

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MAKİNE ÖĞRENİMİ YAKLAŞIMLARINA
DAYANAN SİNCAP KAFESLİ ASENKRON
MAKİNE TASARIMI OPTİMİZASYON
TEKNİĞİ

Sema Nur İPEK

DOKTORA TEZİ
Elektrik Mühendisliği Anabilim Dalı
Elektrik Makinaları ve Güç Elektronik Programı

Danışman
Prof. Dr. Kamuran Nur BEKİROĞLU

Eş-Danışman
Dr. Öğr. Üyesi Engin AYÇİÇEK

Ağustos, 2025

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MAKİNE ÖĞRENİMİ YAKLAŞIMLARINA
DAYANAN SİNCAP KAFESLİ ASENKRON MAKİNE
TASARIMI OPTİMİZASYON TEKNİĞİ

Sema Nur İPEK tarafından hazırlanan tez çalışması 18.08.2025 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik Mühendisliği Anabilim Dalı Elektrik Makinaları ve Güç Elektroniği Programı **DOKTORA TEZİ** olarak kabul edilmiştir.

Prof. Dr. Kamuran Nur BEKİROĞLU
Yıldız Teknik Üniversitesi
Danışman

Dr. Öğr. Üyesi Engin AYÇIÇEK
Yıldız Teknik Üniversitesi
Eş-Danışman

Jüri Üyeleri

Prof. Dr. Kamuran Nur BEKİROĞLU, Danışman
Yıldız Teknik Üniversitesi

Prof. Dr. Atiye Hülya OBDAN, Üye
Yıldız Teknik Üniversitesi

Doç. Dr. Derya Ahmet KOCABAŞ, Üye
İstanbul Teknik Üniversitesi

Doç. Dr. Selin ÖZÇİRA ÖZKILIÇ, Üye
Yıldız Teknik Üniversitesi

Doç. Dr. Ali AĞÇAL, Üye
Süleyman Demirel Üniversitesi

Danışmanım Prof. Dr. Kamuran Nur BEKİROĞLU sorumluluğunda tarafımda hazırlanan "Makine Öğrenimi Yaklaşımlarına Dayanan Sincap Kafesli Asenkron Makine Tasarımı Optimizasyon Tekniğı" başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Sema Nur İPEK

Aileme ve Hocalarıma...



TEŞEKKÜR

Araştırmamın yönünü belirlememdeki rehberliği, potansiyel alanları keşfetmemi sağlayan değerli önerileri ve rol modelim olarak birlikte çalışma imkânı sunduğu için danışmanım Prof. Dr. Nur Bekiroğlu'na teşekkür ederim. Çalışmama değer katan katkıları, karşılaştığım problemleri aşmamda verdiği destek ve çalışmalarımı anlamlı bir sonuca dönüştürmemdeki yol göstericiliği için Dr. Öğr. Üyesi Murat Taşkiran'a teşekkür ederim. İzleme sürecinde yaptıkları değerli yönlendirmeler için Prof. Dr. Atiye Hülya Obdan ve Doç. Dr. Derya Ahmet Kocabaş'a teşekkür ederim. Bu süreçteki önemli tavsiyeleri ve motivasyonel desteği için Dr. Öğr. Üyesi Engin Ayçiçek'e teşekkür ederim. Araştırma becerilerimi geliştirmemde ve akademik kariyerime başlamamda bana ilham veren Prof. Dr. Eyüp Akpınar'a teşekkür ederim. Son olarak, bu süreçte her an yanımda olan ve sürekli desteklerini hissettiren aileme teşekkür ederim.

Sema Nur İPEK

İÇİNDEKİLER

SİMGE LİSTESİ	vii
KISALTMA LİSTESİ	xi
ŞEKİL LİSTESİ	xiii
TABLO LİSTESİ	xv
ÖZET	xvi
ABSTRACT	xviii
1 GİRİŞ	1
2 TEORİK ÇERÇEVE	6
2.1 Asenkron Motor Parametreleri	6
2.1.1 Asenkron Motor Elektriksel Parametreleri	6
2.1.2 Asenkron Motor Mekaniksel Parametreleri	7
2.1.3 Asenkron Motor Güç Akışı	7
2.2 Makine Öğrenimi Yöntemleri	11
2.2.1 Yapay Sinir Ağları	11
2.2.2 Yılan Optimizasyonu Tekniği	15
2.2.3 Performans Değerlendirme Ölçütleri	17
3 ASENKRON MAKİNE TASARIM OPTİMİZASYONU İÇİN GELİŞTİRİLEN HİBRİT YÖNTEM	20
4 GELİŞTİRİLEN HİBRİT YÖNTEMİN FARKLI GÜÇ SE- VİYELERİNDEKİ ASENKRON MAKİNELERE UYGU- LANMASI	26
4.1 Tahmin Aşaması	26
4.1.1 Elektriksel Parametrelerin Tahmini	26
4.1.2 Mekaniksel Parametrelerin Tahmini	42
4.2 Optimizasyon Aşaması	62
4.2.1 Mekaniksel Parametre Kapsamının Geliştirilmesi	62

4.2.2 Yılan Optimizasyonunun Uygulanması	67
5 SONUÇLAR VE ÖNERİLER	78
KAYNAKÇA	80
TEZDEN ÜRETİLMİŞ YAYINLAR	88



SİMGE LİSTESİ

a_c	Elektriksel yüklenme (A/m)
a_r	Uzunluk/kutup adımı oranı
B_{av}	Manyetik yüklenme (T)
B_{cr}	Rotor boyunduruğundaki akı yoğunluğu (T)
B_{cs}	Stator boyunduruğundaki akı yoğunluğu (T)
B_{g1}	Hava aralığı akı yoğunluğu (T)
B_m	Maksimum akı yoğunluğu (T)
B_{tr}	Rotor dışındaki akı yoğunluğu (T)
B_{ts}	Stator dışındaki akı yoğunluğu (T)
b_0	Stator oluk ağız genişliği (mm)
b_1	Stator oluk alt kısım genişliği (mm)
b_2	Stator oluk üst kısım genişliği (mm)
C_M	Stator moment katsayısı
C_{Mr}	Rotor moment katsayısı
C_o	Faydalanma katsayısı
$\cos \varphi$	Güç faktörü
D	Stator iç çapı (mm)
D_b	Rulman çapı (mm)
d_{cs}	Stator boyunduruk derinliği (mm)
d_{cr}	Rotor boyunduruk derinliği (mm)
d_e	Rotor uç halkası genişliği (mm)
d_{eh}	Rotor uç halkası yüksekliği (mm)
D_i	Rotor iç çapı (mm)

D_{os}	Stator dış çapı (mm)
D_r	Rotor dış çapı (mm)
d_0	Rotor oluk ağız genişliği (mm)
d_1	Rotor oluk alt kısım genişliği (mm)
d_2	Rotor oluk üst kısım genişliği (mm)
d_s	Stator oluk gövde yüksekliği (mm)
d_{s0}	Stator oluk ağız yüksekliği (mm)
d_{s1}	Stator oluk yalıtım kısmı yüksekliği (mm)
η	Verim (%)
f	Frekans (Hz)
F	Radyal kuvvet (N)
g	Hava aralığı (mm)
γ_{emf}	EMF katsayısı
γ_{mmf}	Rotor MMF katsayısı
h_r	Rotor oluk gövde yüksekliği (mm)
h_{r0}	Rotor oluk ağız yüksekliği (mm)
h_{r1}	Rotor oluk yalıtım kısmı yüksekliği (mm)
I_1	Stator akımı (A)
I'_2	Rotor akımı (A)
I_{ck}	Rotor çubuk akımı (A)
I_{ha}	Rotor uç halkası akımı (A)
I_0	Mıknatıslanma akımı (A)
J_e	Rotor uç halkası akım yoğunluğu (A/mm ²)
J_{sw}	Stator sargı akım yoğunluğu (A/mm ²)
J_r	Rotor çubuğu akım yoğunluğu (A/mm ²)
k_d	Yayımla faktörü
k_i	İstifleme katsayısı
k_p	Kirişleme faktörü
k_w	Sargı faktörü

L	Stator uzunluđu (mm)
L_1	Stator kaçak endüktansı (H)
L'_2	Rotor kaçak endüktansı (H)
l_e	Rotor çubuk sonu uzunluđu (mm)
L_{ms}	Mıknatıslanma endüktansı (H)
L_s	Stator endüktans terimi (H)
L_r	Rotor endüktans terimi (H)
μ	Sürtünme katsayısı
n	Devir sayısı (d/dk)
N_r	Rotor oluk sayısı
N_s	Stator oluk sayısı
ω	Açısal hız (rad/s)
p	Çift kutup sayısı
$2p$	Kutup sayısı
P_ζ	Çıkış gücü (W)
P_{cus}	Stator bakır kaybı (W)
P_{cur}	Rotor bakır kaybı (W)
P_{Fes}	Stator demir kaybı (W)
P_{fuko}	Fuko akımı kaybı (W/m ³)
P_g	Giriş gücü (W)
P_{hist}	Histerezis kaybı (W/m ³)
ϕ_p	Kutup başına akı (Wb)
$P_{kayıplar}$	Toplam kayıplar (W)
P_{mek}	Mekanik kayıp (W)
P_n	Anma gücü (W)
P_{ek}	Ek kayıplar (W)
P_{rot}	Rotasyonel kayıplar (W)
$P_{rüzgar}$	Rüzgar kayıpları (W)
$P_{sürt}$	Sürtünme kayıpları (W)

Q	Reaktif güç (VAr)
q	Birim kutup ve faz sayısı başına düşen oluk sayısı
R	Korelasyon katsayısı
R^2	Determinasyon katsayısı
r_1	Faz başına stator direnci (Ω/faz)
r'_2	Statora indirgenmiş faz başına rotor direnci (Ω/faz)
r_{Fe}	Faz başına demir kayıp direnci (Ω/faz)
ρ_{Fe}	Demirin özgül direnci ($\Omega \cdot \text{m}$)
k	Pürüzlülük katsayısı
ρ_c	Soğutma maddesi yoğunluğu (kg/m^3)
s	Kayma
t	Laminasyon kalınlığı (mm)
τ_k	Kutup adımı (mm)
τ_o	Oluk adımı (mm)
t_s	Stator dış genişliği (mm)
t_{s1}	Stator dışı üst kısım genişliği (mm)
V	Gerilim (V)
V_f	Faz gerilimi (V)
v	Çevresel hız (m/s)
w_1	Stator sarım sayısı
w_{tr}	Rotor dış genişliği (mm)
w_{tr1}	Rotor dışı üst kısım genişliği (mm)
X_1	Faz başına stator reaktansı (Ω/faz)
X'_2	Statora indirgenmiş faz başına rotor reaktansı (Ω/faz)
X_m	Faz başına mıknatıslama reaktansı (Ω/faz)
Z_1	Toplam iletken sayısı
Z_{1f}	Oluk iletken sayısı

KISALTMA LİSTESİ

ABC	Artificial Bee Colony (Yapay Arı Kolonisi)
ANFIS	Adaptive Network-Based Fuzzy Inference Systems (Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemleri)
ANN	Artificial Neural Network (Yapay Sinir Ağı)
DE	Differential Evolution (Diferansiyel Evrim)
EMF	Electromotive Force (Elektromotor Kuvvet)
ENN	Elman Neural Network (Elman Sinir Ağı)
ES	Evolutionary Strategy (Evrimsel Strateji)
FEM	Finite Element Method (Sonlu Elemanlar Yöntemi)
FFNN	Feed-Forward Neural Network (İleri Beslemeli Sinir Ağı)
GA	Genetic Algorithm (Genetik Algoritma)
GRNN	Generalized Regression Neural Network (Genel Regresyon Sinir Ağı)
GSA	Graph Neural Algorithm (Grafik Sinir Ağı)
GWO	Grey Wolf Optimization (Gri Kurt Optimizasyonu)
ICA	Imperialist Competitive Algorithm (Emperyalist Rekabet Algoritma)
IEC	International Electrotechnical Commission (Uluslararası Elektroteknik Komisyonu)
IM	Induction Motor (Asenkron Motor)
IPA	Interior Point Algorithm (İç Nokta Algoritması)
LSTM	Long Short-Term Memory (Uzun Kısa Süreli Bellek)
MAE	Mean Absolute Error (Ortalama Mutlak Hata)
MAPE	Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hata)

ML	Machine Learning (Makine Öğrenimi)
MLP	Multi-Layer Perceptron (Çok Katmanlı Algılayıcı)
MMF	Magnetomotive Force (Manyetomotor Kuvvet)
MOTEOA	Multi-Objective Thermal Exchange Optimization Algorithm (Çok Amaçlı Termal Değişim Optimizasyon Algoritması)
MSE	Mean Squared Error (Ortalama Karese Hata)
NSGA-II	Non-dominated Sorting Genetic Algorithm II (Baskın Olmayan Sıralama Genetik Algoritması II)
PMSM	Permanent Magnet Synchronous Motor (Kalıcı Mıknatıslı Senkron Motor)
PS	Pattern Search (Örüntü Arama)
PSO	Particle Swarm Optimization (Parçacık Sürü Optimizasyonu)
RBF	Radial Basis Function (Radyal Tabanlı Fonksiyon)
RMSE	Root Mean Square Error (Kök Ortalama Kare Hatası)
RNN	Recurrent Neural Network (Tekrarlayan Sinir Ağı)
RSM	Response Surface Methodology (Cevap Yüzeyi Metodolojisi)
SA	Simulated Annealing (Benzetimli Tavlama)
SA-ERWCA	Simulated Annealing—Evaporation Rate Water Cycle Algorithm (Benzetimli Tavlama - Buharlaştırma Oranlı Su Döngüsü Algoritması)
SGD	Stochastic Gradient Descent (Stokastik Gradyan İnişi)
SGDM	Stochastic Gradient Descent with Momentum (Momentumlu Stokastik Gradyan İnişi)
SMAPE	Symmetric Mean Absolute Percentage Error (Simetrik Ortalama Mutlak Yüzde Hata)
SO	Snake Optimizer (Yılan Optimizasyonu)
SVR	Support Vector Regression (Destek Vektör Regresyonu)
SWG	Standard Wire Gauge (İngiliz Standart Tel Ölçüsü)

ŞEKİL LİSTESİ

Şekil 2.1	Asenkron motorun eşdeğer devresi	7
Şekil 2.2	Asenkron motor mekaniksel boyutları	8
Şekil 2.3	Asenkron motor güç akışı	9
Şekil 2.4	Çok katmanlı algılayıcının yapısı	12
Şekil 2.5	Radyal tabanlı fonksiyon sinir ağının yapısı	12
Şekil 2.6	Genel regresyon sinir ağının yapısı	13
Şekil 2.7	Tekrarlayan sinir ağının yapısı	14
Şekil 2.8	Uzun kısa süreli bellek ağı hücreleri	15
Şekil 2.9	Yılan optimizasyonu algoritması akış diyagramı	16
Şekil 3.1	Yapay sinir ağı ve yılan optimizasyonu tabanlı hibrit optimizasyon tekniği	21
Şekil 4.1	Elektriksel tahmin aşamasının oluşturulması	30
Şekil 4.2	Farklı sinir ağı yapılarının elektriksel parametre tahminlerinin gerçek değerlerle dağılımsal karşılaştırılması	36
Şekil 4.3	Çok katmanlı algılayıcı modelinin elektriksel tahmin aşaması test performansı	37
Şekil 4.4	Radyal tabanlı fonksiyon sinir ağı modelinin elektriksel tahmin aşaması test performansı	38
Şekil 4.5	Genel regresyon sinir ağı modelinin elektriksel tahmin aşaması test performansı	39
Şekil 4.6	Çok katmanlı algılayıcı elektriksel tahmin aşaması test çıktı noktaları	40
Şekil 4.7	Çok katmanlı algılayıcı elektriksel tahmin hata histogram grafikleri	41
Şekil 4.8	Mekaniksel tahmin aşamasının oluşturulması	48
Şekil 4.9	Mekaniksel tahmin aşaması eğitim ve test adımlarının regresyon grafikleri	55
Şekil 4.10	Mekaniksel tahmin aşaması eğitim ve test adımlarının hata histogramları	56
Şekil 4.11	Mekaniksel tahmin aşaması eğitim ve test adımlarının kutu grafikleri	58

Şekil 4.12 Tekrarlayan sinir ağı mekaniksel tahmin çıktı verilerinin dağılımı	59
Şekil 4.13 Yaklaşık makine ağırlığı ve tahmini ana mekaniksel boyutlar arasındaki ilişki	59
Şekil 4.14 Mekaniksel tahmin vaka örneğinin tasarımı	61
Şekil 4.15 Mekaniksel tahmin vaka örneğinin manyetik analizi	62
Şekil 4.16 Stator iç çapının ampirik olarak belirlenmesi	63
Şekil 4.17 Faydalanma katsayısının ampirik olarak belirlenmesi	63
Şekil 4.18 Güncellenen oluk parametreleri	64
Şekil 4.19 Optimizasyon süreci kayıp ve verim değişimleri	71
Şekil 4.20 Optimizasyon süreci parametre değişimleri ve duyarlılıkları	72
Şekil 4.21 Örnek-1 optimizasyon süreci (400 kW)	73
Şekil 4.22 Örnek-2 optimizasyon süreci (250 kW)	74
Şekil 4.23 Örnek-3 optimizasyon süreci (150 kW)	74
Şekil 4.24 Örnek-4 optimizasyon süreci (22 kW)	75
Şekil 4.25 Örnek-5 optimizasyon süreci (4 kW)	75
Şekil 4.26 Örnek-1 motor geometrisi (Motor 1: 400 kW)	76
Şekil 4.27 Örnek-2 motor geometrisi (Motor 2: 250 kW)	76

TABLO LİSTESİ

Tablo 4.1	Elektriksel tahmin aşaması veri setinin temel özellikleri . . .	33
Tablo 4.2	Elektriksel tahmin aşaması sinir ağı yapılarının temel parametreleri	33
Tablo 4.3	Elektriksel tahmin aşaması sinir ağı yapıları simülasyon süreleri	34
Tablo 4.4	İleri beslemeli sinir ağı tabanlı elektriksel tahmin yapılarının farklı hata metriklerine göre performans sonuçları	39
Tablo 4.5	Tekrarlayan sinir ağı elektriksel tahmin performans metrikleri	40
Tablo 4.6	Çok katmanlı algılayıcıyla belirli örnek motorlarda elde edilen elektriksel tahmin sonuçları	43
Tablo 4.7	Mekaniksel tahmin aşaması veri setinin temel özellikleri . . .	51
Tablo 4.8	Mekaniksel tahmin aşaması yapay sinir ağı yapılarının temel parametreleri	52
Tablo 4.9	Sinir ağı tabanlı mekaniksel tahmin yapılarının farklı hata metriklerine göre performans sonuçları	57
Tablo 4.10	Sinir ağı tabanlı mekaniksel tahmin yapısının performansının farklı bir regresyon modeli ile karşılaştırılması	60
Tablo 4.11	Mekaniksel tahmin vaka örneğinin giriş parametreleri	61
Tablo 4.12	Mekaniksel tahmin vaka örneğinin çıkış parametreleri	61
Tablo 4.13	Optimizasyon aşaması örnek motor anma değerleri	69
Tablo 4.14	Optimizasyon aşaması örnek motor çıktı değerleri	70

Makine Öğrenimi Yaklaşımlarına Dayanan Sincap Kafesli Asenkron Makine Tasarımı Optimizasyon Tekniđi

Sema Nur İPEK

Elektrik Mühendisliđi Anabilim Dalı

Doktora Tezi

Danışman: Prof. Dr. Kamuran Nur BEKİROĐLU

Eş-Danışman: Dr. Öğr. Üyesi Engin AYÇİÇEK

Elektrik makinesi tasarım optimizasyonu, birbirleriyle aynı doğrultuda iyileşme göstermeyebilecek hedefler ve parametreler arasında var olabilecek doğrusal olmayan ilişkiler nedeniyle oldukça karmaşık bir problem alanı oluşturmaktadır. Literatürde yer alan geleneksel optimizasyon yöntemlerinin bir kısmı, veri sayısındaki azlık nedeniyle genelleştirilebilirlikten uzaklaşmakta ya da kullanılan algoritmanın doğası geređi yüksek hesaplama maliyetleri gerektirmektedir. Bunların yanı sıra, bazı çalışmalarda makine tasarım parametrelerinin deneysel olarak elde edilmesi zahmetli süreçler gerektirmektedir. Ayrıca, üreticiye özgü verilere erişimin kısıtlı olduđu durumlar da tasarım ya da optimizasyon süreçleri için önemli bir engel teşkil etmektedir. Bu tez kapsamında, düşük gerilimli sincap kafes asenkron motorların tasarım optimizasyonu için Yapay Sinir Ađı ve Yılan Optimizasyonu Algoritmasının entegre edildiđi özgün bir hibrit metodoloji geliştirilmiştir. Önerilen iki aşamalı yaklaşımda, ilk aşamada 4-900 kW güç aralığındaki 1164 motor verisinden öğrenen Yapay Sinir Ađı modelleri (elektriksel parametreler için Çok Katmanlı Algılayıcı (MLP), mekanik parametreler için Tekrarlayan Sinir Ađı (RNN)) ile başlangıç tasarım parametreleri tahmin edilmekte; ikinci aşamada ise bu tahminler, Yılan Optimizasyonu Algoritmasının başlangıç vektörü olarak kullanılmakta ve uygulanan adaptif sınırlama stratejisiyle verim hedefi doğrultusunda optimize edilmektedir. Elektrik makinesi tasarımına

özgü uyarlanan Yılan Optimizasyonu Algoritması ve uygulanan adaptif sınırlama stratejisi ile hem hızlı yakınsama sağlanmış hem de mühendislik açısından uygulanabilir çözümler elde edilmiştir. Geliştirilen hibrit yapı, makine öğrenmesinin hızlı tahmin kabiliyeti ile meta-sezgisel optimizasyonun global arama yeteneğini bir araya getirerek hem hesaplama verimliliği hem de yüksek çözüm kalitesi sunmakta ve optimal tasarım parametrelerine etkin bir şekilde ulaşılmasını mümkün kılmaktadır. Geliştirilen metodoloji, özellikle kritik tasarım verilerine erişimin kısıtlı olduğu durumlarda, tasarımcılara güvenilir bir başlangıç noktası sunarak tasarım sürecini önemli ölçüde kolaylaştırmakta ve endüstriyel uygulamalara katkı sağlamaktadır.

Anahtar Kelimeler: Asenkron makine, tasarım optimizasyonu, hibrit metodoloji, makine öğrenmesi, yılan optimizasyonu, meta-sezgisel optimizasyon

ABSTRACT

Squirrel Cage Asynchronous Machine Design Optimization Technique Based on Machine Learning Approaches

Sema Nur İPEK

Department of Electrical Engineering
Doctor of Philosophy Thesis

Supervisor: Prof. Dr. Kamuran Nur BEKIROGLU

Co-supervisor: Assist. Prof. Dr. Engin AYCICEK

The design optimization of electrical machines constitutes a highly complex problem domain due to objectives that may not improve in the same direction and the potential nonlinear relationships between parameters. Some conventional optimization methods found in the literature lack generalizability due to limited data, or, owing to the inherent nature of the algorithms used, require high computational costs. Furthermore, in some studies, obtaining the machine design parameters experimentally is a labor-intensive process. In addition, restricted access to manufacturer-specific data presents a significant obstacle for design or optimization processes. Within the scope of this thesis, an original hybrid methodology integrating Artificial Neural Networks and the Snake Optimizer Algorithm has been developed for the design optimization of low-voltage squirrel cage induction motors. In the proposed two-stage approach, in the first stage, Artificial Neural Network models trained on data from 1164 motors within the 4–900 kW power range (Multi-Layer Perceptron (MLP) for electrical parameters and Recurrent Neural Network (RNN) for mechanical parameters) predict the initial design parameters. In the second stage, these predictions are used as the starting vector for the Snake Optimizer Algorithm, and the predictions are optimized according to the efficiency target through an implemented adaptive constraint strategy. Both fast convergence and engineeringly feasible solutions have been achieved by the Snake Optimization Algorithm specifically adapted for electrical machine

design and the applied adaptive constraint strategy. This hybrid structure, combining the rapid prediction capability of machine learning with the global search ability of metaheuristic optimization, offers both computational efficiency and high solution quality, enabling effective attainment of optimal design parameters. The developed methodology provides a reliable starting point for designers especially in cases where access to critical design data is limited, significantly facilitating the design process and contributing to industrial applications.

Keywords: Induction machine, design optimization, hybrid methodology, machine learning, Snake Optimizer, metaheuristic optimization



1 GİRİŞ

Elektrik makinelerinin tasarım optimizasyonu, modern mühendislik uygulamalarında kritik bir öneme sahiptir. Artan enerji maliyetleri, çevresel kaygılar ve teknolojik gelişmeler, elektrik makinelerinin daha sürdürülebilir bir karakteristiğe sahip olmasını zorunlu kılmaktadır. Bu bağlamda optimizasyon süreçleri, enerji verimliliğini artırmak, yüksek performanslı çözümler sunmak, uzun ömürlü ürünler üretmek ve üretim maliyetlerini düşürmek gibi temel hedeflere ulaşılmasını sağlamaktadır[1, 2]. Söz konusu hedeflerin yanı sıra, makinelerin elektrikli araçlar, havacılık sistemleri ve enerji üretim tesisleri gibi farklı çalışma alanlarının spesifik gereksinimlerine en uygun şekilde özelleştirilebilmesi mümkün olmaktadır.

Elektrik makinelerinin optimizasyonunda temel olarak Konjugat Gradyan Algoritması, Ardışık Karesel Programlama gibi deterministik yöntemler ve Genetik Algoritma (GA), Parçacık Sürü Optimizasyonu (PSO) gibi stokastik yöntemler kullanılabilir. Bu yöntemler birden fazla maliyet fonksiyonuna odaklanılarak çok amaçlı algoritmalara ya da farklı yöntemler birbiriyle entegre edilerek hibrit yaklaşımlara evrilebilmektedir [3–7]. Bu kapsamda, optimizasyon tekniklerinin etkinlikleri, literatürdeki çeşitli örneklerde değerlendirilmiştir.

Asenkron motorların (IM) optimizasyonunda Genetik Algoritma tabanlı yöntemler yaygın olarak kullanılmaktadır. Altı fazlı asenkron motorun çekirdek uzunluğu, stator iç çapı gibi parametreler Genetik Algoritma ile optimize edilerek motor veriminde yaklaşık %5 artış sağlanmıştır [8]. İç Nokta Algoritması (IPA) ve Genetik Algoritma karşılaştırılarak merdiven tip ikincil tek taraflı lineer asenkron motorun verim, güç faktörü vb. değerleri iyileştirilmiş ve sonuçların analitik hesaplamalarla uyumlu olduğu gösterilmiştir [9]. Diğer bir çalışmada Genetik Algoritma ile asenkron motorun verim ve maliyet optimizasyonunda manyetik yüklenme, elektrik yüklenme, stator/rotor oluk oranları gibi altı tasarım değişkeni optimize

edilmiş, en yüksek verim M19 nüve ve bakır rotor çubuklarıyla elde edilmiştir [10]. Baskın Olmayan Sıralama Genetik Algoritması-II (NSGA-II), üç fazlı asenkron motorun verim ve güç yoğunluğu maksimizasyonu hedeflerini eş zamanlı optimize ederek üç farklı algoritmayla karşılaştırıldığında daha geniş yakınsama alanları sunmuş, %80 verim ve 12 kW/kg güç yoğunluğu değerlerine ulaşılmıştır [11]. Benzer şekilde, NSGA-II tabanlı beş fazlı asenkron makinelerinin çok amaçlı optimizasyon yöntemi, verim ve iletken malzeme maliyetini optimize ederek Sonlu Elemanlar Metodu (FEM) analizleriyle doğrulanan çözümler sunmuştur [12].

Sürü zekası tabanlı yöntemler asenkron motorların optimizasyonunda etkili sonuçlar vermektedir. Parçacık Sürü Optimizasyonu kullanılarak altı fazlı sincap kafesli asenkron motorun stator dış çapı, oluk çapları, dış genişlikleri gibi dokuz geometrik parametresi optimize edilmiş, verim %91'den %95'e çıkarılmıştır [13]. Altı fazlı bakır rotorlu asenkron motor için, Taguchi Metodu ve Değiştirilmiş PSO ile iki aşamalı optimizasyon gerçekleştirilmiştir [14]. Yapay Arı Kolonisi Algoritması (ABC) kullanılarak altı fazlı asenkron motorunun stator yığın uzunluğu, iç stator çapı gibi parametreleri optimize edilmiş, yüksek enerji verimliliği ve daha küçük boyut elde edilmiştir [15]. Gri Kurt Optimizasyonu-Destek Vektör Regresyonu (GWO-SVR) Modeli ve Çok Amaçlı Termal Değişim Optimizasyon Algoritması (MOTEOA) kullanan entegre bir malzeme-yapı tasarım yaklaşımında, toplam kayıp %3.46 azaltılmış, temel hız %0.75 ve verim %0.74 artırılmıştır [16]. Yapay Ekosistem Optimizasyonu ile asenkron motorun stator ve rotor oluk geometrisi parametreleri optimize edilerek motor verimi %90.34'ten %91.575'e yükseltilmiş, Genetik Algoritmaya göre iki kat daha hızlı sonuç elde edilmiştir [17].

İstatistiksel ve deneysel optimizasyon yöntemleri asenkron motorların tasarımında önemli rol oynamaktadır. Cevap Yüzeyi Metodolojisi (RSM) ve Emperyalist Rekabet Algoritması (ICA) Kombinasyonu ile toroidal sargılı doğrusal asenkron motorun tasarım optimizasyonu yapılmıştır [18]. Asenkron motorun rotor oluk boyutlarının üretim toleranslarının etkilerini azaltmak için Adaptif Ağırlıklı Cevap Yüzeyi Metodu ve Monte Carlo Simülasyonu kullanılmış, toplam kayıpta 8.1 W azalma, kalkış momenti ve başlangıç akımının güvenilirliğinde sırasıyla %51.93 ve %47.76 iyileştirilme elde edilmiştir [19]. Elektrikli araç uygulamaları için asenkron motorların optimizasyonunda, Taguchi Metodu ile yüksek yoğunluklu çalışma noktalarının bulunduğu bölgelere odaklanılarak, optimal stator oluk ve rotor çubuk kombinasyonları elde edilmiştir [20].

Yerel ve klasik arama yöntemleri asenkron motorların optimizasyonunda etkin sonuçlar vermektedir. Rastgele Yeniden Başlatmalı Yerel Arama Optimizasyonu Tekniği (RRLS) ile Hill Climbing Algoritması kullanılarak kayma, rotor akımı, kalkış momenti ve güç faktörü parametrelerine odaklanılarak optimizasyon gerçekleştirilmiş; üç farklı asenkron makinede verim, rotor akımı ve güç faktöründe iyileştirme sağlanmıştır [21]. Lineer asenkron motorlarda yan çubuk genişliği gibi parametrelerin tek değişkenli optimizasyon yöntemiyle iyileştirilmesi sonucu, önerilen yapı, geleneksel yapıya kıyasla itme kuvvetini başlangıç hızında %13 ve maksimum hızda %15 oranında artırmıştır [22].

Makine öğrenimi ve hibrit yaklaşımlar asenkron motor optimizasyonunda yenilikçi çözümler sunmaktadır. Tavlamalı Seçim Yaklaşımı (AS), İki Noktalı Çaprazlama ve Adaptif Levy Mutasyonu kullanan Makine Öğrenimi Tabanlı Gen Optimizasyonu Tekniği ile, üç farklı asenkron makinenin verimi %5.5-7.5 oranında artırılmıştır [23]. Çok Aşamalı Optimizasyon Yaklaşımında, Benzetimli Tavlama (SA), Evrimsel Strateji (ES) ve Örüntü Arama (PS) Yöntemleri birleştirilerek, hesaplama yükünü azaltmak için Yapay Sinir Ağları kullanılmış, referans makineye göre %6 daha iyi fitness değeri ve %45 azaltılmış hesaplama maliyeti elde edilmiştir [24].

Teori tabanlı yaklaşımlar da asenkron motorlarının optimizasyonunda kullanılmaktadır. Çift Dönen Alan Teorisi ve Sonlu Elemanlar Analizinden yararlanılarak, tek fazlı asenkron motorun stator ve rotor oluk geometrisi optimize edilmiş, üretim maliyetindeki artışı minimumda tutarak, verimde en az % 3 artış sağlama hedefine odaklanılmıştır [25].

Literatür incelendiğinde, elektrik motorlarının tasarımında odaklanılan verim, boyut, maliyet ve performans gibi birbirleriyle çelişen tasarım hedeflerinin ve elektrik motorlarının doğasında var olan termal, elektromanyetik ve mekanik etkileşimlerin doğrusal olmayan karakteristiğinin, bu makinelerin tasarımını ve optimizasyonunu kompleks hale getirdiği görülmektedir. Konvansiyonel optimizasyon algoritmaları genellikle lokal optimumlara takılma eğilimi gösterirken, sonlu eleman analizleriyle entegre edilen optimizasyon yaklaşımları ise yüksek hesaplama maliyetlerine yol açmaktadır. Bu durum birçok çalışmada kapsamın daralmasına, sınırlamalara ya da bazı hedeflerden ödünler verilmesine neden olmuştur. Bu durum literatürdeki optimizasyon problemlerinin ele aldığı değişken sayısının düşüklüğü, optimizasyon süreçlerinin karmaşıklığı, hesaplama maliyetleri, temel alınan örnek sayılarının azlığı dikkate alındığında fark edilebilir.

