



**YAPAY ZEKA MODELLERİ KULLANARAK ANKARA BÖLGESİNİN
KISA DÖNEM ELEKTRİK ENERJİSİ YÜK TAHMİNİ**

Tuğba AKMAN

**YÜKSEK LİSANS TEZİ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ARALIK 2018

Tuğba AKMAN tarafından hazırlanan “YAPAY ZEKA MODELLERİ KULLANARAK ANKARA BÖLGESİNİN KISA DÖNEM ELEKTRİK ENERJİSİ YÜK TAHMİNİ” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile Gazi Üniversitesi Elektrik Elektronik Mühendisliği Ana Bilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Doç. Dr. Cemal YILMAZ

Elektrik Elektronik Mühendisliği Ana Bilim Dalı, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....

İkinci Danışman: Doç. Dr. Yusuf SÖNMEZ

Teknik Bilimler Meslek Yüksekokulu, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....

Başkan: Doç. Dr. İlhan KOŞALAY

Elektrik Elektronik Mühendisliği Ana Bilim Dalı, Ankara Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....

Üye: Doç. Dr. Uğur GÜVENÇ

Elektrik Elektronik Mühendisliği Ana Bilim Dalı, Düzce Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....

Üye: Doç. Dr. Ercan Nurcan YILMAZ

Elektrik Elektronik Mühendisliği Ana Bilim Dalı, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....

Tez Savunma Tarihi: 03/12/2018

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Prof. Dr. Sena YAŞYERLİ

Fen Bilimleri Enstitüsü Müdürü

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Tuğba AKMAN

03/12/2018

YAPAY ZEKA MODELLERİ KULLANARAK ANKARA BÖLGESİNİN KISA
DÖNEM ELEKTRİK ENERJİSİ YÜK TAHMİNİ

(Yüksek Lisans Tezi)

Tuğba AKMAN

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Aralık 2018

ÖZET

Günlük hayatın vazgeçilmez bir parçası olan enerji, ülkelerin sosyo-ekonomik yapıları içerisindeki yerini ve önemini korurken, enerjinin önemli bir bileşenini oluşturan elektrik enerjisi ise ağırlığını giderek artan bir oranda geliştirmektedir. Elektrik enerjisi talebinin önemi, artan nüfus, şehirleşme, sanayi ve teknolojinin yaygınlaşması ve refah artışına paralel olarak yükselmektedir. Elektrik enerjisi talebi karşılanırken, elektrik güç sistemlerinin gerçek zaman şartları altında gerilim, frekans ve güç akışlarının belirlenen limitler içerisinde kararlılığını kaybetmeden işletme güvenliğinin sağlanması, elektrik iletim sistemlerinin güvenli ve düşük maliyetli olarak planlanması, işletilmesi ve tüketicilere sürekli, güvenilir, kaliteli ve ekonomik olarak elektrik enerjisinin arz edilebilmesi için doğru ve etkin yük tahminlerine ihtiyaç duyulmaktadır. Son yıllarda, güç sistemi analiz ve kontrolünün birçok alanında, statik ve dinamik güvenlik analizlerinde, dinamik yük modellemesi, alarm işleme ve arıza teşhislerinde yapay sinir ağları kullanımı oldukça yaygındır. Bu nedenle bu tez çalışmasında, özellikle lineer olmayan karmaşık problemlerde oldukça iyi tahmin sonuçları elde edilmesinden dolayı yapay sinir ağlarına dayalı yöntemler kullanılarak oluşturulan kısa dönem yük tahmini modeli ile 24 saatlik yük tahmini yapılmış ve sonuçları incelenmiştir.

Bilim Kodu : 90513
Anahtar Kelimeler : Yük tahmini, tahmin yöntemleri, YSA, enerji sistemleri
Sayfa Adedi : 95
Danışman : Doç. Dr. Cemal YILMAZ
İkinci Danışman : Doç. Dr. Yusuf SÖNMEZ

SHORT TERM ELECTRIC ENERGY LOAD FORECASTING OF ANKARA REGION
USING ARTIFICIAL INTELLIGENCE METHODS

(M. Sc. Thesis)

Tuğba AKMAN

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

December 2018

ABSTRACT

While energy, which is an indispensable part of everyday life, maintains its importance and place in socio-economic structures of countries, importance of electricity energy, as an important component of energy, is increasing its gravity exponentially. Importance of electricity energy demand maintains its increasing trend in line with growing population, urbanization, industrialization, becoming widespread of technology and welfare. While meeting electricity energy demand, correct and effective load forecasting is needed in order to ensure operational safety without losing the stability of voltage, frequency and power flows within the limits determined under the real time conditions of electric power systems, operate and plan secure and low-cost electricity transmission systems and supply sustainable, reliable, high quality and affordable electricity to consumers. In recent years, use of the artificial neural networks are quite common in many areas of the power system analysis and control, static and dynamic security analysis, dynamic load modelling and alarm processing and error diagnostics. Therefore, in this thesis study, 24 hours static load forecasting has been carried out with short-term load forecast model created by using methods based on artificial neural networks since fairly good forecasting results are being obtained especially for non-linear complex problems.

Science Code : 90513

Key Words : Load forecasting, forecast methods, ANN, energy systems

Page Number : 95

Supervisor : Assoc. Prof. Dr. Cemal YILMAZ

Co-Supervisor : Assoc. Prof. Dr. Yusuf SÖNMEZ

TEŞEKKÜR

Tez çalışmalarım sırasında, değerli bilgi, birikim ve tecrübeleri ile bana hep yol gösterici ve destek olan, kıymetli zamanını ayırıp sabırla ve büyük bir ilgiyle çalışmalarımı yakından takip edip, değerli önerilerini ve samimiyetini benden esirgemeyen kıymetli danışman hocam Sayın Doç. Dr. Cemal YILMAZ'a sonsuz teşekkür ve saygılarımı sunarım. Yine tez çalışmam boyunca kaynak ve yöntem açısından yaşadığım her türlü sıkıntıda benden yardımlarını esirgemeyen değerli hocam Sayın Doç. Dr. Yusuf SÖNMEZ'e teşekkürü bir borç bilirim. Ayrıca tez çalışmamda kullandığım verilerin temini konusunda bana yardımcı olan Sayın Faik BATAN'a ve TEİAŞ Yüz Tevzi Dairesi Başkanlığına teşekkürlerimi sunarım. Tez çalışmalarım süresince beni sürekli destekleyen ve her konuda yardımcı olmaya çalışan değerli arkadaşlarım ile hayatım boyunca maddi ve manevi destekleriyle beni hiçbir zaman yalnız bırakmayan, bu hayattaki en büyük şansım olan aileme de sonsuz teşekkürler.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ	x
ŞEKİLLERİN LİSTESİ	xi
SİMGELER VE KISALTMALAR	xiii
1. GİRİŞ	1
2. YÜK TAHMİNİ	7
2.1. Elektrik Enerji Sistemlerinde Planlama	7
2.2. Zamana Göre Yük Tahmini Çeşitleri	10
2.2.1. Uzun dönem yük tahminleri	10
2.2.2. Orta dönem yük tahminleri	11
2.2.3. Kısa dönem yük tahminleri	12
2.2.4. Çok kısa dönem yük tahminleri	13
2.3. Yüklerin Özellikleri ve Sınıflandırılması	13
2.3.1. Sanayi	14
2.3.2. Ticarethane	14
2.3.3. Mesken	15
2.3.4. Tarımsal sulama	15
2.3.5. Aydınlatma	16
2.4. Yükü Etkileyen Faktörler	19

Sayfa

2.4.1. Meteorolojik durumlar	19
2.4.2. Zaman faktörü	21
2.4.3. Ekonomik ve demografik faktörler	22
2.4.4. Rastlantısal faktörler	23
2.5. Yük Eğrisinin Özellikleri	23
3. YÜK TAHMİNİ YÖNTEMLERİ	29
3.1. Regresyon Analizi	29
3.2. Zaman Serileri Analizi	30
3.3. Parametrik Yöntemler	32
3.3.1. Trend analizi	32
3.3.2. Son kullanım modeli	33
3.3.3. Ekonometrik modeller	34
3.4. Bulanık Mantık Algoritmaları	34
3.5. Uzman Sistemler	35
3.6. Genetik Algoritma	36
3.6.1 Basit bir genetik algoritmanın yapısı	37
3.7. Destek Vektör Makineleri (DVM)	39
3.8. Yapay Sinir Ağları	41
3.8.1. Yapay sinir ağlarının temel yapısı	44
3.8.2. Yapay sinir ağlarının genel özellikleri	47
3.8.3. Yapay sinir ağlarında öğrenme	50
3.8.4. Yapay sinir ağ çeşitleri	54
4. KISA DÖNEM ELEKTRİK ENERJİSİ YÜK TAHMİNİ İÇİN YAPAY SİNİR AĞLARI VE GENETİK ALGORİTMA TABANLI ADAPTİF HİBRİD SİSTEMİN GELİŞTİRİLMESİ	61

	Sayfa
4.1. Klasik YSA	62
4.2. Adaptif YSA	63
5. YÖNTEMLERİN UYGULANMASI, VERİLERİN DEĞERLENDİRİLMESİ VE SAYISAL SONUÇLAR	65
5.1. Giriş	65
5.2. OAYTM Bölgesi Kısa Dönem Yük Tahmini Modeli	66
5.2.1. Kısa dönem yük tahmini için giriş verilerinin belirlenmesi	67
5.2.2. Gün tipi sınıflandırılması	70
5.2.3. Benzer gün seçimi	71
5.3. YSA Analizi	74
5.3.1. Normalizasyon	76
5.3.2. Kısa dönem yük tahmini için algoritmanın uygulanması	77
5.4. Benzetim Programı	80
5.5. Sayısal Sonuçların Değerlendirilmesi	81
6. SONUÇLAR VE DEĞERLENDİRMELER	89
KAYNAKLAR	91
ÖZGEÇMİŞ	95

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 2.1. 2008–2016 Yılları Türkiye elektrik sistemi puant güç ve enerji tüketimi..	9
Çizelge 2.2. Ocak 2018 döneminde faturalanan elektrik tüketiminin tüketici türü dağılımının dönemler arası karşılaştırılması (MWh-%)	18
Çizelge 4.1. Adaptif YSA’da kullanılan aktivasyon fonksiyonları	63
Çizelge 4.2. Genetik algoritma için tanımlanmış parametreler	64
Çizelge 5.1. OAYTM Bölgesi’ne dahil olan illerin her birinin elektrik enerjisi tüketimleri	67
Çizelge 5.2. Yapay sinir ağı değişken parametreleri	81
Çizelge 5.3. Benzetim sonuçları	82

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. 2007–2016 Yılları Türkiye gerçekleşen puant güç ve enerji tüketimi	10
Şekil 2.2. Elektrik enerjisi tüketiminin tüketici türü bazında dağılımı (%)	18
Şekil 2.3. Ocak 2018 döneminde elektrik tüketiminin saat bazında dağılımı (MWh) ...	22
Şekil 2.4. OAYTM Bölgesi 2017 yılı yük eğrisi (MW)	23
Şekil 2.5. OAYTM Bölgesi 2017 yılı Kasım ayı yük eğrisi (MW)	24
Şekil 2.6. OAYTM Bölgesi 13-19 Kasım yük eğrisi (MW)	24
Şekil 2.7. OAYTM Bölgesi kış mevsimi için seçilen 17.01.2017 Salı günü yük eğrisi (MW).....	25
Şekil 2.8. OAYTM Bölgesi ilkbahar mevsimi için seçilen 18.04.2017 Salı günü yük eğrisi (MW)	25
Şekil 2.9. OAYTM Bölgesi yaz mevsimi için seçilen 18.07.2017 Salı günü yük eğrisi (MW)	26
Şekil 2.10. OAYTM Bölgesi sonbahar mevsimi için seçilen 17.10.2017 Salı günü yük eğrisi (MW)	26
Şekil 2.11. OAYTM Bölgesi 26.08.2017 - 04.09.2017 günlerinin yük eğrisi (MW)	27
Şekil 2.12. OAYTM Bölgesi için 15.05.2017-21.05.2017 günleri arası yük eğrisi (MW)	28
Şekil 2.13. 2018 yılı Yılbaşı için yük eğrisi	28
Şekil 3.1. Basit bir bulanık mantık blok diyagramı	35
Şekil 3.2. İnsan sinir sisteminin blok diyagramı.....	43
Şekil 3.3. YSA sisteminin çalışma prensibi.....	43
Şekil 3.4. Yapay sinir ağı yapısı	45
Şekil 3.5. Çok katmanlı ileri beslemeli bir yapay sinir ağı.....	56
Şekil 5.1. OAYTM bölgesine dahil olan illerin elektrik enerjisi tüketimlerinin yüzdesel dağılımı (MWh)	68
Şekil 5.2. Benzer gün seçim sınırları	72

Şekil	Sayfa
Şekil 5.3. Yapay sinir ağ modeli	76
Şekil 5.4. 27.05.2013 tarihi için gerçek ve tahmini yük eğrileri.....	83
Şekil 5.5. 14.05.2013 tarihi için gerçek ve tahmini yük eğriler.....	83
Şekil 5.6. 20.02.2013 tarihi için gerçek ve tahmini yük eğrileri.....	84
Şekil 5.7. 08.08.2013 tarihi için gerçek ve tahmini yük eğrileri.....	84
Şekil 5.8. 08.08.2013 tarihi için gerçek ve tahmini yük eğrileri.....	85
Şekil 5.9. 28.09.2013 tarihi için gerçek ve tahmini yük eğrileri	85
Şekil 5.10. 20.10.2013 tarihi için gerçek ve tahmini yük eğrileri.....	86
Şekil 5.11. 14-18.10.2013 Kurban Bayramını kapsayan tarihler için gerçek ve tahmini yük eğrileri	86
Şekil 5.12. 23.04.2013 tarihi için gerçek ve tahmini yük eğrileri.....	87

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklamalar
$x_1, \dots, x_k$	Bağımsız değişkenler
y_i	Bağımlı değişkenler
$\beta_1, \dots, \beta_k$	Regresyon katsayıları
e_i	Hata terimi
x_t	Gözlem sayısı
A_t	Hareketli ortalama
S_t	Gözlemlerin yumuşatılmış değeri
α	Düzeltilme sabiti
$\psi_i(x)$	Girişlerin özelliği
W_i, b	DVM regresyon katsayıları
C, ε	Risk fonksiyonu parametreleri
$\Gamma_\varepsilon(a, f)$	ε -duyarsız kayıp fonksiyonu
$w_1, w_2 \dots w_i$	Ağırlık değerleri
v_i	YSA toplama işlevi
θ_i	Eşik değeri
α_j, β_{ij}	Ölçek vektörü
α_0, β_{0j}	Sapma değerleri
$G_{\text{ün}}$	Gün tipi değerleri
$G_{\text{ün}}^n$	Araştırılan günün gün tipi
$\widehat{G_{\text{ün}}}$	Tahmin edilecek gün için belirlenen gün tipi
$\Delta G_{\text{ün}}^k$	Tahmin edilecek gün ile benzer gün arasındaki gün tipi
$G_{\text{ün}}^k$	Benzer gün için gün tipi
GWh	Gigawatt saat enerji birimi
K, J	Nöron sayısı
KWh	Kilowatt saat enerji birimi

Simgeler**Açıklamalar**

L	Katman sayısı
$L_{\max}$	Gün içerisindeki puant güç değeri
L_n^k ($n = 1 \sim 24$)	Benzer güne ait 24 saatlik güç değerleri
m	Giriş katman nöron sayısı
MWh	Megawatt saat enerji birimi
N	Toplam veri örneği sayısı
n	Gizli katman nöron sayısı
$\hat{T}_{\max}$	Tahmin edilecek güne ait ortalama maksimum sıcaklık
$\hat{T}_{\min}$	Tahmin edilecek güne ait ortalama minimum sıcaklık
$T_{\max}^n$	Araştırılan günlere ait maksimum sıcaklık değeri
$T_{\min}^n$	Araştırılan günlere ait minimum sıcaklık değeri
$T_{\max}$	Maksimum sıcaklık
$T_{\min}$	Minimum sıcaklık
$\Delta T_{\max}^k$	Maksimum sıcaklık sapması
$\Delta T_{\min}^k$	Minimum sıcaklık sapması
$\hat{T}_{\max}^k$	Benzer gün maksimum sıcaklık
$\hat{T}_{\min}^k$	Benzer gün için minimum sıcaklık
θ	Sapma terimi
φ	Aktivasyon fonksiyonu

Kısaltmalar**Açıklamalar**

ANN	Artificial Neural Networks
ARMA	Autoregressive Moving Average
ARIMA	Autoregressive Integrated Moving Average
ARIMAX	Autoregressive Integrated Moving Average Exogenous Variables
ART	Adaptif Rezonans Teori Ağları
ÇLR	Çoklu Lineer Regresyon Analizi
EKK-DVM	En Küçük Kareler Destek Vektör Makineleri

Kısaltmalar**Açıklamalar****GSMH**

Gayri Safi Milli Hâsıla

GSYİH

Gayri Safi Yurt İçi Hâsıla

LVQ

Linear Vektor Quantization

MAED

Model for Analysis of Energy Demand

MAPE

The Mean Absolute Percentage Error

OAYTM

Orta Anadolu Yük Tevzi İşletme Müdürlüğü

OSB

Organize Sanayi Bölgesi

RMSE

Root Mean Square Error

SOM

Self Organizing Map

YSA

Yapay Sini Ağı

1. GİRİŞ

Türkiye ve dünya ülkelerinde enerji, stratejik kalkınma ve güvenlik konularının başında yer almaktadır. Enerji talebinin önemi, artan nüfus, şehirleşme, sanayi ve teknolojinin yaygınlaşması ve refah artışına paralel olarak yükselmesini sürdürmektedir. Enerjinin çok büyük bir kısmını ise elektrik enerjisi oluşturmaktadır. Elektrik güç sistemlerinin tasarım ve kaynak planlamalarında, arz ve çevre güvenliğinin sağlanarak sürekli, güvenilir, kaliteli ve düşük maliyetle enerji talebinin karşılanması temel hedefler haline gelmiştir.

Elektrik enerji sistemlerinin planlanmasında ve kontrolünde yük tahmini en belirleyici alanlardandır. Elektrik talebinin tahmin edilmesi, üretim birimleri başlangıç maliyetinin optimize edilmesine ve gerekli sayıda enerji tesislerinin inşa edilerek tasarruf sağlanmasına yardımcı olur. Ayrıca, yük tahminleri, güç dağıtımı ve planlaması için önemli bilgiler sağlayarak talep dalgalanması, değişen rezerv talebi, arızalara karşı hassasiyet gibi sistem işletme risklerini kontrol etmeye kolaylık sağlar. Dahası, serbest piyasada etkin fiyat teklifleri için enerji talebi temel alınır. Bu nedenle enerji piyasalarında neredeyse verilen tüm kararların temelini yük tahminleri oluşturmaktadır. Kısa dönem yük tahmini sonuçlarına göre elektrik enerjisi fiyatlarının optimize edilmesi; elektrik piyasalarının etkin, şeffaf, güvenilir ve sektör ihtiyaçlarını karşılayacak şekilde planlanmasına, kurulmasına, geliştirilmesine ve işletilmesine yardımcı olur.

Yük tahmini, güç sistemlerinin planlanması ve verimli bir şekilde işletilmesi için önemli bir konudur. Doğru tahminler elektrik cihazları ve regülatörler (sistem birimleri üzerinde) üzerinde önemli etkiye sahiptir. Elektrik talebinden daha fazla yapılan tahminler, çok sayıda güç besleme ünitelerinin devreye girerek sistemin gereksiz rezerv seviyelerine ulaşmasına ve aşırı enerji üretiminin yanı sıra güç tesislerinin inşasında önemli ölçüde boşa harcanmış yatırımlara neden olur. Buna karşılık, daha düşük tahminlerin yapılması rezerv seviyelerinin yetersiz kalıp talebin karşılanamamasına ve sistemin risk altında korunmasız bölgede işletilmesine yol açabilir.

Kısa Dönem Yük Tahmini genellikle saatlik tahminden bir haftaya kadar olan süreyi kapsar. Kısa dönem yük tahmini elektrik enerjisinin üretim, iletim ve dağıtım sistemleri içerisinde yük akışı analizi, güç sistemi çalışmaları, günlük sistem işletmesi ve verimlilik gibi birçok konuyu önemli ölçüde ilgilendirir. Başarılı bir tahminle temel işletme

fonksiyonları (hidro-termal koordinasyonu, ekonomik dağılım, yakıt planlaması ve ünitelerin bakımı gibi) verimli ve güvenilir bir şekilde gerçekleştirilebilir.

Son yıllarda, güç sistemi analiz ve kontrolünün birçok alanında, statik ve dinamik güvenlik analizlerinde, dinamik yük modellemesi, alarm işleme ve arıza teşhislerinde yapay sinir ağları kullanımı oldukça yaygındır. Kısa dönem yük tahmininde yük ile sıcaklık arasındaki lineer olmayan karmaşık problemin çözülmesi gerekmektedir. Bu nedenle tez çalışmasında, özellikle lineer olmayan karmaşık problemlerde oldukça iyi tahmin sonuçları elde edilmesinden dolayı yapay sinir ağlarına dayalı yöntemler kullanılarak kısa dönem yük tahmini yapılmıştır.

Yük tahmini ile ilgili yerli ve yabancı literatürde yapılmış çalışmalardan bazıları aşağıda kısaca anlatılmıştır.

[1]' de Kurulu güç, brüt elektrik üretimi, nüfus ve toplam abone sayısı bağımsız değişkenleri belirlenip, çoklu lineer regresyon analizi (ÇLR), yapay sinir ağları (YSA) ve en küçük kareler destek vektör makineleri (EKK-DVM) metotları kullanılarak 2018 yılına kadar Türkiye'nin net elektrik tüketiminin tahmini yapılmıştır. EKK-DVM ile bulunan sonuçlar, ÇLR ve YSA teknikleri sonuçları ile karşılaştırılmıştır. Bulunan sonuçlar EKK-DVM' nin elektrik enerjisi tüketiminde iyi bir tahmin aracı olduğunu göstermiştir.

[2]' de Türkiye'nin piyasa ve mevsimsel koşulları göz önüne alınarak, yapay sinir ağları ve uzman sistemlerin birlikte kullanıldığı, kısa vadeli elektrik talep tahminlerinde yüksek doğruluk derecesi sağlayan bir hibrit sistem geliştirilmiştir. Geliştirilen hibrit sistem ile kısa vadeli dönemler için, gerçekleşen değerlere yakın tahmin sonuçları elde edilmiştir.

[3]' te İran'daki yıllık elektrik tüketiminin tahmin edilmesine yönelik ekonomik kriterler göz önüne alınarak nüfus, Gayri Safi Yurt İçi Hâsıla (GSYİH), ithalat ve ihracat değişkenlerini girdi olarak kullanılarak zaman serisi ARIMA modeli ve YSA modeli tasarlanmıştır. Tasarlanan ağ modelleri karşılaştırıldığında YSA modelinin tahmin etme yeteneğinin gerçek değerlere daha yakın sonuçlar verdiği anlaşılmıştır.

[4]' te Yük talebi ile takvim ve sıcaklık gibi bağımsız değişkenler arasındaki ilişkiyi tahmin etmek için yarı parametrik regresyon modelleri önerilmiştir. Önerilen model,

Avustralya Ulusal Elektrik Piyasası güç sistemleri için yarım saatlik tahminden yedi güne kadar olan sürede elektrik talebini tahmin etmek için kullanılmıştır. Kullanılan modelin performansı, örnek deneylerin yanı sıra güç sistemlerinden gelen gerçek veriler ile sistem işletmesi yerinde kullanılmasıyla doğrulanmıştır.

[5]' te Kısa dönem elektrik yük tahminleri için yapay sinir ağına dayalı bir model geliştirilmiştir ve Kenya Ulusal Elektrik İletim Şirketi güç sistemlerinde gerçek yük verileri uygulanarak bir gün öncesinden yük tahmin etmek için modelin performansı değerlendirilmiştir. Tahmin sonuçları incelendiğinde modelin yeterli sayıda veri ile test edilmesiyle oldukça iyi performans gösterebileceği anlaşılmıştır.

[6]' da Yapay sinir ağları geliştirilen uyarlanabilir öğrenme algoritmasını ile gün içerisinde sıcaklık değişiminin yük tahminine etkisi araştırılmıştır. Önerilen uyarlanabilir öğrenme algoritmasında öngörülen günün bir önceki yıl aynı gün öğrenme aralığı kullanılmıştır. Önerilen yaklaşımın uygunluğu, Japonya'daki Okinawa Elektrik Şirketi'nin güç sistemi gerçek yük verilerine uygulanması yoluyla gösterilmiştir. Gün içerisindeki sıcaklık değişkenlerinin uyarlanabilir öğrenme algoritmasında kullanılmasıyla daha iyi tahminlerin yapıldığı görülmüştür.

[7]'de Nijerya Elektrik güç sistemi için yapay sinir ağları kullanılarak yük tahminlerini bir saat önceden verebilen kısa dönem yük tahmini üzerine bir çalışma sunulmuştur. Ağ, eğitim aşamasında kendisine verilen geçmiş yük verileri ile arasındaki doğrusal olmayan ilişkiyi belirleyerek yükün bir saat içinde ne olacağına dair bir tahmin yapabilmektedir. Çalışmada elde edilen sonuçlar, kısa dönem yük tahmini için yapay sinir ağlarının uygulanabilirliğini ve verimliliğini onaylamıştır.

[8]'de İstanbul İli Avrupa Yakası'nı besleyen iletim hatları için yeterlilik analizi ile birlikte bölgenin elektrik enerjisi yük tahmini yapılmıştır. Tahmin yöntemi olarak regresyon analizi kullanılmıştır. Puant yük verileri, şehrin nüfus ve Gayri Safi Milli Hasıla (GSMH) verileri bağımsız değişken olarak alınarak modellenen bölgenin 2025 yılına kadar puant yük tahmini yapılmıştır.

[9]'da Türkiye'nin 2010-2025 yılları arasındaki puant yük talebi ve toplam elektrik enerjisi talebi matematiksel modelleme kullanılarak tahmin edilmiştir. Kullanılan matematiksel

model ile Model for Analysis of Energy Demand (MAED) karşılaştırıldığında oldukça pratik bir yöntem olması açısından matematiksel model ile yük tahmini yapılmasının kullanışlı ve uygulanabilir bir yöntem olduğu belirlenmiştir.

