T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

GENETİK ALGORİTMA VE YAPAY SİNİR AĞI İLE UYARLANABİLİR NÖRO BULANIK ÇIKARIM SİSTEMLERİNE DAYALI YÜK TAHMİNİ: IRAK ÖRNEĞİ

Ahmed Mazin ALQAYSİ

YÜKSEK LİSANS TEZİ
Elektrik Mühendisliği Anabilim Dalı
Elektrik Tesisleri Programı

Danışman
Dr. Öğr. Üyesi Altuğ BOZKURT

Eş-Danışman
Dr. Öğr. Üyesi Yavuz ATEŞ

Temmuz, 2023

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

GENETİK ALGORİTMA VE YAPAY SİNİR AĞI İLE UYARLANABİLİR NÖRO BULANIK ÇIKARIM SİSTEMLERİNE DAYALI YÜK TAHMİNİ: IRAK ÖRNEĞİ

Ahmed Mazin ALQAYSİ tarafından hazırlanan tez çalışması 20.07.2023 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik Mühendisliği Anabilim Dalı Elektrik Tesisleri Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Dr. Öğr. Üyesi Altuğ BOZKURT
Yıldız Teknik Üniversitesi
Danışman

Dr. Öğr. Üyesi Yavuz ATEŞ
Manisa Celal Bayar Üniversitesi
Eş-Danışman

Jüri Üyeleri

Dr. Öğr. Üyesi Altuğ BOZKURT, Danışman
Yıldız Teknik Üniversitesi _____

Doç. Dr. Erdin GÖKALP, Üye
Yıldız Teknik Üniversitesi _____

Prof. Dr. Osman KILIÇ, Üye
Marmara Üniversitesi _____

Danışmanım Dr. Öğr. Üyesi Altuğ BOZKURT sorumluluğunda tarafımca hazırlanan GENETİK ALGORİTMA VE YAPAY SİNİR AĞI İLE UYARLANABİLİR NÖRO BULANIK ÇIKARIM SİSTEMLERİNE DAYALI YÜK TAHMİNİ: IRAK ÖRNEĞİ 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.

Ahmed Mazin ALQAYSİ

İmza

Bu çalışma Irak Elektrik Bakanlığı tarafından desteklenmiştir.

Aileme ve biricik eşime

TEŞEKKÜR

Babamın ruhuna Allah'tan rahmet diliyorum. O, benim kahramanımdı ve bugün burada olmasını çok arzu ederdim. Bana her zaman ilham veren bu değerli kişi... Aileme ve tüm arkadaşlarıma destekleri ve ilhamları için şahsen teşekkür etmek istiyorum. Bu destekler sayesinde Yıldız Teknik Üniversitesi Elektrik Mühendisliği Bölümü'nde daha rahat bir şekilde eğitimimi tamamlayabildim. Bu çalışma sürecinde rehberlik eden ve destek sağlayan danışmanım Dr. Altuğ Bozkurt'a teşekkürlerimi sunmak istiyorum. Ayrıca, Yıldız Teknik Üniversitesi araştırma ekibine olumlu bir ortamın oluşturulması ve sürdürülmesine katkılarından dolayı minnettarım. Irak Elektrik Bakanlığı'nın mali destekleriyle bu çalışmayı tamamlama fırsatı verdiği için teşekkür etmek istiyorum. Bu çalışmada bana destek olan ve yer alan herkese teşekkürlerimi sunmak istiyorum.

Ahmed Mazin ALQAYSİ

İÇİNDEKİLER

SİMGE LİSTESİ viii

KISALTMA LİSTESİ x

ŞEKİL LİSTESİ xii

TABLO LİSTESİ xiii

ÖZET xiv

ABSTRACT xvi

1 GİRİŞ 1

1.1 Literatür Özeti 1
1.2 Araştırmanın Önemi 5
1.3 Motivasyon ve arka plan 6
1.4 Tezin Amacı 6

2 ELEKTRİK YÜKÜ TAHMİNİ TÜRLERİ VE YÖNTEMLERİ 8

2.1 Yük Tahmini 8
2.2 Yük Tahmininin Avantajları 9
2.3 Elektrik yükü tahmin aralıklarının sınıflandırılması 9
2.4 Elektrik yükü tahmini belirleyicileri ve faktörleri 11

3 YÜK TAHMİN YÖNTEMLERİ VE KULLANILACAK VERİLER 12

3.1 Irak elektrik sistemine genel bakış 12
3.2 İşlemlere girilecek verilerin toplanması 12
3.3 Verilerin işlenmesi 16
3.4 Verilerin Bölünmesi 17
3.5 Yük Tahmin Yöntemleri 18

4 METODOLOJİ 32

4.1 ANN ile Yük Tahmini 32
4.2 ANFIS ile Yük Tahmini 36

4.3 GA-ANN ile Yük Tahmini 38
4.4 Amaca Yönelik Tekniklerde Test ve Eğitim Sonuçları 40

5 SONUÇ VE ÖNERİLER **42**
5.1 Modellerin Performansının Karşılaştırılması 42
5.2 Sonuçlar 43
5.3 Öneriler ve gelecekteki çalışmalar 44

KAYNAKÇA **46**

TEZDEN ÜRETİLMİŞ YAYINLAR **49**

SİMGE LİSTESİ

z_{kj}	ANN tarafından Tahmin edilen değerlerdir
Alpha	Alfa (rasgele bir sayı)
$W1, W2$	Ateşleme gücü düzenlemeleridir
Var_{Min}	Belirtilen arama alanındaki minimum sınır
Var_{Max}	Belirtilen arama alanındaki en büyük sınır
P	Çıkışı
X_N	Çıkış değişken
T	Devrik işlemidir
x1, x2	Ebeveynler
b	Eğimler
X_{Min}	En düşük değeri
X_i	Etkileyen faktörleri
Y	Elektrik yükü
A1,A2,B1,B2	Giriş üyelik fonksiyonlarıdır
b_{kj}	Gözlemlenen değerlerdir
$e(t)$	Gürültü bileşeni
x	Giriş verisidir
y_i	Gerçek ve istenen değer
$x_i(t)$	Hava durumu gibi bir dizi bağımsız etkileyen faktörü
E	Hata miktarını
ε	Hata terimini
$f(t)$	Işlemin uydurma fonksiyon vektörünü
kV	Kilo volt

kVA	Kilo volt amper
MVA	Mega volt amper
MW	Mega watt
X_{Max}	Maksimum değeri
ρ_i, q_i, r_i	Nöronun ayarlanmış parametreleri
W_{ji}	Nöronların ağırlıkların
c	Ortalamayı
n	Örnek sayısıdır
η	Öğrenme oranıdır
°C	Santigrat
a	Standart sapmayı
a_i	Tahmini "yavaş değişen" katsayıları
y_i'	Tahmin edilen değeridir
μ	Üyelik derecesidir
$\beta(t)$	Vektörün katsayısını
β_i	Yanıt veren regresyon değişkenlerini
$y1, y2$	Yavrular
%	Yüzde
L(t)	Zamanındaki tipik veya standart yüktür

KISALTMA LİSTESİ

AI	Yapay zeka
AD	Uyarlanabilir Talep
ANN	Yapay sinir ağı
ANFIS	Uyarlanabilir nöro bulanık çıkarım sistemleri
ANN - GA	ANN, GA Tarafından Optimize Edilmiş
ARMA	Otoregresif hareketli ortalama
BP	Geri yayılımlı
CNN	Evrişimli sinir ağı
EBP	Hata geri yayılım
FF	Ileri beslemeli
FFANN	Ileri beslemeli yapay sinir ağı
FE	Özellik mühendisliği
FIS	Bulanık çıkarım sistemi
FL	Bulanık mantık
GA	Genetik algoritm
LF	Yükü tahmini
LTLF	Uzun vadeli yük tahmini
LM	Levenberg-Marquardt
LSTM	Uzun kısa süreli bellek
LR	Doğrusal regresyon
LSE	En küçük kareler tahmincisi
MAPE	Ortalama mutlak yüzde hatası
MF	Üyelik fonksiyonu

ML	Makine öğrenimi
MLP	Çok katmanlı algılayıcı
MTLF	Orta vadeli yük tahmini
MVLR	Çok değişkenli doğrusal regresyon
NN	Sinir Ağını
PSO	Parçacık Sürüsü Optimizasyonu
R	Regresyon değeri
RBF	Radyal temel fonksiyon
RMSE	kök ortalama kare hatası
RNN	Tekrarlayan sinir ağı
SAMF	Kendinden uyarlamalı momentum faktörü
SSA	Tekil spektrum analizi
STLF	Kısa vadeli yük tahmini
STS	Stokastik Zaman Serileri
SVM	Destek vektör makineleri
WNN	Dalgacık sinir ağı

ŞEKİL LİSTESİ

Şekil 2.1 Son yıllardaki elektrik yükü tahmininin önemli alanları 8
Şekil 3.1 Al-Hussein Dağıtım 33/11,5 kV 31,5 MVA Trafo Merkezi 13
Şekil 3.2 Al-Hussein trafo merkezinin 2020'deki saatlik yükünün dalgalanması 14
Şekil 3.3 2020'de Ramadi şehrinin sıcaklık farkı 15
Şekil 3.4 Ramadi şehrinin 2020'deki nem değişimi 15
Şekil 3.5 Tüm veri setinin bir eğitim ve test grubuna bölünmesi 18
Şekil 3.6 Yük tahmini yöntemleri için şematik gösterim 19
Şekil 3.7 Önerilen bir ANN modelinin şematik gösterimi 23
Şekil 3.8 Yapay sinir ağı ANN'nın akış şeması 24
Şekil 3.9 ANFIS Tasarım 25
Şekil 3.10 ANFIS eğitim ve test sürecinin akış şeması 27
Şekil 3.11 ANN-GA optimizasyonunun akış şeması 29
Şekil 4.1 2018'daki gerçek ve tahmini yük ANN 34
Şekil 4.2 2019'daki gerçek ve tahmini yük ANN 35
Şekil 4.3 Amaçlanan ANN 2018 gerçek ve tahmini yük (gerileme Grafiği) . . . 35
Şekil 4.4 2018'daki gerçek ve tahmini elektrik yükü ANFIS 37
Şekil 4.5 2019'daki gerçek ve tahmini elektrik yükü ANFIS 38
Şekil 4.6 2018 yılı için amaçlanan ANN–GA için gerçek ve tahmini yük 39
Şekil 4.7 2019 yılı için amaçlanan ANN–GA için gerçek ve tahmini yük 40
Şekil 5.1 Modellerin 2018 performansının karşılaştırılması 43
Şekil 5.2 Modellerin 2019 performans karşılaştırması 43

TABLO LİSTESİ

Tablo 4.1 2018 yılı için amaçlanan ANN için eğitim ve test sonuçları 34
Tablo 4.2 2019 yılı için amaçlanan ANN için eğitim ve test sonuçları 34
Tablo 4.3 2018 yılı için amaçlı ANFIS sonuçları 37
Tablo 4.4 2019 yılı için amaçlı ANFIS sonuçları 37
Tablo 4.5 2018 yılı için Amaçlanan ANN–GA Sonuçları 39
Tablo 4.6 2019 yılı için Amaçlanan ANN–GA Sonuçları 39
Tablo 4.7 Amaçlanan tekniklerin çıktı sonuçları 41

ÖZET

GENETİK ALGORİTMA VE YAPAY SİNİR AĞI İLE UYARLANABİLİR NÖRO BULANIK ÇIKARIM SİSTEMLERİNE DAYALI YÜK TAHMİNİ: IRAK ÖRNEĞİ

Ahmed Mazin ALQAYSİ

Elektrik Mühendisliği Anabilim Dalı
Yüksek Lisans Tezi

Danışman: Dr. Öğr. Üyesi Altuğ BOZKURT
Eş-Danışman: Dr. Öğr. Üyesi Yavuz ATEŞ

Elektrik enerjisi, modern ekonominin önemli bir unsuru olarak kabul edilmektedir. Elektrik enerjisinin üretimi ve tüketimi arasında denge sağlanması, enerji sektörünün etkin ve sürdürülebilir işleyişi için kritik bir gerekliliktir. Bu dengeyi sağlamak ve enerji kaynaklarının etkin bir şekilde kullanılabilmesi için elektrik yükünün doğru bir şekilde tahmin edilmesi büyük önem taşımaktadır. Elektrik yükü tahmini, gelecekte tüketilecek elektrik enerjisi miktarını veya yükünü önceden tahmin etmeyi hedefleyen bir çalışma alanıdır ve enerji yönetimi açısından önemli bir rol oynamaktadır. Bu çalışmada, elektrik yükünün tahmin edilmesi konusu üzerinde yoğunlaşılarak verimli enerji yönetimine katkı sağlanması hedeflenmektedir. Çalışmada, farklı istatistiksel yöntemlerin karşılaştırılması ve zaman içinde elde edilen sonuçların analizi amacıyla çeşitli eğitim ve test verileri kullanılmıştır. Bu kapsamda, Yapay Sinir Ağı (ANN) modeli ile birlikte Genetik Algoritmalar (GA) ve Uyarlanabilir Nöro-Bulanık Çıkarım Sistemleri (ANFIS) gibi gelişmiş tahmin teknikleri de kullanılmıştır. Böylelikle, farklı yöntemlerin performansı karşılaştırılarak en iyi tahmin sonuçlarının elde edilmesi amaçlanmıştır. Çalışmada, uzun vadeli bir model kullanılarak tahmin süreci gerçekleştirilmiş ve saatlik bölünmüş yıllık veriler kullanılarak en düşük bağlamsal hata değerlerine ulaşılmıştır. Veri örnekleri, farklı algoritmaların uygulanması ve çeşitli faktörlerin yük tahmini üzerindeki etkilerinin incelenmesi amacıyla kullanılmıştır. Elde edilen sonuçlar, ANN-GA modelinin diğer modellere kıyasla yük tahmini konusunda yüksek doğruluk ve düşük hata oranlarına

sahip olduğunu göstermektedir. Bu çalışma, enerji yönetimi alanında önemli bir katkı sağlamakta olup, elektrik yükünün etkili bir şekilde tahmin edilmesine yönelik gelişmiş yöntemlerin kullanılmasının önemini vurgulamaktadır.

Anahtar Kelimeler: Yapay sinir ağı, uyarlanabilir nöro tabanlı bulanık çıkarım sistemi, genetik algoritma, elektrik yükü tahmini

ABSTRACT

Load Forecasting Based on Genetic Algorithm GA Artificial Neural Network ANN Adaptive Neuro-Fuzzy Inference Systems ANFIS : A Case Study in Iraq

Ahmed Mazin ALQAYSİ

Department of Electrical Engineering
Master of Science Thesis

Supervisor: Asst.Prof.Dr. Altuğ BOZKURT
Co-supervisor: Assoc. Prof. Dr. Yavuz ATEŞ

Electricity is considered a crucial element of the modern economy. Achieving a balance between electricity production and consumption is imperative for the efficient and sustainable functioning of the energy sector. Forecasting electricity load accurately is of great importance to maintain this balance and enable effective utilization of energy resources. Load forecasting aims to predict the future amount of electricity consumption or load, playing a significant role in energy management.

This study focuses on predicting electricity load to contribute to efficient energy management. Various statistical methods are compared, and the outcomes over time are analyzed using different training and testing datasets. Advanced prediction techniques such as Artificial Neural Networks (ANN), Genetic Algorithms (GA), and Adaptive Neuro-Fuzzy Inference Systems (ANFIS) are employed. The objective is to achieve the best prediction results by comparing the performance of different methods.

The forecasting process is performed using a long-term model, utilizing hourly subdivided annual data to attain the lowest contextual error values. Data sets are used to investigate the effects of various factors on load forecasting by applying different algorithms. The obtained results demonstrate that the ANN-GA model outperforms other models, showing high accuracy and low error rates in load prediction. This research significantly contributes to the field of energy management by highlighting the importance of employing advanced tools to accurately forecast electricity load.

Keywords: Artificial neural network, adaptive neuro-based fuzzy inference system, electrical load forecasting, genetic algorithm

1
GİRİŞ

1.1 Literatür Özeti

Elektrik yükü tahmini, gelecekteki elektrik yüklerini tahmin etmek için yapılan bir işlemdir. Bu tahminler, önceki yük verileri ve diğer parametre bilgilerine dayanarak gerçekleştirilir [1].
Elektrik yükü tahmin işlemlerinin sınıflandırılması aşağıdaki dönemlere bağlıdır [2, 3]:

- Kısa vadeli yük tahmini (STLF) (1 saatten 24 saate).
- Orta vadeli yük tahmini (MTLF) (1 haftadan 1 yıla kadar).
- Uzun vadeli yük tahmini (LTLF) (1 yıla kadar).

Talep ve üretim tarafları arasındaki dengeyi kontrol etmek amacıyla, elektrik yükünün tahminleri günümüzde büyük önem taşımaktadır. Bu nedenle, modern yöntemler ve teknikler kullanılarak elektrik yükünün tahmin edilmesi üzerinde yoğun çalışmalar yürütülmektedir [4].
Elektrik yükü tahmini için kullanılan birçok teknik bulunmaktadır, bunlar arasında ANN, ANFIS ve GA-ANN gibi optimizasyon algoritmalarına sahip hibrit ANN yöntemleri yer almaktadır. Ancak, bu teknikler arasında sürekli bir rekabet bulunmamaktadır ve hangi yöntemin daha iyi performans göstereceği konusunda kesin bir sonuca varmak için çeşitli faktörler göz önünde bulundurulmalıdır. Bu nedenle, çeşitli yük tahmin yöntemlerinin performansını analiz etmek ve karşılaştırmak önemlidir [5].
Geçmiş araştırmalar incelendikten sonra, gelecekteki elektrik yükünü tahmin etmek için çeşitli tahmin tekniklerinin kullanıldığı görülmüştür. Bu çalışmada, kullanılan uygulamalar göz önünde bulundurularak çalışmalar ve metodolojiler detaylı bir şekilde gözden geçirilecektir. Ayrıca, elektrik yükü tahminlerinin farklı dönemlere göre sınıflandırılması gerektiği belirtilmiştir, çünkü her dönemde tüm ihtiyaçları

karşılayan tek bir tahmin yöntemi bulunmamaktadır. Bunun yanı sıra, tahminlerin doğruluğunu etkileyen diğer faktörler arasında sıcaklık, rüzgâr ve diğer meteorolijik parametreler de yer almaktadır. Sıcaklık, elektrik enerjisinin kullanımını etkileyen en önemli değişkendir. Gelecekteki dönemler için doğru tahminler yapmayı zorlaştıran diğer unsurların yanı sıra sıcaklık da dikkate alınması gereken bir faktördür [3].

Nti ve arkadaşları, elektrik yükünü tahmin etmek için farklı tekniklerin bulunduğu ve bu t eknikler arasında en popüler olanın sinir ağları olduğu belirtilmektedir. Sinir ağlarının diğer tekniklere göre daha etkin çalıştığı ifade edilmektedir. Bununla birlikte, daha doğru tahmin sonuçları elde etmek için genellikle büyük miktarda veriye ihtiyaç duyulduğu vurgulanmaktadır. Araştırmacıya göre, elektrik yükü tahmini çalışmalarında üzerinde durulması gereken en önemli iki faktör, kullanılan tahmin algoritmalarının ve bu alana uygunluğunun değerlendirilmesidir. Bu faktörlerin doğru bir şekilde belirlenmesi, daha doğru tahminler elde etmek için önemlidir [4].

Arfoa ve arkadaşları, 2014 verilerine dayanarak 2014-2023 yılları için tepe yükünü tahmin etmek amacıyla en küçük kareler yöntemi kullanılmıştır. Bu yöntem, geçmiş yük verileri ve nüfus artışı gibi iki farklı parametreye dayanmaktadır [5].

Shareef ve arkadaşları, yapay sinir ağları (ANN), bulanık mantık (FL) ve uyarlanabilir sinirsel bulanık çıkarım sistemleri (ANFIS) gibi farklı metodolojilerin etkinlikleri incelenmektedir. Bu metodolojilerin enerji yönetim sistemlerindeki performansları, hesaplama hızları ve karmaşıklıkları üzerinde durulmaktadır [6].

