

**ENERJİ TALEP TAHMİNİNE YÖNELİK PROGRAM GELİŞTİRME VE BİR
BÖLGE İÇİN UYGULAMASI**

YÜKSEK LİSANS TEZİ

Abdurrahman BİÇER

Danışman

Dr. Öğr. Üyesi Ahmet YÖNETKEN

**ELEKTRİK MÜHENDİSLİĞİ – YENİLENEBİLİR ENERJİ SİSTEMLERİ
ANABİLİM DALI**

Haziran 2018

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**ENERJİ TALEP TAHMİNİNE YÖNELİK PROGRAM GELİŞTİRME VE BİR
BÖLGE İÇİN UYGULAMASI**

Abdurrahman BİÇER

Danışman
Dr. Öğr. Üyesi Ahmet YÖNETKEN

**ELEKTRİK MÜHENDİSLİĞİ – YENİLENEBİLİR ENERJİ
SİSTEMLERİ
ANABİLİM DALI**

Haziran 2018

TEZ ONAY SAYFASI

Abdurrahman BİÇER tarafından hazırlanan “Enerji Talep Tahminine Yönelik Program Geliştirme ve Bir Bölge İçin Uygulaması” adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca 28/06/2018 tarihinde aşağıdaki jüri tarafından **oy birliği** ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü **Elektrik Mühendisliği Anabilim Dalı - Yenilenebilir Enerji Sistemleri Bilim Dalı’nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Dr. Öğr. Üyesi Ahmet YÖNETKEN

Başkan : Dr. Öğr. Üyesi Said Mahmut ÇINAR
Afyon Kocatepe Üniversitesi
Üye : Dr. Öğr. Üyesi Sertaç GÖRGÜLÜ
Mehmet Akif Ersoy Üniversitesi
Üye : Dr. Öğr. Üyesi Ahmet YÖNETKEN
Afyon Kocatepe Üniversitesi
Üye :
Üye :

İmza



Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü Yönetim Kurulu’nun
...../...../..... tarih ve
..... sayılı kararıyla onaylanmıştır.

Prof. Dr. İbrahim EROL
Enstitü Müdürü


BİLİMSEL ETİK BİLDİRİM SAYFASI
Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

03/09/2018


Imza

Abdurrahman BİÇER

ÖZET
Yüksek Lisans Tezi

**ENERJİ TALEP TAHMİNİNE YÖNELİK PROGRAM GELİŞTİRME VE BİR
BÖLGE İÇİN UYGULAMASI**

Abdurrahman BİÇER
Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü

Elektrik Mühendisliği – Yenilenebilir Enerji Sistemleri Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Ahmet YÖNETKEN

Elektrik enerjisi, çeşitli üretim santrallerinde üretilen, iletim hatları ile yerleşim yerlerine aktarılabilen, aktarımı da kontrol altında tutulabilen ancak depolanamayan bir enerji kaynağıdır.

Giderek gelişen teknolojiye, sanayiden ve artan nüfustan dolayı her enerjiye olan talep arttığı gibi elektrik enerjisine olan talepte artmaktadır. Ülkelerin gelişmişliklerinin belirlenmesinde en önemli parametrelerden bir tanesi de kişi başına düşen elektrik tüketimidir. Bu konunun önemi, tüm dünyada olduğu gibi ülkemizde de bilinmektedir. Bu nedenle elektrik enerjisi üretimi arttırılmaya çalışılmaktadır. Üretimi arttırmanın yanı sıra üretim için gerekli olan üretim kaynaklarının tükeniyor olması ve üretim anında doğaya verilebilen zararlar nedeniyle enerjinin üretilmesi, dağıtımı ve iletimi kadar üretilen enerjinin en yüksek verimle, tasarrufla kullanılması da büyük önem taşımaktadır.

Enerjinin tasarruflu kullanılmasının sağlamak için önemli yöntemlerden biri de enerji talebini önceden tahmin etme konusudur ve bunun birçok yöntemi bulunmaktadır. Elektrik enerjisi depolanamadığından, bu enerji üretildiği gibi tüketilmesi gerekmektedir. Ayrıca enerjinin fiyatlandırılmasını kısa dönemli talep tahmin değeri de etkilemektedir. Bu yüzden de kısa dönemli talep tahmin yönteminin doğruluk oranı çok önemlidir. Doğruluk oranının yüksek olması, enerji piyasasının verimli olmasını sağlayacağı gibi güç sistemlerinin dengeli olarak çalışmasına olanak sağlayacak ve bu

sistemlerin optimizasyonu ve gvenirlięi aısından da son derece saęlıklı olacaktır. Doęruluk oranı yksek bir kısa dnemli talep tahmini sayesinde enerji piyasasında saęlıklı bir planlama saęlayarak, hem kaliteli enerjini kullanımına imkân saęlayıp hem de g sistemlerinin mrn uzatarak ok yksek meblaęlar harcamaktan kurtaracaktır. Bu alıřmada tahmin yntemleri zerinde durularak, MATLAB programında Yapay Sinir Aęları kullanılarak kısa dnemli talep tahmini yntemi geliřtirilmiřtir. Geliřtirilen bu yntem Urla blgesine uygulanarak sonular analiz edilmiřtir.

2018, xii + 69 sayfa

Anahtar Kelimeler: Talep Tahmini, Yapay Sinir Aęları

ABSTRACT
M.Sc. Thesis

**PROGRAM DEVELOPMENT FOR ENERGY DEMAND ESTIMATION AND
APPLICATION OF A REGION**

Abdurrahman BİÇER

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Elektrical Engineering – Renewable Energy Systems

Supervisor: Asst. Prof. Ahmet YÖNETKEN

The electrical energy, whose distribution is controllable but an unstorable energy source itself, is produced in various power plants and transferable to the residential areas via power lines. Due to the increasingly developing technology, industry and increasing population, the demand for electrical energy is increasing as the demand for each energy. One of the most important parameters in determining the development of countries is per capita electricity consumption. The prominence of this matter is also known in our country as it is all over the world. For this reason, the production of electrical energy is tried to be increased. In addition to increasing production, depletion of the resources essential for the mass production and generation of energy due to the damage that can be given to the nature in the course of production are of great importance in economical usage of generated energy with highest efficiency as well as in its distribution and delivery.

One of the most important ways to ensure energy-saving use of energy is the subject of predicting the demand for energy and there are many ways to do it. Since the electrical energy can not be stored, this energy must be consumed as it is produced. Moreover, the pricing of energy is also influencing the short-term demand forecast value. Therefore, the accuracy rate of the short-term demand forecasting method is very important. A high accuracy rate will provide a rich energy market and also enable power systems to work stably and it will be extremely beneficial for the optimization and reliability of these systems.

A high accuracy rate provides a healthy planning for the energy market thanks to the short-term demand forecasting and thereby enables high-quality energy to be used, also saves the user from wasting too much money by extending the systems' lifecycle. In this study focusing on estimation methods, In MATLAB, a short-run demand forecasting method was developed using Artificial Neural Networks.

2018, xii + 69 pages

Keywords: Demand Forecast, Artificial Neural Networks

TEŞEKKÜR

Tez çalışmam için gerekli olan yük verilerini temin edebilmeme olanak sağlayan Sayın Cemil Tütüncü'ye,
Tez çalışmam ve tüm hayatım boyunca koşulsuz yanımda olan destek olan annem, babam ve ağabeylerime,
Çocukluğumdan beri her anımda yanımda olan sıkıldığım her anda dertlerimi dinleyen en yakın arkadaşım Onur Şevik'e,
Üniversite hayatım boyunca destek olan ve bu tez çalışmasında danışmanım olan Dr. Öğr. Üyesi Ahmet Yönetken'e sonsuz teşekkürlerimi sunarım.

Abdurrahman BİÇER
AFYONKARAHİSAR, 2018

İÇİNDEKİLER DİZİNİ

Sayfa

ÖZET	iv
ABSTRACT	vii
TEŞEKKÜR	v
İÇİNDEKİLER DİZİNİ.....	x
KISALTMALAR DİZİNİ	ix
ŞEKİLLER DİZİNİ	x
ÇİZELGELER DİZİNİ.....	xvi
1. GİRİŞ	1
1.1 Yapılan Çalışmalar	2
1.2 Tezin Amacı.....	7
2. LİTERATÜR BİLGİLERİ	8
2.1 Yük Talep Tahmini	8
2.1.1 Yük Talep Tahminin Zamana Göre Sınıflandırılması.....	8
2.1.1.1 Kısa Dönemli Yük Talep Tahmini.....	8
2.1.1.2 Orta Dönemli Yük Talep Tahmini.....	9
2.1.1.3 Uzun Dönemli Yük Talep Tahmini	9
2.1.2 Yüğü Etkileyen Faktörler	10
2.2 Tahmin Yöntemleri.....	15
2.2.1 Analitik Yöntemler	16
2.2.1.1 Regresyon Analizi.....	16
2.2.1.2 En Küçük Kareler Yöntemi	18
2.2.1.3 Benzer Gün Yaklaşımı	19
2.2.1.4 Zaman Serileri Analizi.....	20
2.2.1.5 Wavelet Dalgacık Dönüşümü	22
2.2.2 Yapay Zeka Yöntemleri.....	23
2.2.2.1 Genetik Algoritmalar	23
2.2.2.2 Bulanık Mantık	23
2.2.2.3 Destek Vektör Makinaları.....	25
2.2.2.4 Uzman Sistemler	25
2.2.2.5 Yapay Sinir Ağları	26
2.2.3 Hibrit Yöntemler	26

3. MATERYAL ve METOT	27
3.1 Yapay Sinir Ağları	27
3.1.1 Biyolojik Sinir Sistemi ve Sinir Hücresi	27
3.1.2 Yapay Sinir Hücresi	28
3.1.3 Yapay Sinir Ağlarının Özellikleri.....	30
3.1.3.1 Doğrusal Olmama	30
3.1.3.2 Öğrenme.....	31
3.1.3.3 Genelleme	31
3.1.3.4 Uyarlanabilirlik.....	31
3.1.3.5 Hata Toleransı.....	31
3.1.4 Yapay Sinir Ağlarının Sınıflandırılması.....	31
3.1.4.1 Besleme Tipine Göre YSA'lar.....	32
3.1.4.2 Öğrenme Yöntemlerine Göre YSA'lar	33
3.1.5 Yapay Sinir Ağlarının Uygulama Alanları	34
3.1.5.1 Tahmin	34
3.1.5.2 Örüntülü Tanıma.....	34
3.1.5.3 Fonksiyon Yaklaşımı	34
3.1.5.4 Sınıflandırma.....	34
3.1.6 Tahmin Problemleri için Yapay Sinir Ağları	34
3.1.6.1 Ağ Yapısının Belirlenmesi.....	35
3.1.6.2 Aktivasyon Fonksiyonunun Belirlenmesi.....	36
3.1.6.3 Normalizasyon	36
3.1.6.4 Eğitim.....	36
3.1.6.5 Veri Setlerinin Düzenlemesi	37
3.1.6.6 Performansın Belirlenmesi.....	37
3.1.6.7 Yapay Sinir Ağları Yazılımları	37
4. DENEYSEL ÇALIŞMA	45
4.1 Veri Setlerinin Oluşturulması	45
4.1.1 Yük Verileri.....	46
4.1.2 Sıcaklık Verileri.....	46
4.1.3 Nem Verileri	47
4.2 MATLAB Yazılım Programı İle Tahmin Programının Oluşturulması	48
4.2.1 Arayüz Oluşturma	49
4.2.2 Verilerin MATLAB'e Aktarılması.....	51

4.2.3 Normalizasyon İşlemi.....	51
4.2.4 YSA'nın Oluşturulması ve Eğitimi	52
5. SONUÇ	57
6. KAYNAKLAR.....	63
ÖZGEÇMİŞ.....	70



KISALTMALAR DİZİNİ

Kısaltmalar

AR	Otoregresif
ARIMA	Otoregresif Entegre Hareketli Ortalamalar
ARMA	Otoregresif Hareketli Ortalamalar
EPDK	Enerji Piyasası Düzenleme Kurumu
GEDAŞ	Gediz Elektrik Dağıtım Anonim Şirketi
GWh	Giga Watt Saat
MA	Hareketli Ortalamalar
MAPE	Ortalama Hata Oranı
MGM	Meteoroloji Genel Müdürlüğü
MSE	Hata Oranlarının Kareleri
NNT	Neural Network Toolbox
TM	Trafo Merkezi
YSA	Yapay Sinir Ağı
YSH	Yapay Sinir Hücresi

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1	Urla Bölgesine Ait Örnek Mahallenin Bir Haftalık Yüğü	11
Şekil 2.2	Örnek Mahalleye Ait Kış Ayındaki Yüğü Grafiğı	12
Şekil 2.3	Örnek Mahalleye Ait İlkbahar Ayındaki Yüğü Grafiğı	12
Şekil 2.4	Örnek Mahalleye Ait Yaz Ayındaki Yüğü Grafiğı	13
Şekil 2.5	Örnek Mahalleye Ait Sonbahar Ayındaki Yüğü Grafiğı	13
Şekil 2.6	Örnek Mahalleye Ait Aylık Yüğü Değışimi	14
Şekil 2.7	Örnek Mahalleye Ait Aylık Sıcaklık Değışimi	14
Şekil 2.8	Örnek Mahalleye Ait Aylık Nem Değışimi	14
Şekil 2.9	Talep Tahmin Yöntemleri	15
Şekil 2.10	Regresyon Analizinde Doğrusal İlişki	17
Şekil 2.11	Regresyon Analizinde Doğrusal Olmayan İlişki.....	17
Şekil 2.12	Çoklu Regresyon.....	18
Şekil 2.13	Fourier Dönüşümü	23
Şekil 2.14	Bulanık Mantık Grafiğı.....	24
Şekil 3.1	Sinir Sistemi Blok Diyagramı	28
Şekil 3.2	İnsan Sinir Hücresi.....	28
Şekil 3.3	Yapay Sinir Hücresi	29
Şekil 3.4	Aktivasyon Fonksiyonları	30
Şekil 3.5	İleri Beslemeli YSA Blok Diyagramı	32
Şekil 3.6	Geri Beslemeli YSA Blok Diyagramı.....	33
Şekil 3.7	MATLAB YSA Kullanıcı Arayüzü	39
Şekil 3.8	Verilerin YSA'ya Tanıtılması	39
Şekil 3.9	YSA'nın Adlandırılması ve Oluşturulması.....	41
Şekil 3.10	Oluşturulan YSA'nın Ön İzlemesi	41
Şekil 3.11	Oluşturulan YSA'nın Penceresi	42
Şekil 3.12	Girdi ve Çıktı Değışkenlerinin Tanımlanması ve Eğitimin Başlaması.....	42
Şekil 3.13	YSA Eğitiminin İlerleyişi	43
Şekil 4.1	2013 Başından 2017 Haziran Sonuna Kadar Olan Saatlik Yüğü Verileri	46
Şekil 4.2	2013 Başından 2017 Haziran Sonuna Kadar Olan Saatlik Sıcaklık Verileri ..	47
Şekil 4.3	Havadaki Nem Oranının Hava Sıcaklığına Etkisi.....	48
Şekil 4.4	2013 Başından 2017 Haziran Sonuna Kadar Olan Saatlik Nem Verileri	48

Şekil 4.5 Data Base Kullanıcı Arayüzü.....	49
Şekil 4.6 Tahmin İşlemi İçin Kullanıcı Arayüzü	50
Şekil 4.7 Tahmin Yapılacak Günün Seçileceği Takvim	51
Şekil 4.8 Oluşturulan YSA'nın Yapısı	53
Şekil 4.9 Ağın Oluşturulduğu Parametreler	54
Şekil 4.10 Oluşturulan YSA'nın Eğitim Aşaması.....	54
Şekil 4.11 Oluşturulan Ağın Eğitim Performansı	55
Şekil 4.12 Oluşturulan Ağın Regresyon Doğruları	56
Şekil 5.1 24 Nisan 2017 İçin Tahmin Sonuçları	59
Şekil 5.2 25 Nisan 2017 İçin Tahmin Sonuçları	59
Şekil 5.3 26 Nisan 2017 İçin Tahmin Sonuçları	60
Şekil 5.4 27 Nisan 2017 İçin Tahmin Sonuçları	60
Şekil 5.5 28 Nisan 2017 İçin Tahmin Sonuçları	61
Şekil 5.6 29 Nisan 2017 İçin Tahmin Sonuçları	61
Şekil 5.7 30 Nisan 2017 İçin Tahmin Sonuçları	62

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 3.1 Biyolojik Sinir Sistemi ve YSA Karşılaştırması.....	29
Çizelge 3.2 YSA için Bazı Yazılım Programları	38
Çizelge 5.1 24 – 30 Nisan 2017 Arası Günlük MAPE Değerleri	57



1. GİRİŞ

Geleceğe dair herhangi bir alanda, bir değişkeni tahmin etmek kavramı, elde mevcut olan bilgilere, değerlere dayanarak “çıkarımda” bulunmak, bu çıkarımdan yola çıkarak da geleceğe yönelik “ön deyide” bulunmaktır.