Tezin amacı, girdi olarak sunulan anma değerlere karşılık olarak, makinenin optimal tasarım parametrelerini öneren bir teknik oluşturmaktır. Bu tekniğin literatürdeki kapsam, karmaşıklık ve maliyet gibi sınırlamaları aşarak, geniş bir güç aralığında, hızlı ve pratik bir şekilde çıktı verebilmesi hedeflenmiştir. Bu doğrultuda, katalog verilerinden hareketle elektrik makinelerinin elektriksel ve mekaniksel parametrelerinin tahminini gerçekleştiren ve bu parametreleri katalogda belirtilen verim hedeflerini sağlayacak şekilde optimize eden veri-odaklı bir metodoloji geliştirilmiştir. Tezde, Yapay Sinir Ağı ve Yılan Optimizasyonu (snake optimizer) tabanlı bir parametre optimizasyon yöntemi sunulmaktadır. 4-900 kW arasındaki 2-8 kutuplu, 1164 örnek sincap kafesli asenkron motordan oluşan bir veri seti ile öğrenme sağlanmıştır. Bu sayede, bu yöntemde girilen anma değerlere göre, başlangıç tasarım parametreleri Derin Öğrenme Tabanlı Yapay Sinir Ağları ile tahmin edilir ve sonra Yılan Optimizasyonu kullanılarak verim hedefini ve gerçekleştirilebilirliği sağlayacak şekilde optimize edilir. Bu tez çalışması, literatüre aşağıdaki özgün katkıları sunmaktadır:

- **Veri Merkezli Yaklaşım:** Örnek motor verilerinin %75'i öğrenme, % 25'i ise test için kullanılmış ve sonuçlar bu öğrenme sürecine dayandırılarak sunulmuştur. Bu sayede geleneksel tekniklere dayalı optimizasyon yöntemlerinin aksine, öğrenmenin sağladığı aralıkta parametre önerilerini, tekrarlayan hesaplamalara ihtiyaç duymaksızın doğrudan sunabilen yenilikçi, veri odaklı bir metodoloji ortaya konulmuştur.
- **Makine Öğrenimi ile Hız ve Hesaplama Verimliliği:** Makine öğrenimine dayalı bu yaklaşım sayesinde tasarım parametreleri çok daha hızlı ve düşük hesaplama maliyetiyle elde edilmektedir.
- **Kapsamlı Yapı Optimizasyonu:** Öğrenme süreci karmaşıklıktan kaçınıldığı için, üzerinden çalışılan değişken sayısı artırılabilir.
- **Geniş Güç Aralığı ve Yüksek Genelleştirilebilirlik:** 4–900 kW aralığında ve 2–8 kutuplu motorları kapsayan geniş bir güç aralığında çalışılmıştır ve yüksek genelleştirilebilirlik sağlanmıştır.
- **Hibrit ve Çift Aşamalı Metodoloji:** Yapay Sinir Ağları ve elektrik makineleri optimizasyonunda daha önce kullanılmamış olan Yılan Optimizasyonu, sırasıyla parametre tahmini ve optimizasyon aşamalarında kullanılmak üzere entegre edilmiştir. Böylece tümleşik bir çerçeve oluşturulmuştur. Bu çerçeve ile yalnızca tahmin kullanıldığında

karşılaşılabilecek uygulanamaz çözümlerin ya da yalnızca optimizasyon algoritması kullanıldığında oluşabilecek hesaplama yükünün önüne geçilmektedir.

- **Endüstriyel Uygulanabilirlik:** Üretici verilerinden öğrenme sağlanarak, endüstriyel uygulanabilirlik açısından efektif sonuçlar elde edilebilir.

Özetle bu araştırma, geleneksel optimizasyon yaklaşımlarından farklılaşarak, yeni bir veri odaklı ve makine öğrenimi tabanlı metodoloji ile elektrik makinelerinin tasarım optimizasyonuna katkı sunmayı amaçlamaktadır. Çalışmada düşük gerilimli sincap kafes asenkron motorlara odaklanılmıştır.

İkinci bölümde, motorun elektriksel ve mekaniksel parametrelerine ilişkin temel bilgiler ile çalışmada kullanılan makine öğrenimi yaklaşımlarının teorik özelliklerine değinilmiştir.

Üçüncü bölümde, önerilen hibrit optimizasyon tekniğinin metodolojisi, sistematik bir çerçevede sunulmuştur.

Dördüncü bölümde, gerçekleştirilen geliştirme çalışmalarının aşamaları ve sonuçları açıklanmıştır.

Son bölümde ise elde edilen bulgular kapsamlı şekilde değerlendirilmiş ve gelecekteki çalışmalara yönelik önerilerde bulunulmuştur.

2

TEORİK ÇERÇEVE

2.1 Asenkron Motor Parametreleri

2.1.1 Asenkron Motor Elektriksel Parametreleri

Asenkron motorun elektriksel modeli, stator ve rotoruna ait akım ve gerilim denklemleriyle tanımlanabilir ve 2.1 eşitliğindeki gibi gösterilebilir [26]. Söz konusu denklem, motorun sargı parametrelerini (L_1 , L_2'), mıknatıslanma endüktansını (L_{ms}) ve elektriksel açısal hız değerini (ω) içermektedir.

$$\begin{bmatrix} V_{abcs} \\ V'_{abcr} \end{bmatrix} = \begin{bmatrix} r_1 + j\omega L_s & j\omega L'_{sr} \\ j\omega (L'_{sr})^T & r'_2 + j\omega L'_r \end{bmatrix} \begin{bmatrix} I_{abcs} \\ I'_{abcr} \end{bmatrix} \quad (2.1)$$

Burada:


$$L_s = \begin{bmatrix} L_1 + L_{ms} & -\frac{1}{2}L_{ms} & -\frac{1}{2}L_{ms} \\ -\frac{1}{2}L_{ms} & L_1 + L_{ms} & -\frac{1}{2}L_{ms} \\ -\frac{1}{2}L_{ms} & -\frac{1}{2}L_{ms} & L_1 + L_{ms} \end{bmatrix} \quad (2.2)$$

$$L'_r = \begin{bmatrix} L'_2 + L_{ms} & -\frac{1}{2}L_{ms} & -\frac{1}{2}L_{ms} \\ -\frac{1}{2}L_{ms} & L'_2 + L_{ms} & -\frac{1}{2}L_{ms} \\ -\frac{1}{2}L_{ms} & -\frac{1}{2}L_{ms} & L'_2 + L_{ms} \end{bmatrix} \quad (2.3)$$

$$L'_{sr} = L_{ms} \begin{bmatrix} \cos\theta_r & \cos(\theta_r + \frac{2\pi}{3}) & \cos(\theta_r - \frac{2\pi}{3}) \\ \cos(\theta_r - \frac{2\pi}{3}) & \cos\theta_r & \cos(\theta_r + \frac{2\pi}{3}) \\ \cos(\theta_r + \frac{2\pi}{3}) & \cos(\theta_r - \frac{2\pi}{3}) & \cos\theta_r \end{bmatrix} \quad (2.4)$$

Kararlı durum analizinde, asenkron motorun elektriksel karakteristiği, elektriksel modelinden yola çıkılarak, Şekil 2.1'de gösterildiği gibi tek fazlı eşdeğer devre ile temsil edilebilmektedir. Eşdeğer devrede stator sargı direnci r_1 ve statora indirgenmiş rotor sargı direnci r'_2 ile gösterilmektedir. Demir

kayıpları eşdeğer devrede r_{Fe} ile ifade edilmiştir. Kaçak endüktans değerleri olan L_1 ve L_2' , eşdeğer devrede sırasıyla $X_1 = j\omega L_1$ ve $X_2' = j\omega L_2'$ reaktansları şeklinde ifade edilmiştir. Miknatıslanma bileşeni $X_m = j\omega L_{ms}$ reaktansı ile gösterilirken, kayma ise s parametresi ile temsil edilmektedir.




Şekil 2.1 Asenkron motorun eşdeğer devresi

2.1.2 Asenkron Motor Mekaniksel Parametreleri


Asenkron motorda mekaniksel parametreler, özellikle rotor ve statorun geometrik boyutları ve bu yapılara ait alt karakteristik ölçüler üzerinden belirlenir. Asenkron motorun temel mekanik yapısı ilişkin kesitler Şekil 2.2'deki gibi gösterilebilir. Burada D_{os} , D , L , g , D_r , D_i , d_s , t_s , b_1 , b_2 , d_{cs} , h_r , w_{tr} , d_1 , d_2 ve d_{cr} sırasıyla stator dış çapı, stator iç çapı, stator uzunluğu, hava aralığı, rotor dış çapı, rotor iç çapı, stator oluk gövde yüksekliği, stator dişi alt kısım genişliği, stator oluk alt kısım genişliği, stator oluk üst kısım genişliği, stator boyunduruk derinliği, rotor oluk gövde yüksekliği, rotor dişi alt kısım genişliği, rotor oluk alt kısım genişliği, rotor oluk üst kısım genişliği ve rotor boyunduruk derinliği boyutunu ifade etmektedir [27, 28]. Bu boyutlar dışında, motorun karakteristiklerinin tam olarak yansıtılabilmesi için, rotor uç halkası genişliği d_e değerinin de bilinmesi önemlidir.

2.1.3 Asenkron Motor Güç Akışı


Asenkron motorlarda oluşan kayıplar; bakır kayıpları, demir kayıpları, mekanik kayıplar ve ek kayıplar olmak üzere dört gruba ayrılabilir. Bakır kayıpları, stator ve rotor sargılarının elektriksel dirençlerinden kaynaklanmakta olup, toplam kayıpların önemli bir bölümünü teşkil eder. Bu kayıpların düzeyi, iletkenlerin kesit alanları ve kullanılan materyalin elektriksel özellikleri ile ilişkilidir. Demir kayıpları ise, manyetik nüvede ortaya çıkan histeresis ve eddy akımları nedeniyle meydana gelir. Toplam kayıplar içerisindeki oranları görece düşük olmakla birlikte, hassas boyutlandırma problemlerinde ve verim analizinde mutlaka göz önünde bulundurulmaları gerekmektedir. Mekanik kayıplar ise, motorda oluşan sürtünme ve rüzgâr kayıplarının toplamını



(a) Motorun genel görünümü



(b) Statorun kısmi görünümü




(c) Rotorun kısmi görünümü

Şekil 2.2 Asenkron motor mekaniksel boyutları

ifade eder. Bu kayıplar, motorun mekanik tasarımı ve rulman kalitesi ile bağlantılıdır. Ayrıca, asenkron motorlarda giriş gücünün % 0,5 ila % 2'si

oranında ek kayıpların olabileceği kabul edilmektedir [29].



Şekil 2.3 Asenkron motor güç akışı

Şekil 2.3'te asenkron motorun güç akışına ilişkin bir diyagram verilmiştir. Buradaki bakır kayıpları, stator ve rotor sargı dirençleri dikkate alınarak 2.5 ve 2.6 eşitliklerindeki gibi hesaplanabilir.

$$P_{cus} = 3r_1 I_1^2 \quad (2.5)$$

$$P_{cur} = 3r_2' I_2'^2 \quad (2.6)$$

Burada, I_1 ve I_2' stator ve rotor faz akımlarını ifade etmektedir. Demir kayıpları, maksimum akı yoğunluğu (B_m), demirin özgül direnci (ρ_{Fe}) ve stator laminasyon kalınlığı (t) ile yakından ilişkilidir [29]. Bu doğrultuda birim hacimdeki kayıp değeri 2.7 ile hesaplanabilir.

$$P_{Fe} = P_{hist} + P_{fuko} \quad (2.7)$$

Burada:

$$P_{hist} = k_{hist} f B_m^{2.5} \quad (2.8)$$

$$P_{fuko} = \frac{\pi^2 f^2 B_m^2 t^2}{6\rho_{Fe}} \quad (2.9)$$

Toplam demir kaybı değeri ile 2.10 eşitliğindeki gibi yaklaşık stator hacmi dikkate alınarak hesaplanabilir.

$$P_{Fes} = P_{Fe} V \quad (2.10)$$

Burada:

$$V = \frac{\pi L(D_{os}^2 - D^2)}{4} \quad (2.11)$$

Sürtünme kayıpları ise radyal kuvvet (F) ve rulman çapı gibi (D_b) bileşenlerle ilişkili olarak, 2.12 eşitliğindeki gibi tespit edilebilir [29]. Bu tip motorlarda, rulman çapının değeri rotor mil çapına eşit alınabilir.

$$P_{sürt} = 0.5\omega\mu F D_b \quad (2.12)$$

Burada:

$$\omega = \frac{2\pi n}{60} \quad (2.13)$$

Burada, μ sürtünme katsayısını gösterir. Rüzgar kayıpları ise, rotor parametreleri ile ilişkili olarak, 2.14 eşitliğinden yola çıkılarak belirlenebilir [29].

$$P_{rüzgar} = P_{r1} + P_{r2} \quad (2.14)$$

Burada:

$$P_{r1} = \frac{1}{32} k C_M \pi \rho_c \omega^3 D_r^4 L \quad (2.15)$$

$$P_{r2} = \frac{1}{64} C_{Mr} \rho_c \omega^3 (D_r^5 - D_i^5) \quad (2.16)$$

2.17'de gösterildiği gibi, sürtünme ve rüzgar kayıplarının toplamı, mekanik kayıpları oluşturur.

$$P_{mek} = P_{sürt} + P_{rüzgar} \quad (2.17)$$

Ek kayıplar, giriş gücünün belirli bir yüzdesi esas alınarak 2.18'deki gibi hesaplanır.

$$P_{ek} = P_g 0.02 \quad (2.18)$$

2.19'deki gibi, giriş gücü P_g ile toplam kayıpların farkı alınarak $P_ç$ çıkış gücüne ulaşılabilir.

$$P_ç = P_g - P_{\text{kayıplar}} \quad (2.19)$$

Burada:

$$P_{\text{kayıplar}} = P_{\text{cus}} + P_{\text{cur}} + P_{\text{Fes}} + P_{\text{mek}} + P_{\text{ek}} \quad (2.20)$$

Böylece 2.21'deki gibi verim değerine ulaşılabilir.

$$\eta = \frac{P_ç}{P_g} 100 \quad (2.21)$$

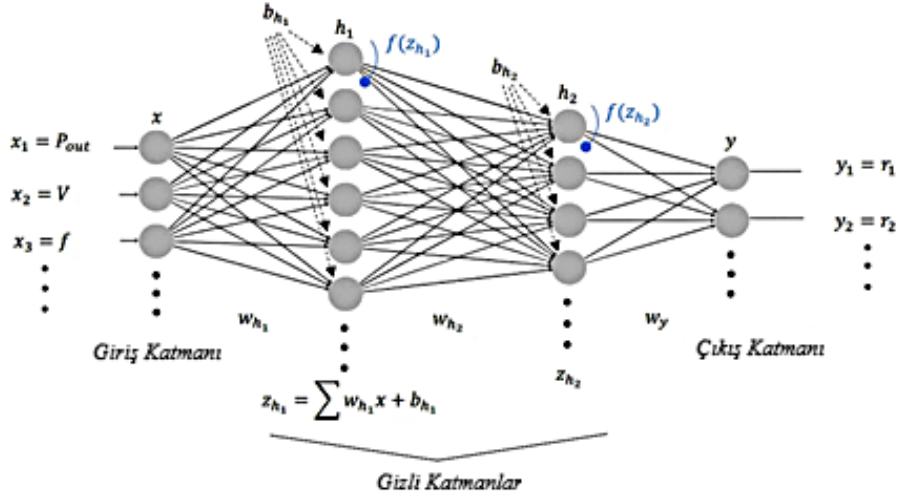
2.2 Makine Öğrenimi Yöntemleri

2.2.1 Yapay Sinir Ağları

Yapay sinir ağı, bir çözüm algoritmasının belirli bir bölümünü tanımlamak için kullanılan bir araçtır. Yönlendirilmiş bir grafik topolojisine sahip, girdilere verilen durum tepkileri aracılığıyla çıktı üreten, paralel olarak karmaşık işlemleri gerçekleştirebilen dinamik sistemlerdir. Bu ağlar, belirli sayıda nörona ve farklı bağlantı şekillerine sahip, sonlu katmanlardan oluşur. Söz konusu katman ve bağlantı biçimleri, yeterli problem çözme kalitesini ve minimum problem çözme süresini sağlayacak şekilde seçilir [30].

2.2.1.1 Çok Katmanlı Algılayıcı

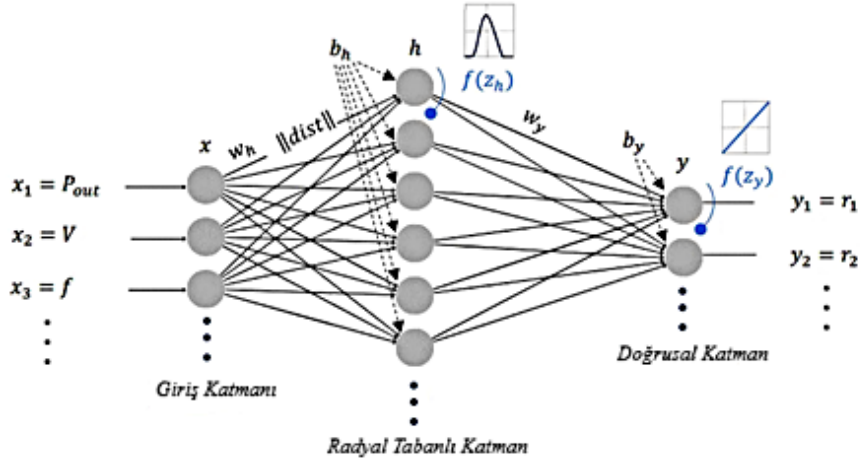
Çok Katmanlı Algılayıcı (MLP), birden fazla hesaplama katmanından oluşan hem ayrık hem de sürekli verileri etkili bir şekilde işleyebilen ileri beslemeli (feedforward) bir sinir ağıdır [31]. Her bir nöron katmanında, girdiler ve ağırlıklar arasındaki etkileşimler yinelemeli olarak işlenir; ağırlıklar, eğitim sürecinde geri yayılım algoritması aracılığıyla optimize edilir ve böylece ağ, verideki ayırt edici desenleri kademeli olarak öğrenir [32–34]. Girişten çıkışa bilgi akışı sırasında ReLU veya sigmoid gibi aktivasyon fonksiyonlarının kullanılması, modele doğrusal olmayan nitelikler kazandırır ve bu durum, MLP'lerin, yalnızca alan tabanlı doğrusal modellerin yetersiz kaldığı, karmaşık problem yapılarında yüksek başarı sağlamasına olanak tanır. Şekil 2.4, bir MLP yapısının basitleştirilmiş bir tasvirini göstermektedir.



Şekil 2.4 Çok katmanlı algılayıcının yapısı

2.2.1.2 Radyal Tabanlı Fonksiyon Sinir Ağı

Radyal Tabanlı Fonksiyon Sinir Ağı (RBF), problem çözümü için büyük boyutlu doğrusal olmayan bir uzay oluşturur ve verileri bu uzayda sınıflandırır [35]. RBF ağı, girdilerin ardından bir gizli katman ve bir çıkış katmanı içerir. Geri yayılım (backpropagation) yerine tek geçişli (single-pass) bir öğrenme algoritması kullanır ve belirli bir hata hedefine ulaşana kadar gizli katmana nöron ekleyerek öğrenir. Sonuç olarak, gizli katmanda, her biri matematiksel olarak bir radyal tabanlı fonksiyon ile tanımlanan, epoch sayısı kadar birim bulunur. Nihai hesaplamaları yapan çıkış katmanının boyutu ise genellikle gizli katmana göre çok daha küçüktür. Şekil 2.5, RBF ağ yapısını göstermektedir.

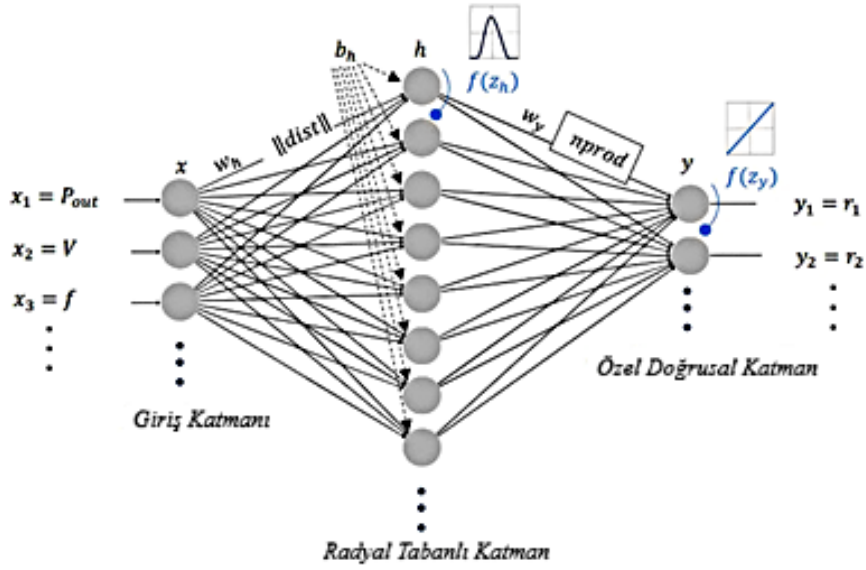


Şekil 2.5 Radyal tabanlı fonksiyon sinir ağının yapısı

2.2.1.3 Genel Regresyon Sinir Ağı

Genel Regresyon Sinir Ağı (GRNN), regresyon prensiplerine dayalı olarak geliştirilen, radyal tabanlı sinir ağlarının özgün bir türevidir. GRNN

mimarisi, giriş ve çıkış katmanları arasında yerleştirilmiş örüntü ve agregasyon katmanlarından oluşur. Örüntü katmanı, ağ topolojisindeki nöron düğüm sayısına bağlı olarak veri öğrenimini parametrize eder [36]. Eğitim verisinin her bir örneği için örüntü katmanında bir nöron bulunur ve bu katmanda, giriş vektörü ile merkezler arasındaki mesafe genellikle Gauss radyal taban fonksiyonuyla hesaplanır. Sonuç olarak ağ, olasılıksal hedef değerlerin ağırlıklı istatistiksel ortalamasını optimum biçimde yakınsayan bir hesaplama paradigması sunar [37]. Yayılım parametresi ise fonksiyonun hassasiyetini belirleyerek, ağı doğruluk ve genelleme yetenekleri arasında denge sağlar. GRNN'nin basit bir gösterimi Şekil 2.6'te sunulmuştur.



Şekil 2.6 Genel regresyon sinir ağının yapısı

2.2.1.4 Tekrarlayan Sinir Ağı

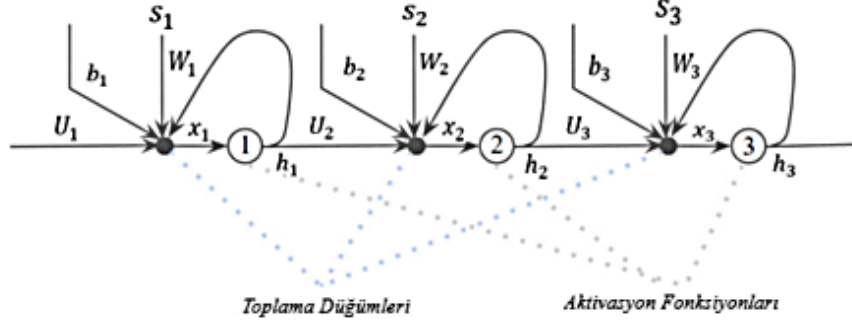
Tekrarlayan Sinir Ağı (RNN), her aşamada katmanın çıkışı ile girişi arasındaki bağlantı üzerinden geri besleme sağlayarak çıktı üretir [38]. Bu bağlantı, ileri beslemeli ağlardan farklı olarak, ağ yapısının zamansal ilişki ve hafıza özellikleri edinmesini sağlar [39–41]. Ağı katmanları hem bir önceki katmandan hem de bir geri besleme bağlantısından aynı anda giriş alır ve katmanlar arasındaki ilişki, 2.22, 2.23 ve 2.24 eşitlikleri ile matematiksel olarak ifade edilebilir [38].

$$x_{t+1} = Ax_1 + U_k h_t + W_k s_t + b_k \quad (2.22)$$

$$h_t = \sigma_t(x_t) \quad (2.23)$$

$$z_t = V_k h_t + D_k s_t + c_k \quad (2.24)$$

Burada; $t = 0, \dots, N$, \mathbf{s}_t : harici giriş vektörü, \mathbf{x}_t : iç durum vektörü, \mathbf{h}_t : gizli birim vektörü, \mathbf{W}_k : ağırlıklar, \mathbf{b}_k : yanlılık değerleri, σ_t : aktivasyon fonksiyonlarıdır. Şekil 2.7 ise RNN mimarisinin sadeleştirilmiş bir gösterimi bulunmaktadır.



Şekil 2.7 Tekrarlayan sinir ağının yapısı

2.2.1.5 Uzun Kısa Süreli Bellek Ağı

Uzun Kısa Süreli Bellek Ağı (LSTM), bellek hücresi ile RNN mimarisini geliştirir ve basit yönlendirme ile gradyan hesaplama zorluklarının üstesinden gelmek için kontrol sinyalleri sağlar [38]. Bir LSTM katmanı, bir veri dizisindeki adımlar arasında var olan uzun vadeli bağlantıları öğrenme ve anlama yeteneğine sahiptir. Ağ modeli, ardışık giriş katmanı, LSTM katmanları ve regresyon problemi için tam bağlantılı bir katman kullanılarak oluşturulabilir [42]. Şekil 2.8'de gösterilen LSTM hücrelerinde i , f , g , o , c ve h sırasıyla giriş kapısı, unutma kapısı, hücre aday, çıkış kapısı, hücre durumu ve gizli durumu göstermektedir ve hücre işlemi matematiksel olarak sırasıyla 2.25, 2.26, 2.27 ve 2.28 ile ifade edilebilir [38].

$$i_t = \sigma_g(W_i x_t + R_i h_{t-1} + b_i) \quad (2.25)$$


$$f_t = \sigma_g(W_f x_t + R_f h_{t-1} + b_f) \quad (2.26)$$

$$g_t = \sigma_c(W_g x_t + R_g h_{t-1} + b_g) \quad (2.27)$$

$$o_t = \sigma_g(W_o x_t + R_o h_{t-1} + b_o) \quad (2.28)$$

LSTM'nin temel mimarisi, her biri bir hücre durumu ve üç ana kapı mekanizması içeren özelleştirilmiş hücrelerden oluşur. LSTM'nin çalışma prensibi, gelen verilerin ve hücre durumunun eşzamanlı olarak işlenmesine dayanır. Unutma kapısı, gereksiz bilgileri ortadan kaldırarak hücre durumunu geliştirir. Güncelleme kapısı, yeni bilgileri hücre durumuna entegre ederek

onu günceller. Son aşamada, çıkış kapısı hücre durumundan işlenmiş bilgileri çıkarır ve bunları çıktı olarak sunar.



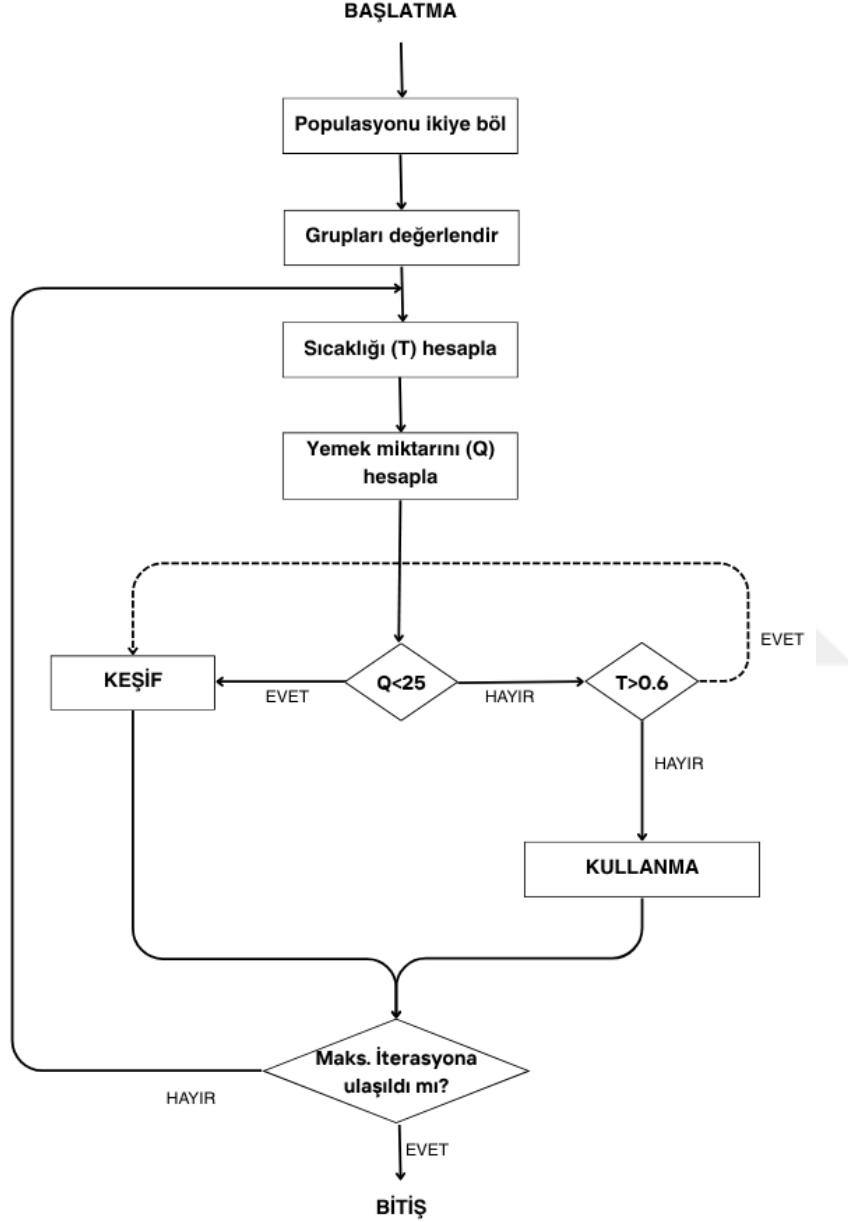
Şekil 2.8 Uzun kısa süreli bellek ağı hücreleri

2.2.2 Yılan Optimizasyonu Tekniği

Optimizasyon, bir yapının performansını en üst düzeye çıkarmak veya istenmeyen bir çıktısını en aza indirmek amacıyla, kontrol edilebilir değişkenlerin sistematik olarak ayarlanması sürecidir. Bu süreç, tanımlanmış kısıtlar çerçevesinde en uygun çözümü bulmayı sağlar ve elektrik makinelerinde de genellikle performans, verim ya da maliyet iyileştirmesi amacıyla kullanılır [7]. Tasarım optimizasyonu özelinde, makine geometrisi, malzeme özellikleri, manyetik alan dağılımları gibi kritik parametrelere odaklanılabilir [43]. Tasarım optimizasyonu, analitik yöntemler, sezgisel algoritmalar ve hibrit teknikler gibi çeşitli yaklaşımlar aracılığıyla gerçekleştirilebilir.

Yılan Optimizasyonu (SO), metasezgisel bir optimizasyon algoritmasıdır. Yılanların, sıcaklık ve yiyecek miktarı gibi çevresel faktörlere bağlı olarak değişen eşleşme eğilimlerinden esinlenerek geliştirilmiştir. Yılan Optimizasyonu, Çakal Optimizasyon Algoritması, Güve-alev Optimizasyonu, Harris Şahinleri Optimizasyonu, Termal Değişim optimizasyonu, Çekirge Optimizasyon Algoritması ve Balina Optimizasyon Algoritması gibi diğer 9 iyi bilinen ve yeni geliştirilmiş algoritmaya karşı etkinliği kanıtlanmış güncel bir algoritmadır [44]. SO, hem küresel hem de yerel arama yeteneklerine sahiptir. Algoritmanın bu dengeyi kurabilmesi, erken yakınsama veya yerel minimumda takılı kalma ihtimalini azaltır. Bazı karmaşık algoritmalarda, parametrelerin hassas ayarlanmasını gerekirken, Yılan Optimizasyonunda ise temel parametre sayısı nispeten azdır ve ayarlaması daha kolaydır. SO'da popülasyonun çeşitliliği yüksek tutulur; bu da çözüm uzayında farklı bölgelere daha etkin yayılım demektir. Belirtilen bu durumlar, SO'yu elektrik makinesi tasarım optimizasyonu gibi değişken sayısının fazla olduğu problemlerde, optimal parametrelere erken erişmek için uygun bir yapı kılmaktadır. Bu yüzden optimizasyon aşaması Yılan Optimizasyonu temel alınarak geliştirilmiştir.

Yılan Optimizasyonunda, yılanların ekolojik davranış şablonları matematiksel modele aktarılmıştır. Sıcaklığın yüksek olduğu durumlarda yılanlar, öncelikli olarak yiyecek aramaya odaklanmaktadır. Buna karşılık, sıcaklığın düşük ve yiyeceğin mevcut olduğu koşullarda ise eşleşme süreci gerçekleşmektedir. Bu davranışsal eğilimler dikkate alınarak algoritmanın arama mekanizması, keşif (exploration) ve kullanma (exploitation) olarak iki aşamaya ayrılır [44].



Şekil 2.9 Yılan optimizasyonu algoritması akış diyagramı

Eşleşme aşaması, ortaya çıkan rekabet ve mücadele durumlarını temsil edecek şekilde savaş modu ve eşleşme modu olmak üzere iki alt başlıkta incelenmektedir. Eşleşme işlemi arama uzayı içerisinde gerçekleştiğinde ise, algoritma yeni çözüm adaylarının üretilmesini sağlamaktadır. Algoritmaya ilişkin genel bir özet Şekil 2.9'da sunulmuştur.

