

**T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI**

**YAPAY SİNİR AĞLARI İLE DENİZLİ İLİ MESKEN ABONELERİ
ELEKTRİK TÜKETİM TAHMİNİ**

YÜKSEK LİSANS TEZİ

SEVGİ ÖKSÜZ

DENİZLİ, AĞUSTOS - 2019

**T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI**



**YAPAY SİNİR AĞLARI İLE DENİZLİ İLİ MESKEN ABONELERİ
ELEKTRİK TÜKETİM TAHMİNİ**

YÜKSEK LİSANS TEZİ

SEVGİ ÖKSÜZ

DENİZLİ, AĞUSTOS - 2019

KABUL VE ONAY SAYFASI

Sevgi ÖKSÜZ tarafından hazırlanan “YAPAY SİNİR AĞLARI İLE DENİZLİ İLİ MESKEN ABONELERİ ELEKTRİK TÜKETİM TAHMİNİ” adlı tez çalışmasının savunma sınavı 22.08.2019 tarihinde yapılmış olup aşağıda verilen jüri tarafından oy birliği / oy çokluğu ile Pamukkale Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı Yüksek Lisans Tezi olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Danışman
Doç. Dr. Hacer GÜNER GÖREN


.....

Üye
Dr. Öğr. Üyesi Leyla DEMİR
Pamukkale Üniversitesi


.....

Üye
Doç. Dr. Ömür TOSUN
Akdeniz Üniversitesi


.....

Pamukkale Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun
10/09/2019 tarih ve ...36121... sayılı kararıyla onaylanmıştır.


.....

Prof. Dr. Uğur YÜCEL

Fen Bilimleri Enstitüsü Müdürü

Bu tezin tasarımı, hazırlanması, yürütülmesi, arařtırmalarının yapılması ve bulgularının analizlerinde bilimsel etięe ve akademik kurallara özenle riayet edildiđini; bu alıřmanın dođrudan birincil ürünü olmayan bulguların, verilerin ve materyallerin bilimsel etięe uygun olarak kaynak gösterildiđini ve alıntı yapılan alıřmalara atfedildiđine beyan ederim.


SEVGİ ÖKSÜZ



ÖZET

YAPAY SİNİR AĞLARI İLE DENİZLİ İLİ MESKEN ABONELERİ ELEKTRİK TÜKETİM TAHMİNİ

YÜKSEK LİSANS TEZİ

SEVGİ ÖKSÜZ

PAMUKKALE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

(TEZ DANIŞMANI:DOÇ. DR. HACER GÜNER GÖREN)

DENİZLİ, AĞUSTOS - 2019

Günümüzde elektrik enerjisine yönelik talep, dünya nüfus artışına paralel olarak her geçen gün hızlı bir şekilde artmaya devam etmektedir. Enerji politikalarını belirleyebilmek için ise geleceğe yönelik güvenilir ve doğru tahminlere ihtiyaç duyulmaktadır. Elektrik dağıtım şirketlerinin temel işlevlerinden biri alınacak elektrik miktarını önceden tahmin etmeleridir. Bu nedenle elektrik talep tahminleri elektrik enerjisi üretim, dağıtım ve iletim sistemlerinin başarılı bir biçimde planlanması için büyük bir öneme sahiptir. Bu doğrultuda hazırlanan tez çalışmasında, 2008-2019 yıllarını kapsayan veriler kullanılarak Denizli mesken aboneleri elektrik tüketim miktarı, nüfus, elektrik birim fiyatları, işsizlik, sıcaklık gibi elektrik tüketimine etkisi olduğu bilinen değişkenler kullanılarak; yapay sinir ağı metodu ve MATLAB programı yardımı ile Denizli ili tüketim tahmini yapılmıştır. Çıkan sonuçlar mevcut değerler ile karşılaştırılmış, gerçeğe yakınlığı ölçülmüştür.

