametreleri belirlenerek, ortalama yanıtın uygun şekilde hedef veya arzu edilen bir seviyede olmasına sağlayacak optimum seviyeleri seçilir.

Tolerans aralık belirlemenin üçüncü aşaması, eğer ikinci aşamada elde edilen yanıt değişkenindeki performans ölçüsü yeterli değilse kullanılır. Çok sınırlı tolerans aralıkları üretimde teknolojik kaliteli malzeme kullanımı gerektireceğinden maliyetleri artıracaktır. Çok geniş toleranslar ise işlevsel performansı etkileyecek ve dolayısıyla enerji, verim ve kalite kayıplarına neden olarak müşteri kayıplarını artıracaktır. Bu iki önemli etkiyi göz önünde bulundurarak denge bulmayı ve kontrol parametrelerinde kabul edilebilir bir varyasyon aralığı belirleyerek bir Tolerans tasarımı gerçekleştirilme amaçlanır.



Şekil 3.88. Bir parametre ayarının sinyal-gürültü oranı ve yanıt değişkeninin ortalaması üzerindeki etkisi (Mitra, 2016)

3.8.4. Kayıp fonksiyonları

Bir kayıp fonksiyonu tanımlanırken, seçilen kalite karakteristiğinin türü fonksiyonel formu etkiler. Üç tür kalite özelliği veya yanıt değişkeni vardır: uzunluk ya da çap gibi bir ürün veya parçasının boyutunu ifade edebileceğimiz hedef-en iyisidir, enerji tüketimi, rulman aşınması gibi özellikleri ifade edebileceğimiz daha küçük-daha iyidir veya bir ürünün dayanımı, dayanıklılığı ya da bir ürünün müşteri tarafından beğenilme oranı daha büyük-daha iyidir.

Hedef En İyisidir

Bu kayıp, kalite özelliğinin hedef değerde olmamasından kaynaklanan memnuniyetsizlikle birlikte, tüketicinin ürünü tamir etme veya değiştirme maliyetini temsil eder. Kayıp fonksiyonu:

$$L(y) = k(y - m)^2 = \frac{A}{\Delta^2}(y - m)^2 \quad (3.58)$$

Yukarıdaki denklemde k bir orantı sabiti, y kalite özelliğinin değeri, m hedef değer ve $m \pm$ kalite özelliğinin tolerans aralığıdır. Kalite özelliği fonksiyonel toleransın sınırında iken tüketicinin ortalama kaybı A olarak tanımlanırken, kalite karakteristiği Y 'nin dağılımı biliniyorsa, birçok ürünlerdeki ortalama kaybı temsil eden beklenen kayıp:

$$\begin{aligned}
E[L(y)] &= E[k(y-m)^2] \\
&= k[Var(y) + (\mu - m)^2] \\
&= k[MSD]
\end{aligned} \tag{3.59}$$

Burada μ ve $Var(y)$ sırasıyla y 'nin ortalaması ve varyansı, MSD ise y 'nin ortalama karesel sapmasıdır. MSD şu şekilde verilir. Gözlem sayısı n olarak belirtilir.

$$MSD = \sum_{i=1}^n \frac{(y_i - m)^2}{n} \tag{3.60}$$

Daha küçük daha iyidir

Bu kalite özelliklerinde hedef değer sıfırdır ve kayıp fonksiyonu:

$$L(y) = ky^2 = \frac{A}{\Delta^2} y^2 \tag{3.61}$$

Burada Δ kalite karakteristiğinin sıfırdan sapma toleransı, A ise bu sapmayla ilişkili kayıptır. Beklenen kayıp:

$$E[L(y)] = \frac{A}{\Delta^2} [Var(y) + \mu^2] = \frac{A}{\Delta^2} [MSD] \tag{3.62}$$

MSD şu şekilde verilir.

$$MSD = \frac{\left(\sum_{i=1}^n y_i^2\right)}{n} \tag{3.63}$$

Daha büyük daha iyidir

Kalite karakteristiğinin büyük değerleri istenen bu türde kayıp fonksiyonu:

$$L(y) = k \frac{1}{y^2} = \frac{A\Delta^2}{y^2} \quad (3.64)$$

Burada Δ müşterinin tolerans seviyesi ve A kalite karakteristiğinin bu seviyesindeki ilişkili kayıptır. Beklenen kayıp:

$$E[L(y)] = A\Delta^2 E\left(\frac{1}{y^2}\right) \quad (3.65)$$

Yanıt değişkeninin n gözlem sayısından:

$$\left(\sum_{i=1}^n 1/y_i^2\right)/n \quad (3.66)$$

$E(1/y^2)$ değeri bulunabilir.

3.8.5. Performans ölçütleri ve sinyal-gürültü oranları

Tasarımı analiz edebilmek için performans ölçüsüne bakmak gerekir. Performans ölçüsü de kalite karakteristiğinin ortalama değeri (istenen) ve değişkenliği (istenmeyen) temsil eden iki bileşeni içermelidir. Taguchi bu özellikleri birleştirmek için sinyal-gürültü (S/N) oranlarını geliştirmiştir. Sinyal, karakteristiğinin ortalama değerini temsil eder. Gürültü ise karakteristiğinin değişkenliğini temsil eder. Taguchi bu iki özelliği sinyal-gürültü oranı adı verilen bir performans ölçütünde birleştirmiştir. Bu S/N oranlarına ilişkin formüller kalite özelliğinin niteliği olan hedef-en iyidir, küçük-daha iyidir veya büyük-daha iyidir ifadelerini içerir. S/N maksimize edildiğinde beklenen kaybın minimize edilmesi özelliğine sahip olmalıdırlar.

Hedef-En İyisidir

Burada hedef sıfır olmayan sonlu bir değerdir. Eğer değilse, ortalama yanıt hedefe yaklaştırmak için bir ayarlama faktörü bulunmalıdır. Maksimize edilecek S/N oranı şu şekilde verilir.

$$\varepsilon = \mu^2 / \sigma^2 \quad (3.67)$$

Burada μ çıktı karakteristiğinin ortalaması, σ ise standart sapmasıdır. Operasyonel performansın ilgili bir ölçüsü aşağıdaki denklemle elde edilir.

$$n = 10 \log \frac{y^{-2}}{s^2} \quad (3.68)$$

Burada y örnek ortalaması, s örnek standart sapmasıdır. Böylece, η 'yi maksimize eden optimum parametre seviyeleri bulunarak ortalama yanıtı hedefe yaklaştıran ayarlama faktörleri kullanılır.

Daha küçük daha iyidir

Bu tür kalite özellikleri için kayıp fonksiyonu Denklem (3.4) ile verilir. Özelliğin ideal hedef değeri sıfırdır ve performans ölçüsü sıfırdan ortalama kare sapma ile verilir (Denklem (3.6)). Herhangi bir ayarlama faktörü olmadığı için maksimize edilecek performans ölçütü şu şekilde verilir.

$$n = -10 \log \left[\frac{\left(\sum_{i=1}^n y_i^2 \right)}{n} \right] \quad (3.69)$$

Bu performans istatistiği gürültünün etkisini etkili bir şekilde ölçer.

Daha büyük daha iyidir

Burada kalite istatistiğinin mümkün olduğunca büyük olması istenir. Bu basitçe açıklamak gerekirse küçük daha iyidir durumunun tersidir ve herhangi bir ayarlama faktörü söz konusu değildir. Kayıp fonksiyonu Denklem (3.7) ile verilmektedir. Bu nedenle, maksimize edilecek bir performans ölçüsü şu şekilde verilir

$$n = -10 \log \left[\frac{\left(\sum_{i=1}^n 1/y_i^2 \right)}{n} \right] \quad (3.70)$$

3.8.6. Deneyisel tasarım

Deneylerin gerçekleştirileceği faktör seviyelerinin ve elde edilecek yanıt değişkeni değerlerinin belirlenmesi Taguchi yönteminin önemli bir bileşenidir.

Çizelge 3.4. Bir L16 iç dizisi ve bir L3 dış dizisi kullanılarak deneyisel düzen

Deney Adeti	A	B	C									Ort. Cevap	Perf. Ölçüsü
1	1	1	1	y ₁₁	y ₁₂	y ₁₃	y ₁₄	y ₁₅	y ₁₆	y ₁₇	y ₁₈	$\bar{y}_1$	η_1
2	1	2	2	y ₁₁	y ₂₂	y ₂₃	y ₂₄	y ₁₅	y ₂₆	y ₂₇	y ₂₈	$\bar{y}_2$	η_2
3	1	3	3	.	.	.	.	.	.	.	.	.	.
4	1	4	4	.	.	.	.	.	.	.	.	.	.
5	2	1	2	.	.	.	.	.	.	.	.	.	.
6	2	2	1	.	.	.	.	.	.	.	.	.	.
7	2	3	4	.	.	.	.	.	.	.	.	.	.
8	2	4	3	.	.	.	.	.	.	.	.	.	.
9	3	1	3	.	.	.	.	.	.	.	.	.	.
10	3	2	4	.	.	.	.	.	.	.	.	.	.
11	3	3	1	.	.	.	.	.	.	.	.	.	.
12	3	4	2	.	.	.	.	.	.	.	.	.	.
13	4	1	4	.	.	.	.	.	.	.	.	.	.
14	4	2	3	.	.	.	.	.	.	.	.	.	.
15	4	3	2	.	.	.	.	.	.	.	.	.	.
16	4	4	1	y ₁₆₁	y ₁₆₂	y ₁₆₃	y ₁₆₄	y ₁₆₅	y ₁₆₆	y ₁₆₇	y ₁₆₈	$\bar{y}_{16}$	η_{16}

Taguchi diyagramları ortogonal bir matris kullanır (Taguchi, 1987). Bu matriste her satır, deneyisel çalışma için seçilen faktörün düzeyini, her sütun ise yanıt değişkeni üzerindeki etkisi açısından belirli bir faktörü temsil eder. Faktör konfigürasyonları ortogondur, yani her test konfigürasyonu için aynı sayıda tekrarlanırlar. Bu, faktör seviyelerinin dengeli bir şekilde karşılaştırılmasına olanak tanır. Ayrıca ortogonal matrisin iki sütunu iki faktörlü bir tasarım oluşturur. Ortogonal bir dizi kullanmak, ikili dengeyi korurken çalışma sayısını azaltır. Taguchi, farklı koşulların etkilerini ortogonal diziler kullanarak incelemek için toplamsal bir modeli savunuyor. Bu, birden fazla faktörün etkilerinin toplamının, bireysel faktörlerin etkilerinin toplamına eşit olduğu anlamına gelir. Bu nedenle ek modellerde ikiden fazla çapraz çarpım terimine izin verilmez. Taguchi'nin motivasyonu mümkün olduğu kadar çok ve az sayıda deney belirlemektir. Etkileşim etkileri önemliyse, Taguchi tasarımlarındaki kafa karıştırıcı düzeyden dolayı bunlar ana etkilerden ayırt edilemeyebilir. Tanımlanan parametrelerin optimal seviyelerini doğrulamak için bir doğrulama çalışması yapılırken, gözlemlenen yanıtın tahminle eşleşmemesi durumunda diğer modellerin uygun olmayabileceğini ve bu modelin kullanılmasının neden önemli olduğunu belirtmek için Taguchi yöntemi kullanılır. Örnek bir Taguchi diyagramı, Çizelge 3.4'te gösterildiği gibi üç tasarım faktörü (A, B, C) için iç dizisi bir L₁₆ düzenlemesi ve dört gürültü faktörü (D, E, F, G)

için dış dizisi bir L_3 düzenlemesi kullanır. Her tasarım özelliğinin 2, her gürültü faktörünün 3 seviyesi vardır. Bu nedenle, iç konfigürasyonun 1. testinde, her tasarım ögesini 1. seviyede tuttuk. Bu test konfigürasyonu, gürültü faktörü konfigürasyonuna karşılık gelen üç yinelemeden oluşuyordu. Yanıtlar y_{11} , y_{12} , y_{13} ve y_{14} ile temsil edilir, ortalama $\bar{y}_1$ 'dir ve performans ölçüsü η_1 'dir. Taguchi tarafından kullanılan ortogonal dizilerin gösterimi şöyledir: Tasarım matrisinde kullanılan $L_{16}(4^3)$ spesifikasyonu, dört tasarım bölümünün dikkate alındığı ve her bölüm için dört seviyede on altı testin gerçekleştirildiği anlamına gelir. Benzer şekilde, $L_3(3^2)$ spesifikasyonu, harici spesifikasyon için toplam dört testle birlikte üç adet iki seviyeli gürültü faktörünün dikkate alındığı anlamına gelir. Dolayısıyla Çizelge 3.4'teki model için toplam test sayısı 64'tür.

Taguchi yönteminin imalat ve hizmet sektörlerindeki çeşitli uygulamaları literatürde bulunabilir (Margavio ve diğ., 1994; Kumar ve diğ., 1996; Taner ve Sezen, 2007; Mohammed ve diğ., 2008; Lajis ve diğ., 2009).

3.8.7. Çoklu yanıt değişkeni problemleri için uzantılar

Gerçekçi problemler, sargı ısısı ve rotor kayma oranı gibi birden fazla ilgi değişkenini içerebilir. Bu durumda sorun, her iki kalite özelliğinin de istenen hedeflerine ulaşmak için kontrollü parametrelerin en uygun ayarlarını belirlemektir. Tüm kalite özelliklerinin aynı olması gerekmediğini unutmayın. Burada sargı ısısı bir nesnenin en iyi özelliği olabilirken, kayma oranı en büyük, en iyi özellik olabilir. Bu nedenle, daha önce de belirtildiği gibi, her kayıp fonksiyonunun veya performans ölçüsünün niteliği farklı olabilir. Fonksiyonların anlamları da farklılık gösterebilmektedir. Ayrıca düzeltme faktörünü seçerken "hedef en iyidir tipi" işlevine yönelik düzeltme faktörü, diğer kalite özelliklerinin ortalama tepkisini önemli ölçüde etkilememesini sağlamalı, ilgili performans göstergesini (örneğin, sinyal-gürültü oranı), önemli ölçüde etkilememeli, ancak ortalama yanıtı etkilemelidir. Çoklu yanıt problemlerini modellemek için çeşitli yaklaşımlar kullanılmıştır (Logothetis ve Haigh, 1988; Shiau, 1990; Tong ve diğ., 1997).

Sonuç olarak Taguchi yöntemi sürdürülebilir tasarım alanına katkıda bulunan bir analiz yöntemidir. Gürültü faktörlerinin mümkün olduğu kadar az değişmesi için tasarım ürünü ve sürecinin parametrelerinin tanımlanmasıyla ilgilenen nitel tasarım teknikleri bu yaklaşımın önemli bir avantajıdır. Ancak Taguchi'nin yöntemi eleştiride alarak iyileştirilmesi gerektiği savunulmaktadır (Box, 1988; Box ve diğ., 1988; Pignatiello ve

Ramberg, 1992). Eleştirileri üç konu altında toplayabiliriz. Birincisi performans ölçümünün yapısıyla ilgilidir. Daha önce de belirtildiği gibi, hedef performansın en iyi özelliği hem ortalamanın ($\bar{y}$) hem de varyansın (s^2) bir fonksiyonudur. Böylece S/N oranının maksimuma çıkarılması, faktörlerin ortalama yanıt ve değişkenlik üzerindeki eşzamanlı etkisini ölçer. S/N oranının maksimuma çıkarılmasının değişkenliği azaltacağına dair hiçbir garanti bulunmadığına ve yalnızca standart sapmanın ortalamayla orantılı olduğu durumlarda geçerli olabileceğine dikkat edilmelidir. Yaklaşım konumun dağılım üzerindeki işlevsel bağımlılığını ortadan kaldıran dönüşümleri incelemenin alternatif olacağı düşünülmektedir. Klasik deneysel modellerle karşılaştırıldığında Taguchi'nin önerdiği ortogonal diziler istenen sonucu vermemektedir. Bazı örtüşmeler doğrusal grafikler kullanılarak tespit edilse de ana etkiler iki yönlü etkileşimlerle karıştırılabilir ve özellikle etkileşim etkileri önemli olduğunda sahte sonuçlara yol açabilir (Leon, 1987). İkincisi, Taguchi ile oluşturulan planlama iç ve dış dizideki toplam deneysel çalışma sayısı klasik deney tasarımından daha büyük olabilir. Bu konuda araştırmacılar, kontrol ve gürültü faktörlerinin tek bir birleşik dizide eşit düzeyde incelenmesini önermektedirler (Miller ve diğ., 1994). Üçüncüsü, araştırmacılar yanıt değişkeni ile tasarım faktörlerinin, gürültü faktörleri / tasarım faktörleri ile tasarım / gürültü faktörleri arasındaki olası etkileşimlerin ilişkisinin analizini önermişlerdir. Ortalama yanıt için yanıt modelleri geliştirmek ve yanıt değişkeninin varyansı için bir model geliştirmek de değerli bir yaklaşım olabilir (Myers ve diğ., 2002; Mitra, 2011).

3.9. Yapay Zeka (Artificial Intelligence, AI)


AI yöntemlerinin yükselişi ve ilerlemesi, yüksek verimli paralel hesaplamalara olanak tanıyan donanım platformlarının geliştirilmesi, sensör üretim maliyetlerinin düşmesi ve toplanan verilerin artmasıyla birlikte, veri güdümlü yöntemler artık ilgi çekmekte ve akademik ve endüstriyel topluluk tarafından araştırılmaktadır. Veri güdümlü yöntemler, özellik teşhisi için büyük miktarda veri kullanan yöntemlerdir. Yöntemler istatistiksel, ML ve DL gibi farklı kategorilerde gruplandırılabilir. İstatistiksel analiz yöntemleri arasında PCA ve PLS bulunmaktadır (Liu ve diğ., 2015). ML yöntemleri büyük miktarda veri için uygundur, ancak genellikle özellikleri vurgulamak ve daha fazla özellik çıkarmak için sinyal işleme teknikleriyle birleştirilir.

Bu bölümde, ASM'ler için önerilen veriye dayalı parametre tahmin yöntemlerini anlamak ve matematiksel modelleme için gereken teorik ve teknik arka plan

detaylandırılmaktadır. Makine öğrenimi ve derin öğrenme hakkında teknik bilgiler verilmektedir.

3.9.1. Makine öğrenimi (Machine Learning, ML)


ML, gelecekteki veriler hakkında tahminlerde bulunmak amacıyla girdi verilerindeki kalıpları otomatik olarak tespit etmek için kullanılan bir dizi yöntem olarak tanımlanabilen yapay zekanın bir alt kümesidir (Murphy, 2012). Tasarımcının bir sonuca ulaşmak için verilerle birlikte kullanılacak kuralları (program) tanımladığı geleneksel programlamanın aksine, ML sistemleri verilere ve önceki yinelemelerin sonuçlarına dayalı olarak kuralları çıkarmak üzere eğitilir (bkz. Şekil 3.89).



Şekil 3.89. Makine öğrenimi paradigması (Chollet, 2021)


ML algoritmaları, geleneksel programlama için zor olan görevleri çözmek için kullanılabilir. En yaygın olanlardan bazıları sınıflandırma, regresyon, makine çevirisi ve anormallik tespittir. Mevcut veri türüne bağlı olarak, makine öğrenimi algoritmaları genel olarak denetimsiz, denetimli veya yarı denetimli olarak Şekil 3.90'daki gibi kategorize edilebilir. Denetimsiz öğrenme, $D = (x_i)_{i=1}^N$ gibi x girdileri ve y çıktıları arasında açık bir eşleme bulunmayan etiketlenmemiş verileri kullanır. Denetimsiz öğrenmenin amacı, verilerin olasılık dağılımını öğrenmek ve verilerdeki örüntüleri bulmaktır. Denetimsiz öğrenme en yaygın olarak, verilerin doğasında bulunan gizli faktörleri keşfetmek amacıyla verileri özelliklerine göre kümelemek için kullanılır (Chollet, 2021). Öte yandan, denetimli öğrenme, $D = (x_i, y_i)_{i=1}^N$ olacak şekilde x girişlerinden y çıkışlarına (hedefler olarak da adlandırılır) bir eşleme öğrenmek için etiketli verileri kullanır; burada D veri kümesini temsil eder ve N veri kümesindeki örnek sayısıdır (Widodo ve Yang, 2007). Denetimli öğrenmenin amacı, gelecekteki,

görülmemiş, etiketlenmemiş veri girdileri X 'ten y 'yi tahmin etmeyi öğrenmektir (Goodfellow ve diğ., 2016). Ayrıca, denetimli öğrenme iki ana problem türüne ayrılabilir: sınıflandırma ve regresyon. Sınıflandırma problemleri, X girişlerinden y çıkışlarına bir eşleme öğrenmeyi amaçlar; burada $y \in \{1, \dots, C\}$, burada C sonlu bir kümedeki ayrık sınıfların sayısıdır. Sınıf sayısı ikiye eşitse problem ikili sınıflandırma, sınıf sayısı ikiden büyükse problem çok sınıflı sınıflandırma olarak tanımlanır. Regresyon problemleri de sınıflandırma problemleri gibi X girdilerinden y çıktılarına bir eşleme öğrenmeyi amaçlar, ancak y sürekli, gerçek değerli bir çıktıdır $y \in \mathbb{R}$. Son olarak, verilerin yalnızca küçük bir kısmı etiketlenmişse, iki ayrı denetimsiz ve denetimli modele sahip olmak yerine yarı denetimli bir model kullanılabilir. Yarı denetimli öğrenme, X 'ten y 'yi tahmin etmek için hem $D = (x_i)_{i=1}^N$ 'deki etiketlenmemiş örnekleri hem de $D = (x_i, y_i)_{i=1}^N$ 'deki etiketli örnekleri kullanır (Nair, 1992).



Şekil 3.90. Makine öğrenimi algoritması

ML modellerinin genel amacı, modelin kapasitesi olarak da tanımlanan yeni verilere iyi genelleme yapmaktır. Eğitim verileri üzerinde iyi performans göstermeyen ve iyi genelleme yapamayan bir modelin yetersiz uyum gösterdiği söylenir. Eğitim verilerinde iyi performans gösteren ancak iyi genelleme yapamayan bir modelin aşırı uyum sağladığı söylenir. Yetersiz uyum ve aşırı uyum modelleri arasındaki denge, genelleme ve tahmin performansı arasındaki bir değiş tokuştur. Model genellemesi.91'de görülmektedir.




Şekil 3.91. Model genellemesi (Mitra, 2016)

Makine öğrenimi algoritmalarının yeni, görülmemiş veriler üzerinde genelleme yapabilmesi ve iyi performans gösterebilmesi için model, model eğitimi olarak da bilinen bir öğrenme sürecinden geçer. Modeller, tahmin edilen değer $\hat{y}$ ile gerçek değer y karşılaştırılarak ve tahmin hatası hesaplanarak yinelemeli olarak eğitilir. Modeller daha sonra öğrenir ve bu hatayı en aza indirerek tahmin performanslarını geliştirir. Tahmin hatası modelin performansını ölçer ve bir kayıp fonksiyonu ile hesaplanır. Bu hatayı ölçmek için farklı hususları dikkate alan birçok farklı kayıp fonksiyonu vardır (Bölüm 3.9.2.3). Tahmin hatasını en aza indirmek için modelin güncellendiği mekanizmaya optimizasyon algoritması denir (Bölüm 3.9.2.4). Kendi iç parametreleri olan farklı kayıp fonksiyonlarının ve optimize edicilerin kullanılması modelin performansını etkiler. Daha ayrıntılı bir açıklama Bölüm 3.9.2.2'de verilmiştir. Makine öğrenimi, Yapay Sinir Ağı (ANN)/Derin Öğrenme, Otomatik Kodlayıcı ve Evrimsel Sinir Ağı (CNN), Geri Yayımlı Sinir Ağları (BPNN), Destek Vektör Makineleri (SVM), k-En Yakın Komşular (KNN), Karar ağaçları/Rastgele orman Algoritması, Çok Katmanlı Algılayıcılar (MLP) ağları, XGBoost (Extreme Gradient Boosting) Geri Yayımlı gibi algoritmalarla parametre tespiti ve tahmini ile arıza tahmini ve teşhisinde yaygın olarak kullanılmaktadır.

3.9.2. Yapay sinir ağları (Artificial Neural Network, ANN) ile derin öğrenme

Yapay Sinir Ağları (ANN), nöron adı verilen birbirine bağlı elemanlardan oluşan biyolojik beyinden esinlenen hesaplama ağı modelleridir. Nöronlar, özellikler olarak da bilinen girdi verileri üzerinde aktivasyon fonksiyonları (bkz. Bölüm 3.9.2.1) olarak da bilinen doğrusal olmayan hesaplamalar gerçekleştirerek bilgileri işler. Özelliklere, önemlerini temsil eden ağırlıklı bir değer atanır. Derin öğrenme, makine öğreniminin bir alt kümesidir ve verilerden örüntü ve bilgi çıkarmak için birçok gizli katmanın

kullanımından yararlanan ANN'lerin bir uzantısıdır. Şekil 3.92'de ML ve DL algoritmaları karşılaştırılmaktadır. Derin öğrenme, hiyerarşik temsilleri öğrenmeye odaklanır; burada öğrenme, giderek daha anlamlı temsillerin bu tür ardışık katmanlarını kullanarak elde edilir (Chollet, 2021).



Şekil 3.92. ML ve DL Algoritma

3.9.2.1. Aktivasyon fonksiyonları

Aktivasyon fonksiyonu giriş verilerini işler ve çıkış değerini tanımlar. Her biri farklı özelliklere ve aralıklara sahip olan ve her biri farklı amaçlar için kullanılan yaygın olarak kullanılan birçok aktivasyon fonksiyonu vardır (Brownlee, 2021a). Tüm gizli katmanların bir tür aktivasyon fonksiyonu kullanması ve son katmanın veya çıktı katmanının gerekli uygulamaya veya tahmine bağlı olarak farklı bir aktivasyon fonksiyonu kullanması yaygındır (Pathimind, 2021). Gizli katman, girdi verileriyle doğrudan etkileşime girmeyen ve çıktısı başka bir gizli katmana veya çıktı katmanına beslenen bir katmandır. ANN sıfır veya daha fazla gizli katmana sahip olabilirken, derin sinir ağları tipik olarak üç veya daha fazla gizli katmana sahiptir (Peltarion, 2021a).

Aşağıda en yaygın kullanılan aktivasyon fonksiyonlarının bir listesi bulunmaktadır:

- Doğrusal fonksiyon, x girişini yalnızca sabit bir C (2.71) ile ölçeklendiren en basit aktivasyon fonksiyonudur (Peltarion, 2021b).

$$linear = f(x) = C * x \quad (3.71)$$

- ReLU olarak da bilinen REctified Linear Unit, negatif değerleri 0'a keser ve üst sınırı yoktur (2.72). ReLU, birçok uygulamada iyi çalıştığı için yaygın olarak kullanılmaktadır (Peltarion, 2021c).

$$ReLU = f(x) = \max(0, x) \quad (3.72)$$

- Softmax aktivasyon fonksiyonu, hepsi 1'e eklenerek hedef etiketlerin ilgili olasılıklarını çıkarır (Peltarion, 2021d).

$$softmax = \sigma(x_j) = \frac{e^{x_j}}{\sum_{k=0}^K e^{x_k}} \quad (3.73)$$

- Sigmoid işlevi, değerleri 0 ve 1'e doğru iten doğrusal olmayan bir işlevdir. Sigmoid işlevi, sınıflandırma amaçları için etkili bir işlevdir (Peltarion, 2021e).


$$sigmoid = f(x) = \frac{1}{1 + e^{-x}} \quad (3.74)$$

- Tanh fonksiyonu, sınırların -1 ve 1 olması dışında sigmoid fonksiyonuna benzer (Peltarion, 2021f).

$$tanh = f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.75)$$

3.9.2.2. Ağ eğitimi

DL modellerinin tahmin yeteneklerini geliştirmesinin yolu gradyan inişi adı verilen bir yöntemdir. Bir modelin ağırlıkları ve parametreleri genellikle rastgele başlatıldığından, gradyan inişi, bir optimizasyon algoritması (bkz. Bölüm 3.9.2.4) aracılığıyla kayıp fonksiyonunu (bkz. Bölüm 3.9.2.3) en aza indirmek amacıyla bu parametreleri güncelleyerek çalışır. Gradyan inişi terimi adını parametreleri güncellemek için kullanılan yaklaşımdan alır. Kayıp fonksiyonunu en aza indirmek için ağırlığın bir önceki katmandaki ağırlığa göre türevi her katman için hesaplanır ve art arda güncellenir. Şekil 3.93'te gösterildiği gibi, başlangıçtaki ağırlık minimum maliyete ulaşılan kadar kademeli olarak güncellenir, bu süreç geriye yayılma olarak da bilinir (Peltarion, 2021g).