Mamun ve arkadaşları, iki veya daha fazla tahmin modelini birleştirerek bir kibrit model oluşturmuşlardır. Elektrik yükü tahmini için çeşitli teknikler incelenmiş ve her bir model ayrı ayrı ve kombinasyon halinde değerlendirilmiştir. Bu çalışmada, her modelin avantajları, dezavantajları ve işlevleri detaylı bir şekilde ele alınmıştır. Ayrıca, performans karşılaştırmaları yapılarak modeller arasındaki farklar belirlenmiştir. Araştırmacılar, yapay sinir ağı (ANN) yöntemine ve modellerine diğer yöntemlere kıyasla daha yüksek doğruluk sağladığı sonucuna varmışlardır [7].

Baek ve arkadaşları, RNN'nin performansı doğruluk ve hata oranı açısından değerlendirilmiştir. Sonuçlar, RNN'nin bir yıllık yük verilerini başarıyla tahmin edebildiğini ortaya koymuştur, ancak daha uzun süreli tahminlerde sonuçların daha kötü olduğu gözlemlenmiştir [8].

Ibraheem ve arkadaşları, Bu çalışmada, Levenberg-Marquardt geri yayılımlı BP (backpropagation) algoritması, çok katmanlı algılayıcı (MLP) modeli ve radyal temel fonksiyon (RBF) kullanılmıştır. Çalışmada, önceki yük değerleri gibi girdi verileri olarak kullanılan ANN modelleri değerlendirilmiştir. Veri seti, test ve eğitim için iki ayrı bölüme ayrılmıştır. Elde edilen sonuçlara göre, RBF modelinin MLP'ye kıyasla daha iyi performans gösterdiği belirlenmiştir [9].

Abdullah ve arkadaşları, hibrit model olan Parçacık Sürüsü Optimizasyonu (PSO) yöntemini kısa vadeli yük tahmini (STLF) için ANN algoritmasıyla birleştiren bir

çalışmayı incelemektedir. Çalışmada, bilgiler hafta içi, hafta sonu ve ulusal tatil günleri olmak üzere üç kategoriye ayrılmıştır. PSO-ANN yönteminin, tüm yük tahmini sonuçlarının doğruluğunu arttırdığı görülmüştür [10].

Alawode ve arkadaşları, hem geri yayılımlı BP'li ileri beslemeli FF (Feedforward) yapay sinir ağı modeli, hem de tekrarlayan sinir ağı RNN (Recurrent Neural Network) kullanılmıştır. Bu iki modelin elektrik yükü tahmini performansı karşılaştırılmıştır. Sonuçlar, ileri beslemeli geri yayılım FF-BP modeli ile karşılaştırıldığında, tekrarlayan ağ RNN'nin daha düşük bir bağıl hata ile daha iyi elektrik yükü tahmini sağladığını göstermektedir. Ayrıca, çalışma ağa gizli katmanlar eklemenin her zaman daha iyi performans sağlamadığını da göstermektedir [11].

Ali ve arkadaşları, uzun vadeli yük tahmini için bulanık mantık (Fuzzy Logic - FL) kullanılmıştır. Bu çalışmada, geçmiş yük verileri, hava durumu değişkenleri (sıcaklık ve nem) ve diğer ilgili bilgiler kullanılarak bir bulanık mantık modeli geliştirilmiştir. Bu model, performansını değerlendirerek elektrik yükünü doğru bir şekilde tahmin edebilme yeteneğini göstermektedir [12].

Ammar ve arkadaşları, Uyarlanabilir nöro-bulanık çıkarım sistemleri (Adaptive Neuro-Fuzzy Inference Systems - ANFIS) ve yapay sinir ağları (Artificial Neural Networks - ANN) modelleri kullanılarak bir karşılaştırma yapılmıştır. Bu karşılaştırmada, hava durumu değişkenlerinin dinamik davranışının yük tahmini için hem ANN hem de ANFIS tarafından başarılı bir şekilde yakalandığı gösterilmiştir. Araştırmada, ANFIS'in uzun vadeli sonuçlarının Yapay Sinir Ağları'ndan (YSA) önemli ölçüde daha doğru olduğu sonucuna varılmıştır [13].

Xu ve arkadaşları, yapay sinir ağı (ANN) ve uyarlanabilir nöro tabanlı bulanık çıkarım sistemi (ANFIS) algoritmalarını aynı işletim ortamında kullanmaktadır. İki yaklaşımı, hatayı en aza indirmek için uygun parametreleri ayarlayarak karşılaştırmaktadırlar [14].

Panda ve arkadaşları, uzun vadeli yük tahmini için yapay sinir ağı (ANN), bulanık mantık (FL), dalgacıklar ve genetik algoritma (GA) gibi farklı tekniklerin kullanıldığı belirtilmektedir. Bu yöntemlerin kullanıldığı zaman serileri ve ANN modelleri karşılaştırıldığında, ANN'nin gerçek verilere çok yakın sonuçlar verdiği gözlemlenmektedir. Ayrıca, bir ANN modelinin minimum miktarda geçmiş veri kullanarak nasıl doğru tahminler üretebileceği de gösterilmektedir [15].

Gökgöz ve arkadaşları, yapay sinir ağı (ANN) modelinin oluşturulması için çeşitli transfer fonksiyonları, yöntemleri ve gizli katman nöron sayıları kullanılmıştır. Optimum performans elde etmek için, ANN modelinin eğitim aşamasında hatayı en aza indirmek amacıyla log-sigmoid transfer fonksiyonu ile Levenberg-Marquardt (LM) algoritması kullanılmıştır [16].

Arvanitidis ve arkadaşları, veri ön işleme aşamasında kullanılan verilerin değiştirilmesi için yeni teknikler önerilmektedir. Örneğin, saat, haftanın günü, tatil durumu, sıcaklık,

ilk gün yükü, yedinci gün yükü ve tatil yükü gibi değişkenler kullanılmaktadır. Bu değişkenler üzerinde yapılan değişiklikler, ANN'yi eğitmek için kullanılan veri setinin daha etkili hale gelmesini sağlayabilir. Bununla birlikte, makine öğrenimi (ML) tekniklerinin performansını önemli ölçüde iyileştiren yeni yöntemler de önerilmektedir [17].

Pham ve arkadaşları, hem derin öğrenme sinir ağı (deep learning neural network) teknikleri hem de tekil spektrum analizi (singular spectrum analysis - SSA) kullanılmıştır. SSA yöntemi kullanılarak dört mevsimlik veriler yıllık yük profiline bölünmüştür. Ardından, sinir ağının giriş birimleri SSA çıkış birimleri olarak kullanılmıştır. Bu kombinasyon olan SSA-NN yöntemi, geleneksel sinir ağı yönteminden elde edilen sonuçlara kıyasla daha doğru sonuçlar sağlamaktadır [18].

Oprea ve arkadaşları, geri yayılımlı BP (backpropagation) algoritmasıyla öğrenme oranının ayarlandığı ileri beslemeli yapay sinir ağı (feedforward artificial neural network - FFANN) teknikleri kullanılmıştır. Çalışmada için hava durumu sensörlerinden ve akıllı sayaçlardan elde edilen veriler kullanılmıştır. Sonuçlar, makine öğrenmesi (machine learning) tekniklerinin etkinliğini göstermektedir[19].

Selvi ve arkadaşları, karşılaştırmalı performans analizi için ileri beslemeli sinir ağı (feedforward neural network - FFNN) ve çok değişkenli doğrusal regresyon (multivariate linear regression - MVLR) yöntemleri kullanılmıştır. Her iki yöntemin de mevsimsel etkileri doğru bir şekilde tahmin edebildiğini göstermektedir. Ayrıca, tahmin sürecinde verilen modelin kullanılmasıyla oynaklık daha da iyileştirilmiştir [20].

Nespoli ve arkadaşları, yapay sinir ağı (artificial neural network - ANN) tabanlı bir makine öğrenimi (machine learning - ML) yaklaşımı kullanılarak tahmin algoritması geliştirilmiştir. Modelin eğitimi için temel bir çok katmanlı perceptron (multilayer perceptron - MLP) yapısı kullanılmıştır. Ayrıca, giriş ve çıkış verileri üzerinde ön işleme adımları uygulanmıştır. Bu adımlar, verilerin daha iyi bir şekilde temsil edilmesini ve modelin daha iyi performans göstermesini sağlar [21].

Zulfiqar ve arkadaşları, dalgacık sinir ağı (wavelet neural network - WNN) kullanılarak elektrik yüklerinin tahmin edilmesi için ek araçlar ve teknikler uygulanmıştır. Bu ek araçlar, modelin performansını artırmak ve yakınsama sürecini iyileştirmek amacıyla kullanılmıştır. Kendinden uyarlamalı momentum faktörü (self-adaptive momentum factor - SAMF), WNN'nin kontrol parametrelerini ayarlamak için kullanılmıştır. Yapılan deneysel bulgular, bu ek araçlar ve tekniklerin kullanıldığı modelin elektrik yüklerini tahmin etme sürecinde daha doğru sonuçlar verdiğini göstermiştir[22].

Faraji ve arkadaşları, üç farklı ANFIS (Adaptive Neuro-Fuzzy Inference System) modeli, yapay sinir ağı MLP-ANN (Multi-Layer Perceptron Artificial Neural Network) ile çok katmanlı algılayıcı ve radyal temel fonksiyon yapay sinir ağı RBF-ANN (Radial Basis Function Artificial Neural Network) kullanılarak zaman serisi verilerinin

tahmin edilmesi üzerine odaklanılmıştır. ANFIS modelinin ortam sıcaklığını ve rüzgar hızını diğer algoritmalara göre daha doğru tahmin edebildiği belirtilmektedir. RBF-ANN ve MLP-ANN ise güneş ışınımını ve yük talep verilerini tahmin etmede en başarılı algoritmalar olarak değerlendirilmiştir. Ayrıca, ANN-MLP'nin mevcut diğer algoritmalara göre en hızlı performansa sahip olduğu vurgulanmıştır[23].

Rafi ve arkadaşları, uzun kısa süreli bellek (Long Short-Term Memory - LSTM) ağı ve evrişimli sinir ağı (Convolutional Neural Network - CNN) kullanılarak geliştirilen yöntem entegre edilmiştir. Toplanan veriler çeşitli standart haftalara bölünmüştür. CNN-LSTM modeli, uzun sıralı zaman serisi elektrik yük verilerini işleyebildiğini ve uzun bir süre boyunca gelecekteki yük talebini tahmin edebildiğini göstermektedir [24].

Mahmud ve arkadaşları, yapay sinir ağı (Artificial Neural Network - ANN) ve otoregresif hareketli ortalama (Autoregressive Moving Average - ARMA) tahmin teknikleri uygulanmıştır. Araştırmaya göre, sıcaklık, nem, güneş ışığı ve tüketici enerji talebi gibi çevresel değişkenler arasında bir bağlantı olduğu belirlenmiştir. Sonuçlar, ANN'nin eğitim sırasında girdiler ve hedefler arasında bağlantılar oluşturduğunu göstermektedir [25].

1.2 Araştırmanın Önemi

Elektrik, modern toplumların temel bir ihtiyacı haline gelmiştir ve ulusların ekonomik gelişimi elektrik şebekeleriyle yakından ilişkilidir. Artan nüfus yoğunluğu ve kentleşme, dünyayı genişlemeye ve hızlı nüfus artışına ayak uydurmaya zorlamış ve elektrik enerjisi tedarikine özel bir önem verilmesini gerektirmiştir.

Geleneksel elektrik şebekesi yönetimi süreçleri, tüketicilere elektriği kolayca sağlama talebini karşılamak için yeterli olmamaktadır. Bu nedenle, akıllı şebeke yönetimi kavramı ortaya çıkmıştır. Akıllı şebeke yönetimi, elektrik enerjisi üretimini taleple eşleştirerek ve koordine ederek gerçekleştirilen bir stratejidir. Bu sayede enerji talebinin yüksek olduğu zamanlarda üretim artırılırken, talebin düşük olduğu zamanlarda üretim azaltılır. Elektriğin sorunsuz bir şekilde dağıtılması ve mümkün olan en düşük maliyetle tedarikçi ve müşteriye iletilmesi için bu denge korunmalıdır [26].

Akıllı şebeke yönetimi ayrıca elektrik akımının sorunsuz iletilmesini, sürekliliği ve ekonomik faydayı sağlamak için gereken diğer gereksinimlerin net bir resmini sunar. Ayrıca, santrallerin çalışması için gereken yakıt miktarını tahmin etme yeteneğine de sahiptir. En önemlisi, tahmin edilen gelecekteki yükler ve bu yüklerle başa çıkma yöntemleri hakkında önemli bilgiler sağlar. Tahmin edilen yük, planlanmamış bir çalışma olayının üstesinden gelebilecek bir sistemin tasarlanmasında önemli bir

unsurdur.
Elektrik yükünün tahmin edilmesi, akademik olarak yazılan bir makalede ele alınan önemli bir konudur. Tahmin edilen yükler, elektrik şebekesine entegre edilebilecek ve günlük işleyişi optimize edebilecek sistemlerin tasarımında önemli bir rol oynar [27].

1.3 Motivasyon ve arka plan

Elektrik yükünün tahmini, belirli bir tesis için gelecekteki yükler hakkında bilgi edinmek ve belirli bir süre boyunca maksimum ne kadar enerji kullanılacağını belirlemek için önemlidir. Bu çalışmanın bir parçası olarak yük tahmini yöntemleri kullanılarak güç arzı ve talebi arasındaki boşluğu kapatmak amaçlanır.
Yük tahmini için en popüler yapay zeka (AI) yöntemleri arasında yapay sinir ağları (ANN), genetik algoritma (GA) ve uyarlanabilir nöro tabanlı bulanık çıkarım sistemi (ANFIS) teknikleri bulunur. Bu yöntemler, çeşitli yük tahmin teknikleri arasında önerilen modele en iyi yanıtı bulmak için kullanılır. Her AI tekniği periyodik olarak diğerlerinden daha iyi performans gösterebilir. Bu nedenle, farklı parametreleri dikkate alarak yük tahminlerinin etkinliğini değerlendirmek önemlidir. Performansları hakkında herhangi bir yargıda bulunmadan önce daha kapsamlı bir karşılaştırma yapmak da önemlidir. Son olarak, her bir yöntemin performans doğruluğunu artırmak için uygun parametre değerleri seçilecektir [28].
Elektrik yüklerini tahmin etmek için kullanılan yöntemler üzerinde zaman, hava durumu, ekonomi ve diğer faktörlerin etkisi vardır. Bu nedenle, bu değişkenleri ve bu değişkenlerin elektrik yükünü tahmin etme yaklaşımları üzerindeki etkilerini incelemek, en güvenilir analizi elde etmek için gereklidir. Ayrıca, daha verimli bir sistem oluşturmak için bu faktörlerin etkisini anlamak önemlidir.

1.4 Tezin Amacı

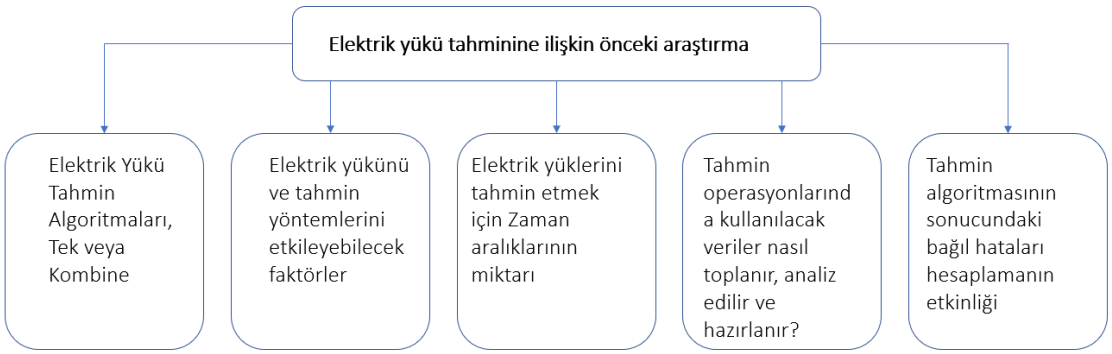
Bu çalışma, elektrik yükünün tahmin edilmesi üzerine odaklanmaktadır ve geçmiş veriler ile çeşitli algoritmaları kullanarak bu tahmini gerçekleştirmeyi amaçlamaktadır. Çalışma, verilerin saatlere bölünmesi, veri ön işleme adımları, eğitim ve test oranlarının belirlenmesi gibi birkaç adımı içermektedir.
Tezin ikinci bölümü, elektrik yükü tahmin sürecini, faydalarını, sınıflandırmalarını ve etkileyen faktörleri tanımlamaktadır. Elektrik yükü tahmininde kullanılan saha ve algoritmalar hakkında bilgi verilmekte ve bu algoritmaların etki mekanizmaları, girdi ve çıktıları, katman sayısı, test ve eğitim oranları, hata doğrulama ilkeleri gibi detaylar açıklanmaktadır.
Üçüncü bölüm, üzerinde çalışılan sahanın detaylı bir açıklamasını içermekte ve

elektrik yükü tahmini için kullanılan algoritmaların etki mekanizmalarını, girdi ve çıktı bilgileriyle nasıl başa çıkıldığını, fonksiyonel mekanizmalarını, denklemlerini ve hata doğrulama ilkelerini anlatmaktadır. Ayrıca, test ve eğitim oranlarının belirlenmesi ve bir doğruluk standardının belirlenmesi gibi konular ele alınmaktadır.
Dördüncü bölümde, hedeflenen algoritmaların program üzerindeki etki mekanizması, test ve eğitim sonuçları ve algoritmanın güvenilirliğinin değerlendirilmesi üzerinde durulmaktadır. Algoritmaların test edilmesi ve eğitilmesi sonuçlarına dayanarak, algoritmanın güvenilirliği ve çıktı değerlerinin değerlendirilmesi gerçekleştirilmektedir.
Beşinci ve son bölümde, çalışmanın sonuçları ve önerileri sunulmaktadır. Ayrıca, elde edilen sonuçların doğrulanması ve gelecekte yapılacak çalışmalarda nelerin göz önünde bulundurulabileceği konusunda öneriler sunulmaktadır.

2
ELEKTRİK YÜKÜ TAHMİNİ TÜRLERİ VE YÖNTEMLERİ

2.1 Yük Tahmini

Günümüzde yaşamın temel ihtiyaçlarından biri elektrik enerjisi olduğu için, endüstriyel, ticari ve evsel amaçlar dahil olmak üzere sürekli olarak elektrik enerjisine ihtiyaç duyulmaktadır. Bu nedenle, gelecekteki elektrik talebini tahmin etmek, elektrik tedarik şirketleri için önemli zorluklar sunmaktadır [29]. Elektrik kapasitesinin yeterli bir şekilde üretildiğinden emin olabilmek için, farklı zamanlar için gelecekteki yükü belirlemek ve tahmin etmek için özel olarak tasarlanmış çalışmaların hazırlanması, yürütülmesi ve geliştirilmesi önemli hale gelmiştir. Ayrıca, elektrik enerjisi üretim şirketleri ile elektrik enerjisi iletim ve dağıtım şirketlerinin planlama yapmasına olanak sağlanması ve tüketici ile tedarikçi arasındaki güvenilirliğin artırılması gibi bazı avantajlar elde edilebilir.
Son yıllarda yürütülen çalışmalar gözden geçirildiğinde, Şekil 2.1'de gösterildiği gibi elektrik yükü tahmini alanındaki araştırmaların çeşitli önemli konulara odaklandığı görülmektedir.



Şekil 2.1 Son yıllardaki elektrik yükü tahmininin önemli alanları

Tahmin süreci, karşılaştığı sayısız sorun nedeniyle "karmaşık" bir süreç olarak adlandırılmaktadır. Zaman, ekonomik durum, hava dalgalanmaları ve diğer birçok değişken kısıtlamalar olabilir. Yüklerin hesaplanmasını etkileyen en önemli unsurlardan biri havadaki değişikliklerdir. Ayrıca, hem insanların hem de endüstrinin faaliyetleri de oldukça önemlidir [28].