ANAHTAR KELİMELEER: Yapay Sinir Ağı, Elektrik, Tüketim Tahmini

ABSTRACT

ELECTRICITY CONSUMPTION FORECAST FOR RESIDENTIAL SUBSCRIBERS IN DENİZLİ WITH ARTIFICIAL NEURAL NETWORK

MSC THESIS

SEVGI OKSUZ

**PAMUKKALE UNIVERSITY INSTITUTE OF SCIENCE
INDUSTRIAL ENGINEERING**

(SUPERVISOR: ASSOC. PROF. DR. HACER GÜNER GÖREN)

DENİZLİ, AUGUST 2019

Today, demand for electrical energy continues to increase rapidly in line with the world population growth. In order to determine energy policies, reliable and accurate forecasts are needed for the future. One of the main functions of electricity distribution companies is to estimate the amount of electricity to be purchased. Therefore, electricity demand forecasts are really important for the successful planning of electric power generation, distribution and transmission systems. In this thesis, the electricity consumption estimation of household subscribers in Denizli is made by using artificial neural network method and MATLAB program using data between 2008-2019. In order to estimate the consumption, various variables such as amount of electricity consumption, population, unit prices of electric, unemployment and temperature have been used. The results have been compared to the actual values and their closeness to reality has been measured.

KEYWORDS: Artificial Neural Network, Electricity, Consumption Forecast

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	ii
ŞEKİL LİSTESİ	v
TABLO LİSTESİ	vi
KISALTMALAR	vii
ÖNSÖZ	viii
1. GİRİŞ	1
1.1 Dünya’da Enerji ve Elektriğin Durumu.....	2
1.2 Türkiye’de Enerji ve Elektriğin Durumu.....	3
1.3 Problem Tanımı	5
1.4 Tezin Amacı.....	6
1.5 Tezin Önemi ve Literatüre Katkısı	6
1.6 Tezin Organizasyonu	6
2. TALEP TAHMİNİ	8
2.1 Talep Tahminin Önemi.....	8
2.2 Talep Tahmininin Sınıflandırılması.....	8
3. ELEKTRİK TALEP TAHMİNİ	12
3.1 Elektrik Talebini Etkileyen Faktörler	12
3.2 Elektrik Tahmininde Kullanılan Yöntemler	14
3.3 Literatürde Elektrik Tahmini İle İlgili Çalışmalar	16
4. YAPAY SİNİR AĞLARI	19
4.1 Yapay Sinir Ağlarının Tarihçesi	19
4.2 Yapay Sinir Ağlarının Yapısı ve Temel Elemanları.....	21
4.2.1 Biyolojik Sinir Hücresi	21
4.2.2 Yapay Sinir Hücresi	22
4.2.3 Yapay Sinir Ağının Yapısı	25
4.2.4 Yapay Sinir Ağlarının Özellikleri	26
4.2.5 Yapay Sinir Ağlarının Sınıflandırılması	27
4.2.6 Yapay Sinir Ağları Modelleri.....	28
4.3 Yapay Sinir Ağları Konulu Literatürdeki Çalışmalar.....	37
5. YÖNTEM VE UYGULAMA	44
5.1 Veriler	44

5.2 Uygulama.....	47
6. SONUÇLAR VE DEĞERLENDİRME.....	53
7. KAYNAKLAR.....	54
8. EKLER.....	60
EK A.....	60
EK B.....	64
9.ÖZGEÇMİŞ.....	68



ŞEKİL LİSTESİ

Sayfa

Şekil 1.1: Elektrik üretiminde ilk 20 ülke (2015).....	3
Şekil 1.2: 2018 Yılı sonu Türkiye elektrik üretiminin kaynaklara dağılımı	5
Şekil 2.1: Tahminin yapı akışı.....	11
Şekil 3.1: Elektrik enerjisi talep tahmini model gösterimi.....	13
Şekil 4.1: Bir biyolojik sinir hücresinin yapısı	21
Şekil 4.2: Yapay sinir hücresi katmanları	25
Şekil 4.3: İleri ve geri beslemeli ağ yapısı	27
Şekil 4.4: Tek katmanlı algılayıcı(TKA) modeli	28
Şekil 4.5: Sınıf ayırıcı doğrusu	30
Şekil 4.6: ÇKA modeli.....	32
Şekil 5.1: 2008-2019 Denizli elektrik tüketim grafiği	44
Şekil 5.2: Optimum ağ yapısı.....	49
Şekil 5.3: Regresyon grafiği.....	49

TABLO LİSTESİ

Sayfa

Tablo 2.1: İçerdikleri veri miktarlarına dayanarak tahmin çeşidi sınıflandırması...9	
Tablo 4.1: Bazı toplama fonksiyonları24	
Tablo 4.2: Biyolojik sinir ağı ile yapay sinir ağının karşılaştırılması.....25	
Tablo 5.1: Simülasyon sonuçları.....48	
Tablo 5.2: Optimum ağ yapısı48	
Tablo 5.2: Simülasyon sonuçları.....49	
Tablo 5.3: 2018-2019 Elektrik tüketim tahmin sonuçları.....50	
Tablo 5.4: Gerçek ve tahmin değerlerinin karşılaştırılması51	