Şekil 3.93. Dereceli alçalma

Bununla birlikte, eğitim sürecinin etkinliği, ağırlıkların güncellenme şeklini etkileyen çeşitli parametrelere bağlıdır; bunlardan en önemlileri öğrenme oranı ve yığın boyutudur. Bu ayarlanabilir parametreler, modelin hiper parametreleri olarak da bilinir. Öğrenme oranı, ağırlık değerleri güncellenirken her iterasyonda minimuma doğru atılan adımın boyutudur. Öğrenme oranı çok küçük ayarlanırsa, minimuma yakınsama çok yavaş olacaktır. Öte yandan, öğrenme oranı çok yüksek ayarlanırsa, model hiç yakınsamayabilir (Murphy ve Kevin, 2012).

Yığın boyutu veya kayıp fonksiyonunun türevini tahmin etmek için kullanılan eğitim örneklerinin sayısı da performans modelinin eğitimini etkiler. Her iterasyondan sonra ağırlıkların güncellenmesi daha doğru bir hesaplama ile sonuçlanacaktır, ancak hesaplama açısından daha pahalı olacaktır. Tersine, tüm eğitim örneklerini kullanarak ağırlıkların güncellenmesi daha az doğru ancak hesaplama açısından çok daha az maliyetli olacaktır (Chollet, 2021). Optimizasyon yönteminin ve hiper parametrelerinin doğru seçimi, uygun model eğitiminin anahtarıdır.

Bir modeli eğitmenin ve test etmenin en yaygın yolu, veri kümesini modeli eğitmek, doğrulamak ve test etmek için kullanılan alt kümelerle rastgele bölmektir. Eğitim seti, model eğitimi ve fonksiyon kaybı optimizasyonu sırasında kullanılır; doğrulama seti, model performansını ve hiper parametre optimizasyonunu gözlemlemek için eğitim seti ile kullanılabilir ve son olarak test seti, eğitimden sonra modeli değerlendirmek için kullanılır. Bu, kullanılan tüm verilerin aynı dağılıma sahip olmasını sağlar. Kfold çapraz doğrulama, veri kümesini çakışmayan k alt kümeye bölmek ve farklı alt kümeleri eğitim, doğrulama ve test kümeleri olarak kullanmak ve farklı amaçlar için farklı alt kümeler kullanırken modeli k kez eğitmek için kullanılan bir yöntemdir (Goodfellow ve diğ., 2016).

3.9.2.3. Kayıp fonksiyonları

Amaç fonksiyonu olarak da adlandırılan kayıp fonksiyonu, modelin ne kadar iyi performans gösterdiğini ölçen bir fonksiyondur. Genel anlamda kayıp fonksiyonu, beklenen değer ile mevcut model çıktısı arasındaki hatadır. Eğitimin amacı kayıp fonksiyonunu en aza indirmektir. Başka bir deyişle, tahmin edilen ve gerçek değerler arasındaki hata ne kadar küçük olursa, modelin performansı o kadar iyi olur (Peltarion, 2021h). Farklı kayıp fonksiyonları hatayı farklı şekillerde ölçer ve bu nedenle farklı tahmin edilen sonuçları farklı şekilde cezalandırır. Regresyon için en yaygın kullanılan kayıp fonksiyonları Ortalama Mutlak Hata ve Ortalama Karesel Hata iken, Kategorik Çapraz Entropi kayıp fonksiyonu genellikle sınıflandırma problemleri için kullanılır

Ortalama mutlak hata (MAE) kayıp fonksiyonu, tahmin edilen değerler ($\hat{y}_i$) ile gerçek değerler (y_i) arasındaki mutlak farkın ortalamasını ölçer. MAE kaybı, ortalamadan her iki yöndeki sapmaları eşit şekilde cezalandırır, burada optimum tahmin medyan olacaktır ve bu nedenle bu kayıp fonksiyonu aykırı değerlere duyarlı değildir (Peltarion, 2021i).

$$MAE = L\left(y, \hat{y}\right) = \frac{1}{N} \sum_{i=1}^N \left| y_i - \hat{y}_i \right| \quad (3.76)$$

Ortalama karesel hata (MSE) kayıp fonksiyonu, tahmin edilen değerler ($\hat{y}_i$) ile gerçek değerler (y_i) arasındaki karesel farkların ortalamasını ölçer. MSE kaybı, her iki yöndeki ortalamadan sapmaları eşit şekilde cezalandırır, ancak tüm hataları karelediği için serttir ve bu nedenle bu kayıp fonksiyonu aykırı değerlere duyarlıdır (Peltarion, 2021j).

$$MSE = L\left(y, \hat{y}\right) = \frac{1}{N} \sum_{i=1}^N \left(y_i - \hat{y}_i \right)^2 \quad (3.77)$$

Kategorik CrossEntropy fonksiyonu, modelin birçok etiket arasından yalnızca birini seçmesi gereken çok sınıflı, tek etiketli sınıflandırma görevleri için kullanılır. Kayıp

fonksiyonu, $\hat{y}_i$ 'nin model çıktısının i -th değeri ve y_i 'nin gerçek değer olduğu formül 2.78 hesaplanarak bulunur (Peltarion, 2021k).

$$CC = L(y, \hat{y}) = \sum_{i=1}^N y_i \cdot \log \hat{y}_i \quad (3.78)$$

İkili Çapraz Entropi işlevi, modelin bir veya birden fazla öznitelik için iki seçenek arasından bir etiket seçmesi gereken çok etiketli, ikili sınıflandırma görevleri için kullanılır. İkili ve kategorik çapraz entropi arasındaki fark, birincisinin iki seçenek arasından bir etiket seçerken kullanılması, ikincisinin ise birçok seçenek arasından bir etiket seçmesidir (Brownlee, 2021b).

$$BC = L(y, \hat{y}) = -\frac{1}{\text{outputsize}} \sum_{i=1}^{\text{outputsize}} y_i \cdot \log \hat{y}_i + (1 - y_i) \cdot \log (1 - \hat{y}_i) \quad (3.79)$$

Son katman aktivasyonunun doğru seçimi, kayıp fonksiyonunun doğru kullanımı için çok önemlidir. Çizelge 3.5'te en sık kullanılan son katman aktivasyonu ve kayıp fonksiyonu kombinasyonları gösterilmektedir.

Çizelge 3.5. Son katman etkinleştirme ve kayıp işlevleri (Chollet, 2021)

Problem Tipi	Son Katman Aktivasyonu	Kayıp Fonksiyon
İkili sınıflandırma	sigmoid	binary_crossentropy
Çok sınıflı, tek etiketli sınıflandırma	softmax	categorical_crossentropy
Çok sınıflı, çok etiketli sınıflandırma	sigmoid	binary_crossentropy
Rastgele değerlere regresyon	hiçbiri	mse
0 ile 1 arasındaki değerlere regresyon	sigmoid	Mse or binary_crossentropy

3.9.2.4. Optimizasyon yöntemleri

3.9.2.2'de açıklandığı üzere, model eğitiminin amacı ağ ağırlıklarını iteratif olarak güncelleyerek kayıp fonksiyonunu minimize etmektir. Gerçek ve tahmin edilen değerler arasındaki hata ne kadar küçük olursa modelin performansı o kadar iyi olur. Farklı

öğrenme oranları ve yığın boyutu paradigmaları kullanarak ağırlıkların güncellenme biçiminde farklılık gösteren bir dizi farklı optimizasyon algoritması vardır. Örneğin, bazı yöntemler momentum (önceki ağırlık güncellemelerini dikkate alarak) ve azalma (öğrenme oranı değerini yavaşça azaltarak) kullanarak model geliştikçe öğrenmeye ince ayar yapmak için öğrenme oranını değiştirir. Aşağıda en yaygın kullanılan optimizasyon algoritmalarının bir listesi bulunmaktadır:

Stokastik gradyan inişi (SGD), güncellemeyi gerçekleştirirken örneklerin tek bir kümesini (gerçek SGD) veya bir alt kümesini (minibatch SGD) kullanan bir gradyan inişi uygulamasıdır (tüm örnek kümesini kullanan gradyan inişinin aksine) (Chollet, 2021).

Uyarlanabilir Gradyanların kısaltması olan **Adagrad**, gradyanlara uyum sağlamak için öğrenme oranının boyutunu otomatik olarak değiştiren gradyan inişinin bir uzantısıdır (Brownlee, 2021c).

Kök Ortalama Karesel Yayılımın kısaltması olan **RMSProp**, gradyan inişinin bir uzantısıdır ve ağırlık güncellemesini gerçekleştirirken gradyanları takip etmek için hareketli bir ortalama kullanan ve böylece en son görülen örnekleri kullanan Adagrad'ın bir modifikasyonudur (Kingman ve diğ. 2017).

Uyarlanabilir moment tahmini (Adam), birinci ve ikinci momentlerin uyarlanabilir tahminlerine dayanan gradyan tabanlı bir optimizasyon amaç fonksiyonudur (Murphy, 2012). Adam, hesaplama verimliliği, küçük bellek ayak izi ve iyi performansı nedeniyle yaygın olarak kullanılan bir optimizasyon algoritmasıdır. Adam, diğer iki iyi bilinen optimizasyon algoritmasının avantajlarını birleştirir. Uyarlanabilir Gradyan Algoritması (AdaGrad) gibi, Adam parametre başına bir öğrenme oranını korur ve Kök Ortalama Kare Yayılım Algoritması (RMSProp) gibi Adam gradyan türevlerine uyum sağlayan parametre başına öğrenmeyi sürdürür (Brownlee, 2017).

3.9.2.5. Değerlendirme metrikleri

Model eğitildikten sonra, modelin performansını ölçmek için farklı değerlendirme metrikleri kullanılır. Başka bir deyişle, değerlendirme metrikleri modelin yeni, görülmemiş örneklerle ne kadar iyi genelleme yaptığını ölçer (Brownlee, 2020). Sınıflandırma problemleri için karışıklık matrisi, bir modelin tahminlerinin ne kadar iyi olduğunu özetleyen kullanışlı bir tablo düzenidir. Çizelge 3.6'da gösterildiği gibi, karışıklık matrisi gerçek pozitiflerin (TP), yanlış pozitiflerin (FP), yanlış negatiflerin (FN) ve gerçek negatiflerin (TN) basit bir görselleştirmesini sağlar. Doğru pozitif ve doğru

negatif, sırasıyla pozitif ve negatifin doğru tahminine karşılık gelir. Yanlış pozitif, pozitif bir değer yanlış tahmin edilmesine karşılık gelirken yanlış negatif, negatif bir değer yanlış tahmin edilmesine karşılık gelir. Mükemmel bir modelde diyagonal tüm tahminleri içerir ve diyagonal olmayan sıfırdır, yani model tüm veri örneklerini doğru tahmin etmiştir.

Çizelge 3.6. Örnek karışıklık matrisi

		Tahmini Değer	
		Pozitif	Negatif
Gerçek Değer	Pozitif	TP	FN
	Negatif	FP	TN

Doğruluk, toplam içindeki doğru tahminlerin yüzdesidir ve 0 ile 1 arasında değerler alır.

$$\text{Doğruluk} = \frac{\text{Doğru}}{\text{Toplam}} \quad (3.80)$$

Hassasiyet, pozitif sınıfta doğru tahmin edilen gerçek pozitiflerin oranını ölçer ve 0 ile 1 arasında değerler alır.

$$\text{Hassasiyet} = \frac{TP}{(TP + FP)} \quad (3.81)$$

Geri çağırma, pozitif sınıfın ne kadar iyi tanımlandığını ölçer ve 0 ile 1 arasında değerler alır.


$$\text{Geri çağırma} = \frac{TP}{(TP + FN)} \quad (3.82)$$

F1-puan, hassasiyet ve geri çağırma puanlarının harmonik ortalamasıdır ve 0 ile 1 arasında değerler alır.


$$F1 - \text{puan} = \frac{2 * \text{Hassasiyet} * \text{Geri} \text{ç} \text{a} \text{ğ} \text{ırma}}{(\text{Hassasiyet} + \text{Geri} \text{ç} \text{a} \text{ğ} \text{ırma})} \quad (3.83)$$

3.9.3. Geri yayımlı sinir ağı (Backpropagation Neural Network, BPNN) algoritması

BPNN, ANN'lerde yaygın olarak kullanılan bir öğrenme algoritmasıdır. Bu algoritma, ağıın çıktılarını gerçek değerlerle karşılaştırarak hata miktarını hesaplar ve ardından bu hatayı azaltacak şekilde ağıın ağırlıklarını günceller. BPNN, MLP gibi yapay sinir ağıları için temel bir öğrenme yöntemidir. Şekil 3.94'te BPNN'in genel gösterimi ve Şekil 3.95'te algoritmanın genel çalışma akış diyagramı görülmektedir.



Şekil 3.94. Geri yayımlı sinir ağıın genel gösterimi



Şekil 3.95. Algoritmanın genel çalışma akış diyagramı

3.9.3.1. Çalışma prensibi

BPNN'nin çalışma prensibi, hata teriminin türevinin, ağıın her bir katmanındaki ağırlıklara göre ters yönde yayılması esasına dayanır. Bu süreç, aşağıdaki adımları içerir:

İleri Yayılım: Giriş verileri, ağıın giriş katmanından başlayarak ileri doğru yayılır. Her katmandaki nöronlar, önceki katmandan gelen girdileri alır, bu girdileri kendi ağırlıklarıyla çarpar ve bir aktivasyon fonksiyonu uygulayarak sonraki katmana çıktı gönderir.

Hata Hesaplama: Ağıın çıktı katmanındaki değerler, beklenen gerçek değerlerle karşılaştırılarak hata hesaplanır. Genellikle ortalama kare hatası (mean squared error-MSE) gibi bir hata fonksiyonu kullanılır.

Geri Yayılım: Hesaplanan hata, çıktı katmanından başlayarak geriye doğru yayılır. Her katmandaki nöronların ağırlıkları, hatayı azaltacak şekilde güncellenir. Bu güncelleme, hatanın ağırlıklara göre kısmi türevi (gradyan) kullanılarak yapılır.

Ağırlık Güncelleme: Her bir ağırlık, belirli bir öğrenme hızıyla güncellenir. Bu öğrenme hızı, ağırlık güncellemelerinin boyutunu kontrol eder.

3.9.3.2. Öğrenme hızı ve momentum

BPNN'de iki önemli hiper parametre vardır: öğrenme hızı ve momentum.

Öğrenme Hızı: Ağırlıkların ne kadar hızlı güncelleneceğini belirler. Çok yüksek bir öğrenme hızı, ağırlıkların hızlıca güncellenmesine ve hızlı öğrenmeye yol açar, ancak aşırı uyuma veya dalgalanmalara neden olabilir. Çok düşük bir öğrenme hızı, öğrenmeyi yavaşlatır ve yerel minimumlarda takılma riskini artırabilir.

Momentum: Önceki ağırlık güncellemelerinin mevcut güncellemeye etkisini belirler. Momentum, ağırlıkların yerel minimumlardan kaçınmasına ve daha hızlı öğrenmesine yardımcı olabilir.

3.9.3.3. Parametreler

Ağırlıklar (Weights): Sinir ağının her bir bağlantısı için bir ağırlık değeri vardır. Bu ağırlıklar, giriş verilerinin nöronlara nasıl etki ettiğini belirler ve öğrenme süreci sırasında sürekli olarak güncellenir.

Biaslar (Biases): Her nöron için bir bias değeri bulunur. Biaslar, nöronun aktivasyon fonksiyonunu kaydırarak aktivasyon eşiğini ayarlar.

3.9.3.4. Hiper parametreler

Öğrenme Hızı (Learning Rate): Ağırlık ve biasların ne kadar hızlı güncelleneceğini belirler. Öğrenme hızı, öğrenme sürecinin hızını ve kararlılığını etkiler.

Momentum: Önceki ağırlık güncellemelerinin mevcut güncellemeye katkısını belirler. Momentum, öğrenme sürecinin hızını artırabilir ve yerel minimumlardan kaçınmaya yardımcı olabilir.

Katman Sayısı ve Nöron Sayısı: Sinir ağının kaç katmandan oluştuğu ve her katmanda kaç nöron bulunduğu önemli bir hiper parametredir. Bu değerler, ağın karmaşıklığını ve modelleme kapasitesini belirler.

Aktivasyon Fonksiyonu: Nöronların çıktılarını hesaplamak için kullanılan fonksiyondur. Sigmoid, ReLU ve tanh gibi farklı aktivasyon fonksiyonları, öğrenme sürecinin dinamiklerini etkileyebilir.


Eğitim Döngüsü (Epoch) Sayısı: Tüm eğitim veri setinin ağda kaç kez ileri ve geri yayılım yapacağını belirler. Daha fazla epoch, genellikle daha iyi öğrenme performansı anlamına gelir, ancak aşırı uyum (overfitting) riskini artırabilir.

Toplu İşlem Boyutu (Batch Size): Eğitim sırasında ağa verilen veri seti parçalarının boyutudur. Toplu işlem boyutu, bellek kullanımını ve eğitim hızını etkiler.


Bu parametreler ve hiper parametreler, BPNN'nin öğrenme performansını ve modelin genel başarısını doğrudan etkiler. Uygun değerlerin seçilmesi, veri setine ve çözülmek istenen probleme bağlı olarak önemlidir.

3.9.4. Çok katmanlı algılayıcılar (Multi Layer Perceptron, MLP) algoritması

MLP, derin öğrenme ve sinir ağları alanında yaygın olarak kullanılan bir model türüdür. Temel olarak, bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanından oluşur. Her katmandaki düğümler (veya nöronlar) bir önceki katmandaki tüm düğümlerle bağlantılıdır, bu da onu tamamen bağlantılı bir ağ yapar. MLP'ler, karmaşık desenleri ve ilişkileri modelleyebilir ve sınıflandırma, regresyon, tahmin yapma gibi çeşitli görevlerde kullanılabilir. Şekil 3.96'da MLP'nin genel gösterimi ve Şekil 3.97'de algoritmanın genel çalışma akış diyagramı görülmektedir.



Şekil 3.96. MLP algoritması genel gösterim



Şekil 3.97. MLP algoritması akış diyagramı

3.9.4.1. MLP'nin temel bileşenleri

Çok katmanlı algılayıcılar (MLP), derin öğrenme ve yapay sinir ağları alanında temel bir yapıdır. Bu yapı, verileri karmaşık işlevler aracılığıyla modelleyebilir ve geniş bir uygulama yelpazesinde kullanılabilir. MLP'nin temel bileşenleri şunlardır:

Giriş Katmanı: Bu katman, modelin aldığı ham veriyi temsil eder. Her bir nöron, veri setindeki bir özelliğe (feature) karşılık gelir. Örneğin, bir görüntü işleme görevinde, her nöron bir pikselin yoğunluğunu temsil edebilir. Giriş katmanının amacı, veriyi alıp ağın diğer katmanlarına iletmektir.

Gizli Katmanlar: MLP'nin asıl öğrenme kapasitesi bu katmanlarda bulunur. Her gizli katman, önceki katmandan aldığı bilgileri işler ve bir sonraki katmana aktarır. Bu işlem, veri setindeki karmaşık özellikleri ve ilişkileri çıkarmak için yapılır. Gizli katman

sayısı ve her birindeki nöron sayısı, modelin karmaşıklığını ve öğrenme yeteneğini belirler. Çok fazla gizli katman ve nöron, modelin daha karmaşık desenleri öğrenmesini sağlarken, aynı zamanda aşırı öğrenme riskini de artırabilir.

Çıkış Katmanı: Modelin sonuçlarını veya tahminlerini sunar. Sınıflandırma görevlerinde, her nöron belirli bir sınıfı temsil eder ve çıkış, genellikle bir softmax fonksiyonu ile işlenir, böylece her sınıf için bir olasılık dağılımı elde edilir. Regresyon görevlerinde ise, genellikle tek bir nöron kullanılır ve bu nöron, sürekli bir değeri tahmin eder.

3.9.4.2. Aktivasyon fonksiyonları

Aktivasyon fonksiyonları, sinir ağlarının lineer olmayan problemleri çözme kabiliyetinin temelini oluşturur. Bu fonksiyonlar, nöronların aktivasyon durumunu belirler ve ağı karmaşık özellikleri öğrenmesine olanak tanır.

ReLU (Rectified Linear Unit): En popüler aktivasyon fonksiyonlarından biridir ve genellikle gizli katmanlarda kullanılır. ReLU, negatif değerler için 0 döndürürken, pozitif değerler için girdi değerini korur. Bu özellik, modelin eğitim sürecini hızlandırır ve vanishing gradient problemine karşı dirençli hale getirir (Denklem 3.72).

Sigmoid: Çıktıları 0 ile 1 arasında sıkıştıran bir fonksiyondur. İkili sınıflandırma görevlerinde çıkış katmanında kullanılır çünkü çıktıları olasılıklar olarak yorumlamaya uygundur. Ancak, gradient vanishing problemine yol açabilir (Denklem 3.73).

Tanh (Hyperbolic Tangent): Çıktıları -1 ile 1 arasında sıkıştıran bir aktivasyon fonksiyonudur ve genellikle gizli katmanlarda kullanılır. Sigmoid'e benzer şekilde, tanh fonksiyonu da gradient vanishing problemine yol açabilir, ancak sıfır etrafında simetrik olması nedeniyle bazı durumlarda sigmoid den daha tercih edilir (Denklem 3.74).

3.9.4.3. Öğrenme süreci

MLP'ler, geri yayılım algoritması kullanılarak eğitilir. Bu süreçte, ağı çıktıları ile gerçek değerler arasındaki hata hesaplanır ve bu hata, ağıdaki ağırlıkları güncellemek için kullanılır. Geri yayılım, her katmandaki hata oranını hesaplar ve bu bilgiyi, ağırlıkları en iyi şekilde ayarlayarak hatayı minimize etmek için kullanır. Bu işlem, gradyan iniş yöntemi ile yapılır ve modelin eğitimi boyunca iteratif olarak tekrarlanır.

3.9.4.4. Aşırı öğrenmeyi önleme

Aşırı öğrenme, modelin eğitim verisine çok iyi uyum sağlaması ancak genel veri setinde kötü performans göstermesi durumudur. MLP'lerde aşırı öğrenmeyi önlemek için çeşitli teknikler kullanılır:

Dropout: Eğitim sırasında rastgele seçilen nöronları "düşürerek" (aktif olmaktan çıkararak) modelin belirli nöronlara aşırı bağımlı hale gelmesini önler. Bu yöntem, modelin daha robust (dayanıklı) olmasını sağlar.

Erken Durdurma (Early Stopping): Eğitim sürecini, modelin doğrulama seti üzerindeki performansı daha fazla iyileşmediğinde durdurarak aşırı öğrenmeyi önler. Bu, modelin eğitim verisine aşırı uyum sağlamasını engeller.

Düzenleme (Regularization): L1 ve L2 düzenlemeleri, ağırlıklara ekstra bir ceza terimi ekleyerek modelin aşırı karmaşık olmasını önler. L1 düzenlemesi, bazı ağırlıkların sıfıra eşitlenmesini sağlayarak modeli daha basit hale getirebilir. L2 düzenlemesi ise büyük ağırlıkları cezalandırarak modelin daha düzgün bir şekilde genelleştirilmesine yardımcı olur.

Bu teknikler, MLP'nin daha etkili bir şekilde genelleştirme yapabilmesi için kritik öneme sahiptir ve modelin farklı veri setlerinde daha iyi performans göstermesini sağlar.

3.9.4.5. MLP'nin matematiksel modeli

Çok katmanlı algılayıcılar (MLP), bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanından oluşur. Her katman, bir dizi nörondan oluşur ve her nöron bir önceki katmandaki tüm nöronlarla bağlantılıdır. Nöronlar arası bu bağlantılar, ağırlıklar (weights) ile ifade edilir. Bir MLP'nin temel işlevi, giriş verilerini ağırlıklar ve aktivasyon fonksiyonları aracılığıyla işleyerek bir çıktı üretmektir.

Bir Nöronun Çıktısı:

$$y = f_{aktv} \left(\sum_{i=1}^n w_i \cdot x_i + b \right) \quad (3.84)$$

x_i : Giriş değerlerini,

w_i : Ağırlıkları,

b : Bias terimini,

f_{aktiv} : Aktivasyon fonksiyonunu temsil eder.

Toplam n , giriş katmanındaki nöron sayısına eşittir.

3.9.4.6. Geri yayılım

MLP'nin eğitimi, geri yayılım (backpropagation) algoritması ile yapılır. Bu süreçte, modelin tahminleri ile gerçek değerler arasındaki fark (hata) hesaplanır ve bu hata, ağdaki ağırlıkları güncellemek için kullanılır. MSE formülü Denklem 3.77'de verilmiştir.

Ağırlık Güncelleme Formülü:

$$w_{new} = w_{old} - \alpha_{oran} \frac{\partial MSE}{\partial w} \quad (3.85)$$

w_{new} : Güncellenmiş ağırlık,


w_{old} : Güncellenmeden önceki ağırlık,

α_{oran} : Öğrenme oranı (adım büyüklüğü),

$\partial MSE / \partial w$: Hata fonksiyonunun ağırlığa göre kısmi türevi.

3.9.5. K-en yakın komşular (k-Nearest Neighbors, KNN) algoritması

K-en yakın komşular, sınıflandırma problemleri için kullanılan basit makine öğrenmesi yöntemleri arasındadır. KNN, benzer öğelerin bir araya getirildiği parametrik olmayan ve örnek tabanlı bir öğrenmedir. Denetimli öğrenme kategorisine aittir ve örüntü tanıma probleminde ve veri madenciliğinde önemli ölçüde kullanılır. Şekil 3.98'de algoritmanın genel çalışma akış diyagramı görülmektedir.



Şekil 3.98. KNN Algoritması Akış Diyagramı

Bu algoritmada, sınıf içindeki örnek veya örnekler benzer özelliklere sahip örneklerle yakın olacaktır (Ho, 1995). Bu algoritmada tüm örnekler n boyutlu $\mathcal{R}^n$ uzayında noktalara aittir. Benzerlik gösteren örneklerin belirlenmesi için Öklid uzaklığı kullanılır. Özellik vektörü $a_1(x), a_2(x), \dots, a_n(x)$ tarafından verilen rastgele bir x örneği, x örneğinin dağılımını gösterebilir. İki örnek x_i ve x_j arasındaki mesafe $d(x_i, x_j)$ olarak tanımlanır.

$$d(x_i, x_j) = \sqrt{\sum_{i=1}^N r = \ln(a_r(x_i) - a_r(x_j))^2} \quad (3.86)$$

KNN'deki hedef fonksiyon gerçek değerli veya ayrık değerli olabilir. Her eğitim örneği $(x, f(x))$ için eğitim örnekleri listesine eklenir. Sınıflandırılacak bir sorgu örneği x_q için; $x_1, x_2, \dots, x_k$ eğitim örneklerinden x_q 'ye en yakın olan k örneği gösterebilir, o zaman:

$$\hat{f}(x_q) \leftarrow \arg \max_{v \in V} \sum_{i=1}^k \delta(v, f(x_i)) \quad (3.87)$$

burada $a = b$ ise $\delta(a, b) = 1$ ve aksi takdirde $\delta(a, b) = 0$ 'dır.

3.9.5.1. KNN'de hiper parametreler

n_neighbors (*K*): KNN modelinin performansını en çok etkileyen parametrelerden biri 'K' sayısıdır. Bu, bir tahmin için dikkate alınacak en yakın komşu sayısını belirler. 'K' çok küçükse, model gürültüye çok duyarlı olur; çok büyükse, sınırlar aşırı düzleşebilir ve model aşırı genelleme yapabilir.

weights: 'uniform' (her komşunun eşit ağırlıklı olduğu) veya 'distance' (komşuların ağırlıklarının onların uzaklıklarının tersiyle orantılı olduğu) olabilir. 'distance' kullanıldığında, daha yakın komşuların tahmine daha büyük bir etkisi olur.

metric: Uzaklık hesaplaması için kullanılan metriği belirler. 'euclidean', 'manhattan', ve 'minkowski' en yaygın kullanılan metriklerdendir.

3.9.5.2. Model değerlendirme

Modelin performansını değerlendirirken kullanılan iki önemli metrik MSE ve R^2 'dir:

MSE (Ortalama Kare Hata): Gerçek değerler ile tahmin edilen değerler arasındaki farkların karelerinin ortalamasıdır. Daha düşük MSE, daha iyi bir model anlamına gelir (Denklemler 3.20).


R^2 (Determinasyon Katsayısı): Modelin verilerin varyansını ne kadar iyi açıkladığının bir ölçüsüdür. 1'e yakın bir değer, modelin verileri iyi açıkladığını gösterir.

$$R^2 = 1 - \frac{\sum \left(y_i - \hat{y}_i \right)^2}{\sum \left(y_i - \bar{y} \right)^2} \quad (3.88)$$

3.9.6. Karar ağaçları ve rastgele karar ormanı (Random Forest, RF) algoritması


Karar ağacı, piramit benzeri bir yapıya sahip olan veya ters ağaç benzeri bir yapı diyebileceğimiz bir tür makine öğrenimi algoritmasıdır. Sınıflandırma ve regresyon problemlerini çözmek için kullanılır. Ağaç benzeri yapıyı taklit eder. Yaprak olmayan her düğüm bir girdi özelliğini temsil eder. İç düğümden (yaprak olmayan düğümler) dallanan yaylar bir girdi özelliği ile işaretlenir. Bu yaylar hedef veya çıktı özelliğinin olası

değerleri ile eşleştirilir. Ayrıca farklı bir girdi özelliği üzerinde bir alt karar düğümüne de yol açabilir. Bir ağacın en üst düğümü kök düğüm olarak adlandırılır. Her yaprak bir sınıf veya sınıf üzerinde bir olasılık dağılımı ile işaretlenir. Bu, veri kümesinin benzersiz bir sınıfa veya olasılık dağılımına sınıflandırıldığını gösterir. Şekil 3.99'da RF algoritması genel gösterimi görülmektedir.