2.2 Yük Tahmininin Avantajları

Elektrik yükünün tahmin edilmesinin avantajları aşağıdaki şekilde özetlenebilir:
Yeni Üretim İstasyonları: Elektrik yükünün tahmin edilmesi, mevcut üretim istasyonlarının genişletilmesi için gerekli hazırlıkların yapılmasını ve elektrik enerjisi talebine ayak uyduracak yeni istasyonların inşası için gelecekteki planlamaların yapılmasını sağlar.
Enerji Nakil Hatları ve Dağıtım Şebekeleri: Tahminler, yeni enerji nakil hatları inşa etmek için bir plan oluşturmayı, mevcut trafo merkezlerinin boyutunu artırmak veya yenilerini inşa etmek için planlar yapmayı ve mevcut dağıtım şebekelerini değiştirmeyi veya yeni elektrik dağıtım şebekelerini geliştirmeyi organize etmeyi sağlar. Ayrıca, artan elektrik enerjisi talebine göre ayarlamaların nasıl yapılacağına dair ayrıntılar ve tavsiyeler sunar, bu da elektrik sisteminin istikrarını sağlar.
Sektörel Yükler: Elektrik yükü tahmini, ticari, konut, tarım ve endüstriyel sektörler için yüklere ilişkin ayrı ayrı istatistikler ve ayrıntılar sunar. Bu bilgiler, enerji santrallerinin işletilmesi için gerekli yakıtın ve elektrik enerjisinin tüketicilere sürekli ve uygun maliyetli bir şekilde iletilmesini garanti etmek için gereken kaynakların belirlenmesini destekler [30].
Verimlilik ve Kayıp Azaltma: Elektrik yükü tahmini, imalat, dağıtım ve nakliye alanlarında beklenen kayıpları azaltacak daha doğru prosedürler hakkında net bir açıklama sağlar. Bu, endüstrilerin gelecekteki yatırımlarla ilgili akıllıca ekonomik seçimler yapmalarına yardımcı olur.
Yukarıdaki avantajlardan hareketle, elektrik yükünün tahmin edilmesi, üretim şirketlerinin doğru yerleri ve alanları seçerek üretim istasyonlarını planlamalarına yardımcı olur. Bu istasyonlar, iletim hatlarını kısaltmak ve dolayısıyla maliyetten tasarruf etmek için tahmin edilen yüklere yakın konumlandırılmalıdır. Bu sayede enerji sistemi daha verimli hale getirilebilir.

2.3 Elektrik yükü tahmin aralıklarının sınıflandırılması

Yük tahmini, hedef tahmin aralıklarına bağlı olarak üç gruba ayrılabilir:

- Kısa Vadeli Yük Tahmini (STLF - Short-Term Load Forecasting): STLF, tahmin

penceresinin birkaç dakikadan tüm güne veya haftaya kadar değişebildiği bir yük tahmini yöntemidir. STLF, günlük operasyonlarda önemli bir rol oynar çünkü talep yönetimi, enerji depolama operasyonları, pik yük azaltma ve elektrik şebekesinin stratejik planlaması gibi alanlarda geniş bir uygulama alanına sahiptir. Günlük ve haftalık güç tüketimi verileri veya belirli bir bölgenin yükü sıklıkla tahmin hedefi olarak kullanılır.

- Orta Vadeli Yük Tahmini (MTLF - Medium-Term Load Forecasting): MTLF, tahmin penceresinin bir haftadan bir yıla kadar değişebildiği bir yük tahmini yöntemidir. Bu tahmin yöntemi, yakıt dağıtımlarını ve ekipman bakımlarını planlamak için kullanılır. Genellikle bir bölgenin pik yükü veya aylık elektrik kullanımı projeksiyonu olarak işlev görür. Tahmin verileri genellikle mevsimsel bir artış eğilimi gösterir ve büyüme trendi yıl boyunca benzer şekildedir. MTLF'nin amacı, aylık rutin bakım programları, depolama işletim programları, işletme modu programları ve yakıt taşıma programları gibi planlamaları oluşturmaktır. Büyük kullanıcıların operasyon stratejileri, hava koşulları, endüstriyel yeniden yapılandırma senaryoları, ulusal tarife politikası ve diğer faktörler, orta vadeli yük tahminini etkileyen temel değişkenlerdir.

- Uzun Vadeli Yük Tahmini (LTLF - Long-Term Load Forecasting), genellikle bir yıldan daha uzun süren, 10, 15 veya 20 yıl gibi bir zaman dilimini kapsayan bir yük tahmini yöntemidir. LTLF, güç kaynakları işletmelerinin yatırım yapması ve bakım planları oluşturması için verimli tahmin işlemlerine dayanır. Bu tahmin yöntemi genellikle yıllık elektrik kullanımı tahmin hedefi olarak hizmet verir.LTLF'nin temel amacı, elektrik şebekesi planlamacılarına sistemin çalışma modunu seçmeleri ve yıllık bakım programlarını oluşturmak için gereken temel bilgileri sağlamaktır. Uzun vadeli yük tahmini, nüfus artışı, yapısal değişiklikler, hükümet tarife stratejisi ve ulusal ekonomik gelişme gibi faktörlerden etkilenir. Elektrik sisteminin işleyişinin verimliliğini ve güvenilirliğini artırmak, geçmiş yıllarda LTLF'nin ana araştırma hedeflerinden biri olmuştur [7].
  Bu tez çalışmasında, saatlere göre organize edilen bir çalışma yapılarak pik yük tahmini için LTLF'ye odaklanılmıştır. Bu tahmin yöntemi, elektrik üretimi ve gerçek zamanlı yönetim için gereklidir. Yük tahmininin doğru yapılması, elektrik sistemi operatörlerinin kaynakları ve işletme stratejilerini planlamalarında yardımcı olur.

2.4 Elektrik yükü tahmini belirleyicileri ve faktörleri

Elektrik yükünün doğru bir şekilde tahmin edilmesi için, çeşitli faktörler dikkate alınmalıdır. Bu faktörler arasında zaman faktörleri, geçmiş hava durumu bilgileri, önceki yük miktarı, insan etkinliği ile ilişkili elektrik yükü, müşteri sayısı, tüketici sınıfı, kullanılan cihazların türleri ve özellikleri, bölgesel ekonomik faktörler vb. yer alır. Tahmin süreci, zaman ve diğer değişkenler arasında karmaşık bir ilişki içerir ve yapay zeka (AI) yöntemleri gibi geleneksel olmayan teknikler bu karmaşıklığı çözmek için kullanılır.

Tarih, saat, gün, hafta, ay, yıl gibi zaman parametreleri yük tahmini için en önemli parametrelerden biridir. Bu parametreler, yükün mevsimsel değişimlerini, günlük ve haftalık trendleri ve diğer zaman bağımlı etkileri yansıtabilir [26].

Bu çalışmada, hava parametrelerinin yanı sıra zaman faktörlerine odaklanılmıştır, çünkü bu faktörler bu bölgedeki elektrik yüklerinin değerlerini önemli ölçüde etkileyebilir. Sıcaklık, nem ve diğer hava parametreleri, ısıtma, soğutma ve iklimlendirme sistemlerinin kullanımını etkileyerek elektrik tüketimini doğrudan etkileyebilir. Zamanın yanı sıra hava durumu verilerinin de tahmin sürecine dahil edilmesi, daha doğru yük tahminleri elde etmek için önemli olabilir.

Bu çalışmanın amacı, hava parametreleri ve zaman faktörlerini kullanarak elektrik yükünü tahmin etmek için yapay zeka (AI) tabanlı teknikleri ve diğer geleneksel olmayan yöntemleri incelemektir.

3
YÜK TAHMİN YÖNTEMLERİ VE KULLANILACAK VERİLER

3.1 Irak elektrik sistemine genel bakış

Irak'taki elektrik şebekesi ring bir yapıya sahiptir ve üretim ve dağıtım olmak üzere iki sistemden oluşur. Yükler, sabit parçalardan oluşan ısıtıcılar, elektrikli fırınlar, aydınlatma armatürleri gibi yüklerden hareketli parçalara sahip olmayan yükler ve pervaneler, motorlar gibi hareketli bileşenleri içeren dinamik yüklerden oluşur. Konutlar, iş yerleri, eğitim kurumları, hastaneler gibi yapılar, endüstriyel yüklerin yanı sıra ışıklar gibi endüstriyel olmayan yükleri de içermektedir. Bu yapıda pompa, ısıtıcı, elektrikli fırın, klima ve ısıtma sistemleri gibi cihazlar bulunmaktadır.

Elektrik güç transformatörleri çeşitli tiplerde ve boyutlarda mevcuttur. Doğal soğutmalı güç transformatörleri, dönüştürme oranı 11,5/33 kV olan ve farklı kapasitelerde (5, 10, 16 ve 31,5 MVA) kullanılan transformatörlerdir. Ayrıca, doğal ve cebri soğutmalı, çeşitli bağlantı gruplarına sahip ve dönüştürme oranı (132/33/11,5 kV) olan 63 MVA kapasiteli güç transformatörleri de bulunmaktadır.

Dağıtım trafosu türleri ve boyutları şunları içerir: 11/0,4 kV düşürücü transformatörler, çeşitli kapasitelerde (100, 250, 400, 630 ve 1000 kVA) doğal soğutma ile çalışan ve farklı bağlantı gruplarına sahip transformatörlerdir. Ayrıca, bağlantı kitine sahip 33/0,4 kV doğal soğutmalı düşürücü transformatörler de bulunmaktadır ve bu transformatörlerin kapasiteleri 100, 250, 400, 630 ve 1000 kVA olarak çeşitlilik göstermektedir.

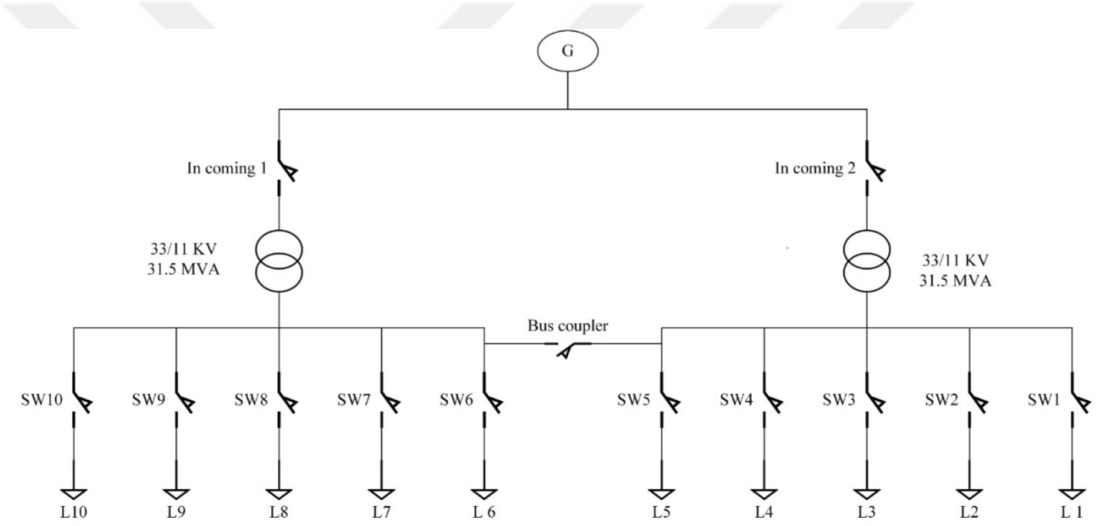
Irak'ta, ülkenin başkenti Bağdat'ta bulunan ana kontrol ve izleme merkezi, ülkenin elektrik şebekesinin kontrol ve izlenmesini denetlemektedir. Bu merkez, tüm il ve şehirlerdeki yükleri takip etme ve yönetme işlevini yerine getirmektedir.

3.2 İşlemlere girilecek verilerin toplanması

Irak'taki Al-Hussein Trafo Merkezi, Ramadi şehrinde bulunan Ulusal Operasyon ve Kontrol Merkezi'nden sorumludur ve elektrik yükü verileri buradan toplanmaktadır.

Trafo merkezi, on farklı elektrikli besleyiciden oluşmaktadır ve çeşitli müşterilere hizmet vermektedir. İstasyon, Şekil 3.1'de gösterildiği gibi konut müşterileri, devlet kuruluşları, endüstriyel besleyiciler ve ticari besleyiciler dahil olmak üzere çeşitli müşterilere hizmet vermektedir. Aşağıda Al-Hussein Trafo Merkezi'ndeki fiderlerin dağılımı verilmiştir :

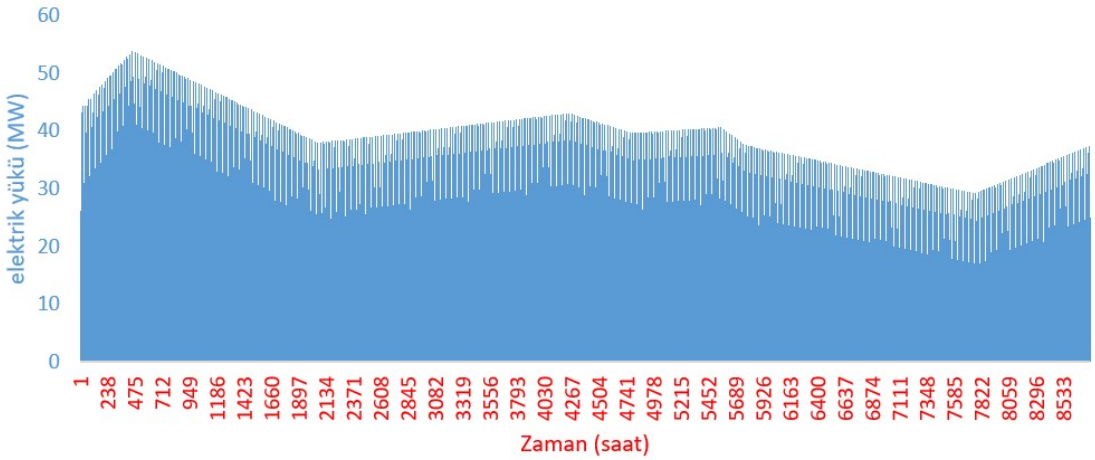
- L1, L2, L3, L7 ve L8: Konut müşterilerine hizmet veren besleyicilerdir.
- L4 ve L6: Devlet kurumlarının besleyicisidir.
- L5 ve L9: Endüstriyel müşterilere hizmet veren besleyicilerdir.
- L10: Ticari müşterilere hizmet veren besleyicidir.



Şekil 3.1 Al-Hussein Dağıtım 33/11,5 kV 31,5 MVA Trafo Merkezi

Veriler, 2018, 2019 ve 2020 yıllarını kapsamaktadır ve saat bazında (günde 24 okuma) sunulmuştur. Bu veriler, MW (Megavat) cinsinden maksimum saatlik elektrik yükünü temsil etmektedir. Yıllık olarak toplamda 8760 okuma yapılmıştır, bu da her saatinin bir okuma değeri olduğu anlamına gelir.
Ayrıca, hava durumu verileri de sunulmuştur ve bunlar sıcaklık değerlerini °C cinsinden ve nem değerlerini % olarak içermektedir. Hava durumu verileri, NASA'nın dünya çapındaki enerji kaynakları veri seti tahminlerinden elde edilmiştir. Bu veriler, sıcaklık ve nem değerlerini gözlemlemek için kullanılmıştır.
Verilerde yer alan tarih, saat, gün ve ay bilgileri, verilerin zamanla ilişkilendirilmesi ve düzenlenmesi amacıyla kullanılmıştır. Bu bilgiler, elektrik yükü ve hava durumu verilerinin belirli tarih ve saatlere atanan değerlerini göstermektedir.
Bu veri seti, elektrik yükünün zamana bağlı olarak nasıl değiştiğini anlamak, talep tahminleri yapmak ve enerji yönetimi stratejileri geliştirmek için kullanılabilir. Aynı

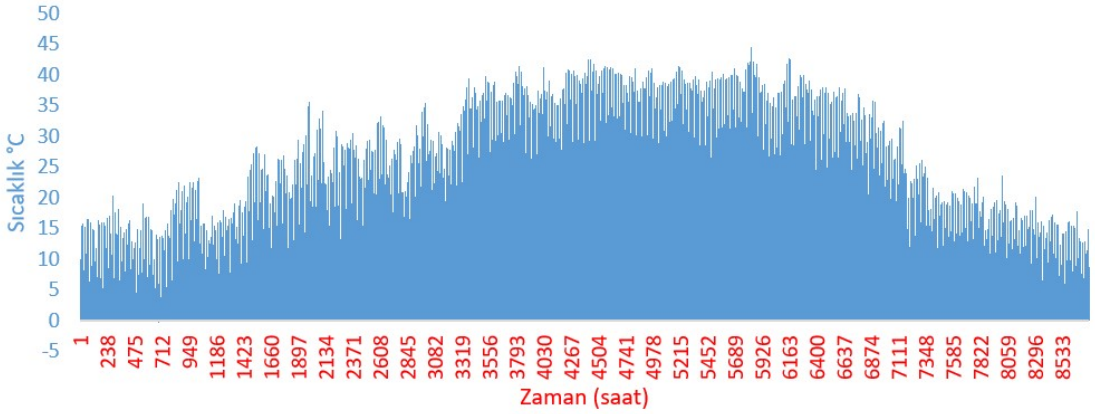
zamanda, hava durumu verileriyle birlikte analiz edilerek, elektrik yükünün hava koşullarından nasıl etkilendiği de incelenebilir.
Elektrik yükü profili, bir tüketim modelini analiz etmek için temel bir unsurdur. 2020 yılında kullanılan eğitim ve test için saatlik tüketim dalgalanmalarını gösteren bir yük profili analizi yapılmıştır. Şekil 3.2, elektrik tüketimindeki tarihsel eğilimi göstermektedir. Kış aylarında tüketim değeri diğer mevsimlere göre genellikle daha yüksektir. Şekil 3.2 aynı zamanda zaman faktörünün önemini vurgulayarak, yük profili hakkında önemli ayrıntıları içermektedir.



Şekil 3.2 Al-Hussein trafo merkezinin 2020'deki saatlik yükünün dalgalanması

Hava faktörleri, yük tahmini için en popüler faktör kategorilerinden biridir. Bu faktörler arasında sıcaklık, yağış, rüzgar hızı ve yönü, bulut örtüsü, nem gibi hava parametreleri sıklıkla kullanılır. Bu parametreler, sayısal veya nominal olarak ifade edilebilir ve yük tahmininde önemli bir rol oynar.
Bu hava faktörleri arasında sıcaklık en önemli olanıdır. Sıcaklık, insanları doğrudan etkileyen bir faktör olduğundan, uzun bir geçmişi olan sıcaklık ölçümleri kullanılmaktadır. Sıcaklık düştükçe, insanlar sıcaklığı korumak için daha fazla enerjiye ihtiyaç duyarlar ve bu da elektrik tüketimini artırır. İnsanlar genellikle sıcaklık arttıkça serinlemek veya ısıtmak için elektriği kullanır. Bu nedenle, sıcaklık ile elektrik yükü arasında güçlü bir ilişki vardır.
Sıcaklık ve elektrik yükü arasındaki ilişki, uzun süredir gözlemlenmektedir. Sıcaklık arttıkça genellikle elektrik yükü de artar. Bu ilişki, yük tahmini tekniklerine uygulanır ve tahminlerin doğruluğunu artırmaya yardımcı olur.
Şekil 3.3, 2020 yılı için saatlik sıcaklık verilerinin zaman içindeki eğilimini göstermektedir. Şekilde görüldüğü gibi, sıcaklık yaz aylarında yükselirken kış aylarında düşmektedir. Bu sıcaklık eğrisi, elektrik yükü ve tahmin süreçleri üzerinde

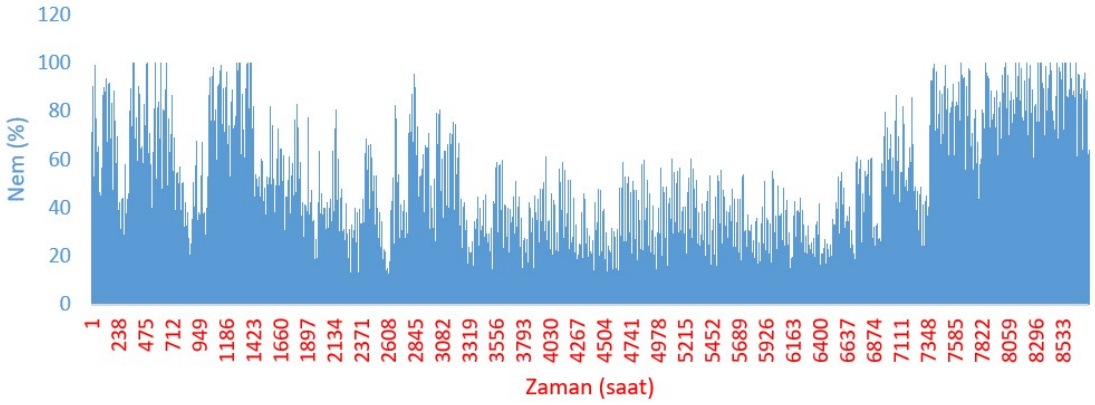
de etkili olabilir. Bu etkiler, daha sonra detaylı bir şekilde gösterilecektir.