Tahminin amacı, geleceğe yönelik yapılan planlamaların, düzenlemelerin daha sağlıklı daha güvenilir bir şekilde yapılmasını sağlamaktır. Örneğin kurulacak bir güç sisteminin yüksek verimli olarak çalışmasını sağlayacaktır. Yapılacak tahminin doğruluk oranı bu bağlamda en önemli konudur. Tahminin doğruluk oranının yüksek olması, geleceğe dönük yapılanmada karar vermedeki belirsizliği azaltarak, verimi arttıracaktır.

Herhangi bir değişkenin gelecekte alacağı değerlerin tahmini, değişkenin geçmiş dönemlerdeki gözlem değerleri kullanılarak oluşturulan modeller yardımı ile sağlanır. Geleceği tahmin amaçlı kurulan bir tahmin sistemini iki aşamada incelemek mümkündür. Bunlardan ilki model kurma, ikincisi de tahmin aşamasıdır. Yapılacak tahminler, kurulan modele göre gerçekleştirileceğinden dolayı model kurma aşaması oldukça önemlidir. Doğru model, gerçeğe daha yakın tahminlerin üretilmesini sağlayacaktır (Hamzaçebi 2011a).

Enerji Piyasası Düzenleme Kurumu Elektrik Piyasası Talep Tahminleri Yönetmeliği adında bir yönetmelik yayınlanmıştır. Bu yönetmelikte, talep tahmin modelini, talep tahmini için bilimsel yöntemler kullanılarak oluşturulacak model olarak açıklarken, talep tahminini ise dağıtım şirketleri tarafından, belli bir zaman aralıklarında farklı senaryolar belirleyerek, geleceği planlamak adına yapılan, elektrik enerjisi miktarının, puant güç talebinin ve abone sayısının tahmini olarak tanımlanmaktadır (EPDK 2016).

Elektrik güç sistemleri, içerisinde üretimden aboneye kadar, generatör, transformatör, iletim hatları ve dağıtım hatları gibi unsurları içinde barındıran sistemdir. Elektrik güç sistemlerinin kurulum maliyeti yüksek olduğunda dolayı, sistem verimli kullanılarak bakım maliyetleri, üretim maliyetleri düşük seviyede tutulabilir ve sistemin güvenilirliği arttırılabilir. Bunun yanı sıra elektrik fiyatlandırılması da planlı bir şekilde yapılabilir.

Tüm bunların sağlanması içinde yük talep tahmini konusu en önemli parametrelerden bir tanesidir.

Bu çalışmanın ikinci bölümünde yük talep tahminin sınıflandırılması, tahmini etkileyen parametreler ve tahmin yöntemleri incelenecektir.

Üçüncü bölümde ise bu çalışmada kullanılan Yapay Sinir Ağları ve MATLAB programı işlenmiştir.

Dördüncü bölümde, örnek bölge için yapay sinir ağları yöntemi kullanılarak kısa dönemli enerji talep tahmini uygulaması ve MATLAB programında benzetimi yapılacak bölgeye dayalı ve toplam yüke dayalı talep tahmin modeli oluşturulup, programın kullanım kolaylığı açısından kullanıcı ara yüzü oluşturulması ve programın çalışması anlatılacaktır.

Beşinci bölümde bu çalışmada elde edilen sonuçlar ve hangi modelin daha başarılı olduğu yorumlanmıştır.

Altıncı yani son bölümde ise çalışmada alıntı yapılan kaynak listesi verilmiştir.

1.1 Yapılan Çalışmalar

Balcı vd. (2010), regresyon analizi yöntemini kullanarak kısa dönemli yük tahmin modeli oluşturmuştur. Bu çalışmada regresyon analizi modelinin, en küçük kareler yöntemi modeline göre başarılı olduğu, bu modele göre yapılacak olan planlamanın daha güvenilir olacağı sonucuna varmışlardır (Balcı *et al.* 2010).

Var ve Türkay, yapay sinir ağlarını kullanarak kısa dönemli yük talep tahmini yapmışlardır. Bu çalışmada %7-%8'lik hata oranı ile %10'nun altında bir değer yakalayarak doğruluk oranı yüksek bir tahmin modeli oluşturmuşlardır (Var ve Türkay 2014).

Kaysal vd. (2014), yük tahmini için yapay sinir ağları ve regresyon analizi yöntemleriyle ve bu iki yöntemin birleşimiyle(hibrit) 3 farklı model oluşturmuşlardır.

Yapay sinir ağıları ile %6,67, regresyon analizi ile %7,49 ve hibrit model ile %5,26'lık hata oranı yakalayarak amaçlarına ulaşmışlardır (Kaysal *et al.* 2014).

Hamzaçebi vd. (2014), yapay sinir ağılarını kullanarak çoklu doğrusal regresyon modeli ve zaman serisine dayalı tahmin modelleri kurarak bunları karşılaştırmışlardır. Bu çalışmada yapay sinir ağıları modelinin kabul edilebilir ve doğruluk oranının çok yüksek olduğu sonucuna varmışlardır (Hamzaçebi *et al.* 2014).

Yavuzdemir, bulanık mantık, zaman serisi ve regresyon yöntemleri ile üç farklı model oluşturmuştur. Bu çalışmada bulanık mantık ile %4,81, zaman serisi ile %2,75 ve regresyon ile %7,64'lük hata oranı yakalamıştır (Yavuzdemir 2014).

Nalbant vd. (2005), en küçük kareler yönetimini kullanarak üç farklı tahmin modeli oluşturmuşlardır. Bu modeller üstel, doğrusal ve kuadratik modellerdir. Kuadratik tahminde %17 hata oranı çıkmıştır. Ancak doğrusal ve üstel modellerde ortalama %5'lik hata oranı yakalamışlardır (Nalbant *et al.* 2005).

Hamzaçebi ve Kutay, yapay sinir ağılarını kullanarak uzun dönemli talep tahmini modeli oluşturarak Türkiye'de 2003 ile 2010 yılları arası tüketilecek elektrik enerjisini tahmin etmeye çalışmıştır (Hamzaçebi ve Kutay 2004).

Yiğit, genetik algoritma yöntemini kullanarak lineer ve karesel model oluşturmuş Türkiye'nin 2020 yılına kadar enerji talebini tahmin etmeye çalışmıştır. 2020 yılında lineer modelde 452,47 TWh, karesel modelde 354,29 TWh olarak hesaplamıştır (Yiğit 2011).

İslam vd. (2014), yapay sinir ağıları ve genetik algoritmalar yöntemleri kullanarak hibrit bir tahmin modeli oluşturmuşlardır. Bu çalışmada yüzdelik hata (MAPE) değerini büyük oranda düşürmüşlerdir (İslam *et al.* 2014a).

Sahay ve Tripathi, yapay sinir ağılarını yöntemini kullanarak kısa dönemli yük talep tahmin modeli oluşturmuşlardır. Ağ eğitimi için 2007'den 2011'e kadar olan verileri

kullanarak modelin testi içinde 2012 yılının verileri ile karşılaştırmışlardır. Bu çalışmada hata oranı ortalama olarak %3,4 civarındadır (Sahay and Tripathi 2013).

Singh vd. (2013), yayınladıkları bir makalede bütün tahmin yöntemlerini detaylıca ele almışlardır. En başarılı yöntemin yapay zeka yöntemi olduğu sonucuna varmışlardır (Singh *et al.* 2013).

Luciano vd. (2014), yapay zeka yöntemlerinden biri olan NARX yöntemi ile çok kısa dönemli tahmin modeli oluşturarak 5'er dakikalık arayla tahmin yapmışlardır. Bu modelin oldukça başarılı olduğu sonucuna varmışlardır (Luciano *et al.* 2014).

Hou vd. (2014), dalgacık dönüşümü ve ARIMA yöntemlerini birlikte kullanarak hibrit bir tahmin modeli oluşturmuşlardır. Bu model ile tahminler sonucunda hata oranını %30 azalmışlardır (Hou *et al.* 2014).

Liu vd. (2014), bulanık mantık, yapay sinir ağları ve uzman sistemler yöntemlerini birlikte kullanarak üçlü bir hibrit model oluşturmuşlardır. Bu hibrit modeli güç sistemlerde kullanarak yük tahmininin yanı sıra frekans kontrolünde, trafo arızalarının tespitinde kullanmışlardır (Liu *et al.* 2014).

Xiaoboi vd. (2014), benzer gün yaklaşımı ve destek vektör makinalarını birlikte kullanarak hibrit bir model oluşturmuşlardır. Bu modelin yaygın olarak kullanılan diğer modellere göre daha başarılı olduğu sonucuna varmışlardır (Xiaoboi *et al.* 2014).

Torkzadeh vd. (2014), çoklu lineer regresyon ve korelasyon yöntemini birlikte kullanarak MATLAB programında hibrit bir tahmin modeli oluşturmuşlardır. Bu model ile orta dönemli yük tahmini yapmışlardır ve haftalık tahminlerde %3,68'lik, aylık tahminlerde %1,46'lık hata oranı yakalamışlardır (Torkzadeh *et al.* 2014).

Bonanno vd. (2014), dalgacık dönüşümü ve yapay sinir ağlarını birlikte kullanarak hibrit bir tahmin modeli oluşturmuşlardır. Bu modeli ile %7'lik hata oranı yakalamışlardır (Bonanno *et al.* 2014).

Ahmed vd. (2014), ARIMA ve yapay sinir ağlarını birlikte kullanarak oluşturdukları hibrit tahmin modeli ile kısa dönemli yük tahmini yapmaya çalışmışlardır. Oluşturdukları hibrit model ile, sadece yapay sinir ağları ile oluşturdukları modele göre daha başarılı bir sonuç elde etmişlerdir (Ahmed *et al.* 2014).

Moraes vd. (2014), zaman serileri ve bulanık mantık yöntemlerini birlikte kullanarak hibrit bir model oluşturmuşlardır. Elleriinde ki verilerin kısıtlı olmasına rağmen doğruluk oranı yüksek bir sonuca varmışlardır (Moraes *et al.* 2014).

Yang vd. (2013), yapay sinir ağlarını ve dalgacık dönüşümlerini ayrı ayrı kullanarak ve bu iki yöntemi birlikte kullanarak farklı modeller oluşturmuşlardır. Sadece yapay sinir ağları ile oluşturdukları modelde %2,96'lık, iki yöntemi de kullanarak oluşturdukları hibrit model ile %1,9'luk, hibrit modele hata düzeltme fonksiyonu uygulayarak oluşturdukları model ile de %0,72'lik hata oranına ulaşmışlardır (Yang *et al.* 2013).

Bakırtaş vd. (2000), ARMA yöntemini kullanarak tahmin modeli oluşturmuşlardır. Bu modelde GSMH'yi kullanarak enerji talebi ve enerji geliri arasındaki ilişkiden yola çıkarak talep tahmini yapmaya çalışmıştır (Bakırtaş *et al.* 2000).

Koo vd. (2013), SARIMA ve Holt-winters yöntemleriyle oluşturdukları modeller ile haftalık yük tahmini yapmaya çalışmışlardır. Holt-winters ile oluşturulan modelin daha iyi sonuç verdiği görmüşlerdir (Koo *et al.* 2013).

Fan ve Hyndman, genelleştirilmiş toplamsal model, yapay sinir ağları ve bunlarla oluşturduğu hibrit modeller de kısa dönemli tahminler yapmaya çalışmışlardır. Bu modellerden genelleştirilmiş toplamsal modelin daha başarılı olduğu sonucuna varmışlardır ve %1,68'lik hata oranına ulaşmışlardır (Fan and Hyndman 2012).

Dordonnat vd. (2008), regresyon ve Kalman filtreleri metotlarını kullanarak oluşturdukları model ile saatlik yük tahmini yapmaya çalışmışlardır. Bu modelde %1,39'luk hata oranına ulaşmışlardır (Dordonnat *et al.* 2008).

Topallı ve Erkmen, yapay sinir ağıları ve ARIMA yöntemlerini kullanarak oluşturduğu iki farklı ile kısa dönemli yük tahmini modellerini karşılaştırmıştır. Bu çalışmada yapay sinir ağlarının daha başarılı olduğu sonucuna varan Topallı ve Erkmen %1,60'lık hata oranına ulaşmıştır (Topallı ve Erkmen 2006).

Toker ve Korkmaz spectrum analiziyle oluşturduğu model ile İstanbul'un, 2009 yılının son 5 ayında yaptığı tahminde %2'lik hata oranına ulaşmıştır (Toker ve Korkmaz 2011).

Yalçınöz vd. (2002). yapay sinir ağıları ve hareketli ortalamalar yöntemleriyle iki farklı orta dönemli yük tahmin modeli oluşturmuştur. İki modelde başarılı sonuçlara ulaşan Yalçınöz ve arkadaşları yapay sinir ağlarıyla oluşturdukları modelin daha başarılı olduğu sonucuna varmışlardır (Yalçınöz *et al.* 2002).