Şekil 3.99. Rastgele orman algoritması genel gösterim

Rastgele orman, karar verme için çoklu karar ağaçlarının bir kombinasyonudur. Bir eğitim zamanında çok sayıda karar ağacına sahiptir. Her bir ağacın sınıfının modunu çıkarır. Ayrıca karar ağaçlarının aşırı solması sorununu da çözer. Bir topluluk öğrenme yöntemidir. Rastgele ormandaki her bir ağaç bir sınıf tahmini hakkında bilgi verir. Maksimum oy alan sınıf tahmin modelimiz olarak seçilir. Modeller arasındaki düşük korelasyon anahtar noktadır. Rastgele orman optimum sınıflandırma performansı sağlar çünkü ağaçlar birbirlerini bireysel hatalarından korurlar (sürekli aynı yönde hata yapmadıkları sürece). Karar ağaçları, üzerinde eğitildikleri verilerdeki değişikliklere karşı çok hassastır. Eğitim setindeki küçük değişiklikler bile farklı ağaç yapısına neden olur. Dolayısıyla, performans da değişir (Peltarion, 20211). Şekil 3.100'de RF algoritma kodunun akış diyagramı görülmektedir.



Şekil 3.100. Kodun akış diyagramı

3.9.6.1. Temel özellikler ve avantajlar

Yüksek Doğruluk: Rastgele Orman, birçok durumda yüksek doğruluk oranları sağlar ve karmaşık veri setlerini iyi bir şekilde işleyebilir.

Aşırı Uyuma Direnci: Birden fazla karar ağacının kullanılması ve her ağacın farklı veri alt kümeleri üzerinde eğitilmesi, modelin aşırı uyuma karşı dirençli olmasını sağlar.

Öznitelik Önemi: Rastgele Orman, her bir özniteliğin tahminler üzerindeki etkisini değerlendirme imkanı sunar. Bu, modelin yorumlana bilirliliğini artırır ve önemli öznitelikleri belirlemede yardımcı olur.

Esneklik: Hem sınıflandırma hem de regresyon görevlerinde etkili bir şekilde kullanılabilir.

Kolay Uygulanabilirlik: Rastgele Orman algoritması, çeşitli programlama dillerinde ve makine öğrenmesi kütüphanelerinde kolayca uygulanabilir.

3.9.6.2. Hiper parametreler

Rastgele Orman algoritmasının performansını etkileyen çeşitli hiper parametreler vardır:

Ağaç Sayısı ($n_estimators$): Ormanda kullanılacak karar ağacı sayısıdır.

Maksimum Derinlik (max_depth): Her bir karar ağacının maksimum derinliğidir.

Minimum Örnek Sayısı ($min_samples_split$): Bir düğümün dallanmadan önce içermesi gereken minimum örnek sayısıdır.

Minimum Yaprak Örnek Sayısı ($min_samples_leaf$): Bir yaprağın (son düğüm) içermesi gereken minimum örnek sayısıdır.

Öznitelik Sayısı ($max_features$): Her bir bölünmede dikkate alınacak maksimum öznitelik sayısıdır.

Bootstrap ($bootstrap$): Her bir karar ağacını eğitmek için örneklerin bootstrap yöntemiyle seçilip seçilmeyeceğini belirler.

Bu hiper parametrelerin uygun şekilde ayarlanması, modelin performansını optimize etmek için kritik öneme sahiptir. Genellikle, bu hiper parametrelerin en iyi kombinasyonunu bulmak için çapraz doğrulama (cross-validation) gibi teknikler kullanılarak bir dizi deneme yapılır.

3.9.6.3. Rastgele orman modelinin değerlendirme metrikleri

Modelimizin performansını değerlendirmek için çeşitli istatistiksel metrikler kullanılmıştır. Aşağıda, kullanılan metriklerin detayları ve formülleri yer almaktadır:

Test Skoru: Modelin test veri seti üzerindeki doğruluk oranını gösterir.

R Kare (R^2): Modelin bağımlı değişkenin varyansını ne kadar açıkladığını gösterir.

$$R^2 = 1 - \left[\frac{\text{ToplamKarelerinToplam}}{\text{KalanKarelerinToplamı}} \right] \quad (3.89)$$

Düzeltilmiş R Kare ($Adjusted R^2$): R Kare değerinin örnek sayısı ve bağımsız değişken sayısına göre düzeltilmiş halidir.

$$Düzeltilmiş R^2 = 1 - \left[(1 - R^2) * (n - 1) / (n - k - 1) \right] \quad (3.90)$$

MSE (Mean Squared Error): Ortalama kare hatası, tahminlerin gerçek değerlerden ne kadar uzak olduğunu bir ölçüsüdür (Denklem 3.77).


RMSE (Root Mean Squared Error): MSE'nin kareköküdür ve hataların ölçeğini orijinal verilerin ölçeğine getirir.

$$RMSE = \sqrt{MSE} \quad (3.91)$$


MAE (Mean Absolute Error): Ortalama mutlak hata, tahminlerin gerçek değerlerden ne kadar uzak olduğunu bir ölçüsüdür (Denklem 3.76).

3.9.7. XGBoost (Extreme Gradient Boosting) gradyan arttırma algoritması

XGBoost, sınıflandırma, regresyon ve sıralama gibi çeşitli makine öğrenmesi görevlerinde kullanılan popüler ve verimli bir gradyan artırma kütüphanesidir. XGBoost, karar ağaçlarına dayalı bir ensemble yöntemi olan gradyan artırma algoritmasının optimize edilmiş bir versiyonudur. Bu algoritma, büyük veri setleri üzerinde hızlı ve yüksek performanslı çalışmasıyla bilinir. XGBoost algoritmasının Şekil 3.101'de genel gösterimi ve Şekil 3.102'de akış diyagramı görülmektedir.



Şekil 3.101. XGBoost algoritmasının genel gösterimi



Şekil 3.102. XGBoost modelinin akış diyagramı

3.9.7.1. Temel özellikler ve avantajlar

Yüksek Performans: XGBoost, paralel işlemeyi ve donanım optimizasyonunu destekleyerek hızlı ve verimli bir şekilde çalışır.

Ölçeklenebilirlik: Büyük veri setlerinde ve dağıtık bilgi işlem ortamlarında etkili bir şekilde ölçeklenebilir.

Esneklik: Sınıflandırma, regresyon ve sıralama gibi çeşitli makine öğrenmesi görevlerinde kullanılabilir.

Düzenleştirme: Aşırı uyuma (overfitting) karşı korunmak için L1 ve L2 düzenleştirme terimlerini içerir.

Öznitelik Önemi: Modelin yorumlanaabilirliğini artırarak önemli öznitelikleri belirlemede yardımcı olur.

3.9.7.2. Hiper parametreler

XGBoost algoritmasının performansını etkileyen çeşitli hiper parametreler vardır:

learning_rate (eta): Öğrenme oranı, her adımda yapılan ağaç ağırlık güncellemesinin boyutunu kontrol eder.

n_estimators: Oluşturulacak ardışık ağaç sayısıdır.

max_depth: Her bir ağacın maksimum derinliğidir.

min_child_weight: Bir düğümün dallanması için gereken minimum ağırlık toplamıdır.

gamma: Dallanma için gereken minimum kayıp azalmasıdır.

subsample: Her bir ağaç için rastgele seçilen örneklerin oranıdır.

colsample_bytree: Her bir ağaç için rastgele seçilen özniteliklerin oranıdır.

lambda (reg_lambda): L2 düzenleme teriminin ağırlığıdır.

alpha (reg_alpha): L1 düzenleme teriminin ağırlığıdır.

Bu hiper parametrelerin uygun şekilde ayarlanması, modelin performansını optimize etmek için önemlidir.

3.9.7.3. XGBoost modelinin değerlendirme metrikleri

XGBoost modelinin performansını değerlendirmek için çeşitli istatistiksel metrikler kullanılır:

Accuracy: Modelin sınıflandırma görevlerindeki doğruluk oranını gösterir.

R² (R Squared): Modelin regresyon görevlerinde bağımlı değişkenin varyansını ne kadar açıkladığını gösterir.

MSE (Mean Squared Error): Ortalama kare hatası, tahminlerin gerçek değerlerden ne kadar uzak olduğunun bir ölçüsüdür.

RMSE (Root Mean Squared Error): MSE'nin kareköküdür ve hataların ölçeğini orijinal verilerin ölçeğine getirir.


MAE (Mean Absolute Error): Ortalama mutlak hata, tahminlerin gerçek değerlerden ne kadar uzak olduğunun bir ölçüsüdür.

Bu metrikler, modelin performansını değerlendirmede ve farklı modellerin karşılaştırılmasında kullanılır.

3.9.8. Destek vektör makinesi (SVM-SVR)


SVM sınıflandırma problemleri için güçlü bir araçtır. Vladimir Vapnik 1994 yılında SVM'yi tanıtmıştır. SVM algoritması sonsuz boyutlu bir uzayda bir hiper düzlem veya hiper düzlem kümesi oluşturur. Marjın maksimum olduğu hiper düzlem en uygun hiper düzlemdir. Böylece SVM, iki sınıf arasındaki ayrımın mümkün olduğunca geniş olacağı şekilde bir karar sınırı oluşturmaya çalışır. Küçük veri tabanı durumları ve makine arıza tespiti için SVM, sınıflandırmalar için etkili bir araçtır. SVM, çekici özellikleri ve

iyi deneysel performansı nedeniyle makine arıza tespiti alanında popülerdir. İkili sınıflandırma SVM'nin temel bir modelidir (Kecman, 2001). Ancak, SVM'in regresyon problemlerine uyarlanmış bir versiyonu olan SVR (Support Vector Regression) da mevcuttur. SVM ve SVR, veri setindeki örnekler arasında en iyi ayrımı veya tahmini yapmayı amaçlar. Temelde iki sınıflı bir problemidir ve uzayda iki sınıfı en iyi şekilde ayırmak için hiper düzlem çizilir. Bu hiper düzlem, algoritmaya bir kez verildiğinde yeni verileri ayırmak için kullanılır. SVM ve SVR'ın temel fikri Şekil 3.103'te gösterilmektedir.



Şekil 3.103. Pozitif ve negatif sınıflar

Pozitif (+) işareti ve negatif (-) işareti ile temsil edilen iki sınıf vardır. İki sınıfı ayırmak için bir sınır (veya hiper düzlem) çizer. Sınır, sınır ile her iki sınıfın en yakın veri noktaları arasındaki mesafe maksimize edilecek şekilde yapılır. Marj, marj seviyesi ile hata arasında pazarlık olarak tutulur. İki sınıfı ayırmak için çok sayıda hiper düzlem çizilebilir (Şekil 3.103'te gösterildiği gibi), ancak sınıfların her iki tarafındaki en yakın veri noktasından maksimum uzaklığa sahip hiper düzlem en iyi fit ve doğruluk için seçilecektir. Şekil 3.104, iki sınıfı en iyi şekilde ayıran hiper düzlemi, yani pozitif (+) işareti ve negatif işareti (-) göstermektedir. SVM sınıflandırma problemi bir optimizasyon tekniği ile çözülür, böylece marj maksimum tutulur ve hata minimum olur.



Şekil 3.104. SVM modelin Destek vektör makinesi genel gösterimi

Son olarak, yeni verilerin sınıfını tahmin edebilen SVM modelleri geliştirilir. ML'deki geleneksel yaklaşım, eğitim veri setindeki hatayı en aza indirmektir ve buna ampirik risk minimizasyonu denir. Ancak, SVM yapısal risk minimizasyonuna dayanmaktadır (Kecman, 2001; Cover ve diğ., 1967). SVM büyük veri setlerini verimli bir şekilde işleyebilir. SVM'nin eğitimi, sınıflandırılan vektörün boyutunun SVM'nin performansını etkilemeyecek ve onu geleneksel sınıflandırıcılardan ayıracak şekilde yapılır. Genel olarak bu yöntem, ampirik risk minimizasyonuna dayalı yöntemlere göre daha iyi genelleme yetenekleri sağlar. Bu, özellik sayısının sınırlı olması gerekmediğinden giriş parametreleri sınıflandırma probleminde avantajlıdır. Genel olarak, bu sınıflandırıcılar geleneksel sınıflandırıcılara kıyasla iyi sınıflandırma özelliklerine sahiptir. Destek vektörü, sınıflandırıcıyı tanımlamak için gereken bilgileri içerir ve destek vektörleri uygun şekilde seçildiğinde, geri kalan özellik çok fazla ilgi çekmez. Doğrusal ve doğrusal olmayan sınıflandırma problemlerini çözmek için kullanılabilir. Doğrusal olmayan sınıflandırma için Gauss, kuadratik ve kübik gibi Kernel fonksiyonları gereklidir.

SVM'in regresyon problemlerine uyarlanmış bir versiyonu olan SVR'da mevcuttur. SVM ve SVR, veri setindeki örnekler arasında en iyi ayrımı veya tahmini yapmayı amaçlar. SVR, veri setindeki örnekleri temsil eden vektörler arasında bir hiper düzlem oluşturarak çalışır. Bu hiper düzlem, regresyon çizgisi olarak düşünülebilir. SVR'ın amacı, hiper düzlemi öyle bir şekilde belirlemektir ki, bu düzlem tüm örnekler arasındaki hata miktarını minimize ederken, aynı zamanda düzleme en yakın örnekler arasındaki marjı maksimize eder.

SVR'da marj, hiper düzlem etrafındaki boşluk olarak tanımlanır. Destek vektörleri ise marj sınırlarına en yakın olan örneklerdir. Bu örnekler, hiper düzlemin konumunu belirlemede kritik öneme sahiptir. SVR, marjı maksimize ederek ve destek vektörlerini kullanarak daha genelleştirilebilir ve dayanıklı bir model oluşturmayı hedefler.

SVR, hata miktarını ölçmek için genellikle epsilon-duyarlı kayıp fonksiyonu kullanır. Bu fonksiyon, belirli bir epsilon değeri içindeki hataları göz ardı eder, bu da modelin küçük sapmalara karşı toleranslı olmasını sağlar. Ayrıca, modelin aşırı uyumunu önlemek için düzenleştirme terimi de eklenir. Düzenleştirme, modelin karmaşıklığını kontrol ederek, daha basit bir modelin tercih edilmesine yardımcı olur.

3.9.8.1. Çalışma mekanizması

SVR, aşağıdaki adımları izleyerek çalışır:

Veri Hazırlığı: Veri seti, öznitelikler ve hedef değişken olmak üzere iki bölüme ayrılır.

Hiper Düzlem Seçimi: Veri setindeki örnekleri en iyi şekilde temsil eden hiper düzlem belirlenir.

Marj Maksimizasyonu: Hiper düzlem etrafındaki marjı maksimize edecek şekilde model parametreleri ayarlanır.

Optimizasyon: Modelin performansını en üst düzeye çıkarmak için destek vektörleri ve düzenleştirme terimi kullanılarak bir optimizasyon problemi çözülür.

3.9.8.2. SVR Hiper parametreleri

SVR modelinin performansı, seçilen hiper parametrelere bağlıdır. Bu hiper parametreler, modelin karmaşıklığını, toleransını ve genelleştirme yeteneğini etkiler. İşte SVR'da sıklıkla ayarlanan bazı önemli hiper parametreler:

C (Ceza Parametresi)

Açıklama: C, modelin hata terimine ne kadar ceza vereceğini belirler. Yüksek bir C değeri, modelin eğitim verilerine daha fazla uyum sağlamasını sağlar, ancak aşırı uyuma (overfitting) riskini artırabilir. Düşük bir C değeri, modelin daha genelleştirilmiş olmasını sağlar, ancak alt uyuma (underfitting) riskini artırabilir.

Ayar: C değeri, genellikle çapraz doğrulama (cross-validation) yöntemiyle belirlenir. Farklı C değerleri deneyerek, en iyi performansı veren değer seçilir.

Epsilon (ϵ)

Açıklama: Epsilon, kayıp fonksiyonunda kullanılan bir parametredir. Bu değer, modelin hedef değerlerle olan sapmalarını ne kadar tolere edeceğini belirler. Epsilon değeri büyükse, model küçük hataları görmezden gelir, bu da daha pürüzsüz bir regresyon çizgisi oluşturur.

Ayar: Epsilon değeri de çapraz doğrulama ile ayarlanabilir. Farklı epsilon değerleri için modelin performansı karşılaştırılarak en uygun değer seçilir.

Kernel Türü

Açıklama: SVR, doğrusal olmayan regresyon problemlerini çözmek için çeşitli kernel fonksiyonları kullanabilir. Bu kernel fonksiyonları, öznitelik uzayını daha yüksek boyutlu bir uzaya dönüştürerek, doğrusal olmayan ilişkilerin yakalanmasını sağlar.

Yaygın Kernel Türleri:

Lineer Kernel: Doğrusal ilişkiler için kullanılır.

Polinom Kernel: Polinom derecesi arttıkça, model daha karmaşık ilişkileri yakalayabilir.


Radyal Temel Fonksiyon (RBF) Kernel: Genellikle doğrusal olmayan ilişkiler için tercih edilir ve iki örnek arasındaki benzerliği ölçer.

Ayar: Kernel türü, problemin doğasına ve veri setinin özelliklerine bağlı olarak seçilir. Çapraz doğrulama, en uygun kernel türünü belirlemek için kullanılabilir.

Gamma (γ)

Açıklama: Gamma, RBF kerneli gibi bazı kernel türlerinde kullanılan bir parametredir. Gamma değeri, kernel fonksiyonunun "genişliğini" belirler ve modelin öğrenme esnekliğini etkiler.

Ayar: Gamma değeri, çapraz doğrulama ile ayarlanabilir. Yüksek bir gamma değeri, modelin eğitim verilerine daha fazla uyum sağlamasına neden olurken, düşük bir gamma değeri, modelin daha genelleştirilmiş olmasını sağlar. Şekil 3.105'te SVM modelinin genel akış diyagramı görülmektedir.



Şekil 3.105. SVM modelinin genel akış diyagramı

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Tez çalışmasının 'Bölüm 3: MATERYAL VE YÖNTEM' bölümünde laboratuvar ortamında kurulan sistemi oluşturan bileşenlerden bahsedilmiştir. Ayrıca yapılan yazılımın detayı, yükleme sistemi için tasarlanan elektriksel ve mekaniksel yük modellerine yer verilmektedir. Kurulan ve tasarlanan sistemle planlanan tüm deneyler gerçekleştirildi. Sonuç olarak elde edilen verilerin grafiksel gösterimi ve grafiklerin yorumlanması gene bu bölümde verildi.

Tezin 4. bölümünde sistemde yapılan deneyler sonucu elde edilen veri yığınlarının analizi üzerinde durulmuştur. Bunun için daha önceki bölümlerde genel bilgilerle bahsedilen iki analiz yöntemi üzerinde yoğunlaşıldı. Bu yöntemler ilk olarak Taguchi, ikinci olarak ise makine öğrenimi üzerinde durulmuştur.

4.1. Giriş Parametre Optimizasyonu

4.1.1. Taguchi analiz uygulaması

Taguchi özellikle parametre tasarımında istatistiksel deney tasarımı yöntemini esas almıştır. Bu yöntem ile çoğu faktörün ürün veya prosese olan etkisini ekonomik bir şekilde belirleyerek varyasyon oluşturan faktörlere karşı önlemleri tasarım halindeyken alınabilir. Parametre tasarımı oluşturulmasının gerekçesi, ürünün ve süreçteki değişebilirlik (hedeften farklılık) durumunun oluşumuna neden olan kontrol edilmesi zor faktörlere karşı, kontrol edilebilecek durumda olan faktörlerin en iyi seviyesini görerek ve seçerek, ürün ve süreçteki değişebilirlik durumunu en az seviyeye düşürmektir (Taguchi ve ark., 2005). Taguchi yönteminde ürün verimini etkileyen değişkenlik durumunu azaltarak, ürünün oluşum aşamasını, kullanımını ve bakımı sırasında meydana gelebilecek maliyetleri en aza indirmek şeklinde parametrelerin en iyi değerleri tespit edilir. Taguchi, deney tasarımında analiz değişkeni ya da verimlilik kriteri olarak kullanılması sebebi ile, “sinyal/gürültü oranı” denilen bir kriter oluşturulmuştur (Taylan, 2009; Şirvancı, 1997). Bu yöntemde, öncelikle bütün kalite değişkenlerinin uygun performans kriterine göre S/N oranları bulunur. Elde edilen S/N oranları herhangi bir analiz yöntemine tabi tutularak optimal değerler bulunur (Işık, 2000). S/N, ortalamanın (sinyal) standart sapmaya (gürültü) olan oranı olarak tanımlanmaktadır. Ölçülmek istenen gerçek değer sinyal değeri, ölçülen değer içindeki istenmeyen paya ise gürültü

değeri denmektedir. Ayrıca, gürültü faktörleri, ürünün belirlenen hedeften sapmasına neden olan değişkenler olarak da bilinmektedir. Bu sebepten dolayı, gürültünün sistem üzerindeki etkisinin mümkün olduğunca azaltılması gerekmektedir (Taylan, 2009).

Bu bölümün ilk kısmı çalışmada Taguchi analizinden faydalanılarak elde edilen sonuçlar ortaya konulmuştur. Daha önce de vurgulanan laboratuvar ortamında gerçek deneylerle gerçekleştirilen çalışmalar; deney alanı, süre ve maliyet gibi birçok dezavantaja sahiptir. Ayrıca bu deneylerin her zaman farklı koşullarda tekrarlanması da mümkün değildir. Taguchi deneysel tasarımlarda yapılması planlanan deneylerin hepsinin yapılmasına gerek kalmadan daha az deney verisiyle genel sonuca varmayı sağlamıştır. Taguchi sonuçları ile sistem deney sonuçları karşılaştırılarak veri analizin doğruluğu ve tutarlılığı kesinleştirilmiştir. Ayrıca giriş olarak belirlenen parametrelerin motor ECP parametreleri üzerindeki etkinlik oranlarının belirlenmesinde de Taguchi yönteminden faydalanılmaktadır. Böylece literatürde karşılaşılan önemli sorunlardan biri olan giriş değişkenlerindeki çeşitlilik ve değişkenliğin artmasıyla matematiksel modellemenin başarı oranında düşme, zorlaştırması ve karmaşılaştırması probleminin çözümü sağlandı. Bu analiz sonucu 'Regresyon Analiz' yöntemiyle gerçekleştirilen matematiksel modellemede başarı yüzdesi olan (R^2) oranı iyileştirildi.

Çalışmada giriş parametrelerinin/çıkış parametreler üzerindeki en büyük etkisi bulunmak istendiği için "ne kadar büyük olursa o kadar iyi" fonksiyonu kullanılmıştır (Purvee).

$$S/N = -10 \cdot \log_{10} \left(\frac{\sum (1/Y^2)}{n} \right) \quad (4.1)$$

S/N: en büyük değer en iyi durumu için sinyal/gürültü oranı

S: Standart sapma

N: Ortalama

Y: Gözlenmiş değer

n: Gözlem sayısı (bir denemede test sayısı)

Taguchi kodlaması için değişken sayıları eşit olmalıdır. Bu yüzden 4 farklı motor (0,75kW-1,5kW-2,2kW ve 4 kW), 4 farklı rotor devri (375-750-1125-1500 d/dk), dört farklı yük oranı (%25- %50- %75- %100) üzerinde analiz gerçekleştirilmiştir. Giriş olarak belirlenen parametreler Çizelge 4.1'de listelenmiştir. Bu üç parametre (P, n, T_y), diğer giriş

parametreleriyle (U, I, f ve pf) karşılaştırıldığında motor çıkışları üzerinde en büyük etkiye sahip oldukları için seçilmiştir.

Çizelge 4.1. Giriş parametreleri

Giriş Parametreleri	Sembol	Ölçü Birimi	Deneysel Seviyeler			
			1	2	3	4
Motor Gücü	P	kW	0,75	1,5	2,2	4
Devir	n	rpm	375	750	1125	1500
Yük	Ty	%	25	50	75	100


Motor gücü, rotor hızı, yük oranı gibi 3 farklı değerdeki giriş parametrelerinden Taguchi deney planlaması oluşturularak 64 deney içinden 16 deneyin gerçek laboratuvar verileri ile analizinin mümkün olacağı belirlenmiştir. Giriş parametrelerini eşzamanlı olarak optimize etmenin etkili bir yolu olan, L16 ortogonal dizileri kullanarak deneyler planlanmıştır. Taguchi ile oluşturulan L16 ortogonal dizisi ve deneysel sonuçlardan elde edilen R_s , X_s , R_2 , X_2 , R_m , X_m , Δt , s çıkış parametrelerinin yüzdesel değişim değerleri Çizelge 4.2’de verilmiştir.

Çizelge 4.2. Kodlanan çıkış parametreleri

Veri Adeti	P	n	Ty	Çıkış Parametreleri							
				R_s	R_2	X_s	X_2	R_m	X_m	Δt	s
1	1	1	1	8,53659	28,62272	3,79587	3,77991	116,38254	4,02863	89,12134	0,06979
2	1	2	2	9,58084	9,92805	0,80389	0,79934	16,33237	6,79368	85,81315	0,04587
3	1	3	3	14,72393	14,61091	0,02138	0,02138	16,79671	12,86447	157,33333	0,04339
4	1	4	4	14,63415	32,54935	10,32319	10,31628	13,82206	18,14001	148,33333	0,03282
5	2	1	2	17,05069	8,26505	0,28123	0,27791	5,03892	3,07426	184,40367	0,08154
6	2	2	1	12,94299	4,96732	0,46163	0,46163	13,43354	13,98466	149,76077	0,02219
7	2	3	4	19,00452	32,43401	4,72951	4,72244	16,04953	15,31073	164,81481	0,03757
8	2	4	3	15,30139	4,12945	3,50908	3,50320	1,24798	0,22812	181,09453	0,02613
9	3	1	3	20,55138	14,62792	1,31179	1,31654	11,67937	48,66062	197,10744	0,09651
10	3	2	4	27,29592	24,75357	19,68937	19,68937	26,38174	31,27294	325,26316	0,05913
11	3	3	1	8,81612	66,66375	3,17581	3,16860	52,15286	2,81109	99,55752	0,02094
12	3	4	2	15,73604	19,46811	3,58048	3,58048	3,87750	3,92626	187,68473	0,01785
13	4	1	4	32,02614	29,73434	1,63235	1,63235	21,73834	50,64947	353,46535	0,11804
14	4	2	3	21,88006	23,96540	6,37441	6,38873	0,25541	3,72841	224,33628	0,04779
15	4	3	2	14,69649	30,55094	6,14986	6,14986	4,32691	9,95289	133,58491	0,01527
16	4	4	1	9,95185	5,80777	1,80879	1,80879	5,12756	7,12007	95,66929	0,01112

Deneyssel olarak elde edilen 16 çıkış değeri, [3] ve [4] kullanılarak "Ne kadar büyük olursa o kadar iyi" kayıp fonksiyonunu oluşturmak için kullanıldı. Taguchi analizi sonucu giriş değişkenlerinin hangi çıkış değişkenlerinin üzerinde etkisi olduğu analizi yapılmıştır. Üzerinde etkisi en fazla olan çıkış parametrelerinin analiz sonuçları Çizelge 4.2.'de renkli olarak belirtilmiştir. Burada giriş olarak belirlenen parametrelerin (P, n, Ty), çıkış parametreleri R_s , R_2 , R_m , Δt , s üzerinde oldukça etkili olduğu görülmektedir. Bunlar her parametre üzerinde incelenecek olursa;

R_s parametresine ait ana etkiler grafiği Şekil 4.1 ve Çizelge 4.3'te görülmektedir.




Şekil 4.1. R_s çıkış parametresinin (a) ana etkiler grafiği, (b) SN oranlarının artık grafikleri

Çizelge 4.3. R_s çıkış parametresinin SN oranları için varyans analizi


SN oranları için Varyans Analizi							
Kaynak	DF	Seq SS	Adj SS	Adj MS	F	P	PC (%)
p	3	34,46	34,46	11,486	5,97	0,031	20,41
n	3	14,57	14,57	4,858	2,53	0,154	8,63
T _y	3	108,19	108,19	36,063	18,76	0,002	64,10
Ölç.Hatası	6	11,54	11,54	1,923			R ²
Toplam	15	168,76					93,16%

Şekilde verilen ana etkiler grafiğinden anlaşılabacağı üzere Motor gücünün 4. Seviyesi, Devir sayısının 1. Seviyesi, Yükün ise 4. Seviyesi en etkili seviyelerdir. Daha açık olarak, P4n1Ty4 etkili parametre seviyeleri göstermektedir. Seviyeler arasında doğruların eğimi etkililik oranını/miktarını gösterir.