Şekil 3.3 2020'de Ramadi şehrinin sıcaklık farkı

Nem, yaygın olarak ölçülen ve kolayca erişilebilen bir hava durumu öğesidir. Diğer hava parametreleriyle birlikte sıcaklık gibi, belirli iklim koşullarında elektrik yük davranışlarını tanımlamak için kullanılabilir. Şekil 3.4, 2020 yılı için zamana göre saatlik nemin yüzde olarak değişimini göstermektedir. Şekil 3.3 ve Şekil 3.4 kıyaslandığında, nem faktörü ile sıcaklık faktörü arasında ters bir ilişki olduğu görülmektedir. Bu durum, diğer yılların genel eğilimine uygun bir şekilde ortaya çıkmaktadır. .

Sıcaklık, nem ve elektrik yükü verilerinin analizi, bu parametreler arasındaki ilişkiyi anlamamıza yardımcı olabilir. Bu analiz, elektrik yükü tahminlerini iyileştirmek için hava faktörlerinin nasıl kullanılabileceğini ve gelecekteki enerji taleplerini daha doğru bir şekilde tahmin etmek için nasıl değerlendirilebileceğini göstermektedir.



Şekil 3.4 Ramadi şehrinin 2020'deki nem değişimi

3.3 Verilerin işlenmesi

Veri analizi, geçmişte çeşitli yöntemlerle işlenmiştir. İstatistiksel analiz kullanmak için en temel yaklaşım, indirgeyici hesaplama araçlarını kullanmaktır. Ancak, büyük veri kavramının daha yaygın hale gelmesiyle birlikte, değişken sayısı da artmış ve konu daha karmaşık hale gelmiştir. Bu durum, hesaplamaları oldukça zorlaştırır ve hatta bilgisayarların bile yetersiz kalmasına neden olabilir [13].

Her veri analizi durumu dikkatlice programlama veya kodlama gerektirir ve her yeni faktörü dikkate almak önemlidir. Bu durum, sorunu daha karmaşık hale getirir. Bu nedenle, bu tür yoğun işler için bilgisayar sistemlerinin kullanılması gereklidir. Teknoloji ilerledikçe, bilgisayarların katkısı kaçınılmaz hale gelmiş ve günümüzde bu alanda performans gösterebilen ve insanlardan daha iyi performans gösterebilen "daha akıllı" makinelerin ihtiyaç duyulduğu bir noktaya gelinmiştir.

Ayrıca, veri işleme alanında da benzer bir durum söz konusudur. Çoğu zaman, ölçüm ekipmanından elde edilen veriler yanlış, düzensiz ve dağınık olabilir ve doğrudan makine öğrenimi algoritmalarında kullanıma uygun olmayabilir [1].

Verilerin doğruluğu, tahmin sonuçları üzerinde önemli bir etkiye sahiptir. Dolayısıyla, bilgi yanlış veya düşük kaliteliyse, sonuçlar da yanlış veya en iyi ihtimalle düşük kalitede olacaktır. Bu nedenle, verileri hızlı bir şekilde temizlemek veya işlemek önemlidir.

Veriler, çeşitli metodolojiler ve prosedürler kullanılarak makine öğrenimi modellerinin eğitimi için temizlenebilir veya daha uygun hale getirilebilir. Veri setinin koşulları buna izin verir.

Performansı artırmak için eksik veri noktaları doldurulabilir veya eksik bölümler çıkarılabilir. Daha sonra, veriler moderasyon amacıyla düzleştirilebilir veya örneklendirilebilir ve son olarak, veriler eğitim ve test için kümeler halinde ayrılarak öğrenme modelinin daha doğru ve kapsamlı bir şekilde değerlendirilmesi sağlanabilir.

Veri setlerindeki eksik verilerin sebepleri çeşitlilik gösterebilir. Ölçüm cihazlarının arızalanması, veri kaybı, ölçümleri yapan firmanın iş süreçlerinde değişiklikler gibi faktörler eksik verilere neden olabilir. Bu nedenle, eksik veri etkisini en aza indirmek önemlidir.

Eksik verilerin işlenmesi çeşitli yöntemlerle gerçekleştirilebilir. En basit ve yaygın yaklaşım, eksik değerler içeren satırları veya hatta sütunları tamamen çıkarmaktır. Ancak, bu yöntem etkili olmayabilir çünkü eksik veri içeren satırlar veya önemli veri içeren sütunlar bulunabilir.

Bazı araştırmacılar ve veri analistleri eksik verilerin doldurulmasını tercih ederler. Ancak, eksik verileri doğru veya eşit değerlerle değiştirmek genellikle zor bir görevdir. Bu tez çalışmasında, eksiklik, boşluk veya değer eksikliği gibi durumlar bulunmamaktadır, çünkü algoritmada kullanılan veri tablolarında eksiklikler kontrol

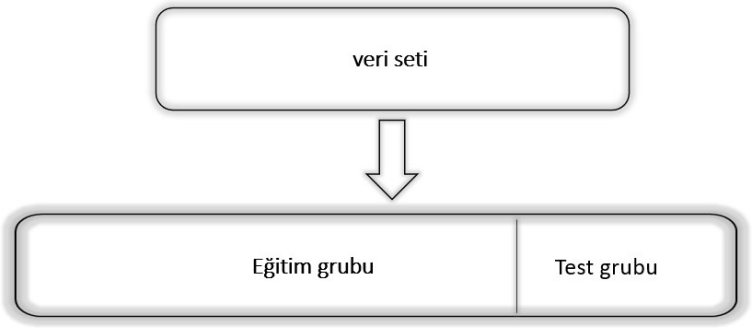
edilmiş ve teyit edilmiştir. Parametre değerlerinin değişim yüzdelerini belirlemek için belirli bir süre için önceki gün ve önceki hafta değerleriyle eşleştirme ve karşılaştırma yapılmıştır. Bu bilgiler algoritmaların uygulanması sürecinde dikkate alınacaktır. Bu hususlar göz önüne alındığında, veri hazırlama, makine öğrenimi içeren herhangi bir projede en önemli aşamalardan biridir. Bununla birlikte, güç sistemlerindeki ek sorumluluklar ve yüksek kalite talepleri göz önüne alındığında, bu aşama özellikle önemlidir.

3.4 Verilerin Bölünmesi

Bir modelin eğitimi için kullanılan verilerin güvenilir olması ve ilgili faktörleri doğru şekilde yansıtması önemlidir. Ancak, modelin doğruluğunu ve kararlılığını doğrulamak için yeni bir veri seti kullanılması gerekmektedir. Makine öğrenimi sistemine genel olarak iki bölümden oluşan bir veri seti girişi yapılır: eğitim verileri ve test verileri. Eğitim verileri, modele veya örnek veri kümesine açık bir şekilde sunulan verilerdir. Bu veriler, modelin eğitilmesi ve öğrenme algoritmalarının uygulanması için kullanılır. Test verileri ise modelden veya örnek veri setinden gizlenir ve modelin doğruluğunu değerlendirmek için kullanılır [10].

Şekil 3.5'de gösterilen prosedür, verilerin bölünmesi için en basit ve yaygın yöntemi göstermektedir. Genellikle, toplam verilerin %80, %70, %60 gibi bir yüzdesi eğitim için ayrılırken, kalan veriler test için ayrılır. Bu yöntem, çok büyük veri kümelerini içeren yıllarca süren gözlemlerle iyi çalışır. Ancak, daha küçük veri kümelerinde, modelin genel durumunu tam olarak yansıtmayabilir, çünkü eğitim sürecinden önemli bir veri kesiti çıkarılmış olabilir.

Makine öğrenimi algoritmalarının veri eğilimlerini iyi bir şekilde öğrendiğine dikkat etmek önemlidir. Bu nedenle, eğitim ve test verilerinin temsil yeteneği, modelin genel performansını doğru bir şekilde yansıtmak için önemlidir. Veri bölümü, modelin doğruluğunu değerlendirmek ve genelleştirme yeteneğini test etmek için kullanılan önemli bir adımdır.



Şekil 3.5 Tüm veri setinin bir eğitim ve test grubuna bölünmesi

3.5 Yük Tahmin Yöntemleri

Yük tahmini konusunda birçok çalışma yapılmış olup, bu çalışmalar genellikle döneme veya araştırmacının önerdiği tahmin stratejisine dayanmaktadır [2]. Yük tahmini araştırmalarını sınıflandırmanın bir başka yöntemi ise kullanılan matematiksel tekniklere göre yapılmaktadır. Tahmin tekniklerini üç temel kategoriye ayırmak mümkündür, bunlar Şekil 3.6'da gösterilmiştir.

1. Geleneksel Yük Tahmini Yöntemleri.
2. Değiştirilmiş Teknikler.
3. Hesaplama Teknikleri.

Yük tahmini çalışmaları genellikle bu kategorilerden birine veya birkaçına ait yöntemleri kullanarak yapılır. Her bir kategori, farklı avantajlar ve kısıtlamalar sunar ve seçim genellikle uygulanacak senaryo ve mevcut veri durumuna bağlı olarak yapılır.



Şekil 3.6 Yük tahmini yöntemleri için şematik gösterim

3.5.1 Geleneksel yük tahmini yöntemleri

Elektrik sistemlerinin planlanması için geleneksel yük tahmini yöntemleri önemli bir konudur. Geleneksel yük tahmin yöntemleri, temel istatistiksel yöntemleri kullanarak yük tahmini yapmayı içerir. Örneğin, hareketli ortalama, regresyon analizi, zaman serisi analizi gibi yöntemler geleneksel yük tahmini yaklaşımlarına örnek olarak verilebilir. Bu yöntemler genellikle basit ve kolay anlaşılır olması nedeniyle tercih edilir. Bu yöntemler, uzun bir geçmişe sahip olmaları nedeniyle eski teknikler olarak kabul edilmektedir. Ancak, yeni yöntemlerin geliştirilmesiyle birlikte, elektrik yükü tahmini alanında daha doğru sonuçlar elde etmek mümkün hale gelmiştir. Sonuç olarak, daha düşük hata oranları elde etmek ve daha iyi tahminler yapmak için yeni yöntemlerin geliştirilmesi ve geleneksel yaklaşımların diğer deneylere dahil edilmesi önemlidir [7].

3.5.1.1 Regresyon yöntemi

Regresyon modeli, hava durumu gibi çeşitli faktörlerle enerji tüketimi gibi bir yük arasındaki ilişkiyi modellemek için kullanılan popüler bir istatistiksel tekniktir. Bu strateji, yükün tüketimini etkileyen değişkenlerle birlikte yükün bir yük etkisine doğrusal olarak bağlı olduğunu varsayar .
Regresyon yöntemine ait matematiksel model Denklem 3.1'de verilmiştir [4].

$$L(t) = Ln(t) + \sum a_i x_i(t) + e(t) \tag{3.1}$$

Bu denklemde, $L(t)$ zamanındaki tipik veya standart yüktür, a_i tahmini "yavaş değişen" katsayıları, $x_i(t)$ hava durumu gibi bir dizi bağımsız etkileyen faktörü, $e(t)$ ise gürültü

bileşeni ve n, gözlem sayısını belirtir.
Bu yöntemin etkinliği, gelecek beklentilerini türetmek için tarihsel bilgilere dayanan değişkenlere bağlıdır. Tahmin modeli aracılığıyla hızlı bir şekilde tanımlanabilen herhangi bir yanlış bilgiyi bulma ve tespit etme yöntemidir.
Bu teknolojiyi kullanan tahmin prosedürü, belirli girdiler ve veriler gerektirir. Çapraz doğrulama araçları kullanılarak, bu veriler sistemden önceki verilere dayanarak elde edilebilir. Ayrıca, süreç günlük yük değişikliklerine, mevsimsel yük değişikliklerine, yıllık yük artışına ve diğer verilere bağlı olarak şekillenir.

3.5.1.2 Çoklu doğrusal gerileme

Yük tahmininde yaygın ve sıkça kullanılan bir yöntem olan regresyon modeli, araştırmacılar tarafından sıklıkla kullanılmaktadır. Bu yaklaşıma göre, yük, akımı etkileyen açıklayıcı faktörlerin doğrusal bir kombinasyonu olarak düşünülebilir. Ayrıca, tahmin sonucunu etkileyen diğer faktörler de bulunmaktadır. Bu modelleme tekniği kullanılarak bir veya daha fazla bağımsız faktör ile bağımlı değişken arasındaki ilişki incelenir.
Bu yöntemin amacı, bağımsız faktörlere dayanarak gerçek değer hakkında tahminler yapmaktır. Bu tahminler, Denklemde 3.2'de gösterildiği gibi ifade edilebilir [20].

$$Y = \beta_0 + \beta_1\chi_1 + \beta_2\chi_2 + \beta_3\chi_3 + \beta_n\chi_n + \varepsilon \tag{3.2}$$

Burada, Y bağımlı değişkeni temsil eder ve β_0, β_1, β_2 ,.... β_n, katsayıları açıklayıcı faktörlerin etkisini temsil eder. χ_0, χ_1, χ_2, ... χ_n ise bağımsız değişkenlerdir. ε ise hata terimini temsil eder, yani tahminin gerçek değerden ne kadar sapabileceğini gösterir.
Regresyon modelinin zayıf yönlerinden biri, bağımsız değişkenlerin yanlışlığından kaynaklanan hataların sonuçları etkileme potansiyelidir. Bu durum, modelin uygulanabilirliğini sınırlayan bir faktördür. Ancak, değişkenler gerçeğe daha yaklaştıkça, hata miktarının azaldığı ve tahmin hatalarının azaldığı görülür. Bu da daha doğru sonuçlar elde edilmesini sağlar.
Gelecekteki yoğun saatler hakkında bilgi elde etmek ve belirlemek için regresyon yöntemi kullanılarak bir model geliştirilir. Bu model, günlük yoğun saatlerin başlangıç girdisine dayalı olarak hesaplanır. Bu yöntem genellikle etkili sonuçlar verir, çünkü çeşitli değişkenlerden etkilenir. Özellikle kısa vadeli yük tahmini (STLF) bağlamında, bu yöntemin doğru sonuçlar ürettiği ve diğer geleneksel süreçlerle eşleştirildiğinde uyumlu sonuçlar sağladığı keşfedilmiştir [6].
Bu şekilde, regresyon modeli günlük yoğun saatlerin tahmin edilmesi gibi önemli elektrik yükü tahmini sorunlarında etkili bir araç olarak kullanılmaktadır. Ancak, modelin doğruluğunu artırmak ve güvenilir tahminler elde etmek için doğru ve

güncel verilerin kullanılması, modelin uygun şekilde uyarlanması ve diğer analitik yöntemlerle desteklenmesi önemlidir.

3.5.1.3 Üstel Düzeltme

Yük tahmini için yaygın olarak kullanılan bir model olan bu yöntem, geçmiş verilerin analizine dayanır. Bu model, durağanlık, trend ve mevsimsel bileşenlerin bir kombinasyonunu içerir . Matematiksel olarak idafesi Denklem 3.3'te verilmiştir [1]. Bu modeli matematiksel olarak açıklamak için aşağıdaki denklem kullanılabilir:

$$y(t) = \beta(t)Tf(t) + e(t) \tag{3.3}$$

burada $f(t)$ işlemin uydurma fonksiyon vektörünü, $\beta(t)$ vektörün katsayısını ve $e(t)$ Gürültü bileşeni ve T Devrik işlemidir.

3.5.1.4 Yinelemeli Olarak Yeniden Ağırlıklandırılmış En Küçük Kareler (IRLS)

Yinelemeli Olarak Yeniden Ağırlıklandırılmış En Küçük Kareler (IRLS) yönteminin temel ilkesi, model parametrelerini tekrarlayan bir şekilde güncellemek için ağırlıklı en küçük kareler amaç fonksiyonunu en aza indirmektir. Bu yöntemde, her yineleme adımında gözlemlerin ağırlıkları, artıklara (tanımlanan ve tahmin edilen değerler arasındaki farklar) dayalı olarak belirlenir ve daha büyük artıklara sahip gözlemlere daha yüksek ağırlıklar verilir. Bir sonraki adım, ağırlıklı en küçük kareler optimizasyonu kullanılarak model parametrelerinin güncellenmesini gerektiren gözlemleri destekleyen daha yüksek ağırlıklarla gerçekleştirilir.
Algoritma genellikle, model parametrelerinde veya amaç fonksiyonunda belirli bir eşik değerinin altında değişiklik olmadığında yakınsama koşuluna ulaşılıncaya kadar yinelenir. Nihai çözüm, yakınsamada belirlenen tahmin edilen model parametrelerini içerir.
IRLS yöntemi, regresyon analizi gibi istatistiksel modelleme problemlerinde sıklıkla kullanılır ve maksimum olabilirlik tahminlerini elde etmek için de uygulanabilir. Ağırlıklı en küçük kareler yaklaşımı, verilere uyum sağlamak için parametreleri güncelleyen bir güçlendirme mekanizması sağlayarak, modelin daha iyi tahminler yapmasını ve daha iyi uyum sağlamasını sağlar.

3.5.2 Değiştirilmiş Teknikler

Bu tür ayarlamalarda, geleneksel tahmin yöntemleri, değişen hava parametrelerine yanıt olarak tahmin faktörlerinin otomatik olarak düzeltilebilmesi için ayarlanır. Tahmini etkileyen parametrelerin ve diğer öğelerin, yüklerin değişen özelliklerine

uyarlanabilir parametreleri koruyarak kendilerini otomatik olarak düzelttiklerine dikkat etmek önemlidir.
Çalışmaların çoğu bu türden birçok kategoriyi kullanmıştır ve bunlardan biri destek vektör makinelerine (SVM) dayalı yöntemlerdir. Bu yöntemler, verileri analiz ederek regresyon ve sınıflandırma analizinde kullanılan kalıpları bulabilme yeteneğine sahiptir. SVM, yeni ve son derece etkili bir makine öğrenimi teknolojisidir. Araştırmacılar, hava durumu bilgilerinin orta ve kısa vadede yük tahmininin doğruluğu üzerinde gözle görülür bir etkisi olmadığını bulmuşlardır [8].
Ayrıca, iki yöntem daha bulunmaktadır. Uyarlanabilir Talep AD (Aggregate Demand) ve Stokastik Zaman Serileri (STS) Tahmini. Bu yöntemler, yaygın olarak kullanılan teknikler arasındadır ve yük tahminlerini hesaplamak için zaman serilerine dayanır. Bu yaklaşımlar, her veri örneğinin otokorelasyon, eğilim veya mevsimsel değişkenlik gibi temel bir özelliği içerdiğini varsayar. Bu yöntemlerin temel amacı, mevcut verilerle eşleşen kalıpları biriktirmek ve ardından zamanla değişen tahmin değerlerini belirlemektir.