KISALTMALAR

GSYH: Gayrisafi Yurt İçi Hasılat

kWh: Kilovat Saat

BP: British Petroleum

EÜAŞ: Elektrik Üretim Anonim Şirketi

TEİAŞ: Türkiye Elektrik İletim Anonim Şirketi

IEA: International Energy Agency

EPDK: Enerji Piyasası Denetleme Kurulu

ABD: Amerika Birleşik Devleti

GW: GigaWatt

MW: MegaWatt

OR: Oto Regresif

HO: Hareketli Ortalama

YSA: Yapay Sinir Ağları

NOAA: National Oceanic and Atmospheric Administration

AVHRR: The Advanced Very High Resolution Radiometer

TÜİK: Türkiye İstatistik Kurumu

MAED: Model for Analysis of Energy Demand

MGM: Meteoroloji Genel Müdürlüğü

LMM: Levenberg-Marguardt metodu

ÇKA: Çok Katmanlı Algılayıcı

ÖNSÖZ

Tez çalışmam boyunca her anda destek olup sorularımı yanıtlayan, ilgi ve sabırla yaklaşp beni aydınlatan saygıdeğer danışman hocam Doç. Dr. Hacer GÜNER GÖREN' e en içten teşekkürlerimi sunarım.

Çalışmada kullandığım, Denizli elektrik tüketim verilerini sağlayan ADM Elektrik Dağıtım A.Ş yetkililerine teşekkürü bir borç bilirim.

Ayrıca her zaman yanımda olan sevgisini ve desteğini her yerde hissettiren, sahip olduğum için şanslı olduğum canım aileme; annem Selda DAMAR'a, anneannem Ayşe DAMAR'a, dedem Kadir Ali DAMAR'a ve sevgili eşim Gökhan ÖKSÜZ'e sonsuz teşekkürlerimi sunarım.

1. GİRİŞ

Günümüz dünya medeniyetinde enerji, önemli bir yaşam kaynağıdır. Enerjisiz bu medeniyetin sürdürülebilmesi neredeyse imkânsız görünmektedir. Bu kadar önemli olan bir konuda gerek dünyada gerekse Türkiye’de araştırmalar yapılması ve bu araştırmaların üzerinde düşünülmesi oldukça doğal bir durumdur. İnsanlık tarihi kadar eski olan enerjiye insanlar diğer canlılardan farklı olarak daha yoğun bir şekilde gereksinim duymaktadırlar. Enerji, fiziki bakımdan iş yapabilme kabiliyeti; enerji kaynağı ise uygun teknik kullanıldığı takdirde enerji verebilen maddeleri ifade eder. Enerji kaynakları değişik yöntemler ve teknikler kullanılarak elde edilir. Enerji kaynakları, genel kabul görmüş sınıflandırmaya göre yenilenebilir ve yenilenemez veya birincil ve ikincil enerji kaynakları olmak üzere iki kısma ayrılabilir (Yılmaz 2010).

Bunlar;

1.Yenilenemeyen Enerji Kaynakları: Doğada enerji kaynaklarının meydana gelişleri sebebiyle yenilenmeleri mümkün olmayan veya çok uzun zaman alan enerji kaynaklarına denir. Örneğin; kömür, petrol, doğalgaz.

2.Yenilenebilir Enerji Kaynakları: Doğada sürekli var olan ve kendilerini yenileyen enerji kaynaklarıdır. Bu kaynaklar, güneş, rüzgâr enerjisi, jeotermal enerji, hidroelektrik enerjisi gibi kaynaklardır. Bu kaynaklar çevre dostu kaynaklardır. Günümüzde popüler olan yenilenebilir enerji kaynaklarına yönelik çalışmalar gittikçe artmaktadır. Son yıllarda rüzgâr ve jeotermal şeklinde alternatif kaynaklara önem verilmektedir. Bu kaynaklar literatürde temiz enerji olarak da nitelendirilebilmektedir.


Örneğin güneş enerjisi, dünyada bitmeyen ve ekonomik sıkıntıdan etkilenmeyen bir enerji türüdür. Güneş enerjisi bitmeyen ayrıca zararlı atıkları olmayan bir enerji sistemidir. Ayrıca yenilenebilir enerji kaynaklarının kullanımının artırılması yenilenemeyen enerji kaynaklarının kullanımını azaltacaktır (Boltürk 2013).