[10]'da 2002 ve 2003 yıllarına ait gerçek güç ve sıcaklık değerleri kullanılarak geriye yayılım algoritması ile eğitilen çok katmanlı yapay sinir ağı modeli ve regresyon analizi yöntemi ile Gölbaşı bölgesinin kısa dönem yük tahmini uygulaması yapılmış ve YSA yönteminin gerçek değerlere daha yakın sonuç verdiği belirlenmiştir.

Bu tez çalışmasının birinci bölümünde tez çalışmasının konusu olan enerji sistemlerinin planlanmasında elektrik yük tahminin önemi ve kısa dönem yük tahmini konuları kısaca anlatılmış ve literatürde konu ile ilgili daha önce yapılan diğer akademik çalışmalardan kısaca bahsedilmiştir.

İkinci bölümünde yük tahmini ve yük tahmini çeşitleri (çok kısa dönem, kısa dönem, orta dönem, uzun dönem yük tahmini), yük tahmini yapılacak bölgenin yük karakteristiği ve yükü etkileyen faktörler ayrıntılı bir şekilde anlatılmıştır. Enerji güç sistemlerinde planlama kavramı açıklanarak planlamanın enerji sektörü için önemi ve aşamaları detaylı biçimde incelenmiştir. Yapılacak planlama çalışmalarında kullanılacak etken faktörler ve yük çeşitleri tanımlanmıştır.

Üçüncü bölümde elektrik yük tahmini ile ilgili kullanılan diğer tahmin yöntemleri, kullanılan yöntemlerin farklılıkları, avantajları ve dezavantajları ile bu tez çalışmasında kullanılan yapay sinir ağları modelleri ile kısa dönem yük tahmini konuları detaylı biçimde anlatılmıştır.

Dördüncü bölümde bu tez çalışmasında Orta Anadolu Yüz Tevzi İşletme Müdürlüğü'nün kısa dönem elektrik enerjisi yük tahmini için geliştirilen yapay sinir ağları ve genetik algoritma tabanlı adaptif hibrit sistem anlatılmıştır.

Beşinci bölümde kısa dönem yük tahmin modelinin oluşturulması, benzer günlerin seçilerek gerçekleştirilmesi, bilgisayar benzetim programının çalışma detayları anlatılmıştır. Yapılan tahmin sonuçları diğer akademik çalışmalar ve uygulamada kullanılan diğer yöntemlerle karşılaştırılmıştır.

Altıncı bölümde ise tez çalışmasının beşinci bölümünde elde edilen sonuçların ne tür anlamlar içerdiği açıklanmış ve öneriler sunulmuştur.





2. YÜK TAHMİNİ

2.1. Elektrik Enerji Sistemlerinde Planlama

Günlük hayatın vazgeçilmez bir parçası olan enerji, ülkelerin sosyo-ekonomik yapıları içerisindeki yerini ve önemini korurken, enerjinin önemli bir bileşenini oluşturan elektrik enerjisi ise ağırlığını giderek artan bir oranda geliştirmektedir. Nüfus artışı, sanayileşme, şehirleşme ve teknolojinin gelişmesi ile birlikte artan enerji talebinin karşılanması için küresel ekonomik ve jeopolitik dengelerin yeniden şekillendiği enerji sektörünün son derece dinamik olduğu bu dönemde enerji arz güvenliği kavramı ülkemiz ve dünya ülkeleri için kritik enerji stratejilerini ve politikalarını oluşturmada önemli bir yer tutmaya başlamıştır.

Enerji arz güvenliğinin sağlanarak artan elektrik enerjisi talebinin zamanında, yeterli, kaliteli, sürekli, düşük maliyetli ve çevreyle uyumlu bir şekilde karşılanıp tüketicilerin kullanımına sunulması ülkemizin kritik enerji politikaları arasında yer almaktadır. Bu kapsamda enerji alanındaki gelişmelerin yakın takipçisi olan Türkiye’de; Dünya elektrik piyasalarındaki gelişmelere paralel olarak, elektrik enerji talebini karşılamak için devreye girecek yeni üretim yatırımlarının piyasa yapısı içerisinde enerji politikalarının kaynak öncelikleri ile uyumlu sürdürülebilir koşullarda gerçekleştirilip, elektrik, iletim ve dağıtım hizmetlerinin kullanıcılara kaliteli, yeterli ve sürdürülebilir bir şekilde verilmesini sağlayacak rekabete dayalı serbest piyasa kuralları çerçevesinde işleyen mali açıdan güçlü, istikrarlı ve şeffaf bir Türkiye Elektrik Piyasası oluşturulması yönünde yasal düzenlemeler yapılmıştır [11,12].

30.03.2013 tarih ve 28603 sayılı Resmi Gazetede yayımlanarak yürürlüğe giren 6446 Sayılı yeni Elektrik Piyasası Kanunu ile başlayan süreçte, elektrik piyasasının şeffaf, güvenilir, rekabete dayalı ve diğer ülkelerin elektrik piyasaları ile bütünleşik bir elektrik piyasasının oluşturulması hedeflenmiştir. Elektrik piyasasının daha güçlü ve daha dinamik olması, piyasa katılımcılarının elektrik piyasasında daha etkin rol alması ve piyasayı işletenlerin en iyi şekilde piyasayı yönetmesi ve takip etmesi için izlenen ilk adım gelecekteki yük ihtiyacının tahmin edilmesidir [13].

Ekonomik kalkınmanın ve sosyal gelişmenin ihtiyaç duyduğu enerjinin, sürekli, güvenli ve düşük maliyetli temin edilmesi ve bu talebin karşılanırken enerjinin üretildiği noktadan iletim hatları üzerinden alıcısına ulaştığı noktaya kadar her safhasında verimli ve tasarruflu kullanılması, elektrik piyasasının sağlıklı işletilebilmesi bakımından enerji sistem işletmecilerinin başlıca hedefleri arasındadır. Bu nedenle sistem işletmecileri tarafından elektrik talebinin zamanında karşılanması için elektrik enerjisi üretim ve iletim gelişim planlamaları yapılmaktadır. İletim sistemi gelişim planlarında, enerji arzının kalitesinin ve sürekliliğinin en yüksek seviyede tutulması, ekonomik, kolay işletilebilir ve gelişime açık bir sistem tasarlanması, mevcut tesislerin ekonomik ömrü süresince kullanılması ve bunların iletim ve dağıtım şebekeleri ile birlikte finanse edilerek minimum yatırım maliyeti ile gerçekleştirilmesi temel amaçlardır. Bu kriterlerin yerine getirilip etkili bir sistem planlanması ve yönetilmesi için yük tahminine ihtiyaç duyulmaktadır.


İletim sistemi elektrik enerji sistemlerinin ana omurgasını teşkil etmekte olup iletim tesisleri yatırımları pahalı ve yapımı uzun süre alan, işletilmesi ülke ekonomisine etkileri açısından büyük önem taşıyan sistemler olduğundan bölgesel gelişim hedeflerinin, yük tahminlerinin, arz kaynak noktalarının önceden optimum olarak belirlenmesi gerekmektedir. Elektrik enerji talebinin mevsimlik, günlük, saatlik ve bölgesel farklılıklar gösteren kendine özgü yapısı ve elektrik enerjisinin depolanamaması nedeniyle, yük-talep eğrisine en iyi şekilde cevap verecek doğru yük tahminlerinin yapılması enerji sistemlerinin yatırım ve işletme birim enerji maliyetlerini en aza indirmeye yarayacak planlamaların yapılmasında bir çözüm olarak yerini alır [12,14].

Enerji sistemlerinin aylık, haftalık ve günlük işletme programları; fiili çalışma koşulları, iklim değişimleri, bakım onarım programları ile birlikte işletmede gerçek zamanda ortaya çıkacak program dışı üretim ve iletim devre dışı olmaları, beklenmedik talep ve hava koşulları gibi olaylar dikkate alınarak belirlenir. Sistemlerinin gerçek zaman şartları altında gerilim, frekans ve güç akışlarının belirlenen limitler içerisinde kararlılığını kaybetmeden işletilmesi işletme güvenliği esaslarındandır. İşletme güvenliğinin sağlanarak elektrik iletim sisteminin güvenilir ve düşük maliyetli olarak planlanması, işletilmesi ve tüketicilere kaliteli, yeterli ve düşük maliyetli elektrik enerjisi arz edilebilmesi için doğru ve etkin yük tahminlerine ihtiyaç duyulmaktadır [15].

Elektrik enerjisi talep deęişimine dikkat edilerek talebe karřılık gelecek řekilde arzın oluřturulması ve enerji darboęazlarının yařanmaması iin enerji g sistemlerinin dzenli olarak planlamalarının yapılması gerekmektedir. Bu planlamalar yapılırken en nemli basamak elektrik enerjisi talep tahminlerini oluřturmaktadır.

izelge 2.1. 2008 – 2016 Yılları Trkiye elektrik sistemi puant g ve enerji tktmi

YIL	PUANT G TALEBİ (MW)	ARTIř (%)	ENERJİ TALEBİ (GWh)	ARTIř (%)	MİN.YK (MW)	MİN.YK / PUANT YK ORANI (%)
2008	30.517	4,3	198.085	4,3	10.409	34
2009	29.870	-2,1	194.079	-2,0	11.123	37
2010	33.392	11,8	210.434	8,4	13.513	40
2011	36.122	8,2	230.306	9,4	14.822	41
2012	39.045	8,1	242.370	5,2	13.922	36
2013	38.274	-2,0	248.324	2,5	14.800	39
2014	41.003	7,1	257.220	3,6	14.927	36
2015	43.289	5,6	265.724	3,3	16.269	38
2016	44.734	3,3	278.346	4,7	17.796	40



Şekil 2.1. 2007–2016 Yılları Trkiye elektrik sistemi gerekleşen puant g ve enerji tktmi

2.2. Zamana Göre Yük Tahmini Çeşitleri

Etkili güç sistemlerinin planlanması ve verimli bir şekilde işletilmesi için gerekli olan puant yük ve enerji talebinin tahmin edilmesinin temelini oluşturan yük tahmini kavramı ise; geçmişteki koşulların ve verilerin incelenerek gelecekteki durumun tahmin edilmesine dayanır. Zamana göre yapılan planlama çalışmalarına bağlı olarak yük tahminleri genel olarak kısa, orta, uzun dönem yük tahminleri olmak üzere tahmin döneminin uzunluğuna göre çeşitli dönemlere ayrılır.

- Uzun dönem yük tahminleri
- Orta dönem yük tahminleri
- Kısa dönem yük tahminleri
- Çok kısa dönem yük tahminleri

2.2.1. Uzun dönem yük tahminleri

Enerji politikalarının belirlenmesi ve piyasa katılımcılarının uzun vadeli değerlendirme yapmalarına yardımcı olmak amacıyla, uzun dönemli talep projeksiyonları ve bu talebi karşılayacak üretim kompozisyonuna ve kapasite ihtiyaçlarına ilişkin projeksiyonlarının hazırlanmasında uzun dönem yük tahminleri kullanılır [11]. Bir yıldan daha fazla tahminler söz konusu olduğunda bu uzun dönem yük tahmini olarak adlandırılır. Uzun dönem yük tahminleri için kullanılan parametreler daha çok ekonomik faktörlerdir. Örneğin ülkelerin büyüme hızı, nüfus artışı, GSMH gibi etkenler bu tahminler için önemli parametrelerdir.

Uzun dönem yük tahminleri gelecek nesil, enerji üretim, iletim ve dağıtım tesislerinin geliştirilmesinde ilk adımdır. Uzun dönem yük tahminleri enerji sistemleri kapasitesin genişletilmesi, enerji kaynak stratejilerinin belirlenmesi, sermaye yatırımları, gelir analizi ve enerji piyasası yönetimleri araştırma çalışmaları için gereklidir. Özellikle yeni piyasa yapısı altındaki tahminlerde önemli bir sapma, arz tesislerinin gereğinden fazla inşa edilmesine veya tüketici talebinin azaltılmasına neden olacaktır. Bu kapsamda mevcut arz potansiyelini, potansiyel arz imkânlarını, yakıt kaynaklarını, iletim ve dağıtım sisteminin yapısı ve gelişme planlarını, ithalat veya ihracat imkânlarını ve kaynak çeşitliliği

politikalarının dikkate alınmasında gelecek yirmi yılı kapsayacak şekilde yapılan uzun dönem talep tahminlerinden yararlanılır. Böylelikle, sosyal ve ekonomik gelişme hedeflerini etkilemeden elektrik enerjisi tüketiminde verimliliği sağlayacak tedbirlerin uygulanmasına yardımcı olur [14].

Bununla birlikte, bazen önümüzdeki otuz yıl kadarını kapsayacak şekilde karakterize edilen uzun dönem tahminler beraberinde çok sayıdaki belirsizliği de getirir. Bu belirsizliklere ülkelerin büyüme hızı, sosyo-ekonomik durum, özel durumların ortaya çıkması, aşırı iklim koşulları ve elektrik sektörünün serbestleştirilmesine bağlı olarak tarife yapılanmalarındaki olası değişiklikler nedeniyle üretimdeki rekabet oluşması örnek verilebilir.

Bu koşullar altında klasik tahmin teknikleriyle yapılan orta ve uzun dönem yük tahminleri, dinamik ve hızlı büyüyen güç sistemlerini planlanmak ve enerji talep tahmini oluşturmak için yetersiz kalabilir. Dolayısıyla, bu konu mevcut tahmin tekniklerinin daha fazla geliştirilmesi arayışıyla bu tür sistemlerin tahmin problemi için başka bir yaklaşım geliştirilmesi yoluyla ayrı bir öneme sahiptir. Sonuç olarak daha doğru ve güvenilir tahminler için güncel bilgileri kapsayan yeni yaklaşımların sürekli geliştirilmesi gerekir.

2.2.2. Orta dönem yük tahminleri

Orta dönem yük tahminleri bir aydan bir yıla kadar olan zamanı kapsayacak şekilde yapılan tahminlerdir. Orta dönem yük tahminleri güç sistemleri yıllık işletme bakım programlarının oluşturulmasında ve kısa süre içerisinde elektrik iletim sistemine dahil edilecek santrallerin planlanma çalışmaları ile kaynak yakıt planlaması ve hidroelektrik sistemlerin rezerv yönetimini belirlemek için kullanılır.

Uzun dönem yük tahminleri gibi orta dönem yük tahminleri de ülkenin ekonomik değerleri ile birlikte nüfus artışı, büyüme hızı gibi parametrelere bağlıdır. Ancak uzun dönem yük tahmininden farkı tahmin edilecek yıl veya ay içerisindeki bazı dönemlik olayların (Örneğin ülkede yapılacak bir olimpiyat aktiviteleri, mevsimlik iş kolları vs.) yük değerlerine etki etmesi söz konusudur.

2.2.3. Kısa dönem yük tahminleri

Kısa dönem yük tahminleri genellikle saatlik tahminden bir haftaya kadar olan süre içerisinde yapılacak olan tahminleri kapsar. Kısa dönem yük tahminleri güç üretim koordinasyonu gibi işlevlerin planlanması için gereklidir. Bu koordinasyon, üretim kaynaklarının saatlik programlarının oluşturulması için kullanılabilir ve böylece enerji güç sistemleri işletme maliyeti en aza düşürülür. Aynı zamanda yapılan tahminler güvenlik analizi, ekonomik sevkıyat, yakıt planlaması ve ünite bakımı gibi enerji güç sistemleri temel işletme fonksiyonları için etkin bir rol oynamaktadır.

Buna ek olarak, kısa dönem yük tahmini kullanıcılara sürekli, güvenilir ve düşük maliyetli enerji sağlanması için akıllı şebekelerin önemli bir bileşenidir. Kullanıcıların enerji tüketimini azaltmaya veya enerji kullanım düzenini değiştirmeye yönelik enerji talep yönetimi için kolaylık sağlar. Değişen bu yük modellerinin önceden tahmin edilebilmesi için yük tahmini yapılması gerekmektedir. Elektrik piyasalarının şeffaf, ekonomik ve güvenilir yönetilmesi, yük tahmininin ne kadar doğru olduğuna bağlıdır. Elektrik alım satımının fiyatlandırılması, mevcut enerji talebiyle ilgili alınan kararlara bağlıdır.

Yük Tevzi Merkezleri, tüketici ihtiyaçlarını karşılanması için yeterli üretim yapılabilecek şekilde önceden yük modeli hakkında fikir sahibi olmalıdır. Günlük yük eğrisindeki puant değerinin tespitinde ve generatörlerin devreye girip çıkacağı zamanların belirlenmesinde kısa dönem yük tahminleri kullanılır. Gelecekteki puant yük talebinden daha fazla yapılan tahminler, ekstra güç besleme ünitelerinin devreye girerek sistemin yedek ve işletme maliyetlerinde gereksiz bir artışa ve aşırı enerji üretiminin yanı sıra güç sistemleri tesislerinin inşasında önemli ölçüde boşa harcanmış yatırımlara neden olur. Buna karşılık, daha düşük tahminlerin yapılması gerekli işletme rezerv seviyelerine ulaşamayarak talebin karşılanamamasına ve sistem istikrarının sağlanamayarak güç sistemi ağının bozulmasına, sistemin risk altında korunmasız bölgede işletilmesine, sistem oturmalarına yol açabilir [16].

Aynı şekilde, akıllı sayaçların ölçüm cihazlarının kullanımı, her son kullanıcı için günlük olarak tüketilen elektrik enerjisi miktarını doğru bir şekilde tahmin edebilme yeteneğini gerektirir, böylece yeterli enerji birimi önceden satın alınabilir.

Kısa dönem yük tahminleri doğruluğunun iyileştirilmesi, güç sistemleri işletmeleri üzerinde önemli bir etkiye sahiptir, çünkü işletme ekonomisi ve güç sistemlerinin kontrolü tahmin hatalarına karşı çok hassastır. Büyük tahmin hataları güç sisteminin türüne bağlı olarak yüksek işletme maliyetlerine neden olabilecek sistem bozulma riski olan sistem oturmalarına neden olabilir.

Kısa Dönem Yük Tahmini için gerekli süreler göz önüne alındığında orta ve uzun dönem yük tahminlerine göre çok farklı parametreler içerir. Bu parametrelerin her birisi ayrıntılı bir şekilde tez çalışmasının beşinci bölümünde analiz edilmiştir.

2.2.4. Çok kısa dönem yük tahminleri

Çok kısa dönem yük tahmini, güç sistemleri işletme kontrol merkezlerinde birkaç saniyede bir (örneğin 4 saniye) toplanan çevrimiçi verilere dayalı hareket edilerek birkaç dakika içerisinde (örneğin, 5 dakika) verilecek kararlar ile bir veya birkaç saatlik yük tahminleri yapmak için kullanılır. Güç sistemlerinin işletilmesi sırasında otomatik üretim kontrolü ve kaynak dağıtımı için kritik kararlar alınması gerektiğinde çok kısa dönem yük tahminlerinin doğruluğu çok önemlidir. Bununla birlikte, veri toplama cihazlarının muhtemel arızalanmasıyla ve karmaşık yük özelliklerinin görülmesi ile gürültülü veri toplama işleminden dolayı etkili çok kısa dönem yük tahminleri yapmak zordur.

2.3. Yüklerin Özellikleri ve Sınıflandırılması

Elektrik piyasasında düzenlemeye tabi tarifelerin hazırlanmasına, incelenmesine, değerlendirilmesine, değiştirilmesine ve onaylanmasına ilişkin usul ve esaslar Elektrik Piyasası Tarifeler Yönetmeliği'ne göre belirlenir. Bu Yönetmelik; iletim, toptan satış, dağıtım, bağlantı, perakende satış, piyasa işletim ve son kaynak tarifelerine ilişkin tarife önerilerinin hazırlanma kriterlerinin tanımlanmasını ve ilgili lisans sahibi kişilerin gelir ve/veya fiyat tavanlarının düzenlenmesine ilişkin usul ve esasları kapsar [17].

Yüklerin doğru sınıflandırmaları için tüketici gruplarının özellikleri dikkate alınmalıdır. Tüketici gruplarının tiplerine ve özelliklerine göre elektrik enerjisi tüketimleri farklılık göstermektedir. Yük tahmini yapılırken tüketici gruplarının kendine özgü yük

karakteristikleri iyi değerdendirilerek tüketim verilerinin ayrı ayrı incelenmesi gerekir. Buna göre tüketici gruplarını aşğıdaki biçimde sınıflandırabiliriz:

2.3.1. Sanayi

6948 sayılı Sanayi Sicili Kanununda tanımı yapılan ve ilgili resmi kuruluşça onaylı sanayi sicil belgesini ibraz eden sanayi işletmeleri bu abone grubu kapsamındadır. 4562 sayılı Organize Sanayi Bölgeleri Kanunu kapsamında olup, tek noktadan ölçüm yapılarak aboneliğı Organize Sanayi Bölge Müdürlüğü tüzel kişiliğı adına yapılan Organize Sanayi Bölgeleri, Sanayi ve Ticaret Bakanlığınca OSB sicil kaydı yapılmış ve onaylanmış Kuruluş Protokolünün ibraz edilmesi halinde bu abone grubu kapsamında değerdendirilir. 3218 sayılı Serbest Bölgeler Kanunu kapsamında kurulmuş olan ve dağıtım lisansı sahibi tüzel kişilerce tek noktadan ölçüm yapılmak suretiyle, elektrik aboneliğı, bölge işleticisi veya bölge kurucu ve işleticisi tüzel kişiliğı adına yapılan/yapılacak serbest bölgeler; bölge içinde üretim faaliyeti ruhsatına sahip kullanıcıların tüketimlerinin serbest bölge toplam elektrik tüketimi içerisindeki oranının daha yüksek olduğunun/olacağının ilgili resmi kuruluşça belgelenmesi halinde sanayi abone grubu kapsamında değerdendirilir. 5686 sayılı Jeotermal Kaynaklar ve Doğal Mineralli Sular Kanununun 12 nci maddesinin sekizinci fıkrasında belirtilen jeotermal kaynak dağıtımı ve üretimini yapan şirketler, Jeotermal Kaynaklar ve Doğal Mineralli Sular Kanunu Uygulama Yönetmeliğine göre alınmış “jeotermal kaynak dağıtım şirketi”, “jeotermal kaynak üretim şirketi” veya “jeotermal kaynak dağıtım ve üretim şirketi” belgelerini ibraz etmeleri halinde bu abone grubu kapsamında değerdendirilir. Otoprodüktör lisansına sahip üreticilerin kendi ihtiyaçlarına ilişkin elektrik enerjisi tüketimleri ile bunun dışındaki diğer üreticilerin deneme üretimlerinde ihtiyaç duyulan elektrik enerjisi tüketimleri bu abone grubu kapsamındadır. Çevre ve insan sağlığını korumak üzere içme suyu ve alıcı ortama verilen sıvı, gaz ve katı zehirli ve zararlı atıkların arıtılması amacıyla kurulan arıtma tesisleri sanayi abone grubunda değerdendirilir.

2.3.2. Ticarethane

Her türlü tesis ve işletmeler, kamu idareleri (resmi daireler), kamu kurum ve kuruluşları, şantiyeler, geçici ve gezici tesisler bu abone grubu kapsamındadır.

a) Hayır kurumları, dernekler, vakıflar, müzeler, resmi okullar, resmi yurtlar, resmi üniversite, resmi yüksekokullar, resmi kurslar, resmi sağlık kuruluşları, spor tesisleri, kültür balıkçılığı ve kümes hayvanları çiftliği:

- Dernekler, vakıflar, hayır kurumları, müzeler, resmi okullar, resmi üniversite, resmi yüksekokullar, resmi yurtlar, resmi sağlık kuruluşları,
- Kamu spor görevini yüklenmiş resmi kuruluşların spor tesisleri,
- Kültür balıkçılığı üretim tesisleri,
- Kümes hayvanları çiftlikleri,

Bu alt abone grubuna dahildir.

b) İçme-kullanma suyu ve tarımsal amaçlı soğuk hava depoları

2.3.3. Mesken

Mesken olarak kullanılan; müstakil binalar, apartmanlar ve apartmanlar içindeki bağımsız bölümler, konut kooperatifleri ve konut siteleridir. Bu yerlerin kalorifer, asansör, hidrofor, merdiven otomatığı, kapıcı dairesi vb. gibi ölçümleri ayrı sayaç ile yapılan ortak kullanım yerleri, ibadethanelerin ısıtma ve soğutma amaçlı tüketimleri ile müştemilatı niteliğindeki lojman ve benzeri yerleri mesken abone grubu kapsamındadır.

a) Şehit aileleri ve muharip/malul gaziler: Mesken alt abone grubudur.

2.3.4. Tarımsal sulama

Tarıma dayalı arazilerin (açık alan araziler) sulanmasını sağlamak amacıyla; 167 sayılı Yeraltı Suları Hakkında Kanun kapsamında ilgili resmi kuruluşlardan alınacak kuyu ruhsatı, su kullanma izin belgesi ile Tarım İl Müdürlüklerinden alınmış sulamanın tarımsal amaçlı olduğunu gösterir belgeyi ibraz eden; ana faaliyeti tarımsal üretim olan gerçek veya tüzel kişilerce kurulmuş sulama kooperatifleri, pompaj tesisleri ile münferit olarak tesis edilmiş tarımsal sulama elektrik tesisleri bu abone grubu kapsamındadır.

2.3.5. Aydınlatma

Bu abone grubu kapsamında:

- a) İl, ilçe, belde ile köylerdeki cadde ve sokakların genel aydınlatmaları ile trafik sinyalizasyonları
- b) Kamuya ait ücretsiz girilen park, bahçe, tarihi ve ören yerleri gibi halka açık yerlerin genel aydınlatmaları
- c) Karayolları Genel Müdürlüğüne ait otoyollar, yerleşim alanları dışındaki yollar, köprüler ve tünellerin aydınlatmaları
- d) Sınır aydınlatmaları
- e) Toplumun ibadetine açılmış ve ücretiz girilen ibadethanelerin aydınlatmaları yer alır.