2.2.3 Performans Değerlendirme Ölçütleri

Makine öğrenimi algoritmaları temel olarak sınıflandırma ve regresyon olarak iki ana kategoriye ayrılmaktadır. Sınıflandırma problemleri, gözlemlerin önceden tanımlanmış kategorilere veya sınıflara atanmasıyla ilgilenirken; regresyon problemleri ise, sürekli hedef değişkenlerin, bağımsız değişkenler göz önünde bulundurularak tahmin edilmesini amaçlamaktadır. Problemin yapısına uygun değerlendirme metriklerinin seçilebilmesi için, öncelikle ele alınan sorunun türünün doğru bir şekilde belirlenmesi gerekmektedir. Bu çalışmada, hedef değişkenlerin ayrık veya kategorik sınıf etiketleri yerine sürekli ve nicel değerlere sahip olması, söz konusu problemin sınıflandırma değil regresyon kapsamında ele alınmasını gerektirmektedir. Literatürde regresyon tabanlı makine öğrenimi modellerinin etkinliğini değerlendirmek için genellikle determinasyon katsayısı (R^2), ortalama mutlak hata (MAE), ortalama karesel hata (MSE), ortalama mutlak yüzde hata (MAPE), simetrik ortalama mutlak yüzde hata (SMAPE) ve kök ortalama kare hata (RMSE) gibi geleneksel metrikler kullanılmaktadır [45, 46]. R^2 , 2.29 ile ifade edilir.

$$R^2 = 1 - \frac{\sum_{i=1}^N (P_i - A_i)^2}{\sum_{i=1}^N (A_i - A_{\text{ort}})^2}, \quad (2.29)$$

burada P_i tahmin edilen değeri, A_i gerçek değeri, A_{ort} gerçek değerlerin ortalamasını ve N toplam gözlem sayısını (eğitim + test) ifade eder. MAE, 2.30 eşitliği ile hesaplanır.

$$MAE = \frac{\sum_{i=1}^N |E_i|}{N}, \quad (2.30)$$

burada $E_i = P_i - A_i$ hata terimini temsil eder. MSE, 2.31 eşitliği ile tanımlanır.

$$MSE = \frac{1}{N} \sum_{i=1}^N (A_i - P_i)^2 \quad (2.31)$$

RMSE, 2.32 eşitliği ile tanımlanır.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N E_i^2}{N}}. \quad (2.32)$$

MAPE, 2.33 ile formüle edilir.

$$MAPE = \frac{100}{N} \sum_{i=1}^N \left| \frac{E_i}{A_i} \right|. \quad (2.33)$$

SMAPE, 2.34 ile ifade edilir.

$$SMAPE = \frac{100}{N} \sum_{i=1}^N \frac{|P_i - A_i|}{\frac{|P_i| + |A_i|}{2}}. \quad (2.34)$$

Ayrıca, doğrusal olmayan ilişkilere sahip matris veri setlerinde, satır ve sütun ortalamaları kullanılarak iki boyutlu sıralama korelasyon katsayısı (R), 2.35 ile hesaplanır [47].

$$R = \frac{\sum_m \sum_n (A_{mn} - \bar{A})(B_{mn} - \bar{B})}{\sqrt{\left(\sum_m \sum_n (A_{mn} - \bar{A})^2\right) \left(\sum_m \sum_n (B_{mn} - \bar{B})^2\right)}} \quad (2.35)$$

Burada A_m ve A_n , A matrisinin m'inci ve n'inci satırlarının ortalamalarını; B_m ve B_n ise B matrisinin m'inci ve n'inci satırlarının ortalamalarını ifade etmektedir.

Bu metrikler topluca, tahmini değerlerle gerçek değerlerin bir N sayıdaki gözlem üzerinde karşılaştırılmasıyla tahmin modellerinin performansını değerlendirmek için kullanılır. R^2 , model tarafından açıklanan gerçek değerlerdeki varyans oranını niceler, 1'e yakın değerler daha yüksek hassasiyeti gösterir. MAE, yönünden bağımsız olarak hata büyüklüklerinin ortalamasını hesaplar. RMSE, sapmaların karesinin ortalamasının karekökünü alarak daha büyük hatalara daha fazla önem verir. MAPE, ortalama mutlak hatayı gerçek değerlere göre yüzde olarak ifade eder ve tahminin doğruluğu hakkında görelî bir ölçü sunar. SMAPE, MAPE'yi hem tahmin edilen hem de gerçek değerlerin ortalamasını paydada kullanarak dengeli, ölçekten bağımsız ve %0 ile %100 arasında değişen bir hata metriği üretir.

Metriklere ek olarak, performansı görselleştirmek için regresyon grafikleri ve hata histogramı gibi araçlar da kullanılabilir. Regresyon, sürecin analizini kolaylaştıran doğrusal bir ilişki sağlamak için veriye en yakın çizgiyi (artan toplam kareler bazında) bulmaya yarayan istatistiksel bir yöntemdir. Hata histogramı ise ağırlık hedef değerleriyle çıktıları arasındaki hataları görselleştirir; hata değerleri sıfır etrafında ne kadar yoğunlaşırsa, modelin performansının o kadar iyi olduğu kabul edilir. Kutu grafikleri de orta ölçekli veri setlerinin

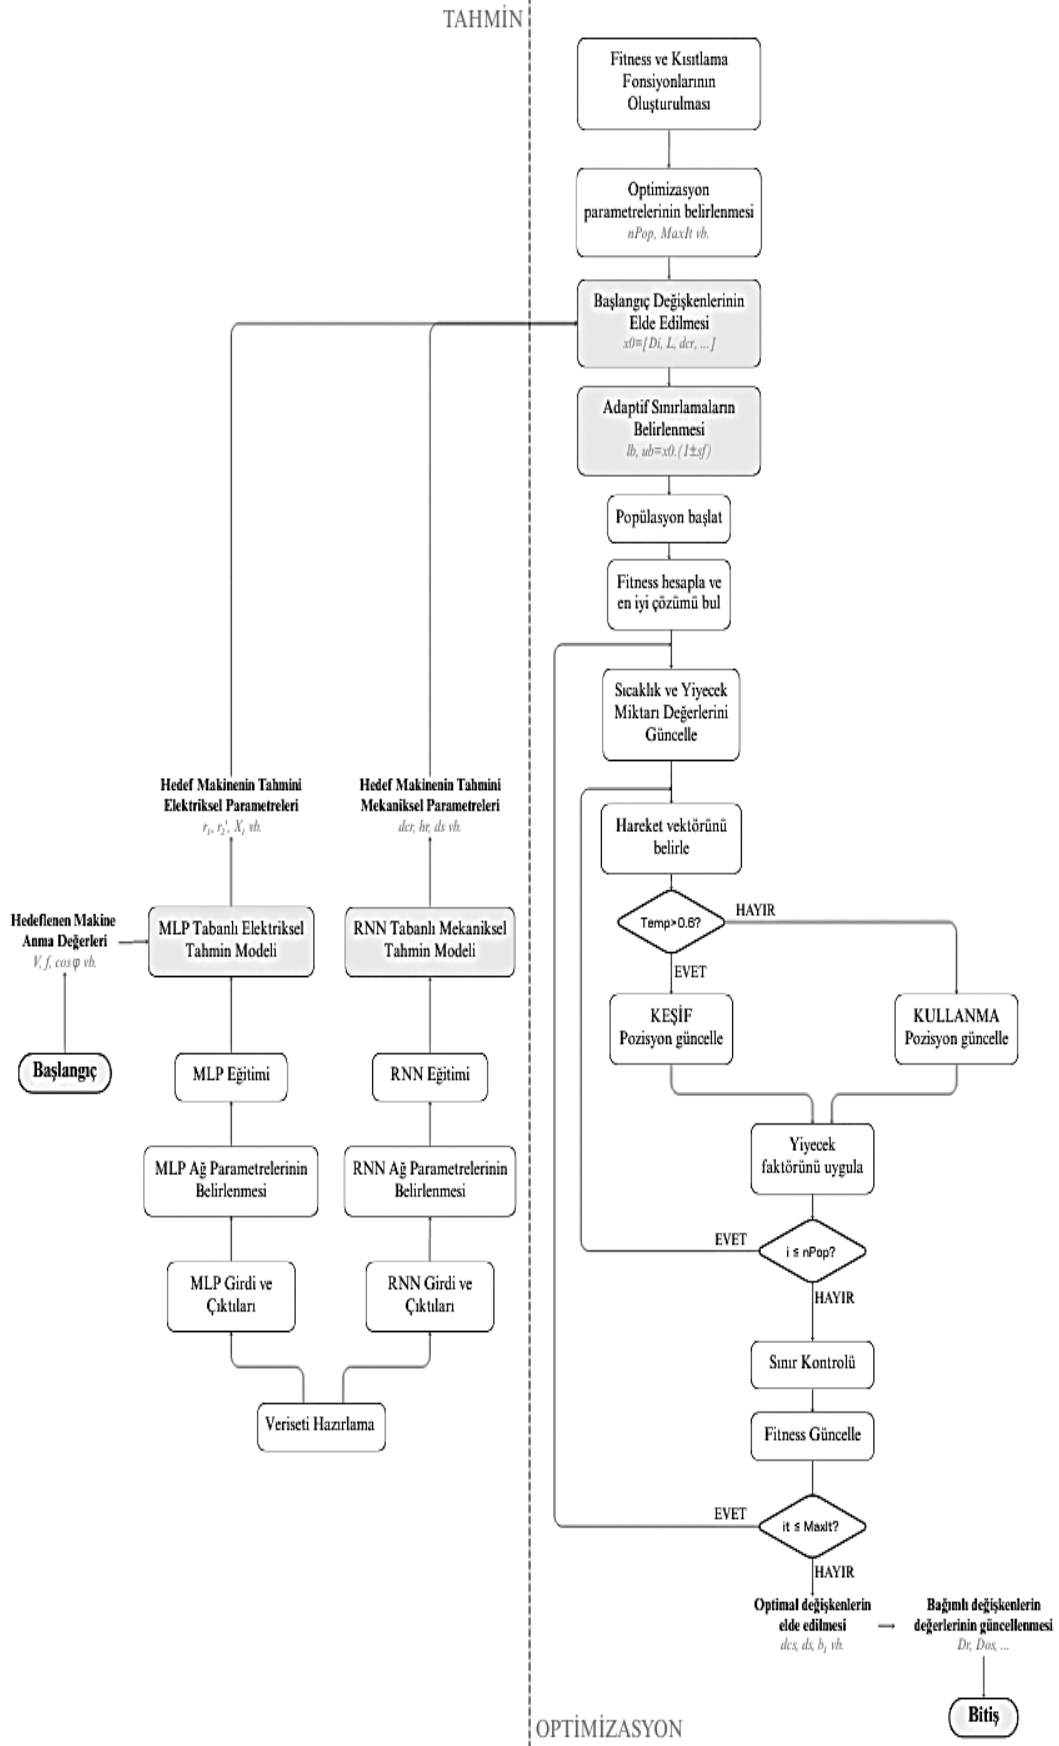
görsel olarak ifade edilmesinde kullanılan etkili yöntemlerden biridir [48]. Bu grafikler, veri seti içindeki eğitim ve test örneklerinin dağılımlarını özetlemek ve karşılaştırmak için kullanılabilir.



3

ASENKRON MAKİNE TASARIM OPTİMİZASYONU İÇİN GELİŞTİRİLEN HİBRİT YÖNTEM

Klasik elektrik makinesi tasarım problemlerinde, tasarımcının her bir özgün elektrik makinesi için elektriksel yüklenme, manyetik yüklenme ve akı yoğunlukları gibi kritik parametreleri dikkate alarak çok sayıda analitik hesaplama gerçekleştirmesi gerekmektedir. Bilgisayar destekli tasarım sistemlerinde de bu parametrelere ulaşılması, karmaşık iteratif süreçler aracılığıyla sağlanmaktadır. Bu tez çalışmasında ise, geliştirilen algoritma üzerinden, tasarımcının girdi olarak sunduğu anma değerlerine karşılık olarak, optimal makine tasarım parametrelerinin belirlenmesi hedeflenmektedir. Tasarımcının hesaplama yapmaksızın bu değerlere ulaşabilmesi, hedeflenen çalışma aralığındaki makinelerin parametrelerini öğrenen sistemlerin tahminleri sayesinde mümkün olmaktadır. Bu yaklaşım, tasarım süreçlerinde tasarımcı için faydalı bir referans oluşturabilir. Bu verileri elde etmenin zahmetli deneysel süreçler ve ölçümler gerektirmesi ya da üreticiye özgü veriler olduğu için zaman zaman bu değerlere ulaşmanın zor olması göz önüne alındığında; makineye ilişkin kontrol sistemlerinin oluşturulması, hata teşhis süreçlerinin gerçekleştirilmesi ya da çeşitli özel hedeflere ilişkin geliştirme süreçlerinin yürütülmesinde, bu veriler, faydalı bir kaynak sağlayabilir. Ancak bu parametrelerin, analiz problemleri ve yardımcı süreçler dışında kullanılması durumunda, titizlikle gözden geçirilmesi gerekmektedir. Yüksek doğrulukta bir tahmin çalışması gerçekleştirilse dahi, minimal düzeydeki hatalar makinenin gerçek dünyada uygulanabilirliğini engelleyebilir. Örneğin, oluk ve diş genişliklerinin toplamının %1 hata ile oluk adını aşması, olukların mühendislik açısından tasarıma entegre edilebilmesini olanaksız kılmaktadır. Benzer şekilde, yüksek doğrulukla gerçekleştirilen bir tahmin çalışmasında rotor çapı ile hava aralığının toplamının stator iç çapından % 0.5 büyük olması, tasarım açısından tutarsız bir durum oluşturmaktadır.



Şekil 3.1 Yapay sinir ağı ve yılan optimizasyonu tabanlı hibrit optimizasyon tekniği

Algorithm 1 Hibrit Asenkron Motor Tasarım Optimizasyonu

Girdi: V, P_n, n, \dots

Veri Hazırlama ve Model Eğitimi

$\mathcal{D} \leftarrow$ dataset.mat yükle ve karıştır

$(x_{\text{mlp}}, y_{\text{mlp}}, x_{\text{rnn}}, y_{\text{rnn}}) \leftarrow$ veriyi ayır

$(\mathcal{I}_{\text{train}}, \mathcal{I}_{\text{test}}) \leftarrow$ %75 train, %25 test böl

$f_{\text{MLP}} \leftarrow$ trainMLP($x_{\text{mlp}}, y_{\text{mlp}}$) {Elektriksel parametreler}

$f_{\text{RNN}} \leftarrow$ trainRNN(normalize($x_{\text{rnn}}, y_{\text{rnn}}$)) {Geometrik parametreler}

Parametre Tahmini

$x^* \leftarrow [P_n, V, f, n, \dots]$ {Kullanıcı girişi}

$\mathbf{e}_v \leftarrow f_{\text{MLP}}(x^*)$ $\{\mathbf{e}_v = [r_1, r'_2, x_1, X'_2, X_m]\}$

$\mathbf{g}_v \leftarrow$ denormalize($f_{\text{RNN}}(\text{normalize}(x^*))$)

$\{\mathbf{g}_v = [D_i, L, d_{cr}, h_{r0}, h_{r1}, h_r, d_{cs}, d_{s0}, d_{s1}, d_s, g, b_1, b_2, d_1, d_2]\}$

Optimizasyon Başlangıç Parametreleri

$\mathbf{x}_0 \leftarrow \mathbf{g}_v$

$[\mathbf{lb}, \mathbf{ub}] \leftarrow$ createAdaptiveBounds($\mathbf{x}_0, 30\%$)

Yılan Optimizasyonu

$\mathbf{P} \leftarrow$ initialize($N_{\text{pop}} = 50, \text{dim} = 15, [\mathbf{lb}, \mathbf{ub}]$)

$\mathbf{x}_{\text{best}} \leftarrow$ arg min motor_fitness(\mathbf{P})

for $t = 1$ **to** MaxIt **do**

$T^{(t)} \leftarrow \exp(-t/\text{MaxIt})$ {Sıcaklık kontrolü}

for $i = 1$ **to** N_{pop} **do**

if $T^{(t)} > 0.6$ **then**

{Keşif fazı}

$\mathbf{x}_i^{(t+1)} \leftarrow$ exploration_move($\mathbf{x}_i^{(t)}, \mathbf{x}_{\text{best}}$)

else

{Kullanma fazı}

$\mathbf{x}_i^{(t+1)} \leftarrow$ exploitation_move($\mathbf{x}_i^{(t)}, \mathbf{x}_{\text{best}}$)

end if

$\mathbf{x}_i^{(t+1)} \leftarrow$ clip($\mathbf{x}_i^{(t+1)}, \mathbf{lb}, \mathbf{ub}$)

$f_i^{(t+1)} \leftarrow$ motor_fitness($\mathbf{x}_i^{(t+1)}$) $\{f = (\eta_{\text{hedef}} - \eta)^2 + \text{penalty}\}$

if $f_i^{(t+1)} < f_{\text{best}}^{(t)}$ **then**

$\mathbf{x}_{\text{best}} \leftarrow \mathbf{x}_i^{(t+1)}$

end if

end for

end for

$\mathbf{x}_{\text{bv}} \leftarrow$ calcDependentVars($\mathbf{x}_{\text{best}}^{(\text{final})}$) $\{\mathbf{x}_{\text{bv}} = [D_r, D, D_{os}, t_s, t_{s1}, w_{tr}, \dots]\}$

Çıktı: $\mathbf{x}_{\text{best}}^{(\text{final})}, \mathbf{x}_{\text{bv}}$

Bu kapsamda, tasarımcının ve sistemlerin hesaplama yükünü ortadan kaldırırken, uygulanabilirlik için çeşitli kıstasların sağlanması, bu tür problemler için yararlı olmaktadır. Bu doğrultuda, bu tezde tahmin ve optimizasyonu bir araya getiren hibrit bir yaklaşımın sunulması hedeflenmiştir.

Çalışmada iki aşamalı bir metodoloji benimsenmiştir. İlk aşamada, asenkron makinenin elektriksel ve mekaniksel parametreleri tahmin edilmektedir. İkinci aşamada ise, tahmin edilen bu parametrelerin bir kısmı başlangıç vektörü olarak kullanılmakta, optimizasyon probleminin sınırlamaları adaptif biçimde başlangıç vektörüne göre formüle edilmekte ve ardından optimizasyon süreci gerçekleştirilmektedir. Optimizasyon, tasarımın belirlenen verim hedefine daha da yaklaşmasını sağlamakta ve parametrelerin gerçekleştirilebilirlik kıstaslarına uyumlu hale gelmesini sağlamaktadır.

Mevcut makine tipinin ve seçilen güç aralığının karakteristiğine en uygun elektriksel ve mekaniksel tahmin yapılarının oluşturulabilmesi için, farklı yapay sinir ağı mimarileri optimize edilerek karşılaştırılmış ve en etkin yapılar seçilmiştir. Elektriksel parametreleri tahmini için MLP, RBF, GRNN ve RNN yapıları denenmiş ve en optimal sonuçlar MLP yapısı ile elde edilmiştir. Mekaniksel parametrelerin tahmini için ise MLP, RNN ve LSTM yapıları üzerine çalışılmış ve en başarılı tahminler RNN ile elde edilmiştir. Optimizasyon aşamasında ise Yılan Optimizasyonunun yeterliliği, farklı güçlerdeki örnek motorların optimizasyon süreçleri yürütülerek test edilmiş; algoritma, uygun fitness ve kısıtlama fonksiyonları ile makine tasarım sürecine uygun hale getirilmiştir. Gerçekleştirilen geliştirme süreçleri ve testleri Bölüm 4'te ayrıntılı olarak açıklanmıştır.

Şekil 3.1'de araştırma metodolojisine ilişkin akış diyagramı sunulmaktadır. Kullanıcı veri girişi öncesinde veri hazırlama ve model eğitimi aşamaları gerçekleştirilmektedir. Bu çalışmada, üretici katalog verilerinden elde edilen anma değerlerinin kullanılmasıyla oluşturulan giriş matrisi ile analitik hesaplamalar sonucunda elde edilen çıkış matrisinin birleştirilmesi yoluyla özgün bir veri seti geliştirilmiş ve çalışmada kullanılmıştır. Araştırma kapsamında kullanılan veri seti, süreç içerisinde yapılan eklemelerle nihai olarak 1164 satır ve 44 sütundan oluşmaktadır. Sütun sayısı, araştırma sürecinde gerçekleştirilen özellik eklemeleri neticesinde kademeli olarak artırılmıştır. Metodoloji adımları aşağıdaki gibi özetlenebilir:

- **Hazırlık Aşaması - Veri Seti Hazırlama ve Tahmin Modellerinin Oluşturulması:** Veri setindeki örneklerin sıralaması, sadece

belirli bir güç aralığındaki örneklerin öğrenilmesinin önüne geçmek ve çeşitliliği artırmak amacıyla rastgele karıştırılmıştır. Çok Katmanlı Algılayıcı (MLP) ve Tekrarlayan Sinir Ağı (RNN) yapılarının giriş ve çıkış kümeleri oluşturulmuştur. MLP ve RNN ağları için oluşturulan alt veri setleri ise, eğitim (%75) ve test (%25) olmak üzere ikiye ayrılmıştır. Ağların hiperparametreleri, belirli performans hedefleri doğrultusunda izgara arama ve manuel ayarlama yöntemleri ile optimize edilmiştir. Son olarak, ağlar eğitilmiş ve kullanıcı girdilerine ilişkin tahmin yapabilen modeller geliştirilmiştir. Model parametreleri Bölüm 4'te verilmiştir.

- **Tahmin Aşaması:** Çıkış gücü, gerilim, frekans, hız, güç faktörü gibi hedeflenen makine anma değerleri belirlenir. Bu değerler, tahmin ve optimizasyon süreçlerinin temel girdileri olarak sunulur. Bu değerlere göre, MLP tabanlı elektriksel tahmin modeli ve RNN tabanlı mekaniksel tahmin modeli kullanılarak, makinenin tahmini elektriksel parametreleri ve tahmini mekaniksel parametreleri elde edilir. Elektriksel ve mekaniksel parametrelerin başarılı şekilde tahmin edilmesinin ardından, bu parametreler optimizasyon sürecine girdi olarak aktarılır. Tahmin edilen parametreler, çeşitli koşul ve kısıtlar altında en uygun sonuçların bulunması için baz teşkil eder.
- **Optimizasyon Aşaması:** Optimizasyon aşamasında, öncelikle hedef anma verim değerine ulaşmayı sağlayacak fitness fonksiyonu ve kısıtlama fonksiyonları oluşturulur. Bu fonksiyonlar, çözümün kalitesini ve uygulanabilirliğini belirlemede kritik rol oynar. Ardından, popülasyon büyüklüğü ve maksimum iterasyon sayısı gibi optimizasyonun parametreleri (n_{Pop} , $MaxIt$, dim) belirlenir. Tahmin aşamasından gelen verilere göre başlangıç vektörü oluşturulur. Başlangıç parametrelerinden belirli bir oranda uzaklaşılmasına izin verecek şekilde (örnek olarak $\pm 30\%$) adaptif sınırlamalar (lb ve ub) tanımlanarak, popülasyon başlatılır ($pop = lb + rand \times (ub - lb)$).

Oluşturulan popülasyon üzerinden fitness değeri hesaplanır ve en iyi çözüm ($BestSol$) belirlenir. Ardından, sıcaklık ($Temp = \exp(-it/MaxIt)$) ve yiyecek miktarı ($Q = \exp(-it/MaxIt) \times ones(1, dim)$) değerleri güncellenerek, hareket vektörü (ilk yılan için $Xm = (BestSol + pop(end, :))/2$, diğer yılanlar için $Xm = (pop(i - 1, :)) + pop(i, :)/2$) tanımlanır.

Hareket yönü, sıcaklık parametrelerinde belirlenen bir eşik değeri (ör. $Temp > 0.6$) esas alınarak 'KEŞİF' veya 'KULLANMA' pozisyon

güncelleme stratejisi ile belirlenir. Her iki durumda da, pozisyon güncellenir ve yiyecek faktörü uygulanır.

Her döngü sonunda, popülasyonun sınır kontrolü ($lb \leq pop \leq ub$) yapılır ve fitness yeniden değerlendirilir. Eğer maksimum popülasyon değeri ve maksimum iterasyon sayısı tamamlanmamışsa, süreç tekrar edilir. Son olarak, optimal değişkenler elde edilir; bağımlı değişkenlerin değerleri, optimal değişkenlere göre güncellenir ve süreç tamamlanır. Optimizasyon sürecinin parametrelerine Bölüm 4'te değilmıştır. Hibrit optimizasyon tekniğinin aşamaları, Algoritma 1'de detaylandırılmıştır.



4 GELİŞTİRİLEN HİBRİT YÖNTEMİN FARKLI GÜÇ SEVİYELERİNDEKİ ASENKRON MAKİNELERE UYGULANMASI

4.1 Tahmin Aşaması

4.1.1 Elektriksel Parametrelerin Tahmini

Makine tasarımının optimal şekilde gerçekleştirilebilmesi için, başlangıç adımını oluşturan tahminin hassas bir şekilde yapılması gerekmektedir. Elektrik makinelerinin parametrelerinin kestirimi üzerine son yıllarda çeşitli çalışmalar yayımlanmıştır. Parametre kestirimi için, Parçacık Sürü Optimizasyonu (PSO) tekniği ile bu tekniğin, H-G diyagramına dayalı direnç kestirim yöntemi, benzetilmiş tavlama tekniği ve Jaya Optimizasyon algoritmaları gibi farklı tekniklerle birleştirilmiş hibrit versiyonları kullanılmıştır [49–53]. Söz konusu çalışmalarda, global arama performansı, hesaplama süresi ve uygunluk fonksiyonunun boyutu gibi konularda iyileştirmeler sağlanmış ve tolere edilebilir aralıklarda sonuçlar elde edilmiştir. Öte yandan, parametre kestirimi için Diferansiyel Evrim (DE) algoritmasına dayalı bir fonksiyon yaklaşımdayıcı da uygulanmıştır [54]. Bir başka çalışmada, harici ölçümlere dayanan Yapay Arı Kolonisi Optimizasyonu (ABC) kullanılarak bir parametre kestirim yöntemi geliştirilmiş ve bu yöntem %2 ile %15 arasında değişen hata oranlarıyla sonuçlanmıştır [55]. Genetik Algoritma (GA) tabanlı bir çalışmada, stator akımı hatasına dayalı bir maliyet fonksiyonu minimize edilerek parametreler belirlenmiş, benzer bir yöntemin kullanıldığı bir başka çalışmada ise yaklaşık %4'lük bir hata payı ile kestirim elde edilmiştir [56, 57]. Diğer bir çalışmada, belirli güç aralıklarına sahip tek kafesli ve çift kafesli IM'lerin parametreleri, Benzetilmiş Tavlama—Buharlaştırma Oranı Su Döngüsü (SA-ERWCA) yöntemiyle tahmin edilmiştir [58]. Literatürdeki farklı bir yaklaşımda ise üretici veri sayfası yöntemi ve hizmet içi yöntem olarak adlandırılan iki farklı kestirim tekniği önerilmiştir [59]. Parametre belirleme konusunda geliştirilen bir diğer

yöntemde, başlangıç ve boşa çalışma modlarında ölçülen hız değerleri ile akım ve gerilim osilogramları kullanılarak, eşdeğer devre parametrelerinin $\pm\%10$ toleransla elde edilebildiği deneysel bir yaklaşım sunulmuştur [60]. Bahsedilen çalışmalar incelendiğinde, veri toplama, test ve doğrulama süreçlerinin bir kısmının veya tamamının yalnızca bir veya birkaç makineden elde edilen verilere dayandığı görülmektedir. Bu nedenle, kapsanan güç aralığının ve buna ilişkin çıkarılabilecek çıkarımların, çalışmalarda kullanılan makinelerin anma değerleriyle sınırlı olabileceği söylenebilir.

Daha geniş güç aralığına odaklanan çalışmalara geçildiğinde, doğrusal olmayan cebirsel denklemler içeren iteratif bir algoritma ile yinelemesiz hesaplamaların birleştirilmesiyle elde edilen hibrit bir yöntemin 200 MW üzerindeki güç seviyelerinde test edildiği görülmektedir [61]. Farklı devirlerde 789 motordan elde edilen verilerin kullanıldığı bir diğer analitik yöntemde ise, elde edilen değerlerin üretici tarafından sağlanan değerlere oldukça benzer olduğu görülmüştür [62]. Analitik yöntemlerde güç aralığının ve veri sayısının genişlediği, ancak bu genişlemenin işlem sayısında artışlara yol açtığı değerlendirilebilir.

Yapay Sinir Ağı (ANN) tabanlı bir tahmin çalışması yürütülmüş ve Grafik Sinir Ağı (GSA) yönteminin gerçek motor parametrelerine yakın bulgular verdiği belirtilmiştir [63]. 20 farklı makineden elde edilen veriler kullanılarak, Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemleri (ANFIS) ve İleri Beslemeli Sinir Ağı (FFNN) yapıları değerlendirilmiş ve ANFIS'in daha etkili bir yöntem olduğu sonucuna varılmıştır [64]. Aynı verilerle yapılan başka bir ANN çalışmasında, FFNN ve Bellek İçermeyen Elman Sinir Ağı (ENN) yaklaşımlarının IM parametrelerinin tahmininde kabul edilebilir sonuçlar sağladığı belirtilmiştir [65]. Derin öğrenme temelli çalışmalarda ele alınan makine sayısında artış gözlenirse de, geniş bir güç aralığındaki öğrenme sürecinde tüm noktaların yeterince temsil edilemeyebileceği ve bazı eksik noktaların kalabileceği değerlendirilmektedir. Bu nedenle, sağlıklı uygulamalar için daha kapsamlı ve çeşitli verilere ihtiyaç duyulabileceği düşünülmektedir.

Ayrıca, Karar Ağaçları, k-En Yakın Komşular ve Komşuluk Bileşeni Özellik Seçimi kullanan makine öğrenmesi tabanlı bir tahmin yöntemi ve giriş empedansı ile kayma arasındaki ilişkiyi ifade eden bir polinoma dayalı bir regresyon yöntemi önerilmiştir [66, 67]. Bunların yanı sıra, literatürde parametre tahmini için farklı yöntemler üzerinde de ayrıntılı incelemeler yapılmıştır [68–70].

Literatürde sunulan yöntemlerde bazı zorluklar veya iyileştirilebilecek noktalar tespit edilmiştir. Öncelikle, deneysel metodolojiler ve testler, iş gücü, zaman kısıtlamaları ve kurulu ve faal durumdaki sahalarda operasyonel zorluklar gibi sınırlamalar getirmektedir [62]. Analitik yöntemler ise, her bir makine için belirli karmaşık hesaplamalar ve yinelemeler gerektirmektedir. Bu problemlerin bir kısmı bilgisayar destekli yöntemlerle çözülebilsede, algoritma ve programlama yapılarındaki kısıtlamalar nedeniyle bazen bu da zor olabilmektedir. Öte yandan, Makine Öğrenimi (ML), büyük miktarda veri ile eğitilerek, klasik programlama yöntemleri yerine verilerdeki kalıpları tanımlayan ve doğrudan bu verilerden tahminler oluşturabilen bir model ortaya koymaktadır [71]. Ancak, az sayıda veri noktasıyla yapılan çalışmalar, modellerin doğru bir sonuca ulaşmasını engelleyebilmektedir. Bu noktadan hareketle, bu aşamada geniş bir veri seti kullanarak elektriksel parametrelerin yüksek doğrulukta ve hızlı bir şekilde kestirilmesine odaklanılmıştır. Literatürdeki mevcut sınırlamaları aşmak amacıyla, geniş güç aralığını kapsayan (4-900 kW) ve farklı kutup sayılarına (2-8) sahip 1164 adet 3-fazlı alçak gerilimli sincap kafesli asenkron motorun katalog verileri toplanarak, ANN tabanlı bir elektriksel parametre tahmin aşaması geliştirilmiştir. Çok Katmanlı Algılayıcı (MLP), Radyal Tabanlı Fonksiyon Sinir Ağı (RBF) ve Genel Regresyon Sinir Ağı (GRNN) yapıları, ağ parametreleri ızgara arama ile optimize edilerek parametre tahminine uygun hale getirilmiştir. Elde edilen bulgular, bu yapıların eşdeğer devre parametre tahmininde farklı performans seviyelerine sahip olduğunu göstermiş, yöntemlerin karşılaştırılması sonucunda ise en etkili yaklaşım belirlenmiştir. Bu doğrultuda, bu aşamada aşağıdaki amaçlara ulaşılması hedeflenmiştir:

- Karşılaştırılan ANN tabanlı yöntemleri optimize ederek, en uygun yöntemi belirlemek,
- Geleneksel yaklaşımlardan kaynaklanan iş gücü, işlem zorluğu ve karmaşıklık gibi faktörleri ortadan kaldırarak, parametre tahminini optimal sürede gerçekleştirmek,
- Tahminlerde 0.9 üzerinde korelasyon ve 0.1'in altında ortalama mutlak hata oranlarına ulaşarak, yüksek doğruluk elde etmek
- Sonuçların genellenebilirliğini artırmak amacıyla literatürdeki çalışmalara oranla geniş bir veri seti ile çalışmak (1164 motor),
- Farklı kutup sayılarına ve güç değerlerine sahip motorlar için güvenilir parametre tahmini yapabilmek,

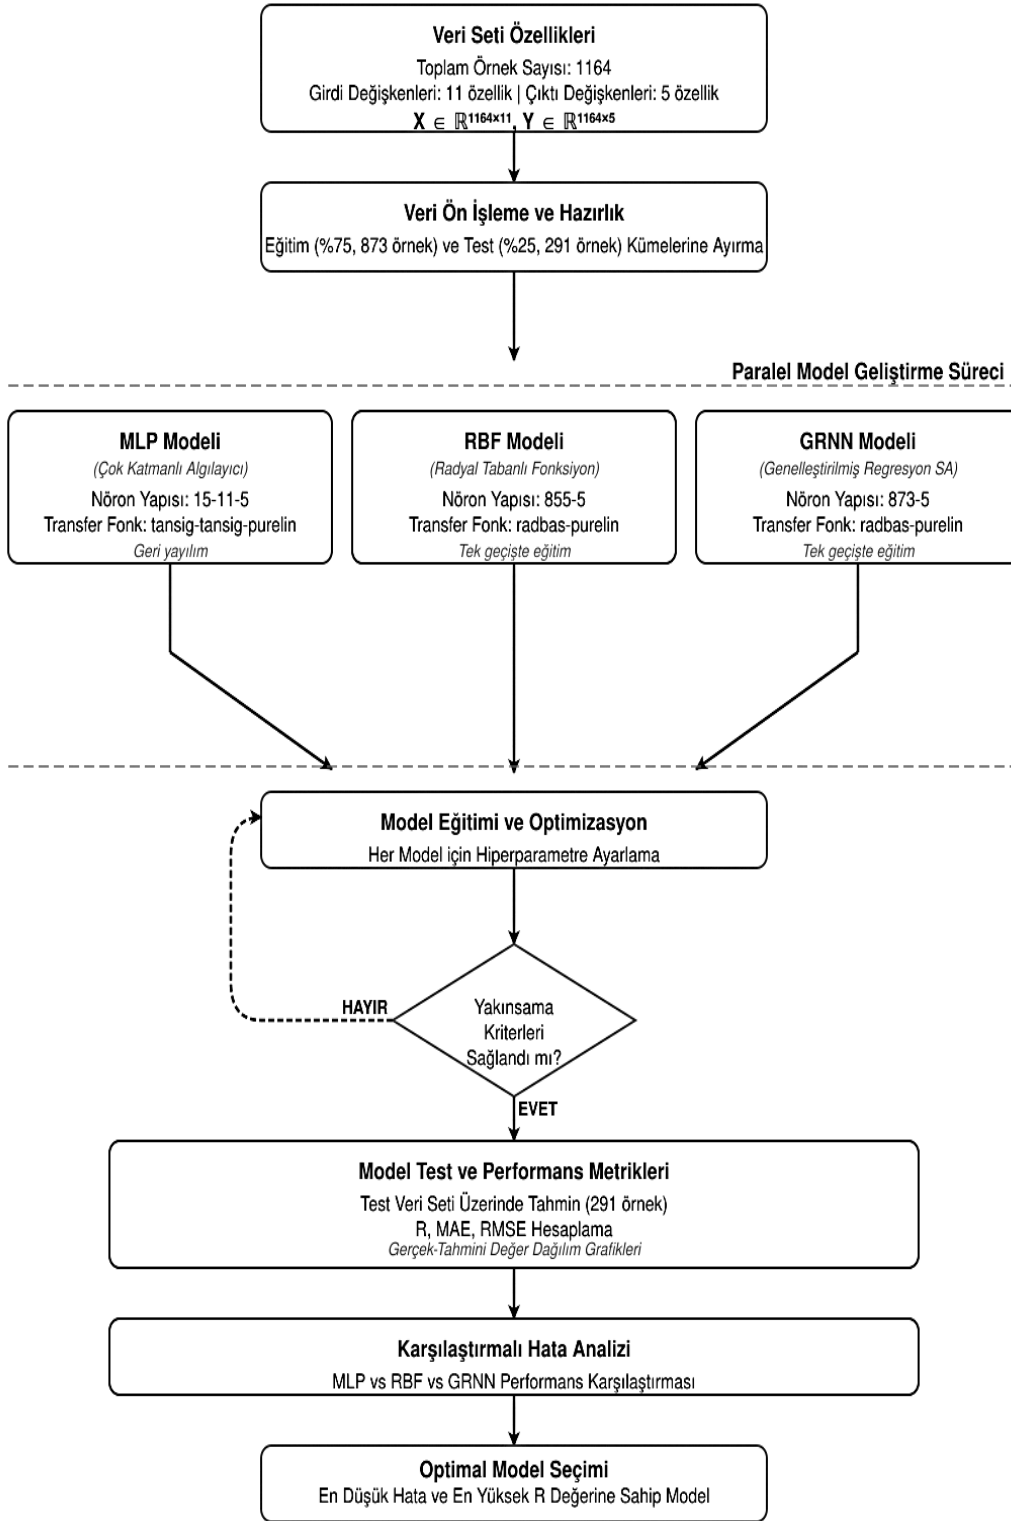
- Asenkron makine parametre tahminlerinde yaygın olarak tercih edilmeyen, GRNN gibi yöntemlerin uygulanabilirliğini ve etkililiğini değerlendirmek.