1.1 Dünya’da Enerji ve Elektriğin Durumu

Enerji; ekonomik ve sosyal gelişmeyi sağlayan, teknolojik ilerlemenin çok önemli bir unsuru olan, hayat kalitesini iyileştiren en önemli faktördür. Dolayısıyla, dünyada enerjiye olan talebin miktarını ve kompozisyonunu en fazla nüfusta ve demografik özelliklerdeki değişiklikler etkilemektedir. Bilindiği üzere dünya nüfusu sürekli artmakta ve 2017’de 7,5 milyar olan nüfusun 2040’da 9,2 milyara yükselmesi beklenmektedir. Çin’in nüfusunu geçecek olan Hindistan’ın nüfusu 2040’da 1,6 milyara ulaşacaktır. Uzun dönemde (2017-2040 arası) ortalama %3,4 büyümesi beklenen dünya ekonomisi ile dünyadaki nüfus artışı, sanayileşme ve kentleşmenin yarattığı koşullarla birlikte, doğal kaynaklara ve enerjiye olan talebi önemli ölçüde arttırmaktadır (IEA 2019).

Tüm dünyada elektrik enerjisi kurulu güç kapasitesinin de 2017-2040 döneminde brüt 5.020 GW artması beklenmektedir. Bu bağlamda elektrik sektörünün, Uluslararası Enerji Ajansı tarafından hazırlanan Yeni Politikalar Senaryosuna göre 2018-2040 döneminde yapılması beklenen 60,0 trilyon dolarlık enerji yatırımlarındaki payının tek başına 20,0 trilyon dolar (2017 dolar değeriyle) olacağı öngörülmektedir.

2017 verilerine (BP 2018) göre, dünya elektrik üretiminde ilk yirmi ülke Şekil 1.1’ de gösterilmiştir. 2016 yılına göre sadece Türkiye iki basamak yükselmiştir. Türkiye 2017’deki yaklaşık 297,3 milyar kWh’ lik değeriyle dünyada 15. sırada yer almaktadır (TEİAŞ 2019).



Şekil 1.1: Elektrik üretiminde ilk 20 ülke (2017) (BP 2019)

1.2 Türkiye’de Enerji ve Elektrik Durumu

Türkiye’nin enerji politikası; enerji arz güvenliği, enerji ve doğal kaynaklarda öngörülebilir piyasalar, sürdürülebilir enerji ve çevre ile yerlileştirme ve teknoloji geliştirilmesi temaları gözetilerek belirlenmiştir. Bu enerji politikasının temel amaçları (T.C. Enerji ve Tabii Kaynaklar Bakanlığı 2018);

- Kaynak ve güzergâh çeşitlendirmesi çalışmalarının yapılması,
- Arama faaliyetlerinin artırılması,
- Enerji alt yapısının güçlendirilmesi,
- Enerjinin yüksek verimle kullanılması,
- Mevcut enerji kaynaklarının yanı sıra alternatif ve yenilenebilir enerji ile yerli kömür potansiyelinin azami ölçüde değerlendirilmesi,
- Enerji teknolojilerinde yenilikçi, AR-GE yoğun ve katma değeri yüksek yatırımlar yapılması,
- Yatırım ortamının yatırımcı tüm taraflar açısından da cazip tutulması,
- Çevre ile uyumlu ve sürdürülebilir bir yaklaşımın dikkate alınması,
- Milli enerji ve maden politikalarının geliştirilip sürdürülmesi,

- Gerek teknoloji gerekse ekipmanların yerlileştirme çalışmalarının yapılması (T.C. Enerji ve Tabii Kaynaklar Bakanlığı 2018).

Bu temalar temelinde oluşturulan başlıca hedefler de özetle şöyledir (T.C. Enerji ve Tabii Kaynaklar Bakanlığı 2018):


- Hem rüzgâr, hem de güneş enerjisinde 10 yıl içerisinde her bir kaynak için sisteme ilave 10'ar bin MW kapasite eklenmesi
- 3 ayrı sahada nükleer santral kurulmasına ilişkin çalışmaların devam ettirilmesi İlave 5.000 MW yerli kömüre dayalı kurulu gücün kurulması,
- Eskişehir, Afyon, Konya ve Trakya kömür sahalarında bulunan yaklaşık 3,5 milyar ton kömür rezervinin ekonomiye kazandırılması,
- Potansiyeli yüksek olan büyük kömür sahalarının yatırıma açılması

Ülkemizin yakaladığı yüksek büyüme oranları (2003-2017 yılları arasında ortalama %5,8), enerji talebinin de hızla artmasını (2003-2017 yılları arasında ortalama % 4,5) beraberinde getirmiştir. Önümüzdeki yıllarda da büyüme oranlarıyla birlikte enerji talebinin de artış eğiliminin devam edeceği hesaplanmaktadır (T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2018). Son 10 yılda Türkiye elektrik, kömür ve doğal gaz talep artış oranları bakımından Avrupa'da ilk sırayı almaktadır (BP 2018).