Nüfus artışı, göç olayları ve diğer demografik durumlar ile bireysel refah düzeyindeki değişimler ve insanların sosyo-ekonomik davranışlarına bağlı olarak mesken tipi yüklerde yıllık artışlar görülmektedir. Bu durum öncelikle büyük kullanıcı sayısına sahip konut sektörü talebini etkilemektedir. Mesken tipi yüklerin günlük ve yıllık yük eğrilerine bakıldığında, mevsimlik değişimlerin yük karakteristiğini önemli ölçüde etkilediği görülür. Kış aylarında ısıtma ve aydınlatma, yaz aylarında ise soğutma ihtiyaçlarına bağlı olarak elektrik enerjisi tüketiminde bölgesel ve mevsimsel farklılıklar oluşur. Ülkemizde mesken yük eğrisi incelendiğinde en çok göze çarpan nokta, saat 17.00' den sonra başlayan ve 22.00' ye kadar devam eden puant taleptir. Talepteki bu yükseklik özellikle kış aylarında yükselirken sıcak aylarda azalmaktadır. Yazın ise puant talep daha çok öğlen vaktine yakın zamanlarda olmaktadır. Ayrıca Mesken grubu tüketicilerinin enerji talebi insanların kullanım alışkanlıklarına ve sosyal gelişimlerine göre kendi içerisinde bölgesel değişiklikler gösterebilir.

Ticarethane tipi yüklerde ticarethanelerin belirli bölgelerde yoğunlaşması ile bölgesel değişimler ve hava koşullarına bağlı olarak mevsimsel farklılıklar görülür. Ticarethane tipi yüklerin elektrik enerjisi tüketimlerini ısıtma ve soğutma amaçlı kullanımlar ile iş yerinin özelliğine bağlı olarak kullanılan elektrikli cihazların tüketimi kapsar. Ticarethane tipi yüklerin günlük ve yıllık yük eğrileri incelendiğinde soğuk ve sıcak aylar arasında oluşan en büyük elektrik enerjisi tüketim farkının, soğuk aylardaki akşam ısıtma harcaması ile sıcak aylardaki öğlen soğutma harcaması olduğu zamanlardır. Bu sebeple ticarethanelerde

puant talebin kışın saat 17.00' den sonra, yazın ise öğlen vakti görülme ihtimalinin daha yüksek olduğu gözlenmektedir [18].

Dünyada ve ülkemizde elektrik talebinin sektörel dağılımı incelendiğinde tüketimdeki en büyük payın sanayi sektörüne ait olduğu görülür. Sanayi tipi yüklerin enerji talebi daha çok ülkenin ekonomik büyümesine bağlı olarak değişir. Sanayi tipi yüklerin yük karakteristiği incelendiğinde en önemli özelliğinin tüm yıl boyunca genellikle aynı şekilde devam etmesidir. Sanayi abone grubunda enerji talebi gündüz saatlerinde artarken, saat 10.00-11.00 arası ilk azalışını göstermektedir ve talebin en büyük düşüşün görüldüğü zaman dilimi ise genel puant başlangıcıdır [19].

Tarımsal sulama tipi yüklerin enerji talebinde ziraat işletmelerinin kendine has özelliklerinden dolayı zirai üretim bölgelerinin hasat ve sulama zamanlarına göre çok önemli farklılıklar görülmektedir. Bu tip yükler mevsimlik değişimlerden önemli ölçüde etkilenir. Örneğin kışın soğuk aylarda, sulama yükü çok az olurken, yazın hem sulama yükü hem de bu yükün sebebi olarak zirai üretim bölge sayısı artmaktadır. Tarımsal sulama tarifesinden dolayı, gece yarısına yakın zamanlarda tarımsal sulama yükü talebi artmaktadır. Özellikle yaz aylarında sulama yapanlar elektriğin pahalı olduğu zamanlarda tüketimlerini gözle görülür şekilde azaltmaktadırlar [19].


Aydınlatma tipi yüklerin yük eğrileri incelendiğinde ise enerji talebinin Türkiye'nin değişik dağıtım bölgelerinde farklı zamanlarda yükseldiği görülür. Gün ışığından yararlanılan saatlerde genellikle sıfıra yakın olmaktadır. Aydınlatma süresi kışın yükselirken, yazın bu süre kısalır. Kış mevsiminde saat 16.00' dan sabah saat 07.00' ye kadar bir aydınlatma talebi oluşurken, yaz mevsiminde akşam saat 19.00-20.00' lerden sabah saat 06.00' ya kadar süren bir talep gözlenir. Böylelikle, kışın 15-16 saatlik bir aydınlatma süresine karşılık, yazın aydınlatma süresi 10-11 saatlere kadar düşmektedir [19].

Şekil 2.2. ve Çizelge 2.2.'de görüldüğü üzere Türkiye elektrik tüketiminin 5 abone grubu bazında (kayıp/kaçaklar ihmal edilmiştir.) değerlendirdiğimizde, en yüksek tüketimin sanayi sektöründe olduğu, bunu ticarethaneler ve mesken tüketici gruplarının takip ettiği görülmektedir.

Bu kapsamda, elektrik enerjisi talep tahmin modellerinde yukarıda belirtilen faktörler dikkate alınarak, tüketici sınıflarına göre net elektrik talepleri tahmin edilerek bunların toplamına kayıp ve kaçak öngörülleri eklenerek brüt enerji talebi hesaplanmaktadır.

Çizelge 2.2. Ocak 2018 döneminde faturalanan elektrik tüketiminin tüketici türü bazında dağılımının dönemler arası karşılaştırılması (MWh-%)

Tüketici Türü	2017 Ocak		2018 Ocak		Değişim (%)
	Miktar	Pay(%)	Miktar	Pay(%)	
Aydınlatma	430.995,70	2,260	465.582,23	2,345	8,02
Mesken	5.345.308,96	28,034	5.061.472,78	25,497	-5,31
Sanayi	7.463.646,87	39,143	8.324.549,57	41,934	11,53
Tarımsal Sulama	84.358,98	0,442	281.569,01	1,418	233,77
Ticarethane	5.743.154,07	30,120	5.718.355,96	28,806	-0,43
Genel Toplam	19.067.464,57	100	19.851.529,54	100	4,11



Şekil 2.2. Ocak 2018 döneminde faturalanan elektrik enerjisi tüketiminin tüketici türü bazında dağılımı (%)

2.4. Yüğü Etkileyen Faktörler

Yük tahminin doğru ve etkin bir şekilde yapılabilmesinin ön şartı, yüğü etkileyen çeşitli faktörlerin göz önüne alınmasıdır. Zaman faktörü, geçmiş hava durumu verileri, tüketicilerin sınıfı, bölgenin geçmişte talep ettiği yük, bölgenin büyümesi, yük miktarı artışı vs. Bunlar, talep yükünün hesaplanmasında kilit rol oynayan faktörlerdir [20].

Kısa Dönem Yük Tahmininde kullanılan parametreler Türkiye için sıralanmış faktörlerdir. Her ülkenin kendine özgü faktörleri var olup bunlar tahmin için parametre olacaktır. Kısa dönem yük tahmini için etkili olan faktörler genel olarak şunlardır:

2.4.1. Meteorolojik durumlar

Hava durumları yük tahminini etkileyen en önemli faktörlerden biridir. Sıcaklık, nem oranı, bulutluluk oranı, rüzgar hızı, mevsim vs. hava faktörlerine örnektir. Hava değişimi, ısıtıcı ve klima gibi elektrikli cihazların kullanımını etkileyerek yük eğrilerinde değişikliklere neden olur. Meteorolojik koşullara bağlı faktörleri kısa dönem yük tahmini girdileri olarak kullanmak önemlidir.

Sıcaklık

Yük tahmini yapılacak bölge için sıcaklık değerleri oldukça önemli bir etkidir. Sıcaklığa göre enerji talebi artış veya azalış göstereceğinden özellikle saatlik tahmin yapılırken sıcaklık değerleri önemli bir etki gösterir. Kış mevsiminde sıcaklığın oda sıcaklığının altına düşmesi, ısıtma yükünde bir artış anlamına gelir, ancak yaz aylarında sıcaklığın oda sıcaklığının üzerinde artması, klima yükünün artması anlamına gelir. (soğutma yükünün arttırılması) Sıcaklık etkileri genellikle yükün gerçek sıcaklık yerine etkin sıcaklık veya sıcaklık sapmasının bir fonksiyonu olduğu göz önüne alınarak modellenir. Sıcaklığın normdan sapması yük eğrilerinde büyük değişikliklerle sonuçlanabilir. Bunun nedeni, sıcaklığın genel etkilerinin mevsimlik yük döngüsüne zaten dahil edilmiş olması ve sadece normdan sapmaların yük değişiklikleri ile sonuçlanacağı gerçeğinden kaynaklanır [21].

Nem oranı

Yaz aylarında klima ve diğer ilgili soğutma yüklerini büyük oranda etkileyen hava durumu değişkeni atmosferdeki nem seviyesidir. Yüksek nem etkisi genellikle oda sıcaklığının üzerindeki yüksek sıcaklıklarda fark edilir. Nem etkisi, bağıl nemin, sıcaklık nem indeksinin veya çiğlenme noktası sıcaklığının bir fonksiyonu olarak gösterilerek yük modelinde düşünülebilir. Sıcaklık nem indeksi, yaz aylarında rahatsızlık seviyesinin bir ölçüsüdür ve hem sıcaklığa hem de bağıl neme bağlıdır. Yaz aylarında en büyük korelasyonu gösterir ve bölge yükünü önceden belirlenmiş sıcaklığının üzerinde etkiler.

Nem oranı diğer parametrelere göre daha az etkili bir faktör olmasına rağmen yük tahmini için bazı bölgelerde oldukça etkili bir parametre olabilir. Örneğin, Türkiye’de sıcaklığın yüksek olduğu Akdeniz Bölgesinde özellikle yaz aylarında nem oranının da etkisiyle gün içerisinde sıcaklık daha yüksek hissedilebilir. Bu durum enerji talebini arttıracığından yük tahmini için önemli bir parametre olarak düşünülür [21].

Bulutluluk oranı

Bulutluluk oranı da nem faktörü gibi bölgeden bölgeye değişen bir parametre olarak kullanılabilir. Örneğin, Karadeniz bölgesinde bulutluluk oranının yüksek olması, gün içerisinde güneşlenme süresini azaltacağından enerji talebinin artmasına neden olabilir.

Rüzgar hızı

Hava şartlarına bağlı yüke etkileyecek önemli faktörlerden biri rüzgardır. Rüzgarın soğutma gücünün doğrudan sonucu olarak rüzgar etkileri kış aylarında özellikle yaygındır. Rüzgarın soğutma etkisi, rüzgar hızına ve kuru sıcaklığa bağlıdır. Bazı araştırmacılar, yük modellerinde rüzgarın temsil edilmesi için rüzgar-soğutma faktörünü kullanmayı tercih etmektedirler, çünkü rüzgar-soğutma faktörü genellikle kış yükü ile ilişkilidir [21].

Aydınlatma

Gündüz aydınlatma, yük modeli üzerinde diğer faktörlerle karşılaştırıldığında küçük bir etkiye sahiptir. Literatürde araştırmalar genellikle bu faktörün çoğu yük modelinden

çıkarıldığını göstermektedir. Bu faktör bulutluluk oranı, toz, sis, pus vb. gibi hava koşullarından etkilenir.

Mevsim

Mevsim faktörü yük tahmini etkileyen bir diğer parametredir. Mevsimin yük üzerindeki etkisi daha çok sezonluk yapılan bazı işlerde gözlemlenir. Sadece bazı mevsimlere özgü yapılan aktiviteler enerji talebinin artmasına ya da azalmasına neden olabilir.

2.4.2. Zaman faktörü

Yük tahmini için zaman faktörü en önemli parametrelerden biridir. Konutların yük tüketimini etkileyen önemli zaman faktörleri; hafta içi / hafta sonu gibi gün tipleri, saat dilimi ile resmi ve dini bayram tatil günleri parametrelerini içerir. Yük tüketimi mesai saatleri, boş zaman, öğle saati ve uyku süresi gibi insanların yaşam tarzlarına bağlı olarak değişiklik gösterir.

Gün tipi


Gün Tipi doğrudan doğruya yük tahminine etkileyen en önemli parametrelerdendir. Hafta sonu veya hafta içi yapılan aktiviteler birbirinden farklılık arz ettiğinden enerji talebinde de değişiklikler görülür. Örneğin Cumartesi ve Pazar aynı karakteristikte günler olduğundan enerji tüketim değerleri birbirine yakındır. Aynı şekilde Pazartesi ve Cuma günlerinde birbirine benzer şekilde enerji tüketimi gerçekleşir.

Resmi ve dini bayramlar

Bu tip bayramlar veya tatil günleri enerji talebinin değiştiği günlerdir. Örneğin dini bayramların hafta içine geldiği bir yılda bütün bir hafta tatil ise tatilin başladığı günler enerji talebi yüksek olurken diğer günlerde düşüş görülebilir.

Saat dilimi

Gece ile gündüz arasındaki enerji talebi doğal olarak farklı olacaktır. Güneşin batışından itibaren gece yarısına kadar belli bir saate kadar elektrik tüketim değeri artarken, gece saatlerinde günün en düşük tüketim değerleri görülür.



Şekil 2.3. Ocak 2018 döneminde elektrik tüketiminin saat bazında dağılımı (MWh)

2.4.3. Ekonomik ve demografik faktörler


Konut doluluk seviyesi, insanların davranışları ve çevreyle olan etkileşimleri ile birlikte ticarethane ve sanayi tüketici gruplarının artması da yük tüketimi değerlerini etkiler ve enerji talep artışına neden olur. Ülkelerin büyüme hızı, nüfus artışı, sosyo-ekonomik durum nüfus dağılımı faktörleri, elektrik talebinin değişiminde büyük rol oynamaktadır. Bu tez çalışmasında sadece kısa dönem yük tahmini yapılacağı için ekonomik ve demografik faktörler önemli değildir ve dikkate alınmayacaktır.

2.4.4. Rastlantısal faktörler

2.5. Yük Eğrisinin Özellikleri


Tez çalışmasında yükü etkileyen tüm faktörlerin doğru olarak anlaşılabilmesi için kısa dönem yük tahmini yapılacak olan Orta Anadolu Yük Tevzi (Gölbaşı) Bölgesinin yıl içerisinde bazı günlerde gerçekleşen yük eğilimleri incelenmiştir. Çalışmada kullanılan veriler OAYTM' ne ait gerçek güç değerleridir.

Şekil 2.4.' te 2017 yılına ait OAYTM Bölgesinin elektrik enerjisi tüketiminin aylık gelişimi verilmiştir. Şekildeki yük eğrileri incelendiğinde kış ve yaz aylarındaki puant yükün, bahar aylarına göre daha fazla olduğu anlaşılmaktadır. Yıllık yük eğrisinde meteorolojik faktörlerinin etkisiyle oluşan mevsimsel ritim farklılıkları ayırt edilmektedir.




Şekil 2.4. OAYTM Bölgesi 2017 yılı elektrik enerjisi tüketiminin aylık gelişimi (GWh)

Şekil 2.5.' te 2017 yılı Kasım ayına ait yük eğrisi verilmiştir. Bir ay içerisindeki 4 hafta, zaman faktörüne bağlı haftalık ritimler olarak ayırt edilmektedir. Diğer günlere göre daha düşük görülen puant yük saatleri, hafta sonlarına denk gelen saatlerdir.




Şekil 2.5. OAYTM Bölgesi 2017 yılı Kasım ayı yük eğrisi (MW)

Şekil 2.6.' da 2017 yılında normal bir haftanın bütün günlerine ait yük eğrileri verilmiştir. Buradan da anlaşılacağı üzere Pazartesi gününden Cuma gününe kadar olan hafta içi günlerinin puant yük değerleri açısından aynı eğilimi gösterdiği, Cumartesi ve Pazar günlerinin ise hafta içi günlerine göre farklılık gösterdiği anlaşılmaktadır.




Şekil 2.6 OAYTM Bölgesi 2017 yılı 13-19 Kasım bir haftalık yük eğrisi (MW)


Şekil 2.7.'den Şekil 2.10'a kadar 4 ayrı mevsimden seçilen Salı günlerine ait yük eğrileri verilmiştir. Mevsime bağlı faktörlere göre yük eğrilerinde farklılıklar görülmektedir.




Şekil 2.7. OAYTM Bölgesi kış mevsimi için seçilen 17.01.2017 Salı günü yük eğrisi (MW)



Şekil 2.8. OAYTM Bölgesi ilkbahar mevsimi için seçilen 18.04.2002 Salı günü yük eğrisi.(MW)



Şekil 2.9. OAYTM Bölgesi yaz mevsimi için seçilen 18.07.2017 Salı günü yük eğrisi (MW)




Şekil 2.10. OAYTM Bölgesi sonbahar mevsimi için seçilen 17.10.2017 Salı günü yük eğrisi (MW)


Milli ve dini bayram günlerinin, hafta içine denk gelen tatil günlerinin veya yılbaşı gibi özel günlerin yük eğrileri normal günlerin yük eğrilerine göre farklılık gösterir. Genel olarak, özel günlerin yük değerlerinin normal yük seviyelerinin altındaki değerlere düştüğü görülür. Öte yandan, aynı özel günlerin yük eğrileri, sistem yükünün büyüme veya düşüş eğilimi nedeniyle her yıl farklı değildir. Özel günlerin yük eğrileri, gün tipi değişiklikleri ile farklılık gösterir. Bu özellik, tatil öncesi veya sonraki günlerde görülür. Kısa dönem

yük tahminini etkileyen Milli ve dini bayramlara ait özel günlerin de yük eğrilerinin ayrı incelenmesi gerekir. İşgünleri ve hafta sonu tatil günleri bütün ülkeler için aynı günler söz konusuyken, özel günler olarak sınıflandırılan günler ise farklı ülkeler için ayrılık gösterir.


Şekil 2.11.' de Kurban Bayramı'nı içine alan 10 günlük periyodun yük eğrisi gösterilmiştir. Periyodun ilk günü pazartesidir. Dördüncü gün arife günü; beşinci, altıncı, yedinci ve sekizinci günler bayram günüdür. Şekil 2.12.' da ise 19 Mayıs Atatürk'ü Anma, Gençlik ve Spor Bayramı'nı içine alan haftanın yük eğrisi verilmiştir. Milli ve dini bayram günlerinde diğer günlerden farklı bir yük karakteristiği görülür. Tatil günlerinin hafta içine denk geldiği durumlarda yük eğrisi farklı bir şekil almaktadır.



Şekil 2.11. OAYTM Bölgesi için Kurban Bayramı'nı da içine alan 26.08.2017–04.09.2017 günlerinin yük eğrisi (MW)



Şekil 2.12. OAYTM Bölgesi için 15.05.2017-21.05.2017 günleri arası yük eğrisi (MW)



Şekil 2.13. OAYTM Bölgesi için 2018 yılı Yılbaşı için yük eğrisi

3. YÜK TAHMİNİ YÖNTEMLERİ

Son yıllarda bilimsel literatürde kısa dönem yük tahmini için pek çok yöntem ve algoritmalar geliştirilmiştir. İncelenen enerji güç sistemlerine göre kısa dönem yük tahminlerinin belirlenmesi için en uygun tahmin yönteminin seçilmesi oldukça önemlidir. Özel bir yöntemi belirlemeden önce, enerji talebindeki değişimlerin ve mevcut elektrik şebeke yapılarının incelenerek kullanılacak farklı tahmin yöntemlerinin avantajlarına ve dezavantajlarına dikkat edilmesi gerekir. Tez çalışmasının bu bölümünde literatürde en çok kullanılan istatistiksel tahmin yöntemleri içerisinde regresyon analizi, zaman serileri analizi ile birlikte yük tahmini için uygulamada uzun süredir kullanılan en çok bilinen parametrik yöntemlerden trend analizi, son kullanım modeli ve ekonometrik modellerden bahsedilecektir. Öğrenmeye dayalı tahmin yöntemlerinden ise yapay sinir ağları (YSA), bulanık mantık algoritmaları, uzman sistemler ve genetik algoritma gibi yöntemlerden ve ayrıca istatistiksel öğrenme algoritmalarına ek olarak makine öğrenmesinin çeşitli tekniklerini birleştiren destek vektör makinelerinden bahsedilecektir.

3.1. Regresyon Analizi

Regresyon analizi, yük tüketimi ile tüketim sınıfı, hava durumu ve tarih gibi çeşitli değişkenler arasında bir ilişki modeli oluşturularak yük tahmininde kullanılan istatistiksel bir tahmin yöntemidir. İstatistiksel regresyon analizi, genel olarak basit doğrusal regresyon modeli ve çoklu regresyon modeli olarak sınıflandırılabilir. Basit doğrusal regresyon modelinde, tahmin değişkenlerin birbirleriyle doğrusal olarak ilişkili olduğu varsayılır ve Eş. 3.1'deki gibi basit bir ilişki ile ifade edilmektedir.

$$y = \beta_0 + \beta_1 x + \varepsilon_1 \quad (3.1)$$

Basit doğrusal regresyon analizi için Eş. 3.1'de x ve y değişkenlerin değerlerini göstermektedir. X değişkeni, bağımsız veya açıklayıcı değişkenler olarak adlandırılırken; y değişkeni, tahmin değişkeni olarak davranır ve bağımlı veya açıklanan değişken olarak adlandırılır. β_0 ve β_1 parametreleri sırasıyla doğru kesimini ve eğiminin sapmasını belirleyen regresyon katsayılarıdır. ε_1 , rastgele hata olarak varsayılan düz çizgi modelinden sapmayı temsil eden hata terimidir. Yukarıdaki basit doğrusal regresyon modelinde

bağımlı değişken y için tahmin değeri, bağımsız değişken x 'in mevcut verileri kullanılarak bir ε_1 marjı ile değerlendirilip tahmin edilebilir.

Çok değişkenli regresyon modeli basit doğrusal regresyon modeline benzer ancak çoklu değişkenler içerir. Çok değişkenli regresyon modelinin genel formülü Eş. 3.2'de verilmiştir.

$$y_i = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots \beta_k x_k + e_i \quad (3.2)$$

Yukarıdaki Eş. 3.2'de y_i tahmin edilecek değişken, $x_1, \dots, x_k$ bağımsız değişkenler iken, $\beta_1, \dots, \beta_k$ regresyon katsayılarıdır. Basit doğrusal regresyon modeline benzer şekilde e_i tahmin sırasında oluşan hatayı gösterir. Modeldeki tüm parametrelerin etkisi de hesaplanarak bağımlı değişken y_i için tahmin değeri belirlenir. Çok değişkenli regresyon modelinde yer alan değişkenlerin değerlendirilmesi, çeşitli istatistiksel tahminlerin uygulanmasıyla gerçekleştirilmektedir.

3.2. Zaman Serileri Analizi

Zaman serileri analizi istatistiksel tahmin yöntemleri modelinin dinamik bir türüdür. Zaman serileri analizi tekniği, elektrik talebi üzerine elde edilen farklı bilgilerin genellikle bir devresel değişim, mevsimsel değişim veya trend şeklinde olabilecek bir iç yapıya sahip belli bir zaman serisi boyunca gözlemlenen dalgalanmalara dayanır. Çalışma prensibi, yük eğrisi serilerinin farklı seriler vasıtasıyla sabit bir zaman serisine dönüştürülmesi ve beyaz gürültü serilerinin diğer serilerden filtrelenmesi üzerine kuruludur. Bu yöntem, yük eğrilerinin mevsimsel, haftalık ve günlük tahminlerle birlikte zaman serisi sinyalleri olduğunu varsayar. Serideki dalgalanmaları tespit ederek ortaya çıkaran bu yöntemler dijital sinyalleşme, görüntü işleme, yük tahmini veya ekonomi gibi alanlarda kullanılır [22].

Bu modelin zorluğu ise, olağandışı yük koşullarının üstesinden gelememesidir. Yük değişimleri belirli bir günde tutarsız olursa, normal koşullardan dolayı bu durum yük tahminine yansır. Ayrıca, yük davranışları yılın bazı dönemlerinde hızla değişebildiğinden, model yeni koşullara hızla uyum sağlayamaz.

Otoregresif-Hareketli Ortalamalar Modeli ARMA (Autoregressive Moving Average), Birleştirilmiş Otoregresif-Hareketli Ortalama Yöntemi ARIMA (Autoregressive Integrated Moving Average) ve Dışa Dönük Değişkenlerle Otoregresif-Hareketli Ortalama ARIMAX (Autoregressive Integrated Moving Average With Exogenous Variables) en sık kullanılan zaman serileri yöntemleridir.

Söz konusu yöntemlerden ARMA modelleri sabit işlemler için çoğu zaman kullanılmaktadır ve son yıllarda zaman serisi tahmininde popüler doğrusal modellerden birisidir. ARIMA modeli ARMA modelinin yanı sıra, durağan olmayan süreçleri de içerir. Her iki modelde yük ve zaman bilgileri girdi parametreleri olarak kullanılır. ARIMAX modelinin bu modeller arasında yük tahmini için en verimli ve doğru yöntem olduğu geçmiş çalışmalardan gözlemlenebilir, çünkü yük tahmini genellikle yöntemin uyguladığı zaman ve havaya bağlıdır. Bununla birlikte, bu yöntemin en büyük dezavantajı, belirli olayların serinin geçmiş düzenlemelerini bozması durumunda, geçmiş eğilimlerin basit ekstrapolasyonunun yanlış sonuçlar verebilmesidir.

Zaman serileri yöntemlerinin başlıca bileşenleri temel seviye, trend ve döngüsel dalgalanmadır. Bu bileşenleri temel alarak hareketli ortalama modeli, üstel düzeltme modeli gibi çeşitli zaman serileri yöntemleri tahmin için kullanılmıştır. Hareketli ortalamalar modeli matematiksel olarak Eş. 3.3'deki gibi yazılabilir:

$$A_t = (x_t + x_{t-1} + x_{t-2} + \dots + x_{t-n} + x_{t-n+1})/n \quad (3.3)$$

Eş. 3.3'de x_t , t döneminde yapılan gözlemi temsil eder. A_t , t döneminde gözlem yaptıktan sonra hesaplanan hareketli ortalamayı belirtir.

Üstel düzeltme modeli matematiksel olarak Eş. 3.4'deki gibi yazılabilir:

$$S_t = \alpha x_t + (1 - \alpha)S_{t-1} \quad (3.4)$$

Eş. 3.4'de α sıfır ile bir arasında değerlere sahip düzeltme sabitidir. S_t ise en iyi tahminimize dayanan ortalama değeri ile ilgili gözlemlerin yumuşatılmış değeridir [23].