Sonuç olarak, bu aşamada literatürdeki yöntemlerde sıkça karşılaşılan deneysel zorlukların ve veri yetersizliğinin aşılması, elektriksel parametre tahmininin hızlı, hassas ve yenellenebilir bir yaklaşımla yapılabilmesi amaçlanmıştır.

4.1.1.1 Elektriksel Tahmin Adımları

Elektriksel tahmin aşamasının oluşturulabilmesi için aşağıdaki adımlar izlenmiş ve bu adımların özetlendiği genel bir blok diyagramı Şekil 4.1’de sunulmuştur.

- Üretici kataloglarında standart olarak yer alan gerilim, güç, frekans, hız, güç faktörü ve verim gibi elektriksel parametreler esas alınarak her motor için toplam 11 farklı elektriksel veri elde edilmiştir.
- Elde edilen elektriksel verilerden, 1164 satır ve 11 sütundan oluşan bir giriş veri matrisi oluşturulmuştur.
- Asenkron makine ürün kataloglarının genelinde eşdeğer devre parametreleri sunulmadığından, öğrenme için gerekli olan çıkış verileri tek seferlik bir analitik hesaplama ile elde edilmiş ve bu değerlerle 1164 satır ve 5 sütundan oluşan bir çıktı matrisi oluşturulmuştur.
- Giriş ve çıktı matrislerinin birleştirilmesiyle, 1164 satır ve 16 sütundan oluşan ve toplamda 18.624 veriden meydana gelen bir veri seti oluşturulmuştur.
- Giriş ve çıkış sayıları dikkate alınarak, farklı katman ve nöron sayılarına sahip yapay sinir ağı modelleri oluşturulmuştur.
- Elde edilen veri seti, ağların eğitimi ve testi amacıyla, eğitim ve test alt kümelerine ayrılmıştır.
- Eğitim seti kullanılarak ağ eğitimi simülasyonu gerçekleştirilmiş, hata oranı belirlenen eğitim hedefinin altına inene yada maksimum epoch sayısına ulaşılan kadar ağ parametreleri optimize edilmiştir.
- Eğitilen ağların performansları, test setleri kullanılarak değerlendirilmiş ve tahmin sonuçları elde edilmiştir.



Şekil 4.1 Elektriksel tahmin aşamasının oluşturulması

- Karşılaştırma matrisleri ve hata metrikleri incelenerek modellerin hata analizi yapılmıştır.
- Üç farklı ağ modeli kullanılarak elde edilen sonuçlar karşılaştırılmış ve en efektif ağ belirlenmiştir.

4.1.1.2 Elektriksel Çıktıların Oluşturulması

Asenkron motor parametrelerinin yapay sinir ağları aracılığıyla tahmin edilebilmesi için, giriş ve hedef değerlerini içeren kapsamlı bir veri setinin oluşturulması gerekmektedir. Mevcut literatürde bu amaçla kullanılacak hazır bir veri tabanının bulunmaması nedeniyle, çalışma kapsamında özgün bir veri seti geliştirilmiştir.

Veri seti giriş parametreleri, farklı üreticilerin teknik kataloglarından derlenmiştir. Hedef değerler ise, tek sefere özgü, analitik hesaplama yöntemleri kullanılarak türetilmiştir. Giriş parametreleri, üretici kataloglarında standart olarak sunulan gerilim, güç ve frekans gibi değerlerden oluşmaktadır. Hedef parametreler ise asenkron motorun eşdeğer devresine ait r_1 ve r_2' gibi direnç parametrelerini kapsamaktadır.

r_1 değeri analitik olarak, 4.1'den elde edilebilmektedir. [62].

$$\begin{bmatrix} P_{ç50} - (1 - s_{50})P_{g50} \\ P_{ç75} - (1 - s_{75})P_{g75} \\ P_{ç100} - (1 - s_{100})P_{g100} \end{bmatrix} = \begin{bmatrix} -(1 - s_{50}) 3I_{150}^2 & -1 \\ -(1 - s_{75}) 3I_{175}^2 & -1 \\ -(1 - s_{100}) 3I_{1100}^2 & -1 \end{bmatrix} \begin{bmatrix} r_1 \\ P_{rot} \end{bmatrix} \quad (4.1)$$

Burada $P_{ç}$ çıkış gücünü, P_g giriş gücünü ve I_1 ise stator akımını ifade etmektedir. Mekanik, manyetik ve ek kayıpların toplamının sabit olduğu varsayılmış; bu kayıplar P_{rot} ile, yani rotasyonel kayıplar olarak gösterilmiştir. r_2' değeri ise 4.2 ile belirlenebilir [62].

$$\frac{s(P_{ç} + P_{rot})}{(1 - s)} = \begin{bmatrix} 3I_1^2 & 1 \end{bmatrix} \begin{bmatrix} r_2' \\ k \end{bmatrix} \quad (4.2)$$

Burada, $k = -3r_2'I_0^2$ 'dir. X_1 , X_2' ve X_m değerleri ise 4.3 ve 4.4 kullanılarak hesaplanmaktadır [62].

$$I_0 X_m = I_2' \sqrt{\left(\frac{r_2'}{s}\right)^2 + X_2'^2} \quad (4.3)$$

$$3X_m I_0^2 = Q - 3 \left(I_1^2 + \frac{I_1^2}{a} - \frac{I_0^2}{a} \right) X_1 \quad (4.4)$$

Burada I_0 mıknatıslanma kolu akımı, Q reaktif güç ve a motora özgü bir sabittir.

4.1.1.3 Elektriksel Tahmin Simülasyonları

Yedi farklı üreticiye ait kataloglardan elde edilen 11 farklı özellik giriş olarak kullanılmıştır. Ağın çıktıları ise, bu verilerden analitik bir yöntemle elde edilen eşdeğer devre parametreleri olarak belirlenmiştir. Ağın parametreleri, farklı parametre kombinasyonları üzerinde ızgara arama yöntemi uygulanarak belirlenmiş ve ağ eğitilmiştir. Ardından test işlemi gerçekleştirilmiş ve yöntemlerin başarımı hata metrikleri kullanılarak değerlendirilmiştir.

• Yazılım ve Donanım Bilgileri

Simülasyonlar, 2.3 GHz Intel Core i7 işlemcili, Nvidia GeForce grafik kartına sahip ve 64-bit işletim sistemi yüklü bir bilgisayarda gerçekleştirilmiştir.

• Veri Seti

Bu çalışmada, Tablo 4.1'de gösterildiği üzere Teco, Weg, Leroy-Somer, CG-Crompton, Havells, Bharat Bijlee ve Kirloskar tarafından üretilen 3 fazlı sincap kafesli asenkron motor tipine sahip düşük gerilimli motorlara ait toplam 1164 örneklik veri seti kullanılmıştır [72–78]. Kullanılan motorların güç aralığı 4 kW–900 kW, frekansları 50/60 Hz ve kutup sayısı 2 ile 8 arasında değişmektedir. Giriş değişkenleri, kataloglardan elde edilen anma gücü (P_n), anma gerilimi (V), frekans (f), kutup sayısı ($2p$), devir sayısı (n), farklı yüklerde güç faktörleri ($\cos \varphi$ %100, $\cos \varphi$ %75, $\cos \varphi$ %50) ve farklı yüklerde verim (η %100, η %75, η %50) değerleridir. Ağın çıkış değişkenleri ise, stator direnci (r_1), rotor direnci (r_2'), stator reaktansı (x_1), rotor reaktansı (X_2') ve mıknatıslama reaktansı (X_m) değerleridir.

Tablo 4.1 Elektriksel tahmin aşaması veri setinin temel özellikleri

Etiket Değerleri	
Toplam örnek sayısı	1164
Markalar	Teco, Weg, Leroy-Somer, CG-Crompton, Havells, Bharat Bijlee, Kirloskar
Motor tipi	3 fazlı sincap kafesli asenkron motor
Güç aralığı	4 – 900 kW
Frekans	50/60 Hz
Gerilim seviyesi	Yaklaşık 400 V
Kutup sayısı	2 – 8
Giriş Değerleri	$P_n, V, f, 2p, n, \cos \varphi$ %100, $\cos \varphi$ %75, $\cos \varphi$ %50, η %100, η %75, η %50
Hesaplama ile Elde Edilen Parametreler	
Çıkış Değerleri	$r_1, r_2', x_1, X_2', X_m$

• Yapay Sinir Ağı Mimarisi

Her bir yapay sinir ağı için ağ parametreleri, ilgili ağın özellikleri dikkate alınarak ızgara arama yöntemiyle belirlenmiştir. Çok katmanlı algılayıcı (MLP) için, katman sayısı, her bir katmandaki nöron sayısı ve aktivasyon fonksiyonları (hiperbolik tanjant sigmoid transfer fonksiyonu, log-sigmoid transfer fonksiyonu ve lineer transfer fonksiyonu) gibi çeşitli parametrelerin kombinasyonları değerlendirilmiş ve en düşük hata oranına sahip yapı belirlenmiştir. Tablo 4.2, özellikle ızgara arama yöntemiyle belirlenen, yapay sinir ağlarının önemli parametrelerine genel bir bakış sunmaktadır. GRNN ve RBF ağlarında genellikle gizli katmanda radyal tabanlı transfer fonksiyonu (radbas), çıktı katmanında ise lineer transfer fonksiyonu (purelin) kullanılmakta olup, bu ağların yapısal özelliklerinden dolayı katman sayısı sabittir. Bu nedenle, GRNN ve RBF ağlarında ayarlamalar, yayılım parametresi, epoch sayısı ve nöron sayısı üzerinden gerçekleştirilmiştir.

Tablo 4.2 Elektriksel tahmin aşaması sinir ağı yapılarının temel parametreleri

Parametre	MLP	RBF	GRNN
Girdi sayısı	11	11	11
Çıktı sayısı	5	5	5
Katman (gizli+çıktı)	2+1	1+1	1+1
Nöron sayısı	15-11-5	855-5	873-5
Aktivasyon	tansig-tansig-purelin	radbas-purelin	radbas-purelin
Epoch sayısı	1000	855	873
Yayılım	-	19	3.5

Eğitim aşamasında, veri setinin %75'i kullanılmıştır. Bu süreçte, MLP ağının eğitimi, erken durdurma (early stopping) kriterinin devreye girmesiyle 1000.

epochta sonlanmıştır. RBF ve GRNN ağlarında ise, eğitim belirlenen hata hedefinin altına ulaşıldığı için sırasıyla 855. ve 873. epochlarda tamamlamıştır. Veri setinin geriye kalan %25'i ile test aşamasına geçilmiş ve ağların bu aşamadaki performansları değerlendirilmiştir.

• Elektriksel Tahmin Simülasyon Sonuçları

Simülasyon sonuçları, zaman kullanımı da dahil olmak üzere çeşitli kriterler çerçevesinde değerlendirilmiştir. Tablo 4.3'te, toplam simülasyon süreleri ile birlikte simülasyon sürecinde en fazla süre harcayan kod bölümlerine ilişkin ayrıntılı bilgiler sunulmaktadır. Buna göre, simülasyonun en çok zaman gerektiren aşamaları, ağ yapılarının oluşturulması, yapıların görselleştirilmesi, eğitim işlemleri ve performans metriklerinin elde edilmesi süreçleridir. 1164 satırdan oluşan geniş veri seti dikkate alındığında, incelenen üç ağ yapısının da 49 saniyeden kısa simülasyon süreleriyle oldukça hızlı sonuç ürettiği görülmektedir. Ancak, benzer şekilde geri yayılım yöntemi gerektirmeyen ve tek geçişli eğitimle çalışan RBF ve GRNN ağları arasında bile 46 saniye gibi kayda değer bir süre farkı bulunduğu görülmüştür. Bu sonuçlar ışığında, zaman kullanımı açısından en iyi performansı, toplam simülasyon süresi 2,596 saniye olan GRNN ağı göstermiştir. Öte yandan, kısa işlem süresi tek başına bir ağ yapısının ideal olduğunu göstermek için yeterli değildir; bu ağların belirlenen süreler sonunda ürettiği çıktılarının doğruluğu da ayrıca değerlendirilmelidir.

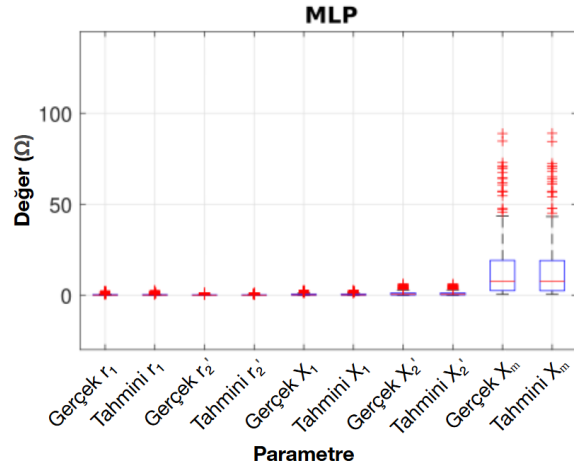
Tablo 4.3 Elektriksel tahmin aşaması sinir ağı yapıları simülasyon süreleri

Ağ Tipi	İlgili Kod Bölümünün İşlevi	Toplam Süre (s)	Süre (%)
MLP	Ağın eğitilmesi	28.473	91.2
	Regresyon grafiklerinin çizilmesi	1.304	4.2
	Ağ yapısının gösterilmesi	0.883	2.8
	Ağ yapısının oluşturulması	0.338	1.1
	Performans parametreleri tablosunun oluşturulması	0.065	0.2
	Diğer tüm işlemler	0.141	0.5
	<i>Toplam</i>	31.203	100
RBF	Ağ yapısının oluşturulması	46.334	95.3
	Ağ yapısının gösterilmesi	1.290	2.7
	Regresyon grafiklerinin çizilmesi	0.681	1.4
	Eğitim çıktılarının elde edilmesi	0.176	0.4
	Performans parametreleri tablosunun oluşturulması	0.063	0.1
	Diğer tüm işlemler	0.073	0.2
	<i>Toplam</i>	48.618	100
GRNN	Regresyon grafiklerinin çizilmesi	1.271	49.0
	Ağ yapısının gösterilmesi	0.861	33.2
	Eğitim çıktılarının elde edilmesi	0.185	7.1
	Ağ yapısının oluşturulması	0.135	5.2
	Performans parametreleri tablosunun oluşturulması	0.066	2.6
	Diğer tüm işlemler	0.077	3.0
	<i>Toplam</i>	2.596	100

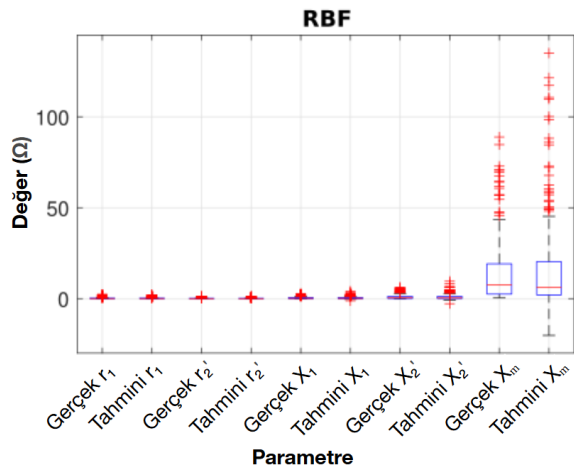
Şekil 4.2’de, üç farklı yapay sinir ağının simülasyonları sonucunda elde edilen tahmin değerler ve gerçek değerlere ilişkin, kutu grafikleri sunulmuştur. Bu kutu grafiklerinde, medyan, minimum ve maksimum değer gibi etmenlerden yararlanılarak, veri setinin istatistiksel dağılımı gösterilmektedir. Sütunlar sırasıyla r_1 , r'_2 , x_1 , X'_2 ve X_m parametrelerine karşılık gelmektedir. Grafikler incelendiğinde, deneyler sonucunda elde edilen değer aralıklarının büyük ölçüde gerçek değerler ile örtüştüğü görülmektedir. Özellikle MLP için bu durum oldukça belirgindir. RBF ve GRNN ağlarında ise, X_m parametresi için tahmin edilen değerlerin bir kısmının gerçek değerlerle örtüşmediği dikkat çekmektedir. Ayrıca, RBF ve GRNN sonuçlarında bazı tahminlerin gerçek değerlerin üzerinde gerçekleştiği gözlenmiştir. Bu bulgular, genel anlamda MLP ağının diğer yapılara göre daha başarılı olduğu izlenimini uyandırmakla birlikte, kesin bir değerlendirme için daha ayrıntılı karşılaştırmalara ihtiyaç duyulmaktadır. Bu nedenle, bu aşamada regresyon grafiklerinden de yararlanılmıştır.

Şekil 4.3, MLP ile elde edilen tahmin sonuçları ile gerçek değerler arasındaki ilişkiyi grafiksel olarak sunmaktadır. Şekil 4.4 ve Şekil 4.5 ise, sırasıyla RBF ve GRNN’nin çeşitli devre parametrelerindeki performanslarını göstermektedir. Tüm grafiklerde, yatay eksen gerçek (hedef) değerleri, dikey eksen ise tahmini (çıktı) değerleri temsil etmektedir ve noktalar ise örneklere ilişkin gerçek ve tahmini değer ikililerinin koordinatlarını göstermektedir. Grafiklerde yer alan uyum doğrusu (fit line), elde edilen veriler için en uygun doğrusal fonksiyonu gösterirken, $Y = T$ doğrusu tahmini ve gerçek değerlerin tamamen örtüştüğü ideal durumu temsil etmektedir. Uyum doğrusunun 45 derecelik açığa yaklaşması ve bu iki doğrunun kesişmesi, yüksek doğruluk düzeyine işaret etmektedir. GRNN için, uyum doğrusunun 45 derecelik açığa tam olarak ulaşamadığı gözlemlenmektedir. RBF modelinde ise x_1 ve X'_2 parametrelerinde tahmin noktalarının dışı doğru belirgin şekilde dağılması, bazı tahminlerin gerçek değerlerden ciddi ölçüde saptığını ve bunun da görece düşük doğruluk sağladığını göstermektedir. Öte yandan, MLP’de uyum doğrusunun 45 derecelik açığa sahip olması ve tahmin değerlerinin bu eksen etrafında yoğunlaşması, modelin yüksek doğrulukta çalıştığını ortaya koymaktadır. Bu bulgular doğrultusunda, regresyon grafikleri, MLP’nin en yüksek performansı sergilediğini açıkça göstermektedir.

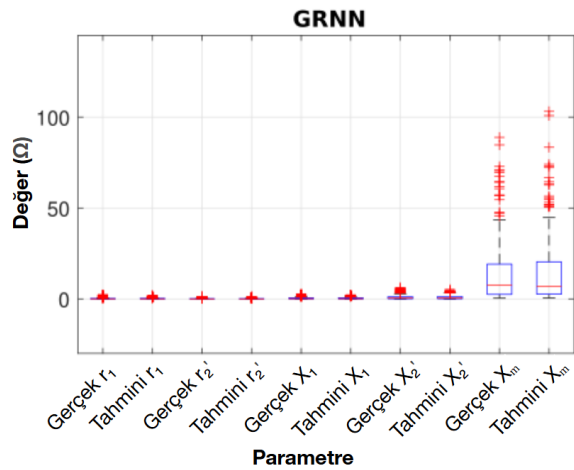
Hata metrikleri, sistemin performansını niceliksel olarak değerlendirmede önemli bir gösterge olarak kullanılmaktadır. Bu metrikler, elde edilen sonuçların doğruluğunu ve modelin başarımını açıkça ortaya koymaktadır. Bu doğrultuda iki boyutlu korelasyon katsayısı, MAE ve RMSE değerleri, gerçek değerler ile ağdan elde edilen çıkış değerleri karşılaştırılarak hesaplanmıştır.



(a) MLP verileri



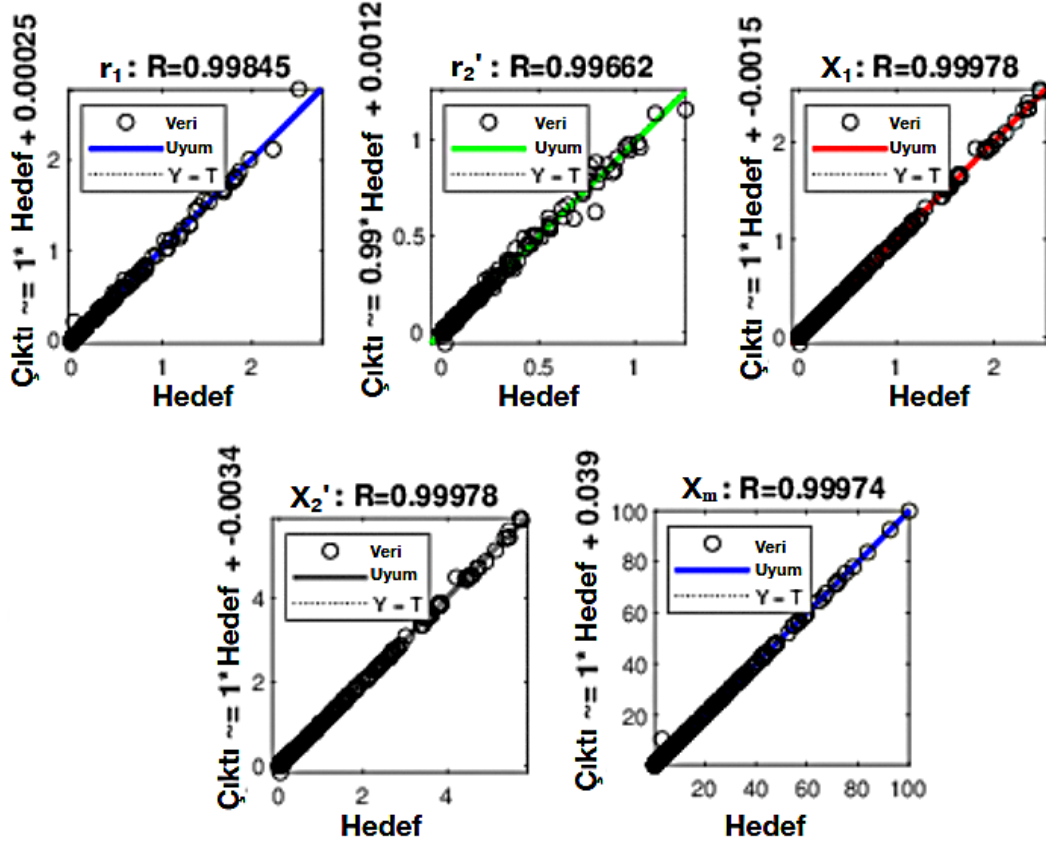
(b) RBF verileri



(c) GRNN verileri

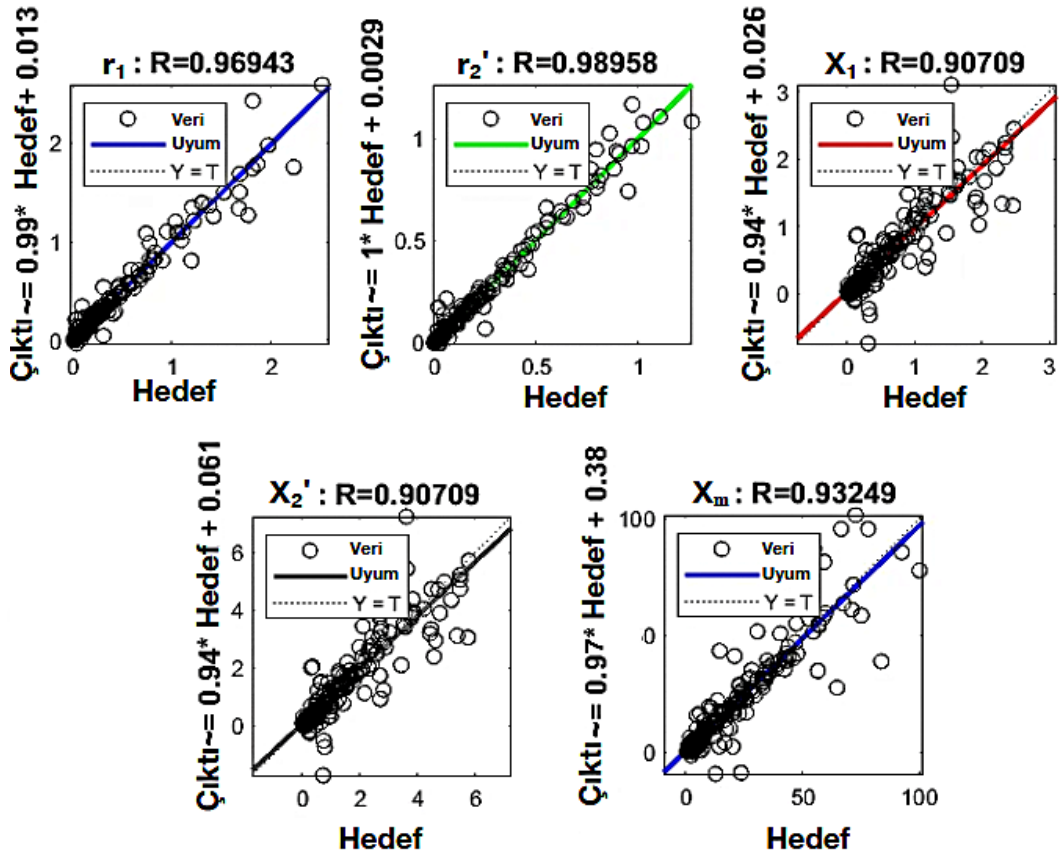
Şekil 4.2 Farklı sinir ağı yapılarının elektriksel parametre tahminlerinin gerçek değerlerle dağılımsal karşılaştırılması

Eğitim ve test aşamalarında yürütülen simülasyon çalışmalarına ilişkin metrikler, Tablo 4.4'te sunulmaktadır.



Şekil 4.3 Çok katmanlı algılayıcı modelinin elektriksel tahmin aşaması test performansı

İki boyutlu korelasyon katsayısının 1'e yakın olması, elde edilen sonuçların yüksek doğrulukta olduğunu göstermektedir. Tablo 4.4'te verilen korelasyon verilerine göre, üç tahmin yöntemi de 0.9'un üzerinde korelasyon değerleri elde etmiş ve istatistiksel olarak anlamlı sonuçlar üretmiştir. Tahmin edilen parametrelerin büyük çoğunluğunda MAE ve RMSE değerlerinin sıfıra yaklaşması, sağlıklı sinir ağı yapılarının oluşturulabildiğini göstermektedir. Test aşamasında, RBF ve GRNN yöntemleri, r_1 , r_2' , x_1 ve X_2' parametrelerinde RMSE değerlerini 0.5'in altına indirmeyi başarmış, MLP ise X_m dahil olmak üzere tüm beş parametrede bu değerlerin altında sonuçlar elde etmiştir. Eğitim aşamasında ise RBF yöntemi, tüm parametrelerde korelasyon katsayısını 1'e ulaştırarak ve MAE ile RMSE değerlerini sıfırlayarak en yüksek performansı göstermiştir. Bunu sırasıyla MLP ve GRNN takip etmiştir. Ancak tahmin yöntemlerinin gerçek etkinliği, daha önce öğrenmedikleri test verileriyle değerlendirilmelidir. Test aşamasında MLP, r_1 , r_2' , x_1 , X_2' ve X_m parametreleri için sırasıyla 0.9985, 0.9966, 0.9998, 0.9998 ve 0.9997 korelasyon değerleri ile 0.0107, 0.0099, 0.0056, 0.0129 ve 0.0660 MAE değerleri elde etmiştir. Hatayı en iyi yansıtan metrik olan RMSE ise aynı parametreler için sırasıyla 0.0253, 0.0203, 0.0125, 0.0289 ve 0.4364 olarak gerçekleşmiştir. RBF ve




Şekil 4.4 Radyal tabanlı fonksiyon sinir ağı modelinin elektriksel tahmin aşaması test performansı

GRNN ise, eğitim aşamasındaki yüksek korelasyon seviyelerini test aşamasında koruyamamış; özellikle X_m parametresinin tahmininde görece yüksek hata oranları sergilemiştir. Sonuç olarak, oldukça yüksek doğruluk değerlerine ulaşmalarına karşın her iki yöntem de tahmin başarısı bakımından MLP'nin gerisinde kalmıştır.

GRNN, zaman tüketimi açısından öne çıkan bir yöntem olmakla birlikte, yapılan tüm değerlendirme çalışmalarında MLP'nin doğruluk bakımından en iyi sonuçları verdiği görülmüştür. Tahmin edilen parametrelerin, makinelerin kullanılacağı sistemlerin tasarımı, arıza analizi ve optimizasyon süreçlerini doğrudan etkileyeceği göz önünde bulundurulduğunda; üç ağ yapısı arasında zaman açısından anlamlı bir dezavantaj bulunmaması nedeniyle, süreçlerin verimliliği açısından doğruluğa dayalı bir karşılaştırmanın daha uygun olacağı sonucuna varılabilir. Bu bağlamda, MLP yönteminin en etkili yaklaşım olduğu belirlenmiştir.