R_2 parametresine ait ana etkiler grafiği Şekil 4.2 ve Çizelge 4.4'te görülmektedir.



(a)



(b)


Şekil 4.2. R_2 çıkış parametresinin (a) ana etkiler grafiği, (b) SN oranlarının artık grafikleri

Çizelge 4.4. R_2 çıkış parametresinin SN oranları için varyans analizi


SN oranları için Varyans Analizi							
Kaynak	DF	Seq SS	Adj SS	Adj MS	F	P	PC (%)
p	3	203,5	203,5	67,82	2,25	0,183	28,58
n	3	189,3	189,3	63,08	2,09	0,203	26,59
T _y	3	138,1	138,1	46,03	1,53	0,301	19,39
Ölç.Hatası	6	181,1	181,1	30,18			R ²
Toplam	15	711,9					74,56%

Şekilde verilen R_2 çıkış parametresinin ana etkiler grafiğinden anlaşılabacağı üzere Motor gücünün 3. Seviyesi, Devir sayısının 3. Seviyesi, Yükün ise 4. Seviyesi en etkili seviyelerdir. Daha açık olarak, P3n3Ty4 etkili parametre seviyeleri göstermektedir. Seviyeler arasında doğruların eğimi etkililik oranını/miktarını gösterir.

X_s parametresine ait ana etkiler grafiği Şekil 4.3 ve Çizelge 4.5'te görülmektedir.



(a)



(b)


Şekil 4.3. X_s çıkış parametresinin (a) ana etkiler grafiği, (b) SN oranlarının artık grafikleri

Çizelge 4.5. X_s çıkış parametresinin SN oranları için varyans analizi

SN oranları için Varyans Analizi							
Kaynak	DF	Seq SS	Adj SS	Adj MS	F	P	PC (%)
p	3	114,24	114,24	38,08	1,21	0,382	20,55
n	3	51,05	51,05	17,02	0,54	0,671	9,17
T_y	3	201,11	201,11	67,04	2,14	0,197	36,35
Ölç.Hatası	6	188,13	188,13	31,36			R^2
Toplam							66,07%

Şekilde verilen X_s çıkış parametresinin ana etkiler grafiğinden anlaşılabacağı üzere Motor gücünün 3. Seviyesi, Devir sayısının 4. Seviyesi, Yüknün ise 2. Seviyesi en etkili seviyelerdir. Daha açık olarak, P3n4Ty2 etkili parametre seviyeleri göstermektedir. Seviyeler arasında doğruların eğimi etkililik oranını/miktarını gösterir.


R_m parametresine ait ana etkiler grafiği Şekil 4.4 ve Çizelge 4.6'da görülmektedir.

**Şekil 4.4.** R_m çıkış parametresinin (a) ana etkiler grafiği, (b) SN oranlarının artık grafikleri**Çizelge 4.6.** R_m çıkış parametresinin SN oranları için varyans analizi

SN oranları için Varyans Analizi							
Kaynak	DF	Seq SS	Adj SS	Adj MS	F	P	PC (%)
p	3	770,7	770,7	256,9	8,34	0,015	32,42
n	3	479,7	479,7	159,89	5,19	0,042	20,18
T_y	3	941,7	941,7	313,89	10,2	0,009	39,62
Ölç.Hatası	6	184,7	184,7	30,79			R^2
Toplam	15	2376,8					92,23%

Şekilde verilen R_m çıkış parametresinin ana etkiler grafiğinden anlaşılabacağı üzere Motor gücünün 1. Seviyesi, Devir sayısının 1. Seviyesi, Yüknün ise 1. Seviyesi en etkili seviyelerdir. Daha açık olarak, P1n1Ty1 etkili parametre seviyeleri göstermektedir. Seviyeler arasında doğruların eğimi etkililik oranını/miktarını gösterir.

X_m parametresine ait ana etkiler grafiği Şekil 4.5 ve Çizelge 4.7’de görülmektedir.




Şekil 4.5. X_m çıkış parametresinin (a) ana etkiler grafiği, (b) SN oranlarının artık grafikleri

Çizelge 4.7. X_m çıkış parametresinin SN oranları için varyans analizi

SN oranları için Varyans Analizi							
Kaynak	DF	Seq SS	Adj SS	Adj MS	F	P	PC (%)
p	3	457,70	457,70	152,57	2,69	0,140	46,3
n	3	113,95	113,95	37,98	0,67	0,601	11,53
T_y	3	76,37	76,37	25,46	0,45	0,727	7,75
Ölç.Hatası	6	340,13	340,13	56,69			R^2
Toplam	15	988,15					65,58%

Şekilde verilen X_m çıkış parametresinin ana etkiler grafiğinden anlaşılabacağı üzere Motor gücünün 3. Seviyesi, Devir sayısının 1. Seviyesi, Yüknün ise 4. Seviyesi en etkili seviyelerdir. Daha açık olarak, P3n1Ty4 etkili parametre seviyeleri göstermektedir. Seviyeler arasında doğruların eğimi etkililik oranını/miktarını gösterir.

Δt sargı ısısı parametresine ait ana etkiler grafiği Şekil 4.6 ve Çizelge 4.8’de görülmektedir.




Şekil 4.6. Δt sargı ısısı çıkış parametresinin (a) ana etkiler grafiği, (b) SN oranlarının artık grafikleri

Çizelge 4.8. Δt sargı ısısı çıkış parametresinin SN oranları için varyans analizi

SN oranları için Varyans Analizi							
Kaynak	DF	Seq SS	Adj SS	Adj MS	F	P	PC (%)
p	3	43,34	43,34	14,44	2,66	0,142	21,98
n	3	17,84	17,84	5,945	1,1	0,42	9,05
T _y	3	103,52	103,52	34,51	6,37	0,027	52,49
Ölç.Hatası	6	32,53	32,53	5,421			R ²
Toplam	15	197,22					83,51%

Şekilde verilen Δt çıkış parametresinin ana etkiler grafiğinden anlaşılaacağı üzere Motor gücünün 3. Seviyesi, Devir sayısının 1. Seviyesi, Yükün ise 4. Seviyesi en etkili seviyelerdir. Daha açık olarak, P3n1Ty4 etkili parametre seviyeleri göstermektedir. Seviyeler arasında doğruların eğimi etkililik oranını/miktarını gösterir.

s kayma parametresine ait ana etkiler grafiği Şekil 4.7 ve Çizelge 4.9'da görülmektedir.

**Şekil 4.7.** s kayma çıkış parametresinin (a) ana etkiler grafiği, (b) SN oranlarının artık grafikleri**Çizelge 4.9.** s kayma çıkış parametresinin SN oranları için varyans analizi

SN oranları için Varyans Analizi							
Kaynak	DF	Seq SS	Adj SS	Adj MS	F	P	PC (%)
P	3	23,35	23,35	7,783	3,51	0,089	4,34
n	3	379,26	379,26	126,42	56,94	0	70,57
T _y	3	121,46	121,46	40,48	18,24	0,002	22,60
Ölç.Hatası	6	13,32	13,32	2,22			R ²
Toplam	15	537,39					97,52%

Şekilde verilen s çıkış parametresinin ana etkiler grafiğinden anlaşılaacağı üzere Motor gücünün 1. Seviyesi, Devir sayısının 1. Seviyesi, Yükün ise 4. Seviyesi en etkili

seviyelerdir. Daha açık olarak, P1n1Ty4 etkili parametre seviyeleri göstermektedir. Seviyeler arasında doğruların eğimi etkililik oranını/miktarını gösterir.

Parametrelerin Düzeltilmiş R^2 değerlerini toplu olarak Çizelge 4.10'da görülmektedir.

Çizelge 4.10. Parametrelerin Düzeltilmiş R^2 değerleri

PC (%)	R_s	R_2	$X_s=X_2$	R_m	X_m	Δt	s
P	20,41953	28,58548	20,60	32,42595	46,31888	21,97546	4,345075
n	8,633562	26,59081	9,21	20,1826	11,53165	9,045736	70,57444
Ty	64,10879	19,39879	36,27	39,6205	7,728584	52,48961	22,60183
R^2	93,16%	74,56%	66,07%	92,23%	65,58%	83,51%	97,52%
Etkin Durum	P, Ty	P, n	P, Ty	P, Ty	P, n	P, Ty	n, Ty

R^2 ve Düzeltilmiş R^2 , elimizdeki örnekleme açıklayıcı değişkenlerin açıklanan değişkenin değerini kestirmekte ne kadar uygun olduğunu gösterir. Dolayısıyla regresyonun öngörü gücünü ifade eder.

4.1.2. Regresyon analiz uygulaması

Taguchi yöntemiyle çıkış parametreleri üzerinde etkili olan giriş parametrelerinin belirlenmesi dikkate alınarak Varyans Analizi (ANOVA)'da regresyon analizi gerçekleştirildi. Elde edilen matematiksel denklemlerin 2. derece denklemler oluşturularak R^2 değerleri karşılaştırıldı. Regresyon analizde tüm motorlar aynı anda değerlendirildiğinde denklemlerin doğruluk oranı düşmüştür. Bu yüzden her motor için giriş parametrelerin o motorun çıkış parametreleri üzerindeki etkisi göz önünde bulundurarak 2. Derecede denklem oluşturuldu. Aynı zamanda örnekleme sayısını Taguchi 'ye göre artırılarak 880 değer üzerinden gerçekleştirildi. Böylece örnekleme sayısını artırarak analiz sonucu elde edilen denklemlerin düzeltilmiş R^2 değerleri daha yüksek elde edildi. Giriş değişkenlerine Δt ve s eklenerek sayısı artırıldığında R^2 değerlerinde yükselme görülmektedir. Giriş değişkenlerine göre elde edilen matematiksel modelleme Denklem 4.2, 4.3, 4.4 ve 4.5'te görülmektedir.

$$f_{(P,n,T_y)} = a_0 + a_1P + a_2n + a_3T_y + a_4P^2 + a_5n^2 + a_6T_y^2 + a_7Pn + a_8PT_y + a_9nT_y \quad (4.2)$$

$$f_{(P,n,T_y,\Delta t)} = a_0 + a_1P + a_2n + a_3T_y + a_4\Delta t + a_5P^2 + a_6n^2 + a_7T_y^2 + a_8\Delta t^2 \dots \\ + a_9Pn + a_{10}PT_y + a_{11}P\Delta t + a_{12}nT_y + a_{13}n\Delta t + a_{14}T_y\Delta t \quad (4.3)$$

$$f_{(P,n,T_y,s)} = a_0 + a_1P + a_2n + a_3T_y + a_4s + a_5P^2 + a_6n^2 + a_7T_y^2 + a_8s^2 \dots \\ + a_9Pn + a_{10}PT_y + a_{11}Ps + a_{12}nT_y + a_{13}ns + a_{14}T_y s \quad (4.4)$$

$$f_{(P,n,T_y,\Delta t,s)} = a_0 + a_1P + a_2n + a_3T_y + a_4\Delta t + a_5s + a_6P^2 + a_7n^2 + a_8T_y^2 \dots \\ + a_9\Delta t^2 + a_{10}s^2 + a_{11}Pn + a_{12}PT_y + a_{13}P\Delta t + a_{14}Ps \dots \\ + a_{15}nT_y + a_{16}n\Delta t + a_{17}ns + a_{18}T_y\Delta t + a_{19}T_y s + a_{20}s\Delta t \quad (4.5)$$

Denklemlerdeki a katsayılarının listesi EK-1’de verilmiştir. Denklem 4.2 giriş değişkeni olarak P, n ve T_y kabul edildiğinde oluşturulan modellemeyi ifade etmektedir. R² değeri olarak X_s= X₂ %99 üzerinde etkiye sahipken, R₂ ve X_m üzerinde %70 üzerinde etki göstermektedir. Kalan parametrelerde etki daha düşüyor. Denklem 4.3’te Denklem 4.2’deki giriş parametrelerine Δt parametresi dahil edilmiştir. Böylece R_s’de X_s = X₂ gibi %99 üzerinde etkiye sahip olur. Denklem 4.4’te Denklem 4.1’deki giriş parametrelerine s parametresi dahil edilmiştir. Böylece R₂ ve X_m parametreleri %80 üzerine çıkmıştır. Denklem 4.5’te giriş değişkenlerine Δt ve s parametreleri beraber dahil edildiğinde R_s ve X_s= X₂ parametreleri %99 üzerinde R₂ ve X_m parametreleri de %82 üzerinde etkiye sahip olmuştur. Çizelge 4.11’de giriş değişken çeşitlerine göre tüm çıkış parametre 2. dereceden denklemlerinin gösterdikleri R² değerleri listelenmektedir.

Çizelge 4.11. Her motorun giriş değişken çeşitlerine göre çıkış parametrenin gösterdikleri R² değerleri

	0,75kW- R ²				1,5kW- R ²				2,2kW- R ²				4kW- R ²			
	Denk .4.2	Denk .4.3	Denk .4.4	Denk .4.5	Denk .4.2	Denk .4.3	Denk .4.4	Denk .4.5	Denk .4.2	Denk .4.3	Denk .4.4	Denk .4.5	Denk .4.2	Denk .4.3	Denk .4.4	Denk .4.5
	P, n, T _y	P, n, T _y , Δt	P, n, T _y , s	P, n, T _y , Δt, s	P, n, T _y	P, n, T _y , Δt	P, n, T _y , s	P, n, T _y , Δt, s	P, n, T _y	P, n, T _y , Δt	P, n, T _y , s	P, n, T _y , Δt, s	P, n, T _y	P, n, T _y , Δt	P, n, T _y , s	P, n, T _y , Δt, s
R _s	57,97	99,84	66,69	99,86	41,25	99,96	51,07	99,98	46,72	99,91	62,69	99,92	53,86	99,51	79,15	99,52
R ₂	72,42	75,48	81,38	82,76	86,61	88,00	90,85	93,63	35,46	36,75	78,26	81,80	79,58	84,64	90,03	91,17
X _s = X ₂	99,76	99,77	99,78	99,79	99,71	99,71	99,73	99,74	98,28	98,40	98,97	99,05	98,62	98,65	99,35	99,47
R _m	2,64	3,39	2,67	3,56	10,13	10,30	14,38	14,41	2,38	2,40	6,23	6,40	5,39	4,11	5,42	5,75
X _m	78,25	79,69	80,73	82,08	44,84	46,11	53,86	55,16	55,79	59,96	63,59	66,10	76,34	78,85	82,74	84,64

Taguchi yöntemiyle çıkış parametreleri üzerinde etkili olan giriş parametrelerinin belirlendikten sonra ANOVA’da regresyon analizi gerçekleştirildi. Elde edilen 2. Derece

matematiksel denklemlerin R^2 değerleri giriş değişkenlere göre değişimler göstermektedir. P , n , T_y giriş değişkenlerine Δt ve s eklendiğinde parametre denklemlerinin R^2 değerlerinde iyileşme gerçekleştirir. Çizelge 4.11’de verilen bu iyileşme Δt ve s parametreleri giriş olarak ayrı ayrı değerlendirildiğinde R_s , X_s , X_2 parametreleri tüm motor güçlerinde s ’den daha çok Δt ’den etkilendikleri görülmektedir. R_m , R_2 , X_m parametreleri üzerinde ise s parametresi Δt parametresinden daha fazla etkilidir. Her iki parametre (s , Δt) ile oluşturulan denklemlerde doğruluk oranı artmaktadır. Fakat bu bazı parametrelerde oldukça sınırlı bir değişim olarak görülmektedir. Giriş değişken sayısı arttıkça denklem basitlikten uzaklaşmaktadır. Bu yüzden iki parametrenin dahil edildiği denklemlerde değişim az ise etkenliği fazla olan parametrenin girişe dahil edilerek oluşturulan denklemi tercih edilebilir. Bu denklemin daha basit ve karmaşıklığından uzaklaşmasını sağlayarak kullanılabilirliğini artıracaktır. Bu nedenle R_s , X_s , X_2 parametreleri için Δt parametresi içeren Denklem 4.3 uygunken R_2 , R_m , X_m içinse s parametresi içeren Denklem 4.4 uygun görülmektedir. Çizelge 4.12’de çıkış parametrelerine karşı denklemler verilmiştir.

Çizelge 4.12. Çıkış parametrelerine göre regresyon denklemi

Çıkış Par.	Regresyon Denklemi
R_s X_s X_2	$f_{(P,n,T_y,\Delta t)} = a_0 + a_1P + a_2n + a_3T_y + a_4\Delta t + a_5P^2 + a_6n^2 + a_7T_y^2 + a_8\Delta t^2 + a_9Pn + a_{10}PT_y + a_{11}P\Delta t + a_{12}nT_y + a_{13}n\Delta t + a_{14}T_y\Delta t$
R_2 R_m X_m	$f_{(P,n,T_y,s)} = a_0 + a_1P + a_2n + a_3T_y + a_4s + a_5P^2 + a_6n^2 + a_7T_y^2 + a_8s^2 + a_9Pn + a_{10}PT_y + a_{11}Ps + a_{12}nT_y + a_{13}ns + a_{14}T_y s$

Bu tabloya göre regresyon analiz ile Taguchi analiz sonuçlarını birleştirerek oluşturulan denklemlerden doğruluk oranı en yüksek olarak 2. Derece denklemde elde edilmiştir. Çıkış parametrelerin üzerinde etkili olan giriş parametresi oransal ve niteliksel olarak farklılık göstermektedir. Bu yüzden her parametreye özgün lineer denkleme oluşturulmuştur.

Gerçek değer ile belirlenen regresyon denklemlerinden elde edilen sonuçlar karşılaştırılarak sonuçların tutarlılığı ortaya konmuştur. Çizelge 4.13’te bu karşılaştırma verilmektedir.

Çizelge 4.13. Gerçek değerle regresyon denklem sonuçlarını karşılaştırma

			Çıkış Parametreleri											
			R _s			R ₂			X _s			X ₂		
P	n	T _y	Gerçek Değ.	Reg. Denk.	Hata %	Gerçek Değ.	Reg. Denk.	Hata %	Gerçek Değ.	Reg. Denk.	Hata %	Gerçek Değ.	Reg. Denk.	Hata %
0,75	375	0,25	8,54	9,62	12,65	28,62	34,07	19,01	3,80	2,34	38,32	3,80	2,34	38,32
0,75	750	0,5	9,58	10,85	13,24	9,93	10,79	8,67	0,80	1,31	62,77	0,80	1,31	62,77
0,75	1125	0,75	14,72	15,37	4,37	14,61	16,59	13,54	0,02	0,026	34,14	0,02	0,026	34,14
0,75	1500	1	14,63	15,80	7,99	32,55	34,81	6,94	10,32	10,45	1,24	10,32	10,45	1,24
1,5	375	0,5	17,05	17,31	1,54	8,27	10,74	29,89	0,28	0,29	3,17	0,28	0,29	3,17
1,5	750	0,25	12,94	13,10	1,19	4,97	5,48	10,38	0,46	0,59	27,64	0,46	0,59	27,64
1,5	1125	1	19,00	20,56	8,16	32,43	33,67	3,80	4,73	5,02	6,24	4,73	5,02	6,24
1,5	1500	0,75	15,30	15,59	1,88	4,13	5,10	23,52	3,51	3,61	2,93	3,51	3,61	2,93
2,2	375	0,75	20,55	22,67	10,29	14,63	16,45	12,45	1,31	1,86	41,85	1,31	1,86	41,85
2,2	750	1	27,30	28,09	2,89	24,75	30,69	23,99	19,69	19,94	1,29	19,69	19,94	1,29
2,2	1125	0,25	8,82	9,43	6,98	66,66	74,51	11,77	3,18	4,11	29,32	3,18	4,11	29,32
2,2	1500	0,5	15,74	16,66	5,86	19,47	21,16	8,71	3,58	4,82	34,64	3,58	4,82	34,64
4	375	1	32,03	32,84	2,53	29,73	34,47	15,94	1,63	1,95	19,27	1,63	1,95	19,27
4	750	0,75	21,88	22,57	3,13	23,97	31,97	33,39	6,37	7,15	12,11	6,37	7,15	12,11
4	1125	0,5	14,70	15,56	5,90	30,55	35,62	16,59	6,15	6,32	2,83	6,15	6,32	2,83
4	1500	0,25	9,95	10,20	2,48	5,81	6,96	19,91	1,81	1,87	3,52	1,81	1,87	3,52
			Ort. Hata	5,69		Ort. Hata	16,16		Ort. Hata	36,95		Ort. Hata	36,95	
			R ²	95,59%		R ²	66,80%		R ²	58,51%		R ²	58,51%	
			Çıkış Parametreleri											
			R _m			X _m			s			Δt		
P	n	T _y	Gerçek Değ.	Reg. Denk.	Hata %	Gerçek Değ.	Reg. Denk.	Hata %	Gerçek Değ.	Reg. Denk.	Hata %	Gerçek Değ.	Reg. Denk.	Hata %
0,75	375	0,25	116,38	101,79	12,54	4,03	4,03	0,09	0,07	0,07	0,69	89,12	89,35	0,25
0,75	750	0,5	16,33	22,08	35,18	6,79	7,03	3,55	0,05	0,05	1,93	85,81	122,60	42,86
0,75	1125	0,75	16,80	23,48	39,77	12,86	12,91	0,36	0,04	0,04	0,36	157,33	133,35	15,25
0,75	1500	1	13,82	18,42	33,26	18,14	18,55	2,28	0,03	0,03	0,59	148,33	134,72	9,18
1,5	375	0,5	5,04	5,62	11,53	3,07	3,41	10,92	0,08	0,08	2,78	184,40	159,53	13,49
1,5	750	0,25	13,43	14,31	6,53	13,98	14,59	4,36	0,02	0,02	1,45	149,76	120,65	19,44
1,5	1125	1	16,05	19,34	20,52	15,31	14,32	6,50	0,04	0,04	1,33	164,81	218,53	32,59
1,5	1500	0,75	1,25	1,59	27,31	0,23	0,23	2,47	0,03	0,03	9,38	181,09	183,78	1,48
2,2	375	0,75	11,68	15,99	36,89	48,66	51,62	6,08	0,10	0,10	0,52	197,11	223,31	13,29
2,2	750	1	26,38	36,96	40,10	31,27	32,00	2,32	0,06	0,06	3,25	325,26	283,41	12,87
2,2	1125	0,25	52,15	57,40	10,06	2,81	2,88	2,33	0,02	0,02	2,22	99,56	136,34	36,94
2,2	1500	0,5	3,88	4,45	14,67	3,93	4,28	8,95	0,02	0,02	0,60	187,68	174,66	6,94
4	375	1	21,74	19,24	11,48	50,65	52,86	4,36	0,12	0,12	0,39	353,47	367,90	4,08
4	750	0,75	0,26	0,94	266,57	3,73	4,50	20,69	0,05	0,05	4,94	224,34	231,90	3,37
4	1125	0,5	4,33	4,53	4,75	9,95	10,14	1,88	0,02	0,01	5,07	133,58	146,65	9,78
4	1500	0,25	5,13	6,40	24,79	7,12	7,18	0,84	0,01	0,01	8,29	95,67	99,03	3,51
			Ort. Hata	37,25		Ort. Hata	4,87		Ort. Hata	2,74		Ort. Hata	14,08	
			R ²	83,72%		R ²	97,88%		R ²	98,81%		R ²	88,13%	

Gerçek uygulama deneylerinde elde edilen parametre verileri her deney için 2600 veri içermektedir. Yapılan bu çalışmada tüm verileri kayıtların tamamına yer vermek ve

analizi mümkün olmadığı için deney süresince değişim oranları yüzde olarak belirlenmiş ve bu değerler üzerinden analizleri gerçekleştirilmiştir.

Çizelge 4.13'te gerçek değerler ile regresyon analiz sonucu elde edilen denklemlerle elde edilen değerler arasında farkların yüzde olarak düşük olduğu görülmektedir. Ayrıca ortalama hata oranıyla model performansını ölçen R^2 değerleri toplamı %100 yakın değerler çıkması modellemenin tutarlılığını göstermektedir.

4.2. Makine Öğrenimi Uygulaması

Laboratuvar ortamında sistemle yapılan her deneyde belirlenen 11 parametrenin (P , n , T_y , R_s , R_2 , X_s , X_2 , R_m , X_m , Δt , s) her biri için 2.700 veri elde edilmiştir. Planlanarak gerçekleştirilen 100 deneyden toplamda her bir parametre için 270.000 veri toplamda tüm parametreler için 2.970.000 veri yığını mevcuttur. Tüm deneyleri içeren (beş farklı motor gücü- P , dört farklı devir- n , dört farklı yük- T_y ve yüksüz) veri bankasını doğru ve geçerliliği tam olarak analiz etmek için makine öğrenimi analiz yöntemi kullanılmıştır. Bu analiz yöntemlerinde kullanılmak üzere giriş parametreleri ve çıkış parametreleri belirlenmiştir. Analiz için 4 veri seti belirlenmiştir. Bu veri setlerinde giriş ve çıkış parametreleri değişkenlik gösterdi. Böylece giriş parametreleri çeşidinde belirlenen değişkenliklerle çıkış parametre üzerlerinde etkinlik oranlarının değişimi ortaya konulmuştur. Oluşturulan veri setleri ve içerdikleri giriş ve çıkış değişkenliğini Çizelge 4.14'te görülmektedir.

Çizelge 4.14. Veri setlerin içerdiği giriş ve çıkış parametreleri

	Veri Seti 1	Veri Seti 2	Veri Seti 3	Veri Seti 4
Giriş Parametreleri	P , n , T_y	P , n , T_y , Δt	P , n , T_y , s	P , n , T_y , Δt , s
Çıkış Parametreleri	R_s , R_2 , X_s , X_2 , R_m , X_m , Δt , s	R_s , R_2 , X_s , X_2 , R_m , X_m , s	R_s , R_2 , X_s , X_2 , R_m , X_m , Δt	R_s , R_2 , X_s , X_2 , R_m , X_m

Motor giriş ve çıkış parametrelerine ve veri yığına göre en uygun algoritma yöntemi olarak beş farklı makine öğrenme yöntemi belirlenmiştir. Bu yöntemler; BPNN, MLP, KNN, RF, XGBoost algoritmaları kullanarak parametre analizi gerçekleştirildi.

4.2.1. Gerçek verilerde geri yayımlı sinir ağları (BPNN) algoritma uygulaması

Geri Yayımlı Sinir Ağları (Backpropagation Neural Networks - BPNN), yapay sinir ağlarında yaygın olarak kullanılan bir öğrenme algoritmasıdır. Bu algoritma, ağın çıktılarını gerçek değerlerle karşılaştırarak hata miktarını hesaplar ve ardından bu hatayı azaltacak şekilde ağın ağırlıklarını günceller. BPNN, MLP gibi yapay sinir ağları için temel bir öğrenme yöntemidir. Bu konuyla ilgili geniş bilgi Bölüm 3.9.3'te verilmiştir.

Veri seti özellikleri ile modellemede kullanılan parametreler Çizelge 4.15'te verilmiştir.

Çizelge 4.15. BPNN modellerde kullanılan veri setlerinin hiper parametreleri

Özellik / Veri Seti	Veri Seti 1	Veri Seti 2	Veri Seti 3	Veri Seti 4
Giriş Katmanı Boyutu	512	512	512	512
Ara Katmanlar Çıkış Katmanı Aktivasyonu	512, 256, 128, 128, 64	512, 256, 128, 128, 64	512, 256, 128, 128, 64	512, 256, 128, 128, 64
Bırakma (Dropout) Oranı	ReLU	ReLU	ReLU	ReLU
Optimize Edici	0.3	0.3	0.3	0.3
Toplu İşlem (Batch) Boyutu	Adam (lr=0.0001)	Adam (lr=0.0001)	Adam (lr=0.0001)	Adam (lr=0.0001)
Eğitim Döngüsü (Epoch) Sayısı	32	32	32	32
Erken Durdurma (Early Stopping) Sabrı	200	200	200	200
	30	30	30	30

Aktivasyon Fonksiyonu: Nöronların çıktılarını hesaplamak için kullanılan fonksiyondur. Sigmoid, ReLU ve tanh gibi farklı aktivasyon fonksiyonları, öğrenme sürecinin dinamiklerini etkileyebilir.

Dropout Rate: "Bırakma" terimi, bir sinir ağındaki birimlerin (hem gizli hem de görünür) bırakılmasını ifade eder. Basitçe söylemek gerekirse, bırakma, rastgele seçilen belirli nöron kümesinin eğitim aşamasında birimlerin (yani nöronların) göz ardı edilmesi anlamına gelir. "Yok sayma", bu birimlerin belirli bir ileri veya geri geçiş sırasında dikkate alınmamasını ifade etmektedir. Daha teknik olarak, her eğitim aşamasında, tek tek düğümler ya $1-p$ olasılığı ile ağdan çıkarılır ya da p olasılığı ile tutulur, böylece azaltılmış bir ağ kalır; çıkarılan bir düğüme gelen ve giden kenarlar da çıkarılır. Aşırı uyumu önlemek için kullanılır.