Erkmen ve Özdoğan, kohonen algoritması, genetik algoritmalar ve yapay sinir ağıları yöntemlerini ele alarak, her yöntemle ayrı ayrı hibrit tahmin modelleri oluşturmuştur. Rastgele olarak seçtiği farklı 12 gün için farklı hata oranlarına ulaşmıştır. YSA modeli ile %2,76'lık, GA ve YSA ile oluşturduğu hibrit model ile %2,64'lük, Kohonen ve YSA ile oluşturduğu hibrit model ile %1,89'luk, Kohonen, GA ve YSA ile oluşturduğu üçlü hibrit model ile %0,96'lık hata oranlarına ulaşmışlardır (Erkmen ve Özdoğan 1997).

Topallı ve Erkmen, yapay sinir ağıları yöntemiyle öğrenmeye dayalı hibrit model ile kısa dönemli yük tahmini yapmaya çalışmışlardır. Türkiye'nin yük tahminin yapan Topallı ve Erkmen bu model ile 2000 yılı için %2,31'lik, 2001 yılı için %2,45'lik hata oranlarına ulaşmışlardır (Topallı ve Erkmen 2003a).

Erkmen ve Topallı, yapay sinir ağıları yöntemi kullanarak vektör, kohonen ile ayrı ayrı iki farklı hibrit modeller, bulanık mantık ile ayrı bir model ve YSA ile ayrı bir model olmak üzere dört farklı tahmin modeli oluşturmuştur. Bu çalışmada en başarılı modelin YSA ile oluşturduğu model olduğu sonucuna varmışlardır. Hafta içi günleri %1,72'lik, Cumartesi günleri için %1,75'lik ve Pazar günleri içinde %2,07'lik hata oranlarına ulaşmışlardır (Topallı ve Erkmen 2003b).

Papadakis vd. (2003), bulanık mantık ve genetik algoritmalar yöntemlerinden oluşturduğu hibrit kısa dönemli yük tahmin modelinde %1,76'lık orana ulaşmıştır (Papadakis *et al.* 2003).

1.2 Tezin Amacı

Bu çalışmada yük talep tahmin yöntemleri, tahmini etkileyecek parametreleri incelemek ve Matlab programında yapay sinir ağları yöntemini kullanarak kısa dönemli yük talep tahmini modeli oluşturma ve bu modeli test edip sonuçların analiz edilmesi amaçlanmıştır.



2. LİTERATÜR BİLGİLERİ

Tezin bu bölümünde ilk olarak talep tahmini konusu ele alınmıştır. Devamında tahmin yöntemleri incelenerek, bu tezin uygulamasında kullanılan tahmin yöntemi olan Yapay Sinir Ağları konusu detaylıca işlenmiştir.

2.1 Yük Talep Tahmini

Elektrik enerjisi piyasasının planlanması düzenlenmesinde, elektriğin üretiminden son kullanıcıya ulaşana kadar ki tüm maliyetleri en düşük seviyeye çekmek, güç sistemlerinin verimliliğini arttırmak, sistemin güvenilirliğini arttırmak ve elektrik enerjisinin en yüksek kalite ile kullanılması amaçlanır. Bu planlama ve düzenlemelerin en önemli adımlarından biri de gelecekte kullanılacak olan talep edilecek olan yükün yüksek doğruluk oranı ile tahminidir. Yapılacak tahminin süresinin uzaması, tahmindeki doğruluk oranını azaltarak ve belirsizliklere neden olur. Bu nedenle de talep tahmini zamanlara göre sınıflandırılır.

2.1.1 Yük Talep Tahmininin Zaman Göre Sınıflandırılması

Kısa Dönemli Tahminler: Saatlik veya Günlük Tahminler

Orta Dönemli Tahminler: Aylık Tahminler

Uzun Dönemli Tahminler: Yıllık Tahminler

2.1.1.1 Kısa Dönemli Yük Talep Tahmini

Kısa dönemli yük talep tahmini talep edilen yükün bir saatten bir haftaya kadar tahmini amaçlar. Sistemin düzenli çalışması açısından en önemli tahmin dönemi kısa dönemli tahmindir. Her saatte veya her yarım saatte ne kadarlık bir talep olacağı yüksek bir doğruluk oranı ile tahmin edilebilmeli ki güç sisteminin çalışması da bu oranda planlanmalıdır.

Güç sistemlerinde gün içerisinde sistemden talep edilen enerji sürekli olarak nonlineer

bir şekilde değişmektedir. Buna bağlı olarak da talebe göre sürekli olarak devreye girip çıkan generatör sayısı değişmektedir. Devreye girip çıkacak olan generatörlerin planlanması da kısa dönemli yük talep tahminine göre yapılır. Bu planlama sağlıklı bir şekilde yapılarak sistemin yük değişimi anlık olarak izlenerek müdahale etme şansı tanır. Kısa dönemli yük talep tahmini güç sisteminin yük – üretim dengesinin sağlanmasına büyük fayda sağlar. Böylece sisteme gereğinden fazla enerji verilmez veya verilen enerji yetersiz gelmez. Üretilen enerji üretildiği gibi tüketilir duruma gelir. Gerek sistemin verimi, güvenilirliği gerek maliyetleri düşürülmesi açısından yararlı planlama yapılmış, güç sistemi sağlıklı olarak kullanılmış olur.

2.1.1.2 Orta Dönemli Yük Talep Tahmini

Orta dönemli yük talep tahmini talep edilen yükün bir haftadan bir yıla kadar tahmini amaçlar. Orta dönemli tahminlere göre güç sistemlerinin periyodik bakımları planlanır. Kısa süre de devreye alınabilecek olan üretim santrallerin devreye alınmasıyla ilgili planlamalar yapılır.

2.1.1.3 Uzun Dönemli Yük Talep Tahmini

Uzun dönemli yük talep tahmini bir yıl ve daha fazla süreler için tahmini amaçlar. Uzun dönemli tahminlere göre eldeki üretim santrallerinin iletim dağıtım hatlarının gelecekteki talebi karşılayıp karşılayamayacağı kararı verilir. Verilen bu karara göre de yeni üretim santralleri, bu santrallerde üretimi sağlayabilmek adına kaynaklar (kömür, su vs), bu kaynaklar üretimde kullanıma hazır hale gelmesi için tesis planlamaları yapılır. İletim dağıtım hatları için nerelerde eklemeler yapılacağı, nerelerde yeni hatlar kurulacağının planlamaları yapıp bu güç sistemleri talebe göre devreye alınır.

Uzun dönemli tahminde, sürenin uzun olmasından dolayı tahminin doğruluk oranının değişebileceği, yapılan planlamaların yetersiz kalabileceği konusu gözden kaçırılmamalıdır. Planlamalar yetersiz kaldığında oluşan belirsizlik ciddi anlamda zararlara yol açabilir. Doğruluk oranını arttırmak sistemdeki kararlılığı yakalamak için uzun dönemli tahminin sürekli olarak güncellemesi gerekir.

2.1.2 Yüğü Etkileyen Faktörler

Sistemden çekilen yük, zaman dilimine ve talep eden yerleşim yerine göre değişmektedir. Pala, 1998 yılında Elektrik Sistemlerinde Bölgesel Yüğü Tahmini adlı çalışmasında yükleri talep edilen yerleşim yerlerine göre; meskenler, ticarethaneler, sanayi ve diğerleri olmak üzere 4'e ayırmıştır (Pala 1998). Bilge ise herhangi bir zamanda sistemin yükünü, dört ayrı bileşene ayırmıştır (Bilge).

$$Y = Y_n + Y_w + Y_s + Y_r \quad (2.1)$$

Bu formülde

Y :sistemdeki toplam yüğü,

Y_n :yükün normal bölümü, yani yıl boyunca görülen her gün için genelleşmiş yüğü verileri setini,

Y_w :yılın mevsimine bağılı olarak yükün hava durumuna göre değişen değerleri,

Y_s :genelleşmiş yüğü tipinden farklı şekilde sapmaya götüren yüğü değerini,

Y_r :rastlantısal olarak ortaya çıkan, daha önceden öngörüleemeyen kısmı, ifade etmektedir.


Elektrik piyasasında, sistem çekilen yükün elektriğın fiyatlandırılmasından da etkilenmektedir. Elektrik enerjisi depolanamadığından, üretildiğı gibi tüketilmesi gerektiğinden, iletim ve dağıtım hatlarının kapasiteleri sınırlı olduğundan elektrik fiyatları yere ve zamana göre değişmektedir. Bundan dolayı sistemden çekilen yüğü etkileyen faktörler ile fiyat arasında da şu ilişki vardır. Yani,

$$Y = f(\text{gün, hava, özel olay, fiyat, rastlantısallık})$$

Burada f fonksiyonunda ki her bileşen nonlineer olduğundan f fonksiyonu da nonlineer

bir fonksiyondur. Bu nedenle talep edilecek yükün tahminini yapmak oldukça karışık bir sorun haline getirmektedir (Chen *et al.* 2001).

Bu çalışmada kullanılacak olan Urla bölgesinin yük veri tabanının ait, örneğin 1 Ocak 2013 tarihinden 7 Ocak 2013 tarihine kadar olan yük karakteristiği aşağıdaki şekil 2.1’de ki grafiği oluşturmaktadır.




Şekil 2.1 Urla Bölgesine Ait Örnek Mahallenin Bir Haftalık Yüğü.

Yukarıda ki grafikte pazartesi gününden pazara gününe kadar bir haftalık yük karakteristiği gösterilmektedir. Grafik ritim açısından incelendiğinde ilk beş ritim birbirine çok yakınken, son iki ritimde birbirine yakındır. İlk beş günlük ritim yani hafta içi çekilen güç hafta sonu çekilen güce göre az olduğu gözlemlenmektedir. Urla bölgesinin tatil yeri olmasından dolayı sosyal aktivitelerinde hafta sonlarında arttığı göz önüne alındığında, ritimlerin hafta sonlarında arttığından kaynaklandığı sonucuna varılmaktadır.


Günlük ritimlerin oluşmasının nedeni ise insanların gün içerisindeki ortak davranışlarından kaynaklanmaktadır. Yani insanların büyük çoğunluğu 00:00 gibi uyuduğundan çekilen güç, uyku saatlerinde en düşük seviyeye inmektedir. İşyerlerinin büyük çoğunluğu gündüz saatlerinde çalıştığından gündüz saatlerinde çekilen güç bu

saatlerde artmaktadır. Günlük ritimler mevsimlere göre değişme gösterir. Bunun nedeni ise hava sıcaklıklarının değişmesinden kaynaklanmaktadır.


Şekil 2.2, 2.3, 2.4 ve 2.5’de dört farklı mevsimdeki ayların 8. gününe ait yük değerleri verilmiştir.




Şekil 2.2 Örnek Mahalleye Ait Kış Ayındaki Yük Grafiği.



Şekil 2.3 Örnek Mahalleye Ait İlkbahar Ayındaki Yük Grafiği.




Şekil 2.4 Örnek Mahalleye Ait Yaz Ayındaki Yük Grafiği.



Şekil 2.5 Örnek Mahalleye Ait Sonbahar Ayındaki Yük Grafiği.


Shi vd. (2014), Yük Profili ve Hava Durumu İlişkisi Analizi adlı çalışmalarında yük değişiminde hava şartlarının büyük bir etkisi olduğu sonucuna varmışlardır (Shi *et al.* 2014). Yük-sıcaklık ve yük-nem grafikleri incelendiğinde sıcaklığın yüke doğrudan etkisi olduğu net bir şekilde söylenebilirken, nemin yüke etkisinin sıcaklık kadar etkisi olduğu tam anlamıyla söylenemez. Çalışmamızda kullanacağımız veri tabanına ait örnek olarak Ocak ayına ait yük değişimi, sıcaklık ve nem oranı grafikleri şekil 2.6, 2.7 ve 2.8’de verilmiştir.



Şekil 2.6 Örnek Mahalleye Ait Aylık Yük Değişimi.



Şekil 2.7 Örnek Mahalleye Ait Aylık Sıcaklık Değişimi.



Şekil 2.8 Örnek Mahalleye Ait Aylık Nem Değişimi.

2.2 TAHMİN YÖNTEMLERİ

Gelişen teknolojiyle sanayileşmenin artması, güç sistemlerinde sağlıklı, güvenilir planlamalar ve düzenlemeler yapılmasını zorunlu hale getirmektedir. Bunun içinde talep tahmininin de doğru bir şekilde yapılması zorunlu hale gelmektedir. Bunun yanı sıra elektrik piyasalarında fiyatlandırma talebe göre yapılmaktadır. Talebin tahmini düşük olursa fiyatlandırma artabilir, mevcut güç sistemleri yetersiz kalabileceğinden elektrik kesintileri yaşanabilir. Kesintiler ekonomiyi doğrudan etkileyeceğinden refah seviyesi artışı sağlanamayabilir. Talebin tahmini yüksek olursa, buna göre düzenleme yapılan, sayısı arttırılan güç sistemlerinin kapasitelerindeki fazlalıklar, yatırım bekleyen diğer alanlara tahsis edilememesinden dolayı kaynak dağılımında yanlışlıklara, kaynak israflarına neden olabilir. Yine refah seviyesinde artış sağlanamayabilir. Bu ekonomik krizleri yaşamamak içinde talep tahminin doğruluk oranının yüksek olması en önemli husustur. Talep tahmininin bu derece önemli olması nedeniyle de bu konuda yapılan çalışmalar artmıştır.

Bu çalışmada Tahmin yöntemleri; analitik yöntemler, yapay zekâ yöntemleri ve hibrit yöntemler olarak 3 farklı kategoride ele alınmıştır.



Şekil 2.9 Talep Tahmin Yöntemleri.

2.2.1 Analitik Yöntemler

2.2.1.1 Regresyon Analizi

Regresyon analizi istatistiksel bir yöntemdir. Regresyon analizi modellemesi istatistik yöntem kullanarak eğri uydurmayla yapılır. Aralarında sebep sonuç ilişkisine dayalı olarak değişkenlerin arasında oluşan bağıntıyı inceleyip belirleyerek, bu bağıntıyı kullanıp tahmin ettiren yönteme Regresyon Analizi adı verilir. Regresyon analizi 2 çeşittir. Değişken sayısı bir tane ise basit regresyon adını alır. Değişken sayısı birden fazla ise çok regresyon adını alır. Bunların yanı sıra en az ikinci dereceden denklemlerle çözümü mümkün olan sistemlerde de polinom regresyon analizi modeli oluşturulur.

Regresyon analizi ile bir değişkenin diğer değişkenlere karşı gösterdiği tepkiler, oluşturulan devamlı fonksiyonlar ile belirtilir. Bu şekilde değişkenler arasındaki ilişki belirlenip hatası belirlenir. Tahmini yapılacak olan değişkenin farklı durumlara göre diğer değişkenler aracılığıyla tahmin işlemi yapılır.

Regresyon analizinde tahminin doğruluk oranı değişkenler arası bağa bağlıdır. Bağ ne kadar kuvvetliyse tahminin doğruluk oranı da aynı oranda yüksektir. Bağ zayıfladıkça tahminin doğruluk oranı da azalacaktır.

Regresyon analizinin olumsuz tarafı, yük talebi ve etkili faktörler arasında ki karmaşık bağ sebebiyle doğruluk oranı yüksek bir model oluşturmak oldukça zordur.