Karşılaştırılan üç sinir ağı, ileri beslemeli (feed-forward) yapıya sahiptir. Geri beslemenin bu problem açısından bir iyileştirme oluşturup oluşturmayacağını



Şekil 4.5 Genel regresyon sinir ağı modelinin elektriksel tahmin aşaması test performansı

Tablo 4.4 İleri beslemeli sinir ağı tabanlı elektriksel tahmin yapılarının farklı hata metriklerine göre performans sonuçları

		MLP			RBF			GRNN		
		R	MAE	RMSE	R	MAE	RMSE	R	MAE	RMSE
Eğitim	r_1	0.9995	0.0073	0.0117	1.0000	0.0000	0.0001	0.9869	0.0225	0.0614
	r_2'	0.9986	0.0068	0.0117	1.0000	0.0000	0.0000	0.9937	0.0086	0.0250
	X_1	1.0000	0.0033	0.0050	1.0000	0.0000	0.0001	0.9832	0.0362	0.0927
	X_2'	1.0000	0.0076	0.0117	1.0000	0.0001	0.0003	0.9832	0.0842	0.2157
	X_m	1.0000	0.0124	0.0165	1.0000	0.0012	0.0058	0.9865	1.2963	2.7621
Test	r_1	0.9985	0.0107	0.0253	0.9694	0.0380	0.1115	0.9361	0.0663	0.1590
	r_2'	0.9966	0.0099	0.0203	0.9896	0.0147	0.0359	0.9692	0.0257	0.0639
	X_1	0.9998	0.0056	0.0125	0.9071	0.1163	0.2549	0.9440	0.0837	0.1939
	X_2'	0.9998	0.0129	0.0289	0.9071	0.2705	0.5927	0.9440	0.1947	0.4509
	X_m	0.9997	0.0660	0.4364	0.9325	3.2311	7.1954	0.9372	3.2452	6.8613

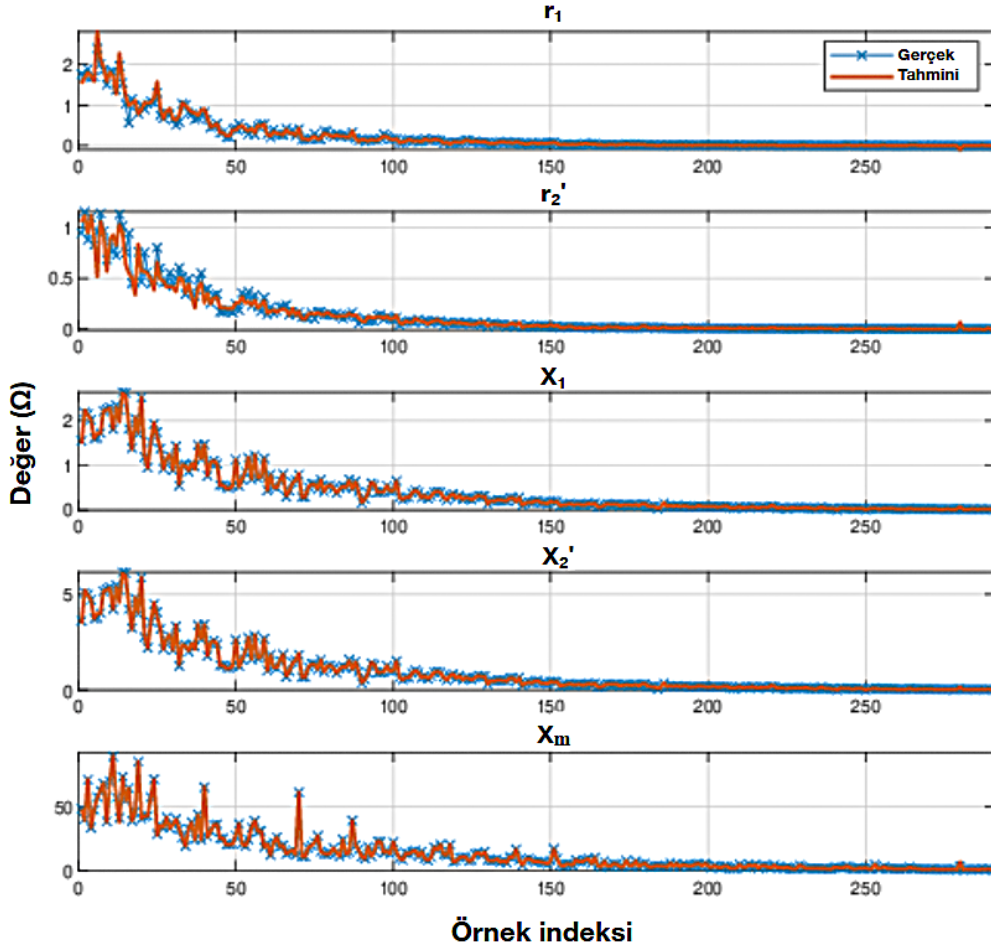
görmek adına, aynı veri seti üzerinde RNN ağı eğitilmiştir. RNN ağının elde ettiği metrikler Tablo 4.5'de verilmiştir. Sonuçlar incelendiğinde test aşamasında, RNN ağının elde ettiği korelasyon ve hata değerlerinin genel olarak MLP ağının gerisinde kaldığı görülmüştür. MLP bu durumda da bu

Tablo 4.5 Tekrarlayan sinir ağı elektriksel tahmin performans metrikleri

Parametre	Eğitim			Test		
	R	MAE	RMSE	R	MAE	RMSE
r_1	0.9945	0.021773	0.043096	0.9935	0.019795	0.041437
r_2	0.9823	0.022031	0.044908	0.9770	0.018881	0.040241
X_1	0.9998	0.006997	0.012282	0.9995	0.006307	0.014803
X_2	0.9998	0.016274	0.028554	0.9995	0.014682	0.034491
X_m	1	0.032095	0.044413	0.9999	0.079869	0.242670

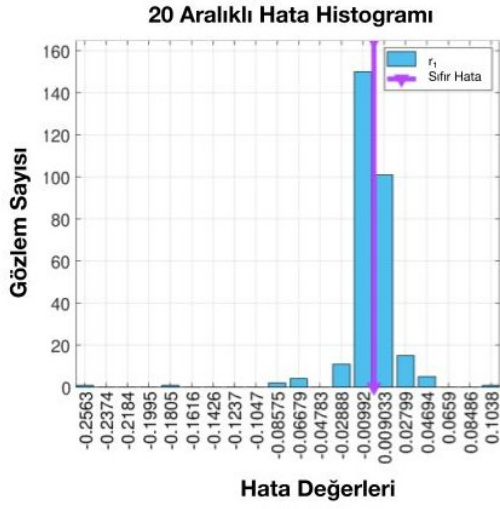
problem için en optimal yapı olmayı sürdürmüştür.

Test veri setindeki gerçek değerler ile çok katmanlı algılayıcı (MLP) tarafından elde edilen tahmini değerler Şekil 4.6'da sunulmuştur. r_1 ve r_2 parametrelerinin yüksek değerlerinde gözlemlenen küçük farklılıklar haricinde, her iki değer türü de tüm veri seti boyunca büyük ölçüde çakışmaktadır.




Şekil 4.6 Çok katmanlı algılayıcı elektriksel tahmin aşaması test çıktı noktaları

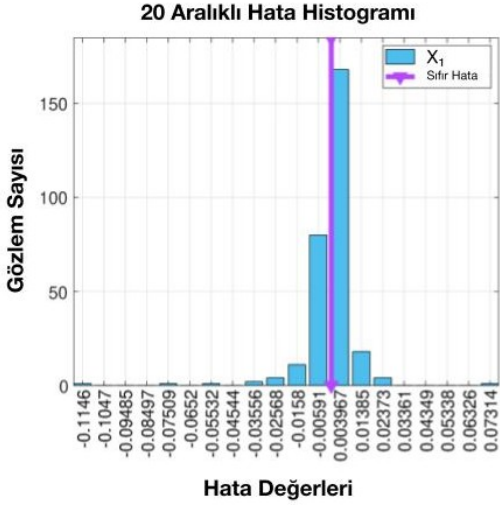
Hata histogramı, MLP ile hedeflenen hata oranının sağlanıp sağlanmadığını doğrulamak için kullanılabilir. Örneğin, Şekil 4.7'de sunulan hata histogramı



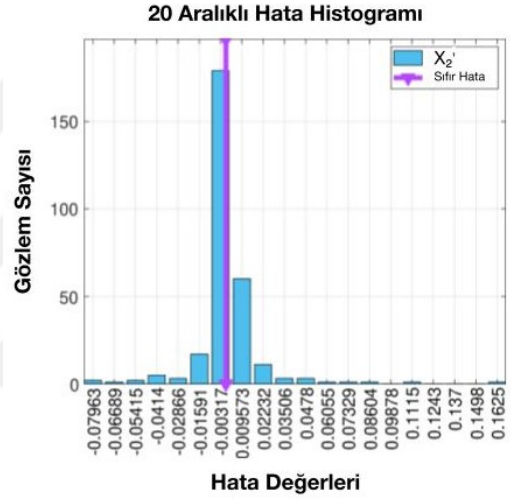
(a) r_1




(b) r_2'



(c) X_1



(d) X_2'



(e) X_m

Şekil 4.7 Çok katmanlı algılayıcı elektriksel tahmin hata histogram grafikleri

grafiklerinde, test aşamasında elde edilen r_1 parametresine ait hata değerlerinin minimum, maksimum, ortalama, medyan, mod, standart sapma ve aralık değerleri sırasıyla -0.2563, 0.1038, -0.07627, -0.07627, -0.2563, 0.1121 ve 0.3602 olarak bulunmuştur. r_2' parametresi için bu değerler -0.07963, 0.1625, 0.04143, 0.04143, -0.07963, 0.07539 ve 0.2421; X_1 parametresi için -0.1146, 0.07314, -0.02074, -0.02074, -0.1146, 0.05846 ve 0.1877; X_2' parametresi için ise -0.07963, 0.1625, 0.04143, 0.04143, -0.07963, 0.07539 ve 0.2421 olarak tespit edilmiştir. Genel olarak r_1 , r_2' , X_1 ve X_2' parametrelerinin medyan değerleri incelendiğinde, hata miktarlarının tepe noktalarının 0.077'nin altında olduğu görülmektedir. Bu durum, düşük bir hata oranına işaret etmektedir. Ayrıca, standart sapma değerlerinin 0.076'nın altında ve sıfıra yakın olması, hata büyüklüklerinin tüm örnekleme ortalama etrafında toplandığını ve böylece tüm veri setinde düşük hata oranına sahip tutarlı sonuçlar elde edilebildiğini göstermektedir.

Tablo 4.6, MLP sonuçlarına dayalı olarak 20 motordan oluşan örnek bir veri kümesi sunmaktadır. Bu tablo, belirlenen performans ve hata değerlerinin sayısal verilere nasıl yansıdığını göstermektedir. Tabloda motor katalog bilgileri, gerçek eşdeğer devre değerleri ve tahmini eşdeğer devre değerleri yer almaktadır. Veri kümesinin ilk 10 verisi eğitim aşamasından, son 10 verisi ise test aşamasından elde edilen sonuçları içermektedir.

4.1.2 Mekaniksel Parametrelerin Tahmini

Elektrik makinelerinin mekanik karakteristiklerinin de kapsamlı bir şekilde anlaşılması, optimizasyon vb. süreçler için büyük önem taşımaktadır. Bu sayede, uygun prosedürlerin uygulanmasıyla makinelerin hassas bir şekilde analiz edilmesi ve kontrolü mümkün hale gelmektedir [79]. Ancak, geleneksel makine tasarımı yaklaşımları, sadece anma değerlerinden yola çıkılarak makine parametrelerinin sıfırdan belirlenmesi sürecinde uzun ve yinelemeli hesaplamalar gerektirmektedir. Bunun yanı sıra, makinenin üretiminden sonra parametrelere erişim sağlamak ve makinenin sağlıklı çalışmasını temin etmek de çeşitli zorluklar barındırmaktadır. Üretici firmalar, çoğunlukla gizlilik gerekçesiyle ayrıntılı parametre bilgilerini teknik dökümantasyonda paylaşmamaktadır. Ayrıca, deneysel yöntemlerle parametre tespiti yapmak ise mevcut operasyonlarda aksamaya neden olabileceğinden, kullanıcılar açısından arzu edilmeyen bir durumdur. Dolayısıyla, bu tür sorunların etkin bir şekilde çözülmesi için alternatif yöntemlerin geliştirilmesi gerekmekte olup, elektrik makinelerinin parametrelerinin belirlenmesine yönelik farklı tahmin yöntemleri literatürde önerilmektedir.

Tablo 4.6 Çok katmanlı algılayıcıyla belirli örnek motorlarda elde edilen elektriksel tahmin sonuçları

No	V (V)	f (Hz)	P (kW)	P_n (kW)	Hız (rpm)	Katalog Verileri					Motor Parametreleri										
						100 %	75 %	50 %	Verim	Güç Faktörü			Gerçek Değerler		Tahmini Değerler						
											r_1	r_2	X_1	X_2	X_m	r_1	r_2	X_1	X_2	X_m	
1	400	50	6	15	980	91.5	91.9	91.3	0.77	0.70	0.58	0.2825	0.1477	0.5589	1.2997	12.8245	0.2856	0.1480	0.5631	1.3084	12.8392
2	415	50	2	19	2920	90.9	90.9	90.0	0.89	0.90	0.81	0.2052	0.1865	0.5101	1.1862	25.6711	0.2159	0.1873	0.5075	1.1800	25.7119
3	415	50	6	22	977	92.2	92.2	92.2	0.88	0.90	0.76	0.1845	0.1395	0.3626	0.8432	17.5872	0.1889	0.1340	0.3638	0.8456	17.5734
4	415	50	2	37	2950	93.7	93.7	92.8	0.88	0.90	0.80	0.0709	0.0595	0.2786	0.6478	12.9060	0.0718	0.0586	0.2729	0.6344	12.8993
5	415	50	2	45	2950	94.0	94.0	93.1	0.90	0.90	0.84	0.0536	0.0503	0.2293	0.5333	13.1553	0.0539	0.0501	0.2265	0.5267	13.1665
6	400	50	6	110	990	94.8	95.0	94.5	0.80	0.80	0.66	0.0240	0.0102	0.0964	0.2243	2.4327	0.0232	0.0117	0.0979	0.2277	2.4374
7	400	50	8	200	740	95.0	95.0	94.5	0.81	0.80	0.66	0.0101	0.0079	0.0462	0.1075	1.3186	0.0140	0.0071	0.0467	0.1088	1.3155
8	400	50	4	260	1480	96.0	95.7	95.7	0.88	0.90	0.80	0.0054	0.0065	0.0383	0.0891	1.8100	0.0055	0.0091	0.0350	0.0817	1.8165
9	400	50	4	315	1485	95.1	95.1	94.7	0.90	0.90	0.85	0.0082	0.0040	0.0340	0.0790	1.9944	0.0082	0.0034	0.0309	0.0721	1.9982
10	400	50	4	500	1490	96.5	96.7	96.4	0.87	0.90	0.77	0.0041	0.0017	0.0193	0.0448	0.8240	0.0043	0.0002	0.0181	0.0424	0.7995
11	400	50	2	4	2925	88.3	89.0	88.1	0.86	0.80	0.70	1.6846	0.7310	1.5559	3.6183	66.4190	1.6433	0.7356	1.5412	3.5817	66.0312
12	415	50	6	7.5	970	89.1	89.1	89.1	0.80	0.80	0.68	0.6575	0.4262	1.6401	3.8142	39.2092	0.6485	0.4315	1.6342	3.8020	39.2341
13	400	50	6	7.5	960	88.0	89.5	89.5	0.78	0.70	0.59	0.8046	0.5519	1.1613	2.7008	25.6544	0.8059	0.5505	1.1735	2.7293	25.6346
14	415	50	6	11	965	90.3	90.3	89.4	0.79	0.80	0.68	0.2424	0.3417	1.1644	2.7078	27.3252	0.2466	0.3450	1.1723	2.7268	27.2672
15	400	50	2	15	2945	91.9	92.6	92.6	0.89	0.90	0.81	0.3441	0.1444	0.6595	1.5338	32.3873	0.3438	0.1503	0.6655	1.5474	32.3691
16	400	50	8	75	738	93.7	93.8	93.5	0.81	0.80	0.69	0.0373	0.0232	0.1513	0.3520	4.0063	0.0361	0.0202	0.1518	0.3530	4.0048
17	400	50	4	110	1484	95.5	95.3	94.8	0.82	0.80	0.65	0.0170	0.0123	0.0650	0.1512	2.3017	0.0191	0.0130	0.0669	0.1558	2.3104
18	400	50	2	200	2973	96.3	96.5	96.3	0.90	0.90	0.84	0.0104	0.0058	0.0508	0.1180	2.9384	0.0137	0.0083	0.0490	0.1141	2.9498
19	400	50	6	250	990	95.8	95.0	94.8	0.80	0.80	0.64	0.0051	0.0048	0.0352	0.0817	0.9938	0.0053	0.0074	0.0357	0.0834	0.9983
20	400	50	6	560	992	96.6	96.7	96.2	0.82	0.80	0.67	0.0027	0.0018	0.0158	0.0366	0.4958	0.0023	0.0020	0.0160	0.0376	0.4881

Kalıcı mıknatıslı senkron motorun (PMSM) üç mekanik parametresinin — viskoz sürtünme katsayısı, sistem atalet momenti ve yük momenti — belirlenmesi için iki aşamalı çevrimiçi paralel bir kestirim tekniği önerilmiştir [80]. Aynı bir çalışmada, torkun kestirimi için, stator akısı bağlantıları ile stator akım vektörlerinin kullanıldığı bir teknik sunulmuştur [81]. Bir başka çalışmada ise, farklı durumlarda atalet momenti ve sürtünme katsayılarının kestirimi için Yinelemeli En Küçük Kareler Yöntemi ve asenkron makinenin hız döngüsü kullanılmıştır [82]. Anahtarlamalı relüktans makineleri üzerine gerçekleştirilen bir araştırmada, doğrusal olmayan ampirik bir model kullanılarak geliştirilen bir metotla, yük momenti, atalet momenti ve yükün viskoz sürtünmesi gibi mekanik parametreler, sinyal-gürültü oranında yaklaşık 30 dB'lik bir bozulma ile tespit edilmiştir [79]. Asenkron makinelerde hava aralığı uzunluğundaki değişimi değerlendirmek amacıyla yenilikçi bir Bayesyen teknik kullanılmıştır. Ancak, yükselen gürültü seviyesi, kestirim sonuçlarındaki belirsizliğin artmasına yol açmıştır [83]. PMSM uygulamalarının testinde kullanılan makine denklemleriyle motor torkunun kestirimine yönelik geliştirilmiş bir yaklaşım önerilmiştir [84].

Elektrik makineleri üzerine yapılan tahmin çalışmalarının büyük bir kısmı, öncelikli olarak elektriksel parametrelerin ayrıntılı şekilde kestirimine odaklanmıştır [85–88]. Ayrıca, bu makinelerin kontrol sistemi parametrelerinin tahminine yönelik araştırmalar da bulunmaktadır [89]. ANN ve Karar Ağaçları gibi makine öğrenmesi yöntemleri ise arıza tespiti uygulamalarında kullanılmaktadır [90]. Bununla birlikte, mekanik parametrelere yönelik araştırmalar, tork ve sürtünme gibi bir dizi faktörle sınırlı kalmıştır. Ayrıca, bu çalışmaların birçoğunda deneysel uygulama veya doğrulama amacıyla kullanılan örneklem sayısının sınırlı olması, elde edilen sonuçların genellenebilirliğini de kısıtlamaktadır.

Bu aşamanın amacı, elektrik motorlarının mekanik boyutlarını yüksek doğrulukta, hızlı ve pratik bir şekilde tahmin edebilen makine öğrenmesi tabanlı bir metodoloji geliştirmektir. Bu doğrultuda, hızlı çalışan, basit mimariye sahip, aşırı hesaplama gücüne veya zaman tüketimine ihtiyaç duymayan yapılara öncelik verilmiştir. Ayrıca, motorun farklı mekanik boyutları arasındaki dolaylı ilişkiler ve çalışmanın kapsamının doğası gereği mevcut olan doğrusal olmayan yapı da dikkate alınmıştır. Bu bağlamda, MLP, doğrusal olmayan aktivasyon fonksiyonları ve hızlı öğrenme yetenekleri sayesinde karmaşık ilişkileri modelleyebilme kapasitesi nedeniyle değerlendirilmiştir. Ayrıca, RNN ve LSTM ağları da, sıklıkla sıralı ya da zamana bağlı veri yapıları üzerinde kullanılmalarına rağmen,

çok deęişkenli ve doğrusal olmayan veri kümeleri üzerinde etkili sonuçlar üretebilmeleri ve veriler arasındaki ilişkileri daha kapsamlı bir şekilde modelleyebilme yetkinlikleri dolayısıyla deęerlendirilmiştir. Böylece, üç farklı ağ mimarisinin karşılaştırılmasıyla yalnızca mekanik parametrelerin bir alt kümesinin tahminine odaklanan geleneksel yaklaşımların ötesine geçilerek, çok sayıda niceliğin çıkarımını mümkün kılan en uygun yapının belirlenmesi amaçlanmıştır. Bu aşamanın hedefleri, şu şekilde özetlenebilir:

- . ***Kapsamlı Boyut Tahmini:*** Farklı güç aralıklarını kapsayan, mevcut yöntemlerin sınırlamalarını aşan ve asenkron motorların 17 mekanik boyutunu doğru şekilde tahmin edebilen sağlam bir çerçeve geliştirmek.
- . ***Yöntem Karşılaştırması:*** Doğruluk, hesaplama verimliliği ve kaynak gereksinimleri arasında denge sağlayan en uygun yapıyı belirlemek amacıyla MLP, RNN ve LSTM ağlarını karşılaştırmak.
- . ***Minimum Kaynak Gereksinimi:*** Sadece katalog verileri kullanarak mekanik boyutları tahmin edebilen, ek veri gereksinimini azaltan bir model tasarlamak.
- . ***Zaman ve Hesaplama Verimliliği:*** Önerilen yaklaşımın pratik uygulamalarda zaman tasarrufu sağlayacak şekilde mekanik boyutların hızlıca belirlenmesine imkân tanınmasını sağlamak.
- . ***Yüksek Doğruluk Metrikleri:*** Tüm parametrelerde korelasyon katsayısının 1'e yakın olmasını, MAE ve RMSE deęerlerinin sıfıra yakın olmasını sağlamak.
- . ***Veri Genellenebilirliği:*** Yöntemin farklı çalışma seviyelerinde uygulanabilirliğini sağlamak için geniş bir güç aralığını kapsayan bir veri kümesi kullanmak.
- . ***Gelecekteki Geliştirmelere Zemin Hazırlama:*** Mekanik ve elektriksel parametrelerin entegrasyonu, hibrit model tasarımlarının araştırılması ve yöntemin farklı makine tipleri ve uygulamalara uyarlanabilirliğinin artırılması gibi çalışmalar için temel oluşturmak.

4.1.2.1 Mekaniksel Tahmin Aşamaları

Bu aşamada gerçekleştirilen metodoloji adımları aşağıda özetlenmiştir:

- Çıkış gücü, gerilim, hız, kutup sayısı, frekans, % 100 yükte verim, % 75 yükte verim, % 50 yükte verim, % 100 yükte güç faktörü, % 75 yükte

güç faktörü ve % 50 yükte güç faktörü özellikleri ile tanımlanan 1164 örneğe ait veriler, üç fazlı sincap kafesli asenkron motor üreten yedi farklı üreticinin kataloglarından toplanmıştır.

- Referans boyutlar (örneğin stator çapı ve uzunluğu), belirli manyetik yükleme veya belirli elektriksel yükleme gibi yerleşik kriterlere dayanarak, analitik olarak tek seferlik hesaplanmıştır.
- Katalog değerleri ve hesaplama sonuçları kullanılarak 32.592 veriden oluşan bir veri seti oluşturulmuştur.
- Özellikler arasındaki ölçek farklılıklarını ve aykırı değerleri gidermek amacıyla, veri seti Z-skoru yöntemiyle normalize edilmiş; böylece veri seti tüm özelliklerin ortalaması 0 ve standart sapması 1 olacak şekilde düzenlenmiştir.
- Normalleştirilmiş veri seti, %75 eğitim ve %25 test olacak şekilde ikiye ayrılmıştır.
- Her bir ağ için, en iyi performans gösteren konfigürasyonların belirlenmesi amacıyla ızgara arama yöntemiyle hiperparametre optimizasyonu gerçekleştirilmiştir.
- Her bir model, hata metriği (MSE) önceden belirlenen bir eşik değerinin altına inene kadar veya maksimum 10.000 epoch'a ulaşılan kadar eğitim veri seti üzerinde eğitilmiştir.
- Eğitim tamamlandıktan sonra, ayrılan test seti kullanılarak ağların testi gerçekleştirilmiştir.
- Model performansını değerlendirmek amacıyla MAE ve RMSE gibi hata metrikleri hesaplanmıştır.
- Tahmini ve gerçek değerlerin uyumunu değerlendirmek için regresyon grafikleri, hata histogramları ve kutu grafikleri gibi görsel araçlar kullanılmıştır.
- Ağlar, işlem süresi, yakınsama özellikleri ve doğruluk metrikleri açısından sistematik olarak karşılaştırılmıştır.
- Ayrıntılı incelemelerin ardından, hata metriklerinin en düşük ve doğruluk düzeyinin en yüksek olduğu ağ, hedef görev için en uygun model olarak belirlenmiştir.

- Önerilen yaklaşımın pratik uygulanabilirliğini doğrulamak amacıyla, veri setinden seçilen belirli bir motor hem gerçek hem de tahmin edilen parametre değerleri kullanılarak analiz edilmiştir.

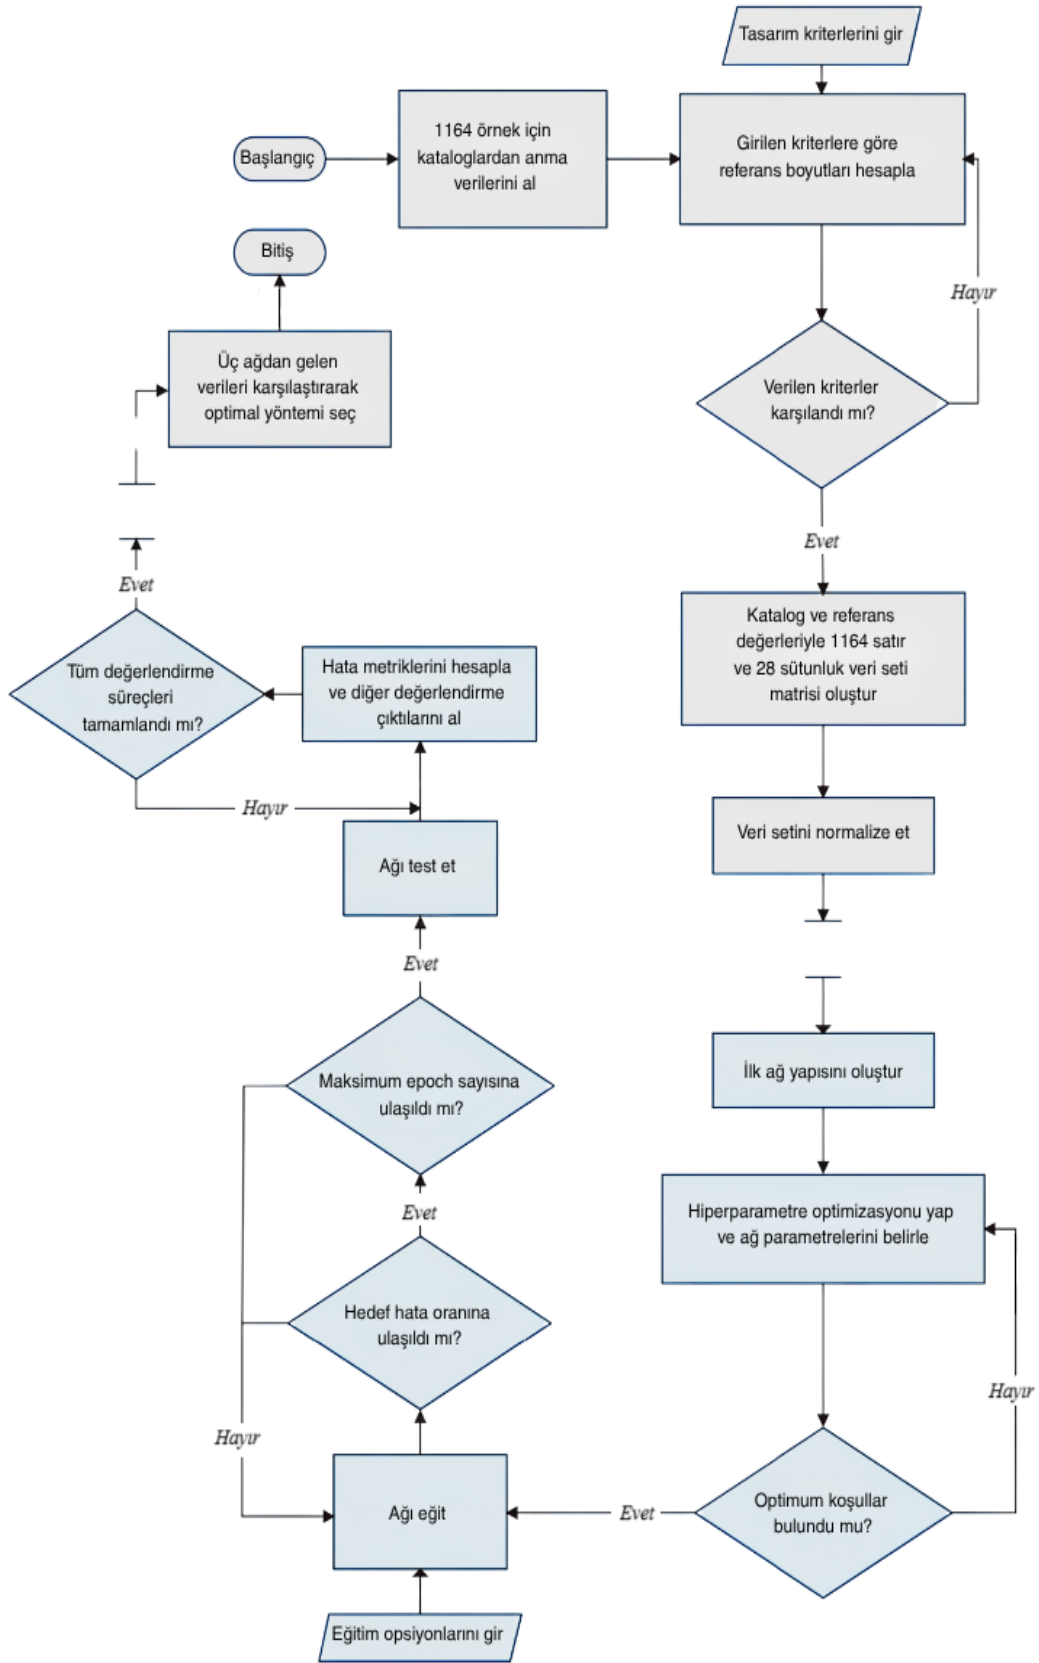
Yöntem adımlarında bahsedilen tek seferlik hesaplamaların gerçekleştirilebilmesi için aşağıdaki varsayımlar yapılmıştır:

1. EMF katsayısı $\gamma_{emf} = 0.97$ ve rotor MMF katsayısı $\gamma_{mmf} = 0.85$ olarak alınmıştır.
2. Sarım katsayısı $k_w = 0.966$ olarak kabul edilmiştir.
3. Çekirdek içerisindeki etkin demir alanını dikkate alan istifleme katsayısı $k_i = 0.96$ olarak belirlenmiştir.
4. Rotor çubukları için akım yoğunluğu $J_r = 4 \text{ A/mm}^2$, uç halkaları için ise $J_e = 8 \text{ A/mm}^2$ olarak alınmıştır. Stator sargılarında ise akım yoğunluğu $J_{sw} = 5 \text{ A/mm}^2$ olarak varsayılmıştır.
5. Manyetik yüklenmenin güce bağlı olarak 0.446 T ile 0.57 T arasında değiştiği; elektriksel yüklenmenin ise başlangıçta $a_c = 30,000 \text{ A/m}$ olarak alındığı ve gerektiğinde iterasyonlarla artırıldığı kabul edilmiştir.
6. Makinelerin uzunluk/kutup adımı oranının 1 ile 1.5 arasında olduğu varsayılmıştır.
7. Stator boyunduruğundaki akı yoğunluğunun 1.4 T ile 1.7 T arasında, stator dışlarında ise 1.4 T ile 2.1 T arasında olabileceği öngörülmüştür. Rotor boyunduruğu akı yoğunluğunun başlangıç değeri $B_{cr} = 1 \text{ T}$ olarak alınmış ve gerektiğinde iterasyonlarda artırılmıştır. Rotor dış akı yoğunluğunun ise $B_{tr} = 1.7 \text{ T}$ olduğu varsayılmıştır.

Şekil 4.8, aşamada kullanılan adımları gösteren basitleştirilmiş bir akış diyagramı sunmaktadır.

4.1.2.2 Mekaniksel Çıktıların Oluşturulması

Elektrik makineleri tasarımında boyutlandırma kritik bir aşamadır. Asenkron makinelerin fiziksel boyutları; faydalanma katsayısının belirlenmesi, temel boyutların ayarlanması, hava aralığının tespiti ve stator ile rotor geometrilerinin oluşturulması gibi çeşitli analitik adımlar izlenerek hesaplanabilmektedir [27, 91–95].



Şekil 4.8 Mekaniksel tahmin aşamasının oluşturulması

İlk adımda, makine faydalanma katsayısı, sargı faktörü, özgül manyetik yükleme ve özgül elektriksel yükleme değerleri dikkate alınarak, Denklem 4.5’de gösterildiği gibi elde edilebilir. Faydalanma katsayısı, bir makineden birim hacim ve birim zamanda elde edilebilecek enerjiyi temsil etmektedir [96]. Bu katsayı kullanılarak hacim hesaplanır ve D ile L parametreleri, uzunluk/kutup adımı oranı dikkate alınarak ayarştırılır.

$$C_o = \frac{1.11\pi^2 B_{av} a c k_w \eta \cos \varphi}{\gamma_{emf}} \quad (4.5)$$

$$D^2 L = \frac{P_\zeta}{C_o n_s} \quad (4.6)$$

Burada, B_{av} : özgül manyetik yükleme, ac : özgül elektriksel yükleme, k_w : sargı faktörü, η : verim, $\cos \varphi$: güç faktörü, P_ζ : çıkış gücü ve n_s : devir sayısıdır.

Stator dış genişliği, stator boyunduruk derinliği ve stator dış çapı sırasıyla Denklem 4.7, 4.8 ve 4.9 ile hesaplanmaktadır [27]. Stator faz akımı dikkate alınarak stator oluk alanı belirlenir. Bu değere göre, standart SWG kesitlerinin yerleştirilebilmesini sağlayacak ve derinlik-genişlik oranını 3 ile 5 arasında tutacak b_1 , b_2 ve d_s değerleri seçilir [93, 97].

$$t_s = \frac{\pi D}{N_s k_i} \left(\frac{B_{g1}}{B_{ts}} \right) \left(\frac{L}{l_i} \right) \quad (4.7)$$

$$d_{cs} = \frac{D}{2pk_i} \left(\frac{B_{g1}}{B_{cs}} \right) \left(\frac{L}{l_i} \right) \quad (4.8)$$

$$D_{os} = D + 2(d_{os} + d_s + d_{cs}) \quad (4.9)$$

Burada, B_{g1} : hava aralığındaki akı yoğunluğu, N_s : stator oluk sayısı, k_i : istifleme katsayısı, B_{ts} : stator dışındaki akı yoğunluğu, l_i : demir boyu, $2p$: kutup sayısı, B_{cs} : stator boyunduruğundaki akı yoğunluğudur.