Toplu İşlem Boyutu (Batch Size): Eğitim sırasında ağıza verilen veri seti parçalarının boyutudur. Toplu işlem boyutu, bellek kullanımını ve eğitim hızını etkiler.

Eğitim Döngüsü (Epoch) Sayısı: Tüm eğitim veri setinin ağıda kaç kez ileri ve geri yayılım yapacağını belirler. Daha fazla epoch, genellikle daha iyi öğrenme performansı anlamına gelir, ancak aşırı uyum (overfitting) riskini artırabilir.

Early stopping: Makine öğreniminde erken durdurma, bir öğrenciyi gradyan inişi gibi yinelemeli bir yöntemle eğitirken aşırı uyumu önlemek için kullanılan bir düzenleme biçimidir. Bu tür yöntemler, her iterasyonda eğitim verilerine daha iyi uyması için öğrenciyi günceller. Bu, bir noktaya kadar öğrencinin eğitim seti dışındaki veriler üzerindeki performansını iyileştirir. Ancak bu noktadan sonra, öğrencinin eğitim verilerine uyumunu iyileştirmek, genelleme hatasının artması anlamına gelir. Erken durdurma kuralları, öğrencinin aşırı uyum sağlamaya başlamadan önce kaç iterasyon çalıştırılabileceği konusunda rehberlik sağlar. Erken durdurma kuralları, değişen miktarlarda teorik temele sahip birçok farklı makine öğrenimi yönteminde kullanılmıştır.

Her veri seti ayrı ayrı analiz edilmiştir. Kodların çalışma süreleri Çizelge 4.16'da verilmiştir.

Çizelge 4.16. BPNN kodların çalışma süreleri

VERİ SETLERİ	Çalışma Süresi (Saniye)
Veri Seti 1	1306,015
Veri Seti 2	718,894
Veri Seti 3	679,134
Veri Seti 4	1243,723

Analiz sonucu verilerin R^2 değerleri her veri için Çizelge 4.17'de görülmektedir. Veri Seti 1'de giriş parametresi olarak P , n ve T_y varken çıkış parametrelerin R^2 başarı oranları düşük görülmektedir. Veri seti 2'de giriş parametresi olarak Δt parametresi dahil edildiğinde R^2 başarı oranların yükseldiği görülüyor. Veri Seti 3'te giriş parametrelerine Δt çıkartılarak yerine Veri Seti 1'den farklı olarak s parametresi dahil edildiğinde R^2 başarı oranlarının daha da arttığı gözlemlenmiştir. Veri Seti 4'te ise Veri Seti 1'e hem Δt hem de s parametreleri beraber eklenmiştir. Omik direnç parametrelerin R^2 başarı oranında Veri Seti 2'ye göre artma görülürken Veri Seti 3'e göre daha sınırlı bir artma görülüyor. Uyarım ve kaçak reaktans dirençlerinin hepsi Veri Seti 4'te diğer veri setlerine göre R^2 başarı oranlarında artma gözlemlenmiştir.

Çizelge 4.17. Geri yayılım algoritması kullanılarak elde edilen başarı değerleri

Başarı Yüzdesi (R ²)	Veri Seti 1	Veri Seti 2	Veri Seti 3	Veri Seti 4
R _s	%52,75	% 76	%95,4	% 95
R ₂	%48,66	%70,69	% 93	%90,5
X _s	%82,93	% 89	%94,84	% 95
X ₂	%82,93	% 89	%94,84	% 95
R _m	%73,85	% 84	%89,86	%89,75
X _m	%51,82	% 60	% 72	%75,5
Δt	%39,19	---	% 70	---
s	%76,85	%87,6	---	---
Eğitim Başarı Yüzdesi	% 96	%98,3	% 99	% 99

Farklı parametrelerle (Çizelge 4.18) sinir ağı tekrar eğitildiğinde elde edilen R² başarı oranları Çizelge 4.19’da görülmektedir.

Çizelge 4.18. BPNN modellerde kullanılan veri setlerinin farklı hiper parametreler

Özellik / Veri Seti	Veri Seti 1	Veri Seti 2	Veri Seti 3	Veri Seti 4
Giriş Katmanı Boyutu	128	128	128	128
Ara Katmanlar Çıkış Katmanı Aktivasyonu	ReLU	ReLU	ReLU	ReLU
Bırakma (Dropout) Oranı	0,2	0,2	0,2	0,2
Optimize Edici	Adam (lr=0,0003)	Adam (lr=0,0003)	Adam (lr=0,0003)	Adam (lr=0,0003)
Toplu İşlem (Batch) Boyutu	32	32	32	32
Eğitim Döngüsü (Epoch) Sayısı	200	200	200	200
Erken Durdurma (Early Stopping) Sabrı	30	30	30	30

Çizelge 4.19. Farklı parametreler verilerek çıkan değerler

Başarı Yüzdesi (R ²)	Veri Seti 1	Veri Seti 2	Veri Seti 3	Veri Seti 4
R _s	%52,02	% 69	% 88	% 92
R ₂	%47,09	% 63	% 88	% 90
X _s	%81,72	% 81	% 90	% 93
X ₂	%81,72	% 81	% 90	% 93
R _m	%73,71	% 75	% 84	% 87
X _m	%51,83	% 55	% 64	% 69
Δt	%37,64	---	% 65	---
s	%73,08	% 81	---	---
Eğitim Başarı Yüzdesi	% 95	% 97	%98	% 98

Farklı parametreler de değişim oranlarında farklılıklar olsa da genel analizde bir değişiklik görülmemiştir. Yani sargı ısısını ifade eden Δt ile rotor kaymayı ifade eden s

parametreleri veri setlerine eklendiğinde R^2 başarı oranlarında artma meydana getirmektedir. Bu durum sargı ısı ve rotor kayma oranının çıkış parametrelerinde etkili bir parametre olduklarının açıkça göstermiştir.

Veri setlerinin her biri için model kaybı grafiği ve gerçekte tahmin değer grafikleri EK-2’te ayrı ayrı Şekil EK-2.1- Şekil EK-2.8’de verilmiştir.

4.2.2. Gerçek verilerde çok katmanlı algılayıcılar (MLP) algoritma uygulaması

MLP, derin öğrenme ve sinir ağıları alanında yaygın olarak kullanılan bir model türüdür. Temel olarak, bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanından oluşur. Veri seti özellikleri ile modellemede kullanılan parametreler Çizelge 4.20’de verilmiştir.

Çizelge 4.20. MLP modellerde kullanılan veri setlerinin hiper parametreleri

Özellik / Veri Seti	Veri Seti 1	Veri Seti 2	Veri Seti 3	Veri Seti 4
Giriş Katmanı Boyutu	Giriş değişkenlerine ('X') bağlı olarak dinamik	Giriş değişkenlerine ('X') bağlı olarak dinamik	Giriş değişkenlerine ('X') bağlı olarak dinamik	Giriş değişkenlerine ('X') bağlı olarak dinamik
Ara Katmanlar	256, 512, 256	256, 512, 256	256, 512, 256	256, 512, 256
Çıkış Katmanı Boyutu	Çıkış değişkenlerine ('y') bağlı olarak dinamik	Çıkış değişkenlerine ('y') bağlı olarak dinamik	Çıkış değişkenlerine ('y') bağlı olarak dinamik	Çıkış değişkenlerine ('y') bağlı olarak dinamik
Aktivasyonu Fonksiyonu	ReLU (Gizli Katmanlar), Lineer (Çıkış Katmanı)	ReLU (Gizli Katmanlar), Lineer (Çıkış Katmanı)	ReLU (Gizli Katmanlar), Lineer (Çıkış Katmanı)	ReLU (Gizli Katmanlar), Lineer (Çıkış Katmanı)
Bırakma (Dropout) Oranı	0.3 (1. ve 3. gizli katmanlar), 0.4 (2. gizli katman)	0.3 (1. ve 3. gizli katmanlar), 0.4 (2. gizli katman)	0.3 (1. ve 3. gizli katmanlar), 0.4 (2. gizli katman)	0.3 (1. ve 3. gizli katmanlar), 0.4 (2. gizli katman)
Öğrenme Oranı	0.001	0.001	0.001	0.001
Toplu İşlem (Batch) Boyutu	32	32	32	32
Eğitim Döngüsü (Epoch) Sayısı	100	100	100	100
Düzenleme	L1_L2 (l1=0.01, l2=0.01)	L1_L2 (l1=0.01, l2=0.01)	L1_L2 (l1=0.01, l2=0.01)	L1_L2 (l1=0.01, l2=0.01)
Kayıp Fonksiyonu	MSE (Ortalama Kare Hata)	MSE (Ortalama Kare Hata)	MSE (Ortalama Kare Hata)	MSE (Ortalama Kare Hata)
Metrik	MAE (Ortalama Mutlak Hata)	MAE (Ortalama Mutlak Hata)	MAE (Ortalama Mutlak Hata)	MAE (Ortalama Mutlak Hata)
Callback'ler	ReduceLROnPlateau, EarlyStopping, ModelCheckpoint, TensorBoard	ReduceLROnPlateau, EarlyStopping, ModelCheckpoint, TensorBoard	ReduceLROnPlateau, EarlyStopping, ModelCheckpoint, TensorBoard	ReduceLROnPlateau, EarlyStopping, ModelCheckpoint, TensorBoard

Her katmandaki düğümler (veya nöronlar) bir önceki katmandaki tüm düğümlerle bağlantılıdır, bu da modeli tamamen bağlantılı bir ağ yapar. MLP'ler, karmaşık desenleri ve ilişkileri modelleyebilir ve sınıflandırma, regresyon, tahmin yapma gibi çeşitli görevlerde kullanılabilir. Bu konuyla ilgili geniş bilgi Bölüm 3.9.4'te verilmiştir.

Her veri seti ayrı ayrı analiz edilmiştir. Kodların çalışma süreleri Çizelge 4.21'de verilmiştir.

Çizelge 4.21. MLP kodların çalışma süreleri

VERİ SETLERİ	Çalışma Süresi (Saniye)
Veri Seti 1	3667,28
Veri Seti 2	2980,84
Veri Seti 3	2777,634
Veri Seti 4	2911,62

Analiz sonucu verilerin R^2 değerleri her veri için Çizelge 4.22'de görülmektedir. Veri Seti 1'de giriş parametresi olarak P , n ve T_y varken çıkış parametrelerin R^2 başarı oranları düşük görülmektedir. Veri seti 2'de giriş parametresi olarak Δt parametresi dahil edildiğinde R^2 başarı oranların yükseldiği görülüyor. Veri Seti 3'te giriş parametrelerine Δt çıkartılarak yerine Veri Seti 1'den farklı olarak s parametresi dahil edildiğinde R^2 başarı oranlarının daha da arttığı gözlemlenmiştir. Veri Seti 4'te ise Veri Seti 1'e hem Δt hem de s parametreleri beraber eklenmiştir. Parametrelerin R^2 başarı oranında Veri Seti 2'ye göre artma görülürken Veri Seti 3'e göre veri setlerin arasında çok az değişimler gözlemlendi.

Çizelge 4.22. MLP algoritması kullanılarak elde edilen başarı değerleri

Başarı Yüzdesi (R^2)	Veri Seti 1	Veri Seti 2	Veri Seti 3	Veri Seti 4
R_s	% 60,65	% 76,40	% 90,40	% 90,82
R_2	% 54,78	% 65,09	% 81,78	% 81,69
X_s	% 86,92	% 89,26	% 92,86	% 92,95
X_2	% 86,92	% 89,25	% 93,18	% 93,09
R_m	% 79,40	% 82,78	% 90,13	% 89,51
X_m	% 68,47	% 73,72	% 80,01	% 79,76
Δt	% 62,48	---	% 81,87	---
s	% 80,21	% 77,06	---	---
Eğitim Başarı Yüzdesi	% 72,47	% 79,08	% 87,18	% 87,97

MLP modellerde kullanılan veri setlerinin farklı hiper parametreleri Çizelge 4.23'te verilmiştir.

Çizelge 4.23. MLP modellerde kullanılan veri setlerinin farklı hiper parametreler

Özellik / Veri Seti	Veri Seti 1	Veri Seti 2	Veri Seti 3	Veri Seti 4
Giriş Katmanı Boyutu	Giriş değişkenlerine ('X') bağlı olarak dinamik	Giriş değişkenlerine ('X') bağlı olarak dinamik	Giriş değişkenlerine ('X') bağlı olarak dinamik	Giriş değişkenlerine ('X') bağlı olarak dinamik
Ara Katmanlar	128, 256, 128	128, 256, 128	128, 256, 128	128, 256, 128
Çıkış Katmanı Boyutu	Çıkış değişkenlerine ('y') bağlı olarak dinamik	Çıkış değişkenlerine ('y') bağlı olarak dinamik	Çıkış değişkenlerine ('y') bağlı olarak dinamik	Çıkış değişkenlerine ('y') bağlı olarak dinamik
Aktivasyonu	ReLU (Gizli Katmanlar), Lineer (Çıkış Katmanı)	ReLU (Gizli Katmanlar), Lineer (Çıkış Katmanı)	ReLU (Gizli Katmanlar), Lineer (Çıkış Katmanı)	ReLU (Gizli Katmanlar), Lineer (Çıkış Katmanı)
Bırakma (Dropout) Oranı	0.3 (1. ve 3. gizli katmanlar), 0.4 (2. gizli katman)	0.3 (1. ve 3. gizli katmanlar), 0.4 (2. gizli katman)	0.3 (1. ve 3. gizli katmanlar), 0.4 (2. gizli katman)	0.3 (1. ve 3. gizli katmanlar), 0.4 (2. gizli katman)
Öğrenme Oranı	0.001	0.001	0.001	0.001
Toplu İşlem (Batch) Boyutu	32	32	32	32
Eğitim Döngüsü (Epoch) Sayısı	20	20	20	20
Düzenleme	L1_L2 (l1=0.01, l2=0.01)	L1_L2 (l1=0.01, l2=0.01)	L1_L2 (l1=0.01, l2=0.01)	L1_L2 (l1=0.01, l2=0.01)
Kayıp Fonksiyonu	MSE (Ortalama Kare Hata)	MSE (Ortalama Kare Hata)	MSE (Ortalama Kare Hata)	MSE (Ortalama Kare Hata)
Metrik	MAE (Ortalama Mutlak Hata)	MAE (Ortalama Mutlak Hata)	MAE (Ortalama Mutlak Hata)	MAE (Ortalama Mutlak Hata)
Callback'ler	ReduceLROnPlateau, EarlyStopping, ModelCheckpoint, TensorBoard	ReduceLROnPlateau, EarlyStopping, ModelCheckpoint, TensorBoard	ReduceLROnPlateau, EarlyStopping, ModelCheckpoint, TensorBoard	ReduceLROnPlateau, EarlyStopping, ModelCheckpoint, TensorBoard

Her veri seti ayrı ayrı analiz edilmiştir. Kodların çalışma süreleri Çizelge 4.24'te verilmiştir.

Çizelge 4.24. MLP kodların farklı hiper parametrelerde çalışma süreleri

VERİ SETLERİ	Çalışma Süresi (Saniye)
Veri Seti 1	5100,02
Veri Seti 2	4600,19
Veri Seti 3	4400,65
Veri Seti 4	4000,12

Sinir ağını farklı parametrelerle tekrar eğitildiğinde elde edilen R^2 başarı oranları Çizelge 4.25'te görülmektedir.

Çizelge 4.25. MLP modellerde farklı parametreler verilerek çıkan değerler

Başarı Yüzdesi (R^2)	Veri Seti 1	Veri Seti 2	Veri Seti 3	Veri Seti 4
R_s	% 60,65	% 76,40	% 90,40	% 90,82
R_2	% 54,78	% 65,09	% 81,78	% 81,69
X_s	% 86,92	% 89,26	% 92,86	% 92,95
X_2	% 86,92	% 89,25	% 93,18	% 93,09
R_m	% 79,40	% 82,78	% 90,13	% 89,51
X_m	% 68,47	% 73,72	% 80,01	% 79,76
Δt	% 62,48	---	% 81,87	---
s	% 80,21	% 77,06	---	---
Eğitim Başarı Yüzdesi	% 72,47	% 79,08	% 87,18	% 87,97

Farklı parametreler de değişim oranlarında farklılıklar olsa da genel analizde bir değişiklik görülmemiştir. Yani sargı ısısını ifade eden Δt ile rotor kaymayı ifade eden s parametreleri veri setlerine eklendiğinde R^2 başarı oranlarında artma meydana getirmektedir. Bu durum sargı ısısı ve rotor kayma oranının çıkış parametrelerinde farklı oranlarda etkili parametreler olduklarını açıkça göstermiştir.

Veri setlerinin her biri için model kaybı grafiği ve gerçekte tahmin değer grafikleri EK-3'te ayrı ayrı Şekil EK-3.1- Şekil EK-3.28'de verilmiştir.

4.2.3. Gerçek verilerde k-en yakın komşu (KNN, k-Nearest Neighbors)

KNN, gözetimli öğrenme algoritmalarından biridir ve hem sınıflandırma hem de regresyon problemlerinde kullanılabilir. Temelde, bir veri noktasının sınıfını veya değerini belirlemek için, veri setindeki diğer noktalara olan "yakınlığına" dayanır. Bu yakınlık genellikle Öklid, Manhattan veya Minkowski gibi uzaklık ölçümleri kullanılarak hesaplanır. Bu konuyla ilgili geniş bilgi Bölüm 3.9.5'te verilmiştir.

n_neighbors (K): KNN modelinin performansını en çok etkileyen parametrelerden biri 'K' sayısıdır. Bu, bir tahmin için dikkate alınacak en yakın komşu sayısını belirler. 'K' çok küçükse, model gürültüye çok duyarlı olur; çok büyükse, sınırlar aşırı düzleşebilir ve model aşırı genelleme yapabilir.

weights: 'uniform' (her komşunun eşit ağırlıklı olduğu) veya 'distance' (komşuların ağırlıklarının onların uzaklıklarının tersiyle orantılı olduğu) olabilir. 'distance' kullanıldığında, daha yakın komşuların tahmine daha büyük bir etkisi olur.

metric: Uzaklık hesaplaması için kullanılan metriği belirler. 'euclidean', 'manhattan', ve 'minkowski' en yaygın kullanılan metriklerdendir.

Veri seti özellikleri ile modellemede kullanılan parametreler Çizelge 4.26’da verilmiştir.

Çizelge 4.26. KNN modellerde kullanılan veri setlerinin hiper parametreleri

Özellik / Veri Seti	Veri Seti 1	Veri Seti 2	Veri Seti 3	Veri Seti 4
Ortalama n_neighbors	13	6	8	3
weights	distance	Distance, uniform	distance	distance
metric	Manhattan, euclidean	manhattan	Manhattan, euclidean	manhattan
cv	5	5	5	5
Bootstrap	42	42	42	42
Örnekleme				
Rastgele Durum	True	True	True	True

Her veri seti ayrı ayrı analiz edilmiştir. Kodların çalışma süreleri Çizelge 4.27’de verilmiştir.

Çizelge 4.27. KNN kodların çalışma süreleri

VERİ SETLERİ	Çalışma Süresi (Saniye)
Veri Seti 1	25,085
Veri Seti 2	27,304
Veri Seti 3	24,634
Veri Seti 4	35.635

Analiz sonucu verilerin R^2 değerleri her veri için Çizelge 4.28’de görülmektedir. Veri Seti 1’de giriş parametresi olarak P, n ve T_y varken çıkış parametrelerin R^2 başarı oranları düşük görülmektedir. Veri seti 2’de giriş parametresi olarak Δt parametresi dahil edildiğinde R^2 başarı oranların yükseldiği görülüyor. Veri Seti 3’te giriş parametrelerine Δt çıkartılarak yerine Veri Seti 1’den farklı olarak s parametresi dahil edildiğinde R^2 başarı oranlarının daha da arttığı gözlemlenmiştir. Veri Seti 4’te ise Veri Seti 1’e hem Δt hem de s parametreleri beraber eklenmiştir. Parametrelerin R^2 başarı oranında Veri Seti 2’ye göre artma görülürken Veri Seti 3’e göre veri setlerin arasında çok az değişimler gözlemlendi.

Çizelge 4.28. KNN algoritması kullanılarak elde edilen başarı değerleri

Başarı Yüzdesi (R^2)	Veri Seti 1	Veri Seti 2	Veri Seti 3	Veri Seti 4
R_s	83,63%	90,45%	98,60%	96,98%
R_2	86,84%	85,99%	99,22%	96,24%
X_s	95,86%	95,99%	98,26%	97,93%
X_2	95,86%	95,99%	98,26%	97,93%
R_m	93,62%	93,91%	96,14%	96,16%
X_m	82,30%	84,52%	88,68%	88,12%
Δt	71,89%	---	88,95%	---
s	93,05%	96,06%	---	---
Eğitim Başarı Yüzdesi	87,88%	91,84%	95,44%	93,70%

KNN modellerde kullanılan veri setlerinin farklı hiper parametreleri Çizelge 4.29’da verilmiştir.

Çizelge 4.29. KNN modellerde kullanılan veri setlerinin farklı hiper parametreler

Özellik / Veri Seti	Veri Seti 1	Veri Seti 2	Veri Seti 3	Veri Seti 4
Ortalama	20	20	20	20
n_neighbors				
weights	Distance	Distance	Distance	Distance
metric	Manhattan	Manhattan	Manhattan	Manhattan
cv	5	5	5	5
Bootstrap	42	42	42	42
Örnekleme				
Rastgele	True	True	True	True
Durum				

Her veri seti ayrı ayrı analiz edilmiştir. Kodların çalışma süreleri Çizelge 4.30’da verilmiştir.

Çizelge 4.30. KNN kodların farklı hiper parametrelerde çalışma süreleri

VERİ SETLERİ	Çalışma Süresi (Saniye)
Veri Seti 1	1970.376
Veri Seti 2	2090.148
Veri Seti 3	2000.582
Veri Seti 4	2250.112

Sinir ağını farklı parametrelerle tekrar eğitildiğinde elde edilen R^2 başarı oranları Çizelge 4.31’de görülmektedir.

Çizelge 4.31. KNN modellerde farklı parametreler verilerek çıkan değerler

Başarı Yüzdesi (R ²)	Veri Seti 1	Veri Seti 2	Veri Seti 3	Veri Seti 4
R _s	% 83.59	%89.63	%98.33	% 98
R ₂	%86.60	%84.11	%98.48	% 97
X _s	%89.87	%95.46	%98.23	% 96
X ₂	%89.87	%95.46	%98.23	% 96
R _m	%93.64	:%92.69	%96.03	% 96
X _m	%82.43	%82.71	%88.14	% 79
Δt	%72.05	---	%88.14	---
s	%93.01	%94.70	---	---
Eğitim Başarı Yüzdesi	%87.88	% 90,63	% 95,08	% 93,63

Farklı parametreler de değişim oranlarında farklılıklar olsa da genel analizde bir değişiklik görülmemiştir. Yani sargı ısısını ifade eden Δt ile rotor kaymayı ifade eden s parametreleri veri setlerine eklendiğinde R² başarı oranlarında artma meydana getirmektedir. Bu durum sargı ısısı ve rotor kayma oranının çıkış parametrelerinde farklı oranlarda etkili parametreler olduklarını açıkça göstermiştir.

Veri setlerinin her biri için model kaybı grafiği ve gerçekte tahmin değer grafikleri EK-4’te ayrı ayrı Şekil EK-4.1- Şekil EK-4.27’de verilmiştir.

4.2.4. Gerçek verilerde rastgele orman algoritması (RF)

RF algoritması, sınıflandırma ve regresyon gibi görevlerde kullanılan popüler bir makine öğrenmesi yöntemidir. Bu algoritma, birden fazla karar ağacının oluşturduğu bir 'orman' kullanarak çalışır. Her bir karar ağacı, veri setinin rastgele seçilmiş alt kümeleri üzerinde eğitilir ve sonuçta elde edilen tahminlerin ortalaması veya çoğunluk oyu alınarak nihai tahmin elde edilir. Bu konuyla ilgili geniş bilgi Bölüm 3.9.6’da verilmiştir.

Veri seti özellikleri ile modellemede kullanılan parametreler Çizelge 4.32’de verilmiştir.

Çizelge 4.32. RF modellerde kullanılan veri setlerinin hiper parametreleri

Özellik / Veri Seti	Veri Seti 1	Veri Seti 2	Veri Seti 3	Veri Seti 4
Ağaç Sayısı (n_estimators)	300	300	300	300
Maksimum Derinlik (max_depth)	30	30	30	30
Minimum Örnek Sayısı (min_samples_split)	5	5	5	5
Minimum Örnek Sayısı (Yaprak) (min_samples_leaf)	2	2	2	2
Bootstrap Örneklemeye Rastgele Durum (Random State)	True	True	True	True

Ağaç Sayısı (n_estimators): Ormanda kullanılacak karar ağacı sayısıdır.

Maksimum Derinlik (max_depth): Her bir karar ağacının maksimum derinliğidir.

Minimum Örnek Sayısı (min_samples_split): Bir düğümün dallanmadan önce içermesi gereken minimum örnek sayısıdır.

Minimum Yaprak Örnek Sayısı (min_samples_leaf): Bir yaprağın (son düğüm) içermesi gereken minimum örnek sayısıdır.

Öznitelik Sayısı (max_features): Her bir bölünmede dikkate alınacak maksimum öznitelik sayısıdır.

Bootstrap (bootstrap): Her bir karar ağacını eğitmek için örneklerin bootstrap yöntemiyle seçilip seçilmeyeceğini belirler.

Her veri seti ayrı ayrı analiz edilmiştir. Kodların çalışma süreleri Çizelge 4.33'te verilmiştir.

Çizelge 4.33. RF kodların çalışma süreleri

VERİ SETLERİ	Çalışma Süresi (Saniye)
Veri Seti 1	5455,446
Veri Seti 2	6852,783
Veri Seti 3	9898,292
Veri Seti 4	10154,645

Analiz sonucu verilerin R^2 değerleri her veri için Çizelge 4.34'te görülmektedir. Veri Seti 1'de giriş parametresi olarak P, n ve T_y varken çıkış parametrelerin R^2 başarı oranları düşük görülmektedir. Veri seti 2'de giriş parametresi olarak Δt parametresi dahil edildiğinde R^2 başarı oranların yükseldiği görülüyor. Veri Seti 3'te giriş parametrelerine Δt çıkartılarak yerine Veri Seti 1'den farklı olarak s parametresi dahil edildiğinde R^2 başarı oranlarının Veri Seti 2'den daha sınırlı olsa da R^2 başarı oranların yükseldiği görülüyor. Veri Seti 4'te ise Veri Seti 1'e hem Δt hem de s parametreleri beraber eklenmiştir. Parametrelerin R^2 başarı oranında Tüm veri setlerinden daha fazla bir R^2 başarı oranı elde edilmiştir. Bu algoritmada daha önceki uygulanan algoritmalarından farklı olarak Δt giriş parametresinin çıkış parametreleri üzerinde s parametresine göre daha yüksek etkiye sahip olduğu görüldü. Veri Seti 4'te ise tüm parametrelerin R^2 başarı oranlarında artma olmuştur.

Çizelge 4.34. RF algoritması kullanılarak elde edilen başarı değerleri

Başarı Yüzdesi (R^2)	Veri Seti 1	Veri Seti 2	Veri Seti 3	Veri Seti 4
R_s	% 73	% 90	% 86	% 93
R_2	% 73	% 90	% 87	% 94
X_s	% 86	% 94	% 91	% 95
X_2	% 86	% 94	% 91	% 95
R_m	% 84	% 93	% 88	% 94
X_m	% 64	% 79	% 73	% 82
Δt	% 45	---	% 60	---
s	% 60	% 72	---	---
Eğitim Başarı Yüzdesi	% 70	% 87	% 82	% 92

RF modellerde kullanılan veri setlerinin genel metrik çıktıları toplu olarak Çizelge 4.35'te görülüyor.

Çizelge 4.35. RF modellerde kullanılan veri setlerinin genel metrik çıktıları

Özellik / Veri Seti	Veri Seti 1	Veri Seti 2	Veri Seti 3	Veri Seti 4
R Kare	0,707535123	0,8719349231	0,82485642078	0,92673651099
MSE	87,61676030	42,459676337	74,3498568105	42,6950117945
RMSE	9,360382486	9,1389771410	8,62263630281	6,53414200905
MAE	4,439354277	2,1960256131	3,95284496284	2,30110721711

Veri setlerinin her biri için model kaybı grafiği ve gerçekte tahmin değer grafikleri EK-5'te ayrı ayrı Şekil EK-5.1- Şekil EK-5.28'de verilmiştir.