- Basit Regresyon

İki değişken arasında ki bağın doğrusal olarak arttığı düşünülen tahmin değerine ulaşma yöntemidir.

$$y = \beta_0 + \beta_1 x + \varepsilon \quad (2.2)$$

formülünde ki gibi doğrusal bir durum düşünülüyorsa, β_0 ve β_1 parametrelerinin tahmin edilmesi gerekir. Bu değerler tahmin edildiğinde bağımsız değişken kullanarak bağımlı

değişkenin alacağı değer tahmin edilir. Bu modele bağımsız değişkenli doğrusal regresyon modeli denir. β_0 ve β_1 parametreleri modelin bilinmeyen parametreleri iken ε ise hata terimidir (Ünver ve Gangam 2008).




Şekil 2.10 Doğrusal İlişki.

Eğer model şekil 2.11'deki gibi noktalar doğrusal olarak hareket etmiyorsa yeni bir model oluşturmak gerekir. Bu eğri için denklemin aşağıdaki gibi oluşturulması yararlı olacaktır.

$$y = \beta_0 + \beta_1 x + \beta_2 x^2 + \varepsilon \quad (2.3)$$

Bu modele bağımsız değişkenli doğrusal olmayan regresyon veya polinom regresyonda denilebilir. β_0 , β_1 ve β_2 parametreleri modelin bilinmeyen parametreleri iken, ε ise hata terimidir. Bu modelin grafiği de şekil 2.11'da verilmiştir(Ünver ve Gangam 2009).




Şekil 2.11 Doğrusal Olmayan İlişki.

- Çoklu Regresyon

Birden fazla değişkenin bağlarının doğrusal olarak arttığı düşünülen ancak x değişkeninin farklı değerler alabileceği durumlarda kullanılan yöntem doğrusal çoklu regresyon analizi denir.

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon \quad (2.4)$$

şeklinde formülize edilebilir. y, $x_1, x_2, \dots, x_k$ gözlenebilen değerler, $\beta_0, \beta_1, \dots, \beta_k$ bilinmeyen parametrelerdir. Bu modelin grafiği de şekil 2.12’de verilmiştir (Ünver ve Gangam 2008).



Şekil 2.12 Çoklu Regresyon.

2.2.1.2 En Küçük Kareler Yöntemi

En küçük kareler yöntemi, gerçek değerler ile tahmin değerleri arasındaki hataların karelerini minimuma çekerek değişkenlerle arasında fonksiyon oluşturulan modeldir (Chapra and Canale 2009).

Regresyon denkleminde kullanılan β_0 ve β_1 parametrelerinden elde edilen kestirimleri β_0 ve β_1 olarak kabul edildiğinde, tek değişkenli regresyon doğrusunun denklemi (2.5)’de gösterilmiştir.

$$Y_i = \beta_0 + \beta_1 x_{1i} \quad (2.5)$$

Bu modelde toplam hataların karelerinin toplamını en küçük değerde tutmak amaçlanır.

Hata terimlerinin formülü (2.6)'de verilmiştir.

$$\varepsilon_i = Y_i - \hat{Y}_i \quad (2.6)$$

(2.6)'da ki formülle elde edilen hata terimleri hem negatif hem de pozitif değerlere sahip olduğundan hatalar toplamı 0 olur.

En küçük kareler yönteminde β_0 ve β_1 farkını en küçük yapacak olan değeri bulmak için kullanılacak olan formül (2.7)'de verilmiştir.

$$\sum_{i=1}^n \varepsilon_i^2 \quad (2.7)$$

Burada tahmine ulaşabilmek için β_0 ve β_1 'ye göre türevler alınır ve 0'a eşitlenir (2.8). Bu formüllerden gerekli çözümler yapıldığında β_0 ve β_1 değerlerinin bulunacağı formüller elde edilir (2.9 ve 2.10).

$$\sum_{i=1}^n (Y_i - (\beta_0 + \beta_1 x_{1i}))^2 = L \quad (2.8)$$

$$\sum_{i=1}^n Y_i = \beta_0 n + \beta_1 \sum_{i=1}^n x_{1i} \quad (2.9)$$

$$\sum_{i=1}^n x_{1i} Y_i = \beta_0 \sum_{i=1}^n x_{1i} + \beta_1 \sum_{i=1}^n x_{1i}^2 \quad (2.10)$$

En küçük kareler katsayısının formülü ise (2.11)'de verilmiştir.

$$EKK^2 = \frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (2.11)$$

2.2.1.3 Benzer Gün Yaklaşımı

Bu tahmin yöntemi, geçmiş dönemlere ait verilerde, tahmini yapılacak olan günün şartlarına benzer günün aranmasıdır. Bu yöntem tek başına bir tahmin modeli değildir. Ancak tahminde kullanılacak veri seti seçiminde kullanılır (Chen *et al.* 2010). Benzer özellikler sıcaklık, nem, haftanın günleri, resmi tatil günü, dini tatil günü gibi birçok değişkeni vardır. Bu tahminin doğruluk oranını arttırmak için geçmiş dönemlerdeki benzer gün sayısını arttırmak gerekir.

2.2.1.4 Zaman Serileri Analizi

Zaman Serileri, bir değişkenin belirli bir süre içerisinde elde edilen sonuç değerlerini içeren serilerdir. Geçmiş dönemde elde edilen istatistiksel verilerin meydana geliş zamanına göre sıralanarak elde edilirler. Bu sıralama eşit zaman aralıklarında analiz yapılarak oluşturulur. Bu nedenle zaman serileri yöntemi geçmişteki verilerin değişimlerine dayanmaktadır.

Zaman serilerinde dalgalanmalar bulunmaktadır. Bunların başlıca nedenleri olarak trend, devresel farklılıklar, mevsimlik farklılıklar, rastlantısal farklılıklar gösterilebilir.

Trend, belirli bir süre boyunca zaman serisinin belirli olarak gösterdiği davranıştır. Doğrusal veya eğrisel olabilir, önemli olan istikrarlı olmasıdır.

Devresel farklılıklar, trend doğrusu veya eğrisi boyunca olan dalgalanmalardır.

Mevsimsel farklılıklar, bir yıllık dönemde oluşan düzenli iniş veya çıkışlara denir. Zaman serisi yıllar üzerinden yapılmışsa mevsimlik dalgalanmalar gözlemlenemez.

Rastlantısal farklılıklar ise genel olarak daha önceden tahmin edilemeyen öngörülemeyen değişimlerdir. Trend, devresel ve mevsimsel değişimler zaman serileri ile hesaplanabilirken, rastlantısal değişimler hesaplanamaz (Spiegel 1981).

Zaman serileri analizlerinin Box-Jenkins Modelleri olarak dört modeli vardır. Bunlar AR, MA, ARMA ve ARIMA modelleridir. Box-Jenkins modelleri doğruluk oranı yüksek fakat bir o kadarda oluşturulması zor modellerdir.

Zaman serisi modeli oluşturulmasında ilk aşama elde edilen verilerden tahmine yönelik modelleri oluşturulur. İkinci aşama olarak eldeki verilerin özellikleri incelenerek, ilk aşamada oluşturulan modellerden uygun olanlar seçilir. Uygun modellerde belirlenen modelin katsayıları tahmin edilmeye çalışılır. Sonrasında ise veri setleri ve tahmin edilen katsayılarla modeller arasında uygunluk testi yapılır. Uygunluk testi başarısız olursa yeni modeller oluşturularak uygun modele ulaşılmaya çalışılır.

- AR(Autoregressive)

AR modelinde geçmişteki verilerin lineer olarak değiştiği düşünülen durumlarda kullanılır.

$$y = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t \quad (2.12)$$

Bu denklemde

t : gözlem yapılan anı

y_t : t anında gözlemlenen yük değerini

ϕ_t : t anındaki sabit değeri

ε_t : hata değişkenini ifade eder.

- MA(Moving Average)

MA modeli hareketli ortalamalar olarak adlandırılır. Geçmişteki hata değerlerinin şimdiki hata değerlerini etkilediği düşünülen durumlarda kullanılır.

$$y = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (2.13)$$

Bu denklemde

t : gözlem yapılan anı

θ_t : t anındaki sabit değeri

y : tahmini yük değeri

ε_t : hata değişkenini ifade eder.

Bu denkleme q mertebesinde hareketli ortalama modeli denir. MA(q) ile gösterilir.

- ARMA(Autoregressive Moving Average)

AR ve MA modellerinin birleştirilmesiyle oluşturulur. Hem güncel hem de geçmişteki veri ve hatalar bakımından lineer olarak arttığı düşünülen durumlarda kullanılır. ARMA(p,q) ile gösterilir. Denklemi şu şekilde oluşturulur;

$$y = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (2.14)$$

- ARIMA(Autoregressive Integrated Moving Average)

AR, MA ve ARMA modellerinin birleştirilmesiyle oluşturulur. Bu modeldeki I, zaman serisindeki trendi ifade eder. ARMA modeli, AR ve MA modelini birleştirip durağan olmayan durumları durağanlaştırarak ARIMA modelinde birleştirilir (Çevik ve Yürekli 2013).


2.2.1.5 Wavelet Dalgacık Dönüşümü

Dalgacık dönüşümü, frekans domeninde kullanılan bir yöntemdir. Zaman domenindeki serileri frekans domenine çevirmek için dört yöntem vardır. En çok kullanılan yöntem Fourier Dönüşümüdür. Diğerleri ise Wigner, Hilbert ve Radon dönüşümleridir.

Fourier dönüşümüyle bir zaman serisinin farklı zamanlardaki frekanslarını hesaplayarak frekans domenine dönüştürülmesini sağlar. Ele alınan sinyalin frekansı durağan ise Fourier dönüşümü, sinyallerin analizinde yeterli olacaktır. Söz konusu sinyalin frekansı durağan olmayan bir durumda ise sinyali analiz etmek için Ayırık Fourier Dönüşümü geliştirilmiştir (Yılmaz ve Bozkurt 2013).

Fourier dönüşümünün katsayılarını hesaplamak içinse Sürekli Dalgacık Dönüşümü geliştirilmiştir. Bu yöntemle, bir sinyal bileşenlerine ayrılabilir (Abbak 2007).

Şekil 2.13’de Fourier dönüşümü ile sinyalin analiz edilmesi gösterilmiştir.



Şekil 2.13 Fourier Dönüşümü.

2.2.2 Yapay Zekâ Yöntemleri

Yapay zekâ yöntemleri, insan zekâsını örnek alarak algılama, öğrenme, düşünme, çıkarımda bulunma, mantık yürütme ve sonuç çıkarma işlevlerini yapabilmeyi amaçlar. Aynı zamanda sonuçlara göre karşı davranışlar sergileyebilmelidir.

Bilgisayar destekli ve hızlı işletim sistemi olduklarından dolayı, tahmin modeli oluşturmada en sık kullanılan yöntemlerdir.

2.2.2.1 Genetik Algoritmalar

Genetik Algoritmalar yöntemi, popülasyon temelli sezgisel bir optimizasyon yöntemidir. İteratif ve stokastik bir yöntemdir.

Genetik Algoritmalar, fonksiyonları bir araya getirerek analizi yapar ve çözümler üreterek çözüm kümeleri oluşturur. Bu çözüm kümeleriyle popülasyon içinde uygunluk fonksiyonlarıyla uygun çözüm yöntemleri belirlenir (Islam *et al.* 2014b).

Genellikle uzun dönemli yük talep tahmininde kullanılırlar.

2.2.2.2 Bulanık Mantık

Bulanık Mantık, belirsiz bilgilerin gösterilmesinde işlenmesinde kullanılan yöntemdir. İnsanların deneyimlerinden faydalanarak makinalara matematiksel ifade aktarılmasına dayanır. Bulanık mantıkta, klasik mantıktaki gibi kesin ifadeler, net değerler yoktur.


Klasik mantıkta doğru veya yanlış, 0 veya 1 olarak sonuçlar üretilirken, bulanık mantıkta ifadeler büyük, küçük, uzun, kısa gibi yaklaşık ifadelerdir. Sonuç değeri için 0 ile 1 arasında sonsuz değer üretilir.

Bulanık Mantıkta tecrübe ile öğrenme işlevinin kolayca modellenebilmesinden dolayı, belirsiz bilgiler matematiksel olarak modellenabilir.

Bulanık Mantığın işleyişi; bulanıklaştırma, bulanık kural tabanı oluşturma ve berraklaştırmadan oluşur.

Bu yöntemde doğruluk oranı yüksek sonuçlara ulaşabilmek için bulanık kural tabanının ayrıntılı olarak hazırlanmış olması gerekir (Khosravi and Nahavandi 2014).

Şekil 2.13 (a)'da bulanık mantığa göre parametrelerin alabileceği değerler, şekil 2.13 (b)'de klasik mantığa göre parametrelerin alabileceği değerler gösterilmiştir.



Şekil 2.13 a) Bulanık Mantık Grafiği b) Klasik Mantık Grafiği.

Bulanıklaştırma aşamasında, giriş verilerini ve fonksiyonları kullanarak sözel değerlerden oluşan bulanık ifadelerle dönüştürülür. Bulanık kural tabanı oluşturma aşamasında ise kontrol yönetimi “eğer-ise” kuralları şeklinde ifade ederek bulanık kurallar kümesi oluşturulur. Bulanıklaştırıcı çıkışını kural tabanındaki bulanık kurallarla eşleştirerek bulanık kontrolün nasıl yapılacağına ilişkin verilecek tepkiyi belirler. Berraklaştırma aşamasında da, tepkiyi kontrol edilen sisteme uygulayabilmek için sayısal kontrol işareti oluşturulur (Topallı *et al.* 2006).

2.2.2.3 Destek Vektör Makinaları

Destek Vektör Makinaları sınıflandırma ve regresyon amaçlı kullanılmaktadır. Destek Vektör Makinaları veri kümelerini sınıflandırmada en başarılı yöntemdir. Bu sınıflandırmaya göre iki sınıf vektörü oluşturarak, bu iki sınıf arası mesafenin en yüksek olduğu düzlemi bulmayı amaçlar.

Destek Vektör Makinalarının iyi bir avantaj olarak sayılacak özelliği; yapısal risk minimizasyonu niteliğinde çalışmasıdır. Destek Vektör Makinalarının temel maddelerinden biri ise, eğitim setindeki bütün örneklemelerin bağımsız ve benzerlikler içererek dağılmış olmasıdır (Song *et al.* 2002).

Destek Vektör Makinalarında veriler doğrusal olarak ayrılabilir veya doğrusal olarak ayrılamayacak yapılarda olabilir. Doğrusal olarak ayrılma durumunda, iki farklı değere sahip veriler direkt olarak aşırı düzlem ile ayrılabilirler. Destek Vektör Makinalarının burada ki amacı aşırı düzlemin iki farklı değerde bulunan örnek grubuna eşit mesafede bulunmasını sağlamaktır. Doğrusal olarak ayrılamama durumunda, doğrusal sınıflandırıcılar yerine doğrusal olmayan sınıflandırıcılar kullanılabilir (Var ve Türkay 2014).