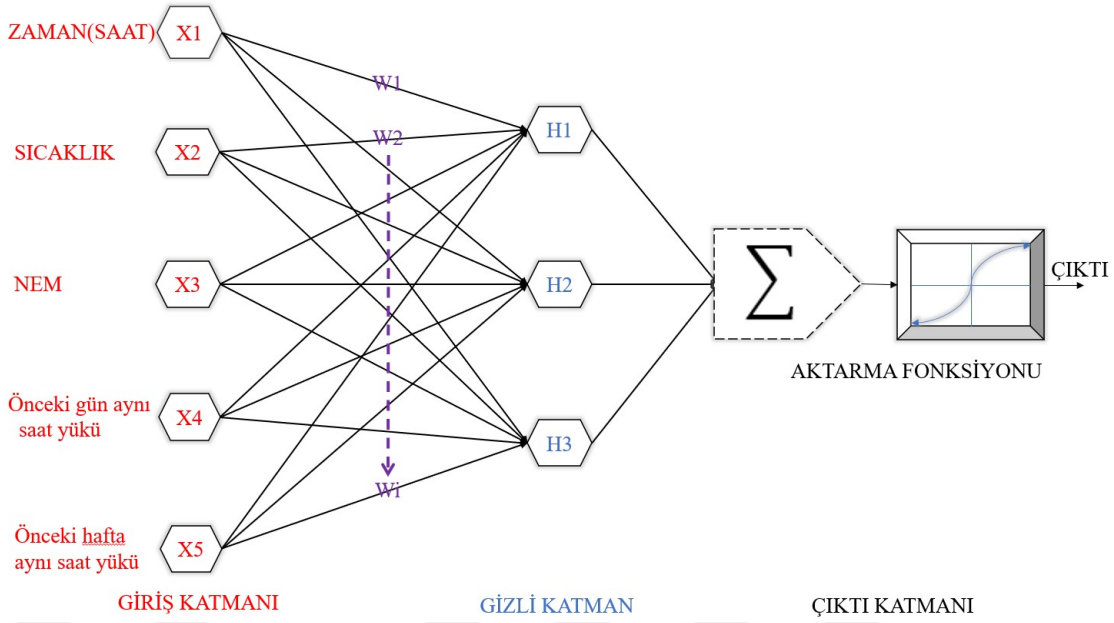
3.5.3 Yük tahmini için hesaplama teknikleri

3.5.3.1 Yapay Sinir Ağı (ANN)

Yapay sinir ağları (ANN) insan beyninin nöral dürtülerini ve düşünce süreçlerini taklit etmek amacıyla geliştirilmiş bir bilgisayar sistemi ve matematiksel bir araçtır [28]. Yapay sinir ağlarındaki temel işlem birimlerine "nöron" denir. Bu nöronlar, beyin nöronları gibi davranabilmek için girdileri ve diğer faktörleri işleyerek çalışırlar [25]. Aşağıda Şekil 3.7'de önerilen ANN modeli gösterilmektedir.

Burada X girdi, W ağırlık. H gizli katmandır.
ANN modelleri, birbirine bağlı ve katmanlar halinde organize edilmiş düğümlerden oluşur [29]. Her düğüm, bir işlem birimi olarak görev yapar. Şekil 3.7'de gösterildiği gibi, her bir düğüm belirli bir sorunu çözmek için çalışır. Her katman, kendi ağırlıklarına sahip birbirine bağlı düğümler içerir.
Nöronlar üç bileşenden oluşur: bir transfer fonksiyonu, toplama fonksiyonu ve ağırlıklara bağlı sözleşme. Yapay sinir ağlarında genellikle üç katman bulunur: girdi katmanı, gizli katmanlar ve çıktı katmanı [3]. Özel veriler girdi katmanından girilir ve geri yayılım algoritması (BP) kullanılarak her iterasyonda ağırlıklar ayarlanarak çıktı katmanına doğru iletilir [31]. Yapay sinir ağları genellikle üç giriş kullanır:

1. Gelecekle ilgili girişler.
2. Belirli bir önceki süre boyunca maksimum normal yükleri içeren geçmiş girdi.
3. Sıkıştırılabilir girdi.



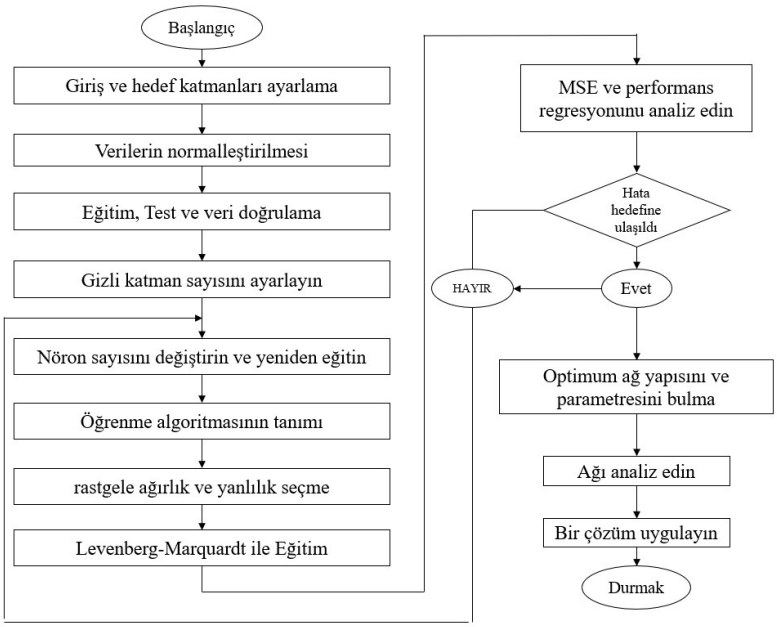
Şekil 3.7 Önerilen bir ANN modelinin şematik gösterimi

Özellik seçimi, yük tahmini gibi görevlerde yapay sinir ağı algoritmalarının performansını artırmak için eğitim sürecinde genellikle önemli bir faktördür. Bu çalışmada, belirli bir saat için MW cinsinden yük değerleri alınır ve bir önceki gün ve haftanın aynı saatine ait yük değerleriyle karşılaştırılır. Bu değerler, yük talebindeki değişiklikleri belirlemek için algoritmanın girdisi olarak kullanılır. Bu bilgi, yük tahmini için önemli olan yük talebinin artıp artmadığını belirlemek için kullanılır.
Nöronlar, yapay sinir ağlarının temel hesaplama birimleridir. Bu hücreler, doğrusal olmayan ve parametrik olmayan teknikler kullanarak birçok farklı değişkeni hesaba katabilir. Ayrıca, ANN modelleri doğrusal olmayan problemleri çözmek için doğrusal olmayan aktivasyon fonksiyonlarını kullanma yeteneğine sahiptir [32]. Yapay sinir ağları için akış şeması Şekil 3.8'de gösterilmektedir. Ağın bağlantı ağırlıklarını değiştirerek istenen hedefe ulaşmak, öğrenme algoritması tarafından kullanılan eğitim prosedürünün görevidir. Transfer fonksiyonu, bir nöronun çıkışının genliğini sınırlamak için kullanılan bir işlevdir. Her yinelemede her ağırlığı güncellemek için transfer fonksiyonunda kullanılan matematiksel ifade Denklem 3.4'te verilmiştir.

$$W_{ij}^{new} = W_{ij}^{old} + \eta \frac{\partial E}{\partial w_{ij}} \tag{3.4}$$

W_{ij} ve η sırasıyla nöronların ağırlıkları ve öğrenme oranıdır. E, Denklem 3.5 kullanılarak hesaplanabilecek hata miktarını temsil eder:

$$E = \sum_{k=1}^{L} \sum_{j=1}^{q} (b_{kj} - z_{kj})^2 \tag{3.5}$$



Şekil 3.8 Yapay sinir ağı ANN'nın akış şeması

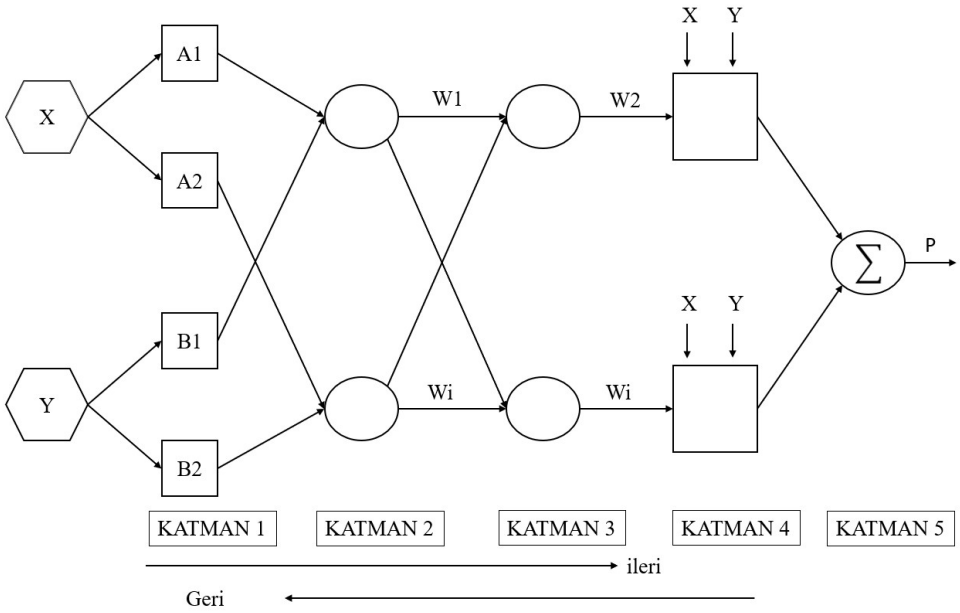
Burada, b_{kj} ve z_{kj} ANN tarafından gözlemlenen ve tahmin edilen değerlerdir [30]. Yapay sinir ağlarında doğrusal ve doğrusal olmayan transfer fonksiyonlarının kullanılması, karmaşık ve geniş kapsamlı problemlerin çözümünü mümkün kılar. İleri besleme süreci verilerin ağa beslenmesini sağlar, transfer fonksiyonları ile çıktılar hesaplanır. Geriye yayılım süreci ise hataların ağ üzerinde yayılmasını ve ağırlık güncellemelerinin yapılmasını sağlar [33]. Bu süreçler, yapay sinir ağlarının eğitimi ve performansının iyileştirilmesinde önemli bir rol oynar.

3.5.3.2 Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (ANFIS)

Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (ANFIS), bulanık mantık (FL) ve yapay sinir ağları (ANN) içeren bir hibrit sistemdir. Bu sistem, elektrik yüklerini tahmin etmek gibi yapay zeka uygulamalarında kullanılabilen bir yöntemdir. ANFIS, ANN'nin öğrenme stilini FL'nin insan mantığıyla birleştiren bir yapıya sahiptir [34]. ANFIS, belirli düğümlerin yönlendirilmiş bağlantılarla birbirine bağlandığı ağlara uyarlanabilir şekilde uygulanabilir. Her düğüm, bağlantıları birleştiren düğümlerin yanı sıra bir işlem birimini temsil eder. ANFIS'te bazı düğümler ayarlanabilirken diğerleri sabittir. Ayarlanabilir düğümlerin yalnızca tek bir çıktısı bulunur.
Uyarlanabilir düğümler, yerel hava koşulları gibi değişkenlere bağlıdır ve gerçek yük ile beklenen çıktı arasındaki farkı ölçerek önceden belirlenmiş bir hatayı en aza indirmek için bu parametreleri güncelleme kuralını kullanır. Bu güncelleme kuralı, ANFIS'in öğrenme sürecinde kullanılır ve sistem performansını iyileştirmeye çalışır.
ANFIS'in yapısı genellikle Şekil 3.9'da gösterildiği gibi 5 katmandan oluşur, bu

katmanlar belirli bir sırayla işlem yaparlar. Uyarlanabilir katmanlar kare sembolleriyle temsil edilirken, uyarlanabilir olmayan katmanlar daire sembolleriyle temsil edilir. Her katmanın belirli bir rolü ve işlevi vardır.

Şekil 3.9'da gösterildiği gibi, uyarlama kullanarak elektrik yükünün tahminine



Şekil 3.9 ANFIS Tasarım

bakıyoruz. Bulanık çıkarım sistemi dikkate alınır ve X ve Y olmak üzere iki girdisi ve P bir çıkışı vardır. Birinci dereceden bir Sugeno bulanık modeli kullanarak (IF-AND-THEN) kurallarını modellerken bunu dikkate alıyoruz ve Denklemler 3.6 ve 3.7 ile formüle ediyoruz [23].

Kural 1: IF X is A_1 AND Y is B_1 THEN

$$P_1 = p_1X + q_1Y + r_1 \tag{3.6}$$

Kural 2: IF X is A_2 AND Y is B_2 THEN

$$P_2 = p_2X + q_2Y + r_2 \tag{3.7}$$

A_1 , A_2, B_1, ve B_2 giriş üyelik fonksiyonlarıdır. Ve nöronun ayarlanmış parametreleri şunlardır: p_i, q_i ve r_i. Denklem 3.8 - 3.10 ile elde edilir.

$$p_1 = \overline{W_i} \times X_1 \tag{3.8}$$

$$q_1 = \overline{W_i} \times X_2 \tag{3.9}$$

$$r_1 = \overline{W_i} \tag{3.10}$$

Ek olarak, $W1$ ve$W2$, Denklem 3.11 ve 3.12'deki ateşleme gücü düzenlemeleridir:

$$W_1 = \mu A_1 * \mu AB_1 \tag{3.11}$$

$$W_2 = \mu A_2 * \mu AB_2 \tag{3.12}$$

μ üyelik derecesidir. Denklem 3.13 W_1 veW_2'yi aşağıdaki gibi ifade eder:

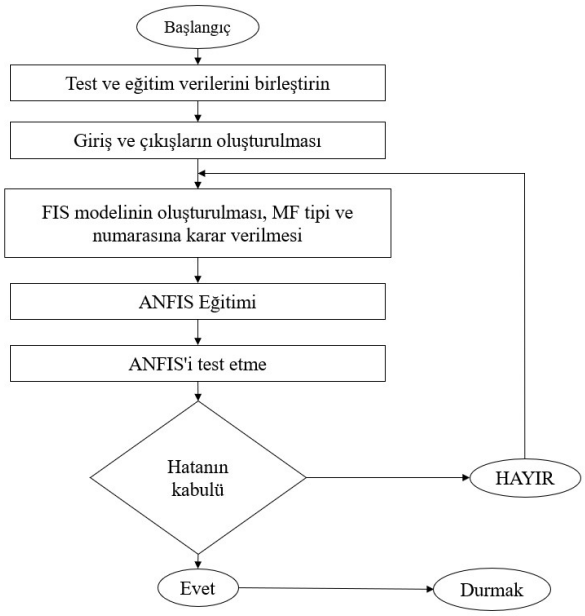
$$P = \frac{W_1 p_1 + W_2 p_2}{W_1 + W_2} = \overline{W_1 P_1} + \overline{W_2 P_2} \tag{3.13}$$

Burada, P çıkışı göstermektedir.

ANFIS, hibrit bir öğrenme algoritmasıdır ve hata geri yayılımı (EBP) ve en küçük kareler tahmincisi (LSE) tekniklerini birleştirir. EBP, ANFIS yapısının ilk katmanında uygulanır [6].
LSE ise dördüncü katmanda kullanılır. ANFIS'te, bulanık üyelik fonksiyonundan sistem çıktısına doğru doğrusal olmayan parametreler birinci katmanda kullanılır. ANFIS sistemi, farklı üyelik fonksiyonu tipleri arasında Gauss, üçgen ve yamuk gibi çeşitli fonksiyonları test edip eğitebilme özelliğine sahiptir. Bu çalışmada, üçgen tipini tercih ettik, ki bu, Denklem 3.14'te tanımlanmıştır.

$$f(x,a,b,c) = \begin{cases} 0 & c \leq x \leq a \\ \dfrac{x-a}{b-a} & a \leq x \leq b \\ \dfrac{c-x}{c-b} & b \leq x \leq c \end{cases} \tag{3.14}$$

Burada x giriş verisidir, a standart sapmayı temsil eder, b eğimler her zaman pozitif olmalıdır ve c ortalamayı temsil eder.
Bu aşamada, ANFIS'e bir giriş sağlanır. Bu giriş, üyelik fonksiyonlarıyla bulanıklaştırılır ve en iyi üyelik fonksiyonu parametrelerini elde etmek için normal ve anormal koşullar altında ölçülen eğitim verileri kullanılarak eğitilir. ANFIS'in eğitim ve test akış şeması Şekil 3.10'da gösterilmiştir.



Şekil 3.10 ANFIS eğitim ve test sürecinin akış şeması

3.5.3.3 Optimizasyon Teknikleri

Bazı organizmaların özel yaşamlarıyla ilgili bilgi edinme ve bu bilgileri mühendislik alanlarının geliştirilmesinde kullanma konusunda araştırmacılar sürekli olarak ilgilenmektedir. Bu programların avantajları, sonuçların geçerliliğini artırması ve özellikle yük tahmini gibi prosedürler sırasında hataları azaltmasıdır. Bu organizmaların davranışları, özel metodolojilere ve bilgisayar algoritmalarına dönüştürülerek mühendislik zorluklarının çözümünde kullanılır [35]. Bu şekilde, araştırmacılar doğadan ve organizmaların doğal davranışlarından ilham alarak, mühendislik alanlarında yenilikçi çözümler geliştirmek için bu bilgileri kullanabilirler. Bu tür yaklaşımlar, özellikle yapay zeka, optimizasyon, veri analizi ve sistem tasarımı gibi alanlarda kullanılarak, karmaşık mühendislik problemlerinin çözümünde etkili olabilir.

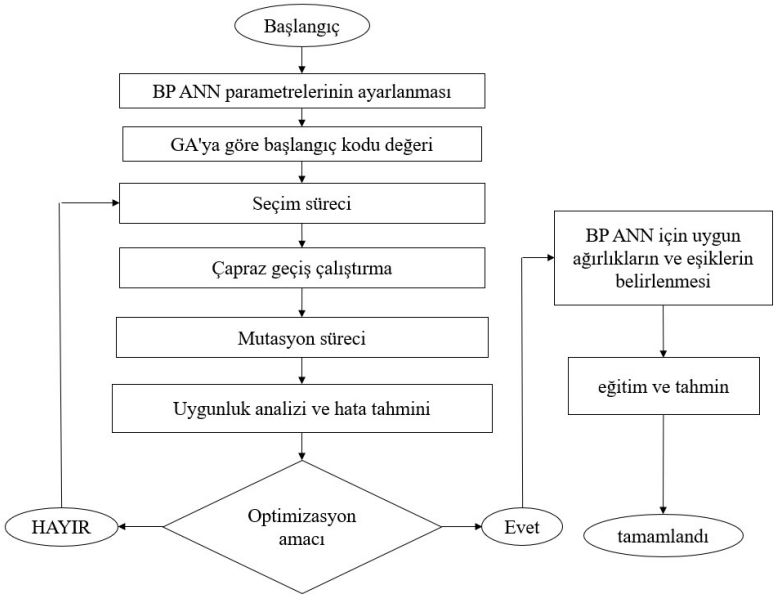
3.5.3.4 Genetik Algoritma Tekniği GA

Genetik Algoritma (GA), evrimsel biyolojiden ilham alarak geliştirilen bir yöntemdir ve küresel minimumu bulmak ve doğrusal olmayan optimizasyon sorunlarını çözmek için kullanılır. GA, evrimsel psikoloji ve teknolojinin tarihinden ilham alarak adını almıştır. Bu yöntem, mevcut bir çözümün ilk nesliyle başlar ve ardışık nesiller oluşturarak çözümü iyileştirir.GA'nın işleyişi şu adımlardan oluşur: başlangıç popülasyonu oluşturma, geçiş, mutasyon, uyum ve seçim [7].
Bu adımlar kullanılarak çeşitli rasgele parametrelerle bir çözüm kümesi geliştirilir. GA, nokta gruplarını arayabilen ve sürekli veya periyodik fonksiyonları içeren geniş

bir fonksiyon yelpazesinde etkili olabilir. Ayrıca, iş bilgilerini kullanarak çözümler üretir ve zor problemleri çözmekte başarılıdır. Hızlı ve etkili çalışmasıyla geleneksel tekniklere göre avantaj sağlar. Ayrıca, uygulanabilir seçenekler bulabilme esnekliği vardır ve geniş bir uygulama yelpazesinde verimli ve güvenilir sonuçlar üretebilir.
GA'nın bazı zayıf noktaları da bulunmaktadır, örneğin yanlış veya rastgele parametrelerle kötü sonuçlar üretebilir. Her üreme adımında, en eski ve en uygun bireylerin kalıntılarından yeni bir sentetik popülasyon oluşturulur. Geçmiş verileri etkili bir şekilde kullanarak, daha iyi performans göstermesi beklenen yeni bir arama noktası hakkında varsayımlarda bulunur [4]. Genetik algoritma, daha fazla veriyi dikkate alarak ve potansiyel olarak daha geniş arama alanları sunarak en iyi sonuçları elde etmede etkilidir .