Rotor boyunduruk derinliği, rotor dış genişliği, rotor dış çapı ve rotor iç çapı sırasıyla Denklem 4.10, 4.11, 4.12 ve 4.13 ile hesaplanır [93]. Rotor çubuğundan geçen akıma bağlı olarak belirlenen rotor çubuk alanı ve belirli genişlik/kalınlık oranı dikkate alınarak, rotor oluk derinlik ve genişlikleri belirlenmektedir. Uç halka derinliği ise, uç halka kesiti baz alınarak tayin edilebilmektedir.

$$d_{cr} = \frac{\phi_p/2}{B_{cr}l_i} \quad (4.10)$$

$$W_{tr} = \frac{\phi_p}{B_{tr} (N_r/p) l_i} \quad (4.11)$$

$$D_r = D - 2g \quad (4.12)$$

$$D_i = D_r - 2(d_{sr} + d_{cr}) \quad (4.13)$$

Burada, ϕ_p : kutup başına akı, B_{cr} : rotor boyunduruğundaki akı yoğunluğu, B_{tr} : rotor dışında akı yoğunluğu, N_r : rotor oluk sayısı anlamına gelmektedir.

4.1.2.3 Mekaniksel Tahmin Simülasyonları

Veri seti oluşturularak, mekaniksel tahmin aşamasının temeli oluşturulmuştur. Belirlenen hedefler doğrultusunda ağların yapısı organize edilmiştir. Yapay sinir ağlarının performansı karşılaştırılmış ve doğrulama çalışmaları sonucunda en iyi strateji seçilmiştir.

• Donanım ve Yazılım

Simülasyon çalışmaları, Intel Core i7 12700H 3.50 GHz 14 çekirdekli 12. nesil bir işlemci, DDR5 64 GB RAM, 2 TB SSD ve Nvidia GeForce RTX 3050 Ti ekran kartına sahip bir bilgisayarda gerçekleştirilmiştir. Makine öğrenmesi sürecinin aşamaları MATLAB R2023a programı kullanılarak uygulanmış, mekanik analiz ise Ansys Electronics Suite 2022 R2 ile yürütülmüştür.

• Veri Seti

Yapay sinir ağı eğitimi için, giriş verileri yedi farklı üreticinin asenkron makine kataloglarından toplanan, çıkış verileri ise analitik hesaplama ile elde edilen bir veri seti kullanılmıştır. Özellikleri Tablo 4.7'de sunulan bu veri seti, 1164 örnek motora ait güç, gerilim, verim ve güç faktörü gibi elektriksel bilgileri ve bu bilgilerin yanı sıra, stator dış çapı, stator oluk genişliği ve stator dış derinliği gibi mekanik ayrıntıları içeren 28 özelliğe sahiptir. Veri seti toplamda 32.592 adet veri noktası içermektedir.

Seçilen güç değerleri, endüstriyel uygulamalarda yaygın olarak kullanılan endüstriyel elektrik motorlarının kapsamlı bir spektrumunu temsil etmektedir. Bu aralık, farklı operasyonel ölçeklerde istatistiksel anlamlılığa ve model sağlamlığına ulaşabilmek için seçilmiştir. Oluşturulan veri seti, genellenebilir bir parametre tahmin modelinin geliştirilmesini kolaylaştırmaktadır. Seçilen boyutlar, motorun elektriksel ve manyetik yüklenme koşullarını sağlamasını mümkün kılan temel geometrik parametreleri ve motorun uygun elektromanyetik özelliklere sahip olması için gereken temel iç tasarım parametrelerini temsil etmektedir.

Tablo 4.7 Mekaniksel tahmin aşaması veri setinin temel özellikleri

	Veri Seti
Örnek sayısı	1164
Veri kaynağı	Üretici katalogları
Markalar	Teco, Weg, Leroy-Somer, CG-Crompton, Havells, Bharat Bijlee ve Kirloskar
Özellik sayısı	28
Girdi özelliklerinin adları	$P_n, V, f, 2p, n,$ $\cos \varphi$ (% 100, % 75 ve % 50 yükte), η (% 100, % 75 ve % 50 yükte)
Çıktı özelliklerinin adları	$D, L, D_{os}, d_s, t_s, d_{cs},$ $b_1, b_2, g, D_i, D_r, h_r,$ $w_{tr}, d_{cr}, d_1, d_2, d_e$
Özelliklerin kapsamı	Makine tipi: 3-fazlı sincap kafesli asenكرون motor Güç aralığı: 4 kW - 900 kW Çalışma frekansı: 50/60 Hz Gerilim değerleri: 400/415 V Kutuplar: 2 - 8

• Sınır Ağları

Makine öğrenmesi algoritmalarının performansı, kullanılan veri setinin boyutu, özellikleri ve kalitesiyle birlikte, yöntem tasarımı ve uygulama aşamalarında seçilen parametrelere bağlıdır [98]. Örneğin, gizli katman sayısı ve katman genişliği gibi parametreler, ağın karmaşıklık düzeyini ve öğrenme kapasitesini belirlerken; öğrenme hızı ve mini yığın (mini batch) boyutu ise ağın yakınsama hızını etkiler [99]. Bu nedenle, ağın minimum kayıpla, maksimum doğrulukta ve en yüksek verimde sonuçlar verebilmesi için hiperparametre optimizasyonu yapılması gereklidir. Bu amaçla, tasarımcı tarafından belirlenen sınırlı bir arama alanında kapsamlı tarama yapan ızgara arama algoritmaları kullanılabilir. Ayrıca, zaman ve hesaplama maliyetlerini azaltmak için manuel

ayarlamalarla süreç mevcut kaynaklarla karşılanabilecek seviyeye indirgenebilir [99, 100].

Tablo 4.8 Mekaniksel tahmin aşaması yapay sinir ağı yapılarının temel parametreleri

Model	Parametre	Değer
MLP	Katman bilgisi	1-girdi, 3-gizli, 1-çıkı
	Özel katman boyutu	29, 17, 17
	Geri yayılım (Backpropagation)	Dayamklı (Resilient)
	Transfer fonksiyonları	Hiperbolik tanjant sigmoid
	Girdi normalizasyonu	Z skoru
	Girdi işleme fonksiyonları	fixunknows, removeconstantrows, mapminmax
	Çıkı işleme fonksiyonları	ppca, removeconstantrows, mapminmax
	Ağırlık/yanıllık öğrenme fonksiyonu	Momentumlu gradyan inişi
	Öğrenme oranı	0.01
Epoch sayısı	10000	
RNN	Katman bilgisi	1-girdi, 3-gizli, 1-çıkı
	Özel katman boyutu	17, 23, 39
	Geri yayılım (Backpropagation)	Dayamklı (Resilient)
	Katman gecikmeleri	1:1
	Girdi normalizasyonu	Z skoru
	Öğrenme oranı	0.01
	Epoch sayısı	10000
LSTM	Katman bilgisi	1-dizi girdi, 2-LSTM, 1-tam bağı, 1-regresyon
	Özel katman boyutu	118, 117
	Çözücü (solver)	Adam
	Girdi normalizasyonu	Z skoru
	Mini yığın boyutu	25
	Gradyan eşik değeri	0.000001
	Gizli katman çıkı modu	Dizi (Sequence)
	Öğrenme oranı	0.01
	Epoch sayısı	10000

MLP ve RNN ağlarının tasarımında, yetersiz eleman kullanılması durumunda ortaya çıkabilecek yetersiz öğrenme (underfitting) problemlerini ve çok sayıda eleman kullanılması durumunda meydana gelebilecek aşırı karmaşıklık, uzun işlem süresi ve aşırı uyum (overfitting) problemlerini önlemek amacıyla, katman sayısı 2-3 ve katman boyutu 15-40 ile sınırlandırılmıştır. Böylece, her iki ağda da katman sayısı ve nöron sayısı, 18.252 deneme noktasından oluşan arama uzayında ızgara arama yöntemiyle belirlenmiştir. LSTM’de ise, işlem süresinin makul bir seviyede tutulabilmesi için, ızgara arama işlemi 9.702 denemeden oluşan bir arama uzayında gerçekleştirilmiştir. Ayrıca, aşırı uyuma sebep olabilecek bir diğer faktör olan epoch sayısı ise, tüm ağlarda sağlıklı bir uygulama yapılabildiği gözlemlendiğinden, 10.000 ile sınırlandırılmıştır.

Problem çözüm hızı ve bir sistemin doğruluğu, geri yayılım (backpropagation) ve çözüm algoritmaları ile değiştirilebilir [99]. BFGS Quasi-Newton, Resilient

Backpropagation, Levenberg-Marquardt ve Gradient Descent algoritmaları arasında, mevcut veri kümesinde hem RNN hem de MLP ağları için en iyi hız-performansı ilişkisi Resilient Backpropagation sağlamıştır. LSTM ağlarında ise, SGDM, RMSProp ve Adam Optimizasyon Algoritmaları göz önünde bulundurulduğunda, mevcut veri kümesi için en iyi sonuç Adam Algoritması ile elde edilmiştir. Öğrenme oranı ve mini yığın boyutu, öğrenme potansiyelini artırabilen parametreler olmakla birlikte, uygunsuz değer seçimlerinde gürültü de yaratabilmektedir [99].

Algorithm 2 Mekaniksel tahmin aşaması

Veri kümesini yükle (D)
Eğitim ($D_{\text{eğitim}}$) ve test (D_{test}) kümelerine ayır
Ağ mimarisini tanımla: katman sayısı, katman boyutları, vb.
Eğitim seçeneklerini belirle: maksimum epoch sayısı, öğrenme oranı, vb.
Hedef hata ($\text{hata}_{\text{hedef}}$), maksimum epoch ($\text{max}_{\text{epoch}}$) ata
Diğer parametreleri rastgele başlat: ağırlık, yanlılık, vb.
epoch $\leftarrow 0$
while epoch $<$ $\text{max}_{\text{epoch}}$ **do**
 epoch \leftarrow epoch + 1
 kayıp $\leftarrow 0$
 for $D_{\text{eğitim}}$ içindeki her (x, y) için **do**
 Ağ çıkışı hesapla (\hat{y})
 \hat{y} ve y ile kayıp fonksiyonunu hesapla (L)
 Parametreleri güncelle
 kayıp \leftarrow kayıp + L
 end for
 Ortalama eğitim kaybını hesapla ($\text{hata}_{\text{ortalama}}$)
 if $\text{hata}_{\text{ortalama}} <$ $\text{hata}_{\text{hedef}}$ **then**
 döngüden çık
 end if
end while
Test verisiyle tahmin yap (\hat{y}_{test})
Değerlendirme ölçütlerini hesapla (MAE, RMSE, vb.)
Çıktı: Tahmini parametreler, değerlendirme ölçütleri

Öğrenme oranı, stokastik gradyan inişi (SGD) sırasında adımın uzunluğunu ifade ederken; mini yığın boyutu, modelin aynı anda işleyeceği veri adedini belirtmektedir [101]. Bu veri kümesi için, değişken öğrenme oranına izin

veren çözücülerde anlamlı bir iyileşme gözlenmediğinden, öğrenme oranı sabit seçilmiştir. LSTM’de öğrenme oranı seçimi, öğrenme oranını dengeleyecek bir mini yığın boyutu ile desteklenirken; MLP’de gürültüyü azaltmak amacıyla momentumlu gradyan inişi tercih edilmiştir.


Aktivasyon fonksiyonu, modele derinlik katarak karmaşık bir veri setinin özelliklerinin yüksek derecede yansıtılmasını sağlar. Bu amacı gerçekleştirmek için sigmoid ve hiperbolik tanjant fonksiyonları yaygın olarak kullanılmaktadır [99, 102–104]. Bu veri seti için hiperbolik tanjant sigmoid ve log-sigmoid fonksiyonları değerlendirilmiş ve ilk seçeneğin daha uyumlu olduğu belirlenmiştir.

Veri setinde geniş bir güç aralığına sahip motorlar bulunduğu ve her bir güç seviyesinden eşit sayıda örnek sağlanmadığı için, uç değerlerin model uyumu üzerindeki etkisini en aza indirmek amacıyla, veri ölçeği Z-skor yöntemi kullanılarak ortalama değeri 0 ve standart sapması 1 olacak şekilde normalize edilmiştir. MLP ağı, diğer ağlara kıyasla daha basit bir yapıya sahip olduğundan, optimal performansını görebilmek için giriş ve çıkış katmanlarında bazı ek işleme fonksiyonları kullanılarak iyileştirilmiştir. Seçilen tüm parametreler Tablo 4.8’de ayrıntılı olarak verilmiştir.

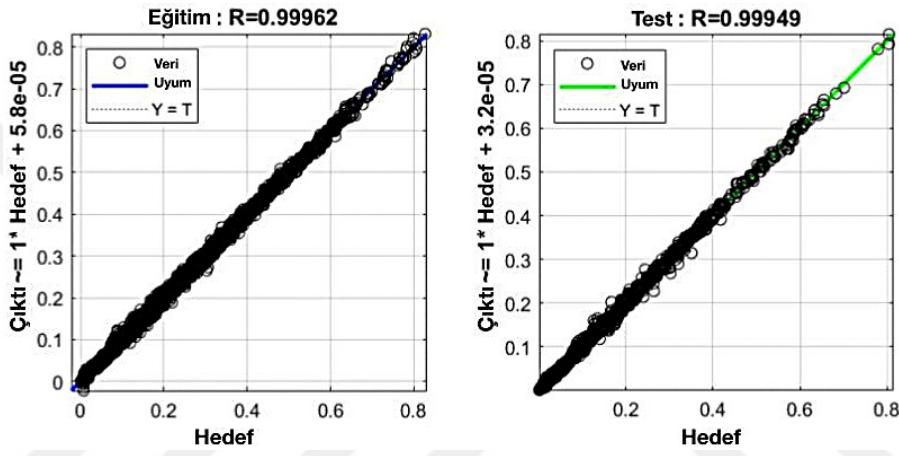
• Karşılaştırmalı Simülasyonlar

Oluşturulan veri seti, eğitim ve test aşamalarında kullanılmak üzere %75 ve %25 olmak üzere ikiye ayrılmıştır. Daha sonra, Algoritma 2’de sadeleştirilmiş haliyle sunulan eğitim ve test aşamaları, hiperparametre optimizasyonu sonucunda belirlenen parametreler dikkate alınarak gerçekleştirilmiştir. MLP, RNN ve LSTM ağları bu aşamaların tamamını sırasıyla 12 saniye, 23 saniye ve 14 dakika 40 saniyede tamamlamıştır. Ağların işlem süreleri karşılaştırıldığında, MLP’nin basit yapısı sayesinde oldukça kısa sürede işlem yaptığı görülmektedir. RNN ise geri besleme bağlantılarına rağmen, seçilen geri yayılım yöntemi sayesinde makul bir işlem süresi sunmuştur. Beklendiği üzere, LSTM ise kendi yapısına özgü bellek işlemleri nedeniyle işlemleri diğer ağlara göre çok daha uzun sürede tamamlamıştır.

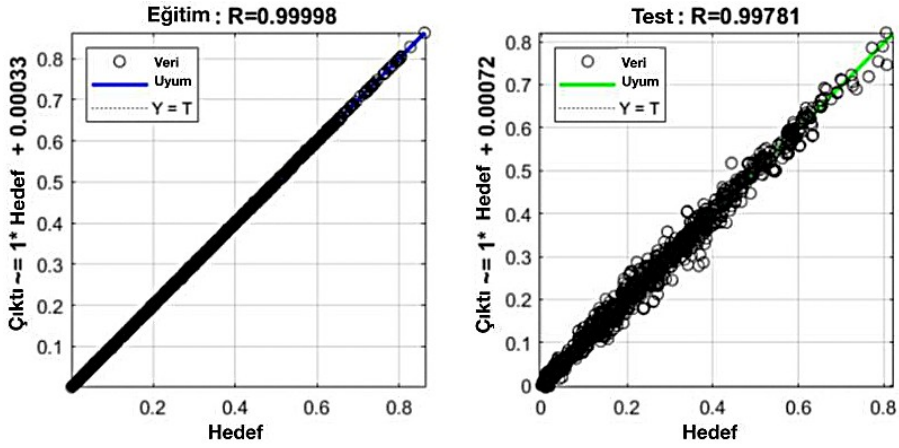
Her bir ağın eğitim ve test aşamalarındaki performansına genel bir bakış Şekil 4.9’da sunulmuştur. Regresyon grafikleri, ağlardan elde edilen çıktılar (Y) ile hedefler (T) arasındaki yakınsamayı göstermektedir. Bu grafiklerde (T, Y) koordinatlarını temsil eden noktaların $T=Y$ eğrisine yaklaşması, doğru çıktılar elde etme olasılığının yüksek olduğunu gösterir. Bu doğrultuda, tüm



a) MLP



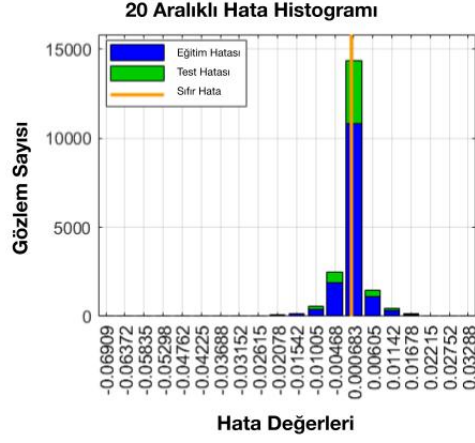
b) RNN



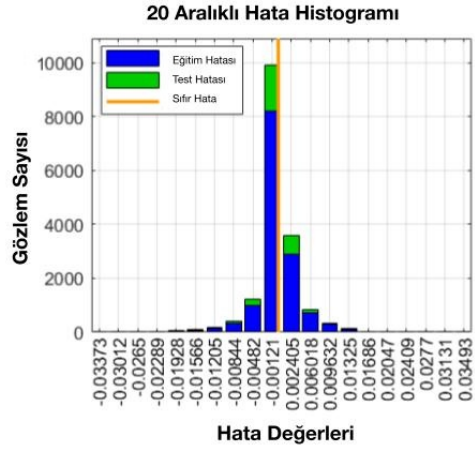
c) LSTM

Şekil 4.9 Mekaniksel tahmin aşaması eğitim ve test adımlarının regresyon grafikleri

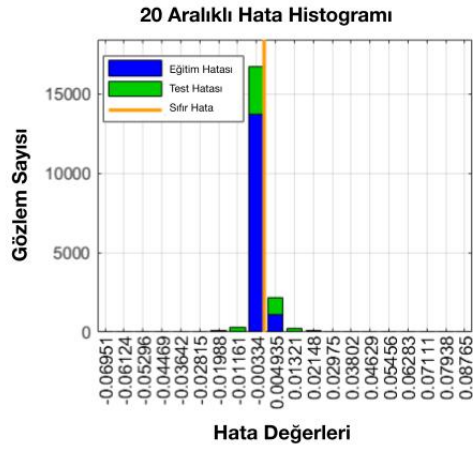
ağlarda anlamlı bir uyum sağlandığı anlaşılmaktadır. Ayrıca, LSTM'nin öğrenme aşamasında öne çıktığı, ancak test aşamasında daha dağınık bir profil sergilediği ifade edilebilir. Test aşamasında ise en iyi uyum RNN tarafından sağlanmıştır.



a) MLP



b) RNN



c) LSTM

Şekil 4.10 Mekaniksel tahmin aşaması eğitim ve test adımlarının hata histogramları


Ağ performansının genel değerlendirmesinde, hata histogramları da ikincil bir yöntem olarak kullanılmıştır. Hata histogramları, süreç boyunca oluşan hataların dağılımını gösteren istatistiksel bir araçtır. X eksenini oluşturan hataların büyüklüğünü, Y eksenini ise bu hata büyüklüklerinin belirli bir zaman aralığındaki tekrar sayılarını göstermektedir. Şekil 4.10'de eğitim ve test süreçlerine ait hata dağılımları görülmektedir. Tüm süreçlerde hataların sıfır hata çizgisine yakın yoğunlaştığı gözlemlense de, ağlar hata büyüklükleri ve yoğunluk değerleri açısından farklı özellikler göstermiştir. Hata dağılımları, MLP, RNN ve LSTM'de sırasıyla 0.000683, -0.00121 ve -0.00334 değerlerinde tepe yapmıştır. Bununla birlikte, hata büyüklüğü açısından avantajlı gibi görünen MLP'de hata yaklaşık 15000 kez tekrar etmektedir. LSTM'de ise hata tekrar sayısı 15000'i aşarken, RNN'de bu değer 10000'in altındadır ve hatanın en az tekrarlandığı ağ RNN olmuştur. Ancak, hata histogramı da tek başına net bir çıkarım yapmak yeterli değildir.

Test aşaması, daha önce öğrenilmemiş veriler üzerinde gerçekleştirildiği için, ağın güvenilirliği açısından eğitim aşamasından daha etkilidir. Test örneklerine ilişkin 17 çıktı özelliğinin her birinde hedef değere yakınsama sağlanıp sağlanmadığını görmek için kutu grafikler kullanılmıştır. Gerçek değerlerin dağılımını kırmızı renkte, ağlar sonucunda elde edilen değerler ise mavi renkte Şekil 4.11'de gösterilmiştir. Bazı aykırı değerlerde farklılıklar gözlemlense de, üç ağ yapısında da herhangi bir özellik değerinin kullanılabilirliğini sorgulatabilecek bir durum görülmemektedir.

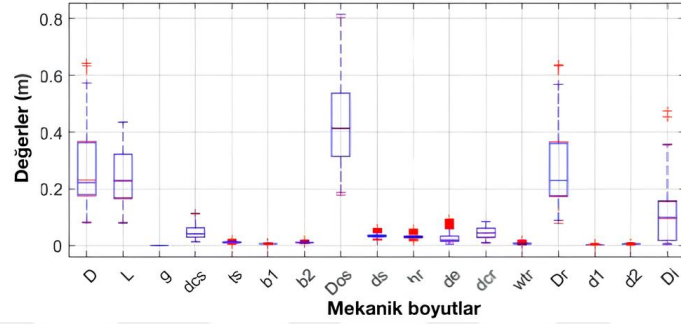
Tablo 4.9 Sinir ağı tabanlı mekaniksel tahmin yapılarının farklı hata metriklerine göre performans sonuçları

	MLP			RNN			LSTM		
	R	MAE	RMSE	R	MAE	RMSE	R	MAE	RMSE
D	0.997970	0.005415	0.008065	0.997690	0.005202	0.007719	0.990780	0.012696	0.017132
L	0.996330	0.006145	0.007945	0.997750	0.004528	0.006136	0.989720	0.009842	0.013324
g	0.995340	0.000012	0.000017	0.997630	0.000009	0.000012	0.960970	0.000142	0.000150
d_{cs}	0.994700	0.001443	0.002382	0.998640	0.000963	0.001229	0.992900	0.002226	0.002947
t_s	0.973690	0.000569	0.000750	0.977960	0.000513	0.000684	0.915020	0.001045	0.001336
b_1	0.975310	0.000232	0.000317	0.979220	0.000233	0.000302	0.937570	0.000963	0.001072
b_2	0.973360	0.000394	0.000548	0.980690	0.000362	0.000485	0.932750	0.000693	0.000877
D_{os}	0.997420	0.007473	0.010635	0.998210	0.006009	0.008215	0.988790	0.016108	0.022097
d_s	0.974710	0.001189	0.001606	0.980810	0.001093	0.001449	0.937580	0.002085	0.002658
h_r	0.867840	0.002824	0.003542	0.887670	0.002933	0.003574	0.734660	0.004194	0.005225
d_e	0.990830	0.001610	0.002349	0.992490	0.001620	0.002252	0.977720	0.002808	0.003743
d_{cr}	0.988300	0.002271	0.003088	0.990860	0.001896	0.002801	0.963360	0.004065	0.005473
w_{tr}	0.818580	0.001372	0.001738	0.857570	0.001397	0.001729	0.673020	0.002006	0.002511
D_r	0.996760	0.006319	0.010143	0.998130	0.005175	0.006882	0.990780	0.012631	0.017063
d_1	0.869940	0.000353	0.000440	0.883230	0.000372	0.000455	0.737880	0.000524	0.000651
d_2	0.865500	0.000573	0.000716	0.887210	0.000587	0.000719	0.740300	0.000853	0.001076
D_i	0.995640	0.006608	0.009517	0.994820	0.006503	0.008936	0.989190	0.010702	0.014934
Total	0.999340	0.002636	0.005287	0.999490	0.002317	0.004377	0.997810	0.004917	0.009616


Hata metrikleri, net bir şekilde karşılaştırılabilen sayısal veriler sunmakta ve görsel araçları desteklemektedir. Tablo 4.9, her bir özellik için, tüm test



a) MLP



b) RNN




c) LSTM

Şekil 4.11 Mekaniksel tahmin aşaması eğitim ve test adımlarının kutu grafikleri


örnekleri dikkate alındığında elde edilen korelasyon katsayısı, MAE ve RMSE değerlerini göstermektedir. Herhangi bir parametre için elde edilebilecek en yüksek korelasyon değeri MLP, RNN ve LSTM'de sırasıyla 0.9979, 0.9986 ve 0.9929'dur. Tüm veri seti genelindeki MAE değerleri sırasıyla 0.0026, 0.0023 ve 0.0049, RMSE değerleri ise 0.0053, 0.0044 ve 0.0096'dır. Bu değerler ışığında da, RNN'nin daha güvenilir sonuçlar verdiğini söylemek mümkündür.

Tüm karşılaştırma aşamaları göz önüne alındığında, LSTM'nin beklenildiği gibi zaman açısından oldukça maliyetli olduğu açıkça söylenebilir. Diğer test edilen yapılara kıyasla daha fazla sayıda eleman içermesine rağmen, bu



Şekil 4.12 Tekrarlayan sinir ağı mekaniksel tahmin çıktı verilerinin dağılımı

aşama özelinde performans açısından geride kalmakta ve doğruluk değerleri dikkate alındığında, zaman açısından sahip olduğu dezavantaj göz ardı edilememektedir. MLP ise, genel olarak LSTM'e göre daha yüksek doğruluk sağlamış olsa da, bazı parametreler için sunduğu korelasyon değeri 0.8186'ya kadar düşmüştür. RNN ise tüm parametrelerde 0.8576 korelasyon değerinin üzerinde kalmıştır. Sonuç olarak, ele alınan güç aralığındaki asenkron motorların mekanik parametrelerinin belirlenmesinde en etkili yöntemin RNN olduğu söylenebilir. Şekil 4.12'da, gerçek ve tahmini değerlerin dağılımının benzerliği, RNN'nin etkinliğini doğrulamaktadır. Bu şekilde, x eksenini özellik sayısını, y eksenini test örneklerinin sayısını ve z eksenini ise büyüklükleri göstermektedir.



Şekil 4.13 Yaklaşık makine ağırlığı ve tahmini ana mekaniksel boyutlar arasındaki ilişki

RNN ağı, kütleli ağırlık parametresi giriş olarak eklenerek yeniden

çalıştırılmıştır ve bu sayede ağırlık ile boyutlar arasındaki ilişki incelenmiştir. Şekil 4.13, temel boyutlar (D ve L) ile ağırlık arasındaki bağlantıyı göstermektedir. Grafikte mavi yıldızlar 175 test örneği için tahmin edilen değerleri, turkuaz noktalar ise gerçek değerleri göstermektedir; ayrıca güç değerleri belirli aralıklarla işaretlenmiştir. Gerçek değer dağılımı, ağırlık ve güç arttıkça D ve L değerlerinde bir artış eğilimi olduğunu göstermektedir. Bu eğilim, tahmin edilen değer dağılımında da etkili şekilde yansıtılmaktadır. Görselleştirme, boyutsal parametreler ile hem ağırlık hem de güç değerleri arasında net bir pozitif korelasyon olduğunu ortaya koymaktadır. Farklı güç aralıklarında tahmin edilen değerler ile gerçek değerlerin birbirine yakın olması, ağırlık çoklu giriş parametreleri arasındaki karmaşık ilişkileri başarıyla yakaladığını ortaya koymaktadır. Bu durum, modelin giriş uzayının arttırılmasına rağmen tahmin doğruluğunu koruyabildiğini göstermektedir.

Tablo 4.10 Sinir ağı tabanlı mekaniksel tahmin yapısının performansının farklı bir regresyon modeli ile karşılaştırılması

Model	R		MAE		RMSE	
	Eğitim	Test	Eğitim	Test	Eğitim	Test
SVR	0.9989	0.9976	0.0035	0.0048	0.0067	0.0104
RNN	0.9996	0.9995	0.0022	0.0023	0.0039	0.0044

Tahmin çalışması, modelin performansını diğer makine öğrenimi algoritmalarıyla karşılaştırmak amacıyla, Destek Vektör Regresyonu (SVR) algoritması kullanılarak gerçekleştirilmiştir ve Gauss çekirdeği (kernel) kullanılarak, girişler ve hedefler arasındaki karmaşık ilişkiler analiz edilmiştir. Bu yapı, her biri 17 farklı hedefe karşılık gelen 17 farklı hücre yapısından oluşmaktadır. RNN ve SVR modellerinin performanslarının karşılaştırılması Tablo 4.10'te sunulmuştur.

Performans karşılaştırması, RNN'in hem eğitim hem de test aşamalarında SVR'den daha iyi performans gösterdiğini ortaya koymaktadır. RNN (Eğitim: 0.99962, Test: 0.99949), SVR'ye kıyasla (Eğitim: 0.99886, Test: 0.99756) daha yüksek R değerlerine ve daha düşük hata metriklerine (MAE ve RMSE) ulaşmaktadır. Bu sonuçlar, RNN'in karmaşık ilişkileri modelleme ve daha iyi genelleme yapma yeteneğini göstermekte, bu da onu bu görev için daha uygun bir seçim haline getirmektedir.

• Vaka Çalışması

Başarılı bulunan metodolojinin, uygulanabilirliğini doğrulamak amacıyla bir vaka çalışması gerçekleştirilmiştir. Tablo 4.11’te giriş verileri verilen motor örnek olarak seçilmiş ve bu motora ait gerçek değerler ve RNN ile elde edilen tahmini değerler kullanılarak manyetik analiz yapılmıştır; söz konusu değerler Tablo 4.12’de sunulmaktadır. Gerçek ve tahmini değerler arasındaki ortalama sapma %1,67 olarak gözlemlenmiştir. Motor tasarımı optimizasyonunun karmaşıklığı göz önüne alındığında, bu sapmanın %2’nin altında olması tatmin edici olarak değerlendirilmiştir.


Tablo 4.11 Mekaniksel tahmin vaka örneğinin giriş parametreleri

V	f	$2p$	P_n	n	η			$\cos \varphi$		
					100%	75%	50%	100%	75%	50%
400 V	50 Hz	6	37 kW	980 rpm	93.3%	94%	94%	0.85	0.82	0.75

Tablo 4.12 Mekaniksel tahmin vaka örneğinin çıkış parametreleri


Stator	Boyut	D	L	g	d_{cs}	t_s	b_1	b_2	D_{os}	d_s
	Gerçek (m)	0.3290	0.1758	0.0007	0.0299	0.0103	0.0064	0.0106	0.4539	0.0318
	Tahmini (m)	0.3280	0.1711	0.0007	0.0299	0.0108	0.0064	0.0107	0.4507	0.0323
	% Fark	-0.30%	-2.68%	0.00%	0.00%	4.85%	0.00%	0.94%	-0.71%	1.57%
Rotor	Boyut	h_r	d_e	d_{cr}	w_{tr}	D_r	d_1	d_2	D_i	
	Gerçek (m)	0.0294	0.0160	0.0395	0.0065	0.3277	0.0037	0.0059	0.1898	
	Tahmini (m)	0.0286	0.0159	0.0410	0.0063	0.3251	0.0036	0.0058	0.1871	
	% Fark	-2.72%	-0.63%	3.80%	-3.08%	-0.79%	-2.70%	-1.69%	-1.42%	

Şekil 4.14’de gösterilen tasarım, örnek motora ilişkin ağdan elde edilen değerlerin kullanılması yoluyla gerçekleştirilebilmiştir. Sağlıklı bir boyutlandırmanın yapılmasının mümkün olduğu görülmüştür.