2.2.2.4 Uzman Sistemler

Uzman Sistemler, herhangi bir alanda sadece o alana ait olan bilgilerle oluşturulmuş ve sorunlara, o alanda uzman olan birinin çözüm bulduğu gibi çözüm bulan yapay zekâ modelidir (Rahman 1993).

Uzman Sistemlerde seri veri işleme mantığı vardır. Girdi verisi olarak sözel bilgiler kullanılır. Sezgisel algoritmaya sahip Uzman sistemlerde hesaplamalar sembolik olarak yapılır. Uzman Sistemler yönteminin çıktıları tündengelemlidir.

Uzman Sistemler, modern bilgi sistemleri olmasına karşı karar verme kurallarında ve problemlerde yüksek bir performans göstermektedir. Bu yöntem genellikle bulanık mantık veya yapay sinir ağları gibi yöntemlerle birlikte kullanılarak hibrit model olarak

kullanılmaktadır. Uzman Sistemler, sađlık sektöründen endüstriye, ekonomik analizlerden askeri uygulamalara kadar birçok alanda kullanılmaktadır (Şener 2005).

2.2.2.5 Yapay Sinir Ağları

Bu tez çalışmasında Yapay Sinir Ağları yöntemi kullanıldığından üçüncü bölümde detaylı olarak incelenecektir.

2.2.3 Hibrit Yöntemler

Hibrit Yöntemleri tek başına bir yöntem olmayıp, önceki bölümde anlatılan yöntemlerden iki veya daha fazlasının birlikte kullanılarak oluşturulan yöntemlerdir.

3. MATERİYAL ve METOT

3.1 Yapay Sinir Ağları

Yapay Sinir Ağları, en çok başvurulan tahmin yöntemlerinden biridir. Yapay Sinir Ağları örüntülü girdi verileriyle paralel veri işlemeye sahiptir. Algoritmaları istatistiksel olan Yapay Sinir Ağlarının hesaplamaları sayısal olarak yapılarak tümevarımsal çıktılar elde edilir. Yapay Sinir Ağlarının modellenmesinde, girdi ve çıktı değerleri için ön bilgiye ihtiyaç duyulmaz.

Yapay Sinir Ağları yöntemi, insan beyninin sinir sisteminden yola çıkarak bilgisayar ortamında geliştirilerek ortaya çıkan bir yöntemdir.

Yapay Sinir Ağı, elektronik bileşenler ile tanımlanarak bilgisayar benzetimi yapılır. Yapay Sinir Ağları, öğrenme aşamasında başarılı hesaplamalar yapmaktadır. Yapay sinir ağı, performans anlamında en yüksek değere ulaşmak için, sinir hücreleriyle arasında güçlü bir bağlantı vardır.

Yapay Sinir Ağları, insan sinir hücresinin işleyişinden yola çıkarak aşağıdaki maddeleri temel alır:

- 1- Bilgi işleme süreci nöronlardan meydana gelir.
- 2- Sinyaller, nöronlar arasındaki bağlantılar ile iletilirler.
- 3- Nöronlar arasındaki her bir bağlantı bir ağırlık değerine sahiptir.
- 4- Her bir nöronun net çıkıntısı, net girdisinin bir aktivasyon fonksiyonundan geçirilmesiyle elde edilir (Hamzaçebi 2011b).


3.1.1 Biyolojik Sinir Sistemi ve Sinir Hücresi

Biyolojik sinir sistemi, merkezinde sürekli olarak bilgi toplayıp yorumlayarak probleme göre uygun bir karar üretir. Sinir sisteminin blok diyagramı şekil 3.1’de gösterilmiştir. Sinir sistemi, alıcı sinirler, beyin ve tepki sinirlerinden oluşan 3 katmanlı bir sistemdir. Alıcı sinirler, algıladığı uyarıları elektriksel sinyal olarak beyne iletir. Tepki sinirleri ise, beynin ürettiği elektriksel tepkileri gerekli çıktı tepkilerine dönüştürür.



Şekil 3.1 Sinir Sistemi Blok Diyagramı.


Sinir sisteminde, hücre gövdesi, dendrit ve akson olmak üzere 3 bileşen bulunmaktadır. Sinir hücresinin blok diyagramı şekil 3.2’de verilmiştir. Dendritler, diğer hücrelerden aldığı bilgileri hücre gövdesine iletirler. Aksonlar ise bilgiyi hücreden dışarı çıkaran yoldur. Aksonların bitimi ince yollara ayrılarak diğer hücrelerin dendritleriyle birleşirler. Aksonlarla dendritler arasındaki bu bağlantıya sinaps denir. Hücreye gelen bilgi değerleri belirli bir seviyeye geldiğinde, hücre bir tepki verir. Hücrenin bu tepkisinin etkisini sinaps belirler.



Şekil 3.2 İnsan Sinir Hücresi.

3.1.2 Yapay Sinir Hücresi

Yapay Sinir Hücresi, insan sinir hücresi örnek alınarak oluşturulmuştur. İnsan sinir hücrelerine göre daha basit yapıdadırlar.



Şekil 3.3 Yapay Sinir Hücresi.

Yapay Sinir Hücresindeki x girişleri, w ağırlıkları, b kutuplama değerini, v aktivasyon potansiyelini, y ise çıkışları ifade eder. YSH'nin blok diyagramı şekil 3.3'de verilmiştir.

Çizelge 3.1'de insan sinir sisteminin bölümlerinin görev olarak YSH'deki hangi birime denk geldiği gösterilmiştir.

Çizelge 3.1 Biyolojik Sinir Sistemi ve Yapay Sinir Ağı Karşılaştırması (Bakırtaş *et al.* 2000).

Biyolojik Sinir Sistemi	Yapay Sinir Ağı
Nöron	İşlemci Elemanı
Dendrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Yapay Nöron Çıkışı
Sinapslar	Ağırlıklar


Girişler: Girişler diğer sinirlerden alınan verileri sinir ağına getirirler.

Ağırlıklar: Girişler aracılığıyla alınan verilerin sinire etkisini belirleyen katsayılardır.

Katsayıların artması yapay sinir hücresine olan bağlantıyı güçlendirir.

Toplama Fonksiyonu: Girişler kendi ağırlıkları ve kutuplama değeri ile çarpılarak toplanır. Toplama fonksiyonu sonunda veriler aktivasyon fonksiyonuna gönderilir.

Aktivasyon Fonksiyonu: Yapay sinir hücresinin son aşamasıdır ve girdi çıktı değerleri arası eğrisel eşleşmeyi sağlar. En yaygın aktivasyon fonksiyonları logaritmik sigmoid, tanjant sigmoid ve doğrusal fonksiyonlardır. Bu fonksiyonların grafikleri şekil 3.4’de gösterilmiştir.



Şekil 3.4 Aktivasyon Fonksiyonları (Doğan ve Çıngı 2010).

Logaritmik sigmoid fonksiyonu, lineer ve lineer olmayan kesin artan bir fonksiyon olarak tanımlanır. Tanjant sigmoid fonksiyonu, doğrusal olmayan ve türevi alınabilir bir fonksiyondur. Doğrusal fonksiyon ise giriş değerini direkt çıkışa aktarır.

Bu çalışmada aktivasyon fonksiyonu olarak logaritmik sigmoid fonksiyonu kullanılmıştır.

3.1.3 Yapay Sinir Ağlarının Özellikleri

Yapay Sinir Ağları, paralel dağılmış yapısıyla doğrusal olmayan yapıları modelleyebilir. Öğrenme, genelleme ve hata toleransı özellikleriyle öğrenme aşamasında karşılaşılmayan girdi değerlerine rağmen hesaplama yapabilir ve bilgi işleyebilir.

3.1.3.1 Doğrusal Olmama

YSA'yı oluşturan YSH'de kullanılan YSH doğrusal değildir. Ağ için kullanılan aktivasyon fonksiyonları sayesinde doğrusal veya doğrusal olmayan modellemeler oluşturulabilir. Günlük hayatta birçok sorunun doğrusal olmadığı göz önünde

bulundurulduğunda YSA ile birçok soruna çözüm bulunabilir.

3.1.3.2 Öğrenme

İnsan sisteminden yola çıkılarak oluşturulan YSA, kendisinden istenilen çözümü bulabilmek için girdiler arası ilişkiyi belirler. Bu ilişkinin belirlenmesi öğrenme olarak adlandırılır. Öğrenme işlemi, YSA'nın YSH'ler arası bağlantıların ağırlıklarının belirlenmesi işlemidir.

3.1.3.3 Genelleme

YSA'nın çözümünü bulunduğu problemlere ilişkin, öğrenme işlemi sırasında yeni girdi değerleri içinde kabul edilebilir seviyede sonuç üretebilmesi YSA'nın genelleme özelliğidir.

3.1.3.4 Uyarlanabilirlik

YSA'nın çözümünü bulduğu problemlerdeki değişiklikler için YSA, değişen probleme de uyarlanabilir.

3.1.3.5 Hata Toleransı

YSA eğitimi sırasında oluşan gürültü etkisi denilen sistem hataları oluşabilir. Bu etkiler YSA'lar paralel dağılmış YSH'leri arasındaki ağırlıklara dengeli olarak yayıldığından hata etkileri azaltılmış olur.


3.1.4 Yapay Sinir Ağlarının Sınıflandırılması

Yapay Sinir Ağları, besleme tipi, öğrenme yöntemi, katman sayısı ve yapı olarak dört farklı kategoride sınıflandırılmaktadır. Besleme tipine göre, ileri ve geri beslemeli, öğrenme yöntemine göre, öğretmeli, öğretmesiz ve destekleyici, katman sayısına göre tek katmanlı ve çok katmanlı, yapı olarak otoasosyatif ve heteroasosyatif olarak ayrılmaktadır.

3.1.4.1 Besleme Tipine Göre Yapay Sinir Ağları

- İleri Beslemeli YSA'lar


İleri beslemeli YSA'larda nöronlar giriş biriminden çıkış birimine doğru ilerler. Tek katmanlı veya çok katmanlı olabilirler. Giriş katmanına gelen veri, giriş katmanında herhangi bir işlemten geçmeden geldiği gibi orta katmandaki hücrelere geçer. Veri bu katmanda işlenir ve çıkışa gönderilir. Şekil 3.5'de ileri beslemeli YSA'nın blok diyagramı verilmiştir.



Şekil 3.5 İleri Beslemeli YSA Blok Diyagramı.

- Geri Beslemeli YSA'lar

Geri beslemeli YSA'larda nöronlar doğrudan kendinden sonra gelen katmana girdi olarak gönderilebildiği gibi kendinden önceki katmana da girdi olarak gönderilebilir. Gösterdikleri bu karakteristikten dolayı doğrusal olmayan dinamik bir yapıya sahiptirler. Şekil 3.6'da geri beslemeli YSA'nın blok diyagramı verilmiştir.



Şekil 3.6 Geri Beslemeli YSA Blok Diyagramı.

3.1.4.2 Öğrenme Yöntemleri Göre YSA'lar

Öğrenme, YSA'ların en temel özelliklerinden biridir. YSA'da öğrenme işlemi ağırlıkların değiştirilmesiyle yapılmaktadır. YSA'da öğrenme, ağırlıkların ayarlanması sürecidir. Öğrenmenin amacı yeni girdilerin hangi sınıfa ait olduğuna karar verebilir.

- Öğretmeli Öğrenme

Ağ eğitiminde girdi değerlerinin ağa tanıtılmasının yanı sıra çıktı olarak istenen değerlerinde tanıtılabildiği öğrenme yöntemidir. Ağ verilen girdi değerlerini işleyerek çıktı değerlerini oluşturur. Bu çıktı değerleri ile ağa tanıtılan çıktı değerleri karşılaştırılarak bir hata değeri elde edilir. Hata değeri kabul edilebilir bir seviyeye inene kadar, ağ ağırlıklarını güncelleyerek tekrar çıktı üretir.

- Öğretmesiz Öğrenme

Öğretmesiz öğrenmede ağa sadece girdi değerleri tanıtılabilir. Çıktı değerleri tanıtılamaz. Giriş değerlerine göre ağ, değerleri kendi aralarında sınıflandırarak kendi kurallarını oluşturup ağırlıklarını belirler.

- Destekleyici Öğrenme

Destekleyici öğrenmede çıktı değerleri yine ağa tanıtılmaz. Girdi değerine karşılık ağın ürettiği çıktı değeri için iyi veya kötü olduğu, olumlu veya olumsuz olduğu konusunda karar verir. Bu karara göre de çıktıları belirli değer aralıklarında gruplar.

3.1.5 Yapay Sinir Ağlarının Uygulama Alanları

Geçmişten günümüze birçok alanda birçok probleme YSA'lar ile çözüm bulunmuştur. Hemen her alanda kullanılan YSA'ları sınıflandırmak oldukça zordur. Genel olarak sınıflandırılması aşağıda ki 4 adet olarak sınıflandırılabilir.

3.1.5.1 Tahmin

Herhangi bir alanda, geleceğe dair planlamalar düzenlemeler yapabilmek için o alanda geleceğe dönük tahminlerin yapılması gerekir. Bu tahmin, nüfus sayısı, bir mal için olacak talep vs birçok durumda kullanılabilir.

3.1.5.2 Örüntülü Tanıma

Bozuk ya da eksik örüntülerin YSA'ya tanıtılmış örüntülerle, eksik ya da bozuk olan örüntünün doğrusallaştırılması, tamamlanması işlemidir.

3.1.5.3 Fonksiyon Yaklaşımı

Birçok modelde belirli girdi değerlerine karşılık belirli çıktı değerleri yakın fonksiyonlarla elde edilebilir. Girdi ve çıktı değerlerine rağmen aralarındaki fonksiyon belirlenemediğinde aynı çıktıyı üretecek yaklaşık fonksiyon oluşturulması işlemidir.

3.1.5.4 Sınıflandırma

Sınıflandırma, girdi değerlerinin birde fazla sınıf içerisinde hangi sınıftan olduğuna karar verme işlemidir.

3.1.6 Tahmin Problemleri için Yapay Sinir Ağları

Tahmin amaçlı kullanılan YSA'larda modellemenin sisteme oturması son derece önemlidir. Modellemenin sisteme oturması için, modelleme işlemine başlamadan önce, problemle ilgili veriler yani girdi değerleri faktörüne dikkat edilmelidir.

Zaman serisi analizine dayalı tahminlerde, veriler yani girdi değerleri problemin

serisidir. Bu verilerde YSA'nın girdi ve çıktı değerlerini oluşturacak olan sıralı gözlem değerleridir. Sebep-sonuç ilişkisine dayalı tahminlerde ise girdi değerleri bağımsız değişken iken çıktı değerleri bağımlı değişken verileridir. Böyle bir tahmin probleminde modeli zorlaştırmamak adına bağımsız değişkenlerin seçiminde özenli davranılmalı, gereksiz değişken kullanılarak model şişirilmemelidir.

Verilerle alakalı işlemlerin ardından YSA modellenmesine geçilebilir. Modelleme işleminin ilk adımı ağ yapısının belirlenmesidir. Yani, katman ve nöron sayılarının belirlenmesidir. Sonraki adımlar ise aktivasyon fonksiyonunun belirlenmesi, YSA eğitimi, normalizasyon işlemi, veri setinin belirlenmesi ve ağın performans ölçüleridir.