4.2.5. Gerçek verilerde XGBoost (Extreme Gradient Boosting) algoritması

XGBoost, sınıflandırma, regresyon ve sıralama gibi çeşitli ML görevlerinde kullanılan popüler ve verimli bir gradyan artırma kütüphanesidir. XGBoost, karar ağaçlarına dayalı bir ensemble yöntemi olan gradyan artırma algoritmasının optimize edilmiş bir versiyonudur. Bu algoritma, büyük veri setleri üzerinde hızlı ve yüksek performanslı çalışmasıyla bilinir. Bu konuyla ilgili geniş bilgi Bölüm 3.9.7’de verilmiştir.

Veri seti özellikleri ile modellemede kullanılan parametreler Çizelge 4.36’da verilmiştir.

Çizelge 4.36. XGBoost modellerde kullanılan veri setlerinin hiper parametreleri

Özellik / Veri Seti	Veri Seti 1	Veri Seti 2	Veri Seti 3	Veri Seti 4
Ağaç Sayısı (n_estimators)	300	300	300	300
Maksimum Derinlik (max_depth)	7	7	7	7
Öğrenme Oranı (learning_rate)	0,1	0,1	0,1	0,1
Alt Örneklem Oranı (subsample)	0,8	0,8	0,8	0,8
Ağaç Başına Sütun Örneklemesi (colsample_bytree)	0,8	0,8	0,8	0,8

learning_rate (eta): Öğrenme oranı, her adımda yapılan ağaç ağırlık güncellemesinin boyutunu kontrol eder.

n_estimators: Oluşturulacak ardışık ağaç sayısıdır.

max_depth: Her bir ağacın maksimum derinliğidir.

subsample: Her bir ağaç için rastgele seçilen örneklerin oranıdır.

colsample_bytree: Her bir ağaç için rastgele seçilen öz niteliklerin oranıdır.

Kodların çalışma süreleri Çizelge 4.37’de verilmiştir.

Çizelge 4.37. XGBoost kodların çalışma süreleri

VERİ SETLERİ	Çalışma Süresi (Saniye)
Veri Seti 1	64,733
Veri Seti 2	66,125
Veri Seti 3	66,300
Veri Seti 4	63,644

Analiz sonucu verilerin R^2 değerleri her veri için Çizelge 4.38’de görülmektedir. Veri Seti 1’de giriş parametresi olarak P, n ve Ty varken çıkış parametrelerin R^2 aşarı oranları düşük görülmektedir. Veri seti 2’de giriş parametresi olarak Δt parametresi dahil edildiğinde R^2 başarı oranların yükseldiği görülüyor. Veri Seti 3’te giriş parametrelerine Δt çıkartılarak yerine Veri Seti 1’den farklı olarak s parametresi dahil edildiğinde R^2 başarı oranlarının daha da arttığı gözlemlenmiştir. Veri Seti 4’te ise Veri Seti 1’e hem Δt hem de s parametreleri beraber eklenmiştir. Parametrelerin R^2 başarı oranında tüm veri setlerinden daha fazla bir R^2 başarı oranı elde edilmiştir.

Çizelge 4.38. XGBoost algoritması kullanılarak elde edilen başarı değerleri

Başarı Yüzdesi (R^2)	Veri Seti 1	Veri Seti 2	Veri Seti 3	Veri Seti 4
R_s	% 65	% 89	% 97	% 97,5
R_2	% 67	% 87	% 97	% 96
X_s	% 90	% 94	% 95	% 96
X_2	% 89	% 94	% 95	% 96
R_m	% 82	% 93	% 90	% 95
X_m	% 62	% 73	% 75	% 78
Δt	% 44	---	% 80	---
s	% 82	% 94	---	---
Eğitim Başarı Yüzdesi	% 73	% 89	%90	% 93

XGBoost modellerde kullanılan veri setlerinin farklı hiper parametreleri Çizelge 4.39’da verilmiştir.

Çizelge 4.39. XGBoost modellerde kullanılan veri setlerinin farklı hiper parametreler

Özellik / Veri Seti	Veri Seti 1	Veri Seti 2	Veri Seti 3	Veri Seti 4
Ağaç Sayısı (n_estimator)	100	100	100	100
Maksimum Derinlik (max_depth)	7	7	7	7
Öğrenme Oranı (learning_rate)	0,1	0,1	0,1	0,1
Alt Örneklem Oranı (subsample)	0,9	0,9	0,9	0,9
Ağaç Başına Sütun Örneklem (colsample_bytree)	0,8	0,8	0,8	0,8

Sinir ağını farklı parametrelerle tekrar eğitildiğinde elde edilen R^2 başarı oranları Çizelge 4.40'ta görülmektedir.

Çizelge 4.40. XGBoost modellerde farklı parametreler verilerek çıkan değerler

Başarı Yüzdesi (R^2)	Veri Seti 1	Veri Seti 2	Veri Seti 3	Veri Seti 4
R_s	% 65	% 88	% 96	% 97
R_2	% 67	% 86	% 97	% 96
X_s	% 90	% 94	% 94	% 95
X_2	% 89	% 94	% 95	% 95
R_m	% 82	% 92	% 90	% 94
X_m	% 62	% 74	% 75	% 74
Δt	% 44	---	% 79	---
s	% 82	% 93	---	---
Eğitim Başarı Yüzdesi	% 73	% 89	% 89	% 92

Farklı parametreler de değişim oranlarında farklılıklar olsa da genel analizde bir değişiklik görülmemiştir. Yani sargı ısısını ifade eden Δt ile rotor kaymayı ifade eden s parametreleri veri setlerine eklendiğinde R^2 başarı oranlarında artma meydana getirmektedir. Bu durum sargı ısısı ve rotor kayma oranının çıkış parametrelerinde farklı oranlarda etkili parametreler olduklarını açıkça göstermiştir.

Veri setlerinin her biri için model kaybı grafiği ve gerçekte tahmin değer grafikleri EK-6'da ayrı ayrı Şekil EK-6.1 - Şekil EK-6.24'te verilmiştir.

Tüm algoritmaların çalışma süreleri toplu olarak çizelgede verilmiştir. Bu çalışma süreleri karşılaştırıldığında KNN tüm veri setlerinde kısa süre içinde analiz gerçekleştirdiği görülüyor. Tüm veri setlerinde en uzun çalışma süresi ise RF algoritmasında gerçekleşmiştir.

Çizelge 4.41. Sınıflandırma algoritmaların veri setlerine göre çalışma süreleri

VERİ SETLERİ	Çalışma Süresi (Saniye)				
	BPNN	MLP	KNN	RF	XGBoost
Veri Seti 1	1306,015	3667,28	25,085	5455,446	64,733
Veri Seti 2	718,894	2980,84	27,304	6852,783	66,125
Veri Seti 3	679,134	2777,634	24,634	9898,292	66,300
Veri Seti 4	1243,723	2911,62	35,635	10154,645	63,644

Tüm veri setlerindeki parametrelerin algoritmalara göre başarı yüzdesi (R^2) oranları toplu olarak Çizelge 4.42 ile Çizelge 4.45'te verilmiştir.

Çizelge 4.42. Sınıflandırma algoritmaların Veri Seti 1'e göre başarı yüzdesi (R^2)

Başarı Yüzdesi (R^2)	Veri Seti 1				
	BPNN	MLP	KNN	RF	XGBoost
R_s	52,75	60,65	83,63	73	65
R_2	48,66	54,78	86,84	73	67
X_s	82,93	86,92	95,86	86	90
X_2	82,93	86,92	95,86	86	89
R_m	73,85	79,40	93,62	84	82
X_m	51,82	68,47	82,30	64	62
Δt	39,19	62,48	71,89	45	44
s	76,85	80,21	93,05	60	82
Eğitim Başarı Yüzdesi	96	72,47	87,88	70	73

Çizelge 4.43. Sınıflandırma algoritmaların Veri Seti 2'ye göre başarı yüzdesi (R^2)

Başarı Yüzdesi (R^2)	Veri Seti 2				
	BPNN	MLP	KNN	RF	XGBoost
R_s	76	76,40	90,45	90	89
R_2	70,69	65,09	85,99	90	87
X_s	89	89,26	95,99	94	94
X_2	89	89,25	95,99	94	94
R_m	84	82,78	93,91	93	93
X_m	60	73,72	84,52	79	73
Δt	---	---	---	---	---
s	87,6	77,06	96,06	72	94
Eğitim Başarı Yüzdesi	98,3	79,08	91,84	87	89

Çizelge 4.44. Sınıflandırma algoritmalarının Veri Seti 3'e göre başarı yüzdesi (R^2)

Başarı Yüzdesi (R^2)	Veri Seti 3				
	BPNN	MLP	KNN	RF	XGBoost
R_s	95,4	90,40	98,60	86	97
R_2	93	81,78	99,22	87	97
X_s	94,84	92,86	98,26	91	95
X_2	94,84	93,18	98,26	91	95
R_m	89,86	90,13	96,14	88	90
X_m	72	80,01	88,68	73	75
Δt	70	81,87	88,95	60	80
s	---	---	---	---	---
Eğitim Başarı Yüzdesi	99	87,18	95,44	82	90

Çizelge 4.45. Sınıflandırma algoritmalarının Veri Seti 4'e göre başarı yüzdesi (R^2)

Başarı Yüzdesi (R^2)	Veri Seti 4				
	BPNN	MLP	KNN	RF	XGBoost
R_s	95	90,82	96,98	93	97,5
R_2	90,5	81,69	96,24	94	96
X_s	95	92,95	97,93	95	96
X_2	95	93,09	97,93	95	96
R_m	89,75	89,51	96,16	94	95
X_m	75,5	79,76	88,12	82	78
Δt	---	---	---	---	---
s	---	---	---	---	---
Eğitim Başarı Yüzdesi	99	87,97	93,70	92	93

Veri analizlerinin tahmin modellemesi için algoritma seçim sürecinde kapsamlı bir değerlendirme gerçekleştirildi. Araştırma ve literatür incelendiğinde, özellikle tahmin uygulamalarında ağaç modellerinin tutarlı ve güvenilir sonuçlar verdiği sonucuna varılmaktadır. Bu bağlamda, çeşitli yapay öğrenme algoritmaları arasından, ağaç tabanlı modellerin tahmin başarısındaki potansiyeli test edildi.

ANN ve ağaç tabanlı algoritmalar arasında karşılaştırmalı analizler yapıldığında, KNN ve RF algoritmaları gibi ANN uygulamalarında, veri setinin öğrenme sürecindeki zorluklar ve modelin genelleme yeteneğindeki eksiklikler ön plana çıktı. Özellikle ezberleme (overfitting) sorunu, modelin genel uygulanabilirliğini sınırlandıran bir faktör olarak belirlendi. Fakat ağaç tabanlı modellerin uygulaması, bu sorunları büyük ölçüde hafifletti. Ağaç tabanlı bu modellerde özellikle veri seti büyüklüğü arttıkça hesaplama maliyeti ve zamanı konusunda yeni zorluklar ortaya çıkardı. Her ne kadar bu zorluklar mevcut olsa da elde edilen doğruluk oranlarındaki iyileşme, bu maliyet artışını göz ardı edilebileceğini göstermektedir. Veri setlerinin çeşitliliği ve hacmi arttıkça, modelin doğruluk oranı da istikrarlı bir şekilde yükseldi.

Veri örnekleme stratejisi ve iyileştirme çalışmalarında ilk sistemde uygulanan rastgele veri örnekleme metodolojisi, 80/20 oranında, özellikle küçük örneklerde, dengesizliğe sebep oldu. Bu sorunu ele alarak, her motor verisinden sistematik bir şekilde %20 örnek alınması sağlandı. Beş motor verisinin her birinden yapılan bu seçim, her bir veri kümesinin model tarafından eşit bir temsiliyetini sağladı. Bu yaklaşım, modelin genelleme kabiliyetini artırarak başarı oranını iyileştirdi.



5. SONUÇLAR VE ÖNERİLER

Tez bu bölüm ile sonlandırılmıştır. İlk olarak tezin kısa bir özeti sunulmuştur. Ardından, bu tez çalışması boyunca literatüre yapılan katkılar listelenmiştir. Son olarak, bu tezin bulgularıyla ilgili gelecekteki çalışmalara değinilmektedir.

5.1.1. Tezin Kısa Bir Özeti

Bu çalışmanın temel yönü, güç elektroniği araştırmalarının ana alanı olan model öngörülü kontrol (Model Predictive Control, MPC), arıza teşhisi ve arıza sonrası onarımda verilerin doğruluğu gibi ASM ile ilgili çeşitli alanlar arasında köprü kurmaktır. ASM'leri maliyetlerinin her geçen gün artması ve üretim alanlarının kesintisiz kullanımının sağlanması konusu bu motorların hassas kontrol ile verimli, arızalanmadan uzun süre kullanımlarını ön planda tutmaktadır. Sonrasında arıza teşhisi ve arıza sonrası onarımla motorun fabrika verilerine yakın verilerle çalışmaya uygun hale getirilmesi gibi süreçleri kapsar. Taleplerin karşılanabilmesi için süreçlerin içerdiği ASM'lerin uzun süre arızalanmadan verimli kullanılması, arıza teşhisi ve onarım sonrası içinde matematiksel modellemesinin tam ve doğru bir şekilde yapılması gerekmektedir. ASMECP'lerin doğru ve hassas belirlenmesi, asenkron motorların hız ve konum kontrolleri gibi uygulamalarda önem arz etmektedir. Bu tür motorların son kontrolü, değişken hızlı sürücüler (VSD) aracılığıyla ya alan odaklı ya da doğrudan tork vektör kontrolüne bağlıdır. VSD ile uygun motor kontrolü ve doğru arıza teşhisi için motor parametrelerinin kesin olarak tahmin edilmesi çok önemlidir (Wang ve diğ., 2020). Matematiksel modellemenin doğruluğu ise öncelikle ASMECP'lerin tüm değişen koşullar altında hatasız belirlenmesine bağlıdır.


İlk olarak, çağdaş literatüre çok sayıda referansla birlikte ECP tahmini ve arıza tespiti yöntemlerinin kapsamlı bir analizi sunulmuştur. Farklı güçleri, farklı rotor hızları ve farklı yük oranlarını içeren etkili bir motor veri yığını, oluşturulan sistemle zorlu ve zaman alan deneyler yapılarak elde edilmiştir. Bu verilerin analizi Bölüm 3'te ayrıntılı olarak verilmiştir.

Ayrıntılı parametre grafikleri ve deneylerdeki değişim oranlarının sunulmasında sonra, bir sonraki odak noktası, bu çalışmanın ikinci ana yönü olarak giriş değişken parametrelerinin, çıkış parametreleri üzerindeki etkinlikleri üzerinde durulmuştur. Burada gerçekleştirilen zorlu ve zaman alan deneylerin tüm verilerine ihtiyaç duymadan Taguchi analiz yönteminde kodlama ile deney kısıtlamasına gidilmiştir. Böylece maliyet, zaman ve laboratuvar ortamı gibi zorluklardan kurtularak daha az deneyle tüm deneylerde

elde edilebilen sonuçlara yaklaşık sonuçlar elde edilebildiği gösterildi. Ayrıca Taguchi analiziyle, giriş değişkenlerinin çıkış değişkenleri üzerindeki etkinliği tespit edilerek giriş değişken sayısı ve matematiksel modellemenin karmaşıklığı azaltıldı. Doğruluk oranı R^2 oranları düzeltilerek matematiksel modellemenin doğruluğu sunuldu. Doğruluk oranı Regresyon analiz yöntemiyle matematiksel bir modelleme ortaya konuldu. Elde edilen bulgular;

1) Modele giriş parametrelerinin (motor tipe, rotor devir ve yük) mümkün olduğu kadar gerçekçi veriler ile simüle edilmiş bir sincap kafesli asenkron motor, Taguchi yöntemine dayandırıldı.

2) Bu araştırma çalışmasına dayanarak belirlenen giriş parametrelerinden Taguchi analiz sonucu S/N oranının en yüksek olduğu düzeltilmiş R^2 (model doğruluğu) yani giriş parametrelerin en çok etkili olduğu çıkış parametreleri belirlenmiştir. R^2 değerlerinin grafiksel gösterimi Şekil 5.1’de sunulmuştur.



Şekil 5.1. Giriş parametrelerin Çıkış parametre üzerinde etkisini gösteren R^2 grafiği

Bu değerlere göre her bir çıkış parametresinin üzerinde etkinliği fazla olan giriş parametreleri Çizelge 5.1’de verildi.


Çizelge 5.1. Çıkış parametre üzerinde etkili giriş parametreleri

PC (%)	R_s	R_2	$X_s=X_2$	R_m	X_m	Δt	s
Active on	P, Ty	P, n	P, Ty	P, Ty	P, n	P, Ty	n, Ty

3) Yukarıdaki tespitler sonucu oldukça fazla çeşitlilikteki çevresel etkenler altında çalışan sincap kafesli asenkron motorların hangi giriş parametreleri önemli parametre olduğu doğrulandı. Bu giriş parametrelerine göre stator direnci (R_s) üzerinde rotor devresi direncinin stator devresine aktarılmış eşdeğeri (R_2), uyarım devresi direnci (R_m), sargı

ısısı (Δt) ve kayma (s) üzerindeki yüksek etkisi olduğu görüldü. R_s parametresi üzerinde giriş parametrelerinden %64,1 ile en fazla yükün etkisi görüldü. R_2 parametresi üzerinde giriş parametrelerinden %28,58 ile en fazla motor tipinin etkili olduğu görüldü. R_m parametresi üzerinde giriş parametrelerinden %39,62 ile en fazla yükün etkisi görüldü. Sargı ısısı üzerinde giriş parametrelerinden %57,49 ile en fazla yükün etkisi görüldü. Kayma üzerinde giriş parametrelerinden %70,57 ile en fazla rotor devrinin etkisi görüldü.

4) Giriş değişkenlerinden etkilendiği ortaya konan Δt ve s parametreleri de omik ve reaktans parametreleri üzerinde etkili olduğu bilinmektedir. Bu iki parametre de giriş parametresi olarak analize eklendiğinde düzeltilmiş R^2 değerinde iyileştirme gerçekleştiği Şekil 5.2’de görülmüyor.



Şekil 5.2. R^2 oranları (a) P, n, T_y (b) P, n, T_y , Δt (c) P, n, T_y , s (d) P, n, T_y , Δt , s giriş parametreleri

Şekil 5.2’de Regresyon analiz sonucu elde edilen matematiksel modellemelere de yer verilmiştir. Her farklı giriş değişkenine göre oluşturulan matematiksel modellemeler grafiklerin altında görülmektedir.

5) Elde edilen test sonuçlarına göre ASM'lerin ECP'leri çevresel faktörlerin türüne göre farklı oranlarda etkilenmektedir. Tek çevresel faktöre dayalı matematiksel modellemenin yetersizliği bu çalışma verileri ışığında ortaya konmuştur. Parametrelerin değişkenliği çoğunlukla yüke bağlı olsa da yük motor ısınıyı yani sargı ısınıyı artırdığı için sarım sıcaklığına etkisi olduğunu belirtebiliriz. Yapılan çalışmada tüm motorların matematiksel model sonucu tek bir formülde değerlendirilemez. Çünkü çıkış parametrelerinin hepsinin üzerinde ayrı bir giriş değişkeni farklı oranlarda etken olmaktadır.

ASM'lerin parametre belirlemede evrensel bir matematiksel modelleme için tüm çalışma şartlarını bir arada ele almamız gerektiği ve motor çıkış parametresinin üzerinde yüksek etkiye sahip olanların belirlenmesinin önemi çalışma ile kanıtlanmıştır. Çalışma sonuçlarımızın gelecekte yapılacak çalışmalara yol göstereceği düşünülmektedir.

Son odak noktası, bu çalışmanın üçüncü ana yönü olarak deney düzeneği ile elde edilen parametre veri yığınlarının çokluğu tam analiz için çalışmayı ANN'ye yönlendirdi. Veri analizlerinin tahmin modellemesi için algoritma seçim sürecinde kapsamlı bir değerlendirme gerçekleştirildi. Ağaç tabanlı algoritmalarda ilk sistemde uygulanan rastgele veri örnekleme metodolojisi tüm verilerin içinden %20 oranında seçildiğinde dengesizliğe sebep olması üzerine beş farklı motorun her birinin parametre verileri kendi içinde %20 örnekleme verisiyle eğitildi. Bu her bir veri kümesinin model tarafından eşit bir temsiliyetini sağladı. Bu yaklaşım, modelin genelleme kabiliyetini artırarak başarı oranını iyileştirdi. Taguchi analizinde olduğu gibi dört farklı giriş kombinasyonu oluşturularak veri setleri belirlendi. Bu veri setlerini oluşturan giriş değişken kombinasyonu Bölüm 4'te Çizelge 4.14'te verildi.

Uygulanan düzenlemeler ve iyileştirmelerle, modelin verimliliği anlamlı bir biçimde arttı. Eşit oranlarda veri dağılımı sağlanması, modelin tahmin doğruluğunda belirgin bir artışa yol açmış, aynı zamanda veri temsiliyetindeki dengesizlikleri minimize etmiştir. Ağaç tabanlı modellerin uygulanması, veri seti ve tahmin görevleri için uygun bir karar olarak ortaya çıkmıştır. Veri tahmin analizinde başarılı olduğu belirlenen algoritmalarda çıkış parametrelerinin veri setlerindeki giriş değişkenlere göre başarı oranı R^2 'nin nasıl değiştiği Şekil 5.3'te görülmektedir.




Şekil 5.3. Çıkış parametrelerinin veri setlerindeki giriş değişkenlere göre R^2 oranları (a) BPNN algoritması (b) MPL algoritması (c) KNN algoritması (d) BF algoritması (e) XGBoost algoritması

Tüm veri setlerindeki parametrelerin algoritmalara göre başarı yüzdesi (R^2) oranları Şekil 5.4'te verilmiştir.



Şekil 5.4. (a) Veri Seti 1'in tüm sınıflandırma algoritmalarına göre başarı yüzdesi (R^2) (b) Veri Seti 2'nin tüm sınıflandırma algoritmalarına göre başarı yüzdesi (R^2) (c) Veri Seti 3'ün tüm sınıflandırma algoritmalarına göre başarı yüzdesi (R^2) (d) Veri Seti 4'ün tüm sınıflandırma algoritmalarına göre başarı yüzdesi (R^2)

Veri setlerinin algoritmalara göre gösterdikleri eğitim başarı yüzdeleri ise Şekil 5.5'te verilmiştir.



Şekil 5.5. (a) Algoritmaların eğitim başarı oranlarının karşılaştırılması (b) Veri Setlerinin eğitim başarı oranlarının karşılaştırılması

BPNN algoritması tüm veri setinde yüksek eğitim başarı yüzdesi gösterdiği görüldü. Diğer algoritmaların oranları birbirine yakın gerçekleşti. Bu durum motor parametre analizinde BPNN algoritmasının en uygun algoritma olduğunu göstermiştir. Veri seti başarı yüzdeleri değerlendirildiğinde ise BPNN algoritmasında Veri Seti 3 (P , n , T_y ve s giriş değişkenli) ve Veri Seti 4 (P , n , T_y , s ve Δt giriş değişkenli) en yüksek eğitim başarı yüzdesi göstermiştir. Bu sonuçlar değerlendirildiğinde oluşturulacak matematiksel denklemin bu girişler üzerine kurgulanması gerektiği görüldü.

5.1.2. Literatüre Yapılan Katkılar

Bu tez çalışması boyunca 1 adet SCI dergi makalesi ve 1 adet uluslararası konferans makalesi ve yayınlanmıştır. Bu yayınların ana katkıları aşağıdaki gibi özetlenmiştir:

- ✓ “Real-Time Investigation of Temperature Effect on Induction Motor Equivalent Circuit Parameter Change” başlıklı makalede; SCADA sisteminden oluşan deney düzeneği ile ASM'lerin adaptif parametre tespiti yapılmıştır. Test başlangıcında motor üreticisinin verileri sürücü tarafından ölçülen giriş parametreleri ile birleştirilerek üç fazlı ASM'lerin çıkış parametreleri belirlenmiştir.

Deneylerde çevresel faktörlerin (stator sargı sıcaklığı, mil hızı, güç ve yük) motor eşdeğer devre parametreleri üzerindeki etkileri belirlenmiştir.

Elde ettiğimiz test sonuçlarından, ASM'lerin ECP'lerinin çevresel faktörlerin türlerine göre farklı oranlarda etkilendiği görülmüştür. Bu Bölüm 3'te kurulan sistem deneylerinin temelini oluşturmuştur. Tek bir çevresel faktöre dayalı matematiksel modellemenin yetersizliği bu çalışmada veriler ışığında ortaya konmuştur.

- ✓ “Electrical and Mechanical Load Design for Induction Motors” başlıklı makalede; Asenkron motorları yüklerken karşılaşılan sorunlar için maliyeti düşük bir yük modeliyle çözümü sunulmuştur. Asenkron motorlarda elektriksel yükleme için kullanılan kompunt generatörler tam devir aralığında çalıştırıldıklarında yüksek verimle çalışmakta ve tam yük sağlayabilmektedirler. Daha düşük devirlerde yükleme kapasiteleri oldukça düşmektedir. Bu yüzden özellikle motor kuvveti yükseldikçe karşılık olarak aynı kuvvette kompunt generatör bağlansa bile düşük devirlerde yükleme yapılamamaktadır. Ayrıca bu generatörler ısındıkça yükleme kapasitelerinde de düşme meydana gelmektedir. Bu yüzden bir deney boyunca aynı performansta bir yük verimi alınamamaktadır. Endüstriyelde asenkron motorların kullanım alanındaki

yaygınlığı her devir ve yük altında çalışmalarını gerektirmektedir. Bu durum onların farklı devir ve yükler altındaki çalışma karakteristiklerinin de tam analiz edilmesi ve bu verilerin ışığı altında sürülmelerini gerektirmektedir. Motor parametrelerini ve davranışlarını tam tespit etmek için hazırlanan deney düzeneğinde bu problemin üstesinden gelmek amacıyla mekanik bir yük tasarımı gerçekleştirilmiştir. Tasarlanan mekanik yük düşük devirlerde de motorları yükleme yapabilme olanağını sağladı.



KAYNAKLAR

- Agamloh, E. B., Cavagnino, A. and Vaschetto, S., 2017, Accurate Determination of Induction Machine Torque and Current Versus Speed Characteristics, *IEEE Transactions on Industry Applications*, 53 (4), 3285–3294.
- Ahmed, M., Vahidnia, A., Datta, M. and Meegahapola, L., 2020, An adaptive power oscillation damping controller for a hybrid AC/DC microgrid, *IEEE Access*, 8, 69482–69495.
- Al, R., Behera, C. R., Zubov, A., Gernaey, K. V. and Sin, G., 2019, Meta-modeling based efficient global sensitivity analysis for wastewater treatment plants—An application to the BSM2 model, *Computers & Chemical Engineering*, 127, 233–246.
- Alain, C., Espanet, C. and Wavre, N., 2003, BLDC Motor Stator and Rotor Iron Losses and Thermal Behaviour Based on Lumped Schemes and 3-D FEM Analysis, *IEEE Transactions on Industry Applications*, 39 (5), 1314–1322.
- Aminu, M., 2019, A parameter estimation algorithm for induction machines using artificial bee colony (ABC) optimization, *Nigerian Journal of Technology*, 38 (1), 193–201.
- Anonymous, 2017, IEA technology collaboration programme on energy efficient end-use equipment (4E), *IEA Annual Report*, <https://www.iea4e.org/document/416/4e-2017-annual-report> [4 Kasım 2017].
- Anonymous, 2024, Induction Motor Market Report by Product Type (Single Phase Induction Motor, Three Phase Induction Motor), End-Use Sector (Industrial, Commercial, Residential), and Region 2024-2032, <https://www.imarcgroup.com/induction-motor-market>, accessed 15 April 2024.
- Armor, A.F., 1980, Transient three-dimensional, finite element analysis of heat flow in turbine generator rotors, *IEEE Transactions on Power Apparatus and Systems*, PAS-99 (3), 934–946.
- Batos, J.P., Cabreira, M.F., Sadowski, N. and Aruda, S.R., 1997, A Thermal analysis of induction motors using a weak coupled modeling, *IEEE Transactions on Magnetics*, 33 (2), 1714–1717.
- Bellini, A., Filippetti, F., Tassoni, C. and Capolino, G.-A., 2008, Advances in diagnostic techniques for induction machines, *IEEE Trans. Ind. Electron.*, 12, 4109–4126.
- Benbouzid, M.E.H., 2000, A review of induction motors signature analysis as a medium for faults detection, *IEEE Trans. Ind. Electron.*, 47, 984–993.
- Boglietti, A., Cavagnino, A., Ferraris, L. and Lazzari, M., 2010, Skin effect experimental validations of induction motor squirrel cage parameters, *COMPEL-The international journal for computation and mathematics in electrical and electronic engineering*, 29 (5), 1257–1265.