3.5.3.5 GA Tarafından Optimize Edilmiş ANN

Genetik Algoritma (GA), iş yerindeki durumlara uygulanabilen kromozomlu bir popülasyon oluşturur. Her popülasyondaki kromozomların uygunluğu değerlendirilir ve ilerleme adım adım sağlanır. Ebeveynler, çaprazlama operatörü kullanılarak yeni yavrular oluşturmak için çaprazlanır. Çaprazlama yapılmadığında, yavrular ebeveynlerin tam bir kopyası olur. Ayrıca, mutasyon olasılığı kullanılarak her lokusta yeni mutasyonlar oluşturulur. Yeni yavrular popülasyona eklendikten sonra, yeni bir popülasyon oluşturulur ve bu süreç toplam iterasyon sayısı tamamlanana kadar devam eder. Son şart karşılandığında algoritma durur ve mevcut popülasyon içinde en uygun çözüm seçilir. Uygunluk korunarak popülasyon birleştiğinde algoritma otomatik olarak sona erer [36].
GA ve ANN birleştirildiğinde, GA optimizasyonu ile ANN modelinin ağırlıkları ve eşikleri belirlenir. Bu sayede, YSA'nın yerel minimumlarda takılı kalma sorunu aşılmış olur. GA, YSA yapısını belirlemek ve optimizasyonunu gerçekleştirmek için kullanılır. GA'nın işlemleri, ANN ağırlıklarını ve eşiklerini belirlemek için iteratif bir şekilde uygulanır. Şekil 3.11'de ANN-GA optimizasyonunun akış şeması gösterilmiştir.



Şekil 3.11 ANN-GA optimizasyonunun akış şeması

3.5.3.6 Veri Kümeleri Normalleştirme

Veri kümelerini normalleştirmek için kullanılan çeşitli yöntemler vardır, örneğin standardizasyon, [0, 1] ölçekleme ve [-1, 1] ölçekleme gibi. Normalizasyon, verilerin ölçeğini eşitlemek için kullanılır. Bu modülde standardize edilen veriler, sinir ağları ve genetik algoritmalar tarafından tahmin için girdi verileri olarak kullanılır. Standardizasyon işlemi, her bir değerin ortalamadan farkının standart sapmaya bölünmesini içerir [21].

Çalışmada, normalize edilecek değerlerin bir vektörü, bu değerler aralığındaki en düşük değeri ("MinX") ve aralıktaki maksimum değeri ("MaxX") kabul eden "Normalize Fcn" adlı bir MATLAB işlevi kullanılmıştır. Bu fonksiyon, [0, 1] aralığındaki giriş verilerini normalleştirmek için en düşük değeri çıkarır ve minimum ve maksimum değerler arasındaki aralığa böler. Normalleştirme değerleri "xN" çıkış değişkeninde korunur. İlgili formül, Denklem 3.15'te gösterildiği gibi, "Normalize Fcn" işlevinin ilk satırında kullanılır.

$$X_N = (X - X_{Min})/(X_{Max} - X_{Min}) \tag{3.15}$$

Bu formülde, her girdi vektörü X öğesinden en küçük değer çıkarılır ve sonuç, minimum ve maksimum değerler arasındaki aralığa bölünür. Bu işlem, verileri [0, 1] aralığına normalize etmek için kullanılır. Çıkış değişkeni X_N, normalleştirilmiş değerleri saklamak için kullanılır.

3.5.3.7 Bir GA'da geçiş işlemi (Crossover operation)

MATLAB işlevi genetik algoritmadaki çaprazlama işlemini gerçekleştirir. İki ebeveyn birey ($x1$ ve $x2$) için bir çaprazlama işlemi yapılır ve ebeveynlerin genetik verileri birleştirilerek iki yavru ($y1$ ve $y2$) oluşturulur.

Çaprazlama işlemi için kullanılan gamma parametresi, ebeveynlerin karışma düzeyini kontrol eder. Gamma, 0 ile 1 arasında herhangi bir değer alabilir ve negatif değerler de kabul ederek yavruların ebeveyn aralığı dışında üretilmesine izin verir. Ayrıca, bu işlemde ebeveyn bireylerin her bir öğesine rasgele bir alfa değeri atanır. Alfa değerleri, -gamma ile +gamma arasında bir düzgün dağılım kullanılarak elde edilir. Alfa, $x1$ ile aynı boyutta bir vektördür.

Daha sonra, bu işlev, ebeveynlerin genetik bilgilerinin bir kombinasyonunu kullanarak $y1$ ve $y2$ bireylerini oluşturur, işlem Denklemler 3.16 ve 3.17'deki gibi formülize edilir.

$$y1 = Alpha * x1 + (1 - Alpha) * x2 \tag{3.16}$$

$$y2 = Alpha * x2 + (1 - Alpha) * x1 \tag{3.17}$$

Ardından, fonksiyon yavruların $VarMin$ ve $VarMax$ olarak tanımlanan arama alanı sınırlarını aşmadığından emin olmalıdır. Bu aralık, $[VarMin, VarMax]$ olarak belirtilir ve Denklem 3.18, 3.19, 3.20 ve 3.21'de gösterildiği gibi $y1$ ve $y2$ bireylerini kırpma işlemi için kullanılır.

$$y1 = max(y1, Var_{Min}) \tag{3.18}$$

$$y1 = min(y1, Var_{Max}) \tag{3.19}$$

$$y2 = max(y2, Var_{Min}) \tag{3.20}$$

$$y2 = min(y2, Var_{Max}) \tag{3.21}$$

Fonksiyon sonunda iki yavru bireyi, $y1$ ve $y2$'yi üretir.

3.5.3.8 Genetik algoritmadaki mutasyonlar

Genetik algoritmaların mutasyon operatörü genellikle aşağıdaki adımları içerir:

1. Mutasyon oranını toplam öğe sayısına bölerek ve en yakın tamsayıya yuvarlayarak, mutasyona uğraması gereken öğelerin sayısını belirler.

2. Rasgele örnekleme işlevini kullanarak, x vektöründen rasgele ve benzersiz endekslerin bir vektörünü seçer. Bu seçilen endeksler, mutasyona uğraması gereken öğeleri temsil eder.

3. Rasgele örnekleme işleminde seçilen ilk endeksi kullanarak, mutasyon boyutunu hesaplar. Bu çalışmada, mutasyon boyutu, x'in maksimum ve minimum değerleri arasındaki farkın 0.1 katı olarak belirlenir.

4. Girdinin bir kopyasını oluşturur ve seçilen endekslerdeki öğeleri değiştirmek için normal dağılımdan rastgele değerler ekler. Bu değerler, ortalama değeri 0 ve mutasyon boyutu sigmasına eşit bir standart sapmaya sahip olan normal dağılımdan seçilir.

5. Değiştirilen öğelerin değerlerini VarMin ve VarMax tarafından tanımlanan aralıklar içinde kırpmak için min ve max fonksiyonlarını uygular. Böylece, mutasyon sonucunda elde edilen öğeler arama alanı sınırlarını aşmaz.

Bu adımlar, genetik algoritmanın çeşitliliğini ve keşif yeteneğini artırmak için mutasyonu uygular ve yeni çözüm alanlarında arama yapabilmesini sağlar.

3.5.4 Hata Doğrulama

Kullanıcı, eğitilen algoritmanın testten sonra düşük hata tahminleri üretebildiğini doğrulayabilir [36]. Çalışmada önerilen algoritmanın Denklem 3.22 ve 3.23 yardımıyla elde edilen Ortalama Mutlak Yüzde Hatası (MAPE) ve kök ortalama kare hatası (RMSE) değerlerini azalttığı ve test seti üzerinde düşük hata tahminleri ürettiği doğrulanmıştır. Bu durum, algoritmanın tahmin performansının iyi olduğunu ve veri setindeki gözlemleri başarılı bir şekilde tahmin edebildiğini göstermektedir.

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - y_i')^2} \tag{3.22}$$

$$MAPE = \frac{1}{n}\sum_{i=1}^{n}\frac{y_i - y_i'}{y_i} * 100 \tag{3.23}$$

Burada n örnek sayısı, y_i' modelin tahmin edilen değeri ve y_i gerçek ve istenen değerdir.

4
METODOLOJİ

Yük tahmininde kullanılan yöntemler MATLAB 2022a programında modellenmiş ve 2.4 GHz işlemcili 8 GB RAM'li Core i5 özelliklerine sahip bilgisayarda analiz edilmiştir.

4.1 ANN ile Yük Tahmini

İlk olarak, Al Hussein istasyonundan bir yıl boyunca (1 Ocak 2018'den 31 Aralık 2018'e kadar) Irak'taki elektrik yüküne ilişkin hava durumu verileri ve istatistikleri kullanıldı. Bu veriler, zaman, sıcaklık ve nem bilgilerini içerir. Zaman verileri tarih, saat, gün ve ay olarak ayrılmıştır. Sıcaklık verileri Celsius derecesi olarak ve nem verileri yüzde olarak kaydedilmiştir. Veriler, saat bazında dağıtılmıştır, yani her saat için veriler sağlanmıştır. Toplam süre 365 gündür, bu nedenle her sütun 8760 karakter uzunluğundadır. Toplamda 7 kolon bulunmaktadır, bu nedenle Excel dosyasında toplam 61.320 hücre vardır.
Bu veriler, MATLAB'a aktarılmıştır. Excel sayfasından 8760 satır ve ilgili sütunlar içe aktarıldı. Her sütuna, yük tahmini sürecindeki etkisini açıklamak için belirli bir değişken verilmiştir. Veri seti, eğitim seti ve test seti olmak üzere iki gruba ayrılmıştır. Eğitim seti, yapay sinir ağı modelinin eğitilmesi için kullanılan veri setidir. Modelin öğrenme algoritması bu veri setine uygulanarak ağırlıklar ve bias değerleri ayarlanır. Test seti ise eğitilen modelin performansını değerlendirmek için kullanılan ayrı bir veri setidir. Modelin eğitim sırasında görmediği verilerle gerçekleştirilen tahminlerin doğruluğunu test etmek için kullanılır. Bu şekilde, veriler MATLAB'da düzenlenmiş ve eğitim ve test setlerine ayrılmıştır.

- %80 eğitim — %20 test.
- %70 eğitim — %30 test.
- %60 eğitim — %40 test.
- %50 eğitim — %50 test.

Eğitim setini oluşturmak için aşağıdaki girdiler kullanılmıştır:

1. Zaman (saat).
2. Sıcaklık (°C).
3. Nem (%).
4. Önceki Gün Aynı Saatteki Yük (MW).
5. Önceki Hafta Aynı Gün Aynı Saatte Yük (MW).

ANN gizli katmanlardaki nöron sayısı olarak 5, 10 ve 15 kullanılarak gerçekleştirildi. Bu ANN, geri yayılım eğitimi yöntemiyle eğitildi ve eğitim için Levenberg-Marquardt algoritmasının eğitim fonksiyonu kullanıldı. Bu eğitim prosedürü, düşük hata oranı elde etmek için ANN'ın iç ağırlıklarını ve bias parametrelerini yinelemeli olarak ayarladı.

Eğitim için bir öngörücü veri seti ve bir hedef veri seti kullanıldı. Hedef veri seti, yalnızca eğitim öngörücü veri setindeki belirli bir öngörücü veriye karşılık gelen gerçek yük değerlerinden oluşuyordu. Eğitim sonrasında, ANN bu verileri kullanarak değerlendirildi. Tahmin sonuçları kaydedildi ve tüm ANN eğitimi ve tahmin prosedürü, önceden belirlenmiş sayıda tekrarlandı.

Tablo 4.1'de sunulan sonuçlar, algoritma fonksiyonunun (Levenberg-Marquardt) 2018 için performansını göstermektedir. Ayrıca, eğitim oranı, gizli katman sayısı ve test oranının artmasıyla birlikte MAPE ve RMSE'deki hata oranının arttığını göstermiştir.

En iyi sonuç, %80 eğitim ve %20 test bölme oranıyla ve gizli katman sayısı 5 olarak elde edilmiştir. Bu durumda, MAPE için %3,2451 ve RMSE için 0,4248 gibi kabul edilebilir hata değerleri elde edilmiştir. Hata değerleri, gerçek yük profili üzerinde programlı veya beklenmedik bir kesinti veya başka bir ani yük kaymasının olduğu günlerle ilişkilidir.

Kullanılan minimum giriş sayısı ve gizli katman nöronlarının sayısı, MATLAB yazılımındaki ANN eğitim süresini doğrudan etkilemiştir. Bu parametrelerin ayarlanması, eğitim süresi ve hesaplama yükü üzerinde etkili olmuştur. Optimal sonuçlar elde etmek için, bu parametrelerin dikkatli bir şekilde seçilmesi ve ayarlanması önemlidir.

Aynı prosedür 2019 yılında da uygulanmıştır. En iyi sonuç, %80 eğitim ve %20 test bölme oranıyla ve gizli katman sayısı 5 olarak elde edilmiştir. Tablo 4.2'de gösterildiği gibi, bu durumda MAPE için %3,7452 ve RMSE için 0,3177 gibi hata değerleri elde edilmiştir. Karşılaştırma ve eşleştirme için kaynak olarak 2020 yılı kullanılacaktır. ANN algoritmasında 40 epoch sayısına göre yapılan analizler 3-5 dakika arasında gerçekleşmiştir.

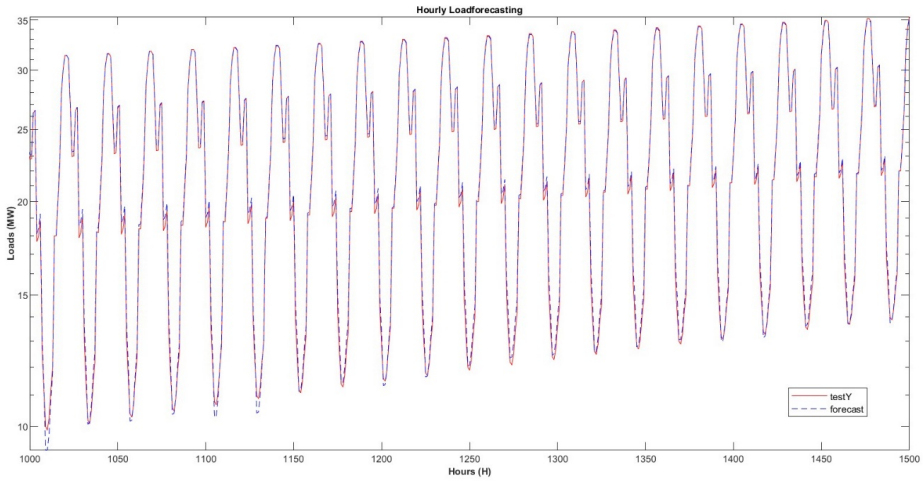
Tablo 4.1 2018 yılı için amaçlanan ANN için eğitim ve test sonuçları

bölünme oranı	%80 eğitim — %20 test.		%70 eğitim — %30 test.		%60 eğitim — %40 test.		%50 eğitim — %50 test.	
Eğitim Fonksiyonları	Levenberg–Marquardt		Levenberg–Marquardt		Levenberg–Marquardt		Levenberg–Marquardt	
5 gizli katman	%MAPE	3,2451	%MAPE	5,3756	%MAPE	5,4447	%MAPE	5,9299
	RMSE	0,4248	RMSE	0,6928	RMSE	0,7059	RMSE	0,7318
10 gizli katman	%MAPE	5,4319	%MAPE	7,5222	%MAPE	7,6136	%MAPE	7,9921
	RMSE	0,7206	RMSE	1,0655	RMSE	1,1513	RMSE	1,2919
15 gizli katman	%MAPE	6,3252	%MAPE	8,2533	%MAPE	8,5213	%MAPE	9,3836
	RMSE	0,8350	RMSE	1,0885	RMSE	1,2918	RMSE	1,3370

Tablo 4.2 2019 yılı için amaçlanan ANN için eğitim ve test sonuçları

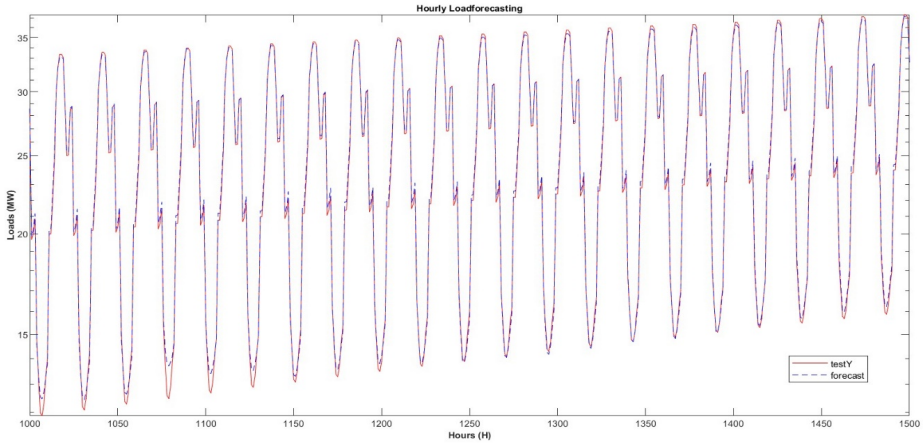
bölünme oranı	%80 eğitim — %20 test.		%70 eğitim — %30 test.		%60 eğitim — %40 test.		%50 eğitim — %50 test.	
Eğitim Fonksiyonları	Levenberg–Marquardt		Levenberg–Marquardt		Levenberg–Marquardt		Levenberg–Marquardt	
5 gizli katman	%MAPE	3,7452	%MAPE	6,2402	%MAPE	6,5315	%MAPE	6,8512
	RMSE	0,3177	RMSE	0,8452	RMSE	0,8997	RMSE	0,9682
10 gizli katman	%MAPE	5,4613	%MAPE	8,1691	%MAPE	8,8338	%MAPE	9,2921
	RMSE	1,1954	RMSE	1,2181	RMSE	1,5890	RMSE	1,7019
15 gizli katman	%MAPE	6,9019	%MAPE	8,4002	%MAPE	9,1607	%MAPE	10,2756
	RMSE	1,2876	RMSE	1,3403	RMSE	1,6893	RMSE	1,7601

2018 ve 2019 yılları için tahmin edilen elektrik yükü, zamana karşı bir grafik üzerinde çizilmiş ve tahmin edilen yük, test verileriyle (gerçek yük) karşılaştırılmıştır. Şekil 4.1 ve Şekil 4.2'de gösterilen grafiklerde, gerçek yüke kıyasla tahmin edilen elektrik yükü hafif bir sapma sergilemektedir. Kesintisiz kırmızı çizgi gerçek elektrik yükünü, mavi kesikli çizgi ise tahmin edilen elektrik yükünü temsil etmektedir.