3.1.6.1 Ağ Yapısının Belirlenmesi

YSA'larda ağ yapısı için girdi nöronu, gizli katmanı, gizli nöronu ve çıktı nöronu sayıları belirlenmelidir. Bu sayıları belirlemek için garanti sonuç verecek yöntem bulunmamaktadır. Yaklaşımlar yapılarak bu sayılar belirlenmektedir.

- Girdi Nöronu Sayısı: Sebep-sonuç ilişkisine dayalı tahmin problemlerinde probleme ait bağımsız değişken sayısı girdi nöronu sayısını verecektir. Ancak zaman serisi analizine dayalı tahmin problemlerinde girdi sayısını belirlemek kolay değildir. Tang ve Fishwick tek değişkenli zaman serileri için girdi nöron sayısının Box-Jenkins AR(p) modelinin derecesine eşit olduğu kanısına varmışlardır (Tand and Fishwick 1993).

Girdi nöronları, veri içerisinde ki bilgilerin ortaya çıkmasında önemli görev üstlenirler. Bu nedenle uygun girdi nöron sayısını belirlemek oldukça önemlidir.

- Gizli Katman Sayısı: Genellikle tek gizli katmanlı YSA'lar problem çözmede yeterli olmaktadır. Fakat zaman zaman birden fazla katmana ihtiyaç duyulabilmektedir. Gizli katman sayısının artması tahminin doğruluk oranını arttırabilir fakat bunun yanı sıra hesaplama zamanı artar ve YSA öğrenme yerine ezberleme yoluna gider. Buda modellemenin sisteme oturmamasına neden olabilir.

- Gizli Nöron Sayısı: Gizli nöron sayısını belirlemek adına genel bir yöntem yoktur. Bu sayıyla alakalı olarak şu hususun gözden kaçırılmaması gerekir; gizli nöron sayısı gerektiğinden az olursa öğrenme işlemi başarısız olabilir, sayı gereğinden fazla olursa ağ öğrenme yerine ezberleme yoluna gidebilir. Gizli nöron sayısı, düşük nöron sayısıyla başlayıp ağ performansı düşme eğilimine geçene kadar gizli nöron sayısı artırılarak belirlenebilir.
- Çıktı Nöron Sayısı: Zaman serisi analizine dayalı tahmin problemlerinde tahmin döneminin sayısı kadardır. Sebep-sonuç ilişkisine dayalı tahminde ise bağımlı değişken sayısına eşittir.

3.1.6.2 Aktivasyon Fonksiyonunun Belirlenmesi

Aktivasyon fonksiyonu ağın performansını etkileyen bir başka önemli faktördür. Tahmin amaçlı kullanılan YSA'larda en çok kullanılan fonksiyonlar (logsig, tansig, purelin) 4. bölümün 2. başlığında anlatılmıştı. Bu üç fonksiyondan hangisinin seçileceğine dair genel bir yöntem yoktur. Genellikle gizli katman nöronları için sigmoid ya da tanjant sigmoid fonksiyonu kullanılır.

3.1.6.3 Normalizasyon

Ağ eğitiminin hızı açısından normalizasyon işlemi önemlidir. Normalizasyon ile nöron çıktıları $[0,1]$ aralığına veya $[-1,1]$ aralığına yerleştirilirler. Normalizasyon işlemi eğitime başlamadan uygulanır.

Zaman serilerine dayalı tahmin problemlerinde girdi ve çıktıları normalizasyon işlemi birlikte yapılır. Normalizasyon işlemi için aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmışsa değerler $[0,1]$, tanjant sigmoid fonksiyonu kullanılmışsa değerler $[-1,1]$ arasına yerleştirilir.

3.1.6.4 Eğitim

YSA eğitimi doğrusal olmayan minimizasyon işlemidir. Eğitim için birçok optimizasyon yöntemi vardır. Bunlardan bazıları, gradyan dik iniş algoritması,

Levenberg-Marquardt optimizasyonu, genetik algoritma ve rassal aramadır.

3.1.6.5 Veri Setlerinin Düzenlenmesi

YSA ile tahmin işleminde eldeki mevcut veri seti, eğitim-test veya eğitim-doğrulama-test olmak üzere ayrılır. Eğitim seti YSA'nın eğitiminde, doğrulama seti eğitim sürecinin ne zaman durdurulacağını belirlemede, test verileri de YSA tahmin sonuçlarının karşılaştırılması için kullanılır. Veri setinde bu gruplandırmalar rastgele yapılmamalıdır. Bu oranlama ağ performansını doğrudan etkilemektedir. Genellikle %70-%15-%15 veya %80-%10-%10 olarak yapılmaktadır.

3.1.6.6 Performansın Belirlenmesi

Tahmin için oluşturulan YSA modellemesinin hızlı ve doğruluk oranının yüksek olması beklenir. Tahmindeki hata değeri, gerçek gözlem değeri ile tahmin edilen değer arası farktır. %'lik olarak formülizasyonu şu şekildedir;

$$MAPE = \frac{\text{Gerçek Değer} - \text{Tahmin Değeri}}{\text{Gerçek Değer}} 100 \quad (3.1)$$

3.1.6.7 Yapay Sinir Ağları Yazılımları

Piyasada YSA'lar için geliştirilmiş birçok yazılım bulunmaktadır. Araştırmacılar, bu yazılımların yanı sıra kendi geliştirdikleri yazılımlarla da çalışmalar yapmaktadırlar. Piyasada ücretli ücretsiz birçok yazılım bulunmaktadır. Aşağıdaki çizelge 3.2'de bunlardan bazıları verilmiştir.

Çizelge 3.2 YSA için Bazı Yazılım Programları.

Ücretsiz Yazılımlar	Ücretli Yazılımlar
NeuralShell	STATISTICA: Neural Network
PDP++ Software	NeuroForecaster/GENETICA
Pittnet	NeuroSolution
MUME	BrainMaker
NNSYSID	Braincel
SNNS	NeuroLab
DartNet	MATLAB: Neural Network Toolbox

Bu çalışmada MATLAB: Neural Network Toolbox yazılımı kullanıldığından bu konu hakkında giriş seviyesinde bilgi verilecektir.


- MATLAB Neural Network Toolbox

NNT, MATLAB programında YSA oluşturmak, eğitmek, uygulamak ve simüle etmek için kullanılan bir yazılımdır. NNT ile birçok YSA modellemesi yapılabilir. NNT ile YSA simülasyonu, kullanıcı ara yüzü kullanarak veya MATLAB kodlama editörü ile yapılabilir.


- NNT Kullanıcı Ara yüzü

Kullanıcı ara yüzü (Şekil 3.7) MATLAB komut penceresi “nntool” komutu verilerek açılır.

Yeni ağ oluşturmak için ara yüzdeki “New” butonuna basılır. Ekrana yeni ağ oluşturmak için “Create Network or Data” penceresi açılır. Data sekmesinde (Şekil 3.8) girdi ve çıktı değerleri ağa tanıtılır. “Name” alanı verilere verilecek olan ismin yazıldığı alandır. “Data Type” alanı ise verilerin girdi mi çıktı mı olduğu belirtilir. Bu pencere, Şekil 3.8’de gösterilmiştir.



Şekil 3.7 MATLAB YSA Kullanıcı Arayüzü.




Şekil 3.8 Verilerin YSA'ya Tanıtılması.

Her bir veri girişinin ardından “Create” düğmesine tıklanır. Veri giriş işleminin ardından “Network” sekmesine geçilir (Şekil 3.9). “Name” alanına oluşturulacak ağın


adı girilir. “Network Type” alanında YSA’nın türü seçilir. “Training Function” alanında hata fonksiyonu optimizasyonunda kullanılacak algoritmanın seçimi yapılır. “Adaption Learnig Function” alanında eğitim fonksiyon tipi seçilir. “Performans Function” alanında ise ağıın performansının ölçülmesinde kullanılacak olan ölçüt belirlenir.

“Proporties for” kısmında “Layer1 ve Layer2” için sırasıyla nöron sayısı ile aktivasyon fonksiyonları tanımlanır. Tanımlamaların ardından “View” butonu ile oluşturulan ağıın ön izlemesi görülebilir(Şekil 3.10). “Create” butonu ile ağıın kurulumu gerçekleştirilir. Kurulum işleminin ardından “Network/Data Manager” ara yüzüne geri dönülerek “Network” kısmında ağıın ismine tıkladıldığında kurulan ağıın penceresi açılır (Şekil 3.11).






Şekil 3.9 YSA'nın Adlandırılması ve Oluşturulması.




Şekil 3.10 Oluşturulan YSA'nın Ön İzlemesi.




Şekil 3.11 Oluşturulan YSA'nın Penceresi.

Ağın penceresinde “Train” sekmesinde girdi ve çıktı değişkenleri tanımlanır. “Training Parameters” alt sekmesinde ise eğitimin iterasyon sayısı, istenilen hata düzeyi gibi parametreleri tanımlanır. “Train Network” butonu ile ağın eğitimi başlatılır(Şekil 3.12).



Şekil 3.12 Girdi ve Çıktı Değişkenlerinin Tanımlanması ve Eğitimin Başlaması.

Eğitim süreci başladığında ekrana eğitimin ilerleyiş penceresi gelir(Şekil 3.13). Bu pencerenin “Neural Network” alanında, oluşturulan ağ yer alır. “Algortihm” alanında ise ağda kullanılan algoritmalar belirtilir. “Progress” alanında ise ağ eğitiminin iterasyon sayısı, eğitimin zamanı, performansı, hata değeri, istenilen hata değerini kaç kez tekrarladığı gösterilir. “Plots” alanında ise ağın eğitim performansının grafiği, eğitim grafiği, girdilere göre çıktı değerlerinin grafiği gösterilir.



Şekil 3.13 YSA Eğitiminin İlerleyişi.

NNT’de bir başka veri girme yolu ise MATLAB komut penceresinden Network/Data Manager arayüzünde ki “import” butonu ile alınır. “Import” butonuna tıkladıktan sonra gelen pencerede “Select a Variable” alanında ilgili veri setinin değişkeni seçilir ve “Destination” alanında bu değişkenin hangi tür veri olarak alınacağı tanımlanır.

Ardından diğ er iřlemlere yukarıda anlatıldıđı gibi devam edilir.



4. DENEYSEL ÇALIŞMA

Çalışmanın bu bölümünde, MATLAB programında Neural Network Toolbox kullanılarak, Yapay Sinir Ağları yöntemi ile Urla'ya ait örnek mahalle için kısa dönemli enerji talep tahmini yapılacaktır.

Tahmin işlemi için iki farklı tahmin modeli (bölgeye dayalı ve toplam yüke dayalı) oluşturulup, bu modellerle tahmin işlemi yapılmaya çalışılacaktır. Tahmin işleminin ardından modeller karşılaştırılıp, hangisinin daha uygun olduğu açıklanacaktır.

Uygulamaya geçmeden önce Yapay Sinir Ağlarının oluşturulması için geçmişe ait verilerin bulunması gerekmektedir.

4.1 Veri Setlerinin Oluşturulması

Enerji talebini etkileyen birçok parametre bulunmaktadır. Bunların en önemlileri meteorolojik veriler yani sıcaklık ve nem değerleridir. Bunun yanı sıra günün özelliği yani hafta içi, hafta sonu veya tatil günü olması da talebi etkileyen önemli parametrelerdir.


Veri seti, Microsoft Excel programında hazırlanmıştır. Bu veri seti toplam yüke dayalı tahmin modeli için oluşturulmuştur. Elimizdeki veriler 2013 yılı başından 2017 yılı Haziran ayı sonuna kadar olan verilerdir. Tüm saatlik değerlerin mevcut olduğu düşünüldüğünde, 39384 adet veri olması gerekmektedir. Analizör arızaları, enerji kesintilerinden dolayı alınamayan değerler mevcut olduğundan 39329 adet veri bulunmaktadır. Bu verilerin 35033 adedi ağ oluşturmak için, geri kalanı ise tahmin işleminin ardından tahminin doğruluğu hesaplamak adına test verisi olarak kullanılmıştır. Yani ağ oluşumunda kullanılacak veri setinin bir matris olduğu göz önüne getirildiğinde, bu matrisin satır sayısı 35033 olacaktır. Bu matrisin sütunlarında ise sırasıyla yıl, ay, gün, saat, sıcaklık, nem, gün özelliği ve yük değerleri bulunmaktadır. Yani sütun sayısı 9 olacaktır. Matrisin toplam boyutu 35033×9 'dur.

Bölgeye dayalı tahmin modeli içinse, MATLAB’de program yazılarak her bölge için kendine ait veri seti oluşturulması sağlanmıştır. Bunun nedeni ise üst paragrafta da bahsettiğimiz gibi analizör arızalarında veya enerji kesintilerinde yük değerinin 0 olduğu durumlar bulunmasıdır. Yükün 0 olduğu durumlar, YSA eğitimini olumsuz etkileyeceğinden, hata oranını arttıracığından veri setinin dışında bırakılmıştır.

Sonuç olarak toplam yüke dayalı 1 adet veri seti ve bölgeye dayalı 2 adet veri oluşturulmuştur. Bölgeye dayalı veri setinin 2 adet olmasının nedeni ise örnek mahalleye ait 2 adet TM bulunmasıdır.

4.1.1 Yük Verileri


Bu veriler, Urla’daki örnek mahalleye ait 2013 başından 2017 Haziran sonuna kadar olan GEDAŞ’a ait verilerdir.



Şekil 4.1 2013 Başından 2017 Haziran Sonuna Kadar Olan Yük Verileri.

4.1.2 Sıcaklık Verileri

Sıcaklık değerleri, enerji tüketimini doğrudan etkileyen en önemli parametrelerden biridir. Veri setinde kullanılan değerler $^{\circ}\text{C}$ cinsindendir. Bu veriler örnek mahalleye ait 2013 başından 2017 Haziran sonuna kadar olan MGM’ye ait verilerdir.




Şekil 4.2 2013 Başından 2017 Haziran Sonuna Kadar Olan Saatlik Sıcaklık Verileri.

4.1.3 Nem Verileri

Sıcaklık değerlerinin enerji tüketimini doğrudan etkilediğinden bahsetmiştik. Havadaki nem oranı da sıcaklığı doğrudan etkilemektedir. Dolayısıyla nem oranı da enerji tüketimini doğrudan etkileyen parametrelerden bir tanesidir. Şekil 4.3’de Sıcaklık ve Nem arasındaki ilişki gösterilmiştir.