Şekil 4.14 Mekaniksel tahmin vaka örneğinin tasarımı

Gerçek değerler ve tahmin edilen değerler kullanılarak elde edilen tasarımların elektromanyetik alan davranışlarını incelemek için bir simülasyon gerçekleştirilmiştir. Bu çalışmanın grafiksel gösterimi Şekil 4.15’de verilmiştir. Her iki tasarımın da birbirine benzer şekilde dağılmış alan büyüklüklerine sahip olduğu görülmüş ve her iki tasarımda da ulaşılabilen maksimum akı yoğunluğunun yaklaşık 3000 mTesla civarında olduğu tespit edilmiştir.



a) Gerçek değerlerle manyetik analiz



b) Tahmini değerlerle manyetik analiz

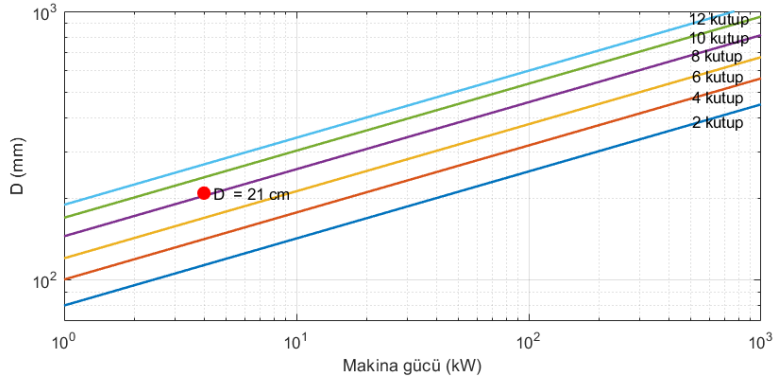
Şekil 4.15 Mekaniksel tahmin vaka örneğinin manyetik analizi

4.2 Optimizasyon Aşaması

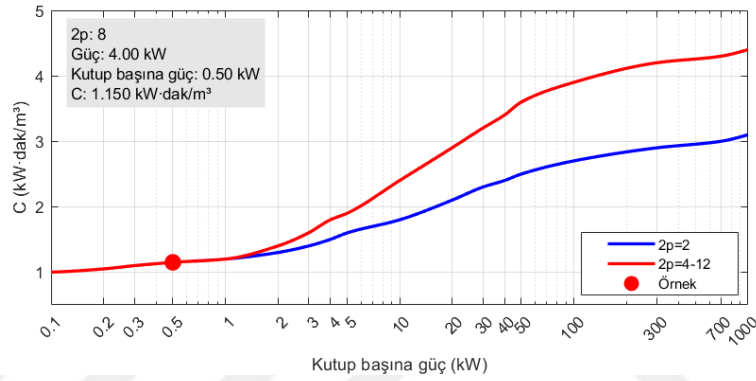
4.2.1 Mekaniksel Parametre Kapsamının Geliştirilmesi

Asenkron makinede daha geniş bir parametre aralığının kapsanması, oluşabilecek diş - oluk genişliği gibi tasarımsal uyumsuzlukların engellenmesi ve standart gövde boyutlarına uygun çıktı parametrelerinin elde edilebilmesi için, araştırma sürecinde, parametre aşamasını geliştirme ihtiyacı doğmuştur. Bu doğrultuda veri seti çıktı matrisini oluşturmakta kullanılan analitik hesaplamalar, parametrik ilişkileri daha hassas biçimde yansıtacak şekilde

revize edilmiş ve daha ayrıntılı bir veri seti oluşturulmuştur.



Şekil 4.16 Stator iç çapının ampirik olarak belirlenmesi



Şekil 4.17 Faydalanma katsayısının ampirik olarak belirlenmesi

Bu aşamada, stator iç çapının büyüklüğü ile faydalanma katsayısının değeri, sırasıyla Şekil 4.16 ve Şekil 4.17’de sunulan ampirik ilişkiler kullanılarak belirlenmiştir [96]. Söz konusu ilişkilerin, standart gövde boyutlarına uygun ölçülerin tespitinde daha etkin olduğu gözlemlenmiştir. Elde edilen bu parametreler doğrultusunda diğer bir temel parametre olan stator uzunluğu değeri hesaplanabilmektedir. Ayrıca, bu değerler üzerinden boyunduruk bölgesinde beklenen manyetik akı ve iletkenlerde oluşması öngörülen akım yoğunlukları dikkate alınarak ikincil parametrelere de ulaşılabilmektedir. Bu aşamada, oluk-diş uyumunu sağlamak amacıyla diş ve oluk genişlikleri basitçe oluk adımı esas alınarak hesaplanmakta, oluk genişliğinin ise oluk adımının 0,4–0,6 katı arasında olmasına dikkat edilmektedir.

Hedeflenen rotor ve stator oluk parametreleri Şekil 4.18’te görüldüğü gibi artırılmıştır. Optimizasyon aşamasının temeli, bu geliştirilmiş parametre setine dayanmaktadır. Bu kapsamda, d_{s0} , d_{s1} , t_{s1} , b_0 , h_{r0} , h_{r1} , w_{tr1} ve d_0 sırasıyla stator oluk ağız yüksekliği, stator oluk yalıtım kısmı yüksekliği, stator dişi üst kısım genişliği, stator oluk ağız genişliği, rotor oluk ağız yüksekliği,

Algorithm 4 Stator boyutlarının belirlenmesi

for $i = 1$ **to** $n_{\text{örnek}}$ **do**

...

Adım 3: Stator Oluk Sayısı ve Kirişleme

$[q, N_s, \tau_o] \leftarrow \text{statorOlukSayisi}(D, P_n, p)$

$k_{bo} \leftarrow N_s/p$

$stp \leftarrow (k_{bo} - 1)/k_{bo}$ (kirişleme oranı)

Adım 4: Sargı Faktörü Hesabı

$\alpha \leftarrow \pi p/N_s$

$k_d \leftarrow \sin(q\alpha/2)/(q \sin(\alpha/2))$ (yayıma faktörü)

$k_p \leftarrow \cos(\pi/2 \times (1 - stp))$ (kirişleme faktörü)

$k_w \leftarrow k_d \times k_p$ (sargı faktörü)

Adım 5: Sarım Sayısı ve İletken Bilgileri

$B_{g1} \leftarrow 0.65$ [T] (hava aralığı akı yoğunluğu)

$\phi \leftarrow B_{g1} \times \alpha_i \times \tau_k/100 \times L_1$ [Wb]

$vemf \leftarrow \text{calculateAsyncMotorValue}(p)$

$E_1 \leftarrow V_f \times vemf$ [V]

$w_1 \leftarrow E_1/(4.44 \times f \times k_{f1} \times k_w \times \phi)$

$w_{1rounded} \leftarrow \text{roundToNextMultiple}(w_1, N_s)$

$Z_1 \leftarrow 2 \times m \times w_{1rounded}$ (toplam iletken sayısı)

$Z_{1f} \leftarrow Z_1/N_s$ (oluk iletken sayısı)

Adım 6: İletken Kesit Alanı

$J_{sw} \leftarrow \text{getCurrentDensity}(P_n)$ [A/mm²]

$A_{iletken} \leftarrow I_n/J_{sw}$ [mm²]

$d_{std} \leftarrow \text{selectStandardWire}(d_{iletken})$ [mm]

$A_{oluk} \leftarrow Z_{1f} \times A_{std}/k_{fill}$ [mm²]

Adım 7: Stator Oluk Optimizasyonu

$B_{ts_min} \leftarrow 1.3, B_{ts_max} \leftarrow 1.7$ [T]

for $b_k = 0.4$ **to** 0.6 **step** 0.01 **do**

b_0 değeri ata

d_{s0} değeri ata

d_{s1} değeri ata

$b_1 \leftarrow b_k \times b_{1_tau_o}$

$t_s \leftarrow b_{1_tau_o} - b_1$

$b_2 \leftarrow b_1 + b_1 \times 0.25$

$d_s \leftarrow A_{oluk}/((b_1 + b_2)/2)$

$t_{s1} \leftarrow b_{2_tau_o} - b_2$

$B_{ts} \leftarrow \phi/((N_s/p) \times L_i \times t_s \times 10^{-6})$

B_{ts} kontrolü yap

end for

Adım 8: Stator Core Yüksekliği ve Dış Çap

$B_{cs} \leftarrow 1.2$ [T]

$d_{cs1} \leftarrow \phi(1 + a_1)/(2 \times k_{fe} \times L_1 \times B_{cs})$ [m]

$D_{os} \leftarrow D + 2d_{cs} + 2(d_{s0} + d_{s1} + d_s)$ [mm]

...

end for

Algorithm 5 Rotor boyutlarının belirlenmesi

```
for  $i = 1$  to  $n_{\text{örnek}}$  do
    . . .
    Adım 9: Rotor Parametreleri
     $D_r \leftarrow D - 2g$  [mm] (rotor dış çapı)
     $N_r \leftarrow \text{findRotorSlots}(p, N_s)$ 
     $\tau_{u_r} \leftarrow \pi D_r / N_r$  [mm] (rotor oluk adımı)
     $s$  (kayma) değeri belirle
     $I_{ck} \leftarrow (P_n \times 1000 + P_{katma}) / (N_r \times E_{ck} \times (1 - s))$  [A]
    Adım 10: Rotor Oluk Optimizasyonu
     $B_{tr\_min} \leftarrow 1.3, B_{tr\_max} \leftarrow 1.7$  [T]
     $J_r \leftarrow \text{getRotorCurrentDensity}(P_n)$  [A/mm2]
    for  $b_r = 0.4$  to  $0.6$  step  $0.01$  do
         $S_{cubuk} \leftarrow I_{ck} / J_r$  [mm2]
         $A_{r\_oluk} \leftarrow S_{cubuk} + S_{bosluk}$  [mm2]
         $d_2 \leftarrow \tau_{u_r} \times b_r$ 
         $d_1 \leftarrow d_2 \times 0.8$ 
         $h_r \leftarrow A_{r\_oluk} / d_{12}$  (damla faktörü ile)
         $d_0, h_{r0}, \bar{h}_{r1}$  değeri ata
         $h_{rt} \leftarrow h_{r0} + h_{r1} + h_r$ 
         $w_{tr}, w_{tr1} \leftarrow \text{hesapla dış genişliği}$ 
         $B_{tr} \leftarrow \phi / ((N_r / p) \times L_i \times w_{tr} \times 10^{-6})$ 
        if  $B_{tr} \in [B_{tr\_min}, B_{tr\_max}]$  then
            Optimum boyutları kaydet ve break
        end if
    end for
    Adım 11: Rotor Mil Çapı
     $B_{cr} \leftarrow 1.2$  [T]
     $d_{cr} \leftarrow \phi / (2 \times k_{fe} \times L_1 \times B_{cr}) \times 1000$  [mm]
     $D_i \leftarrow D_r - 2h_{rt} - 2d_{cr}$  [mm] (rotor mil çapı)
    Adım 12: Kısa Devre Halkası Boyutları
     $I_e \leftarrow N_r \times I_{ck} / (2\pi p)$  [A]
     $J_e \leftarrow 8$  [A/mm2]
     $A_e \leftarrow I_e / J_e$  [mm2]
     $d_e$  değeri belirle
     $d_{eh}$  değeri belirle
     $l_e \leftarrow \text{calculateEndLength}(d_{eh}, d_e, P_n)$  [mm]
    Sonuç: Tüm boyutlar hesaplandı
end for
```

Diğer temel makine boyutlarını ifade eden D , L , D_{os} , d_{cs} , g , D_i , D_r ve d_{cr} gibi parametreler ise ilk aşamadaki isimlendirilmeleriyle korunmuştur. Yapılan bu düzenlemelerle, bu aşamada dikkate alınan mekanik parametre sayısı 28'e çıkarılmıştır. Veri setinin oluşturulmasında kullanılan ana boyutların, stator boyutlarının ve rotor boyutlarının belirlenmesine ilişkin güncel algoritmalar,

örnek sayısal oranlarla birlikte sırasıyla Algoritma 3, Algoritma 4 ve Algoritma 5'te sunulmuştur.

4.2.2 Yılan Optimizasyonunun Uygulanması

Fitness fonksiyonu, bir optimizasyon probleminin çözüm uzayındaki aday tasarım parametrelerinin uygunluğunu nicel olarak değerlendirmek için kullanılır. Bu çalışmada fitness fonksiyonu, optimizasyonun her iterasyonunda elde edilen tasarım parametreleriyle hesaplanan verim değerinin, üretici kataloğunda hedeflenen anma güç değerine karşılık verilen tam yük verim değerine olan yakınlığının karesel fark cinsinden ifadesidir ve Algoritma 6'da tanımlanmıştır. Oluşturulan optimizasyon tekniği, tanımlanan fitness fonksiyonunu minimize etmek üzere yapılandırılmıştır ve belirlenen tasarım değişkenleri ve parametreler doğrultusunda, fitness fonksiyonunu en küçük değere indirgeyen en uygun makine tasarımını bulunmasını sağlar. x başlangıç vektörünü ifade etmektedir ve tahmin aşamasında elde edilen değerleri içerir. $param$ ise katalog bilgilerini içeren bir vektördür. Sürecin ilk aşamasında, rotor mil çapı, rotor boyunduruk çapı, oluk yükseklikleri ve hava aralığı gibi tasarım değişkenleri x vektöründen; kutup sayısı, anma güç, gerilim ve hedef verim gibi anma değerler ise $param$ dizisinden alınarak ilgili değişkenlere atanır. Bu temel büyüklükler üzerinden, rotor ve stator çapları gibi makinenin dış geometrik özellikleri hesaplanır. Devamında, kutup sayısına bağlı olarak stator oluk sayısı ve bu parametreyle ilişkili olarak türetilen rotor oluk sayısı belirlenir. Ayrıca, anma güç ve kutup sayıları dikkate alınarak makinenin hangi IEC standart gövde aralığında yer alabileceği saptanır. Mekanik dayanım ve performans açısından kritik öneme sahip olan uzunluk/kutup adımı oranı ve çevresel hız parametreleri hesaplanır. Elektromanyetik açıdan ise, boyunduruk ve dış bölgelerindeki manyetik akı yoğunlukları belirlenerek manyetik doyum riski değerlendirilir.

Toplam kayıp analizi kapsamında, stator ve rotor bakır kayıpları, akım ve direnç değerleri kullanılarak hesaplanırken; demir kayıplarının hesabında frekans, malzeme özellikleri ve stator boyutları dikkate alınmaktadır. Ayrıca, mekanik kayıplar rotor ve mil parametrelerine dayalı olarak değerlendirilmekte ve diğer ek kayıplarla birlikte makinenin toplam kayıp profili oluşturulmaktadır. Bu kayıplar doğrultusunda, makinenin çıkış gücü ile elde edilen gerçek verim nicel olarak belirlenmekte ve hesaplanan verim, hedeflenen verimle karşılaştırılmaktadır. Makinenin teknik ve fiziksel açıdan uygunluğunu sağlamak amacıyla, tüm geometrik, elektriksel ve manyetik parametrelere çeşitli mühendislik sınırları kapsamında kısıtlamalar

Algorithm 6 Makine Fitness Değerlendirme Algoritması

function **MakineFitness**($x, param$)

$D_i, L, d_{cr}, h_{r0}, h_{r1}, h_r,$

$d_{cs}, d_{s0}, d_{s1}, d_s, g,$

$b_1, b_2, d_1, d_2 \leftarrow x$

▷ Tasarım değişkenlerini al

$p, n, f, P_n, V, \eta_{hedef}, \cos \varphi,$

$r_1, r_2', X_1, X_2', X_m \leftarrow param$

▷ Makine parametrelerini al

$D_r \leftarrow D_i + 2d_{cr} + 2(h_{r0} + \dots)$

▷ Rotor dış çapı

$D \leftarrow D_r + 2g$

▷ Stator iç çapı

$D_{os} \leftarrow D + 2d_{cs} + 2(d_{s0} + \dots)$

▷ Makine dış çapı

$(Ns, \tau_o) \leftarrow \text{StatorSlot}(D, P_n, p)$

▷ Stator oluk parametreleri

$Nr \leftarrow \text{RotorSlot}(p, Ns)$

▷ Rotor oluk sayısı

$\text{gövde} \leftarrow \text{IECFrame}(P_n, p)$

▷ IEC gövde büyüklüğü

$v \leftarrow \pi Dn/60000$

▷ Çevresel hız [m/s]

$ar \leftarrow L/(\pi D/p)$

▷ Uzunluk/kutup adımı (aspect) oranı

$B_{cs}, B_{cr} \leftarrow \dots$

▷ Manyetik akı yoğunlukları

$B_{ts}, B_{tr} \leftarrow \dots$

▷ Dış akı yoğunlukları

$P_{cus} \leftarrow 3r_1 I_1'^2$

▷ Stator bakır kaybı

$P_{cur} \leftarrow 3r_2' I_2'^2$

▷ Rotor bakır kaybı

$P_{Fes}, P_{mek}, P_{ek}, P_{kayıplar} \leftarrow \dots$

▷ Demir vb. kayıplar

$P_{\zeta} \leftarrow (P_n 1000)/\eta_{hedef} - P_{kayıplar}$

▷ Çıkış gücü

$\eta \leftarrow 100P_{\zeta}/P_{in}$

▷ Hesaplanan verim

$cv \leftarrow [1.6 \text{ gövde} - D_{os}; D_{os} - 2.2 \text{ gövde}; v - 75;$

$0.5 - ar; ar - 2.0; h_{r1} - 0.3h_r; h_{r0} - h_{r1};$

$d_{s1} - 0.3d_s; d_{s0} - d_{s1}; 0.1D_{os} - D_i;$

$\tau_o - 25; 1.2 - B_{cs}; B_{cs} - 1.4;$

$1.2 - B_{cr}; B_{cr} - 1.4; 1.3 - B_{ts};$

$B_{ts} - 1.7; 1.3 - B_{tr}; B_{tr} - 1.7;$

$b_1 - b_2; d_1 - d_2]$

▷ Tüm kısıtlamaları uygula

$penalty \leftarrow \sum \max(0, cv)$

▷ Kısıt ihlallerinin toplamı

$fval \leftarrow (\eta_{hedef} - \eta)^2 + penalty$

▷ Amaç fonksiyonu

return $fval, [D_r, D, D_{os}],$

$[P_{cus}, P_{cur}, P_{Fes}, P_{mek}, P_{ek}],$

cv

▷ Çıktılar

end function

uygulanmakta; kısıtların ihlali halinde ilgili ceza terimleri fitness fonksiyonuna eklenmektedir. Sonuç olarak, fitness fonksiyonu hedeflenen verim ile hesaplanan verim arasındaki farkın karesiyle, kısıt ihlallerinin toplam cezasının

bileşimi olarak tanımlanır. Böylelikle algoritma, hem makinenin belirlenen tüm teknik gereksinim ve sınırlara uygunluğunu sağlamaya çalışmakta hem de istenen performansa en yakın tasarımları önermektedir. Optimizasyon sürecinin sonunda, fitness fonksiyonunun minimum olduğu tasarım noktasının bulunmasıyla, hedef anma değerlere karşılık gelen için en etkin geometrik parametreler belirlenmiş olur.

Tablo 4.13 Optimizasyon aşaması örnek motor anma değerleri

Motor	Gerilim (V)	Frek. (Hz)	Kutup Sayısı	Güç (kW)	Hız (d/dk)	Verim (%)			Güç Faktörü		
						100	75	50	100	75	50
Motor 1	400	50	4	400	1491	96.40	96.70	96.60	0.88	0.87	0.83
Motor 2	415	50	6	250	993	95.50	95.00	94.00	0.84	0.81	0.73
Motor 3	415	50	2	150	2975	95.00	94.50	92.50	0.94	0.92	0.90
Motor 4	400	50	2	22	2952	93.60	94.10	93.80	0.89	0.87	0.81
Motor 5	400	50	2	4	2920	88.50	89.50	89.40	0.89	0.85	0.77

Algoritmanın etkinliğini değerlendirmek amacıyla rastgele seçilen beş farklı örneğe ait hedef anma setleri kullanılarak her bir örnek motor için optimizasyon süreci uygulanmıştır. Bu kapsamda, 400 kW, 250 kW, 150 kW, 22 kW ve 4 kW gücündeki motorlar için analizler gerçekleştirilmiş olup, söz konusu motorların anma değerleri Tablo 4.13'te sunulmaktadır.

Hibrit tasarım tekniğinin bu anma değerlere karşılık, sunduğu tasarım parametreleri ise 4.14'te görülebilir. Motor boyutlarının güç değeri küçükdükçe azaldığı, güçle ilişkili olarak daha büyük ya da küçük yapılar elde edilebildiği görülmektedir. Hava aralıklarının standart sınırlarda kaldığı ve tutarlı oluk parametreleri elde edildiği anlaşılmaktadır. Tablo incelendiğinde sistemin anlamlı sonuçlar sunduğu söylenebilir.

Bu motorların optimizasyonu, popülasyon büyüklüğü 50 ve maksimum iterasyon sayısı 100 olarak belirlenerek gerçekleştirilmiştir. Motor 1'de hedef verim % 96.40'dır. Optimizasyon süreci başında hesaplanan verim değeri % 94.33 iken, optimizasyon sonunda bu değer % 94.83'e çıkmış ve 2.85 değerinde bir fitness sonucu elde edilmiştir.


Motor 2'de hedef verim % 95.50'dir. Optimizasyon başlangıcında hesaplanan verim % 93.94 iken, optimizasyon sonunda bu değer % 94.54'e yükselmiş ve 0.92 büyüklüğünde bir fitness değeri elde edilmiştir. Motor 3 için verim hedefi % 95'tir. Optimizasyon başlangıcında hesaplanan verim % 94.55 iken, optimizasyon sonunda bu değer % 94.85 çıkmış ve 0.022840 büyüklüğünde bir uygunluk değeri elde edilmiştir. 4. motorda verim hedefi % 93.6'dır. Bu motorda başlangıçta % 91.20'lik bir verim değerine

Tablo 4.14 Optimizasyon aşaması örnek motor çıktı değerleri


Parametre	Motor 1	Motor 2	Motor 3	Motor 4	Motor 5
D_{os}	618.2482	605.2230	448.0055	288.0001	180.3669
D	337.2602	359.4896	247.8902	150.2677	85.8345
g	1.0604	0.8841	0.9641	0.7807	0.3717
D_r	335.1393	357.7214	245.9619	148.7063	85.0911
D_i	185.1821	228.2280	92.2292	38.6482	20.9646
L	292.7193	299.1212	316.5672	128.8257	87.4442
b_0	3.0038	2.6274	3.8294	3.1057	2.0383
b_1	15.0192	13.1369	19.1472	15.5285	10.1913
b_2	22.8705	19.7958	24.2777	24.1376	11.6973
d_{s0}	1.5327	1.3314	1.9265	0.5244	0.2880
d_{s1}	8.8801	7.7533	11.9476	3.1936	1.6010
d_s	105.3018	91.8552	46.3896	26.1723	18.6652
t_s	3.7301	3.3415	4.9068	5.1148	5.4490
t_{s1}	6.9060	4.6986	7.8728	3.3576	10.4584
d_{cs}	24.7794	21.9267	39.7940	38.9760	26.7120
d_0	2.5983	1.5661	5.0871	1.6565	3.6337
d_2	12.9915	7.8304	25.4357	8.2824	18.1685
d_1	12.9730	6.7100	13.6866	7.3333	11.6495
h_{r01}	0.3842	0.4217	0.1685	0.1027	0.0535
h_{r0}	3.8418	4.2167	1.6854	1.0268	0.5346
h_{r1}	7.6820	6.4716	4.4794	2.1295	0.9222
h_r	39.3128	33.2140	31.8318	13.6294	4.4362
w_{tr1}	12.8103	5.0556	1.7486	5.2734	1.6906
w_{tr}	6.3285	3.6311	6.0902	3.6276	6.0655
d_{cr}	24.1421	20.8444	38.8697	38.2433	26.1703
d_e	52.1169	44.1180	40.1277	17.4478	5.9531
d_{eh}	18.5182	22.8228	9.2229	3.8648	2.0965
l_e	33.6219	38.7874	22.4675	9.0919	6.4772

Not: Tüm değerler milimetre (mm) cinsindedir.


sahip olduğu, optimizasyon sonunda ise bu değer 92.14'e çıktığı görülmektedir. Son motorda ise hedef verimlik değeri % 88.50'dir. Optimizasyon süreci % 87.01'lik bir verimle başlamış ve bu değer % 88.50'ye yükseltilerek, fitness değeri 0'a düşürülmüştür. Bu değişimler 4.19'de görülebilir. Şekil incelendiğinde verimdeki artış ve kayıplardaki azalış miktarı görülebilir. Tüm örnek motorlarda, normalde toplam kayıplara oranla yüzdesi düşük olsa da farkedilir azalmanın demir kayıplarında olduğu ve verim değerindeki artışı bu kayıplardaki düşüşün tetiklediği söylenilebilir. Bununla birlikte, gerçekleştirilen optimizasyon süreçlerinin etkinliğinin tam olarak değerlendirilebilmesi için daha fazla parametre ve etmenin dikkate alınması gerekmektedir.




a) 400 kW




b) 250 kW



c) 150 kW





d) 22 kW





e) 4 kW



Şekil 4.19 Optimizasyon süreci kayıp ve verim değişimleri





a) 400 kW





b) 250 kW



c) 150 kW



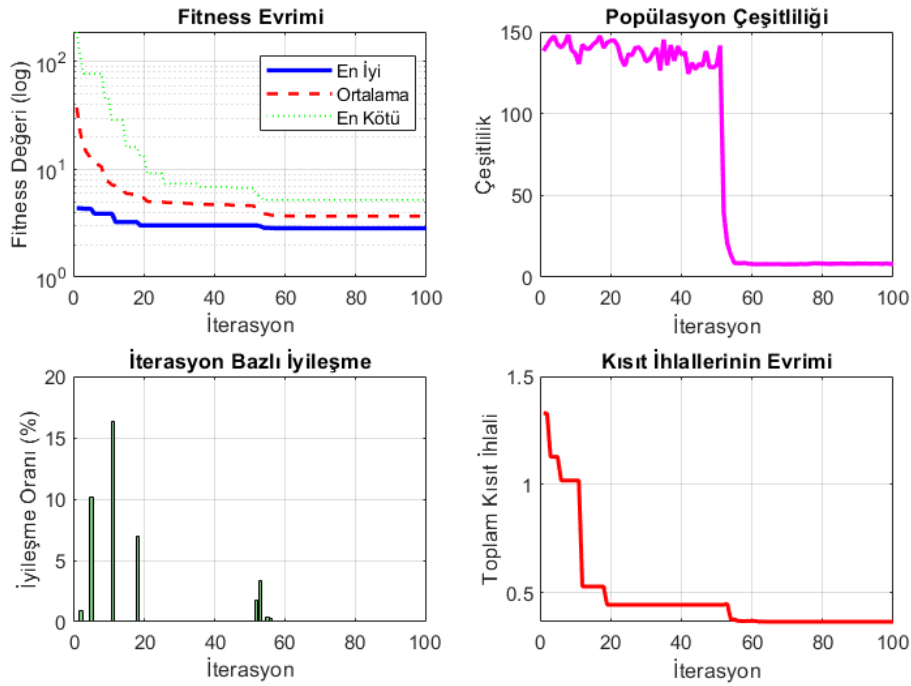
d) 22 kW



e) 4 kW

Şekil 4.20 Optimizasyon süreci parametre değişimleri ve duyarlılıkları

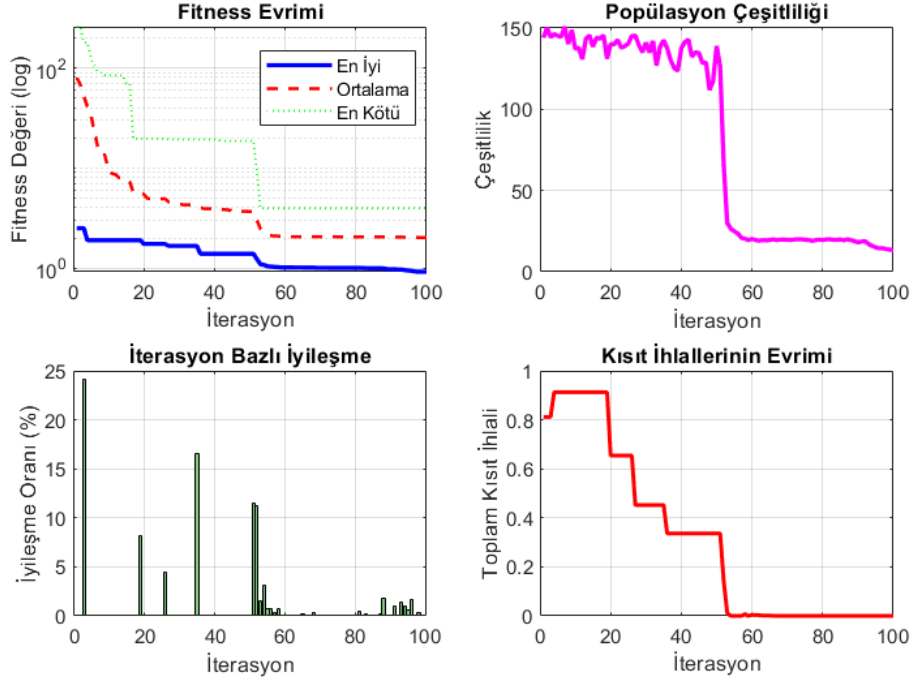
Hangi parametrelerin sürece daha fazla etki ettiğinin belirlenmesi, optimizasyon sürecinin anlaşılmasına ve gerekiyorsa iyileştirilmesine katkı sağlayabilir. Bu doğrultuda, optimizasyon süresince parametrelerin değişimi ve optimizasyon sürecine ilişkin duyarlılık analizleri Şekil 4.20’de sunulmuştur. Bu parametreler dikkate alındığında, birbirbirinden uzak güç gruplarına bakıldığı halde fitness hedefine en çok etki eden parametrelerin benzer olduğu söylenebilir. Motorlar genelinde stator ve rotor oluk alt genişliklerinden en az biri fitness değerinde yüksek düzeyde etkili olmuştur.



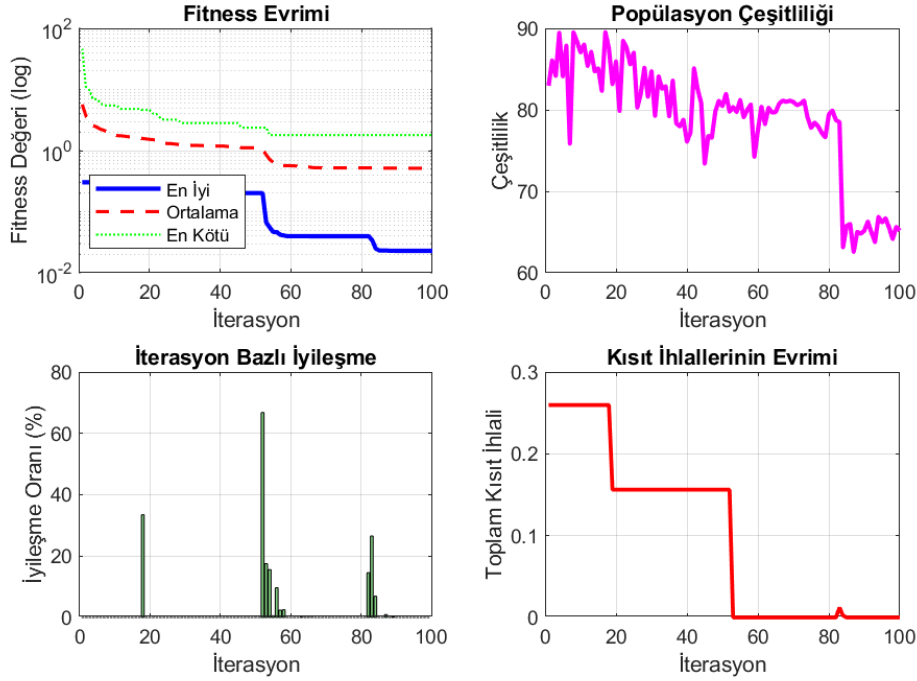
Şekil 4.21 Örnek-1 optimizasyon süreci (400 kW)

Rotor iç çapı değerinin etkisi, oluk parametreleri kadar etkin olmasa da, her motorun optimizasyon sürecinde belirginleşmektedir. Güç seviyesi düştükçe rotor boyunduruk derinliğinin uygunluk düzeyinin üzerindeki etkisinin arttığı görülmüştür. Farklı güç seviyelerinde, fitness hedefi üzerine etki eden parametre sayısı da farklılıklar göstermektedir. Bu durum göz önünde bulundurularak, optimizasyonda güç seviyelerine göre yalnızca belirli büyüklüklerin değiştirilmesini temel alan opsiyonların değerlendirilebileceği söylenebilir. Ancak temel olarak parametrelere ilişkin gerçekleştirilen bu analiz, mevcut algoritmanın parametrelerin değişimini sağlıklı şekilde yönlendirebildiğini göstermektedir.

Algoritmanın çözüm süreçleri sırasıyla Şekil 4.21, 4.22, 4.23, 4.24 ve 4.25’te sunulmuştur. Bu süreçler incelendiğinde, her güç seviyesinde algoritmanın başarısı, fitness değerlerinde anlamlı bir düşüş ile kendini göstermektedir.