3.3 Parametrik Yöntemler

Parametrik yöntemler, yük talebini etkileyen faktörlerin matematiksel model ile ilişkilendirilmesine dayanmaktadır. Parametrik modeller ile geçmiş yük verileri üzerine istatistiksel teknikler kullanılarak tahmin yapılır. Geleneksel istatistiksel yük talep tahmin teknikleri veya parametrik yöntemler uygulamada uzun süredir kullanılmaktadır. Bununla birlikte, bu yöntemler, yük ve bunu etkileyen bir dizi faktör arasında bulunan karmaşık doğrusal olmayan ilişkileri düzgün bir şekilde sunamaz. En çok kullanılan parametrik yöntemler trend analizi, son kullanım modeli ve ekonometrik modellerdir.

3.3.1 Trend analizi

Trend analizi, gelecekte gözlemlenebilecek yük değişikliklerini tahmin etmek için yük değişiklikleri ve yük talebi hakkında geçmiş verilere dayanan başka bir yük tahmini yöntemidir. Trend analizi, yük talebindeki geçmiş değişikliklere veya hareketlere odaklanır ve gelecekteki elektrik talebi değişikliklerini tahmin etmek için bunları kullanır. Genellikle, talebin neden geçmişte ya da gelecekte olduğu gibi yürüdüğüne pek fazla bir açıklaması yoktur. Eğilimler, sıklıkla bilgilendirilmiş yargı tarafından değiştirilir ve burada uzman tahminciler, gelecekteki elektrik talebini geçmişteki durumundan farklı gösterebilecek bilgi birikimine dayanan tahminlerini değiştirir. Trend analizi yoluyla tahmin, zaman serisi veri setinde çizilen bir eğilim çizgisinin geleceğe yansıtılmasına dayalıdır.

Trend analizinin avantajı, gerçekleşmesi kolay ve hızlı olmasıdır. Trend analizi yönteminin en büyük dezavantajı ise metodun gelecekteki elektrik talepleri üzerine yalnızca tek bir sonuç üretilip elektrik talebinin gelecekte neden belirli şekillerde hareket edeceğini açıklayamamasıdır. Enerji piyasalarında ve ülkelerin enerji politikalarında meydana gelen değişikliklerin elektrik talebini nasıl etkilediğini doğru bir şekilde ölçmek için fayda sağlamaz. Teknik gelecekteki gelişmeler hakkında yeterli bilgiye sahip olmayan tahminciler tarafından kullanıldığında tamamen yanlış sonuçlar çıkarılabilir.

3.3.2 Son kullanım modeli

Diğer bir parametrik yük tahmini yöntemi ise son kullanıcılardan edinilen bilgileri kullanarak tüketilen enerjiyi tahmin eden son kullanım modelidir. Bu bilgiler tüketicilerin kullanımı, evlerin büyüklüğü, tüketicilerin yaşı ve uygulamaları olabilir. Yöntem, tahminlerin temelini oluşturan değişiklikler ile tüketicilerin istatistiksel bilgilerine dayanmaktadır. Bu durum son kullanım modellerinin ağırlıklı olarak ticarethane, sanayi ve mesken sektörlerinde çeşitli elektrik kullanımlarına odaklanacağı anlamına gelir. Bu yöntem, elektrik talebinin soğutma, ısıtma ve aydınlatma için her zaman son kullanıcının talebine bağlı olduğu konseptine dayanmaktadır.

Yöntem, modellerin çeşitli uygulamaların bir fonksiyonu olarak kullanıldığında talep edilen elektriği açıklaması nedeniyle son derece doğrudur. Bununla birlikte, bu modelin doğruluğu tamamen son kullanıcılardan edinilen bilgilerin doğruluğuna ve miktarına dayanmaktadır. Örneğin, bazı durumlarda tüketici yaşı üzerine elde edilen bilgiler meskenlerin büyüklüğünün bilinmesine kıyasla daha kullanışlı olacaktır. Bunun nedeni ısıtıcılar, buzdolabı, video oyunları ve bilgisayarlar gibi çeşitli elektronik cihazlarıyla elektriği aşırı kullanma eğilimi gösteren genç yaş grubunu içeren belirli alanların olmasıdır. Bu durum, birey tarafından kullanılan bir evin büyüklüğünün küçük olabileceğini, ancak çok fazla elektrik tüketimi olabileceği anlamına gelir. Bu nedenle yük tahmincilerinin, son kullanıcıların talebi gibi dağıtım metodu faktörlerini de analiz ederek kullanılacak uygun değişkenleri belirlemesi çok önemlidir. Bunun dışında, son kullanım modelleri genelde son kullanıcılar hakkında daha fazla bilgi talep ederek ve geçmiş veriler hakkında daha az bilgi ister. Son kullanım yaklaşımı yönteminin davranışsal yönlerinin matematiksel denklemlere uyarlanması ekonometrik yöntemlerle bütünleştirilebilir ve böylece çok daha doğru yaklaşımlar elde edilir.

Son kullanım analizinin dezavantajı ise en son kullanım modellerinin, elektrik ve son kullanıcı arasında cihaz başına elektrik gibi sabit bir ilişki varsayıyor olmasıdır. Bu varsayım birkaç yıldan fazla sürebilir, ancak 10 veya 20 yıllık dönemlerin üzerinde enerji tasarrufu teknolojisi ve enerji fiyatları şüphesiz değişecektir ve bu ilişkiler sabit kalmayacaktır.

3.3.3 Ekonometrik modeller

Ekonometrik yaklaşım elektrik talebini tahmin etmek için ekonomik teorilerin ve istatistiksel tekniklerin bütünleştirilip kullanıldığı modellerdir. Bu yöntem, zaman serileri, regresyon analizi, istatistiksel öğrenme algoritmaları ve bulanık mantık gibi çeşitli tekniklere uygulanır. Yaklaşım, bağımlı değişken enerji tüketimi ile tüketimi etkileyen faktörler arasındaki ilişkiyi tahmin etmektedir. İlişkiler en küçük kareler metodu veya zaman serileri yöntemleri ile tahmin edilir. Bu çerçevedeki seçeneklerden biri, farklı sektörlerdeki tüketimin (mesken, ticarethane, sanayi vb.) hava, ekonomik ve diğer değişkenlerin bir fonksiyonu olarak hesaplanması durumunda ekonometrik yaklaşımı toplamaktır. Daha sonra tahminler son tarihsel veriler kullanılarak birleştirilir. Ekonometrik yaklaşımın son kullanım yaklaşımına entegrasyonu, davranışsal bileşenlerin son kullanım denklemlerine dahil edilmesidir.

Bu yöntemin en önemli avantajı, elektrik talebinin çeşitli faktörlerden nasıl etkilendiği hakkında ayrıntılı bilgi sunarak gelecekteki elektrik talep artışı hakkında ayrıntılı bilgi ve doğru veri sağlayarak gelecekte elektrik talebinin neden arttığı veya azaldığını açıklayabilmesidir. Ayrıca bu yaklaşım, elektrik talebinin hava ve ekonomik koşullar gibi çeşitli bağımlı değişkenlerden nasıl etkilendiğini göstermektedir.


Bu yöntemin en büyük dezavantajı ise sürekli esneklik varsayıyor olmasıdır. Sürekli esneklik olarak adlandırılan bu varsayımı özellikle elektrik fiyatlarının çok büyük değiştiği dönemlerde haklı kılmak, müşterileri elektrik fiyatlarına karşı daha duyarlı hale getirmek zor olabilir. Ekonometrik tahminlerin doğru olması için, tahmin döneminde elektrik talebindeki değişimlerin geçmişteki değişimler ile aynı kalması gerekir. Tahminin gerçekçi olabilmesi için, elektrik tüketimindeki değişiklikleri etkili bir faktör olarak içeren gelişmiş bir yöntem sunması gerekir.

3.4. Bulanık Mantık Algoritmaları

Bulanık mantık algoritma modelleri, kontrol karar mekanizmaları olan bulanık kuralları uygulayan kural tabanlı bir sistemdir. Bulanık kontrol sistemlerinin amacı normalde uzman bir insan operatörünü bulanık kural tabanlı bir sistemle değiştirmektir. Kurallar genellikle belirli uyaranlardan enerji talebindeki etkileri bir faktör olarak ayarlar. Model, tahmin için

‘eğer öyleyse değilse’ mantıksal ifadesini kullanarak basitçe bir dizi çıktı değişkenine girdi değişkenleri seti üzerinde eşleşme yapar. Bu uygulama eşleştirme türleri, uzman bilginin bulanık mantık modelleriyle birleştirilmesini sağlar. Bulanık mantık modelleri, uzmanlık bilgisine dayalı dilsel terimleri otomatik stratejilere dönüştüren algoritmalar sağlayabilir. Şekil 3.1’de bulanık mantık algoritmalarının temel konfigürasyonu gösterilmektedir [24].

Bulanık kurallar genellikle yapay sinir ağlarını eğitilmesi için sinir ağlarıyla bütünleştirilerek yük talep tahmini açısından daha iyi sonuçlar elde etmek için kullanılır. Bu hibrid sistemin avantajı, hem yapay sinir ağlarının hem de bulanık mantık çıkarımların faydalarının kullanılarak uzman bilgi ve tecrübelerinin aktarılması ve işlenmesi ile uzman tahminlerin yapılabilmesidir.



Şekil 3.1. Basit bir bulanık mantık blok diyagramı

3.5. Uzman Sistemler

Uzman sistemlerin alanında uzman kişiler tarafından üretilen kuralları uyguladığı bilinmektedir. Uzman sistemler ile uzmanın bilgi ve tecrübesinden edindiği bu kurallara dayalı tahminler yapılır. Uzman sistemler buluşsal yaklaşım niteliğindedir. Aynı zamanda bilirkişi görüşü her zaman istikrarlı ve güvenilir olmadığı için, net bir uzman değerlendirmesine sahip olmak zordur. Bu durum dengesiz kurallara yol açabilir.

Uzman sistemde yeni bilgi ve kurallar, bilgi tabanına eklenir. Sistem tarafından bu prosedürler ve kurallar daha sonra elektrik talebi hakkında otomatik olarak tahmin yapabilen yazılımlara dönüştürülür. Bununla birlikte, verimli tahminlerin yapılabilmesi için uzman tahminciler yazılım geliştiricileri ile birlikte tüm uzman bilgilerini yazılıma dahil etmeleri gerekmektedir. Bu işleme, varyasyonları doğru bir şekilde modellemeye yardımcı olan bir optimizasyon problemini çözerek önceki verilerden öğrenilen bir parametre veri tabanı da eşlik eder. Bu varyasyonlar dönemsel değişikliklerdir. Uzman sistemler değişen koşullardan etkilenirler.

Bu yöntemi kullanmanın avantajları, elektrik talebi hakkında tahmin yapılırken kullanımı kolay bir yöntem olup ve hızlı, doğru sonuçlar elde edilmektedir. Bunun nedeni, genellikle verimli ve hızlı çalıştırılabilen yazılım uygulamalarını içermesidir.

Uzman sistemler, tahmin yöntemleri ve tahmin kurallarının güncellenmesinde çok esnektir. Uzman sistemlerin sistem planlamacılarına, yıllık yük tahmini görevlerini yerine getirmek için faydalı bir yardımcı olarak hizmet etmeleri beklenmektedir [25].

3.6. Genetik Algoritma

Genetik algoritmalar son zamanlarda çeşitli problemler için dayanıklı stokastik arama algoritmaları olarak dikkat çekmektedir. Bu yöntem sınıfı, doğal seçim mekanizmasına dayalıdır. Doğal genetik, araştırma alanındaki noktaların en uygun, rasgele ve yapılandırılmış arama ve paralel değerlendirmesinin hayatta kalma kavramını birleştirmektedir. Genetik algoritmalar, yük akışı analizleri, arıza bulma, kararlılık analizi, ekonomik dağıtım, güç sistemi kontrolü ve yük talep tahmini gibi çeşitli alanlarda başarıyla uygulanmaktadır.

Yapay zekaya dayalı diğer bir teknik genetik algoritmaların kullanılmasını içerir ve yük tahmininde genetik programlamanın kullanılması ile ilgilidir. Bu programlamadan elde edilen sonuçlar, başarıyla uygulandığı sürece genellikle hata olasılığı düşük olduğu için güvenilirdir. Bu yaklaşım, aynı zamanda adapte olabilen ve öğrenilebilen bir genetik sinir ağı modeli ile birlikte kullanılabilir. Bu da genetik algoritmaların sağlam ve güvenilir olduğu anlamına gelir. Bu noktada model, yükü etkileyen tüm değişkenler yansıtıldığı kapsamlı bir etki yaratmak için alanında uzmanların fikirlerini ve deneyimlerini içerir. Bu

inceleme, tekniğin sayısal bir optimizasyon yaklaşımı kullandığını açıkça ortaya koymaktadır.

Genetik algoritmaları kullanmanın temel avantajı, kararsızlık, doğrusalsızlık, sağlamlık ve belirsizlik gibi hesaplamaların tüm yönlerini içermesidir.

Genetik algoritmalar sayısal bir optimizasyon tekniğidir. Daha spesifik olarak, bunlar doğal genetiğin mekaniğine dayanan parametre arama yöntemleridir. Bu teknik, son yıllarda mühendislik, bilim, ekonomi, finans gibi çeşitli problemler için sağlam bir optimizasyon aracı olarak popülerite kazanmıştır. Önemli özelliklerden bazıları aşağıdaki gibi özetlenebilir:

- **Öğrenme:** Genetik algoritmalar, mevcut performans veya öğrenme özelliklerini kullanarak belirli bir çalışma alanını keşfetme ve kullanma becerisine sahip en iyi bilinen ve yaygın olarak kullanılan global arama teknikleridir.
- **Genetik Kod Yapısı:** Genetik algoritmalar, doğrudan parametreler üzerinde değil, kodlanmış bir parametre dizisi üzerinde çalışır. Bu durum, kullanıcının sorunun herhangi bir yönünü optimize edilebilir bir değişken olarak ele almasını sağlar.
- **Çözümlerin Optimizasyonu:** Birçok sorunda pürüzsüzlüğün garantisi yoktur. Geleneksel arama teknikleri genellikle bu tür arama alanlarında kötü bir şekilde başarısız olurlar. Genetik algoritmaların karmaşık arama alanlarında en iyi çözümleri bulma yeteneğine sahip olduğu bilinmektedir.
- **Gelişmiş Operatörler:** Birden fazla çözüm keşfetmek için, sinir ağları, bulanık mantık ve kaos teorisinin kombinasyonları ve çok amaçlı optimizasyon gibi teknikleri içerir [25].

3.6.1. Basit bir genetik algoritmanın yapısı

Basit bir genetik algoritma, algoritmanın performansını önemli derecede etkileyen beş temel parametreden oluşmaktadır. Bunlar: Çözümlerin temsil şekli, başlangıç popülasyonunu oluşturma yöntemi, uygunluk/kalite değerlendirme fonksiyonu, kullanılan genetik operatörler ve kontrol parametreleridir [33].

Temsil Mekanizması: Genetik algoritmalarda karmaşık yapıların temsilinde en sık kullanılan mekanizma (0,1) ikili bit dizisidir. İkili kodlama en yaygın kullanılan kodlama

teknikidir. Aynı zamanda ikili sistemde uniform kodlama ve Gray kodlama gibi temsil mekanizmaları da mevcuttur [33].

Başlangıç Popülasyonunun Oluşturulması: Genetik algoritmaların başlangıç popülasyonunu genellikle rasgele sayı üreticisi kullanılarak oluşturulur. Problemlerle ilgili başlangıçta bazı çözümler biliniyorsa başlangıç popülasyonu bu çözümler kullanılarak da oluşturulabilir. Optimal çözüm bulmada zaman açısından tasarruf sağladığı için uygulamalarda genellikle bu yöntem tercih edilir [33].

Uygunluk/kalite Değerlendirilmesi: Genetik algoritmanın performansını, çözümlerin kalitesini belirlemede kullanılan teknik oldukça etkiler. Araştırmanın başlangıcında ham sonuçların kullanımı yeterli olsa da, araştırma ilerledikçe iyi ve daha iyi çözümler veya kötü ve daha kötü çözümler arasındaki farkı belirlemek zordur. Bu durumda genetik algoritmanın çözümleri geliştirmesi olumsuz etkilenir. Böylelikle uygunluk değerlendirme biriminde normalizasyon işlemine ihtiyaç duyulur.

Genetik Operatörler: Genetik algoritmalar genellikle tekrar üreme, çaprazlama ve mutasyon operatörlerinin değişik formlarını içeren geliştirilmiş genetik operatörleri kullanırlar. Genetik algoritmaların performansı için uygun operatörlerin kullanımı oldukça önemlidir. Özellikle karmaşık problemlerin çözümünde, probleme özel geliştirilmiş operatörlere ihtiyaç duyulur. Genellikle kullanılan genetik operatörlerden bazıları şunlardır:

Tekrar Üreme Operatörü: Tekrar üreme operatörü kalitesi yüksek bireylerin hayatta kalıp sayılarının artması, kalitesi düşük bireylerin de sayılarının azalarak kaybolması prensibine sahip bir genetik algoritma elemanıdır. Yapay sistemlerde bu seçme işlemi amaç fonksiyonu ve kalite değerlendirme işlemleri tarafından kontrol edilir. Daha kaliteli çözümler popülasyonda baskın olurken, kalitesiz olanlar ise zamanla kaybolur. Bu operatörün uygulanmasında rulet tekerleği metodu kullanılır [33].

Çaprazlama Operatörü: Çaprazlama operatörü genetik çaprazlama yoluyla ortaya çıkan hibrit yapıların üretilmesine benzer bir özelliği genetik algoritmaya kazandırır. Eşleştirme havuzundan bir çift rastgele seçilir ve çaprazlama operatörü ile bu iki yapıdan yeni bir iki yapı meydana getirilir. Eski yapılar ve ortaya çıkan yeni iki yapılar mevcut jenerasyonda

tutulur veya birbirleri ile yer deđiřtirirler. İkinci durumda kötü yapılar atılarak popölasyon büyüklüğü sabit tutulur. Çaprazlama operatörleri, iyi çözümlerden daha iyi çözümler üreterek yapıların elamanlarını birleřtirir [33].

Mutasyon Operatörü: Mutasyon operatörü genetik mutasyon olayının benzerini yaparak, mutasyon oranına göre bitlerin deęerlerini tersine döndürme işlevini yerini getirir. Mutasyon yeni, görölmemiş, araştırılmamış çözüm elemanlarının bulunmasını saęlayarak genetik algoritmanın performansında etkin rol oynar. Mutasyon operatörü kullanılmayan genetik algoritmaların iyi bir performans göstermeleri ancak popölasyonların oldukça büyük tutulmasıyla saęlanır [33].

Kontrol Parametreleri: Genetik algoritmaların temel kontrol parametreleri řunlardır; popölasyon büyüklüğü, maksimum jenerasyon sayısı, çaprazlama ve mutasyon oranlarıdır.

Popölasyon Büyüklüğü: Bu parametre için seçilen deęerin genetik algoritmanın performansına etkilerinden birincisi, popölasyon büyüklüğünün aşırı küçölmesi araştırma uzayının yetersiz örneklenmesine sebep olur ve böylece kontrollü ıraksamayı saęlamak zorlaşır ve araştırma belirli bir alt optimal noktaya doęru sürüklenir. İkincisi ise popölasyon için aşırı yüksek deęer seçildiğinde bir jenerasyonluk gelişim için oldukça uzun sürüye ihtiyaç duyulur. Gerçek zamanlı problem uygulamalarında istenmeyen bir durumdur [33].

Çaprazlama Oranı: Çaprazlama operatörünün frekansını belirlemek amacıyla kullanılan parametredir. Düşük çaprazlama oranı yeni kuşaęa çok az sayıda yeni yapının girmesine sebep olmakla birlikte, yüksek çaprazlama oranı araştırma uzayının çok hızlı bir şekilde araştırılmasına sebep olur.

Mutasyon Oranı: Mutasyon operasyonu arařtırmaya yeni bölgelerin girmesini saęlar. Yüksek mutasyon oranı arařtırmayı çok hızlı ıraksatarak popölasyonun gelişmesine engel olur. Çok düşük mutasyon oranının kullanılması ise ıraksamayı aşırı düşürerek araştırma uzayının tamamen araştırılmasına engel olur. Dolayısıyla etkili bir genetik algoritma tasarlamak için mutasyon oranının frekansı çok iyi kontrol edilmelidir [33].

3.7. Destek Vektör Makineleri (DVM)

Destek vektör makineleri sınırlı sayıda öğrenme modellerinde iyi genellemeler elde etmek için bilgi veya verilerin sınıflandırılması için kullanılan bir yöntemdir. Destek vektör makineleri geleneksel sinir ağları modellerinin deneysel/gözlemsel risk minimizasyonu ilkesinden ziyade yapısal risk minimizasyonu prensibine dayanan bir tekniktir. Örneğin, yinelenen sinir ağı bu tekniğin bir parçasıdır ve her birimin tüm ağın bir çıktısı olduğu ve bir eğitim sürecinde girdi olarak düzeltilmiş bilgilerin sağlanması düşüncesine dayanır. Yinelenen sinir ağları genellikle geriye yayılım algoritmaları tarafından eğitilir. Düğümler arasındaki ağırlıkları belirlemek için genetik algoritmalara sahip DVM' ler kullanılır.

Destek vektör makineleri için destek vektör sınıflandırılması ve destek vektör regresyonu olmak üzere iki ana kategori vardır. Destek vektör makineleri, yüksek boyutlu öznitelik uzayı uygulamalarının ve destek vektörlerinin bir alt kümesinde genişletilmiş tahmin fonksiyonları üreten bir öğrenme sistemidir. DVM, karmaşık gri düzey yapılarını yalnızca çok az destek vektörüyle genelleştirebilir. Böylece görüntü sıkıştırma sistemi için yeni bir mekanizma sağlanmaktadır.

Destek Vektör Makinesi, veri sınıflandırması için yararlı bir tekniktir. Sinir ağlarından daha kolay kullanıldığı düşünülse de bununla birlikte, DVM' ye aşina olmayan kullanıcılar genellikle ilk uygulamalarda tatmin edici sonuçlar elde edememektedir. Doğrusal olmayan regresyon tahmin problemlerini çözmek için DVM' ler geliştirilmiştir.

DVM regresyonunun temel kavramı, orijinal veriyi x doğrusal olmayan olarak daha yüksek boyutlu bir öznitelik uzayına eşlemektir. Burada, Eş. 3.5'de bir dizi veri ele alındığında x_i girdi vektörü, a_i gerçek değer ve N toplam veri örneği sayısıdır.

$$G = \{ (x_i, a_i) \}_{i=1}^N \quad (3.5)$$

DVM regresyon fonksiyonu Eş. 3.6'da verilmiştir:

$$f = g(x) = W_i \psi_i(x) + b \quad (3.6)$$

Eş. 3.6'da $\psi_i(x)$ girişlerin özelliği W_i ve b ise katsayılarıdır. Katsayılar (W_i ve b) Eş. 3.7'deki düzenlenmiş risk fonksiyonunu asgariye indirgeyerek tahmin edilir:

$$r(C) = C \frac{1}{N} \sum_{i=1}^N \Gamma_{\varepsilon}(a_i, f_i) + \frac{1}{2} \|\omega\|^2 \quad (3.7)$$

$$\Gamma_{\varepsilon}(a, f) = \begin{cases} 0, & |a - f| \leq \varepsilon \\ |a - f| - \varepsilon, & \text{diğer} \end{cases} \quad (3.8)$$

Eş. 3.7 ve Eş. 3.8'deki C ve ε kullanıcı tarafından belirtilen parametrelerdir. $\Gamma_{\varepsilon}(a, f)$, ε -duyarsız kayıp fonksiyonu olarak adlandırılır. Eğer tahmin edilen değer ε sınırları içerisinde ise kayıp sıfıra eşittir. $\frac{1}{2} \|\omega\|^2$, fonksiyonun düzgünlüğünü ölçer. Dolayısıyla C , deneysel risk ile model düzgünlüğü arasındaki dengeyi belirtir.

3.8. Yapay Sinir Ağları (YSA)

Yapay Sinir Ağı (YSA), biyolojik sinir ağlarının çalışmasına dayanan bir sistemdir. YSA, temel olarak deneyimlerden öğrenen insan beyninin nöral yapısına dayanan nispeten kaba elektronik modellerdir. Model biyolojik bir nöronun işlevselliği üzerine kurulmuştur. Biyolojik sistemlerde öğrenme, nöronlar arasında var olan sinaptik bağlantıların ayarlanmasını içerir. Tüm biyolojik beyinlerin temel yapı taşı bir sinir hücresi veya bir nörondur. Bir nöronun temel bir bileşeni, ağı çeşitli girişleri gösterir. Aynı prosedür YSA için de kullanılır. YSA'lar da insanlar gibi, örneklerle öğrenirler.

Genel olarak, sinir ağları, çeşitli görevleri yerine getirmek için tasarlanmış basit matematiksel tekniklerdir. Yapay sinir ağları örüntü tanıma, veri madenciliği, sınıflandırma, tahmin ve süreç modelleme gibi çeşitli görevleri gerçekleştirmek için çeşitli düzenlemelerle yapılandırılabilir. Bir sinir ağının yazılım uygulaması avantajları ve dezavantajları ile yapılabilir.

Yapay sinir ağlarının avantajları şöyle sıralanabilir:


- Bir sinir ağı, doğrusal bir programın yapamayacağı görevleri gerçekleştirebilir. Yapay sinir ağı bir unsuru başarısız olduğunda, paralel doğası gereği herhangi bir sorun olmadan ağ işlevselliğine devam edebilir.
- Ağı yeniden programlanmasını ve öğrenilmesini gerektirmez, herhangi bir sorun olmadan herhangi bir uygulamada uygulanabilir.
- Verileri eğiterek öğrenebilme ve genelleme yapabilme yeteneğine sahiptir. Bu nedenle programlamanın diğer yeteneklerine ihtiyaçları yoktur.
- Özellikle hata toleransı oldukça yüksektir bu durum biyolojik sistemlerde bulunan kontrollü azalmaya eşdeğerdir.
- Gürültüye karşı yüksek toleranslıdır, böylece normal mantık sistemlerin zorlandığı durumlarla başa çıkabilirler.
- Prensip olarak, mantık sistemlerinin yapabileceği her şeyi ve daha fazlasını yapabilirler.
- Son derece güçlü hesaplamalı cihazlarla benzer yetenekleri vardır.