2018 yılında elektrik tüketimimiz bir önceki yıla (296,7 milyar kWh) göre %2,06 artarak 302,8 milyar kWh, elektrik üretimimiz ise bir önceki yıla göre (297,28 milyar kWh) %2,05 oranında artarak 303,38 milyar kWh olarak gerçekleşmiştir (TEİAŞ 2018-2019). Elektrik talebinin; 2027 yılında Yüksek Talep Senaryosunda (yıllık ortalama %5,6 artış öngörülen) 508,6, Düşük Talep Senaryosunda (yıllık ortalama %3,7 artış) ise 425,0 milyar kWh düzeyine ulaşacağı gösterilmektedir (TEİAŞ 2018)

Kaynaklar açısından bakıldığında, 2018 yılı itibariyle, toplam elektrik üretiminin %37,4'ü kömürden, %29,9'u doğal gazdan, %19,8'i hidrolik kaynaklardan, %6,6'sı rüzgârdan, %2,5'i jeotermalden, %0,3'ü sıvı yakıtlardan, %3,3'ü biyoyakıtlar ve güneş enerjisinden ve %0,2'si atık ısıdan karşılanmıştır (Şekil 1.2). 2017 yılı ile kıyaslandığında hidrolik kaynaklar, kömür, jeotermal, biyoyakıtlar, rüzgar ve güneşten yararlanma oranı artarken; doğal gaz, sıvı yakıtlar, atık ısıdan yararlanma oranında düşme görülmüştür.

EÜAŞ'ın bu üretimde 2016 yılında sahip olduğu pay %17,0'den, 2017 yılında %15,8'e, 2018 yılında ise %15,1'e düşerken, geri kalan %84,9'luk üretim ise özel sektör tarafından karşılanmıştır (EÜAŞ Raporu 2019).



Şekil 1.2: 2018 Yılı sonu Türkiye elektrik üretiminin kaynaklara dağılımı (EÜAŞ Raporu 2019).

1.3 Problem Tanımı

Nihai enerji tüketimindeki payı sürekli yükselen yegâne enerji kaynağı olan elektrik enerjisine yönelik talep, küresel ekonomik büyümeye paralel olarak, her geçen gün hızlı şekilde artmaya devam etmektedir. Oluşan talebin en düşük maliyetle ve en kaliteli biçimde karşılanması, arz ve çevre güvenliğinin sağlanması, günümüz çağdaş elektrik sistemleri tasarım ve kaynak planlamalarında temel hedefler haline gelmiştir. Söz konusu hedeflere ulaşılmasında en önemli ön koşulun, elektrik enerjisi talep tahminlerinin doğru yapılabilmesi olduğu değerlendirilmektedir. Üretilen ve depolanamayan elektriği; elektrik üretim santrallerinden alarak, tüketiciye ulaştıran elektrik dağıtım şirketleri için dağıtılacak olan elektrik miktarının planlanması önemli bir problem oluşturmaktadır. Bu nedenle Denizli ili mesken aboneleri için uzun dönemli elektrik tüketimi tahminleme çalışması yapılmıştır.

1.4 Tezin Amacı

Bu tez çalışmasında, Denizli ili için elektrik tüketim tahmini yapılması amaçlanmaktadır. Tahminler yapılırken 2008-2018 yıllarına ait elektrik tüketim miktarı, abone sayısı, elektrik birim fiyatları, işsizlik, sıcaklık gibi tüketim miktarına etki ettiği düşünülen değişkenler kullanılmış ve Denizli ili 2019-2023 dönemi için elektrik tüketim tahminlemesi yapılmıştır.