		BAĞIL NEM (%)																		
HAVA SICAKLIĞI (°C)		5	10	15	20	25	30	35	40	45	50	55	60	65	70	75	80	85	90	95
	50	45	48	53	58	66	69	76	83	91	99									
	49	44	47	51	55	61	66	72	79	86	94									
	48	43	46	49	53	58	63	68	75	81	88	96								
	47	42	45	48	51	55	60	65	70	76	83	90	98							
	46	41	43	46	49	53	57	62	67	72	78	85	91	99						
	45	41	43	45	48	52	56	62	65	70	76	82	88	96						
	44	40	42	44	46	49	52	57	61	66	71	77	83	89	96					
	43	39	40	42	44	47	50	54	58	62	67	72	77	83	90	97				
	42	38	39	41	43	45	48	51	54	58	62	67	72	78	83	90	96			
	41	37	38	39	41	43	45	48	51	55	59	63	67	72	78	83	89	96		
	40	36	37	38	39	41	43	46	48	51	55	59	63	67	72	77	83	88	95	
	39	35	36	37	38	39	41	43	46	48	51	55	58	62	67	71	76	81	87	93
	38	35	35	36	37	38	40	42	44	47	50	53	56	60	64	68	73	78	83	89
	37	34	34	35	36	37	38	40	42	44	46	49	52	56	59	63	67	72	76	81
	36	33	33	34	34	35	36	38	39	41	43	46	48	51	55	58	62	66	70	74
	35	32	32	33	33	34	35	36	37	39	41	43	45	48	50	53	57	60	64	68
	34	31	31	32	32	32	33	34	35	37	38	40	42	44	46	49	52	55	58	61
	33	31	31	31	31	32	32	33	34	36	37	39	40	42	45	47	49	52	55	58
	32	30	30	30	30	31	31	32	33	34	35	36	38	39	41	43	45	47	50	53
	31	29	29	29	29	29	30	30	31	32	33	34	35	36	38	40	41	43	45	47
	30	28	28	28	28	28	29	29	30	30	31	32	33	34	35	36	38	39	41	42
	29	27	27	27	27	28	28	28	28	29	30	30	31	32	32	33	34	36	37	38
	28	26	26	26	27	27	27	27	27	28	28	29	29	30	30	31	32	32	33	34
	27	26	26	26	26	26	27	27	27	27	28	28	28	29	29	30	30	31	31	32
	26	25	25	25	26	26	26	26	26	26	27	27	27	27	27	28	28	28	28	29
	25	25	25	25	25	25	26	26	26	26	26	26	26	26	27	27	27	27	27	27

Şekil 4.3 Havadaki Nem Oranının Hava Sıcaklığına Etkisi (İnt.Kyn.1).



Şekil 4.4 2013 Başından 2017 Haziran Sonuna Kadar Olan Saatlik Nem Verileri.


4.2 MATLAB Yazılım Programı ile Tahmin Programının Oluşturulması

Bu bölümde örnek bölge için talep tahminine yönelik iki farklı model oluşturulup iki modele göre tahmin programı oluşturulacaktır.

4.2.1 Arayüz Oluşturma

Oluşturulacak olan programın kullanıcılara kullanım kolaylığı sağlaması açısından MATLAB GUI ile kullanıcı arayüzü oluşturulacaktır. Kullanıcılar bu arayüz sayesinde kolay talep tahmini yapabileceklerdir.

Öncelikle tahmin işleminde kullanılacak olan veri tabanının ve oluşturulan YSA'yı kontrol etmek için "Data_base" arayüzü oluşturulmuştur. Bu arayüz ile veri tabanına yeni veriler eklenebilir ve YSA'nın güncellemesi sağlanabilmektedir. Şekil 4.5'de oluşturulan Database Arayüzü gösterilmiştir.




Şekil 4.5 Data Base Kullanıcı Arayüzü.

Database Arayüzün'de ki "Excel Dosyası" butonu ile veri setini oluşturduğumuz Excel dosyası açılır. Açılan dosyaya yeni veriler eklenebilir. Verilerde değişiklik yapıldıktan sonra yeni veriler ile ağı eğitmek için "Ağı Eğit" butonu kullanılır.


Bu arayüzün ardından yani ağ eğitimi tamamlandıktan sonra tahmin işleminin yapılabilmesi için Load_Forecasting arayüzü oluşturulmuştur. Şekil 4.6'da Tahmin

Programının arayüzü gösterilmiştir. “Veri Gir” butonundan tahmin yapılacak güne ait sıcaklık ve nem değerlerinin girileceği Excel dosyası açılmaktadır. “Veri Tabanı” butonundan ise Database arayüzüne geçilir.



Şekil 4.6 Tahmin İşlemi İçin Kullanıcı Arayüzü.

“Gün Seç” butonundan tahminin yapılacağı gün seçilir. Bu butona bastığında Şekil 4.7’de ki takvim açılır ve bu takvimden tahmin yapılacak gün seçilerek “ok” butonuna basılır. Tahmin yapılacak gün belirlendikten sonra “Tahmin Et” butonuna basılarak tahmin işlemi gerçekleştirilir. Tahmin işlemi gerçekleştirildikten sonra Load_Forecasting arayüzündeki grafik alanında, oluşturulan iki farklı modele göre tahminin grafikleri ve tahmin değeriyle karşılaştırılabilmesi için gerçek değerlerden oluşan grafik oluşur. Tahmin işleminin sonuçlarını sayısal olarak görmek içinde “Sonuçlar” butonuna basılmalıdır. Bir başka gün için tahmin işlemi yapılacaksa “Sıfırla” butonuna basılarak arayüz sıfırlanıp, tekrar gün seçilerek tahmin işlemi yapılır.



Şekil 4.7 Tahmin Yapılacak Günü Seçileceği Takvim.

4.2.2 Verilerin MATLAB'e Aktarılması

YSA'nın oluşturulması ve eğitilmesi için veri tabanında bulunan girdi ve çıktı değerlerinin MATLAB'e aktarılması gerekmektedir. Tüm veriler öncelikle 35033x9 boyutunda matris olarak MATLAB'e aktarılır. Daha sonra YSA eğitimi için giriş ve çıkış matrislerinin ayrılması gerekmektedir. Giriş matrisi 35033x7 boyutunda, çıktı matrisi ise 35033x2 boyutunda matrise atanır. YSA'lar sütunlar ile işlem yaptığından, bu matrisler YSA'ya uygun olması için transpozesi alınır.

4.2.3 Normalizasyon İşlemi

Ağın eğitilmesi ve performansının artırılması açısından bazı işlemler yapmak gerekmektedir. Bu işlemler giriş değerlerini ağ eğitimi için uygun formlara dönüştürmektedir. Bu işlemler "Normalizasyon" adını almaktadır. Normalizasyon işlemi veri setine uygulanarak ağ eğitimi için uygun formda veri tabanını oluşturur. Normalizasyon işlemiyle tüm girdi ve çıktı değerleri belirli bir aralıkta değerlere atanır, ağın, değerleri okuması kolaylaştırılır. Buda ağ eğitiminin zamanını azaltarak, performansını artırır.

Bu çalışmada normalizasyon işlemi için MATLAB’de “mapminmax” fonksiyonu kullanılmıştır. Bu işlem ile tüm girdi değerleri -1 ile 1 arasındaki değerlere atanmışlardır. Çıktı değerlerinin normalizasyon işlemi içinse MATLAB’de ki “minmax” fonksiyonu kullanılmıştır. Bu işlem ile de tüm çıktı değerleri 0,1 ile 0,9 arasındaki değerlere atanmışlardır.

Ağ oluşturulmasından sonra çıktı değerlerine “Denormalizasyon” işlemi uygulanarak gerçek formuna dönüştürülür. Denormalizasyon işleminin yapılmasının nedeniyse gerçek değerler ile ağ çıktı değerlerinin karşılaştırılması içindir. Denormalizasyon işlemi, normalizasyon için oluşturulan fonksiyonun tersidir.

$$[P_n, \sim] = \text{mapminmax}(P); \quad \text{Giriş Değerlerinin Normalizasyonu}$$

$$mm = \text{minmax}(T_n);$$

$$\min = mm(1);$$

$$\max = mm(2);$$

$$T_n = 0,8 \frac{T - T_{\min}}{T_{\max} - T_{\min}} + 0,1 \quad \text{Çıkış Değerlerinin Normalizasyonu}$$

P : Girdi değerlerini,

P_n : Normalizasyon yapılmış girdi değerlerini,

T : Çıktı değerlerini,

T_n : Normalizasyon yapılmış çıktı değerlerini,

T_{min} : Çıktı değerleri setindeki en küçük değerini,

T_{max} : Çıktı değerleri setindeki en büyük değerini ifade etmektedir.


4.2.4 YSA’nın Oluşturulması ve Eğitimi

YSA besleme tipi olarak ileri beslemeli olarak çeşitli YSA’lar oluşturulmuştur.

Oluşturulan bu YSA'lar içerisinde doğruluk oranı en yüksek olan ağa erişilmeye çalışılmıştır.

Doğruluk oranı en yüksek ağ, katmanlarda ki farklı nöron sayıları, çeşitli aktivasyon fonksiyonları, eğitim için optimizasyon algoritmaları, iterasyon sayısı ile denenerek seçilmiştir.

Oluşturulan ileri beslemeli ağın eğitimi için MATLAB bünyesinde bulunan Levenberg-Marquardt optimizasyon algoritmasıyla geliştirilen “trainlm” eğitim fonksiyonu kullanılmıştır. Oluşturulan ağın yapısı şekil 4.8’de gösterilmiştir.



Şekil 4.8 Oluşturulan YSA'nın Yapısı.

Oluşturulan bu YSA girdi ve çıktı katmanı olarak 2 katmanlıdır. Girdi katmanında nöron sayısı denemeler sonucunda 28 olarak belirlenmiştir. Çıktı katmanında ise sadece “logsig” aktivasyon fonksiyonu kullanılmıştır.

Veri setindeki tüm veriler ağın eğitimi için kullanılmamıştır. Verilerin %70'i ağ eğitimi, %15'i doğrulama ve %15'i de programın testi için kullanılmıştır.


Oluşturulan ağ öğrenimi performans olarak hata oranlarının kareleri (MSE) yöntemi baz alarak sağlamaktadır. Şekil 4.9'da oluşturulan ağın parametrelerinin belirlenmesi gösterilmiştir.

```

hiddenSizes = [28]; %Yapay Sinir Ağının Nöron Sayısı
trainFcn = 'trainlm'; %Ağın Eğitim Fonksiyonu
net = feedforwardnet(hiddenSizes,trainFcn); %Ağın Besleme Tipi, İleri Beslemeli
net.layers{1}.transferFcn = 'logsig'; %Ağın Aktivasyon Fonksiyonu
net.trainParam.show = 1000; %Eğitim Aşamasında Ağın Yakaladığı Hata Değerini Kaç İterasyonda Bir Ekranda Gösterdiği
net.trainParam.epochs = 5000; %Ağın Kaç İterasyonda Biteceği
net.trainParam.goal = 0.000001; %Ağda Hedeflenen Hata Değeri. Bu Hata Değeri Yakalanınca Eğitim Biter
net.trainParam.max_fail = 100; %Ağın Yakaladığı Hata Değerini Kaç İterasyonda Tekrarlarsa Eğitimin Bitirileceği
    %Üstteki 3 Şarttan Herhangi Biri Sağlanırsa Eğitim Biter
net.PerformFcn = 'mse'; %Ağın Eğitim Performansının Belirleneceği Parametre. Hata Oranlarının Kareleri
net = init(net); %Eğitimi Başlatma Komutu
net.divideParam.trainRatio = 0.7; %Veri Setindeki Değerlerin Yüzde 70'i Eğitim İçin
net.divideParam.valRatio = 0.15; %Değerlerin Yüzde 15'i Doğrulama İçin
net.divideParam.testRatio = 0.15; %Değerlerin Yüzde 15'i Test İçin Kullanılmıştır.

```

Şekil 4.9 Ağın Oluşturulduğu Parametreler.




Şekil 4.10 Oluşturulan YSA'nın Eğitim Aşaması.


Şekil 4.10'da ağıın eğitim aşaması gösterilmiştir. Bu sekmede oluşturulan ağıın yapısı, kullanılan algoritma, hata performansı yöntemi, eğitimin performans grafiğı ve sistemin uygunluk derecesi belirlemek için oluşan regresyon doğrularına ulaşılabilir.

Şekil 4.11'de oluşturulan ağıın performans grafiğı gösterilmektedir. Ağıın hata hedefi 10^{-5} olarak belirlenmişken, oluşturulan YSA yaklaşık olarak 10^{-3} değerine yaklaşmıştır.

Şekil 4.12'de, ağıın regresyon doğruları gösterilmiştir. Regresyon doğrularıyla sistemin uygunluğu tespit edilir. Regresyon doğrusunu oluşturan parametre, tahmin edilen değerlerin gerçek değerlere oranıyla hesaplanır (Kuutsoyiannis 1989). Regresyon değeri 0 ile 1 aralığında bir değeri alır. Değeri 0 olması sistemin uyumsuz olduğı, 1 olması sistemin uyumlu olduğı belirtir. Bu yüzden, regresyon katsayısının 1'e oldukça yakın olması istenir. Uyumun yeterli denebilmesi için, regresyon değeri 0,9 ile 1 aralığında olmalıdır. Uygulamamızda bu değeri ortalama olarak 0,95 olarak hesaplanmıştır.



Şekil 4.11 Oluşturulan Ağıın Eğitim Performansı.



Şekil 4.12 Oluşturulan Ağın Regresyon Doğruları.

5. SONUÇ

Uygulamada iki farklı model oluşturulduğundan bahsetmiştik.

1.model; toplam yüke dayalı YSA modeli

2.model; bölgesel yüke dayalı YSA modeli.

Bu modellere göre rastgele seçilen bir haftanın her günü için yapılmış bir haftalık tahminin yüzdelik olarak hata değerleri çizelge 5.1’de verilmiştir.

Çizelge 5.1 24 – 30 Nisan Arası Günlük MAPE Değerleri.

Gün		Model 1 MAPE	Model 2 MAPE
1	(24 Nisan 2017)	7,93	9,03
2	(25 Nisan 2017)	6,88	7,53
3	(26 Nisan 2017)	4,47	5,14
4	(27 Nisan 2017)	9,71	11,08
5	(28 Nisan 2017)	6,74	5,39
6	(29 Nisan 2017)	7,48	9,12
7	(30 Nisan 2017)	6,07	6,36
ORTALAMA		7,04	7,66

Ağın performansı hesaplanırken MSE kullanılmıştı. Tahminde ki performans değeri yani hata değeri için MAPE kullanılmıştır.

MAPE’nin hesaplanması şu şekildedir;

$$MAPE = \left[\frac{(Gerçek Değer - Tahmin Değeri)}{Gerçek Değer} \right] \times 100$$

MAPE : Ortalama hata oranını

Gerçek Değer : Ölçülen değeri

Tahmin Değeri : YSA’nın tahmin ettiği değeri göstermektedir.


Lewis 1982’de MAPE değerinin %10’nun aşığısında olduđu modeller için “çok iyi”, %10 - %20 arasında olduđu modeller için “iyi”, %20 - %50 arasında olan modeller için “kabul edilebilir” ve %50’nin üstüne çıkan modeller içinse “hatalı” değlendirmesinde bulunmuştur(Lewis 1982). Lewis’in bu değlendirmesinden yola çıkarak, çalışmamız iki farklı modelde de MAPE değerinini %10’un altında tutarak amacına ulaşmıştır.