- Boldea, I. and Nasar, S. A., 2010, *The Induction Machines Design Handbook*, C. Press, Ed. Taylor & Francis Group. <https://doi.org/10.1201/9781315222592>
- Boulghasoul, Z., Kandoussi, Z., Elbacha, A. and Tajer, A., 2020, Fuzzy improvement on luenberger observer based induction motor parameters estimation for high performances sensorless drive, *J. Electr. Eng. Technol.*, 15, 2179-2197
- Box, G., 1988, Signal-to-noise ratios, performance criteria, and transformations, *Technometrics*, 30 (1), 1-17.
- Box, G., Bisgaard, S. and Fung, C., 1988, An explanation and critique of Taguchi's contributions to quality engineering, *Quality and reliability engineering international*, 4 (2), 123-131.
- Boys, J.T. and Miles, M.J., 1994, Empirical thermal model for inverterdriven cage induction machines, *IEEE Proceedings on Electric Power Applications*, 141 (6), 360-372.
- Brownlee, J., 2017, Gentle Introduction to the Adam Optimization Algorithm for Deep Learning, *Machine Learning Mastery*, enUS, URL: <https://machinelearningmastery.com/adam-optimization-algorithm-for-deep-learning/> [Ziyaret Tarihi: 07/13/2021].
- Brownlee, J., 2020, Tour of Evaluation Metrics for Imbalanced Classification. enUS, URL: <https://machinelearningmastery.com/tour-of-evaluation-metrics-for-imbalanced-classification/> [Ziyaret Tarihi: 11/09/2021].
- Brownlee, J., 2021a, How to choose an activation function for deep learning, *Machine Learning Mastery*, 181. URL: <https://machinelearningmastery.com/choose-anactivation-function-for-deep-learning/> [Ziyaret Tarihi: 11/09/2021].
- Brownlee, J., 2021b, Gradient Descent With RMSProp from Scratch, *Machine Learning Mastery*, Recuperado, 29. URL: <https://machinelearningmastery.com/gradient-descent-with-rmsprop-from-scratch/> [Ziyaret Tarihi: 11/09/2021].
- Brownlee, J., 2021c, Gradient Descent With AdaGrad From Scratch, *Machine Learning Mastery*, enUS, URL: <https://machinelearningmastery.com/gradient-descent-with-adagrad-from-scratch/> [Ziyaret Tarihi: 11/09/2021].
- Byrne, D. M., 1987, The Taguchi approach to parameter design, *ASQ's Annu Qual Congr Proc*, 40, 168.
- Cao, J., He, X., Li, D., Jia, B., and Liu, Q., 2023, Electromagnetic Optimization Design of Permanent Magnet Synchronous Traction Motor Based on Taguchi Method, *In 2023 IEEE 6th International Electrical and Energy Conference (CIEEC)*, 4110-4114. IEEE. <https://doi.org/10.1109/CIEEC58067.2023.10166646>

- Chen, H. and Bi, C., 2022, An effective method for determination and characteristic analysis of induction motor parameters. *IET Electric Power Applications*, 16 (5), 605-615.
- Chen, Q., Min, S., Xu, Z., Zheng, Z., Zhong, C., You, D. and Jiang, Z., 2024, Multi-objective optimization design of electric vehicle in-wheel motor based on Taguchi method, *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, <https://doi.org/10.1177/09544070241229775>.
- Chollet, F., 2021, Deep learning with Python, eng. 1st edition, NY: Manning Publications, Shelter Island, ISBN: 9781617294433.
- Choqueuse, V. and Benbouzid, M., 2015, Induction machine diagnosis using stator current advanced signal processing, *Int. J. Energy Convers.*, 3, 76–87.
- Costa, N., Jamkai, W. B. and Mehta, P. M., 2023, Determination of Combination of Input Values of Simulated Motor Using Taguchi Method. *TWIST*, 18 (2), 35-43. <https://doi.org/10.5281/zenodo.10049652#14>
- Cover, T. and Hart, P., 1967, Nearest neighbor pattern classification, *IEEE transactions on information theory*, 13 (1), 21-27.
- Cui, M., Khodayar, M., Chen, C., Wang, X., Zhang, Y. and Khodayar, M. E., 2019, Deep learning-based time-varying parameter identification for system-wide load modeling, *IEEE Transactions on Smart Grid*, 10 (6), 6102-6114.
- Debbabi, F., Nemmour, A. L., Khezzar, A. and Chelli, S. E., 2020, An approved superiority of real-time induction machine parameter estimation operating in self-excited generating mode versus motoring mode using the linear RLS algorithm: Ideas & applications, *International Journal of Electrical Power & Energy Systems*, 118, 105725.
- Duan, N., Ma, X., Lu, S., Wang, S. and Wang, S., 2021, Simulation Calculation of Loss of Induction Traction Motor, *In The Proceedings of the 9th Frontier Academic Forum of Electrical Engineering*, Springer Singapore, 2, 599-606.
- El-Hameed, M. A., Elkholy, M. M. and El-Fergany, A. A., 2020, Three-diode model for characterization of industrial solar generating units using Manta-rays foraging optimizer: Analysis and validations, *Energy conversion and management*, 219, 113048.
- Elkholy, M. M., El-Hay, E. A. and El-Fergany, A. A., 2022, Synergy of electrostatic discharge optimizer and experimental verification for parameters estimation of three phase induction motors, *Engineering Science and Technology, an International Journal*, 31, 101067.
- Elnaghi, B. E., Mohammed, R. H., Dessouky, S. S. and Shehata, M. K., 2019, Load test of induction motors based on PWM technique using genetic algorithm, *Int. J. Eng. Manuf*, 9 (1).

- Feyzi M.R. and Parker, A.M., 1997, Heating in deep-bar rotor cages, *IEEE Proceedings on Electrical Power Applications*, 144 (4), 271-276.
- Filippetti, F., Bellini, A. and Capolino, G.-A., 2013, Condition monitoring and diagnosis of rotor faults in induction machines: State of art and future perspectives. In *Proceedings of the 2013 IEEE Workshop on Electrical Machines Design, Control and Diagnosis (WEMDCD)*, Paris, France, 196-209.
- Gashtil, H., Pickert, V., Atkinson, D., Giaouris, D., & Dahidah, M. (2019, April). A case study of real time implementation of extended kalman filter in dual core dsp for the on-line estimation of induction machine parameters, In *2019 IEEE 13th International Conference on Compatibility, Power Electronics and Power Engineering (CPE-POWERENG)*, IEEE, 1-7.
- Giri, F. (Ed.), 2013, AC electric motors control: advanced design techniques and applications. *John Wiley & Sons*.
- Goodfellow, I., Bengio, Y. and Courville, A., 2016, Deep learning, *MIT press*, <https://www.deeplearningbook.org/> [Ziyaret Tarihi: 07/09/2021].
- Gope, D. and Goel, S. K., 2021, Design optimization of permanent magnet synchronous motor using Taguchi method and experimental validation, *International Journal of Emerging Electric Power Systems*, 22 (1), 9-20. <https://doi.org/10.1515/ijeeps-2020-0169>
- He, J., Li, G., Zhou, R. and Wang, Q., 2020, Optimization of permanent-magnet spherical motor based on taguchi method. *IEEE Transactions on Magnetics*, 56 (2), 1-7. <https://doi.org/10.1109/TMAG.2019.2947863>
- Heising, C., 2007, IEEE recommended practice for the design of reliable industrial and commercial power systems, *IEEE Inc.*, Singh, G. *Induction machine drive condition monitoring and diagnostic research—A survey. Electr. Power Syst. Res.* New York, 64, 145–158.
- Henao, H., Capolino, G.-A., Fernandez-Cabanas, M., Filippetti, F., Bruzzese, C., Strangas, E., Pusca, R., Estima, J., Riera-Guasp, M. and Hedayati-Kia, S., 2014, Trends in fault diagnosis for electrical machines: A review of diagnostic techniques, *IEEE Ind. Electron. Mag.*, 8, 31–42.
- Ho, T. K., 1995, Random decision forests, In *Proceedings of 3rd international conference on document analysis and recognition*, IEEE, 1, 278-282.
- Holtz, J., 1994, The induction motor-a dynamic system, In *Proceedings of IECON'94-20th Annual Conference of IEEE Industrial Electronics*, IEEE, 1, 1-6.
- Holtz, J., 1995, The representation of ac machine dynamics by complex signal flow graphs, *IEEE transactions on industrial electronics*, 42 (3), 263-271. doi: 10.1109/41.382137.

- Holtz, J., 2002, Sensorless control of induction motor drives, *Proceedings of the IEEE*, 90 (8), 1359-1394.
- Holtz, J., 2006, Sensorless control of induction machines—With or without signal injection?, *IEEE transactions on industrial electronics*, 53 (1), 7-30. <https://www.sciencedirect.com/science/article/pii/S0003682X13001515> [Ziyaret Tarihi: 08/11/2021].
- Iegorov, O., Iegorova, O., Miroshnyk, O. and Savchenko, O., 2020, Improving the accuracy of determining the parameters of induction motors in transient starting modes. *Energetika*, 66, 15–23.
- Kackar, R. N., 1985, Off-line quality control, parameter design, and the Taguchi method, *Journal of Quality Technology*, 17 (4), 176-188.
- Karmakar, S., Chattopadhyay, S., Mitra, M. and Sengupta, S., 2016, Induction Motor Fault Diagnosis, *Springer: Berlin/Heidelberg, Germany*, 25.
- Kecman, V., 2001, Learning and soft computing: support vector machines, neural networks, and fuzzy logic models. *MIT press*, Cambridge.
- Kingma, D. P., and Ba, J., 2014, Adam: A method for stochastic optimization, *arXiv preprint arXiv:1412.6980*, URL: <http://arxiv.org/abs/1412.6980> [Ziyaret Tarihi: 07/13/2021].
- Krause, P.C. and Thomas, C.H., 1965, Simulation of symmetrical Induction machines, *IEEE Transactions PAS-84*, 11, 1038- 1053.
- Kumar, A., Motwani, J. and Otero, L., 1996, An application of Taguchi's robust experimental design technique to improve service performance, *International Journal of Quality & Reliability Management*, 13 (4), 85-98.
- Kumar, P., Dalal, A. and Singh, A. K., 2014, Identification of three phase induction machines equivalent circuits parameters using multi-objective genetic algorithms, in *2014 International Conference on Electrical Machines (ICEM)*, 1211–1217.
- Lajis, M. A., Radzi, H. C. D. M. and Amin, A. K. M. N., 2009, The implementation of Taguchi method on EDM process of tungsten carbide, *European Journal of Scientific Research*, 26 (4), 609-617.
- Leon, R. V., Shoemaker, A. C. and Kacker, R. N., 1987, Performance measures independent of adjustment: an explanation and extension of Taguchi's signal-to-noise ratios, *Technometrics*, 29 (3), 253-265.
- Liao, C.M., Chen, C.L. and Katcher, T., 1999, Thermal Management of AC Induction Motors Using Computational Fluid Dynamic Modelling, *International Conference (IEMD '99) Electric machines and Drives*, 189-191.

- Lin, C. H., 2020, Altered grey wolf optimization and Taguchi method with FEA for six-phase copper squirrel cage rotor induction motor design. *Energies*, 13 (9), 2282. <https://doi.org/10.3390/en13092282>
- Ling, Z., Zhou, L., Guo, S. and Zhang, Y., 2014, Equivalent Circuit Parameters Calculation of Induction Motor by Finite Element Analysis, *IEEE Transactions on Magnetics*, 50 (2), 833–836.
- Liu, X., Bo, L. and Luo, H., 2015, Bearing faults diagnostics based on hybrid LS-SVM and EMD method, *Measurement*, 59, 145-166.
- Logothetis, N. and Haigh, A., 1988, Characterizing and optimizing multi-response processes by the taguchi method, *Quality and reliability engineering international*, 4 (2), 159-169.
- Maleki, M.G., Chabanloo, R.M. and Farrokhifar, M., 2019, Accurate coordination method based on the dynamic model of overcurrent relay for industrial power networks taking contribution of induction motors into account, *IET Gener. Transm. Distrib.*, 14, 645–655.
- Malhi, A., & Gao, R. X., 2004, PCA-based feature selection scheme for machine defect classification, *IEEE transactions on instrumentation and measurement*, 53 (6), 1517-1525, ISSN: 1557-9662. DOI: 10. 1109/TIM.2004.834070.
- Margavio, G. W., Fink, R. L. and Margavio, T. M., 1994, Quality improvement using capital budgeting and Taguchi's function, *International Journal of Quality & Reliability Management*, 11 (6), 10-20.
- Mehrjou, M. R., Mariun, N., Marhaban, M. H., and Misron, N., 2011, Rotor fault condition monitoring techniques for squirrel-cage induction machine—A review, *Mechanical Systems and Signal Processing*, 25(8), 2827-2848.
- Mellor, P.H., Roberts, D. and Turner, D.R., 1985, Microprocessor based induction motor thermal protection, 2nd International conference on electrical machines, design and applications, *IEEE conference publication* 254, 16-20.
- Mellor, P.H., Roberts, D. and Turner, D.R., 1988, Real time prediction of temperatures in an induction motor using a microprocessor, *IEEE Transactions on Electric Machines and Power system*, 13, 333-352.
- Mellor, P.H., Roberts, D. and Turner, D.R., 1991, Lumped parameter model For electrical machines of TEFC design, *IEEE Proceedings-B*, 138 (5), 205-218.
- Miller, A., Sitter, R. R., Jeff Wu, C. F. and Long, D., 1993, Are large Taguchi-style experiments necessary? A reanalysis of gear and pinion data, *Quality Engineering*, 6 (1), 21-37.
- Mitra, A., 2011, The taguchi method. *Wiley Interdisciplinary Reviews: Computational Statistics*, 3 (5), 472-480.

- Mitra, A., 2016, Fundamentals of quality control and improvement. 3rd ed. Hoboken, NJ: John Wiley & Sons.
- Mohamed, H., Lee, M. H., Sarahintu, M., Salleh, S. and Sanugi, B., 2008, The use of Taguchi method to determine factors affecting the performance of destination sequence distance vector routing protocol in mobile ad hoc networks, *Journal of Mathematics and Statistics*, 4, 194–198.
- Murphy, K. P., 2012, Machine learning: a probabilistic perspective, Adaptive computation and machine learning series. Cambridge, United States MIT press, ISBN: 9780262305242. [Ziyaret Tarihi: 07/14/2021].
- Myers, R. H., Montgomery, D. C., Vining, G. G. and Robinson, T. J., 2012, Generalized linear models: with applications in engineering and the sciences, John Wiley & Sons, 480.
- Nair, V.N., Abraham, B., MacKay, J., Box, G., Kacker, R.N., Lorenzen, T.J., ... and Jeff Wu, C.F., 1992, Taguchi's parameter design: a panel discussion, *Technometrics*, 34 (2), 127-161.
- Nandi, S., Toliyat, H.A. and Li, X., 2005, Condition monitoring and fault diagnosis of electrical motors-a review, *IEEE Trans. Energy Convers*, 20, 719–729.
- Nandi, S., Toliyat, H.A. and Li, X., 2005, Condition monitoring and fault diagnosis of electrical motors-a review. *IEEE Trans. Energy Convers.*, 20, 719–729.
- Okoro, O.I. 2005. Thermal analysis of Asynchronous Machine, *Journal of ASTM International*, 2 (1), 1-20.
- Palmieri, F. A., Baldi, M., Buonanno, A., Di Gennaro, G., & Ospedale, F., 2020, Probing a deep neural network, *Neural Approaches to Dynamics of Signal Exchanges*, 201-211.
- Pan, S.J. and Yang, Q., 2009, A survey on transfer learning, *IEEE Trans. Knowl*, 22, 1345–1359.
- Pathimind, A Beginner's Guide to Neural Networks and Deep Learning, en, URL: <http://wiki.pathmind.com/neural-network> [Ziyaret Tarihi: 11/09/2021].
- Peltarion, 2021a, Available activations, *Build an AI model*, en, [https : / / peltarion.com/knowledge-center/documentation/modeling-view/buildan-ai-model/activations](https://peltarion.com/knowledge-center/documentation/modeling-view/buildan-ai-model/activations) [Ziyaret Tarihi: 11/09/2021].
- Peltarion, 2021b, Linear activation function, *Build an AI model*, URL: <https://peltarion.com/knowledge-center/documentation/modeling-view/buildan-ai-model/activations/linear> [Ziyaret Tarihi: 11/09/2021].
- Peltarion, 2021c, ReLU activation function, *Build an AI model*, en, URL: <https://peltarion.com/knowledge-center/documentation/modeling-view/buildan-ai-model/activations/relu> [Ziyaret Tarihi: 11/09/2021].

- Peltarion, 2021d, Softmax activation function, *Build an AI model*, en, URL: <https://peltarion.com/knowledge-center/documentation/modeling-view/build-an-ai-model/activations/softmax> [Ziyaret Tarihi: 11/09/2021].
- Peltarion, 2021e, Sigmoid activation function, *Build an AI model*, en, URL: <https://peltarion.com/knowledge-center/documentation/modeling-view/build-an-ai-model/activations/sigmoid> [Ziyaret Tarihi: 11/09/2021].
- Peltarion, 2021f, Tanh activation function, *Build an AI model*, en, URL: <https://peltarion.com/knowledge-center/documentation/modeling-view/build-an-ai-model/activations/tanh> [Ziyaret Tarihi: 11/09/2021].
- Peltarion, 2021g, What are the Optimization principles in Deep Learning, *Peltarion Platform*, en, URL: [https://peltarion.com/knowledge-center/documentation/modeling-view/run-a-model/optimization-principles-\(in-deep-learning\)](https://peltarion.com/knowledge-center/documentation/modeling-view/run-a-model/optimization-principles-(in-deep-learning)) [Ziyaret Tarihi: 07/29/2021].
- Peltarion, 2021h, Regression loss metrics, *Peltarion Platform*, en, URL: <https://peltarion.com/knowledge-center/documentation/evaluation-view/regression-loss-metrics/mae/-mean-absolute-error> [Ziyaret Tarihi: 07/13/2021].
- Peltarion, 2021i, Regression loss metrics, *Peltarion Platform*, en, URL: <https://peltarion.com/knowledge-center/documentation/evaluation-view/regression-loss-metrics/mse/-mean-squared-error> [Ziyaret Tarihi: 07/29/2021].
- Peltarion, 2021j, Categorical crossentropy loss function, *Peltarion Platform*, en, 2021. URL: <https://peltarion.com/knowledge-center/documentation/modeling-view/build-an-ai-model/loss-functions/categorical-crossentropy> [Ziyaret Tarihi: 07/29/2021].
- Peltarion, 2021k, Binary crossentropy loss function, *Peltarion Platform*, en, URL: <https://peltarion.com/knowledge-center/documentation/modeling-view/build-an-ai-model/loss-functions/binary-crossentropy> [Ziyaret Tarihi: 11/09/2021].
- Phadke, M. S., 1995, Quality engineering using robust design, *Englewood Cliffs, Prentice Hall PTR*.
- Pignatiello Jr, J. J. and Ramberg, J. S., 1991, Top ten triumphs and tragedies of Genichi Taguchi, *Quality Engineering*, 4 (2), 211-225.
- Rajput, S., Bender, E. and Averbukh, M., 2020, Simplified algorithm for assessment equivalent circuit parameters of induction motors, *IET Electric power applications*, 14 (3), 426-432.
- Raptis, D. S. and Kladas, A. G., 2019, Adaptive predictive control of induction motors with on line parameter estimation using a modified genetic algorithm, *In 2019 IEEE Workshop on Electrical Machines Design, Control and Diagnosis (WEMDCD)*, IEEE, 1, 103-108.

- Riera-Guasp, M., Antonino-Daviu, J.A. and Capolino, G.-A., 2015, Advances in electrical machine, power electronic, and drive condition monitoring and fault detection: State of the art, *IEEE Trans. Ind. Electron.*, 62, 1746–1759.
- Roberts, D., 1986, The application of an induction motor thermal model to motor protection and other functions, PhD thesis, *University of Liverpool*, Liverpool.
- Sang-Bin, L., Habetler, T.G., Ronald G. and Gritter J.D., 2002, An Evaluation of Model-Based Stator Resistance Estimation for Induction Motor Stator Winding Temperature Monitoring, *IEEE Transactions on Energy Conversion*, 17 (1), 7-15.
- Sarıoğlu, M. K., Gökaşan, M. and Boğosyan, S., 2003, Asenkron makinalar ve kontrolü, *Birsen Yayınevi*.
- Senanayaka, J.S.L., Kandukuri, S.T., Van Khang, H. and Robbersmyr, K.G., 2017, Early detection and classification of bearing faults using support vector machine algorithm, *In Proceedings of the 2017 IEEE Workshop on Electrical Machines Design, Control and Diagnosis (WEMDCD)*, Nottingham, UK, 250–255.
- Shen, Fei, Chen, Chao, Yan, Ruqiang, and Gao, Robert X., 2015, Bearing fault diagnosis based on SVD feature extraction and transfer learning classification. *In: 2015 Prognostics and System Health Management Conference (PHM)*, 1–6. DOI: 10.1109/PHM.2015.7380088
- Shepard, R. A., 2021, A Computational Investigation of Cathode Materials for Next-Generation Secondary Batteries, Doctoral dissertation, *State University of New York, Binghamton*.
- Shiau, G. H., 1990, A study of the sintering properties of iron ores using the Taguchi's parameter design, *Journal of the Chinese Statistical Association*, 28 (2), 253-275.
- Siddique, A., Yadava, G. and Singh, B., 2005, A review of stator fault monitoring techniques of induction motors, *IEEE Trans. Energy Convers.*, 20, 106–114.
- Siddique, A., Yadava, G.S. and Singh, B., 2005, A review of stator fault monitoring techniques of induction motors, *IEEE Transactions on Energy Conversion*, 20 (1), 106–114.
- Silva, A. M., Alberto, J., Antunes, C. H. and Ferreira, F. J., 2020, A Stochastic Optimization Approach to the Estimation of Squirrel-Cage Induction Motor Equivalent Circuit Parameters, *In 2020 International Conference on Electrical Machines (ICEM)*, IEEE, 1, 45-51.
- Swami, H. and Jain, A.K., 2021, An Improved Scalar Controlled Drive Based on Steady State Model of Vector Controlled Drive for Squirrel Cage Induction Motor. *In Proceedings of the IEEE 30th International Symposium on Industrial Electronics (ISIE)*, Kyoto, Japan, 1–6.
- Taguchi, G., 1986, Introduction to quality engineering: designing quality into products and processes, *Asian Productivity Organization*, Hong- Kong.

- Taguchi, G., 1987, System of experimental design; engineering methods to optimize quality and minimize costs. *White Plains, NY: UNIPUB*.
- Taguchi, G. and Wu, Y., 1980, Introduction to off-line quality control, *Central Japan quality control association*, Available from American Supplier Institute, 32100.
- Taguchi, G., Chowdhury, S. and Taguchi, S., 2000, *Robust engineering*, McGraw-Hill, New York
- Taner, M. T. and Sezen, B., 2007, Taguchi's experimental design method on improvement of medical image quality, *Leadership in health services*, 20 (1), 42-51.
- Tang, Y., He, X. and Cao, J., 2021, Fast calculation method of transient temperature rise of motor for electro-mechanical braking, *Science Progress*, 104 (2), 00368504211024553.
- Terzioğlu, H., & Agacayak, A. C., (2022), Real-Time Investigation of Temperature Effect on Induction Motor Equivalent Circuit Parameter Change, *Elektronika ir Elektrotechnika*, 28 (5), 23-33.
- Terzioğlu, H., & Agacayak, A. C., (2024), Electrical and Mechanical Load Design for Induction Motors, *2nd International Conference On Scientific And Innovative Studies Icsis 2024, All Sciences Academy*, 2, 597-603. ISBN 978-625-6314-02-3
- Toliyat, H.A., Nandi, S., Choi, S. and Meshgin-Kelk, H., 2012, Electric Machines: Modeling, Condition Monitoring, and Fault Diagnosis, *CRC Press: Boca Raton, FL, USA*, 1-45.
- Tong, L. I., Su, C. T. and Wang, C. H., 1997, The optimization of multi-response problems in the Taguchi method, *International Journal of Quality & Reliability Management*, 14 (4), 367-380.
- Toren, M. ve Mollahasanoğlu, H., 2021, Üç Fazlı Asenkron Motor Parametrelerinin Elde Edilmesi İçin Optimum Stator ve Rotor Direnç Değerlerinin Taguchi Yöntemi ile Belirlenmesi, *13. Uluslararası Elektrik ve Elektronik Mühendisliği Konferansı (ELECO)*, IEEE, 440-444.
- Vapnik, V., 2013, The nature of statistical learning theory, *Springer science & business media*, New York.
- Verma, M., Singh, M. and Sreejeth, M., 2022, Integrated Taguchi method-assisted polynomial Metamodelling & Genetic Algorithm based optimisation of a surface inset permanent synchronous motor for performance improvement, *IET Electrical Systems in Transportation*, 12 (1), 26-35. <https://doi.org/10.1049/els2.12035>
- Waide, P. and Brunner, C., 2011, Energy-Efficiency Policy Opportunities for Electric Motor-Driven Systems, *IEA Energy Papers*, No. 2011/07, 1–132, OECD Publishing, Paris, <https://doi.org/10.1787/5kgg52gb9gjd-en>.

- Wang, H., Chau, K., Lee, C.H., Cao, L. and Lam, W.H., 2020, Design, Analysis, and Implementation of Wireless Shaded-Pole Induction Motors, *IEEE Trans. Ind. Electron*, 68, 6493–6503.
- Wang, Y. S., Ma, Q. H., Zhu, Q., Liu, X. T. and Zhao, L. H., 2014, An intelligent approach for engine fault diagnosis based on Hilbert–Huang transform and support vector machine, *Applied acoustics*, 75, 1-9. ISSN: 0003-682X. DOI: 10.1016/j.apacoust.2013.07.001.
- Widodo, A. and Yang, B. S., 2007, Support vector machine in machine condition monitoring and fault diagnosis, *Mechanical systems and signal processing*, 21 (6), 2560-2574.
- Y. Zeybek, 2023, Asenkron Motorlarda Kullanılan Rotor Malzemelerinin Elektriksel Özelliklerinin İyileştirilmesi ve Enerji Verimliliğine Etkilerinin İncelenmesi, Yüksek Lisans, *Fen Bilimleri Enstitüsü*, Ege Üniversitesi, TezNo.843176
- Yildiz, R., Barut, M. and Demir, R., 2020, Extended Kalman filter based estimations for improving speed-sensored control performance of induction motors, *IET Electric Power Applications*, 14 (12), 2471-2479.
- Yin, S., Ding, S. X., Xie, X., & Luo, H., 2014, A review on basic data-driven approaches for industrial process monitoring, *IEEE Transactions on Industrial electronics*, 61(11), 6418-6428. ISSN: 1557- 9948. DOI: 10.1109/TIE.2014.2301773.
- Zhang, L., 2023, Optimization of asynchronous motor with Taguchi method based on Finite Element Analysis, *In MATEC Web of Conferences*, 382, 1-6, *EDP Sciences*. <https://doi.org/10.1051/macconf/202338201010>
- Zhang, P., Du, Y., Habetler, T.G. and Lu, B., 2010, A survey of condition monitoring and protection methods for medium-voltage induction motors, *IEEE Trans. Ind. Appl.*, 47, 34–46.

EKLER

EK-1 Regresyon analizle giriş değişkenlerine göre elde edilen denklemlerin a katsayıları.

Tüm denklemlerdeki a_x katsayılarının listesi Çizelge EK-1.1- Çizelge EK-1.4'te verilmiştir.