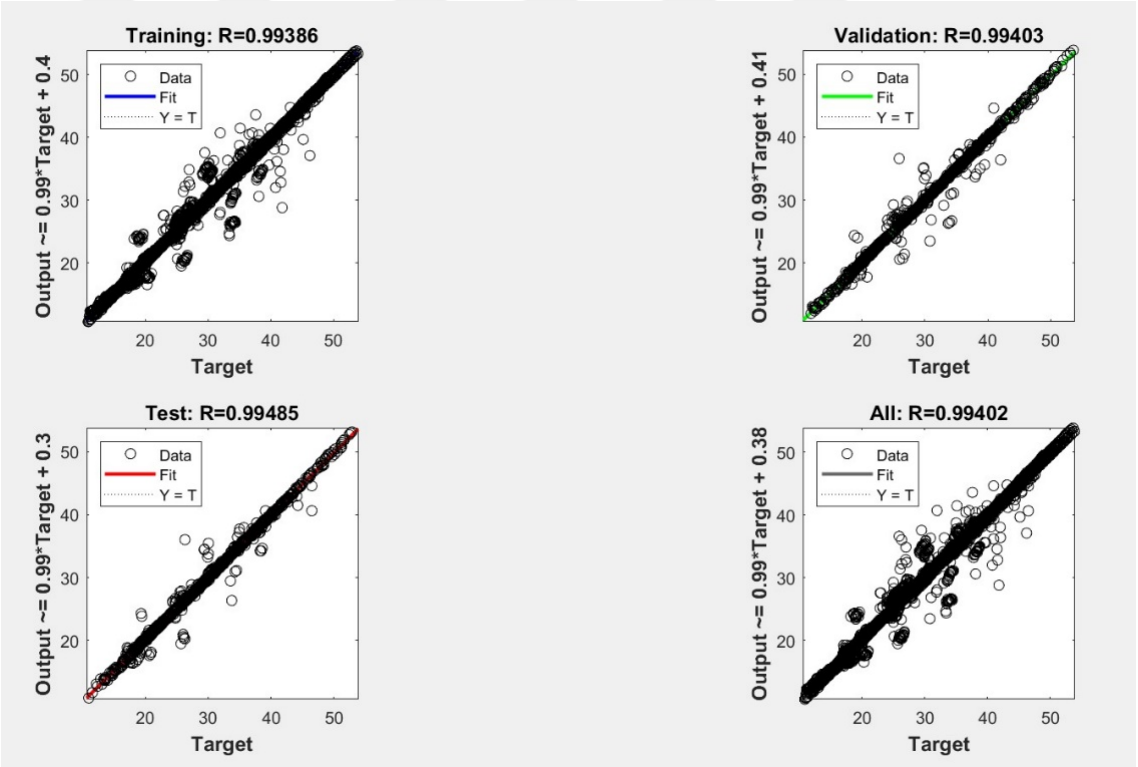
Şekil 4.1 2018'daki gerçek ve tahmini yük ANN

2018 yılı için test setinin regresyon değeri R=0,99485, eğitim setinin regresyon değeri R=0,99386 ve doğrulama seti için R=0,99403 olarak hesaplandı. Bu değerler, modelin test verilerindeki gerçek yük değerleriyle tahmin edilen yük değerleri arasındaki ilişkiyi göstermektedir.R değeri, 1'e yaklaştıkça, tahminlerin gerçek değerlerle daha iyi bir uyum içinde olduğunu gösterir. Bu durumda, R değerinin yaklaşık olarak 0,9940 olması, modelin iyi bir uyum ve doğruluk seviyesi sağladığını göstermektedir. Benzer şekilde, 2019 yılı için elde edilen regresyon değerleri de Şekil



Şekil 4.2 2019'daki gerçek ve tahmini yük ANN

4.3'te gösterildiği gibi benzer ve yakın değerlere sahiptir.



Şekil 4.3 Amaçlanan ANN 2018 gerçek ve tahmini yük (gerileme Grafiği)

4.2 ANFIS ile Yük Tahmini

ANFIS modellemesi için standardın, üyelik fonksiyonlarını doğru bir şekilde uygulamak, çıkış hatasını en aza indirgemek ve performans göstergesini maksimize etmek olduğunu belirtelim. Veriler, eğitim, test ve doğrulama setleri olarak kullanılır. İlk olarak, bulanık çıkarım sistemi FIS oluşturmak ve bir üyelik fonksiyonu türü seçmek gerekmektedir.

Tablo 4.3 ve Tablo 4.4, test edilen ve eğitilen üçgen üyelik fonksiyonlarını göstermektedir. Daha sonra, özellik girdileri olarak 2018 ve 2019 yıllarına ait zaman, sıcaklık, nem ve önceki yük değerleri gibi verileri aynı bölme oranıyla (8760 saatlik veri) MATLAB'dan alırız .

Üyelik fonksiyonunun girişi olarak özellik girdileri kullanılır ve tüm girişler için üyelik fonksiyonunun tüm olası kurulumlarını listeleriz, bu şekilde kuralları oluştururuz. ANFIS algoritması çağrıldığında, çalışılan yılın elektrik yükü değerleri için bir döngü oluşturulur. Yani test sırasında elektrik yükünün son değeri ilk değerine geri döner.

Ayrıca, diğer değişkenlerle yapılan testlerde de yükleri tekrar tekrar okuyarak testleri tekrarlarız ve değişim değerlerini ve yüzdesini belirleriz. Önerilen ANFIS, 3, 4 ve 5 üyelik fonksiyonuna sahip olacak şekilde tanımlanmıştır. Epoch, bir makine öğrenimi modelinin eğitim sürecinde tüm eğitim veri setinden tam geçişi temsil eder.

Bu çalışma, farklı epoch sayıları (20, 30 ve 40 gibi) ile deneyler yaparak, modelin performansı üzerinde epoch sayısının etkisini analiz etmeyi ve veri kümesi için en uygun epoch sayısını belirlemeyi amaçlamaktadır. Üyelik fonksiyonu türünü değiştirmeye karar verdiğimizde, üyelik fonksiyonunun biçimini değiştirmenin çıkarılan veriler üzerinde çok az veya fark edilmeyen bir etkisi olduğu için üçgen üyelik fonksiyonları tercih edilir.

Ayrıca, epoch sayıları üzerindeki değişimin çok küçük bir etkiye sahip olduğu görülmüştür. MAPE değeri üzerindeki etkiyi sadece üyelik fonksiyonlarının sayısının etkilediği, bu varyasyonun da oldukça küçük olduğu belirlenmiştir. ANFIS algoritmasında 40 epoch sayısı ve 5 üyelik fonksiyonuna na göre yapılan analizler 10-30 dakika arasında gerçekleşmiştir.

Tablo 4.3'te gösterildiği gibi, 2018 yılı için %2,8036 MAPE ve 0,3301 RMSE gibi düşük hata oranları elde edilmiştir.

Ek olarak, Tablo 4.4'te gösterildiği gibi, 2019 yılı için %2,8036 MAPE ve 0,3125 RMSE değerleri elde edilmiştir.

Bu değerler, 2018 ve 2019 yılları için ANFIS modelinin iyi bir performans sergilediğini ve verilerle iyi bir uyum sağladığını göstermektedir. Karşılaştırma ve eşleştirme için kaynak olarak 2020 yılı kullanılacaktır.

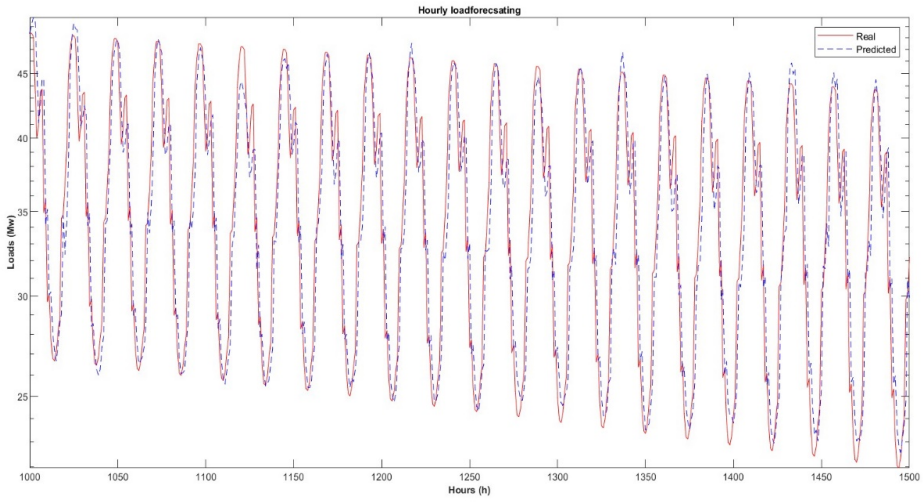
Tablo 4.3 2018 yılı için amaçlı ANFIS sonuçları

Epoch Sayı	20		30		40	
üyelik fonksiyonunun Türü	Triangular Membership fonksiyonu		Triangular Membership fonksiyonu		Triangular Membership fonksiyonu	
3 üyelik fonksiyonu	%MAPE	3,0165	%MAPE	3,0073	%MAPE	3,0039
	RMSE	0,3294	RMSE	0,3294	RMSE	0,3294
4 üyelik fonksiyonu	%MAPE	2,9318	%MAPE	2,9317	%MAPE	2,9330
	RMSE	0,3297	RMSE	0,3297	RMSE	0,3297
5 üyelik fonksiyonu	%MAPE	2,8785	%MAPE	2,8761	%MAPE	2,8532
	RMSE	0,3301	RMSE	0,3302	RMSE	0,3301

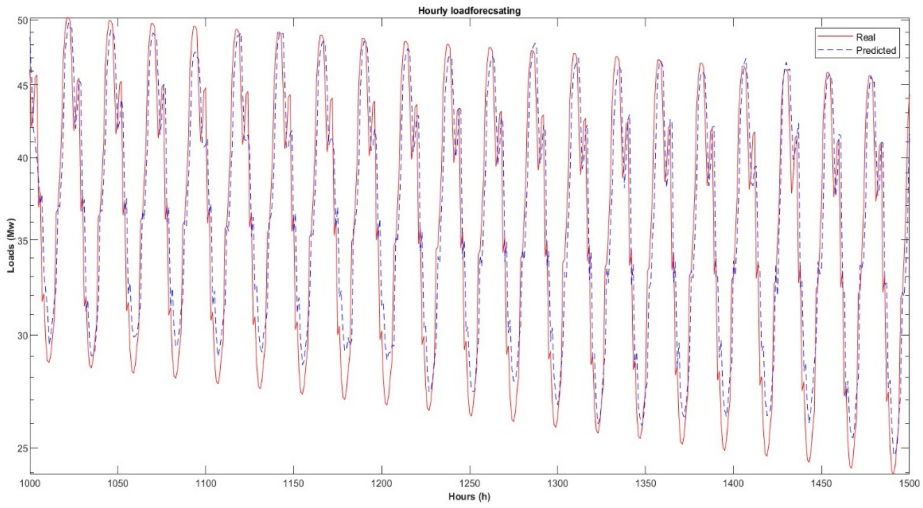
Tablo 4.4 2019 yılı için amaçlı ANFIS sonuçları

Epoch Sayı	20		30		40	
üyelik fonksiyonunun Türü	Triangular Membership fonksiyonu		Triangular Membership fonksiyonu		Triangular Membership fonksiyonu	
3 üyelik fonksiyonu	%MAPE	2,9065	%MAPE	2,9026	%MAPE	2,9005
	RMSE	0,3117	RMSE	0,3117	RMSE	0,3117
4 üyelik fonksiyonu	%MAPE	2,8273	%MAPE	2,8299	%MAPE	2,8303
	RMSE	0,3121	RMSE	0,3121	RMSE	0,3135
5 üyelik fonksiyonu	%MAPE	2,8189	%MAPE	2,8118	%MAPE	2,8036
	RMSE	0,3125	RMSE	0,3125	RMSE	0,3125

2018 ve 2019 yılları için gerçek elektrik yükünü tahmin edilen yükle karşılaştırmak için çizilen grafiklerin bir bölümü Şekiller 4.4 ve Şekil 4.5'de gösterilmektedir. Test verisi yükünden tahmin edilen grafik, gerçek yüke göre hafif bir sapmaya sahiptir. Gerçek elektrik yükü değerleri sürekli kırmızı çizgiyle temsil edilirken, tahmin edilen elektrik yükü değerleri kesikli mavi çizgiyle temsil edilir.



Şekil 4.4 2018'daki gerçek ve tahmini elektrik yükü ANFIS



Şekil 4.5 2019'daki gerçek ve tahmini elektrik yükü ANFIS

4.3 GA-ANN ile Yük Tahmini

Genetik algoritma (GA), yapay sinir ağı (ANN) tahminlerini optimize etmek için kullanılan bir yöntemdir. GA, ANN modelinin başlangıç ağırlıklarını ve eşik değerlerini rastgele seçerek başlar. Bu ağırlıklar ve eşikler, 5 gizli katmanlı bir ANN için %80 eğitim ve %20 test verilerine göre normalize edilir ve işlenmek üzere GA'ya giriş yapılır. GA, 5, 10 ve 15 gizli katman içeren farklı yapıları içermektedir. 2018 yılı için, Tablo 4.5'te gösterildiği gibi, en iyi sonuç gizli katman sayısı 5 olduğunda elde edilmiştir. Bu durumda MAPE için %1,866 ve RMSE için 0,0476 hata oranlarına ulaşılmıştır.
Ayrıca, 2019 yılı için Tablo 4.6'da gösterildiği gibi, en iyi sonuç yine gizli katman sayısı 5 olduğunda elde edilmiştir. Bu durumda MAPE için %2,4571 ve RMSE için 0,0476 hata oranlarına ulaşılmıştır. GA-ANN algoritmasında 40 epoch sayısına göre yapılan analizler 20-30 dakika arasında gerçekleşmiştir.
Bu sonuçlar, GA'nın ANN tahminlerini optimize etme yeteneğini göstermektedir. En iyi sonuçlar, gizli katman sayısı 5 olduğunda elde edilmiş ve düşük hata oranlarına sahip olmuştur. 2020 yılı, eşleştirme ve karşılaştırma için referans olarak kullanılacaktır.
Bu çalışma, GA'nın ANN modelinin performansını artırmak için etkili bir yöntem olduğunu ve en iyi sonuçların gizli katman sayısı 5 olduğunda elde edildiğini göstermektedir.

2018 ve 2019 yılları için gerçek yükü tahmin edilen elektrik yüküyle karşılaştırmak için, gerçek yük saatlik zaman dilimine göre çizilmiştir. Şekil 4.6 ve Şekil 4.7, bu grafiklerin bir bölümünü göstermektedir. Bu görsel karşılaştırma, tahmin edilen ve gerçek elektrik yükü arasındaki benzerlik ve sapmayı göstermektedir. Görsel olarak, tahmin edilen elektrik yükü değerleri genellikle gerçek yükle uyumlu olmakla birlikte, bazı noktalarda hafif sapmalar görülebilmektedir.

Tablo 4.5 2018 yılı için Amaçlanan ANN–GA Sonuçları

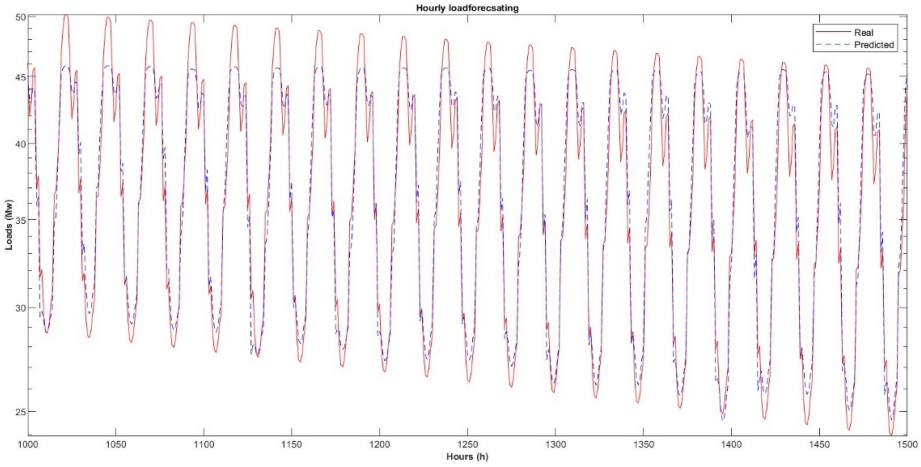
bölünme oranı	%Hata	
5 gizli katman	%MAPE	1,8663
	RMSE	0,0476
10 gizli katman	%MAPE	4,8722
	RMSE	0,1889
15 gizli katman	%MAPE	5,9395
	RMSE	0,1714

Tablo 4.6 2019 yılı için Amaçlanan ANN–GA Sonuçları

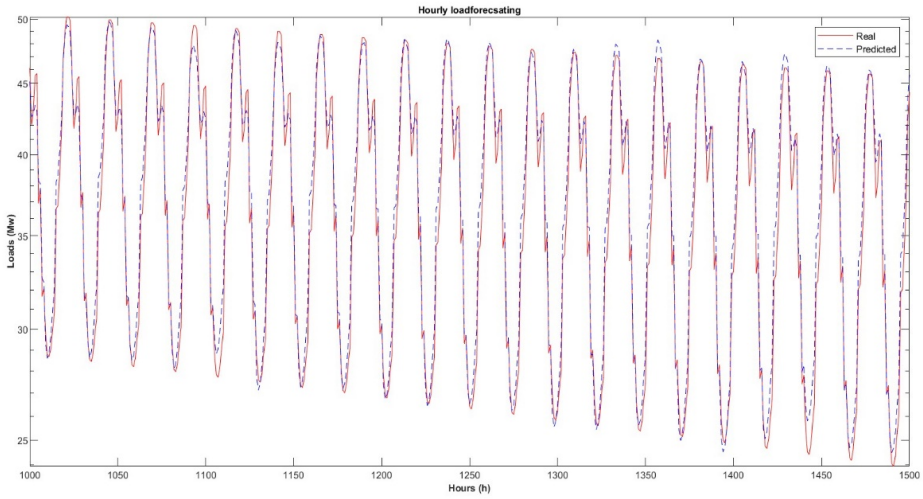
bölünme oranı	%Hata	
5 gizli katman	%MAPE	2,4571
	RMSE	0,0623
10 gizli katman	%MAPE	3,7701
	RMSE	0,0668
15 gizli katman	%MAPE	5,9110
	RMSE	0,1572

Bu analiz, GA'nın ANN modelinin gerçek elektrik yükünü başarılı bir şekilde tahmin ettiğini ve genel olarak iyi bir uyum sağladığını göstermektedir. Tahminlerin gerçek verilere yakın olduğu ve modellerin iyi bir performans sergilediği görülmektedir.

.



Şekil 4.6 2018 yılı için amaçlanan ANN–GA için gerçek ve tahmini yük



Şekil 4.7 2019 yılı için amaçlanan ANN–GA için gerçek ve tahmini yük

4.4 Amaca Yönelik Tekniklerde Test ve Eğitim Sonuçları

Bu çalışma, uzun vadeli yük tahmini (LTLF) üzerinde yoğunlaşan ve büyük miktarda veri kullanımını içeren bir çalışmadır. Tahmin yapmak için, her ay için bir maksimum değer yaklaşımı kullanılmıştır, ayrıntıları Tablo 4.7'de verilmiştir.

Elektrik yükünü tahmin etmek için bağıl nem ve sıcaklık arasında ilişki kurmayı amaçlayan teknikler kullanılmış ve 2018 yılı tahmin sürecinde 2019 yılına ait elektrik yükü değerleri elde edilmiştir. 2018 için tahmin edilen değerler ANN, ANFIS ve ANN-GA yöntemleriyle karşılaştırılmış ve 2019 için gerçek değerlerle (hedef) karşılaştırılmıştır. Sonuçlar, ANN-GA yönteminin diğer iki yönteme göre daha doğru tahminler ürettiğini göstermektedir.

Bu süreç 2019 yılı için tekrarlanarak o yıl için tahmin edilen elektrik yükü değerleri 2020 yılındaki gerçek değerlerle (hedef) karşılaştırılmıştır. ANN-GA yöntemi, diğer yöntemlere göre gerçek değerlere daha yakın tahminler üretmede bir kez daha üstünlük sağlamıştır. Ayrıca, 2018 ve 2019 yılları için bu algoritmalar arasındaki yüzde hata oranları, ANN-GA yönteminin diğer yöntemlere göre üstünlüğünü doğrulamıştır.