Dezavantajlar şunları içerir: Yapay sinir ağının çalışması için eğitime ihtiyacı vardır. Bir sinir ağının mimarisi, mikroişlemciler mimarisinden farklıdır. Bu nedenle ağı benzetilmesi gerekir. Bu durum büyük sinir ağları için yüksek işlem süresi gerektirir. YSA'nın diğer büyük bir dezavantajı ise, ağ içerisinde işlevlerin ve verilerin saklama alanının bilinmemesidir ve diğer sistemlere uyarlanması zor olması ve bazı ağların kararlılık analizlerinin yapılamamasıdır.


Yapay sinir ağları, verilerden bir işlev gerçekleştirmeyi öğrenen uyarlamalı, çoğu zaman doğrusal olmayan bir sistemdir. Yapay sinir ağları, performans kriterlerini optimize etmek veya genellikle öğrenme kuralı olarak adlandırılan bazı içsel kısıtlamaları takip etmek için sistematik adım adım prosedürlerle oluşturulur. Giriş/çıkış eğitimi verileri yapay sinir ağı teknolojisinin temelidir. Çünkü en uygun çalışma noktasını belirlemek için gerekli bilgileri iletirler. Sinir ağının işleme elemanlarının doğrusal olmayan yapısı sistemin istenen herhangi bir girdi / çıktı haritasına ulaşmak için çok fazla esneklik sağlar.

Yapay sinir ağlarının tarihsel gelişimi incelendiğinde, 1970 yılının bir dönüm noktası olduğu anlaşılmaktadır. Bu tarihe kadar birçok araştırmanın yapıldığı, ancak 1969 yılında XOR probleminin çözülememesi nedeni ile araştırmalara ara verildiği görülmektedir. 1970

yılından sonra sınırlı sayıda araştırmacının çalışmalarını sürdürmeleri ve XOR probleminin çözülmesi sonucu yapay sinir ağlarına olan ilgi yeniden ortaya çıkmıştır. Sonraki 10 yıl içerisinde birbirinden farklı modeller geliştirilmiştir. Aynı zamanda bu zaman aralığında çalışmalar laboratuvarlardan çıkarak günlük hayatta kullanılan sistemler haline getirilmiştir. Bu alandaki çalışmalar yapay zeka ve donanım teknolojisindeki gelişmeler ile de desteklenerek günümüz teknolojisinde pek çok alanda uygulamalardan faydalanan sistemler olarak yer edinmiştir (Öztemel, 2003: 30).



Şekil 3.2. İnsan sinir sisteminin blok diyagramı



Şekil 3.3. YSA sisteminin çalışma prensibi

Şekil 3.2 ve Şekil 3.3'te biyolojik sinirlerin ve YSA sisteminin çalışma prensibindeki benzerlik gösterilmektedir. Yapay sinirler, biyolojik sinirlere göre daha basit olmasına rağmen dört temel biyolojik sinir işlevini yerine getirir. Şekil 3.3' te x_i sembolü ile gösterilen girişler ($x_1, x_2 \dots x_n$) çevreden aldığı bilgiyi sinire getirir. Bu girişlerin her biri ağırlık w ile çarpılır. Ağırlıklar ($w_1, w_2 \dots w_i$) yapay sinir tarafından alınan girişlerin sinir üzerindeki etkisini belirleyen uygun katsayılarıdır. Her bir giriş kendine ait bir ağırlığa

sahiptir. Toplama işlevi v_i sinirde her bir ağırlığın ait olduğu girişlerle çarpımının toplamalarını eşik θ_i değeri ile toplayarak etkinlik işlevine gönderir. Toplama işlevinin sonucu etkinlik işlevinden $f(\text{etkinlik})$ geçirilip çıkışa iletilir. Çıkış $y_i = f(s)$ etkinlik işlevi sonucunun dış dünyaya veya diğer sinirlere gönderildiği yerdir (Elmas, 2010: 31).


Yapay sinir ağlarını kısa dönem yük tahmini için son derece uygun kılan temel faktörler şöyle sıralanabilir: Elektrik yükü ve hava koşulları gibi diğer değişkenler arasında önceden varsayılmış bir işlevsel ilişki gerektirmez. Önceden belirlenmiş modele gerek duymadan elektrik yükü, hava değişkenleri ve geçmiş yük modelleri arasında doğrusal olmayan bir eşlem sağlar. Genellikle hataya dayanıklı ve güvenilirdir.

3.8.1 Yapay sinir ağlarının temel yapısı

Çok katmanlı ileri beslemeli sinir ağları ve özellikle çok katmanlı perceptron sinir ağları en yaygın yapay sinir ağlarıdır. Perceptron ağının genel formu 3 katmana sahiptir. Bunlar giriş katmanı, gizli katman ve çıktı katmanıdır.

Giriş ve çıkış katmanları, ağ modelinin sırasıyla girdi ve çıktı değişkenlerini gösterir. Bu iki katman arasında, girişler ve çıkışlar arasında doğrusal olmayan ilişkilerin öğrenilmesinde ağ yeteneğinin bunlara bağlı olduğu bir veya daha fazla gizli katman vardır. Ağdaki veri süreci, giriş katmanından çıktı katmanına doğrudur.

Giriş katmanından alınan girişler. Giriş katmanı ve gizli katman arasında bulunan bağlantı ağırlıkları ile çarpılıp gizli katmana iletilmektedir. Gizli katmandaki sinirlere gelen girişler toplanarak aynı şekilde gizli katman ile çıkış katmanı arasındaki bağlantı ağırlıkları ile çarpılarak çıkış katmanına iletilir. Çıkış katmanındaki sinirler de kendisine gelen bu girişleri toplayarak buna uygun bir çıkış üretirler. Burada giriş katmanından çıkış katmanına doğru, gizli katmanlar üzerinden tek yönlü bir iletişim mevcuttur (Elmas, 2010: 40-45).



Şekil 3.4. Yapay sinir ağı yapısı

Yapay sinir ağıın genel yapısı Şekil 3.4' te görülmektedir. Bu ağ mimarisi şu şekildedir: Her bir nöronun girişi, her nöronun sonraki katmanın nöronlarına bağlandığı ve tam bağlantıya sahip olduğu, önceki katmanların nöronlarından oluşur. Her nöron, bağımlı sapmaya sahip olabilir. Eş. 3.9'da perceptron ağıının matematiksel ifadesi verilmiştir.

$$y_t = \alpha_0 + \sum_{j=1}^n \alpha_j f \left(\sum_{i=1}^m \beta_{ij} y_{t-i} + \beta_{0j} \right) + \varepsilon_t \quad (3.9)$$

Eş. 3.9'da m , giriş katmanının nöronlarının sayısıdır. n , Gizli katman nöronlarının sayısıdır ve f , gizli katman nöronlarının dönüşüm fonksiyonudur. $(\alpha_j, j = 0, 1, \dots, n)$ Gizli ve çıktı nöronlarının ölçek vektörüdür. $(\beta_{ij}, i = 1, 2, \dots, m; j = 0, 1, \dots, n)$ Giriş ve gizli katmanların arasındaki nöronların ölçek vektörüdür. Aynı zamanda α_0 ve β_{0j} sabit ve 1'e eşit olan sapma değerleridir [3].

Perceptron ağlarının en yararlı ve istenilen öğrenme prensibi, gözlem ile öğrenme yöntemlerinden biri olarak kabul edilen hata geri yayılım algoritmasıdır. Bu yöntemde, tüm ağ ölçeklerinin birincil değerleri rastgele hesaplanır. Daha sonra, eğitim veri kümesi ağa verilir ve ağ çıktıları gerçek verilerle karşılaştırılır. Eğer ağ çıktıları ile gerçek veriler

arasında herhangi bir fark varsa, ağ hatası hesaplanır ve ağ çıktıları ve gerçek veriler arasındaki hata kareleri ortalamasını en aza indirmek için ağ ölçekleri, elde edilen hata kullanılarak düzeltilir.

Sinir ağları mimarisi, farklı çalışmaların temel konularından biridir ve çeşitli faktörlere bağlıdır:

- Gizli katman nöron sayısı.
- Gizli ve çıkış katmanlarının aktivasyon fonksiyonları.
- Ağ öğrenme algoritması.

Ağ mimarisini tasarlamak için temel olarak, yukarıda bahsedilen faktörler deneme yanılma yöntemiyle ve hata yöntemini kullanılarak açıklanır ve en az hata kareleri ortalamasına sahip olan ağ, en iyi ağ olarak seçilir.

Yapay sinir ağları, girdi verileri ve hedef verilerle elde edilen çıktıyı karşılaştırıp ağı uyarlayarak eğitilir. Ağın eğitimi, ağ çıkışı hedef verilerle eşleşene kadar gerçekleştirilir. Sinir ağları, her bir giriş değişkenine karşılık ağırlık ve çıktı üretmek için eşik olarak işlev gören bir sapma değeri kullanır. Ayrıca, bir ağın ağırlık ve hassas sapmalarını belirlemek için öğrenme algoritmalarını kullanırlar, böylece çıktı ağırlık ve sapmalardan elde edilebilir. Öğrenme algoritmaları, ağırlık ve sapmalardaki küçük bir değişikliğin çıktıda küçük bir değişikliğe yol açacak şekilde seçilmelidir.

Eş. 3.10'da verilen sigmoid fonksiyonu, gerçek nöronlara büyük benzerlik gösterdiği için ağırlık değerlerini belirleyerek ağın çıktısını hesaplayan bir fonksiyon olarak seçilir.

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (3.10)$$

Eş. 3.11'de $w_{j,k}^l$, $(l - 1)$. katmandaki k . nöronun l . katmanındaki j . nöronuna olan bağlantı için ağırlığı belirtir. Sırasıyla $(l - 1)$. katmandaki toplam nöron sayısı K ve J , toplam katman sayısı L olarak belirtilir. b_j^l , l . Katmanındaki j . nöronun sapmasını gösterir. a_j^l , l . Katmanındaki j . nöronun aktivasyonunu gösterir [16].

$$a_j^l = \sigma\left(\sum_k w_{j,k}^l a_k^{l-1} + b_j^l\right), \quad j = 1, \dots, J \quad (3.11)$$

Ağırlık $w_{j,k}^l$ Eş. 3.12'deki gibi tanımlanan W^l ağırlık matrisinin bir girdisidir:

$$W^l = \begin{bmatrix} w_{1,1}^l & \cdots & w_{1,K}^l \\ \vdots & \ddots & \vdots \\ w_{j,1}^l & \cdots & w_{j,K}^l \end{bmatrix} \quad (3.12)$$

a_j^l ve b_j^l ise Eş. 3.13 ve 3.14'de tanımlanan vektörlerin girdileridir:

$$a^l = [a_1^l \quad a_2^l \quad a_j^l] \quad (3.13)$$

$$b^l = [b_1^l \quad b_2^l \quad b_j^l] \quad (3.14)$$

Sinir ağı, Eş. 3.15'de verilen maliyet fonksiyonunu en aza indirerek ağırlık ve sapmaları bulur:

$$C = \frac{1}{2} \sum_t (y_t - a_t^l)^2 \quad (3.15)$$

Eş. 3.15'de y_t , t anında bilinen çıktıdır ve a_t^l , t anındaki l . katmanın aktivasyon fonksiyonu uygulanmasıyla elde edilen çıktı değeridir.

Aktivasyon fonksiyonu girdi ve çıktı değerleri arasındaki eşleşmeyi sağlar. Hatayı minimum yapan doğru aktivasyon fonksiyonunun seçilmesi, ağı performansı için oldukça önemlidir. Kullanılan aktivasyon fonksiyonuna göre çıktı değeri genellikle $[-1,1]$ veya $[0,1]$ arasındadır. Aktivasyon fonksiyonları doğrusal veya doğrusal olmayan bir fonksiyondur. Doğrusal olmayan aktivasyon fonksiyonlarının kullanılması yapay sinir ağlarının karmaşık ve çok farklı problemlerde uygulanabilir olmasını sağlar [29].

3.8.2 Yapay sinir ağlarının genel özellikleri

Yapay sinir ağlarının çalışma mantığı bilinen hesaplama yöntemlerinden farklı hesaplama yöntemleri önermektedir. Bulundukları ortama uyum sağlayan, adaptif, eksik bilgi ile çalışabilen, belirsizlikler içerisinde karar verebilen, yüksek hata toleransı olan hesaplama

yöntemlerine sahiptir. Uygulamada kullanılacak olan ağ modelinin belirlenmesinde ve ağ parametrelerinin seçiminde belirli bir standardın olmaması, problemlerin sadece nümerik bilgiler ile gösterilebilmesi, eğitimin nasıl bitirileceğinin bilinmemesi ve ağın davranışlarının açıklanamamasına rağmen yapay sinir ağları ile geliştirilen uygulamalar oldukça yaygındır. Yapay sinir ağlarının sahip olduğu bu özellikler sayesinde, sınıflandırma, örüntü tanıma, sinyal filtreleme, veri sıkıştırma ve optimizasyon çalışmalarında yapay sinir ağları en güçlü teknikler arasında sayılabilirler. Veri madenciliği, optik karakter taşıma, optimum rota belirleme, parmak izi tanıma, malzeme analizi, iş çizelgelemesi ve kalite kontrol, tıbbi analizler gibi bir çok alanda günlük hayatımızda göreceğimiz başarılı örneklerine rastlamak mümkündür (Öztemel, 2003: 30-35).

Yapay sinir ağlarının klasik programlama uygulamalarına göre oldukça farklı bir veri işleme metodu vardır. Yapay sinir ağlarında bilgi ağ elemanlarının ağırlık değerleri ile ölçülmekte ve ağ katmanlarında gizlenmektedir. Klasik programlama çalışma mantığında olduğu gibi bilgiler bir veri tabanında veya programın içerisinde saklı değildir. Ağın üzerindeki saklı verilerin çıkartılıp yorumlanması zordur (Öztemel, 2003: 32).

Yapay sinir ağlarının sahip olduğu temel özellikler şöyle sıralanabilir:

- Paralellik
- Öğrenme
- Genelleme
- Eğitim
- Uyum sağlama özellikleri
- Yüksek hata toleransı
- Gerçeklenme kolaylığı
- Uyarlanabilirlik

Yapay sinir ağları birbirleriyle bağlantılı sinir hücrelerinden oluşmaktadır. Yapay sinir ağını oluşturan bu hücreler eşzamanlı, birbirlerinden bağımsız halde ağ işlemlerini gerçekleştirmektedir. Ağ elemanlarının problemin tamamı ile işlem yapmak yerine, sadece kendileri ile ilgili bölümde işlev gören paralel bir yapıları vardır. Böylece yapay sinir ağları yüksek hızda işlemler gerçekleştirebilmektedir. Ayrıca paralellik özelliğinin başka bir avantajı ise yapay sinir ağlarını dayanıklı hale getirmesidir. Ağ elemanlarının paralellik

özelliği sayesinde, ağ elemanlarından birinde meydana gelecek herhangi bir sorunda ağ üzerinde sadece kendi işlevsel katkısı oranında değişikliğe sebep olur. Bu nedenle, klasik programlama sistemlerini çalışamaz hale getirebilecek sorunlar yapay sinir ağları üzerinde sadece küçük sapmalara sebep olur [30].

Klasik programlar programcı tarafından ne yapılacağı ve nasıl yapılacağı tam olarak tanımlandıkları programlar olmalarına karşın yapay sinir ağları klasik anlamda programlanmamaktadır. Yapay sinir ağları problemin çözümü için örnekler üzerinde çalışarak veriler arasındaki ilişkiyi belirlemektedir. Klasik programlama sürecindeki programcının yaptığı programlama işlemi yerine yapay sinir ağlarında ağ eğitime tabi tutularak problemle ilgili geniş tanım yapılmadan problemle ilgili algoritma geliştirilir. Böylece yapay sinir ağları, eğitimleri sırasında işledikleri örneklerden elde ettikleri bilgiler sonucu genellemeler yaparak ve eğitim sırasında daha önce hiç karşılaşılmayan problemlere karşı istenen çıktıları verir. Ayrıca, ilgili problemde meydana gelen değişimlere göre ağ yeniden eğitilebilir ve ağın yeni duruma uyum sağlayabilme özelliği ile beklenen çıktılarına ulaşmak mümkündür [30].

Yapay sinir ağları programcının geleneksel yeteneklerini gerektirmeyen, kendi kendine öğrenme sistemleridir. Bu ağlar öğrenmenin yanı sıra, ezberleme ve bilgiler arasında ilişkiler oluşturmada yeteneğine de sahiptir (Elmas, 2010: 20-22).

Yapay sinir ağları eğitildikten sonra eksik bilgiler olması halinde ağ işlem yapabilmeye devam eder ve elde edilen yeni bilgiler ile genelleme yapılarak modelde eksik bilgi olmasına rağmen doğru sonuçlar elde edilir. Yapay sinir ağlarının böyle durumlarda eksik bilgilerle de çalışabilme yetenekleri yapay sinir ağlarının yüksek hata toleransına sahip olduklarını gösterir. Ağ üzerindeki bazı işlem elemanlarının bozulması veya islemez duruma gelmesi sonucu ağ tekrar eğitilip yeni modele uyum sağlayarak çalışmasına devam eder.

Yapay sinir ağlarının uygulama alanları örnekleri ise aşağıdaki gibi 5 grupta sınıflandırılabilir (Elmas, 2010: 160-165):

Endüstriyel Uygulamalar

Yapay sinir ağları kalite denetiminde, kalitenin geliştirilmesinde yaygın olarak kullanılmaktadır. Teknoloji firmaları tarafından geliştirilen bir sinir ağı işlem denetim sistemi, ürün kalitesi geliştirme ve ürün kalitesinin yükseltilmesinde kullanılmaktadır.

Ulaştırma ve Havacılık Uygulamaları

Pek çok otomobil imalatçısı otomobillerde ve otomobil ürünlerinde sinir ağı fren denetimi, mühendislik hataları, etkin süspansiyon denetimi gibi alanlarda kullanılmaktadır. Uçaklarda titreşim seviyeleri ve sesin görüntülenerek motor sorunlarında erken uyarı için sinir ağları geliştirme çalışmaları yapılmaktadır.

Finans, Borsa ve Kredi Kartı Uygulamaları

Banka işlemleri, kredi kartı şirketleri ve ticari borç verme kuruluşlarının kararlarında, tüm bunların öğrenilmesi ve istatistiksel eğilimlerin olması gerekmektedir.

Tıp, Biyomedikal ve İlaç Sanayi Uygulamaları

Hastaların ilaçlara karşı tepkilerinin incelenmesinde, kazalarda sakatlıklardan korunmada, meme, göğüs ve akciğer kanseri tanısında yapay sinir ağları kullanılmaktadır.

İletişim, Sanayi Uygulamaları

Yapay sinir ağları iletişim sanayinde yaygın olarak kullanılmaktadır. Bu uygulamalarda temel amaç, belgegeçer ve telefon hatlarının güncellenmesinde ve hatlarda olabilecek yankıların giderilmesidir. Yapay sinir ağları ayrıca veri sıkıştırma işlemleri için de kullanılmaktadır.

3.8.3 Yapay sinir ağlarında öğrenme

Yapay sinir ağları, bir giriş setinin uygulanmasının istenen çıkış setini üreteceği şekilde yapılandırılmalıdır. Yapay sinir ağlarında öğrenme sinirler arasındaki bağlantıların

değiştirilmesi ile gerçekleşir. Ağdaki bağlantıların ağırlıklarını ayarlamak için çeşitli yöntemler vardır. Bir yol, bir ön bilgi kullanarak ağırlıkları açıkça belirlemek. Bir başka yol ise, ağıın öğrenme alışkanlıklarını besleyerek ve bazı öğrenme kurallarına göre ağırlıkların değiştirilmesine izin vererek sinir ağlarının eğitilmesidir. Öğrenme işlevi düğümler arasındaki ağırlıkların, düğümlerdeki etkinlik veya aktarım işlevleri değişkenlerinin ayarlanmasıyla yapılır (Elmas, 2010: 85-120).

Öğrenme durumları temel olarak iki ayrı kategoride kategorize edilebilir. Ağıın, giriş ve eşleştirme çıktı kalıpları sağlanarak eğitildiğı, denetimli (danışmanlı) öğrenme ve bir çıktı biriminin girdi içindeki model kümelerine cevap vermek ve girdi popülasyonunun istatistiksel olarak göze çarpan özelliklerini keşfetmek üzere eğitildiğı denetimsiz (danışmansız) öğrenmedir. Takviyeli öğrenme, denetimli ve denetimsiz öğrenmenin bir arası formu olarak düşünülebilir. Burada, öğrenme makinesi çevre üzerinde bazı eylemler yapar ve çevreden bir geri bildirim cevabı alır. Öğrenme sistemi, çevresel tepkiye dayalı olarak eylemini iyi veya kötü dereceye tabi tutar ve buna göre, bir denge durumu ortaya çıkana kadar ağ parametrelerini ayarlar.

Danışmanlı Öğrenme: Danışmanlı öğrenmede yapay sinir ağı kullanılmadan önce eğitilmelidir. Eğitim işlemi sinir ağına giriş ve çıkış bilgileri sunmaktan oluşur. Bu bilgiler genellikle eğitim kümesi olarak tanımlanır. Yani her bir giriş kümesi için uygun çıkış kümesi ağı sunulmalıdır. Sinir ağı belirli bir sıralamadaki girişler için istenen istatistiksel doğruluğı ulaştığı zaman ağıın eğitim işi tamamlanmış kabul edilerek eğitim işlemi bitirilir. Danışmanlı öğrenmede ağ giriş bilgisine göre ürettiğı çıkış değerini istenen değerle karşılaştırarak ağırlıkların belirlenmesinde kullanılacak bilgiyi elde eder. Girilen değer ile istenilen değer arasındaki fark hata değeri olarak önceden belirlenen değerden küçük oluncaya kadar ağıın eğitimi devam eder. Hata, istenen değerın altına düştüğünde tüm ağırlıklar sabitlenerek ağıın eğitime son verilir (Elmas, 2010: 85-120).

Danışmansız Öğrenme: Danışmansız öğrenmede ağ istenen dış verilerle değil girilen bilgilerle çalışır. Danışmansız olarak eğitilebilen ağlar istenen ya da hedef çıkış olmadan giriş bilgilerinin özelliklerine göre ağırlık değerlerini ayarlar. Bu öğrenme kuralında, verilen giriş vektörleri için önceden bilinebilen performansını ölçebilecek ağ için hiçbir çıkış örneğı sağlanmaz, ağ yaparak öğrenmektedir. Danışmansız öğrenmeye Hebbian

öğrenme, Grossberg öğrenme, Kohonen'in harita ağı örnek verilebilir (Elmas, 2010: 138-145).

Önemli öğrenme kurallarından bir kaç aşağıda örnek olarak verilmiştir (Elmas, 2010: 30-35).

Delta Öğrenme Kuralı:

En küçük ortalamalar karesi olarak da bilinen Delta Öğrenme Kuralında bir sinirin gerçek çıkışı ile istenilen çıkış değeri arasındaki farkı azaltmak için giriş bağlantı güçlerini sürekli olarak geliştirme fikrine dayanır. Bu kural ağ hatasının karesini minimize etmek için bağlantı boyutlarını değiştirir.

Hebb Kuralı:

Donald Hebb tarafından geliştirilen bu kuralda, eğer bir sinir başka bir sinirden bir giriş alırsa ve her ikisi de yüksek aktif ise sinirler arasındaki boyut kuvvetlendirilir.

Hopfield Kuralı:

Bu kural kuvvetlendirme ve zayıflatmanın genliğini belirleyebilmesi istisnası haricinde Hebb kuralı ile benzerdir.

Kohonen Öğrenme Kuralı:

Kohonen tarafından geliştirilen bu kural, biyolojik sistemlerdeki öğrenmeden esinlenerek oluşturulmuştur. Sinirler öğrenmek için elverişli durum veya ölçülerini güncellemek için yarışır. En büyük çıkış ile işlenen sinir kazananı belirler ve komşularına bağlantı boyutlarını güncellemeleri için izin verilir.

Eğimli İniş Kuralı:

Delta kuralına benzeyen bu kuralda, transfer fonksiyonunun türevi bağlantı ağırlıklarına uygulanmadan önce delta hatasını düzeltmek için kullanılır. Durağan bir noktaya birçok şekilde yaklaşmasına rağmen sıkça kullanılır.

Geri Yayılımlı Öğrenme:

Geri yayılım çok katmanlı ağlarda kullanılan delta kuralı için genelleştirilmiş bir algoritmadır. Çok katmanlı ağlarda hesap işlerini öğrenmede kullanılır. Öğrenme işlemi bu ağda basit çift yönlü hafıza birleştirmeye dayanır. Geri yayılım öğrenme yöntemi türevi alınabilir etkinlik işlevlerini çok katmanlı herhangi bir ağa uygulayabilir. Bu öğrenme yönteminde Delta kuralı gibi sistem hatasını veya maliyet işlevini azaltma esasına dayanan bir optimizasyon işlemidir. Öğrenme sırasında, giriş örnekleri ağa belli bir sırada sunulur, her bir çalışma örneği çıktı örneği hesaplanana kadar ileri yayılır. Hesaplanan çıktı değeri olması istenen değerle karşılaştırılıp aradaki fark hata olarak bulunur. Hatalar katman katman sinaptik ayarlamaların yapıldığı geri besleme bağlantılarında girdiler olarak kullanılır. Geriye yayılım öğrenme kullanıldığında sonraki katmanların hataları kullanılarak gizli katmanın ağırlıkları ayarlanır. Böylece çıkış katmanında hesaplanan hatalar son gizli katman ile çıkış katman arasındaki ağırlıklar ayarlanır. Toplam hata en aza indirilinceye kadar bu işlemler tekrarlanır (Elmas, 2010: 85-120).