Oluşturulan modellemelerin sisteme uygun olup olmadığını kontrol etmek içinde şekil 4.12’de verilen regresyon eğrileri incelenmelidir. Regresyon katsayıları ortalaması bu çalışmada 0,95 çıkmıştır. Bu katsayı değerde modellemelerin sisteme uygun olduğunu göstermektedir.


Her iki modelde de amacına ulaşılmasına rağmen model 1’in(bölgeye dayalı) daha başarılı olduğu sonucuna varılmıştır.

Uygulamada örnek olarak ele alınan bölgenin turistik bölge olmasından dolayı nüfusun sürekli olarak değışmesi, bölgenin rüzgarlı bölge olmasından kaynaklı rüzgarlarda direk devrilmesi hat kopması gibi nedenlerden enerji kesintilerinin olmasından dolayı ağda kullanılan verilerin eksik olmasından dolayı tahminde dalgalanmalara sebebiyet vermiştir.


Aşığıdaki şekillerde çizelge 5.1’de verilen tahmin sonuçlarının, programda oluşturulan kullanıcı ara yüzündeki grafikleri verilmiştir.




Şekil 5.1 24 Nisan 2017 İin Tahmin Sonuları.




Şekil 5.2 25 Nisan 2017 İin Tahmin Sonuları.




Şekil 5.3 26 Nisan 2017 İçin Tahmin Sonuçları.




Şekil 5.4 27 Nisan 2017 İçin Tahmin Sonuçları.



Şekil 5.5 28 Nisan 2017 İçin Tahmin Sonuçları.



Şekil 5.6 29 Nisan 2017 İçin Tahmin Sonuçları.



Şekil 5.7 30 Nisan 2017 İçin Tahmin Sonuçları.

6. KAYNAKLAR

- Abbak, A. (2007). Jeodezide Zaman Dizilerinin Dalgacık (Wavelet) Analizi. Jeodezi ve Fotogrametri Mühendisliği Bölümü, Selçuk Üniversitesi, Konya 2007.
- Ahmed, K.M.U., Ampatzis, M., Nyugen, P.H. and Kling, W.L. (2014). Application of Time-series and Artificial Neural Network Models in Short Term Load Forecasting for Scheduling of Storage Devices. Department of Electrical Engineering, Technische Universiteit Eindhoven, the Netherlands.
- Bakırtaş, T., Karbuz, S. ve Bildirici, M. (2000). An Econometric Analysis of Electricity Demand in Turkey METU Studies in Development. **27**: 23-34.
- Balcı, H., Esenler, İ.I. ve Kurban, M. (2010). Regresyon Analizi Kullanılarak Kısa Dönem Yük Tahmini. Bilecik Şeyh Edebali Üniversitesi, Bilecik.
- Bilge, B. Kısa Dönem Yük Tahmini. TEİAŞ Milli Yük Tevzi İşletme Müdürlüğü, Gölbaşı, Ankara.
- Bonanno, F., Capizzi, G. and Sciuto, G.L. (2014). A Neuro Wavelet-Based Approach for Short-Term Load Forecasting in Integrated Generation Systems. Department of Electrical, Electronics and Informatics Engineering, University of Catania, Catania, Italy.
- Ceylan, G. (2004). Yapay Sinir Ağları ile Kısa Dönem Yük Tahmini. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, İstanbul.
- C.Chapra, S. and P.Canale, R.; çev. Haperken, H. ve Keskin, U. (2009). Yazılım ve Programlama Uygulamalarıyla Mühendisler için Sayısal Yöntemler.
- Chen, H., Canizares, C. and Singh, A. (2001). ANN-based Short-Term Load Forecasting in Electricity Markets. Department of Electircal&Computer Engineering, University of Waterloo, Waterloo, ON, Canada.
- Chen, Y., Luh, P.B., Guan, C., Zhao, Y., Michel, L. D., Coolbeth, M.A., Friedland, P.B. and Rourke, S.J. (2010). Short-Term Load Forecasting: Similar Day Based Wavelet Neural Networks. *IEEE Transactions on Power Systems*, **25**: 322.

- Colin D. LEWIS. (1982). Industrial and Business Forecasting Methods. Butterworths Publishing: London, 40.
- Çevik, O. ve Yürekli, K. (2013). Mevsimsel ARIMA Modeli Kullanılarak Yeşilırmak Nehri Aylık Akım Serisinin Modellenmesi. *Tarım Bilimleri Dergisi*, **9**: 261-268.
- Doğan, G. ve Çıngı, H. (2010). Yapay Sinir Ağları Kullanılarak Türkiye’de ki Özel Bir Sigorta Şirketinde Portföy Değerlendirmesi. Yüksek Lisans Tezi, Hacettepe Üniversitesi.
- Dordonnat, V., Koopman, S.J., Ooms, M., Dessertaine, A. and Collet, J. (2008). An Hourly Periodic State Space Model for Modelling French National Electricity Load. *Intelligent Journal of Forecasting*, **24**: 566-587.
- EPDK, 2016, Elektrik Piyasası Talep Tahminleri Yönetmeliği, Ankara.
- Erkmen, I. and Ozdogan, A. (1997). Short Term Load Forecasting Using Genetically Optimized Neural Network Cascaded with a Modified Kohonen Clustering Process. 12th IEEE International Symposium on Intelligent Control, Istanbul, 107-112.
- Fan, S. and Hyndman, R.J. (2012). Short-Term Load Forecasting Based on a Semi Parametric Additive Model. *IEEE Transactions on Power Systems*, **27**: 134-141.
- Hamzaçebi C. (2011a). Yapay Sinir Ağları: Tahmin Amaçlı Kullanımı Matlab ve Neurosolution Uygulamaları. Ekin Basım Dağıtım, Bursa, 13.
- Hamzaçebi C. (2011b). Yapay Sinir Ağları: Tahmin Amaçlı Kullanımı Matlab ve Neurosolution Uygulamaları. Ekin Basım Dağıtım, Bursa, 11.
- Hamzaçebi, C., Kalender Y.F. ve Es, H.A. (2014). Yapay Sinir Ağlar ile Türkiye Net Enerji Talep Tahmini. Karadeniz Teknik Üniversitesi, Trabzon.
- Hamzaçebi, C. ve Kutay, F. (2004). Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini. Gazi Üniversitesi, Ankara.
- Hou, Z.J., Etingov, P.V., Makarov, Y.V. and Samaan, N.A. (2014). Uncertainty Reduction in Power Generation Forecast Using Coupled Wavelet-ARIMA. Pacific Northwest National Laboratory, Richland, Washington USA.

- Islam, B., Baharudin, Z., Raza, M.Q. ve Nallagownden, P. (2014a). Optimization of Neural Network Architecture Using Genetic Algorithm for Load Forecasting. Department of Electrical & Electronics Engineering, Universiti Teknologi Petronas, Tronoh, Preak, Malaysia,.
- Islam, B., Baharudin, Z., Raza, M.Q. and Nallagownden, P. (2014b). A Hybrid NeuroGenetic Approach for STLF: A Comporative Analysis of Model Parameter Variations. IEEE 8th International Power Engineering and Optimization Conference (PEOCO2014), Langkawi, The Jevell of Kedah, Malaysia.
- Kaysal, K., Hocaoglu, F.O. ve Kaysal, A. (2014). Yük Tahmini için Hibrit (YSA ve Regresyon) Model. Afyon Kocatepe Üniversitesi, Afyonkarahisar.
- Khosravi, A. and Nahavandi, S. (2014). Load Forecasting Using Interval Type-2 Fuzzy Logic System: Optimal Type Reduction. *IEEE Trancastions on Industrial Informatics*, **10**: 2.
- Koo, B.G., Kim, M.S., Kim, K.H., Lee, H.T., Park, J.H. and Kim, C.H. (2013). Short-Term Electric Load Forecasting Using Data Mining Technique. *Conference on Intelligent Sysytems and Control*, **7**: 807-813.
- Kuutsoyiannis, A.: çev. Senesen, Ü., Senesen, G.G. (1989). Ekonometri Kuramı: Ekonometri Yöntemlerinin Tanıtımına Giriş. Versa Yayıncılık, Ankara.
- Liu, Q., Xu, H., Shi, C. and Wei, S. (2014). The Application of Intelligent Control Technology in Power Systems. International Conference on Mechatronics and Automation, 2034-2038.
- Luciano, C.M., Oleskovicz, M., Santos, A.Q., Coury, D.V. and Fernandes, R.A.S. (2014). Very Short-Term Load Forecasting Based on NARX Recurrent Neural Networks. Department of Electrical and Computer Engineering, University of Sao Paulo and Federal University of Sao Carlos, Sao Carlos, Brasil.
- Moraes, L.A., Flauzino, R.A., Araujo, M.A. and Batista, O.E. (2014). A Fuzzy Methodology to Improve Time Series Forecast of Power Demand in Distribution Systems. Department of Electrical and Computing Engineering, University of Sao Paulo, Sao Carlos, Brazil.

- Nalbant, A., Aslan, Y. ve Yaşar, C. (2005). Kütahya İli Elektrik Puant Yük Tahmini. Dumlupınar Üniversitesi, Kütahya.
- Pala, İ. (1998). Elektrik Sistemlerinde Bölgesel Yük Tahmini. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, İstanbul.
- Papadakis, S.E., Theocharis, J.B. and Bakirtzis, A.G. (2003). A Load Curve Based Fuzzy Modelling Technique for Short-Term Load Forecasting. *Fuzzy Sets and Systems*. **135**: 279-303.
- Rahman, S. (1993). Generalized Knowledge-Based Short-Term Load Forecasting Technique. *IEEE Transaction on Power Systems*, **8**: 508-514.
- Sahay, K.B. and Tripathi, M.M. (2013). Day Ahead Hourly Load Forecast of PJM Electricity Market and ISO New England Market by Using Artificial Neural Network. Department of Electrical Engineering, Delhi Technological University, New Delhi, India.
- Shi, D., Li, R., Shi, R. and Li, F. (2014). Analysis of the Relationship between Load Profile and Weather Condition. Department of Electronic and Electrical Engineering, University of Bath, UK.
- Singh, A.K., Khatoon, S., Muazzam, Md. and Chaturvedi, D.K. (2012). Load Forecasting Techniques and Methodologies: A Review. 2nd International Conference on Power, Control and Embedded Systems.
- Song, O., Hu, W. and XIE, W. (2002). Robust Support Vector Machine with Bullet Hole Image Classification. *IEEE Transactions on Systems, Man and Cybernetics – Part C: Application and Review*.
- Spiegel, M. R. (1981). Theory and Problems of Statistics in SI Units. McGraw-Hill, New York.
- Şener, F. (2005). Yük Tahmin Yöntemleri ve Ankara Merkez Metropol Alan için Regresyon Analizi Yöntemi Kullanılarak Uygulanması. Yüksek Lisans Tezi, Gazi Üniversitesi, Ankara.

- Tang, Z. and Fishwick, P.A. (1993). Feedforward Neural Nets as Models for Time Series Forecasting. TR91-008 Computer and Information Sciences, University of Florida, 1-26.
- Topallı, A.K. and Erkmen, I. (2003a). A Hybrid Learning for Neural Networks Applied to Short Term Load Forecasting. *Neurocomputing*, **51**: 495-500.
- Topallı, A.K. and Erkmen, I. (2003b). Four Methods for Short-Term Load Forecasting Using Benefits of Artificial Intelligence. *Electrical Engineering*, **85**: 229-233.
- Topallı, A.K., Erkmen, I. and Topallı, I. (2006). Intelligent Short-Term Load Forecasting in Turkey. *Electrical Power & Energy Systems*, **28**: 437-447.
- Toker, A.C. ve Korkmaz, O. (2011). Türkiye'nin Kısa Süreli Elektrik Talebinin Saatlik Olarak Tahmin Edilmesi. 17.Uluslararası Enerji ve Çevre Konferansı, İstanbul, 32-35.
- Torkzadeh, R., Mirzaei, A., Mirjalili, M.M., Anaraki, A.S., Sehati, M.R. and Behdad, F. (2014). Medium Term Load Forecasting in Distribution Systems Based on Multi Linear Regression & Principal Component Analysis: A Novel Approach. The 19th Electrical Power Distribution Conference, Niroo Research Institute, 66-70.
- Ünver, Ö. ve Gangam, H. (2008). Uygulamalı Temel İstatistik Yöntemler. Seçkin Yayınları, Ankara, 2008.
- Var, H. ve Türkay, E.B. (2014). Yapay Sinir Ağları Kullanılarak Kısa Dönem Elektrik Yükü Tahmini. İstanbul Teknik Üniversitesi, İstanbul.
- Xiaobo, X., Liu, W., Xi, Z. and Tianyang, Z. (2014). Short-Term Load Forecasting for the Electric Bus Station Based on GRA-DE-SVR. 2014 IEEE Innovative Smart Grid Technologies, Asia 388-393.
- Yalçınöz, T., Herdem, S. ve Eminoglu, U. (2002). Yapay Sinir Ağları ile Niğde Bölgesinin Elektrik Yük Tahmini. *ELECO'2002*, Bursa, 25-29.
- Yang, H., Liao, J. and Lin, C. (2013). A Load Forecasting Method for HEMS Applications. Department of Electrical Engineering, Research Center for Energy Technology and Strategy, National Cheng Kung University, Tainan, Taiwan.

- Yavuzdemir, M. (2014). Türkiye'nin Kısa Dönem Yıllık Brüt Elektrik Enerjisi Talep Tahmini. Ankara Üniversitesi, Ankara.
- Yılmaz, Z. ve Bozkurt, M.R. (2013). Ayırık Dalgacık Dönüşümü Kullanarak Aritmilere ait Özniteliklerin Çıkarılması. Elektrik Elektronik Mühendisliği Bölümü, Sakarya Üniversitesi, Sakarya.
- Yiğit, V. (2011). Genetik Algoritma ile Türkiye Net Elektrik Enerjisi Tüketiminin 2020 Yılına Kadar Tahmini. Endüstriyel Mühendislik Departmanı, Erzurum.

İnternet Kaynakları

- 1) <https://www.mgm.gov.tr/genel/sss.aspx?s=hissedilensicaklik>, 13.01.2018

ÖZGEÇMİŞ

Ad Soyad : Abdurrahman BİÇER
Doğum Yeri ve Tarihi : Gelibolu 02/01/1994
Yabancı Dil : İngilizce
İletişim (Telefon/e-posta) : 505 901 85 65 / abicer029@gmail.com

Eğitim Durumu

Lise : Soma Rıfat Dağdelen Anadolu Lisesi, (2008-2012)
Lisans : Afyon Kocatepe Üniversitesi, Elektrik Mühendisliği Bölümü, (2012-2016)
Yüksek Lisans : Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Yenilenebilir Enerji Sistemleri Anabilim Dalı, (2016 – Devam Ediyor)

İş Tecrübesi : İmbat Madencilik Sanayi Turizm AŞ (2016 Temmuz – Devam Ediyor)

Yayınları : Bicer, A., Yonetken, A., “Program Development For Energy Demand Forecasting And Its Application For A Site” *International Journal of Scientific & Engineering Research* Vol. 9, Issue 8, August-2018, ISSN 2229-5518, 18-27.