Tablo 4.7 Amaçlanan tekniklerin çıktı sonuçları

Ay	Uzun Vadeli Girdiler			Hedef		ANN		ANFIS		ANN–GA	
	Sıcaklık (°C)	Nem (%)	GERÇEK 2018 (MW)	GERÇEK 2019 (MW)	GERÇEK 2020 (MW)	Tahmin edilen 2018 (MW)	Tahmin edilen 2019 (MW)	Tahmin edilen 2018 (MW)	Tahmin edilen 2019 (MW)	Tahmin edilen 2018 (MW)	Tahmin edilen 2019 (MW)
OCAK	20,40	97,44	53,856	55,85	59,35	53,88	55,84	56,44	56,43	54,27	59,96
ŞUBAT	23,42	96,81	51,012	53,01	56,51	50,96	52,94	51,53	52,98	53,97	54,45
MART	35,73	83,12	43,665	45,66	58,92	43,69	45,67	44,83	44,91	46,20	47,49
NISAN	33,37	95,62	39,915	41,91	45,47	39,79	41,78	41,20	43,94	40,15	44,40
MAYIS	39,82	80,75	41,625	43,62	47,18	41,50	43,48	49,58	44,02	42,26	44,41
HAZİRAN	41,42	61,44	43,050	45,05	48,55	42,98	44,96	43,86	47,67	45,44	47,88
TEMMUZ	42,55	60,31	42,156	44,00	47,35	42,16	43,98	41,55	44,35	44,70	45,46
AĞUSTOS	49,59	60,25	40,615	42,61	46,11	40,55	42,54	42,85	43,63	42,76	43,90
EYLÜL	42,81	55,19	37,174	39,17	42,57	37,11	39,08	39,01	40,14	40,95	40,87
EkİM	38,00	86.62	34,074	36,07	39,47	34,09	36,06	38,14	39,40	34,70	37,02
KASIM	26,20	91,20	31,374	33,37	37,07	31,23	33,29	33,86	35,50	33,41	36,86
ARALIK	20,13	97,66	37,374	39,4	54,18	37,16	39,23	37,63	40,00	37,34	40,16
					MAPE	%3,245	%5,017	%2,853	%2,807	%1,866	%2,457
					RMSE	0,424	0,654	0,330	0,312	0,047	0,062

5
SONUÇ VE ÖNERİLER

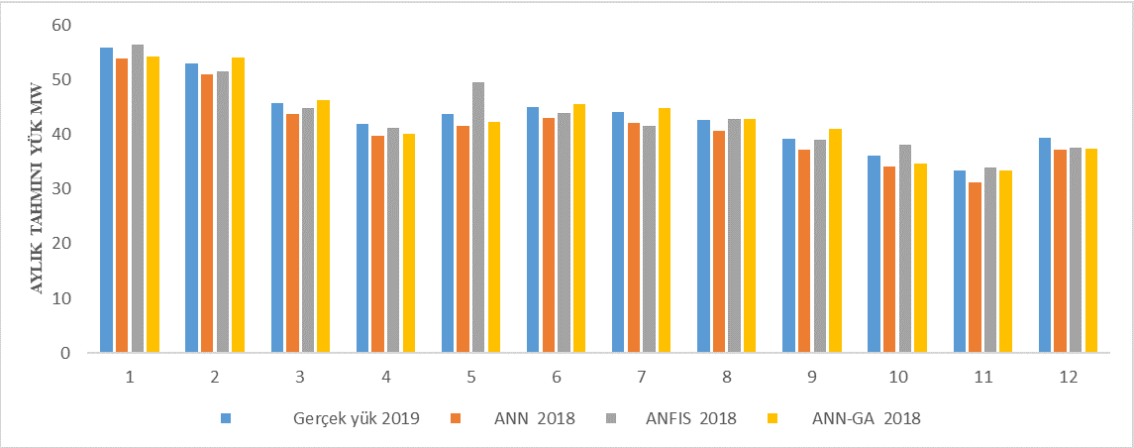
5.1 Modellerin Performansının Karşılaştırılması

Model karşılaştırması, her bir modelin performansındaki değişiklikleri aylık olarak tahmin edilen elektrik yükü sonuçlarına göre göstermektedir. Bu, her modelin tüm veri kümesine ne kadar iyi uyum sağladığını gösterirken, tahmin doğruluğundaki varyasyona dikkat etmek önemlidir. Şekil 5.1 ve 5.2'de, kullanılan her model için MW olarak tahmin edilen yük değerleri karşılaştırılmıştır. Bu, 2018 ve 2019 yılları için aynı veri seti kullanılarak tahminler yapıldığında bir modelin ne kadar iyi performans gösterdiğini açıklar.

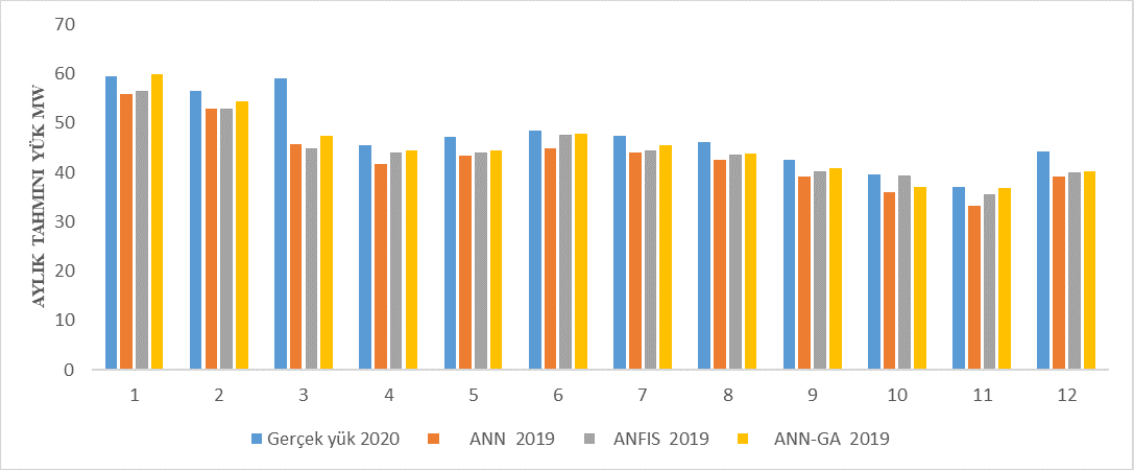
ANN modeli, çok çeşitli parametreleri kabul etmesi, düşük hata oranlarına sahip olması ve aynı veri setiyle yüksek performans göstermesi gibi birçok avantaja sahip olmasına rağmen, şekillerde görüldüğü gibi düşük performans göstermiştir. Önerilen ANN-GA modeli, zaman serileri ve saatlik bölme kullanarak verileri çözmek için önerilen yöntemi kullanarak her iki yılda da diğer modellere göre daha iyi performans göstermiştir. Ancak, uzun ve karmaşık bir uygulama, eğitim ve test prosedürleriyle karmaşık bir algoritma olduğu için zaman alıcıdır.

ANFIS modeli, performans açısından diğer iki model arasında hız, sonuç, zorluk, hata oranları ve diğer özellikler açısından orta seviyede yer almaktadır.

Sonuç olarak, bu çalışmada ANN-GA modelinin diğer modellere göre daha iyi performans gösterdiği görülmektedir. Ancak, her modelin avantajları ve dezavantajları göz önüne alınmalı ve uygulanacak problem bağlamına göre en uygun model seçilmelidir.



Şekil 5.1 Modellerin 2018 performansının karşılaştırılması



Şekil 5.2 Modellerin 2019 performans karşılaştırması

5.2 Sonuçlar

Bu tez çalışmasında, saatlere bölünmüş yıllık veri örneği kullanılarak elektrik yükü tahmini için üç önemli algoritma olan ANN, ANFIS ve ANN-GA'nın performansı değerlendirildi. Ayrıca veriler, günlere, haftalara, aylara, tatillere vb. bölmek suretiyle farklı algoritmalar için kullanıldı.

Sonuçlar, ANN-GA'nın diğer iki yöntem olan ANN ve ANFIS'e kıyasla uzun vadeli yük tahmini için daha iyi doğruluk ve hata oranı sergilediğini gösterdi. 2018 yılı için ANN-GA'nın MAPE için %1,866 ve RMSE için 0,047 hata değerleri elde ettiği görüldü. Bu, ANFIS teknolojisiyle karşılaştırıldığında MAPE için %2,853 ve RMSE için 0,330, ANN teknolojisiyle karşılaştırıldığında ise MAPE için %3,245 ve RMSE için 0,424 olarak hesaplandı. Bu sonuçlar tüm test ve eğitim oranları için geçerliydi.

2019 yılı için de ANN-GA, MAPE için %2,457 ve RMSE için 0,062 hata oranlarıyla iyi doğruluk ve hata sonuçları elde etti. Bu, ANN teknolojisiyle karşılaştırıldığında MAPE

için %5,017 ve RMSE için 0,654, ANFIS teknolojisiyle karşılaştırıldığında ise MAPE için %2,807 ve RMSE için 0,312 olarak hesaplandı.

Ayrıca, bu çalışmada ANN'deki gizli katman sayısı ile test ve eğitim oranlarının artmasının doğrulukta azalmaya ve hata oranında artışa neden olduğu bulundu. ANFIS teknolojisi ise hata oranında küçük bir artış gösterdi, bu da neredeyse fark edilmeyen üyelik fonksiyonundan kaynaklanmaktadır. Aynı durum, uygulama süresi açısından ANN-GA için de geçerlidir.

Genel olarak, bu çalışma ANN-GA'nın ANN ve ANFIS'e kıyasla uzun vadeli yük tahmini için daha doğru ve verimli bir yöntem olduğunu göstermektedir. ANFIS sonuçları, tahmin edilen değerlerin elektrik yüklerinin gerçek değerlerine yakınsaması açısından iyi görünse de, ANN tekniği, her türlü doğrusal ve doğrusal olmayan parametre ve girdiye en uyumlu olanıdır (zaman, hava durumu, ekonomik faktörler vb).

ANN-GA teknolojisinin, diğer yaklaşımlardan üstün olmasının nedeni, tahmin edilen verileri ve ANN çıktılarını optimum uygunluk değerleri belirlenmeden, yeniden biçimlendirilmeden ve kullanılmadan önce normalleştirmesidir. Hibrit sistemlerin avantajlarından biri, algoritma performansını geliştirerek en uygun değerleri elde etmeleridir. Parametrelerin en iyi değerlerini seçerler ve bu sayede en düşük hata oranını elde ederler. Bu yöntem, tahmin doğruluğunu artırarak elektrik yükü tahmini için daha etkili bir çözüm sunar.

5.3 Öneriler ve gelecekteki çalışmalar

Diğer yük tahmin yöntemlerini kullanarak, en düşük hata oranına sahip sonuçları üreten metodolojiyi belirlemek için karşılaştırma tabloları oluşturmak ve daha doğru sonuçlar elde etmek için ek optimizasyon teknikleri kullanmak önemlidir. Bu şekilde farklı yöntemlerin performansını objektif bir şekilde değerlendirebilir ve en etkili yöntemi belirleyebiliriz.

Uzun süreli çalışmalar yapmak, yük tahminlerinin doğruluğunu artırmak için önemlidir. Bir veya iki yıldan daha uzun süren çalışmalar, daha geniş bir veri setine dayanarak daha güvenilir sonuçlar elde etmemizi sağlar. Ayrıca, saatlik veriler yerine daha kısa aralıklarla (30, 15 veya hatta dakika) verileri kullanmak, daha ayrıntılı ve hassas tahminler yapmamıza yardımcı olabilir.

Hava durumu değişkenlerinin yanı sıra, elektrik yükü tahminlerini etkileyebilecek diğer faktörler ve değişkenler de dikkate alınmalıdır. Örneğin, elektrik fiyatları ve

belirli bir elektrik şebekesindeki toplam müşteri sayısı gibi ekonomik faktörler, tahmin modellerine entegre edilerek tahmin doğruluğunu artırabilir. Bu faktörlerin elektrik yükü üzerindeki etkisini araştırmak ve modellere entegre etmek, daha sağlam ve güvenilir tahminler elde etmemizi sağlayabilir

Daha fazla araştırma yaparak, elektrik yükü tahminini iyileştirmek için farklı faktörlerin ve değişkenlerin etkisini daha iyi anlayabiliriz. Bu şekilde, enerji planlaması ve yönetimi alanında daha doğru kararlar alabiliriz ve enerji verimliliğini artırabiliriz.

KAYNAKÇA

[1] M. Matijaš, "Electric load forecasting using multivariate meta-learning," *Fakultet elektrotehnike i računarstva, Sveučilište u Zagrebu*, 2013.

[2] A. M. Kotriwala, *Load forecasting for temporary power ınstallations*, 2017.

[3] L. Han, Y. Peng, Y. Li, B. Yong, Q. Zhou, L. Shu, "Enhanced deep networks for short-term and medium-term load forecasting," *Ieee Access*, vol. 7, pp. 4045–4055, 2018.

[4] I. K. Nti, M. Teimeh, O. Nyarko-Boateng, A. F. Adekoya, "Electricity load forecasting: A systematic review," *Journal of Electrical Systems and Information Technology*, vol. 7, no. 1, pp. 1–19, 2020.

[5] A. A. Arfoa *et al.*, "Long-term load forecasting of southern governorates of jordan distribution electric system," *Energy and Power Engineering*, vol. 7, no. 05, p. 242, 2015.

[6] H. Shareef, M. S. Ahmed, A. Mohamed, E. Al Hassan, "Review on home energy management system considering demand responses, smart technologies, and intelligent controllers," *Ieee Access*, vol. 6, pp. 24 498–24 509, 2018.

[7] A. Al Mamun, M. Sohel, N. Mohammad, M. S. H. Sunny, D. R. Dipta, E. Hossain, "A comprehensive review of the load forecasting techniques using single and hybrid predictive models," *IEEE Access*, vol. 8, pp. 134 911–134 939, 2020.

[8] S.-M. Baek, "Mid-term load pattern forecasting with recurrent artificial neural network," *Ieee Access*, vol. 7, pp. 172 830–172 838, 2019.

[9] I. K. Ibraheem, M. O. Ali, "Short term electric load forecasting based on artificial neural networks for weekends of baghdad power grid," *International Journal of Computer Applications*, vol. 89, no. 3, pp. 30–37, 2014.

[10] A. G. Abdullah, G. M. Suranegara, D. L. Hakim, "Hybrid pso-ann application for improved accuracy of short term load forecasting," *WSEAS Transactions on Power Systems*, vol. 9, no. 446, p. 51, 2014.

[11] K. O. Alawode, M. O. Oyedeji, "Comparison of neural network models for load forecasting in nigeria power systems," *Int. J. Renew. Energy Technol*, vol. 2, pp. 218–222, 2013.

[12] D. Ali, M. Yohanna, P. M. Ijasini, M. B. Garkida, "Application of fuzzy–neuro to model weather parameter variability impacts on electrical load based on long-term forecasting," *Alexandria engineering journal*, vol. 57, no. 1, pp. 223–233, 2018.

[13] N. Ammar, M. Sulaiman, A. F. M. Nor, "Long-term load forecasting of power systems using artificial neural network and anfıs," *ARPN Journal of Engineering and Applied Sciences*, vol. 13, no. 3, pp. 828–834, 2018.

[14] Y. Xu, J. Cai, J. V. Milanović, "On accuracy of demand forecasting and its extension to demand composition forecasting using artificial intelligence based methods," in *IEEE PES Innovative Smart Grid Technologies, Europe*, IEEE, 2014, pp. 1–6.

[15] S. K. Panda, S. N. Mohanty, A. K. Jagadev, "Long term electrical load forecasting: An empirical study across techniques and domains," *Indian journal of science and technology*, vol. 10, no. 26, pp. 1–16, 2017.

[16] F. GÖKGÖZ, F. Filiz, "Electricity load forecasting via ann approach in turkish electricity markets," *Bilgi Yönetimi*, vol. 3, no. 2, pp. 170–184, 2020.

[17] A. I. Arvanitidis, D. Bargiotas, A. Daskalopulu, V. M. Laitsos, L. H. Tsoukalas, "Enhanced short-term load forecasting using artificial neural networks," *Energies*, vol. 14, no. 22, p. 7788, 2021.

[18] M.-H. Pham, M.-N. Nguyen, Y.-K. Wu, "A novel short-term load forecasting method by combining the deep learning with singular spectrum analysis," *IEEE Access*, vol. 9, pp. 73 736–73 746, 2021.

[19] S.-V. Oprea, A. Bâra, "Machine learning algorithms for short-term load forecast in residential buildings using smart meters, sensors and big data solutions," *IEEE Access*, vol. 7, pp. 177 874–177 889, 2019.

[20] M. V. Selvi, S. Mishra, "Investigation of performance of electric load power forecasting in multiple time horizons with new architecture realized in multivariate linear regression and feed-forward neural network techniques," *IEEE Transactions on Industry Applications*, vol. 56, no. 5, pp. 5603–5612, 2020.

[21] A. Nespoli, S. Leva, M. Mussetta, E. G. C. Ogliari, "A selective ensemble approach for accuracy ımprovement and computational load reduction in ann-based pv power forecasting," *IEEE Access*, vol. 10, pp. 32 900–32 911, 2022.

[22] M. ZulfiqAr, M. Kamran, M. B. Rasheed, T. Alquthami, A. H. Milyani, "A short-term load forecasting model based on self-adaptive momentum factor and wavelet neural network in smart grid," *IEEE Access*, vol. 10, pp. 77 587–77 602, 2022.

[23] J. Faraji, A. Ketabi, H. Hashemi-Dezaki, M. Shafie-Khah, J. P. Catalão, "Optimal day-ahead self-scheduling and operation of prosumer microgrids using hybrid machine learning-based weather and load forecasting," *IEEE Access*, vol. 8, pp. 157 284–157 305, 2020.

[24] S. H. Rafi, S. R. Deeba, E. Hossain, *et al.*, "A short-term load forecasting method using integrated cnn and lstm network," *IEEE Access*, vol. 9, pp. 32 436–32 448, 2021.

[25] K. Mahmud, J. Ravishankar, M. Hossain, Z. Y. Dong, "The impact of prediction errors in the domestic peak power demand management," *IEEE Transactions on Industrial Informatics*, vol. 16, no. 7, pp. 4567–4579, 2019.

[26] H. Mansoor, H. Rauf, M. Mubashar, M. Khalid, N. Arshad, "Past vector similarity for short term electrical load forecasting at the individual household level," *IEEE Access*, vol. 9, pp. 42 771–42 785, 2021.

[27] M. R. Haq, Z. Ni, "A new hybrid model for short-term electricity load forecasting," *IEEE access*, vol. 7, pp. 125 413–125 423, 2019.

[28] J. Song, G. Xue, X. Pan, Y. Ma, H. Li, "Hourly heat load prediction model based on temporal convolutional neural network," *IEEE Access*, vol. 8, pp. 16 726–16 741, 2020.

[29] K. Chen, K. Chen, Q. Wang, Z. He, J. Hu, J. He, "Short-term load forecasting with deep residual networks," *IEEE Transactions on Smart Grid*, vol. 10, no. 4, pp. 3943–3952, 2018.

[30] E. Akarslan, F. O. Hocaoglu, "Electricity demand forecasting of a micro grid using ann," in *2018 9th International Renewable Energy Congress (IREC)*, IEEE, 2018, pp. 1–5.

[31] W. Kong, Z. Y. Dong, Y. Jia, D. J. Hill, Y. Xu, Y. Zhang, "Short-term residential load forecasting based on lstm recurrent neural network," *IEEE transactions on smart grid*, vol. 10, no. 1, pp. 841–851, 2017.

[32] M. Dattatrey, A. K. Tiwari, B. Ghoshal, J. Singh, "Predicting bone modeling parameters in response to mechanical loading," *IEEE Access*, vol. 7, pp. 122 561–122 572, 2019.

[33] H. Liu, Y. Wang, C. Wei, J. Li, Y. Lin, "Two-stage short-term load forecasting for power transformers under different substation operating conditions," *IEEE Access*, vol. 7, pp. 161 424–161 436, 2019.

[34] A. Moradzadeh, B. Mohammadi-Ivatloo, M. Abapour, A. Anvari-Moghaddam, S. S. Roy, "Heating and cooling loads forecasting for residential buildings based on hybrid machine learning applications: A comprehensive review and comparative analysis," *IEEE Access*, vol. 10, pp. 2196–2215, 2021.

[35] T. Lin, Y. Pan, G. Xue, J. Song, C. Qi, "A novel hybrid spatial-temporal attention-lstm model for heat load prediction," *IEEE Access*, vol. 8, pp. 159 182–159 195, 2020.

[36] T. Ouyang, Y. He, H. Li, Z. Sun, S. Baek, "Modeling and forecasting short-term power load with copula model and deep belief network," *IEEE Transactions on Emerging Topics in Computational Intelligence*, vol. 3, no. 2, pp. 127–136, 2019.

TEZDEN ÜRETİLMİŞ YAYINLAR

Makale

1. AL-Qaysi, Ahmed Mazin Majid, Altug Bozkurt, and Yavuz Ates. "Load Forecasting Based on Genetic Algorithm–Artificial Neural Network-Adaptive Neuro-Fuzzy Inference Systems: A Case Study in Iraq." Energies 16, no. 6 (2023): 2919.

Konferans Bildirisi

1. ALQAYSI, A. M., BOZKURT, A., & ATEŞ, Y., (2022). ELECTRICAL LOAD FORECASTING BASED ON ARTIFICIAL NEURAL NETWORK IN IRAQ. 10th international congress on engineering architecture and design (pp.957-964). İstanbul, Turkey.