Sinir ağlarının öğrenmesini etkileyen faktörler şunlardır:

- Örneklerin seçilmesi
- Girdi ve çıktıların ağa sunulması
- Girdi ve çıktıların sayısal gösterimi
- Ağırlıkların başlangıç değerlerinin atanması
- Öğrenme ve momentum katsayılarının belirlenmesi
- Örneklerin ağa sunulması
- Ağırlıkların değiştirilme zamanları
- Girdi ve çıktıların ölçeklendirilmesi
- Durdurma kriterinin belirlenmesi
- Ağların büyütülmesi ve budanması

Sinir ağlarının eğitim performansını anlamak için eğitim tamamlandıktan sonra ağın eğitim sırasında görmediği örnekler ağı sunularak çıkış değerlerine bakılır. Eğer ağ görmediği örneklerle doğru cevaplar ürettiyorsa o zaman ağın performansı iyidir ve olayı öğrenmiştir (Öztemel, 2003: 20-44).

Öğrenme oranının ağ üzerinde önemli etkisi vardır. Öğrenme oranı çok küçük değerlerde seçilirse ağın eğitimi uzun zaman alırken, bu değer büyütülmesi ile ağın eğitimi daha kısa zamanda tamamlanır. Öğrenme oranının artırılması ile ağın toplam hatası iyileşirken, bununla birlikte çok büyük öğrenme oranı değerleri seçilirse ağın yakınsama olayı azalır.

Momentum terimi ağ performansı üzerinde etkilidir. Momentum terimi ile ağ adım sayısında ve toplam hata değerinde küçülme görülür. Momentum terimi yüksek seçilirse toplam hata değerinin sıfıra doğru yaklaşır.

Gizli katman nöron sayısının artırılması işlemcinin yükünü artırır, yalnız daha hassas öğrenme işlemi gerçekleşir. Gizli katman nöron sayısı azaltılırsa ağın yakınsama yeteneğini olumsuz etkiler. Bu sebeple gizli katman nöron sayısı kullanılan sinir ağı için deneme yanılma yolu ile belirlenir.

Hata toleransı toplam hata değerindeki hassasiyet ile ilgilidir. Küçük tolerans değerleri toplam hatayı sıfıra doğru yaklaştırarak bağlantı ağırlıklarındaki hassasiyeti de aynı oranda artırır. Ayrıca hata toleransının küçülmesi ağın eğitim süresini de artırmaktadır.


3.8.4 Yapay sinir ağ çeşitleri

YSA topolojik olarak iki türe ayrılır: İleri beslemeli ağlar ve geri besleme ağlar. İleri besleme ağlar, girişten çıkışa doğru sinyallerin sadece bir yöne hareket etmesine izin verir. Geri beslemeli ağlarda bu durum yoktur.

İleri Beslemeli Ağlar:

İleri beslemeli yapay sinir ağlarında ters yöne bir akış yoktur. Giriş verilerin önce giriş katmanına daha sonra sırasıyla gizli ve çıktı katmanlarına doğru ilerleyen bir ağ yapısına sahiptir. Bir katmandaki sinir hücreleri kendisinden bir önceki katmanın sinir hücreleri tarafından beslenerek ilerler. Sinir hücrelerinin girişlerin ve giriş ağırlıklarının işlevini hesaplayıp sonucu sonraki aşamaya aktarma işlemi, çıkış katmanındaki sinir hücreleri tarafından da yapıldıktan sonra tamamlanır.

En çok bilinen ileri besleme ağ çok katmanlı ileri beslemeli ağlardır. Çok katmanlı ileri beslemeli ağlar iki veya daha fazla katmandan oluşur. Basit iki katmanlı ağlarda gizli katman yoktur, sadece girdi ve çıktı katmanlarını içerir. Şekil 3.5’ de çok katmanlı ileri beslemeli bir ağ görülmektedir. Ağ modeli seçerken asıl soru şudur: ‘İyi bir ağ performansı elde etmek için kaç tane gizli katman gereklidir?’. Bu konuda uzmanlara göre teorik olarak, tek bir gizli katmanın pratik problemlerin çoğu için oldukça güvenilir bir şekilde kullanıldığını belirtir. Giriş ve çıkış vektörleri ağı eğitmek için kullanılır. Çok katmanlı ileri beslemeli ağlar eğitim sırasında çıktıdaki hataya göre ağırlıklarını ayarlayarak, verilen çıktı vektörlerini giriş vektörleriyle ilişkilendirmeyi öğrenirler. Ağırlık modifikasyon algoritmasında, doğrusal olmayan bir fonksiyonu en aza indirmek için genellikle delta öğrenme kuralı kullanılır. Algoritma geri hata yayılımı veya geri yayılma olarak adlandırılır, çünkü hatalar gizli katmanlardan geri yayılır. Her katman, bitişik katmanlardaki nöronlara bağlanan çoklu nöronlardan oluşur. Bağlantı ağırlıkları ve düğüm sapmaları model parametreleridir.



Şekil 3.5. Çok katmanlı ileri beslemeli bir yapay sinir ağı

Geri Beslemeli Ağlar:

Geri beslemeli sinir ağlarında, sinir hücreleri sonraki katmanlardaki sinir hücreleri tarafından da beslenir. Bu tip ağlarda veri akışının sadece ileriye doğru değil geriye doğru da yönelebildiği bir tür geri besleme işlemi vardır.

Geri beslemeli ağ mimarileri, genellikle danışmansız öğrenme kurallarının uygulandığı ağlarda kullanılmaktadır. Bu tür ağlarda bir sinirin çıkışı diğer her bir sinirin girişine bağlıdır.

Eş. 3.16'da ağın çalışması tanımlanır. Burada i . sinirin dış girdisi x_i , çıkışı y_i , j sinirinin çıkışı ile i . Siniri arasındaki bağlantının ağırlığı ise w_{ij} ve $y_j = g(u_i)$ ile gösterilir (Elmas, 2010: 55-57).

$$\frac{du_i}{dt} = -u_i + \sum_{i=1}^n w_{ij} y_i + x_i \quad (3.16)$$

$$g(x) = \frac{1}{2} \left(\tanh\left(\frac{x}{a_0}\right) + 1 \right) \quad (3.17)$$

Eş. 3.17’de $a_0 = 0$ olması durumu katı sınırlayıcı transfer işlevine karşılık gelir. a_0 değeri yeterince küçük ise, ağırlıkların simetrik yani tüm i ve j ’ler için $w_{ij} = w_{ji}$ olması durumunda, ağ Eş. 3.18’de ifade edildiği şekilde bir sistem işlevini en küçükleyecek şekilde davranır ve bu enerji işlevinin bir yerel minimuma karşılık gelen kararlı duruma ulaşır.

$$E = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n w_{ij} y_i y_j - \sum_{i=1}^n y_i x_i \quad (3.18)$$

Belirli amaçlarla ve değişik alanlarda kullanılmak için geliştirilen yapay sinir ağı çeşitlerinden bazıları şunlardır:

LVQ (Linear Vektor Quantization) Ağları: Destekli öğrenme stratejisini kullanan LVQ ağlarının eğitimi sırasında ağa sadece öğrenilmesi istenen girdiler verilerek ağın çıktıyı kendisinin üretmesi beklenir. Sonrasında ağa sunulan girdi vektörüne karşılık gelen ağın ürettiği çıktı sonuçlarının doğru veya yanlış olup olmadığına bakılır. LVQ ağının temel yapısında ağa sunulan girdi vektörünü problem uzayını temsil eden referans vektörlerinden birisine haritalanması vardır. LVQ ağı girdi, Kohonen ve çıktı katmandan oluşur.

Girdi katmanındaki her eleman Kohonen katmanındaki her elemana bağlıdır. Girdi katmanından, Kohonen katmanına bağlantıların ağırlıkları bir referans vektörünü oluştur. Öğrenme sırasında sadece bu referans vektörlerinin ağırlık değerleri değiştirilir. Her iterasyonda sadece tek bir vektörün değerleri değiştirilir. Öğrenmenin başarısı ise bu vektörlerin başlangıç değerleri ile yakından ilgilidir. Kohonen katmanındaki elemanların her biri çıktı katmanındaki sadece tek bir elemana bağlıdır. Kohonen katmanı ile çıktı katmanı arasındaki ağırlıklar sabit olup değerleri 1’dir. Eğitim sırasında bu ağırlıkların değerleri değiştirilmez. LVQ ağlarında öğrenme işlevi girdi vektörü ile referans vektörleri arasındaki öklid mesafesine dayanmaktadır. Kohonen katmanındaki her eleman bir referans vektörünü gösterir ve birbirleri ile yarışır. Yarışmayı öklid mesafesi en kısa olan eleman kazanır. Yarışmayı kazanan elemanın çıktı 1 diğerleri 0 değerini alır. Yarışmayı kazanan çıktı elemanı ilgili girdinin sınıfını gösterir. Eğer girdi doğru sınıflandırılmış ise ilgili referans vektörü girdi vektörüne yaklaştırılır, doğru sınıflandırılmamış ise uzaklaştırılır. Yaklaştırma ve uzaklaştırma işlevi öğrenme katsayısı ile gerçekleşir. LVQ ağının en önemli sorunu ise çok sık aynı vektörün kazanması ve ağın öğrenme

performansının düşük olmasıdır. Böylece ağıın öğrenmesi zamanla öğrenmenin tersi yönünde öğrenmemeye dönüşmesine neden olur. Bu durumu önlemek için öğrenme katsayısı zamanla azaltılarak sıfır değerine kadar düşürülüp öğrenme tamamlanınca sıfır değerini alarak öğrenmeyi durdurması sağlanır. Ancak sorunu çözmek için yeterli olmadığından, öğrenme algoritması geliştirilmiştir. LVQ2 öğrenme yöntemi sınıflar arasında kalan örnekleri sınıflandırabilme özelliğine sahiptir. Aynı zamanda sürekli kazanan proses elemanlarını cezalandırarak diğer proses elemanlarına da şans verilmesi için başka bir yöntem önerilir. Başka bir yöntem ise, eğitim sırasında her iterasyonda birden fazla referans vektörünün ağırlıklarını değiştirerek yanlış sınıflandırılan örnekler referans vektörlerinden uzaklaştırılır, doğru sınıfın bir örneği referans vektörüne yaklaştırılır. LVQ-X adı verilen bu yöntem ile başlangıç değerlerine bağıllık yok edilerek, öğrenme tamamen gerçekleştirilir. Böylece eğitim performansı yükselir öğrenme hızı artar (Öztemel, 2003: 20-25).

Adaptif Rezonans Teori Ağları (Art): ART ağların en önemli özellikleri gerçek zamanlı çalışabilmeleri ve çevrimiçi öğrenebilmeleridir. Yeni durumlara adapte olabilmekte ART ağları oldukça güçlüdür. Bunu yaparken bir taraftan öğrenip bir taraftan da unutabilmektedirler. Bir ART ağı, gösterim katmanı (F1) ve kategori katmanı (F2) olmak üzere iki katmandan oluşmaktadır. Ayrıca ağı sunulan girdilerin sınıflandırılmaması durumunda yeni bir kategori oluşturmaya yardım eden oryantasyon modülü vardır. F1 ve F2 katmanları arasında hem aşağıdan yukarı hem de yukarıdan aşağı ağırlık vektörü vardır. Bu ağırlıklar eğitim sırasında örneklerle bakılarak değiştirilir. Girdiler F1 katmanından ağı sunulur ve yukarı doğru ağırlıklar ile F2 katmanından çıktı değerleri hesaplanır. F2 katmanında en yüksek çıktı değerini oluşturan proses elemanı yarışmayı kazanan proses elemanı olarak 1 değerini, diğerleri ise 0 değerini alır. Bu elemana bağlı ağırlıklar değiştirilir. Kazanan elemanın ilgili girdi vektörünün sınıfını göstermesi için ona bağlı hafızadaki vektör ile girdi vektörünün birbirine benzemesi gerekmektedir. Bu benzerliğe benzerlik katsayısı denilen bir katsayı ile karar verilir. Eğer iki vektör birbirine benzer bulunursa girdi vektörü o sınıfın elemanı sayılır ve ağırlıklar girdi vektörüne göre güncellenir. Arada benzerlik olmaz ise o zaman oryantasyon sistemi o girdi vektörü için yeni bir sınıf oluşturur. Bu nedenle bir ART ağında örnek sayısı kadar sınıf sayısı oluşturulabilir. Değişik ART ağları geliştirilmiştir. ART1 ağı geliştirilmiş ilk ART ağıdır. Bu ağ sadece ikili (binary) değerlerden oluşan girdi vektörlerini kabul eder. ART2 ağları ise sürekli değerleri de kabul etmektedirler. Benzer şekilde ART3, Fuzzy ART gibi başka

modellerde geliştirilmiştir. Bu modellerin eğitim performansları benzetim katsayısı ile yakından ilgilidir. Bu katsayının küçük olması sınıf sayısını azaltmakta, büyük olması ise sınıf sayısını artırmaktadır. Çünkü sayının büyük olması daha fazla benzerlik istenmesidir. İstenilen benzerlik düzeyi yakalanamayınca yeni sınıflar oluşturulmaktadır. ART ağları endüstriyel problemlerde özellikle sınıflandırma amaçlı kullanılmakta ve oluşturulan etiketlendirme mekanizması ile sorunlara çözümlere önerilebilmektedir. Grup teknolojisi gibi makine hücrelerinin belirlenmesinde de geleneksel yöntemlerden daha etkili çözümler üretebilmektedirler. Bu ağlardan özellikle ART2 ağının en önemli sorunlarından birisi birçok parametreyi kullanıcının belirlemesinin gerekmesidir. Bunlar ise ancak uzun denemeler ve deneyimler sonucunda doğru olarak belirlenebilmektedir (Öztemel, 2003: 20-25).

Özgürtlemeli Harita Ağı (Self Organizing Map, SOM): SOM ağlarında, giriş verisi düzeni sağlayan seyrek veriye uyan ve yığın veriye yayılan bir çift boyutlu katmana göre projelendirilmemiştir. Özörgütlemeli haritaların başlıca kullanımı topolojiye ve yüksek sistem boyutları giriş başlıklarının hiyerarşik yapısını görüntüler. SOM ağları Kohonen katmanı tarafından oluşturulmuş çift boyutlu boşluk içindeki alan doldurma eğrilerine meydana getirmek için kullanılmıştır. Bu ağ ile diğer ağlar arasındaki temel fark SOM ağlarının kontrolsüz öğrenim işlevidir. Özörgütlemeli harita iki katmana sahiptir. Giriş katmanı tamamıyla çift boyutlu Kohonen katmanına bağlanmıştır. Çıkış katmanı niceleme probleminde kullanılarak giriş vektörünün ait olduğu üç sınıfı temsil eder. Çıkış katmanı delta kuralını uygulayarak öğrenir (Elmas, 2010: 77-79).

Uyarlanabilir Rezonans Ağı: Danışmansız öğretim işlevini kullanan uyarlanabilir rezonans ağlarında sistem belirgin giriş verisini analiz eder veya giriş vektörü içindeki karakteristikleri sınıflandırır. Bu ağların temelini giriş ve çıkış katmanlarının arasına yerleştirilmiş işlemci elementlerin karşılıklı birleştirilmiş iki katmanı oluşturur. Düşük rezonans katmanına bağlı her bir giriş modeli, yüksek katmandan düşük katmana bir sonraki girişi etkilemek üzere gönderilerek beklenen modele yol açar. Böylece modeller arasındaki ağ uyumunu kolaylaştırmak için düşük ve yüksek katmanlar arasındaki rezonansı oluşturur (Elmas, 2010: 76-78).

Hopfield Ağı: Hopfield ağı her bir elemanı işleyerek ikili sayı biçimi oluşturur. Bu elemanlar girişlerin toplamı ve çıkış sayıları sıfır veya bir olarak hesaplanır. Hopfield ağ

topolojisinin diğ er ağılardan farkı, ağıda her d  ğ  m diğ er t  m d  ğ  mlere bağılıdır. Bağılantılar  ift y  nl   ve simetriktir. Hopfield ağında bir giriř s  zme katmanı, Hopfield katmanı ve bir  ıkıř katmanı olmak  zere 3 katman kullanılmasına rağmen farklı katmanlar yoktur. Bu ağı tipi, geriyayılımlı ağın eğıtildiğı gibi eğıtilmek yerine  rnek desen grupları se ilerek ağına ağırlıklarının bařlangı  deėerlerini saptamak i in kullanılır. Bir kez yapıldıktan sonra herhangi bir desen ağı sunulur ve giriř desenine en  ok benzeyen  rnek desenlerden biriyle sonu lanır.  ıkıř deseni, birimlerin durumuna bakılarak ağıdan okunur (Elmas, 2010: 66-68).



4. KISA DÖNEM ELEKTRİK ENERJİSİ YÜK TAHMİNİ İÇİN YAPAY SİNİR AĞLARI VE GENETİK ALGORİTMA TABANLI ADAPTİF HİBRİD SİSTEMİN GELİŞTİRİLMESİ

Yapay sinir ağları (YSA) doğrusal olmayan denklemlerin çözümünde başarılı olmasına rağmen; model tam olarak belirlenmemişse, genel minimum noktayı bulmak zordur. Burada en önemli faktör önerilen modele bağlı olarak aktivasyon fonksiyonunun uygun şekilde belirlenmesidir. Diğer önemli bir faktör ise yüksek tahmin doğruluğu ile etkili bir model geliştirmek için büyük ve esnek veri setine ihtiyaç duyulmasıdır. YSA ve bir genetik algoritmanın birlikte kullanılarak hibrid optimizasyon yöntemleri ile en uygun aktivasyon fonksiyonunun seçilebilmesi bu dezavantajların üstesinden gelen bir çözümdür. Bu özellik, klasik yapay zeka tabanlı yöntemlere karşı hibrid yöntemlere bir avantaj sağlar. Hibrid algoritmalara dayalı optimizasyon ve tahmin modelleri, bilimin tüm bölümleri için uygundur. Özellikle, deneysel uygulamaların zor olduğu verileri tahmin etmekte büyük kolaylık sağlar. Ayrıca, hibrid algoritmalar ile doğrusal olmayan sistemlerin optimizasyonu için daha doğru ve hızlı bir çözüm elde edilir.

Kısa dönem yük tahmini parametrelerini tanımlamak için en yaygın algoritmalar yapay zekaya dayalı algoritmalarlardır. Literatürdeki çalışmalarda, geri yayılım algoritmasına sahip yapay sinir ağları ile doğru tahmin modelleri elde etmek için farklı parametreler kullanılmıştır. Tez çalışmasında uygun sistemin geliştirilmesi için farklı yapay sinir ağı algoritmaları ve gizli katmanların sayısı incelenip ve karşılaştırılmıştır.

Bu tez çalışmasında, kısa dönem elektrik yük tahmini için yapay sinir ağları ve genetik algoritma tabanlı adaptif hibrid bir sistem önerilmiştir. Genetik algoritmaya (GA) dayanan yapay sinir ağı kullanarak kısa dönem elektrik yük tahmini için yeni bir yaklaşım geliştirilmiştir. Önerilen bu hibrid algoritma, kısa dönem yük tahmini için uygulanmıştır. Asıl tahmin YSA tarafından gerçekleştirilmiş ve bazı parametreler gizli katman nöron sayısı, öğrenme hızı ve momentum terimi genetik algoritma tarafından optimize edilmiştir. Genetik algoritma YSA'nın en uygun aktivasyon fonksiyonunu seçmek için kullanılmıştır. Bu sayede, ağ hatasının klasik YSA'ya göre daha da azaldığı gözlemlenmiştir. Sonuçlar, hibrid YSA'nın klasik YSA'dan daha iyi sonuçlar verdiğini göstermektedir. Böylece, kısa dönem yük tahmini için önerilen modelin doğruluğu artırılmıştır. Kullanılan modelin ayrıntılarına tez çalışmasının beşinci bölümünde yer verilmiştir.

4.1. Klasik YSA

YSA görüntü tanıma, sınıflandırma, fonksiyon tahmini ve optimizasyonu gibi birçok işlemde en güçlü yöntemlerden biridir. İnsan sinir sistemini ve beynin öğrenme yeteneğini taklit eden bu yöntem sayesinde bu süreçlerin birçok başarılı uygulaması geliştirilmiştir. Tez çalışmasının üçüncü bölümünde de detaylı anlatıldığı üzere, YSA' nın farklı öğrenme türleriyle birkaç ağ yapısı vardır. Geriye yayılım algoritması, en yaygın ağ yapısıdır ve düğüm ağırlıklarının ayarlanması için güçlü bir algoritma türüdür.

Şekil 3.5' te verilen genel ağ yapısında görüldüğü gibi, bir yapay sinir ağı, bir giriş katmanı, en az bir gizli katman, bir çıktı katmanı, bir dizi yayılım hatası, katmanlardaki her bir yayılma hatası için bir aktivasyon fonksiyonu ve katmanlar arasındaki düğümleri birleştiren ağırlıkları içeren tabakalardan oluşur. Genelleştirilmiş delta kuralı olarak bilinen eğitim sürecini gerçekleştirmek için, başlangıçta her bir ağırlığa rasgele değerler atanır ve daha sonra girdi örnekleri ağı sırayla iletilir. Bu ileri besleme sürecinde, her bir giriş örneği için çıktılar hesaplanır. Ardından, hesaplanan çıkışlar ve beklenen çıkışlar karşılaştırılarak bir hata sinyali hesaplanır. Bundan sonra, bu hata sinyalleri, ağırlık ayarlamalarını gerçekleştirmek için çıktıdan giriş katmanına geriye doğru yayılır. Bu ileri besleme geri yayma işlemi, toplam hata değeri beklenen minimum değere ulaşana kadar tekrar eder ve daha sonra öğrenme süreci durdurulur.

A' nın giriş vektörünü ve B' nin istenen çıktı vektörünü tanımladığı varsayıldığında, n girişleri ve m çıkışları için ağıdaki A ve B değerleri Eş. 4.1 ve 4.2' deki gibi verilebilir.

$$A = (a_1, a_2, \dots, a_n) \quad (4.1)$$

$$B = (b_1, b_2, \dots, b_m) \quad (4.2)$$

Eğitim sürecinde, giriş katmanına bir dizi girdi örneği verilir ve bunlar ağırlıklar aracılığı ile gizli tabakaya taşınır. Gizli katmandaki her bir yayılım hatası, net çıkışı hesaplamak için kendisine bağlı olan ağırlıklı girişlerin toplamını hesaplar. j . katman üzerindeki i . yayılım hatasının net çıkışı Eş. 4.3' deki gibi hesaplanır. Burada, w_{ik} , k . katman üzerindeki i . yayılım hatasının ağırlık değeridir. Aktivasyon değeri, aktivasyon fonksiyonuna bağlı

olarak aşağıdaki gibi hesaplanır. Bu çalışmada kullanılan transfer fonksiyonları Çizelge 4.1'de verilmiştir.

$$net_i^j = \sum_{k=0}^n w_{ik} a_{ik} \quad (4.3)$$

$$b_{net} = f^k(net_i) \quad (4.4)$$

Bu aktivasyon değerleri çıkış katmanına hareket eder ve ağın gerçek çıktıları da aynı şekilde hesaplanır. Geriye yayılım ağırları, istenen çıkış b ve ağın gerçek çıkışı b_{net} , arasındaki hatayı en aza indirmeyi amaçlamaktadır. Ağın eğitimi, bu hata değeri minimum seviyede olana kadar devam eder.

Çizelge 4.1. Adaptif YSA'da kullanılan aktivasyon fonksiyonları

Doğrusal	$f(x) = x$
Eşik	$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases}$
Lojistik Sigmoid	$f(x) = \frac{1}{1 + e^x}$
Sinüs	$f(x) = \sin x$
Hiperbolik Tanjant	$f(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}}$
Radyal Bazlı	$f(x) = e^{-x^2}$

4.2. Adaptif YSA

Klasik YSA yönteminden farklı olarak, adaptif YSA yönteminin bir sezgisel arama birimi vardır. YSA, genetik algoritma tarafından optimize edilmiş ve buna adaptif YSA denilmiştir. Literatürde hibrid yöntemler birkaç optimizasyon problemine uygulanmıştır. [2], [31], [32]. Geliştirilen yöntem, nöronların farklı karakterlere cevap verebileceği hipotezine dayanmaktadır. Bu hipotezi gerçekleştirmek için, bir ağdaki nöronlar farklı tipte aktivasyon fonksiyonlarına sahip olacak şekilde tasarlanmıştır. Sezgisel arama algoritmasının görevi, ağ performansını en üst düzeye çıkarmak için her bir nöronun işlevini belirlemektir. Bu tez çalışmasında, sezgisel bir arama birimi olarak genetik algoritma kullanılmıştır. Ağdaki her bir nöron tarafından kullanılan alternatif altı farklı

transfer fonksiyonu, geliştirilen genetik algoritma ile belirlenir. Bu fonksiyonlar Çizelge 4.1.'de belirtilmiştir. (Kullanılan Genetik Algoritmanın ayrıntılarına tez çalışmasının 3.6. bölümünde yer verilmiştir.)

Bu tez çalışmasında, kullanılan genetik algoritma, adaptif YSA'nın iki gizli katmanındaki nöronların kullandığı aktivasyon fonksiyonlarının optimal kombinasyonunu bulmayı amaçlamaktadır. Amaç fonksiyonu Eş. 4.5'de verilmiştir. Bunu başarmak için, optimizasyon için kullanılan maliyet fonksiyonu, her yaklaşım için YSA tarafından üretilen Ortalama Karesel Hata (Root Mean Square Error, RMSE) değeri olarak tanımlanır. Önerilen genetik algoritma, öğrenme sürecinde her yaklaşımda çalışarak bu hata değerini en aza indirir. RMSE değerini en aza indirmek için kullanılan genetik algoritmanın tanımlanmış parametreleri Çizelge 4.2.'de verilmiştir.

$$\text{Min } f = \frac{1}{2} \sum_t (y_t - a_t^L)^2 \quad (4.5)$$

Çizelge 4.2. Genetik algoritma için tanımlanmış parametreler

Popülasyon birey sayısı	40
Sonlandırma kriteri (jenerasyon)	50
Ebeveyn seçim yöntemi	Rulet tekerleği
Mutasyon katsayısı	1
Mutasyon yöntemi	Bit ters çevirme

Adaptif YSA, önerilen model için yedi farklı transfer fonksiyonundan en düşük hatayı veren bir fonksiyon seçer. Böylece, klasik YSA' dan daha doğru tahmin modelinin geliştirilmesini sağlar.