Çizelge EK-1.1. P, n, T_y giriş parametrelili Regresyon Analiz Denklem 4.2'nin ' a_x ' katsayıları

$f(p,n,T_y) = a_0 + a_1P + a_2n + a_3T_y + a_4P^2 + a_5n^2 + a_6T_y^2 + a_7Pn + a_8PT_y + a_9nT_y$										
	a_0	a_1	a_2	a_3	a_4	a_5	a_6	a_7	a_8	a_9
0,75	R_s	2,0 E+01	1,6 E-02	-5,3 E-03	-2,2 E+00	2,7 E-05	3,0 E-06	4,4 E-01	-1,9 E-05	-6,2 E-03
	R_2	-5,4 E-01	-2,3 E-02	2,3 E-03	3,5 E+00	-8,4 E-05	-1,0 E-06	-5,5 E-01	3,8 E-05	1,6 E-02
	X_s	-5,9 E+00	1,2 E-02	6,8 E-02	3,6 E+00	-3,3 E-05	-1,0 E-06	-0,4 E-06	1,3 E-05	2,5 E-03
	X_2	-3,6 E+03	-3,8 E+01	1,4 E+01	1,8 E+03	-3,7 E-02	-7,1 E-03	-2,1 E+02	3,3 E-02	7,6 E+00
	R_m	-3,6 E+03	-3,8 E+01	1,4 E+01	1,8 E+03	-3,7 E-02	-7,1 E-03	-2,1 E+02	3,3 E-02	7,6 E+00
	X_m	5,3 E+00	3,9 E-01	7,3 E-02	-1,4 E+01	1,2 E-03	3,6 E-05	5,3 E+00	-7,9 E-04	-2,4 E-01
	X_m	5,3 E+00	3,9 E-01	7,3 E-02	-1,4 E+01	1,2 E-03	3,6 E-05	5,3 E+00	-7,9 E-04	-2,4 E-01
1,5	R_s	7,8 E+00	3,3 E-03	-1,5 E-03	-1,6 E-01	0,0 E+00	1,0 E-06	1,7 E-02	-1,0 E-06	-9,0 E-05
	R_2	1,2 E+01	3,1 E-02	-2,1 E-02	-3,0 E+00	1,7 E-05	9,0 E-06	2,0 E-01	-2,6 E-05	-4,0 E-03
	X_s	-3,4 E+00	9,1 E-03	3,4 E-02	1,4 E+00	-8,0 E-06	-1,0 E-06	-1,2 E-01	5,0 E-06	9,5 E-04
	X_2	-1,3 E+03	-5,6 E+00	4,3 E+00	4,0 E+02	-4,0 E-03	-2,0 E-03	-2,8 E+01	5,9 E-03	8,7 E-01
	R_m	-1,3 E+03	-5,6 E+00	4,3 E+00	4,0 E+02	-4,0 E-03	-2,0 E-03	-2,8 E+01	5,9 E-03	8,7 E-01
	X_m	-1,1 E+01	3,8 E-01	7,5 E-03	-2,2 E+01	9,3 E-04	4,2 E-05	3,4 E+00	-9,1 E-04	-1,2 E+00
	X_m	-1,1 E+01	3,8 E-01	7,5 E-03	-2,2 E+01	9,3 E-04	4,2 E-05	3,4 E+00	-9,1 E-04	-1,2 E+00
2,2	R_s	4,8 E+00	6,4 E-05	-9,5 E-04	-5,5 E-02	0,0 E+00	0,0 E+00	7,0 E-04	0,0 E+00	7,7 E-05
	R_2	-2,8 E+00	-2,4 E-02	1,4 E-02	1,2 E+00	-1,1 E-05	-9,0 E-06	-6,0 E-02	2,2 E-05	2,0 E-03
	X_s	-7,9 E+00	-6,0 E-03	3,7 E-02	1,6 E+00	3,0 E-06	-3,0 E-06	-5,3 E-02	2,0 E-06	-2,1 E-04
	X_2	-2,2 E+03	-4,5 E+00	6,0 E+00	5,1 E+02	-3,1 E-03	-2,8 E-03	-2,6 E+01	6,3 E-03	6,8 E-01
	R_m	-2,2 E+03	-4,5 E+00	6,0 E+00	5,1 E+02	-3,1 E-03	-2,8 E-03	-2,6 E+01	6,3 E-03	6,8 E-01
	X_m	-4,6 E+01	-6,4 E-02	1,2 E-01	1,0 E+01	1,3 E-04	-2,0 E-05	-1,0 E-01	-1,3 E-04	1,7 E-02
	X_m	-4,6 E+01	-6,4 E-02	1,2 E-01	1,0 E+01	1,3 E-04	-2,0 E-05	-1,0 E-01	-1,3 E-04	1,7 E-02
4	R_s	7,0 E+00	3,9 E-04	-6,4 E-04	-1,1 E-01	0,0 E+00	0,0 E+00	5,3 E-03	-1,0 E-06	-6,0 E-05
	R_2	4,7 E-01	-6,8 E-04	1,8 E-04	7,5 E-02	0,0 E+00	0,0 E+00	-1,9 E-03	1,0 E-06	7,3 E-05
	X_s	-2,2 E+00	1,3 E-02	5,3 E-02	6,7 E-01	-1,0 E-06	3,0 E-06	-3,1 E-02	-2,0 E-06	4,7 E-04
	X_2	-2,2 E+00	1,3 E-02	5,3 E-02	6,7 E-01	-1,0 E-06	3,0 E-06	-3,1 E-02	-2,0 E-06	4,7 E-04
	R_m	5,9 E+03	2,1 E+01	-2,7 E+01	-4,9 E+02	4,8 E-03	2,3 E-02	9,9 E+00	-2,1 E-02	-5,5 E-01
	X_m	1,9 E+00	1,2 E-03	1,0 E-01	4,6 E+00	2,0 E-05	1,2 E-05	-1,7 E-01	-6,5 E-05	-1,2 E-03
	X_m	1,9 E+00	1,2 E-03	1,0 E-01	4,6 E+00	2,0 E-05	1,2 E-05	-1,7 E-01	-6,5 E-05	-1,2 E-03

Çizelge EK-1.2. P, n, T_y, Δt giriş parametrelili Regresyon Analiz Denklem 4.3'nin 'a_x' katsayıları


$f_{(P,n,T_y,\Delta t)} = a_0 + a_1P + a_2n + a_3T_y + a_4\Delta t + a_5P^2 + a_6n^2 + a_7T_y^2 + a_8\Delta t^2 + a_9Pn + a_{10}PT_y + a_{11}P\Delta t + a_{12}nT_y + a_{13}n\Delta t + a_{14}T_y\Delta t$																
		a ₀	a ₁	a ₂	a ₃	a ₄	a ₅	a ₆	a ₇	a ₈	a ₉	a ₁₀	a ₁₁	a ₁₂	a ₁₃	a ₁₄
0,75	R _s	1,48 E+01	-1,36 E-03	3,88 E-04	1,27 E-01	5,62 E-02	-2,00 E-06	0,00 E+00	-1,7 6E-02	1,48 E-04	2,00 E-06	5,20 E-04	0,00 E+00	-2,16 E-04	0,00 E+00	-9,90 E-05
	R ₂	-9,29 E+00	-4,32 E-02	1,22 E-02	5,73 E+00	1,57 E-01	-9,20 E-05	-3,00 E-06	-5,64 E-01	1,57 E-04	4,80 E-05	1,74 E-02	3,21 E-04	-6,78 E-03	-1,27 E-04	-3,88 E-02
	X _s	-3,27 E+00	1,87 E-02	6,57 E-02	2,70 E+00	-2,87 E-02	-2,40 E-05	0,00 E+00	-4,24 E-01	-1,77 E-04	6,00 E-06	5,20 E-04	4,70 E-05	-6,02 E-03	-4,00 E-06	8,85 E-03
	X ₂	8,04 E+03	-9,50 E+00	1,09 E+00	-1,31 E+03	-1,96 E+02	-1,91 E-02	-3,34 E-03	-1,18 E+02	-2,60 E-01	1,60 E-02	4,28 E+00	-2,58 E-01	-1,28 E+00	1,27 E-01	4,62 E+01
	R _m	4,29 E+01	3,77 E-01	6,86 E-02	-1,28 E+01	-1,42 E+00	1,43 E-03	5,00 E-06	7,89 E+00	1,78 E-02	-8,96 E-04	-2,94 E+03	3,48 E-03	9,82 E-02	-5,82 E-04	-2,97 E-01
	X _m	6,02 E+00	-6,00 E-06	-2,30 E-05	-2,52 E-03	2,21 E-02	0,00 E+00	0,00 E+00	-1,61 E-04	5,40 E-05	0,00 E+00	1,00 E-06	0,00 E+00	4,00 E-06	1,00 E-06	7,50 E-05
1,5	R _s	9,14 E+00	2,74 E-02	-1,79 E-02	-2,55 E+00	3,97 E-02	1,60 E-05	8,00 E-06	1,87 E-01	5,00 E-06	-2,40 E-05	-3,64 E-03	2,00 E-05	2,66 E-03	-2,00 E-05	-4,14 E-03
	R ₂	-3,57 E+00	7,44 E-03	3,44 E-02	1,36 E+00	9,10 E-03	-8,00 E-06	-1,00 E-06	-1,18 E-01	-3,80 E-05	4,00 E-06	8,15 E-04	3,80 E-05	-2,28 E-03	-2,40 E-05	-1,22 E-03
	X _s	-2,06 E+03	-6,84 E+00	5,34 E+00	5,00 E+02	1,49 E+01	-4,17 E-03	-2,14 E-03	-2,98 E+01	-2,90 E-02	6,24 E-03	9,09 E-01	1,84 E-02	-7,46 E-01	-1,66 E-02	-1,42 E+00
	X ₂	-4,18 E+01	2,50 E-01	1,12 E-01	-8,60 E+00	-8,17 E-01	9,18 E-04	2,30 E-05	2,96 E+00	2,30 E-02	-8,73 E-04	-1,66 E-01	1,64 E-03	1,13 E-01	-1,47 E-03	-1,64 E-01
	R _m	3,63 E+00	-7,20 E-05	5,40 E-05	8,30 E-04	1,43 E-02	0,00 E+00	0,00 E+00	1,60 E-05	3,20 E-05	0,00 E+00	4,00 E-06	0,00 E+00	-4,00 E-06	-1,00 E-06	-1,40 E-05
	X _m	-2,01 E+00	-2,28 E-02	1,31 E-02	1,07 E+00	-2,38 E-02	-1,00 E-05	-9,0 E-06	-6,02 E-02	1,06 E-04	2,10 E-05	1,92 E-03	-2,30 E-05	-1,37 E-03	2,70 E-05	2,10 E-03
2,2	R _s	-9,12 E+00	-9,55 E-03	4,10 E-02	1,60 E+00	5,94 E-02	1,00 E-06	-3,00 E-06	-6,53 E-02	-5,70 E-04	5,00 E-06	1,74 E-04	4,00 E-05	-1,58 E-03	-9,00 E-05	1,75 E-03
	R ₂	-2,85 E+03	-5,10 E+00	6,86 E+00	5,56 E+02	1,24 E+01	-3,26 E-03	-3,03 E-03	-2,76 E+01	-2,70 E-02	6,6 0E-03	7,01 E-01	5,40 E-03	-9,27 E-01	-1,06 E-02	-4,50 E-01
	X _s	3,34 E+01	-3,24 E-02	7,99 E-02	1,88 E+00	-1,04 E+00	1,17 E-04	-5,00 E-06	-2,40 E-01	-4,15 E-03	-1,23 E-04	-1,74 E-02	-4,17 E-04	1,71 E-02	1,80 E-05	1,60 E-01
	X ₂	5,72 E+00	8,70 E-05	-1,72 E-04	-5,19 E-03	2,22 E-02	0,00 E+00	0,00 E+00	-3,22 E-04	1,20 E-05	0,00 E+00	8,00 E-06	-2,00 E-06	-1,40 E-05	3,00 E-06	2,35 E-04
	R _m	1,23 E-01	-8,24 E-04	4,12 E-04	1,00 E-01	5,77 E-03	0,00 E+00	0,00 E+00	-2,59 E-03	1,80 E-05	1,00 E-06	8,30 E-05	2,00 E-06	-1,72 E-04	-2,00 E-04	-2,28 E-04
	X _m	-2,98 E+00	1,19 E-02	5,56 E-02	5,63 E-01	5,45 E-02	-1,00 E-06	3,00 E-06	-3,14 E-02	-7,26 E-04	-2,00 E-06	4,47 E-04	1,90 E-05	-2,63 E-03	-6,60 E-05	2,11 E-03
4	R _s	1,92 E+03	1,50 E+01	-1,76 E+01	-3,53 E+02	1,01 E+02	4,21 E-03	2,15 E-02	9,10 E+00	-3,00 E-01	-1,94 E-02	-5,21 E-01	7,94 E-02	4,90 E-01	-2,05 E-01	-2,46 E+00
	R ₂	3,49 E+01	-1,23 E-02	1,21 E-01	3,83 E+00	-8,82 E-01	1,60 E-05	1,00 E-05	-2,56 E-01	2,89 E-03	-5,40 E-05	-2,60 E-04	-7,00 E-06	7,30 E-04	-5,36 E-04	5,05 E-02
	X _s	1,92 E+03	1,50 E+01	-1,76 E+01	-3,53 E+02	1,01 E+02	4,21 E-03	2,15 E-02	9,10 E+00	-3,00 E-01	-1,94 E-02	-5,21 E-01	7,94 E-02	4,90 E-01	-2,05 E-01	-2,46 E+00
	X ₂	3,49 E+01	-1,23 E-02	1,21 E-01	3,83 E+00	-8,82 E-01	1,60 E-05	1,00 E-05	-2,56 E-01	2,89 E-03	-5,40 E-05	-2,60 E-04	-7,00 E-06	7,30 E-04	-5,36 E-04	5,05 E-02
	R _m	3,49 E+01	-1,23 E-02	1,21 E-01	3,83 E+00	-8,82 E-01	1,60 E-05	1,00 E-05	-2,56 E-01	2,89 E-03	-5,40 E-05	-2,60 E-04	-7,00 E-06	7,30 E-04	-5,36 E-04	5,05 E-02
	X _m	3,49 E+01	-1,23 E-02	1,21 E-01	3,83 E+00	-8,82 E-01	1,60 E-05	1,00 E-05	-2,56 E-01	2,89 E-03	-5,40 E-05	-2,60 E-04	-7,00 E-06	7,30 E-04	-5,36 E-04	5,05 E-02

4	R_m	1,00	9,50	3,30	3,05	-1,46	-2,52
		E-01	E-03	E+00	E+00	E+03	E+02
	X_m	6,06	7,02	-2,34	1,14	-1,05	4,39
		E-02	E-04	E+00	E-01	E+02	E+00
	R_s	-1,10	2,00	6,64	1,95	3,33	1,02
		E-05	E-06	E-04	E-04	E-02	E-03
	R_2	-2,35	1,00	-3,56	-1,88	9,26	-5,20
		E-04	E-06	E-03	E-04	E-02	E-03
	X_s	-1,13	1,60	-1,40	6,90	3,33	-1,40
	X_2	E-03	E-05	E-02	E-03	E+00	E+00
	R_m	6,90	-2,79	3,39	-3,40	-1,48	-8,20
		E-01	E-01	E+01	E+00	E+03	E+01
	X_m	2,11	-1,03	9,26	2,72	2,33	-1,18
		E-02	E-03	E-01	E-02	E+01	E+00


EK-2 BPNN Algoritmasının Model Kaybı Grafiği ve Gerçekle Tahmin Değer Grafikleri

Veri setlerinin her biri için model kaybı grafiği ve gerçekle tahmin değer grafikleri ayrı ayrı Şekil EK-2 .1- Şekil EK-2 .8’de verilmiştir.

Veri Seti 1:




Şekil EK-2.1. Veri Seti 1 için modelin kayıplar grafiği




Şekil EK-2.2. Veri Seti 1 için gerçek değer – tahmin değer grafikleri

Veri Seti 2:




Şekil EK-2.3. Veri Seti 2 için modelin kayıplar grafiği




Şekil EK-2.4. Veri Seti 2 için gerçek değer – tahmin değer grafikleri

Veri Seti 3:




Şekil EK-2.5. Veri Seti 3 için modelin kayıplar grafiği




Şekil EK-2.6. Veri Seti 3 için gerçek değer – tahmin değer grafikleri

Veri Seti 4:



Şekil EK-2.7. Veri Seti 4 için modelin kayıplar grafiği




Şekil EK-2.8. Veri Seti 4 için gerçek değer – tahmin değer grafikleri


EK-3 MLP Algoritmasının Model Kaybı Grafiği ve Gerçekle Tahmin Değer Grafikleri

Veri setlerinin her biri için model kaybı grafiği ve gerçekle tahmin değer grafikleri ayrı ayrı Şekil EK-3.1- Şekil EK-3.28’de verilmiştir.


Veri Seti 1:




Şekil EK-3.1. Veri Seti 1-Rs için modelin kayıplar grafiği




Şekil EK-3.2. Veri Seti 1-R2 için modelin kayıplar grafiği




Şekil EK-3.3. Veri Seti 1-Xs için modelin kayıplar grafiği




Şekil EK-3.4. Veri Seti 1-X2 için modelin kayıplar grafiği




Şekil EK-3.5. Veri Seti 1-Rm için modelin kayıplar grafiği



Şekil EK-3.6. Veri Seti 1-Xm için modelin kayıplar grafiği




Şekil EK-3.7. Veri Seti 1-s için modelin kayıplar grafiği




Şekil EK-3.8. Veri Seti 1-s için modelin kayıplar grafiği


Veri Seti 2:




Şekil EK-3.9. Veri Seti 2-Rs için modelin kayıplar grafiği




Şekil EK-3.10. Veri Seti 2-R2 için modelin kayıplar grafiği




Şekil EK-3.11. Veri Seti 2-Xs için modelin kayıplar grafiği




Şekil EK-3.12. Veri Seti 2-X2 için modelin kayıplar grafiği



Şekil EK-3.13. Veri Seti 2-Rm için modelin kayıplar grafiği




Şekil EK-3.14. Veri Seti 2-Xm için modelin kayıplar grafiği




Şekil EK-3.15. Veri Seti 2-s için modelin kayıplar grafiği


Veri Seti 3:




Şekil EK-3.16. Veri Seti 3-Rs için modelin kayıplar grafiği




Şekil EK-3.17. Veri Seti 3-R2 için modelin kayıplar grafiği




Şekil EK-3.18. Veri Seti 3-Xs için modelin kayıplar grafiği




Şekil EK-3.19. Veri Seti 3-X2 için modelin kayıplar grafiği



Şekil EK-3.20. Veri Seti 3-Rm için modelin kayıplar grafiği




Şekil EK-3.21. Veri Seti 3-Xm için modelin kayıplar grafiği




Şekil EK-3.22. Veri Seti 3-Δt için modelin kayıplar grafiği


Veri Seti 4:




Şekil EK-3.23. Veri Seti 4-Rs için modelin kayıplar grafiği




Şekil EK-3.24. Veri Seti 4-R2 için modelin kayıplar grafiği




Şekil EK-3.25. Veri Seti 4-R2 için modelin kayıplar grafiği



Şekil EK-3.26. Veri Seti 4-X2 için modelin kayıplar grafiği



Şekil EK-3.27. Veri Seti 4-Rm için modelin kayıplar grafiği




Şekil EK-3.28. Veri Seti 4-Xm için modelin kayıplar grafiği


EK-4 KNN Algoritmasının Model Kaybı Grafiği ve Gerçekle Tahmin Değer Grafikleri

Veri setlerinin her biri için model kaybı grafiği ve gerçekle tahmin değer grafikleri ayrı ayrı Şekil EK-4.1- Şekil EK-4.27’de verilmiştir.


Veri Seti 1:




Şekil EK-4.1. Veri Seti 1- R_s için gerçek değer – tahmin edilen değer grafiği




Şekil EK-4.2. Veri Seti 1- R_2 için gerçek değer – tahmin edilen değer grafiği




Şekil EK-4.2. Veri Seti 1- X_s için gerçek değer – tahmin edilen değer grafiği




Şekil EK-4.3. Veri Seti 1- X_2 için gerçek değer – tahmin edilen değer grafiği




Şekil EK-4.4. Veri Seti 1- R_m için gerçek değer – tahmin edilen değer grafiği



Şekil EK-4.5. Veri Seti 1- X_m için gerçek değer – tahmin edilen değer grafiği




Şekil EK-4.6. Veri Seti 1- Δt için gerçek değer – tahmin edilen değer grafiği




Şekil EK-4.7. Veri Seti 1-s için gerçek değer – tahmin edilen değer grafiği


Veri Seti 2:




Şekil EK-4.8. Veri Seti 2-R_s için Gerçek Değer – Tahmin Edilen Değer Grafiği




Şekil EK-4.9. Veri Seti 2-R₂ için Gerçek Değer – Tahmin Edilen Değer Grafiği




Şekil EK-4.10. Veri Seti 2-X_s için Gerçek Değer – Tahmin Edilen Değer Grafiği




Şekil EK-4.11. Veri Seti 2- X_2 için Gerçek Değer – Tahmin Edilen Değer Grafiği



Şekil EK-4.12. Veri Seti 2- R_m için Gerçek Değer – Tahmin Edilen Değer Grafiği




Şekil EK-4.13. Veri Seti 2- X_m için Gerçek Değer – Tahmin Edilen Değer Grafiği




Şekil EK-4.14. Veri Seti 2-s için Gerçek Değer – Tahmin Edilen Değer Grafiği


Veri Seti 3:




Şekil EK-4.15. Veri Seti 3-R_s için Gerçek Değer – Tahmin Edilen Değer Grafiği




Şekil EK-4.16. Veri Seti 3-R₂ için Gerçek Değer – Tahmin Edilen Değer Grafiği




Şekil EK-4.17. Veri Seti 3- X_s için Gerçek Değer – Tahmin Edilen Değer Grafiği




Şekil EK-4.18. Veri Seti 3- X_2 için Gerçek Değer – Tahmin Edilen Değer Grafiği



Şekil EK-4.19. Veri Seti 3- R_m için Gerçek Değer – Tahmin Edilen Değer Grafiği




Şekil EK-4.20. Veri Seti 3- X_m için Gerçek Değer – Tahmin Edilen Değer Grafiği




Şekil EK-4.21 Veri Seti 3- Δt için Gerçek Değer – Tahmin Edilen Değer Grafiği


Veri Seti 4:




Şekil EK-4.22. Veri Seti 4- R_s için Gerçek Değer – Tahmin Edilen Değer Grafiği




Şekil EK-4.23. Veri Seti 4- R_2 için Gerçek Değer – Tahmin Edilen Değer Grafiği




Şekil EK-4.24. Veri Seti 4- X_s için Gerçek Değer – Tahmin Edilen Değer Grafiği



Şekil EK-4.25. Veri Seti 4- X_2 için Gerçek Değer – Tahmin Edilen Değer Grafiği



Şekil EK-4.26. Veri Seti 4- R_m için Gerçek Değer – Tahmin Edilen Değer Grafiği




Şekil EK-4.27. Veri Seti 4- X_m için Gerçek Değer – Tahmin Edilen Değer Grafiği


EK-5 RF Algoritmasının Model Kaybı Grafiği ve Gerçekle Tahmin Değer Grafikleri

Veri setlerinin her biri için model kaybı grafiği ve gerçekle tahmin değer grafikleri ayrı ayrı Şekil EK-5.1- Şekil EK-5.28’de verilmiştir.


Veri Seti 1:




Şekil EK-5.1. Veri Seti 1 RF-R_s için gerçek değer – tahmin edilen değer grafiği




Şekil EK-5.2. Veri Seti 1 RF- R₂ için gerçek değer – tahmin edilen değer grafiği




Şekil EK-5.3. Veri Seti 1 RF- X_s için gerçek değer – tahmin edilen değer grafiği




Şekil EK-5.4. Veri Seti 1 RF- X_2 için gerçek değer – tahmin edilen değer grafiği




Şekil EK-5.5. Veri Seti 1 RF- R_m için gerçek değer – tahmin edilen değer grafiği



Şekil EK-5.6. Veri Seti 1 RF- X_m için gerçek değer – tahmin edilen değer grafiği




Şekil EK-5.7. Veri Seti 1 RF- Δt için gerçek değer – tahmin edilen değer grafiği




Şekil EK-5.8. Veri Seti 1 RF-s için gerçek değer – tahmin edilen değer grafiği


Veri Seti 2:




Şekil EK-5.9. Veri Seti 2 RF- R_s için gerçek değer – tahmin edilen değer grafiği




Şekil EK-5.10. Veri Seti 2 RF- R_2 için gerçek değer – tahmin edilen değer grafiği




Şekil EK-5.11. Veri Seti 2 RF- X_s için gerçek değer – tahmin edilen değer grafiği




Şekil EK-5.12. Veri Seti 2 RF- X_2 için gerçek değer – tahmin edilen değer grafiği



Şekil EK-5.13. Veri Seti 2 RF- R_m için gerçek değer – tahmin edilen değer grafiği




Şekil EK-5.14. Veri Seti 2 RF- X_m için gerçek değer – tahmin edilen değer grafiği




Şekil EK-5.15. Veri Seti 2 RF- s için gerçek değer – tahmin edilen değer grafiği


Veri Seti 3:




Şekil EK-5.16. Veri Seti 3 RF- R_s için gerçek değer – tahmin edilen değer grafiği




Şekil EK-5.17. Veri Seti 3 RF- R_2 için gerçek değer – tahmin edilen değer grafiği




Şekil EK-5.18. Veri Seti 3 RF- X_s için gerçek değer – tahmin edilen değer grafiği




Şekil EK-5.19. Veri Seti 3 RF- X_2 için gerçek değer – tahmin edilen değer grafiği



Şekil EK-5.20. Veri Seti 3 RF- R_m için gerçek değer – tahmin edilen değer grafiği




Şekil EK-5.21. Veri Seti 3 RF- X_m için gerçek değer – tahmin edilen değer grafiği




Şekil EK-5.22. Veri Seti 3 RF- Δt için gerçek değer – tahmin edilen değer grafiği


Veri Seti 4:




Şekil EK-5.23. Veri Seti 4 RF- R_s için gerçek değer – tahmin edilen değer grafiği




Şekil EK-5.24. Veri Seti 4 RF- R_2 için gerçek değer – tahmin edilen değer grafiği




Şekil EK-5.25. Veri Seti 4 RF- X_s için gerçek değer – tahmin edilen değer grafiği



Şekil EK-5.26. Veri Seti 4 RF- X_2 için gerçek değer – tahmin edilen değer grafiği



Şekil EK-5.27. Veri Seti 4 RF- R_m için gerçek değer – tahmin edilen değer grafiği




Şekil EK-5.28. Veri Seti 4 RF- X_m için gerçek değer – tahmin edilen değer grafiği


EK-6 XGBoost Algoritmasının Model Kaybı Grafiği ve Gerçekle Tahmin Değer Grafikleri

Veri setlerinin her biri için model kaybı grafiği ve gerçekle tahmin değer grafikleri ayrı ayrı Şekil EK-6.1- EK-6.24'te verilmiştir.


Veri Seti 1:




Şekil EK-6.1. Veri Seti 1 XGB R_s için gerçek değer – tahmin edilen değer grafiği




Şekil EK-6.2. Veri Seti 1 XGB R_2 için gerçek değer – tahmin edilen değer grafiği




Şekil EK-6.3. Veri Seti 1 XGB X_s için gerçek değer – tahmin edilen değer grafiği




Şekil EK-6.4. Veri Seti 1 XGB X_2 için gerçek değer – tahmin edilen değer grafiği




Şekil EK-6.5. Veri Seti 1 XGB R_m için gerçek değer – tahmin edilen değer grafiği



Şekil EK-6.6. Veri Seti 1 XGB X_m için gerçek değer – tahmin edilen değer grafiği




Şekil EK-6.7. Veri Seti 1 XGB Δt için gerçek değer – tahmin edilen değer grafiği




Şekil EK-6.8. Veri Seti 1 XGB s için gerçek değer – tahmin edilen değer grafiği


Veri Seti 2:




Şekil EK-6.6. Veri Seti 2 XGB R_s için gerçek değer – tahmin edilen değer grafiği




Şekil EK-6.7. Veri Seti 2 XGB R_2 için gerçek değer – tahmin edilen değer grafiği




Şekil EK-6.8. Veri Seti 2 XGB X_2 için gerçek değer – tahmin edilen değer grafiği



Şekil EK-6.9. Veri Seti 2 XGB R_m için gerçek değer – tahmin edilen değer grafiği




Şekil EK-6.10. Veri Seti 2 XGB X_m için gerçek değer – tahmin edilen değer grafiği




Şekil EK-6.11. Veri Seti 2 XGB s için gerçek değer – tahmin edilen değer grafiği


Veri Seti 3:




Şekil EK-6.12. Veri Seti 3 XGB R_s için gerçek değer – tahmin edilen değer grafiği




Şekil EK-6.13. Veri Seti 3 XGB R_2 için gerçek değer – tahmin edilen değer grafiği




Şekil EK-6.14. Veri Seti 3 XGB X_s için gerçek değer – tahmin edilen değer grafiği




Şekil EK-6.15. Veri Seti 3 XGB X_2 için gerçek değer – tahmin edilen değer grafiği



Şekil EK-6.16. Veri Seti 3 XGB R_m için gerçek değer – tahmin edilen değer grafiği




Şekil EK-6.17. Veri Seti 3 XGB X_m için gerçek değer – tahmin edilen değer grafiği




Şekil EK-6.18. Veri Seti 3 XGB Δt için gerçek değer – tahmin edilen değer grafiği


Veri Seti 4:




Şekil EK-6.19. Veri Seti 4 XGB R_s için gerçek değer – tahmin edilen değer grafiği




Şekil EK-6.20. Veri Seti 4 XGB R_2 için gerçek değer – tahmin edilen değer grafiği




Şekil EK-6.21. Veri Seti 4 XGB X_s için gerçek değer – tahmin edilen değer grafiği



Şekil EK-6.22. Veri Seti 4 XGB X_2 için gerçek değer – tahmin edilen değer grafiği



Şekil EK-6.23. Veri Seti 4 XGB R_m için gerçek değer – tahmin edilen değer grafiği



Şekil EK-6.24. Veri Seti 4 XGB X_m için gerçek değer – tahmin edilen değer grafiği