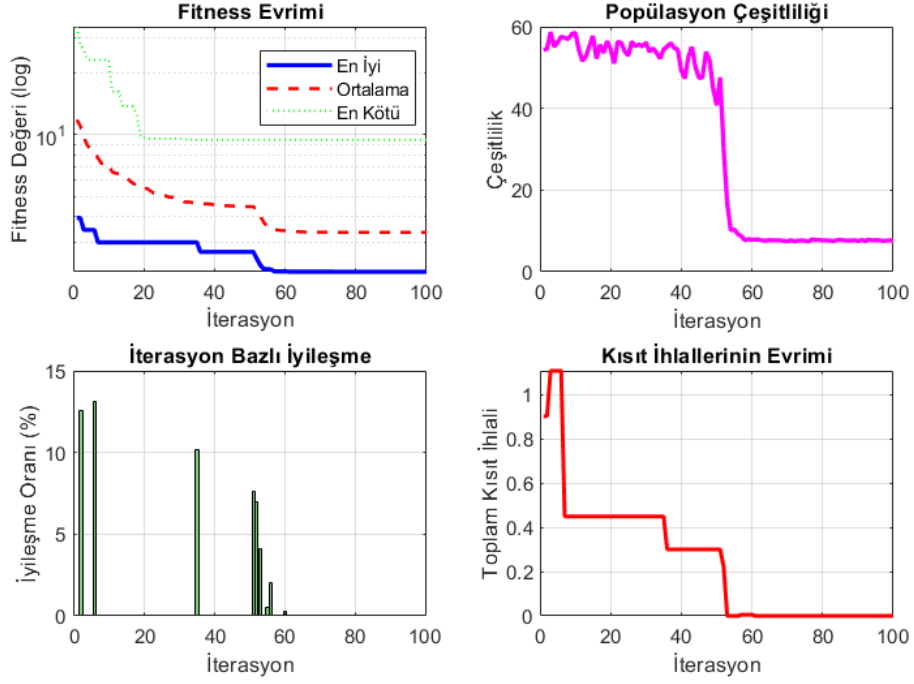


Şekil 4.22 Örnek-2 optimizasyon süreci (250 kW)

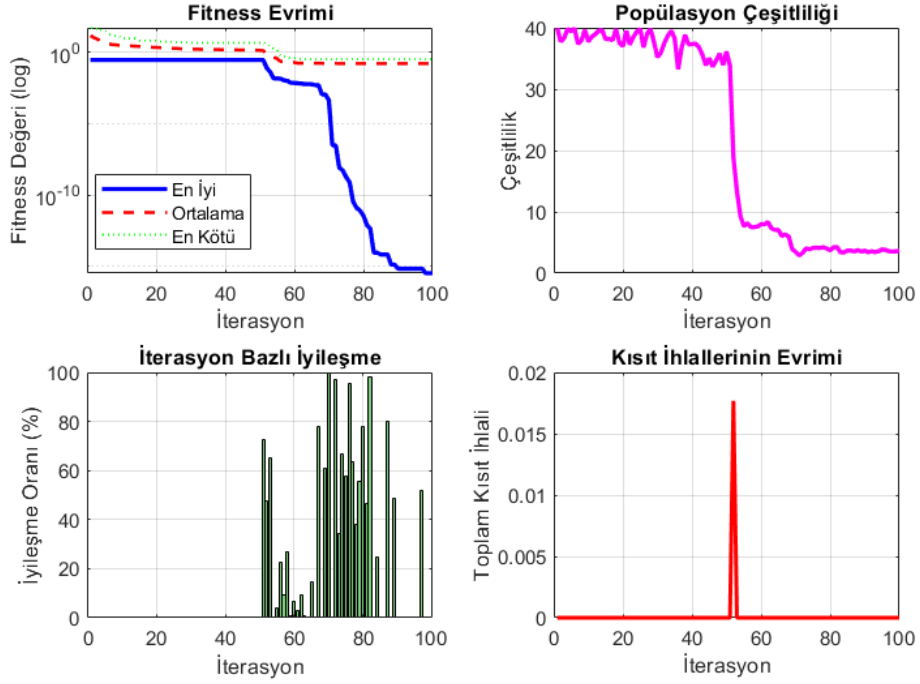


Şekil 4.23 Örnek-3 optimizasyon süreci (150 kW)

Tüm güç seviyelerinde var olan kısıt ihlalleri aşılarak, sağlıklı sonuçlar elde edilmiştir. İyileştirme yaşanan iterasyon sıralarına baktığımızda, güç seviyesine göre süreçlerin dinamikleri arasında farklar olabileceği söylenebilir. Ancak neredeyse tüm motor gruplarında kısıtlar 50. iterasyon civarında




Şekil 4.24 Örnek-4 optimizasyon süreci (22 kW)




Şekil 4.25 Örnek-5 optimizasyon süreci (4 kW)

aşılmış, çeşitlilikte düşüş yaşanmıştır. Bu durum iterasyon sayısının yeterli olduğunu ve sürecin gereksiz uzamaması açısından olumlu etki yarattığını göstermektedir.




a) Örnek-1 motor yapısı




b) Örnek-1 motor verim ve güç değerleri

Şekil 4.26 Örnek-1 motor geometrisi (Motor 1: 400 kW)



a) Örnek-2 motor yapısı



b) Örnek-2 motor verim ve güç değerleri

Şekil 4.27 Örnek-2 motor geometrisi (Motor 2: 250 kW)

Sonuç olarak, algoritmanın hemen hemen her güç güç seviyesinde kararlı ve başarılı bir optimizasyon eğilimi sergilediği gözlemlenmiştir. Yüksek güçlerde optimizasyonda çözüm çeşitliliği açısından daha zengin bir yapı ortaya konduğu söylenebilir. Bu durum, optimizasyon süreçlerinin farklı güç seviyelerinde davranışsal olarak farklılık gösterebileceğini, ancak her durumda uygun çözümlere ulaşılabileceğini ortaya koymaktadır.

Optimizasyon sonuçları ile oluşturulabilecek yapıların sağlıklı olup olmayacağını görmek için, Motor 1 ve Motor 2 örnek olarak seçilerek, elde edilen optimal parametreler ile, motor geometrileri oluşturulmuştur. Motorlar için oluşturulan yapı ve bu yapı karşılığında elde edilebilecek güç ve verim değerleri sırasıyla 4.26 ve 4.27’de gösterilmiştir. Elde edilen verim ve güç değerlerin, motor anma değerlerine yaklaşık olduğu ve verilerin kullanılabilir olduğu anlaşılmıştır.

5 SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında, asenkron makine tasarımının karmaşık süreçlerini basitleştiren özgün bir yaklaşım geliştirilmiştir. Geleneksel yöntemlerin aksine, tasarımcıların zahmetli hesaplamalar yapmasına gerek kalmadan optimal makine parametrelerine ulaşmasını sağlayan hibrit bir metodoloji sunulmuştur.

Çalışmanın temelini oluşturan iki aşamalı yaklaşımda, öncelikle Yapay Sinir Ağları kullanılarak tahmin modelleri oluşturulmuş, ardından bu modeller ile elde edilen tahminler, Yılan Optimizasyonu Algoritması ile iyileştirilmiştir. Tahmin aşamasında farklı sinir ağı mimarileri kapsamlı şekilde test edilmiş ve her parametre grubu için en uygun yapılar belirlenmiştir.

Elektriksel parametrelerin tahmininde MLP, RBF, GRNN ve RNN yapıları değerlendirilmiş, sonuç olarak MLP mimarisinin diğerlerine kıyasla daha tutarlı ve güvenilir tahminler ürettiği gözlenmiştir. Bu model sayesinde, makinenin elektriksel eşdeğer devre parametreleri başarıyla tahmin edilebilmiştir.

Mekanik boyutların belirlenmesinde ise MLP, RNN ve LSTM yapıları değerlendirilmiş ve RNN mimarisi performans açısından öne çıkmıştır. RNN, 0.0023 gibi oldukça düşük bir ortalama mutlak hata değeri yakalamış ve tüm parametrelerde 0.8576'nın üzerinde korelasyon katsayıları elde etmiştir. Bu başarı, modelin makine geometrisinin karmaşık ilişkilerini etkili biçimde öğrenebildiğini göstermektedir. Ayrıca, hesaplama süresi açısından da RNN'nin dengeli bir performans sergilediği belirlenmiştir.

Geliştirilen tahmin yaklaşımının genelleştirilebilirliğini değerlendirmek amacıyla, tahmin metodolojisi kalıcı mıknatıslı senkron makinenin (PMSM) elektriksel eşdeğer devre parametrelerinin tahmini için uyarlanmıştır. Bu kapsamda oluşturulan ANN tabanlı topluluk (ensemble) tahmin modeli, PMSM parametrelerinin belirlenmesinde başarılı sonuçlar vermiştir. Bu durum, tez kapsamında uygulanan yöntemin yalnızca asenkron makinelerle

sınırlı kalmayıp, farklı elektrik makinesi tiplerine de uygulanabilecek esnek bir yapıya sahip olduğunu ortaya koymaktadır.

Optimizasyon sürecinde Yılan Optimizasyonunun makine tasarımına özgü uyarlaması gerçekleştirilmiştir. Tahmin edilen değerlerden hareketle başlatılan optimizasyon, eklenen adaptif sınırlama stratejisi sayesinde hem hızlı yakınsama sağlamış hem de mühendislik açısından uygulanabilir çözümler üretmiştir. Test edilen örneklerde, başlangıç verim değerlerinde kayda değer iyileşmeler elde edilmiş ve hedeflenen performans kriterlerine yakın sonuçlara ulaşılmıştır.

Geliştirilen sistemin temel amacı, makine tasarım sürecindeki belirsizlikleri azaltması ve tasarımcılara güvenilir bir başlangıç noktası sunulmasıdır. Özellikle üretici verilerine erişimin kısıtlı olduğu durumlarda, bu yaklaşım bir alternatif oluşturmaktadır. Bunun yanında, tahmin ve optimizasyonun entegre edilmesi, salt tahmine dayalı yöntemlerin üretebileceği uygulanamaz çözümlerin önüne geçmektedir.

Sonuç olarak, bu tez kapsamında geliştirilen hibrit metodoloji, elektrik makinesi tasarımı için, makine öğrenimi tabanlı güçlü bir çerçeve sunmaktadır. Gelecek çalışmalarda, veri artırma (data augmentation) ve transfer öğrenme gibi yaklaşımlar kullanılarak, özellikle az temsil edilen güç aralıkları veya özgün makine tasarımları için modelin genelleştirilebilirliği artırılabilir; ayrıca ilave veri toplama ihtiyacı azaltılabilir. Bu yöntem, farklı oluk yapılarına odaklanılarak uygulanabilir ve daha verimli makine yapılarının elde edilip edilemeyeceği araştırılabilir. Önerilen teknikle gerçek zamanlı sistemler oluşturularak, üretim ve bakım hata teşhisi süreçlerinde anlık geri bildirim sağlanarak, ele alınan makine performansı artırılabilir. Bu yaklaşım, farklı endüstriyel gereksinimleri karşılamak üzere, daha fazla makine tipine uyarlanabilir ve böylece makine tasarım süreçlerinin daha da iyileştirilmesine katkı sağlanabilir.

- [1] T. Orosz et al., “Robust design optimization and emerging technologies for electrical machines: Challenges and open problems,” *Applied Sciences*, vol. 10, no. 19, p. 6653, 2020.
- [2] G. Buticchi et al., “Challenges of the optimization of a high-speed induction machine for naval applications,” *Energies*, vol. 12, no. 12, p. 2431, 2019.
- [3] I. More, “Optimization of electric machine designs—part i,” *IEEE Transactions on Industrial Electronics*, vol. 64, no. 12, p. 9717, 2017.
- [4] A. Cavagnino, G. Bramerdorfer, J. A. Tapia, “Optimization of electric machine designs—part ii,” *IEEE Transactions on Industrial Electronics*, vol. 65, no. 2, pp. 1700–1703, 2017.
- [5] M. F. B. Omar, E. B. Sulaiman, I. A. Soomro, M. Z. B. Ahmad, R. Aziz, “Design optimization methods for electrical machines: A review,” *Journal of Electrical Engineering & Technology*, vol. 18, no. 4, pp. 2783–2800, 2023.
- [6] G. Lei, J. Zhu, Y. Guo, C. Liu, B. Ma, “A review of design optimization methods for electrical machines,” *Energies*, vol. 10, no. 12, p. 1962, 2017.
- [7] G. Bramerdorfer, J. A. Tapia, J. J. Pyrhönen, A. Cavagnino, “Modern electrical machine design optimization: Techniques, trends, and best practices,” *IEEE Transactions on Industrial Electronics*, vol. 65, no. 10, pp. 7672–7684, 2018.
- [8] Z. Fazlipour, R. Kianinezhad, M. Razaz, “Genetic algorithm based design optimization of a six phase induction motor,” *Journal of Electrical Engineering and Technology*, vol. 10, no. 3, pp. 1007–1014, 2015.
- [9] M. H. Ravanji, Z. Nasiri-Gheidari, “Design optimization of a ladder secondary single-sided linear induction motor for improved performance,” *IEEE Transactions on Energy Conversion*, vol. 30, no. 4, pp. 1595–1603, 2015.
- [10] S. Mallik et al., “Efficiency and cost optimized design of an induction motor using genetic algorithm,” *IEEE Transactions on Industrial Electronics*, vol. 64, no. 12, pp. 9854–9863, 2017.
- [11] S. Ranjan, S. K. Mishra, “Multi-objective design optimization of three-phase induction motor using nsga-ii algorithm,” *Computational Intelligence in Data Mining-Volume 2: Proceedings of the International Conference on CIDM, 20-21 December 2014*, New Delhi: Springer India, Dec. 2014, pp. 1–8.

- [12] L. A. Pereira, S. Haffner, G. Nicol, T. F. Dias, “Multiobjective optimization of five-phase induction machines based on nsga-ii,” *IEEE Transactions on Industrial Electronics*, vol. 64, no. 12, pp. 9844–9853, 2017.
- [13] L. Wogi, A. Thelkar, T. S. Tahiro, T. Ayana, S. Urooj, S. Larguech, “Particle swarm optimization based optimal design of six-phase induction motor for electric propulsion of submarines,” *Energies*, vol. 15, no. 9, p. 2994, 2022.
- [14] C. H. Lin, C. C. Hwang, “Multi-objective optimization design using amended particle swarm optimization and taguchi method for a six-phase copper rotor induction motor,” *Engineering Optimization*, vol. 49, no. 4, pp. 693–708, 2017.
- [15] P. P. Das, S. N. Mahato, “Artificial bee colony based design optimization of a six-phase induction motor,” *2016 2nd International Conference on Control, Instrumentation, Energy & Communication (CIEC)*, IEEE, Jan. 2016, pp. 526–530.
- [16] N. Wang, C. Li, W. Li, M. Xiong, “Material-structure integration design optimization for energy efficiency performance improvement of an induction motor,” *Journal of Electrical Engineering & Technology*, pp. 1–23, 2025.
- [17] H. Apaydin, N. F. Oyman Serteller, Y. Oğuz, “Induction motor geometric parameter optimization using a metaheuristic optimization method for high-efficiency motor design,” *Energies*, vol. 18, no. 3, 2025, issn: 1996-1073.
- [18] A. A. Pourmoosa, M. Mirsalim, “Design optimization, prototyping, and performance evaluation of a low-speed linear induction motor with toroidal winding,” *IEEE Transactions on Energy Conversion*, vol. 30, no. 4, pp. 1546–1555, 2015.
- [19] C. Li, M. Huang, W. Li, N. Wang, J. Fu, “Optimization of an induction motor for loss reduction considering manufacturing tolerances,” *Structural and Multidisciplinary Optimization*, vol. 65, no. 7, p. 187, 2022.
- [20] F. Mahmouditabar, N. J. Baker, “Design optimization of induction motors with different stator slot rotor bar combinations considering drive cycle,” *Energies*, vol. 17, no. 1, p. 154, 2023.
- [21] P. P. Selvam, R. Narayanan, “Random restart local search optimization technique for sustainable energy-generating induction machine,” *Computers & Electrical Engineering*, vol. 73, pp. 268–278, 2019.
- [22] Q. Lu, L. Li, J. Zhan, X. Huang, J. Cai, “Design optimization and performance investigation of novel linear induction motors with two kinds of secondaries,” *IEEE Transactions on Industry Applications*, vol. 55, no. 6, pp. 5830–5842, 2019.
- [23] P. P. Selvam, R. Narayanan, “Machine learning perspective gene optimization for efficient induction machine design,” *Journal of Electrical Engineering and Technology*, vol. 13, no. 3, pp. 1202–1211, 2018.

- [24] M. Nell, A. Kubin, K. Hameyer, “Multi-stage optimization of induction machines using methods for model and parameter selection,” *Energies*, vol. 14, no. 17, p. 5537, 2021.
- [25] M. Karpe, S. Ghosh, N. Shindhe, R. Birajdar, D. Bhawe, “Optimization of single-phase induction motor,” *2019 IEEE Conference on Energy Conversion (CENCON)*, IEEE, Oct. 2019, pp. 115–120.
- [26] P. C. Krause, O. Wasynczuk, S. D. Sudhoff, S. D. Pekarek, *Analysis of electric machinery and drive systems*. New Jersey: Wiley-IEEE Press, 2013.
- [27] T. A. Lipo, *Introduction to AC Machine Design*. John Wiley & Sons, 2017.
- [28] G. Joksimović, “Dynamic model of cage induction motor with number of rotor bars as parameter,” *The Journal of Engineering*, vol. 2017, no. 6, pp. 205–211, 2017.
- [29] J. Pyrhonen, T. Jokinen, V. Hrabovcova, *Design of Rotating Electrical Machines*. John Wiley & Sons, 2013.
- [30] A. I. Galushkin, *Neural Networks Theory*. Cham, Switzerland: Springer, 2007.
- [31] C. C. Aggarwal, *Neural Networks and Deep Learning*. Cham, Switzerland: Springer, 2018.
- [32] M. Islam, G. Chen, S. Jin, “An overview of neural network,” *American Journal of Neural Networks and Applications*, vol. 5, no. 1, pp. 7–11, 2019.
- [33] A. Nielsen, *Neural networks and deep learning*, 2015. url : <http://neuralnetworksanddeeplearning.com>.
- [34] S. Shalev-Shwartz, S. Ben-David, *Understanding Machine Learning: From Theory to Algorithms*. Cambridge University Press, 2014.
- [35] S. Haykin, *Neural networks and learning machines*. Hoboken: Pearson Prentice Hall, 2009.
- [36] S. K. Das, S. P. Das, N. Dey, A. E. Hassanien, Eds., *Machine Learning Algorithms for Industrial Applications*. Berlin: Springer, 2021.
- [37] *Generalized regression neural networks - mathworks australia*, Accessed: 2023-06-10, 2023. url : <https://au.mathworks.com/help/deeplearning/ug/generalizedregression-neural-networks.html>.
- [38] F. M. Salem, *Recurrent Neural Networks: From Simple to Gated Architectures*. Cham, Switzerland: Springer, 2022.
- [39] M. Boden, “A guide to recurrent neural networks and backpropagation,” *The Dallas Project*, vol. 2, no. 2, pp. 1–10, 2002.
- [40] B. Ghogh, A. Ghodsi, “Recurrent neural networks and long short-term memory networks: Tutorial and survey,” *arXiv preprint arXiv:2304.11461*, 2023.
- [41] M. V. Wüthrich, M. Merz, *Statistical foundations of actuarial learning and its applications*. Springer Nature, 2023, p. 605.

- [42] *Long short-term memory neural networks*, Accessed: Nov. 2024, 2024. url:<https://www.mathworks.com/help/deeplearning/ug/long-short-term-memory-networks.html>.
- [43] İ. Topaloğlu, O. Gürdal, “Elektromanyetik tasarım programı kullanılarak elektrik makinelerinin tasarımında boyut optimizasyonu için geliştirilmiş ikinci dereceden hassasiyet analizi temelli nümerik bir yaklaşım,” *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, vol. 25, no. 2, 2010.
- [44] F. A. Hashim, A. G. Hussien, “Snake optimizer: A novel meta-heuristic optimization algorithm,” *Knowledge-Based Systems*, vol. 242, p. 108320, 2022.
- [45] M. Z. Naser, A. H. Alavi, “Error metrics and performance fitness indicators for artificial intelligence and machine learning in engineering and sciences,” *Architecture, Structures and Construction*, vol. 3, no. 4, pp. 499–517, 2023.
- [46] M. Razbin et al., “Application of soft computing techniques in the optimization of 3d-printed piezoresistive sensors,” *Sensors and Actuators A: Physical*, p. 116277, 2025.
- [47] F. Dikbaş, “A new two-dimensional rank correlation coefficient,” *Water Resources Management*, vol. 32, no. 5, pp. 1539–1553, 2018.
- [48] H. Hofmann, H. Wickham, K. Kafadar, “Letter-value plots: Boxplots for large data,” *Journal of Computational and Graphical Statistics*, vol. 26, no. 3, pp. 469–477, 2017.
- [49] D. Bhowmick, M. Manna, S. K. Chowdhury, “Estimation of equivalent circuit parameters of transformer and induction motor from load data,” *IEEE Transactions on Industry Applications*, vol. 54, no. 3, pp. 2784–2791, 2018. doi:[10.1109/TIA.2018.2790378](https://doi.org/10.1109/TIA.2018.2790378).
- [50] L. Wang, Y. Liu, “Application of simulated annealing particle swarm optimization based on correlation in parameter identification of induction motor,” *Mathematical Problems in Engineering*, vol. 2018, 2018. doi:<https://doi.org/10.1155/2018/1869232>.
- [51] H. Rezk, A. A. Elghany, M. Al-Dhaifallah, A. H. M. El Sayed, M. N. Ibrahim, “Numerical estimation and experimental verification of optimal parameter identification based on modern optimization of a three phase induction motor,” *Mathematics*, vol. 7, no. 12, p. 1135, 2019. doi:<https://doi.org/10.3390/math7121135>.
- [52] M. I. Abdelwanis, R. A. Sehiemy, M. A. Hamida, “Hybrid optimization algorithm for parameter estimation of poly-phase induction motors with experimental verification,” *Energy and AI*, vol. 5, p. 100083, 2021. doi:<https://doi.org/10.1016/j.egyai.2021.100083>.
- [53] J. Vukašinić, S. Štatkić, M. Milovanović, N. Arsić, B. Perović, “Combined method for the cage induction motor parameters estimation using two-stage pso algorithm,” *Electr Eng*, pp. 1–12, 2023. doi:<https://doi.org/10.1007/s00202-023-01849-9>.

- [54] J. J. Guedes, M. F. Castoldi, A. Goedel, C. M. Agulhari, D. S. Sanches, "Parameters estimation of three-phase induction motors using differential evolution," *Electric Power Systems Research*, vol. 154, pp. 204–212, 2018. doi:<https://doi.org/10.1016/j.epsr.2017.08.033>.
- [55] M. Aminu, "A parameter estimation algorithm for induction machines using artificial bee colony (abc) optimization," *Nigerian Journal of Technology*, vol. 38, no. 1, pp. 193–201, 2019. doi:10.4314/njt.v38i1.24.
- [56] A. Accetta, F. Alonge, M. Cirrincione, F. D'Ippolito, M. Pucci, A. Sferlazza, "Ga-based off-line parameter estimation of the induction motor model including magnetic saturation and iron losses," *IEEE Open Journal of Industry Applications*, vol. 1, pp. 135–147, 2020. doi:10.1109/OJIA.2020.3024567.
- [57] K. Postoyankova, V. Polishchuk, A. Shuvalova, *Research of a genetic algorithm for identification of induction motor parameters*, Paper presented at International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM), 2021.
- [58] M. Calasan, M. Micev, Z. M. Ali, A. F. Zobaa, S. H. Abdel Aleem, "Parameter estimation of induction machine single-cage and double-cage models using a hybrid simulated annealing–evaporation rate water cycle algorithm," *Mathematics*, vol. 8, no. 6, p. 1024, 2020. doi:<https://doi.org/10.3390/math8061024>.
- [59] M. M. Elkholy, E. A. El-Hay, A. A. El-Fergany, "Synergy of electrostatic discharge optimizer and experimental verification for parameters estimation of three phase induction motors," *Engineering Science and Technology, an International Journal*, 31, vol. 31, no. 101067, 2022. doi:<https://doi.org/10.1016/j.jestch.2021.09.013>.
- [60] M. S. Ershov, A. N. Komkov, O. M. Gamidov, "Determination of the equivalent-circuit parameters and the main characteristics of squirrel-cage low-power induction motors based on analysis of current and voltage signals," *Russian Electrical Engineering*, vol. 93, no. 2, pp. 123–128, 2022. doi:<https://doi.org/10.3103/S1068371222020055>.
- [61] V. A. Pavlukov, S. N. Tkachenko, *The hybrid method for parameters estimation of a single-loop equivalent circuit of induction motors*, Paper presented at 5th International Youth Conference on Radio Electronics, Electrical and Power Engineering (REEPE), 2023.
- [62] G. F. V. Amaral, J. M. R. Baccarini, F. C. R. Coelho, L. M. Rabelo, "A high precision method for induction machine parameters estimation from manufacturer data," *IEEE Transactions on Energy Conversion*, vol. 36, no. 2, pp. 1226–1233, 2020. doi:10.1109/TEC.2020.3032320.
- [63] D. K. Chaturvedi, M. P. Singh, "Online equivalent circuit parameter estimation of three-phase induction motor using ann," *J. Inst. Eng. India Ser. B*, vol. 100, pp. 343–347, 2019. doi:<https://doi.org/10.1007/s40031-019-00387-y>.

- [64] M. A. Jirdehi, A. Rezaei, "Parameters estimation of squirrel-cage induction motors using ann and anfis," *Alexandria Engineering Journal*, vol. 55, no. 1, pp. 357–368, 2016. doi:<https://doi.org/10.1016/j.aej.2016.01.026>.
- [65] O. Çetin, A. Dalcalı, F. Temurtaş, "A comparative study on parameters estimation of squirrel cage induction motors using neural networks with unmemorized training," *Engineering Science and Technology, an International Journal*, vol. 23, no. 5, pp. 1126–1133, 2020. doi:<https://doi.org/10.1016/j.jestch.2020.03.011>.
- [66] L. Romeo, J. Loncarski, M. Paolanti, G. Bocchini, A. Mancini, E. Frontoni, "Machine learning-based design support system for the prediction of heterogeneous machine parameters in industry 4.0," *Expert Systems with Applications*, vol. 140, p. 112 869, 2020.
- [67] S. T. Nguyen, S. Goetz, T. M. Pham, A. Hoang, T. V. Pham, *A detailed procedure of squirrel-cage three-phase induction motor parameter estimation using polynomial regression*, Paper presented at International Conference on Engineering Research and Applications, 2022.
- [68] A. P. Desai, A. Nanoty, "A novel practical approach to identify equivalent circuit parameters of six-phase asymmetrical induction motor," *Journal of The Institution of Engineers (India): Series B*, vol. 104, no. 1, pp. 9–21, 2023. doi:<https://doi.org/10.1016/j.eswa.2019.112869>.
- [69] M. A. Al-Ahmar, "Estimation of induction motor model parameters-case study," *ERJ. Engineering Research Journal*, vol. 42, no. 3, pp. 177–182, 2019.
- [70] G. Trisha Gupta, S. Shiva Kumar, "Review of the parameter estimation and transient analysis of three-phase induction motor," in *Advances in Smart Grid Automation and Industry 4.0*, D. Reddy M.J.B.and Mohanta, D. Kumar D.and Ghosh, Eds., Singapore: Springer, 2021, pp. 223–232.
- [71] U. S. Shanthamallu, A. Spanias, *Machine and deep learning algorithms and applications*. Switzerland: Springer, 2022.
- [72] *Teco Technical Catalogue*, [Accessed 10-Jan-2023]. url:https://www.teco-group.eu/Resources/Electric-Motors/Catalog-Manuals/TECO_Motor_Katalog_UK_web-2014.
- [73] *Weg W40 Open Induction Motors Technical Catalogue*, [Accessed 10-Jan-2023]. url : <https://static.weg.net/medias/downloadcenter/h29/h8b/WEG-w40-european-market-50049923-brochure-english-web.pdf>.
- [74] *Imfinity 3-phase Induction Motors*, [Accessed 10-Jan-2023]. url:https://www.leroy-somer.com/documentation_pdf/5147_en.pdf.
- [75] *Crompton Standard Motor*, [Accessed 10-Jan-2023]. url:<https://www.makhariaelectricals.net/CG-Crompton-Standard-Motor.html>.

- [76] *Havells Energy Efficiency 3-phase Lv Induction Motors*, [Accessed 10-Jan-2023]. url : <https://havells.com/HavellsProductImages/HavellsIndia/Content/dam/havells/brouchers/dealer/brochure/Motor%5C%20Catalogue%5C%202018.pdf>.
- [77] *Bharat Bijlee Ac Motors*, [Accessed 10-Jan-2023]. url : <http://www.kbengineering.co.in/bharat-bijlee-motor.php>.
- [78] *Kirloskar Low Voltage 3-phase Induction Motors*, [Accessed 10-Jan-2023]. url : <https://www.kirloskaroilengines.com/documents/541738/771479/IETC+AC+MOTOR+Catalogue+%5C%282%5C%29.pdf/8a67e60c-1516-c8ba-4410-3b015542e14f?t=1650967970549>.
- [79] A. M. Oteafy, “Fast and comprehensive online parameter identification of switched reluctance machines,” *IEEE Access*, vol. 9, pp. 46 985–46 996, 2021.
- [80] C. Yang, B. Song, Y. Xie, X. Tang, “Online parallel estimation of mechanical parameters for pmsm drives via a network of interconnected extended sliding-mode observers,” *IEEE Transactions on Power Electronics*, vol. 36, no. 10, pp. 11 818–11 834, Oct. 2021.
- [81] S. Yamamoto, H. Hirahara, B. A. S. Gunasekara, M. Motosugi, “Stator-flux-linkage-calculation-based torque estimation of induction motors considering iron, mechanical, and stray load losses,” *IEEE Transactions on Industry Applications*, vol. 57, no. 6, pp. 5916–5926, Dec. 2021.
- [82] R. Prasad et al., “Online estimation of the mechanical parameters of an induction machine using speed loop characteristics and recursive least square technique,” *Proc. 2022 25th Int. Conf. Electrical Machines and Systems (ICEMS)*, Nov. 2022, pp. 1–5.
- [83] I. T. Ardekani, R. Nicholson, “A bayesian approach to online estimation of airgap spatial variation in induction machines with static eccentricity,” *Applied Mathematical Modelling*, vol. 128, pp. 571–587, 2024.
- [84] L. Yang, S. Zhao, G. Feng, “Mechanical and electrical parameter estimation for pmsms considering sensor measurement offset,” *Proc. 2023 China Automation Congress (CAC)*, Nov. 2023, pp. 3651–3656.
- [85] M. X. Bui, R. Dutta, F. Rahman, “Application of deep learning in parameter estimation of permanent magnet synchronous machines,” *IEEE Access*, vol. 12, pp. 40 710–40 721, 2024.
- [86] M. O. H. Abd El-Wanis, R. El-Sehiemy, M. A. Hamida, “Parameter estimation of permanent magnet synchronous machines using particle swarm optimization algorithm,” *Revue Roumaine des Sciences Techniques—Serie Electrotechnique et Energetique*, vol. 67, no. 4, pp. 377–382, 2022.
- [87] J. C. Travieso-Torres et al., “Self-commissioning parameter estimation algorithm for loaded induction motors,” *IEEE Transactions on Industrial Electronics*, 2024.

- [88] M. Tilahun, G. F. Olson, L. Peretti, M. Mamo, “Validation of fem-based parameter estimation for variable phase-pole induction machines,” *IEEE Transactions on Energy Conversion*, 2023.
- [89] S. Gdaim, A. Mtibaa, M. F. Mimouni, “Artificial neural network-based dtc of an induction machine with experimental implementation on fpga,” *Engineering Applications of Artificial Intelligence*, vol. 121, p. 105 972, 2023.
- [90] A. Abdulkareem, T. Anyim, O. Popoola, J. Abubakar, A. Ayoade, “Prediction of induction motor faults using machine learning,” *Heliyon*, vol. 11, no. 1, 2025.
- [91] A. K. Sawhney, *A Course in Electrical Machine Design*, 1st. Dhanpat Rai and Sons, 1984.
- [92] P. Cochran, *Polyphase Induction Motors: Analysis, Design, and Application*. CRC Press, 1989.
- [93] R. K. Agarwal, *Principles of Electrical Machine Design*, 5th. S.K. Kataria & Sons, 2014.
- [94] K. M. Vishnu Murthy, *Computer-Aided Design of Electrical Machines*. BS Publications, 2008.
- [95] O. Gürdal, *Elektrik Makinalarının Tasarımı*. Bursa Orhangazi Üniversitesi Yayınları, 2015.
- [96] T. Boduroğlu, *Elektrik Makinaları Dersleri, Cilt: 2, Kısım: 3, Asenkron Makinaların Hesap ve Konstrüksiyonu*. İstanbul: İTÜ Matbaası, 1984.
- [97] *Engineering tables/standard wire gauge*, Wikibooks, Accessed: Nov. 2024. url:https://en.wikibooks.org/wiki/Engineering_Tables/Standard_Wire_Gauge.
- [98] H. Alibrahim, S. A. Ludwig, “Hyperparameter optimization: Comparing genetic algorithm against grid search and bayesian optimization,” *Proc. 2021 IEEE Congress on Evolutionary Computation (CEC)*, Jun. 2021, pp. 1551–1559.
- [99] T. Yu, H. Zhu, *Hyperparameter optimization: A review of algorithms and applications*, arXiv preprint arXiv:2003.05689, 2020.
- [100] P. Liashchynskiy, P. Liashchynskiy, *Grid search, random search, genetic algorithm: A big comparison for nas*, arXiv preprint arXiv:1912.06059, 2019.
- [101] I. Goodfellow, Y. Bengio, A. Courville, *Deep Learning*. MIT Press, 2016.
- [102] V. Nair, G. E. Hinton, “Rectified linear units improve restricted boltzmann machines,” *Proc. 27th Int. Conf. on Machine Learning (ICML-10)*, 2010, pp. 807–814.
- [103] P. Ramachandran, B. Zoph, Q. V. Le, *Searching for activation functions*, arXiv preprint arXiv:1710.05941, 2017.
- [104] I. Goodfellow, D. Warde-Farley, M. Mirza, A. Courville, Y. Bengio, “Maxout networks,” *Proc. Int. Conf. on Machine Learning*, May 2013, pp. 1319–1327.

TEZDEN ÜRETİLMİŞ YAYINLAR

Makale

1. S. N. Ipek, N. Bekiroglu, M. Taskiran, “An ensemble learning-based predictive parameterization approach for permanent magnet synchronous machines,” *IEEE Access*, vol. 13, pp. 96857–96873, 2025, doi: 10.1109/ACCESS.2025.3576101.
2. S. N. Ipek, M. Taskiran, N. Bekiroglu, “A neural network-based approach to determining the mechanical design dimensions of asynchronous machines,” *IEEE Access*, vol. 13, pp. 47805–47819, 2025, doi: 10.1109/ACCESS.2025.3550824.
3. S. N. Ipek, M. Taskiran, N. Bekiroglu, E. Aycicek, “Optimal induction machine parameter estimation method with artificial neural networks,” *Electrical Engineering*, vol. 106, pp. 1959–1975, 2024, doi: 10.1007/s00202-023-02049-1.

Konferans Bildirisi

1. S. N. Ipek, N. Bekiroglu, M. Taskiran, “Identification of equivalent circuit parameters of permanent magnet synchronous machine with cascade-forward neural network,” *Proc. Grad Colloquium’24 Artificial Intelligence*, İstanbul, Turkey, 2024, pp. 36.
2. S. N. Ipek, M. Taskiran, N. Bekiroglu, E. Aycicek, “Low error rate induction machine parameter estimation with recurrent neural network,” *Proc. 2nd Int. Engineering Conf. Electrical, Energy, and Artificial Intelligence (EICEEAI)*, Zarqa, Jordan, 2023, pp. 1–6, doi: 10.1109/EICEEAI60672.2023.10590425.