5. YÖNTEMLERİN UYGULANMASI, VERİLERİN DEĞERLENDİRİLMESİ VE SAYISAL SONUÇLAR

5.1. Giriş

Tez çalışmasının bu bölümünde, çalışmada kullanılan yapay sinir ağları ile kısa dönem yük tahmini modelinin oluşturulması, benzer günlerin seçilerek gerçekleştirilmesi ve Türkiye Elektrik İletim A.Ş. (TEİAŞ) ve Meteoroloji Genel Müdürlüğünden elde edilen geçmiş verilerin analizi ile yapay sinir ağları kullanılarak geliştirilen kısa dönem yük tahmini için oluşturulan bilgisayar benzetim programının çalışma detaylarından bahsedilmektedir.

Bölüm 2.4.'te de anlatıldığı üzere talep yükünü etkileyen en önemli faktörler arasında zaman faktörü, geçmiş hava durumu verileri, tüketicilerin sınıfı, bölgenin geçmişte talep ettiği yük, bölgenin büyümesi, yük miktarı artışı vs. gösterilebilir. Bu faktörlerden bazıları yapılacak tahminler üzerinde doğrudan ve büyük oranda etkiliyken, bazıları ise kısa dönem yük tahmini yapılacak bölge için dolaylı şekilde ve daha az etkilidir. Bölge talep yükünü etkilediği saptanan faktörler, etki derecelerine bağlı olarak kısa dönem yük tahmini modellerinde bağımsız değişken olarak kullanılmaktadır.

Bu tez çalışmasında Orta Anadolu Yüz Tevzi İşletme Müdürlüğüne ait 01.01.2009 tarihinden 31.12.2015 tarihine kadar gerçekleşen saatlik yük verileri kullanılmıştır [26]. OAYTM (Gölbaşı) bölgesine dahil olan iller Ankara, Konya, Kayseri, Kırıkkale, Kırşehir, Nevşehir, Niğde, Yozgat, Aksaray ve Karaman illeridir.

Bu tez çalışmasındaki kısa dönem yük tahmini modelinin oluşturulmasında [6] ve [10]'daki benzerlik tabanlı model örnek alınmıştır. Çalışmada aşağıdaki durumlar analiz edilerek yöntemin uygulanması tamamlanır.

- Geçmiş yük verileri kullanılarak eğitilebilen yapay sinir ağı modelini oluşturmak.
- Öğrenme hızı, momentum faktörü ve gizli nöron sayısı gibi farklı parametrelerin bulunduğu geri yayılım algoritması kullanılarak ağı maksimum kabul edilebilir hata altında eğitilmesi.
- Test modelleri için optimum parametrelerin bulunması.
- Parametreler için optimum değerleri kullanarak tahmin değerlerinin bulunması.

5.2. OAYTM Bölgesi Kısa Dönem Yük Tahmini Modeli

Son yıllarda literatürde, kısa dönem yük tahmini için benzerlik tabanlı çeşitli matematiksel modeller geliştirilerek uygulanmış çalışmalar bulunmaktadır. Benzerlik tabanlı bu modeller, benzer günün bilgi verilerini kullanarak tahmin edilen günün hava durumuna benzer şekilde gelecekteki güç yük eğrisini tahmin etmektedir. Geliştirilen bu model sadece yükün doğrusal olmayan kısmı ile değil, hafta sonu veya bayramlar gibi diğer özel günlerin de yük karakteristiğinin incelenip modele eklenmesiyle yük tahminindeki doğruluğu arttırma avantajına sahiptir. Genel olarak, benzerlik tabanlı tahmin yönteminde yük tahmininin doğruluğunu iyileştirmek için seçilmiş çeşitli benzer günlerin yük ortalaması alınır.

Yapay sinir ağları özellikle lineer olmayan karmaşık problemlerin çözümü için oldukça iyi tahmin sonuçları vermesi nedeniyle kısa dönem yük tahminleri için de uygundur. Çalışmada mevsimsel değişimlere uyum sağlayan, hafta içi, hafta sonu ve diğer özel günler için doğru kısa dönem yük tahminleri elde edilebilen bir model önerilir.

Bu tez çalışmasında, ertesi günün 24 saatlik yük tahmini yapılarak günlük yük eğrileri elde edilmiştir. Aynı zamanda elde edilen tahmin sonuçları ile gün içerisindeki puant yük değeri de tahmin edilmiş olur.

24 saatlik yük tahmini yapılacak olan OAYTM (Gölbaşı) Bölgesi'nin bölüm 2.5'te geçmiş yük eğrileri incelenerek yük etüdü yapılmıştır. Şekil 2.7'den, Şekil 2.10'a kadar farklı mevsimlerden örnek alınmış günlük yük eğrileri verilmiştir. Dört farklı mevsimden aynı günün yük eğrileri incelendiğinde, aydınlatma süreleri ve meteorolojik koşullar gibi nedenlerden dolayı yılın farklı mevsimlerinde aynı bölge içerisinde yük karakteristiklerinin değiştiği gözlemlenir. Yük eğrilerindeki bu fark yaz ve kış mevsimlerinde daha belirgindir. Hava değişimi, ısıtıcı ve klima gibi elektrikli cihazların kullanımı ile puant yük kış aylarında akşam saatlerinde, yaz aylarında ise öğlen saatlerinde görülmektedir. Bu nedenle, çalışmada önerilen uyarlanabilir öğrenmeye dayalı yapay sinir ağı algoritması için tahmin edilecek günden bir önceki yıla ait öğrenme aralığındaki veriler ile tahmin edilecek güne en yakın günlerin verileri kullanılır. Böylece önerilen ağ, tahmin edilen günün meteorolojik koşulları da dahil olmak üzere öğrenme verileri kullanılarak eğitilebilir.

Önerilen yaklaşımın uygunluğu, TEİAŞ'ın gerçek yük verilerine uygulanması yoluyla gösterilmiştir.

5.2.1. Kısa dönem yük tahmini için giriş verilerinin belirlenmesi

Kısa dönem yük tahmini için kullanılacak giriş verileri belirlenirken Bölüm 2.4.'te ayrıntılı olarak anlatılan yükü etkileyen faktörlerin ayrı ayrı ele alınıp oluşturulan yük tahmini modeline etkisinin incelenmesi gerekir.

Sıcaklık, nem oranı, bulutluluk oranı, rüzgar hızı, aydınlatma, mevsim vs. yükü etkileyen meteorolojik durumlara örnektir. Tez çalışmasında OAYTM bölgesi için oluşturulan kısa dönem yük tahmini modelinde sıcaklık karşısında diğer hava faktörlerinin yüke etkisinin oldukça düşük olduğu gözlemlenmiştir. Böylece çalışmada kullanılacak yapay sinir ağı modelinin daha kısa sürede ve verimli bir şekilde uygulanabilmesi için giriş verileri belirlenirken sıcaklık dışındaki diğer hava faktörleri ihmal edilmiştir. Aynı zamanda bu duruma karşı, kısa dönem yük tahmini yapılacak farklı bölgelerin mevsimsel özelliklerine göre diğer hava faktörlerinin yüke etkisi ihmal edilemeyecek oranda olabilir.


Kış mevsiminde sıcaklığın oda sıcaklığının altına düşmesi, ısıtma yükünde artışa, yaz aylarında sıcaklığın oda sıcaklığının üzerinde artması ise klima yükünün artmasına neden olduğu için hava sıcaklığının en yüksek ve en düşük değerlerinin görüldüğü günlerde, yıl içerisinde talep edilen puant yükün de en yüksek değerlere ulaştığı görülür. Hava sıcaklığının oda sıcaklığı ortalama değerlerinde olduğu günlerde ise yıl içerisindeki en düşük puant yük değerleri görülür.

Çizelge 5.1. Ocak 2018 döneminde OAYTM Bölgesine dahil olan illerin faturalanan elektrik enerjisi tüketimleri (MWh)

İLLER	Elektrik Enerjisi Tüketimi (MWh)
ANKARA	1.315.789,65
KONYA	426.452,74
KAYSERİ	307.101,77
NİĞDE	79.208,57

Çizelge 5.1. (devam) Ocak 2018 döneminde OAYTM Bölgesine dahil olan illerin faturalanan elektrik enerjisi tüketimleri (MWh)

YOZGAT	58.954,36
AKSARAY	56.635,63
KIRIKKALE	52.608,96
NEVŞEHİR	51.671,08
KARAMAN	49.973,23
KIRŞEHİR	33.748,66
GENEL TOPLAM	2.432.144,65



Şekil 5.1. Ocak 2018 döneminde OAYTM Bölgesine dahil olan illerin elektrik enerjisi tüketimlerinin yüzdesel dağılımı (%-MWh)

Tez çalışmasında kısa dönem yük tahmini yapılacak OAYTM Bölgesi için oluşturulan yapay sinir ağı modelinde giriş verileri olarak kullanılacak olan günlük maksimum ve minimum sıcaklık değerleri, OAYTM Bölgesine dahil olan illerin yükünün, bölge toplam yüküne etkileri oranında ağırlıklı olarak hesaplanmıştır.

Çizelge 5.1’de OAYTM Bölgesi’ne dahil olan illerin her birinin elektrik enerjisi tüketimleri ve Şekil 5.1’deki tüketim yüzdeleri incelendiğinde; Ankara, Konya ve Kayseri dışındaki illerin toplam enerji tüketimine etkisinin Ankara, Konya, Kayseri illerinin enerji tüketim yüzdelerine göre ihmal edilecek kadar düşük olduğu gözlemlenir. Böylelikle OAYTM Bölgesinin yük tahmininde kullanılacak maksimum ve minimum sıcaklık

değerlerinin hesaplanmasında Ankara, Konya ve Kayseri illerinin sıcaklık değerleri ağırlıklı olarak kullanılır. Bu illerin elektrik enerjisi tüketimlerine göre Eş. 5.1 oluşturulmuştur. Bu tez çalışmasında kullanılan tüm sıcaklık verileri Eş. 5.1 göre hesaplanan bölge sıcaklığıdır.

$$T = 0,64T_{Ank} + 0,21T_{Kon} + 0,15T_{Kay} \quad (5.1)$$

Eş. 5.1 oluşturulurken, elektrik enerjisi tüketimleri ihmal edilen illerin toplam %15'lik tüketim yüzdesi; Ankara, Kayseri ve Konya illerine elektrik enerjisi tüketim yüzdelerine orantılı olarak eklenmiştir. Böylece, Ankara ilinin bölge içinde %54 olan enerji tüketim yüzdesi, enerji tüketim yüzdesi daha düşük olan iller ihmal edildiğinde %64'e çıkar. Sonuç olarak OAYTM Bölge sıcaklığı hesaplanırken Ankara ili için yeni sıcaklık yüzdesi 0,64 Kayseri ili için yeni sıcaklık yüzdesi 0,15 ve Konya ili için yeni sıcaklık yüzdesi ise 0,21 olarak kullanılır. Bu hesaplamaların ayrıntıları aşağıda verilmiştir:

Bölge sıcaklık hesabında ihmal edilecek illerin toplam sıcaklık yüzdesi:

$$0,032 + 0,024 + 0,023 + 0,022 + 0,021 + 0,020 + 0,014 = 0,15 \quad (5.2)$$

Bölge sıcaklık hesabına dahil olan illerin toplam sıcaklık yüzdesi:

$$0,54 + 0,18 + 0,13 = 0,85 \quad (5.3)$$

Yeni durumda Ankara ili için sıcaklık yüzdesi:

$$0,54 + 0,15 \frac{0,54}{0,85} \cong 0,64 \quad (5.4)$$

Yeni durumda Konya ili için sıcaklık yüzdesi:

$$0,18 + 0,15 \frac{0,18}{0,85} \cong 0,21 \quad (5.5)$$

Yeni durumda Kayseri ili için sıcaklık yüzdesi:

$$0,13 + 0,15 \frac{0,13}{0,85} \cong 0,15 \quad (5.6)$$

Olacak şekilde hesaplanır.

Ankara, Kayseri ve Konya illerine ait 01.01.2009 tarihinden 31.12.2015 tarihine kadar gerçekleşen günlük maksimum ve minimum hava sıcaklık verileri Meteoroloji Genel Müdürlüğünden elde edilmiştir [27].

5.2.2. Gün tipi sınıflandırılması

Bölüm 2.5'te anlatılan günlük ve haftalık yük eğrileri gözlemlendiğinde zaman faktörünün yükü etkileyen önemli bir parametre olduğu görülür. Şekil 2.7'de görülen günlük yük eğrileri, gün boyunca bölge yük karakteristiğinin davranışlarını gösterir. Haftalık ritimler iş günü ile başlar. Hafta içi (iş günü) sosyal aktiviteler, hafta sonları (cumartesi ve pazar günleri) ve tatil günlerine kıyasla daha fazladır. Bu durum hafta içi günlerinde enerji tüketiminin arttığı anlamına gelir. Genellikle gece saatlerinde aktivitelerin azalması bu saatlerde enerji tüketiminin azalmasına neden olur. Ayrıca gün içerisinde mesai saatleri, boş zaman, öğle saati, uyku süresi ve dinlenme gibi insanların yaşam tarzlarına bağlı olarak gerçekleşen aktivitelere göre günlük yük eğrileri değişim eğilimi gösterir.

Sonuç olarak günlük yük eğrilerinin arasında bariz farklılıkların olması durumu, uygulamada kullanılacak kısa dönem yük tahmini modeli için bir gün tipi endeksi belirlenmesini gerektirir.

Yük eğrileri incelendiğinde cumartesi ve pazar günlerinin, hafta içi günlerine göre farklı sınıflandırılması gerektiği açıkça bellidir. Ancak, doğru yük tahminleri için milli ve dini bayram günleri gibi özel günler için de ayrı gün tipi faktörü belirlenmelidir. Çoğu zaman özel günlerin pazar günleri ile benzer yük karakteristiğine sahip olması ile birlikte, bazı özel günlerin yük tüketimi eğilimi farklılık gösterebilir.

Milli ve dini bayramlar veya tatil günleri enerji talebinin değiştiği günlerdir. Örneğin dini bayramların hafta içine geldiği bir yılda bütün bir hafta tatil ise tatilin başladığı günler enerji talebi yüksek olurken diğer günlerde düşüş görülebilir. Milli ve dini bayram


günlerinin, hafta içine denk gelen tatil günlerinin veya yılbaşı gibi özel günlerin yük eğrileri normal günlerin yük eğrilerine göre farklılık gösterir. Genel olarak, özel günlerin yük değerlerinin normal yük seviyelerinin altındaki değerlere düştüğü görülür. Öte yandan, aynı özel günlerin yük eğrileri, sistem yükünün büyüme veya düşüş eğilimi nedeniyle her yıl farklı değildir. Özel günlerin yük eğrileri, gün tipi değişiklikleri ile farklılık gösterir. Kısa dönem yük tahminini etkileyen Milli ve dini bayramlara ait özel günlerin de yük eğrilerinin ayrı incelenmesi gerekir. Milli ve dini bayram günlerinde diğer günlerden farklı bir yük karakteristiği görülür. Tatil günlerinin hafta içine denk geldiği durumlarda yük eğrisi farklı bir şekil almaktadır.

Bu tez çalışmasında gün tipi endeksi aşağıdaki şekilde sınıflandırılmıştır:

1. Gün Tipi: Pazartesi Salı Çarşamba Perşembe günleri
2. Gün Tipi: Cuma günleri
3. Gün Tipi: Cumartesi günleri
4. Gün Tipi: Pazar günleri
5. Gün Tipi: Arife günü, yarım günlük tatiller (28 Ekim vb.)
6. Gün Tipi: 23 Nisan, 19 Mayıs, 1 Ocak, 30 Ağustos gibi tek günlük tatiller
7. Gün Tipi: Dini Bayram günleri

5.2.3. Benzer gün seçimi

Benzer gün seçimi temelinde, eğitim setindeki araştırılan önceki günlerin tahmin edilecek günlerle benzer özelliklere sahip olması gerçeğine dayanmaktadır. Kısa dönem yük tahmininin doğruluğunu iyileştirmek için, eğitim setini benzer günlerde seçmek esastır. Bu da uygulanacak ağın eğitim süresini kısaltır. Tahmin edilecek güne karşılık gelen benzer günlerin seçim sınırları Şekil 5.2' te gösterilmektedir. Benzer günleri seçmek için Şekil 5.3' teki sınırları kapsamak yeterlidir, çünkü yük karakteristiği her yılın aynı sezonunda mevsimsel benzerlik göstermektedir [10].



Şekil 5.2. Benzer Gün Seçim Sınırları

Benzer gün, tahmin edilecek günden önceki otuz günün setinden ve bir önceki yıla ait aynı günün otuz gün öncesi ve sonrasından itibaren altmış bir gün içerisinde seçilir. Tahmin edilecek günde bir değişiklik olması durumunda benzer günler yine aynı şekilde seçilir. Benzer günü seçmek için toplamda doksan bir günlük bir süre incelenir. Hem tahmin edilecek gün hem de eğitim setindeki günler için benzer bir gün seçilir [22].

Bu tez çalışmasında, tahmin edilen gün ile araştırılan önceki günler arasındaki benzerliği değerlendirmek için ağırlık faktörleri ile öklid normu kullanılır. Öklid normuna göre belirlenen değerlendirme, norm kavramına dayalı bir ifade kullanarak benzerliği anlamamız için kullanışlıdır. Öklid normuna dayanarak tahmin edilecek güne karşılık gelen benzer günler seçilir. Böylece öklid normunun azalması, benzer günün daha iyi değerlendirilmesine neden olur. Öklid normunun uygulanmasından önce hava durumu verileri ile yük arasındaki korelasyon katsayısı araştırılmıştır. Yapılan incelemelere göre maksimum sıcaklık, minimum sıcaklık ve yük arasında yüksek bir korelasyon olduğu anlaşılmıştır. Bu nedenle, tahmin edilecek güne karşılık gelen benzer günler, maksimum ve minimum sıcaklık kullanılarak oluşturulmuş öklid normuna göre seçilmiştir. Aynı zamanda benzer günler, tahmin edilecek günün gün tipine karşılık gelen gün tipinden seçilir.

Genel olarak çalışmada kullanılacak benzer gün seçimi için Eş. 5.7'deki ağırlık faktörleri ile oluşturulmuş öklid normu kullanılır:

$$D = \sqrt{\hat{w}_1 \Delta T_{\max}^2 + \hat{w}_2 \Delta T_{\min}^2 + \hat{w}_3 \Delta \text{Gün}^2} \quad (5.7)$$

$$\Delta T_{\max} = \hat{T}_{\max} - T_{\max}^n \quad (5.8)$$

$$\Delta T_{\min} = \hat{T}_{\min} - T_{\min}^n \quad (5.9)$$

$$\Delta \text{Gün} = \hat{\text{Gün}} - \text{Gün}^n \quad (5.10)$$

Eş. 5.8 ve Eş. 5.9'da yer alan $\hat{T}_{\max}$ ve $\hat{T}_{\min}$ tahmin edilecek güne ait ortalama maksimum ve minimum sıcaklıktır. $T_{\max}^n$ ve $T_{\min}^n$ ise sırasıyla araştırılan önceki günlere ait maksimum ve minimum sıcaklıktır. Eş. 5.10'da $\hat{\text{Gün}}$ tahmin edilecek günün gün tipi Gün^n ise araştırılan günün gün tipi olarak belirlenmiştir. $\hat{w}_i$ ($i = 1, 2$) ağırlık faktörüdür. Ağırlık faktörü $\hat{w}_i$ çoklu regresyon modeline dayanan en küçük kareler yöntemi ile belirlenir.

$$L_{\max} = \hat{w}_0 + \hat{w}_1 T_{\max} + \hat{w}_2 T_{\min} + \hat{w}_3 \text{Gün} \quad (5.11)$$

Eş. 5.11'de $L_{\max}$ gün içerisindeki puant güç değerini, $T_{\max}$ maksimum sıcaklık, $T_{\min}$ minimum sıcaklık ve Gün Bölüm 5.2.2'de belirtilen gün tipi değerleridir. $\hat{w}_i$ ($i = 0 \sim 3$) ise ağırlık faktörüdür.

Ağırlık faktörleri, yük faktörünün maksimum gücü nasıl etkilediğini göstermek ve öklid normunda bunu dikkate alarak benzer günü belirlemek için kullanılır. Eş. 5.11 doksan bir günlük zaman için analiz edilir. Çoklu regresyon modeline dayanan bu doksan bir denklemin çözülmesiyle $\hat{w}_i$ ($i = 0 \sim 3$) ağırlıklar hesaplanabilir. Ancak bu tez çalışmasında Eş. 5.11'de verilen doğrusal denklem katsayıları ($\hat{w}_i$), modern bir sezgisel algoritma olan Yerçekimsel Arama Algoritması (Gravitational Search Algorithm) kullanılarak hesaplanmıştır. Bu değerlerin Eş. 5.7'de yerine koyulmasıyla, analiz edilen doksan bir günlük bir süre için D değerleri hesaplanır. En küçük değere sahip olan gün, tahmin edilecek gün için benzer gün olarak seçilir. Bu durum, öklid normu sonuçları ne kadar küçük olursa, benzer gün seçiminin daha iyi belirleneceği anlamına gelir [6,22,10].

5.3. YSA Analizi

Yapay sinir ağı, biyolojik sinir sisteminin fonksiyonelliği tarafından harekete geçirilerek oluşturulan bir model çeşidini ifade eder. Yapay sinir ağı öğrenme süreci boyunca bilgiyi depolar.

Birçok yönden kategorize edilmiş farklı çeşitlerde yapay sinir ağı modelleri vardır, ancak bunlar arasında en yaygın kullanılanı öğrenme prensibine dayalı yapay sinir ağı modelleridir. Bir sinir ağı, örneklerden öğrenirken denetimli ya da denetlenmeyen öğrenmeyi kullanır. Denetimli/Eğitici öğrenmede ağı, girişi ve istenilen çıktıyı gösterir. Denetlenmeyen öğrenmede ise yalnızca giriş sinyali gösterilir. En yaygın denetimli yapay sinir ağı modeli çok katmanlı algılayıcı sinir ağıdır. Araştırılan çoğu kısa dönem yük tahmini modelleri buna dayanmaktadır. Bu tez çalışmasındaki denetimli öğretici ağı modeli, ileriye doğru bir şekilde birbirine bağlanan algılayıcılar olarak adlandırılan çok sayıdaki hesaplama birimi katmanlarından oluşur. Çıktılar, giriş sinyallerinin doğrusal kombinasyonu alınarak ve bir aktivasyon fonksiyonu kullanılarak dönüştürülmesiyle elde edilir.

Algılayıcının çıktısı Eş. 5.12'deki şekilde yazılabilir:

$$y = \varphi(\sum_i^n w_i x_i - \theta) \quad (5.12)$$

Burada y çıktıyı, x_i giriş sinyallerini, w_i nöron ağırlıklarını, θ sapma terimini temsil eder. φ doğrusal fonksiyon, basamak fonksiyonu, lojistik fonksiyon veya hiperbolik teğet fonksiyonu olabilen aktivasyon fonksiyonudur. Genel olarak kullanılan çok katmanlı ileri beslemeli yapay sinir ağı üç katmandan oluşur. Bunlar Şekil 3.5 'te görülebileceği üzere bir giriş katmanı, gizli katman ve çıktı katmanından oluşur.

Gizli katmandaki aktivasyon fonksiyonu doğrusal değildir, çıktı katmanının aktivasyon fonksiyonu ise doğrusal veya doğrusal değildir. Bu tez çalışmasında ileri düzeyde bir hesaplama kabiliyeti elde etmek için çok katmanlı bir algılayıcı ağı kullanılmıştır. Çok katmanlı ileri beslemeli ağı öğrenme süreci için geriye yayılım algoritması kullanılır, bu teknikte ağırlık ile ilgili olarak hata karaler toplamının gradyanı hatayı geriye doğru ağda yaymak suretiyle gradyan alçalma metodu uygulanarak yaklaştırılır.

Eş. 5.13'te enerji fonksiyonu öğrenme sürecini durdurmak için bir kriter olarak kullanılır:

$$E = \frac{1}{2} \sum (\Delta y - \Delta c)^2 \quad (5.13)$$

Burada, Δy ve Δc sırasıyla gerçek sonucu ve arzu edilen sonuçları temsil eder. Amaç, E değerini en aza indirmektir. Eğer $E = 0$ ise, ağ minimize edilmiş çıktıya ulaşmıştır.

Bu tez çalışması için önerilen yapay sinir ağı modeli Şekil 5.4' te gösterilmektedir. Önerilen sinir ağının çıkış katmanından elde edilen 24 birim, kısa dönem yük tahmini yapılacak gün için saat 01:00' dan gece saat 00:00' a kadar olan saatlik güç değerleridir.

Önerilen sinir ağının girdi değişkenleri:

- Benzer güne ait L_n^k ($n = 1 \sim 24$) 24 saatlik güç değerleri,
- Tahmin edilecek gün için ortalama maksimum sıcaklık değeri $\hat{T}_{max}$,
- Tahmin edilecek gün için ortalama minimum sıcaklık değeri $\hat{T}_{min}$,
- Tahmin edilecek gün ile benzer gün arasındaki maksimum sıcaklık sapması ΔT_{max}^k ,

$$\Delta T_{max}^k = \hat{T}_{max} - \hat{T}_{max}^k \quad (5.14)$$

- Tahmin edilecek gün ile benzer gün arasındaki minimum sıcaklık sapması ΔT_{min}^k ,


$$\Delta T_{min}^k = \hat{T}_{min} - \hat{T}_{min}^k \quad (5.15)$$

- Tahmin edilecek gün için belirlenen gün tipi $\widehat{Gün}$, ($\widehat{Gün} = 1 \sim 7$)
- Tahmin edilecek gün ile benzer gün arasındaki gün tipi sapması $\Delta G_{ün}^k$,

$$\Delta G_{ün}^k = \widehat{Gün} - G_{ün}^k \quad (5.16)$$

Eş. 5.14'te $\hat{T}_{max}^k$ benzer günler için maksimum sıcaklıktır. Eş. 5.15'de $\hat{T}_{min}^k$ benzer günler için minimum sıcaklıktır. Eş. 5.16'da $G_{ün}^k$ benzer günler için gün tipidir.

Genellikle, üç katmanlı yapay sinir ağı, gizli katmanın sayısının artırılması nedeniyle doğrusal olmayan bir fonksiyon için yaklaşım yeteneğine sahiptir. Bu nedenle, Şekil 5.3'te gösterilen model üç katmandan oluşur ve her katmanın ileri besleme bağlantısı vardır. Bu modelde giriş katmanı birim sayısı 30, gizli katman birim sayısı 20 ve çıkış katman birim sayısı 24'tür.



Şekil 5.3. Yapay Sinir Ağ Modeli

5.3.1 Normalizasyon

İyi bir sonuç elde etmek ve hesaplama süresini kısaltmak için ağ eğitiminden önce ağın girdi ve çıktı değişkenlerini normalize etmek çok önemlidir. Genellikle, yapay sinir ağının eğitilmesi için kullanılan girdi değişkenleri, 0' dan 1' e kadar olan sınırlar içinde normalize edilir. Ağın eğitilmesi için kullanılan girdi değişkenleri tüm yılın verileri kullanılarak normalize edildiyse, normalize edilmiş verilerin değerleri, yaz aylarında üst seviyeye ya da kış aylarında daha düşük seviyeye doğru kümelenmiş olduğu için eğitilen sinir ağının verimliliği düşer. Bu tez çalışmasında ağın eğitilmesi için kullanılan veri kümesindeki tüm girdi değişkenlerinin minimum normalizasyon değeri 0,1maksimum normalizasyon değeri 0,9 olacak şekilde, (0,1 - 0,9) değerleri arasındaki sınırlar içinde öğrenme aralığı verileri kullanılarak normalize edilmiştir.

Normalizasyon tekniklerinde iki temel tip vardır:

1. Min - Max Normalizasyon: Bu teknik ile girilen veride doğrusal bir dönüşüm uygulanır. Bir öz nitelikli veri kümesinin her değerinden minimum değerini belirleyip ve farkı öznitelik aralığına böler. Eş. 5.17’de matematiksel ifadesi verilmiştir.

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (5.17)$$

Eş.5.17’de $\max(x)$ ve $\min(x)$, değişken x değeri için minimum ve maksimum değerdir. Eğer $\max(x)$ değeri $\min(x)$ 'e eşitse, normalize edilmiş x değeri 0.5'e kabul edilir.

2. Ondalık Ölçeklendirme: Bir öznitelik veri kümesi değerlerinin ondalık noktası ölçeklendirilerek normalize edilir. x değerine karşılık gelen modifiye edilmiş bir x' Eş.5.18’de verilen matematiksel ifade kullanılarak elde edilir.

$$x' = \frac{x}{10^j} \quad (5.18)$$

burada j en küçük tamsayıdır, böylece $\max(|x'|) < 1$

Bu tez çalışması için oluşturulan çok katmanlı yapay sinir ağı modelinde logaritmik sigmoid aktivasyon fonksiyonunun kullanılması nedeniyle max-min normalizasyon kullanılmıştır. Ayrıca herhangi bir sapma eklenmeden veriyle ilişkili tüm özellikler korunur.

5.3.2 Kısa dönem yük tahmini için algoritmanın uygulanması

Çalışmada kullanılan geriye yayılım algoritması eğitilmeden önce bazı parametreler belirlenmelidir. Bu parametreler şunlardır:

1. Ağırlıklar: Başlangıç ağırlıkları küçük rasgele değerlere sahip olmalıdır. Literatürdeki çalışmalar aynı katmandaki başlangıç ağırlıklarının eşit olması durumunda geriye yayılım algoritmasında yakınsama olmayacağını göstermektedir.
2. Öğrenme Hızı: Geriye yayılım algoritmasının uygunluğu ve yakınsaması kesinlikle öğrenme hızının değerine bağlıdır. Öğrenme hızının optimum değeri sisteme bağlıdır.

Aynı zamanda, öğrenme hızının küçük bir değere sahip olması gerektiği önerilmektedir.

3. Momentum Terimi: Momentum terimi genellikle geriye yayılım algoritmasının güncellemesi için eklenir, böylece algoritma daha hızlı çalışır. Aynı zamanda momentum terimi de öğrenme hızı gibi sisteme bağlıdır.

4. Gizli Nöronlar

Kullanılacak gizli nöronların optimum sayısının belirlenmesi, tahmin sonuçlarının doğruluğunu etkileyebileceği için başarılı tahmin sonuçları elde edilmesinde çok önemli bir karardır. Örneğin, gizli nöronlar çok küçük seçilirse yetersiz bilgi sonucunda doğru olmayan tahmin sonuçları elde edilir. Benzer şekilde, eğer gizli nöronlar çok fazla ise, sonuca ulaşmak çok uzun bir zaman alacaktır. Benzer çalışmalarda olduğu gibi gizli nöronların sayısı aşağıdaki kurallar kullanılarak belirlenebilir:

- $(x - 1)$ Gizli nöronlar
- $(x + 1)$ Gizli nöronlar
- Her 5 giriş nöronu için 8 gizli nöron vardır. Bu durum 5 girdi, 8 gizli ve 1 çıktı nöronu içeren bir ağ olarak açıklanabilir.
- p/x Nöronlar

Bu ifadelerde x, giriş nöronunu ve p, eğitim modellerinin sayısını temsil eder. Bu kurallar ışığında çalışmada kullanılan yapay sinir ağı parametreleri gizli katman nöron sayısı 20, öğrenme hızı 0,02, momentum terimi 0,015, sigmoid fonksiyonu katsayısı 1 olacak şekilde belirlenmiştir.

Önerilen üç katmanlı bir yapay sinir ağı için geriye yayılım algoritmasının adımları şöyle ifade edilebilir:

1. Başlangıç ağırlıkları ve küçük rasgele değerlere yakınsama.
2. Model seçimi
3. Gizli ve çıktı katmanlarındaki her birimin net girdi ve çıktısının hesaplanması.
4. Çıkış birimlerinde hata hesabı.

5. Yayılmakta olan hataları görebilmek için ağırlıkların ve yakınsamaların güncellenmesi.
6. Sonraki birimlerde hatanın daha fazla yayılmaması için 2. adıma geri dönüp tekrarlanmasıdır.

Önerilen yapay sinir ağı için eğitim ve tahmin süreçleri aşağıdaki gibi sıralanır:

1. Ağın öğrenme aralığının belirlenmesi: Önerilen ağ, tahmin edilecek günden önceki otuz günün verileri ve bir önceki yıla ait aynı günün otuz gün öncesi ve sonrasında itibaren altmış bir günün verileri kullanılarak eğitilir.
2. Bir öğrenim günü için benzer günlerin seçimi: Bir öğrenim gününde N benzer gün seçilir. N benzer gün için geriye yayılım algoritmasının eğitimi: Önerilen ağ, bir öğrenim günü için N benzer günler kullanılarak eğitilir.
3. Öğrenme aralığının her günü için geriye yayılım algoritmasının eğitilmesi: Önerilen ağ, 2. adım ile aynı yöntemle öğrenim gününün her günü boyunca eğitilir.
4. Belirli aralıkta 1000 iterasyon ile geriye yayılım algoritmasının eğitilmesi: Belirli aralıkta iterasyon ile algoritmanın eğitilmesi bir öğrenme setinden oluşur. Ağ, öğrenme setini 1000 kez tekrarlayarak eğitilir.
5. Tahmin edilecek gün için benzer günleri seçilmesi: Yük tahmininde bulunmadan önce, tahmini güne karşılık gelen M benzer günler seçilir.
6. Yük tahmini için ağ parametrelerinin girilmesi: Bölüm 5.3' de tanımlanan girdi değişkenlerinin ağa sunulması.
7. Yük tahmini: 6. Adımda açıklanan girdi değişkenleri, eğitilmiş ağ tarafından kullanılır. Böylelikle kısa dönem yük tahmini elde edilir.

5.4. Benzetim Programı

Bölüm 5.3' te önerilen ağ modelinin anlatıldığı gibi, 30 giriş birimi ve 24 çıkış biriminden oluşan ağ modeli kurulur. Oluşturulan çok katmanlı yapay sinir ağı modelinde logaritmik sigmoid aktivasyon fonksiyonunun kullanılarak bütün giriş ve çıkış verileri ağa sunulabilmeleri için 0-1 aralığında normalize edilir. Ağın işlevselliğini daha verimli hale getiren gizli katmanın sayısı, deneme yanılma esasına göre seçilir. Bu tez çalışması için gizli katman nöron sayısı 20 seçilmiştir.

Ağ önceki veriler kullanılarak eğitilir. Bu tez çalışmasında, ağın eğitimi için:

- Orta Anadolu Yüz Tevzi İşletme Müdürlüğüne ait 01.01.2009 tarihinden 31.12.2015 tarihine kadar gerçekleşen saatlik yük verileri,
- 01.01.2009 tarihinden 31.12.2015 tarihine kadar gerçekleşen günlük maksimum ve minimum hava sıcaklık verileri,
- Bu tarihler arasındaki tüm günlere ait gün tipi değerleri kullanılmıştır.

Önerilen ağa yük tahmini yapılacak günlere ait girişlerin sunulması ile ağın çıktısı, normalize edilmiş 24 saatlik yük tahmini değerleridir. Bu sonuçlar gerçek veri ile yazılmış sonuçlar arasında bir karşılaştırma yapmak üzere geri normalize edilerek gerçek tahmin değerleri elde edilir. Son adım ağın performansının değerlendirilmesidir. Ortalama mutlak yüzde hatası (The mean absolute percentage error, MAPE) kullanılan ağ performansının ölçüsüdür.

Benzetim programı Microsoft Visual Studio tümleşik geliştirme ortamında C# dili kullanılarak gerçekleştirilmiştir. 24 saatlik yük tahmini sırasında açıklanan yöntemle göre geri yayılım algoritması kullanılmıştır. Rasgele değerlerin ne ölçüde istikrarlı olduğuna dair bilgi edinmek için ağ farklı ağırlıklarda test edilmiştir. Ağırlıklar rastgele küçük değerlere göre belirlenir. Bu değerleri seçerken ağın performansının değişkenlik gösterdiği görülür. Ağırlıklar, ağın performansını artırır veya azaltır. Bu ağırlıklar 0,05'den 0,1'e kadar seçilerek ayarlanır. Deneme yanılma ile elde edilen ağın öğrenme değişkenleri Çizelge 5.2.' de verilmiştir.

Çizelge 5.2. Yapay Sinir Ağı Değişken Parametreleri

Öğrenme Hızı	0,02
Momentum Terimi	0,015
İterasyon	1000
Gizli Katman Nöron Sayısı	20
Sigmoid Fonksiyon Katsayısı	1

Tekrarlama için 2000'den fazla sinir ağının eğitilmesi daha iyi ve daha istikrarlı bir performans getiremez, böylece 1000 iterasyon yeterlidir. Bu tez çalışmasında ağ, 91 günün verileri kullanılarak eğitilir. Tahmin edilecek gün değıştikçe ağ tekrar eğitilir. Hata sürekli bir değere gelene kadar eğitim devam eder.

5.5. Sayısal Sonuçların Değerlendirilmesi

Kısa dönem yük tahmini için geliştirilen ağ TEİAŞ'tan elde edilen 01.01.2009 tarihinden 31.12.2015 tarihine kadar gerçekleşen saatlik yük verileri kullanılarak test edilmiştir. Önerilen ağ, Microsoft Visual Studio tümleşik geliştirme ortamında C# dili kullanılarak gerçekleştirilirken, 2013 yılının farklı zamanlarında, farklı gün tipi endeksine sahip günler için yük tahmini yapılmıştır. Bu tez çalışması için oluşturulan benzetim programının kullanılabilirliğinin ölçülmesi için farklı gün tiplerinde seçilerek test edilmiş günler şöyledir:

- İlkbahar mevsiminde hafta içi günü
- Yaz mevsiminde hafta içi günü
- Sonbahar mevsiminde hafta içi günü
- Kış mevsiminde hafta içi günü
- Pazartesi, Salı, Çarşamba, Perşembe günü örneği
- Cuma günü
- Cumartesi günü
- Pazar günü
- Milli Bayram örneği
- Dini Bayram örneği

Yük tahmini performansı ortalama mutlak yüzdesi hatası (MAPE) şeklinde hesaplanmıştır. MAPE, ağ performansını değerlendirmede kullanılan en yaygın hata tahmin ölçütlerinden biridir. Mutlak hata yüzde olarak ölçülür ve Eş. 5.13'te şöyle tanımlanır:


$$MAPE (\%) = \frac{1}{N} \sum_{i=1}^N \frac{|H_A^i - H_F^i|}{H_A} \times 100 \quad (5.13)$$

Eş. 5.13'te H_A gerçek yük değeri, H_F tahmin edilmiş yük değeri, N toplam saat sayısı ve i saat endeksi olarak tanımlanır. Ortalama mutlak yüzde hata oranının daha küçük elde edilmesi için bazı değişkenlerin optimum değerler seçilir. Bu optimum değerler öğrenme hızı için 0,02, momentum sabiti için 0,015, 1000 iterasyon ve 20 gizli nörondur. Bu optimum değerler deneyerek ve hata oranları dikkate alınarak seçilmiştir. Bu parametreler ile elde edilen yüzde hata hesapları Çizelge 5.3.' te verilmiştir.


Çizelge 5.3. Benzetim Sonuçları

Test Edilen Günler	YSA MAPE (%)	GA + YSA MAPE (%)
27.05.2013	17,5108	5,788481
14.05.2013	12,56611	6,871812
20.02.2013	15,50986	2,699343
08.08.2013	16,53364	7,061283
14.06.2013	21,46847	9,960938
28.09.2013	39,50391	34,59648
20.10.2013	5,652136	5,085615
14-18.10.2013	29,34922	1,42763
23.04.2013	5,520896	10,03819


Kullanılan ağ eğilimin nasıl görüldüğüne dair bir fikir edinmek için gerçek ve tahmin edilen sonuçlara göre haftalık yük eğrileri çizilir. Şekil 5.6' dan 5.14' e kadar, tahmin edilen günlerin yük eğrilerinin neredeyse gerçek yük eğrileri ile uyduğu gözlenmiştir. Bu durum, önerilen ağ modelinin kısa dönem yük tahmini için doğru eğilimde olduğunu göstermektedir.




Şekil 5.4. 27.05.2013 tarihi için gerçek ve tahmini yük eğrileri




Şekil 5.5. 14.05.2013 tarihi için gerçek ve tahmini yük eğrileri




Şekil 5.6. 20.02.2013 tarihi için gerçek ve tahmini yük eğrileri




Şekil 5.7. 08.08.2013 tarihi için gerçek ve tahmini yük eğrileri




Şekil 5.8. 14.06.2013 tarihi için gerçek ve tahmini yük eğrileri




Şekil 5.9. 28.09.2013 tarihi için gerçek ve tahmini yük eğrileri



Şekil 5.10. 20.10.2013 tarihi için gerçek ve tahmini yük eğrileri



Şekil 5.11. 14-18.10.2013 Kurban Bayramını kapsayan tarihler için gerçek ve tahmini yük eğrileri



Şekil 5.12. 23.04.2013 tarihi için gerçek ve tahmini yük eğrileri



6. SONUÇLAR VE DEĞERLENDİRMELER

Elektrik enerji sistemlerinin planlanmasında, işletilmesinde ve kontrolünde yardımcı olduğu için doğru kısa dönem yük tahminleri en belirleyici alanlardan biridir. Kısa dönem yük tahmini sadece güç sisteminin işletilmesi için değil, aynı zamanda enerji verimliliği politikalarının belirlenmesinde, enerji işlemlerinde ve enerji piyasalarında karar vermenin temeli oluşturduğu için de çok önemli bir konudur. Enerji sektöründeki karar vericilerin doğru tahminlere ihtiyacı vardır, çünkü kararların çoğu zorunlu olarak gelecekteki taleplerin tahminlerine dayanmaktadır. Enerji sistemlerinde tahmin yapmak, o an için talep edilen enerjiyi karşılamak demektir. Elektrik talebi için yapılan kısa dönem yük tahmini, enerji arzını ve sistem güvenliğini sağlamak için gereken elektrik güç rezervinin hesaplanmasına ve işletme maliyetlerinin düşürülmesine olanak sağlar.

Yük tahmini modeli, elektrik sisteminin güvenli ve ekonomik olarak işletilebilmesi için kritik öneme sahip bir karar destek aracıdır. Yapılacak ilk kararlardan biri, bölgedeki yük tahmini etkileyebilecek faktörlerin incelenerek uygun bir modelin seçilmesidir. Ayrıca, kısa dönem yük tahmini için, güç sistemini ayrıntılı olarak bilinmesi gerekir. Böylelikle, belirtilen güç sistemi için en iyi yöntem seçilebilir.

Bu tez çalışmasında, OAYTM (Gölbaşı) bölgesinin kısa dönem elektrik yük tahmini için yapay sinir ağları ve genetik algoritma tabanlı adaptif bir hibrid sistem modeli önerilmiştir. Klasik YSA çıkış nöronlarını hesaplamak için önceden tanımlanmış aktivasyon fonksiyonunu kullanır. Geliştirilen bu adaptif model her katman için bu işlevi dinamik olarak günceller. Geliştirilen bu modelde, nöronların aktivasyon fonksiyonunun optimal kombinasyonunu tanımlamak için genetik algoritma, sezgisel bir arama birimi olarak kullanılmıştır. Geliştirilen model, test verilerine uygulanmış ve sonuçlar klasik YSA ile karşılaştırılmıştır. Geliştirilen modelin yük tahmini performansı ortalama mutlak yüzdesi hatası (MAPE) şeklinde hesaplanmıştır. Hesaplamalar, geliştirilen adaptif hibrid modelinin klasik YSA' nın performansından daha iyi performans gösterdiğini doğrulamaktadır. Böylece, önerilen modelin kısa dönem yük tahmini için gerçeğe yakın sonuçlar verdiğini ve doğru eğilimde olduğunu göstermektedir.

Önerilen yaklaşım, deneysel olarak daha kolay, basit ve uygun maliyetli olduđu için büyük fayda sağlamaktadır. Gerçek zamanlı yük verilerinin doğru ve tam kullanılmasıyla tahminlerin doğruluğunu geliřtirmek mümkündür. Ayrıca daha fazla sıcaklık ve parametre bilgisi modele dahil edilerek tahminlerin doğruluđu geliřtirilebilir. Tahminlerin belirsizliğini azaltmak için yeni teknikler geliřtirmek gereklidir. Gelecekte farklı öğrenme algoritması ve diğerk destek vektör makine öğrenimi tekniklerinin kullanılması önerilmektedir.



KAYNAKLAR

1. Kaytez, F. (2012). *En küçük kareler destek vektör makineleri ile Türkiye'nin uzun dönem elektrik tüketim tahmini ve modellenmesi*, Yayınlanmamış Doktora Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
2. Başoğlu, B. ve Bulut, M. (2016). Kısa dönem elektrik talep tahminleri için yapay sinir ağları ve uzman sistemler tabanlı hibrit sistem geliştirilmesi. *Gazi Üniversitesi, Mühendislik Mimarlık Fakültesi Dergisi*, 575-583.
3. Kargar, M. C. ve Charsoghi K. (2014). Predicting annual electricity consumption in Iran using artificial neural networks (narx). *Indian Journal of Scientific Research*, 5(1), 231-242.
4. Fan, S. ve Hyndman, R. J. (2010). Short-term load forecasting based on a semi-parametric additive model. *IEEE Transactions on Power Systems*, 27(1), 134-141.
5. Moturi, C. A. ve Kiako, F. K. (2013). Use of artificial neural networks for short-term electricity load forecasting of kenya national grid power system. *International Journal of Computer Applications*, 63(2), 0975 – 8887.
6. Senjyu, T., Sakihara H., Tamaki Y., ve Uezato K. (2010). Next day peak load forecasting using neural network with adaptive learning algorithm based on similarity. *Electric Machines & Power Systems*, 28, 613–624.
7. Adepoju, G. A., Ogunjuyigbe, S. O. A. ve Alawode, K.O. (2007). Application of neural network to load forecasting in nigerian electrical power system. *Ladoke Akintola University of Technology Nigeria, The Pacific Journal of Science and Technology*, 8(1), 68-72.
8. Örün, S. ve Karatekin C. (2014). *İstanbul ili avrupa yakası için uzun dönem elektrik enerjisi yük tahmini long term load forecasting for Istanbul european side*. *İstanbul Teknik Üniversitesi, Eleco 2014 Elektrik – Elektronik – Bilgisayar ve Biyomedikal Mühendisliği Sempozyumu*, 38-43.
9. Oğurlu, H. (2011). *Matematiksel modelleme kullanarak Türkiye'nin uzun dönem elektrik yük tahmini*, Yayınlanmamış Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
10. Ceylan G. (2004). *Yapay sinir ağları ile kısa dönem yük tahmini*, Yayınlanmamış Yüksek Lisans Tezi İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
11. Türkiye Elektrik İletim A.Ş. (2010). *Enerji Verimliliği Strateji Belgesi (2010 – 2023)*. Ankara: Türkiye Elektrik İletim A.Ş., 1-16.
12. İnternet: 2016 yılı Türkiye elektrik iletimi sektör raporu.URL: <https://www.teias.gov.tr/tr/sektor-raporlari> ,Son Erişim Tarihi: 15.11.2016.
13. İnternet: T.C. Enerji ve Tabii Kaynaklar Bakanlığı 2015-2019 Stratejik Planı.URL: https://sp.enerji.gov.tr/ETKB_2015_2019_Stratejik_Planı.pdf Son Erişim Tarihi: 15.09.2018.

14. İnternet: Türkiye elektrik enerjisi 5 yıllık üretim kapasite projeksiyonu (2017-2021). URL: <https://www.teias.gov.tr/tr/sektor-raporlari> Son Erişim Tarihi: 15.11.2018.
15. İnternet: Elektrik İletim Sistemi Arz Güvenilirliği ve Kalitesi Yönetmeliği. URL: <https://www.teias.gov.tr/tr/yonetmelikler> Son Erişim Tarihi: 15.11.2018.
16. Khwaja, A.S., Naeem, M., Anpalagan, A., Venetsanopoulos, A. ve Venkatesh, B. (2015). Improved short-term load forecasting using bagged neural networks. *Ryerson University, Toronto, Canada. Electric Power Systems Research* 125, 109–115.
17. İnternet: Elektrik Piyasası Tarifeler Yönetmeliği. URL: <https://www.teias.gov.tr/tr/yonetmelikler> Son Erişim Tarihi: 15.11.2018.
18. Gürsoy, E. (2000). *Yük tahmini yöntemleri ve Çukurova Elektrik A.Ş. Kepez Elektrik T.A.Ş. bölgelerine uygulanması*. Yayımlanmamış Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
19. İnternet: Türkiye Elektrik Talebinin Profiller Üzerinden Analizi (2012). URL: <http://www.barissanli.com/pdf/kisiselcalismalar/> Son Erişim Tarihi: 15.08.2018.
20. Sheikh, S.K. ve Unde M. G. (2012). Short-term load forecasting using ann technique. *International Journal of Engineering Sciences & Emerging Technologies*, 1(2), 97-107.
21. Inc, E. (2010). *Electrical Load Forecasting: Modeling and Model Construction* 79-97.
22. Nkachukwu, C. C. (2014). *Short-term load forecasting using neural network for a residential building*. Eastern Mediterranean University Gazimağusa, North Cyprus.
23. Alkhatami, M. (2015). Introduction to electric load forecasting methods. *Columbia International Publishing Journal of Advanced Electrical and Computer Engineering*, 2(1), 1-12.
24. Elmas, Ç. (2016). *Yapay Zeka Uygulamaları*. Yer:Seçkin Yayıncılık, 230-240.
25. Ghods, L. ve Kalantar, M. (2011). Different methods of long-term electric load demand forecasting; a comprehensive review. *Iran University of science and technology (IUST), Tehran, Iran. Iranian Journal of Electrical & Electronic Engineering*, 7(4), 249-259.
26. İnternet: Orta Anadolu Yük Tevzi İşletme Müdürlüğü 2009 - 2015 yılları saatlik yük verileri. URL: https://ytbs.teias.gov.tr/ytbs/frm_login.jsf Son Erişim Tarihi: 15.08.2018.
27. İnternet: Meteoroloji Genel Müdürlüğü, Ankara, Kayseri ve Konya illeri 2009-2015 yılları gerçekleşen günlük maksimum ve minimum hava sıcaklık verileri. URL: <https://www.mgm.gov.tr/> Son Erişim Tarihi: 15.08.2018.
28. Öztemel, E. (2003). *Yapay Sinir Ağları*. Yer:Papatya Yayıncılık, 34-140.

29. Yavuz, S. ve Deveci, M. (2013). İstatiksel normalizasyon tekniklerinin yapay sinir ağın performansına etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 40, 167-187.
30. Akkurt, A. (2005). *Yapay sinir ağları ve Türkiye elektrik tüketimi tahmin modeli*, Yayınlanmamış Yüksek Lisans Tezi İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
31. Kaysal, K., Hocaoglu F. O. ve Kaysal, A. (2014). *Yük tahmini için hibrit (YSA ve regresyon) model*. Afyon Kocatepe Üniversitesi Elektrik Elektronik Mühendisliği, ISITES2014 Karabük - Türkiye
32. Sönmez, Y. ve Özden, S. (2017). Modelling of thermodynamic properties of a refrigerant gas (r404a) using hybrid algorithm artificial bee colony-artificial neural network (abc-ann). *International Journal of Refrigeration*, 18, 183-187
33. Karaboğa, D. (2017). *Yapay Zeka Optimizasyon Algortimaları*. Yer:Nobel Akademik Yayıncılık, 75-95.



ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : AKMAN, Tuğba
 Uyruğu : T.C.
 Doğum tarihi ve yeri : 14.07.1990, Ankara
 Medeni hali : Bekar
 Telefon : 0 (312) 203 83 70
 Faks : 0 (312) 203 82 65
 e-mail : akmantugba@hotmail.com.tr



Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Yüksek lisans	Gazi Üniversitesi / Elektrik Elektronik Mühendisliği	Devam ediyor
Lisans	Dumlupınar Üniversitesi / Elektrik Elektronik Mühendisliği	2012
Lise	Polatlı Anadolu Lisesi	2008

İş Deneyimi

Yıl	Yer	Görev
2013-Halen	TEİAŞ Genel Müdürlüğü	Mühendis

Yabancı Dil

İngilizce

Yayınlar

Akman, T., Yılmaz, C. ve Sönmez, Y. (2018). Elektrik Yüğü Tahmin Yöntemlerinin Analizi, *Gazi Mühendislik Bilimleri Dergisi*, 4(3), 65-73

Hobiler

Seyahat, Trekking, Sinema



GAZİ GELECEKTİR..