1.5 Tezin Önemi ve Literatüre Katkısı

Enerji, ülkelerin kalkınma politikaları içinde hayati önem taşıyan stratejik bir alandır. Enerji ihtiyacının; artan nüfus, artan sanayileşme ve gelişen teknolojilere bağlı olarak hızlı şekilde artış göstermesi enerji politikalarının önemini daha da arttırmaktadır. Enerji politikalarını belirleyebilmek için ise geleceğe yönelik güvenilir ve doğru tahminlere ihtiyaç duyulmaktadır. Elektrik dağıtım şirketlerinin temel işlevlerinden biri satacakları elektrik miktarını önceden tahmin etmeleridir. Bunlar için farklı dağıtım şirketlerinin kullandıkları farklı yöntemler vardır. Kendilerinden elektrik talep eden firmaların ileride ne kadar elektrik talep edeceğini öngörmek önemli bir durumdur. Bu tez çalışmasında, enerji talep tahminleme çalışması ile geleceğe ışık tutan ve literatüre katkı sağlayan bir çalışma yapılması amaçlanmıştır. Yapılan literatür araştırmasına göre Denizli ili özelinde mesken aboneleri için elektrik tüketim tahminleme çalışmasının daha önce yapılmadığı gözlenmiştir. Denizli mesken aboneleri özelinde bu şekilde bir elektrik tüketim tahminleme çalışmasının yapılmamış olması, bu çalışmanın literatüre olan bir katkısıdır.

1.6 Tezin Organizasyonu

Elektrik tüketim tahmini için ele alınan çalışmanın giriş bölümünde enerjinin ve elektriğin dünya ve ülkemizdeki durumu, problemin tanımı, tezin amacı, tezin önemi ve literatüre katkısı açıklanmıştır. İkinci bölümde talep tahminin önemi ve sınıflandırılmasından, tezin üçüncü bölümünde elektrik talep tahminin etkileyen faktörlerden, elektrik tüketim tahmininde kullanılan yöntemlerden ve literatürde yapılan çalışmalardan, tezin dördüncü bölümünde elektrik tüketim tahmininde kullandığımız yöntem olan yapay sinir ağlarından bahsedilmiştir.

Beşinci bölümde ise yapay sinir ağı yöntemi kullanılarak MATLAB programı yardımı ile Denizli ili için yapılan elektrik tüketim tahmini uygulaması aktarılmıştır ve yapılan çalışma sonucunda elde edilen bulgular açıklanmıştır. Son bölümde ise elde edilen bulgular tartışılmış ve gelecek çalışmalar belirtilmiştir.



2. TALEP TAHMİNİ

2.1 Talep Tahminin Önemi

Tahmin çoğu operasyonel aktiviteler için gerekli bir ön ihtiyaçtır. Geleceği tahmin etmeden beklenen aktivitelerin miktarını planlamak; tasarımı yapılacak, planlanacak ve kontrol edilecek kaynakları tahmin etmek olası değildir (Lewis 2012). Talep tahmini sadece enerjide olmayıp başka alanlarda da önemlidir. Yapılacak olan planlamalarda, maliyet analizlerinde, ithalat-ihracat durumlarında ve satış gibi çalışmalarda insanlar önünü görmek isteyeceklerdir. Talep tahmini bu noktada öne çıkmaktadır. Talep tahmini öncelikle planlama için önemlidir. Birçok sektörde ve konuda önemli olmasına rağmen elektrik için ayrı bir önemlidir. Çünkü elektrik depolanamayan bir enerjidir. Elektrik tahminini gerçek tüketimden az tahmin edildiği zaman elektrik kesintilerine gidilmektedir. Bu durum elektrik şirketlerini elektrik tasarruflarına zorlayacaktır. Ülke bazında bakıldığında ise kişilerin refah düzeylerinde ve ekonomi büyümede önemli bir değişim meydana gelecektir.

Elektrik tahmininin gerçekleşen tüketimden fazla olması durumunda ise fazladan elektrik ücreti ödenmiş olacaktır. Tahminleme çalışmaları ile boş yere ödenen elektrik tüketim ücretlerinin önü kesilecektir. Yani tahmin edilecek tüketim miktarı ne kadar gerçekçi olursa o kadar iyi bütçeleme planı yapılabilir. Bu konuda şirketler kendi tüketim miktarlarını ve elektrik tüketimlerini etkileyen değişkenleri içeren doğru modeller bulmaya çalışmaktadır. Bunları gerçekleştirmek için zaman serisinde yer alan verilerin sayısı önemli olmaktadır (Boltürk 2013).

2.2 Talep Tahmininin Sınıflandırılması

Talep formları günlük, haftalık veya yıllık olarak gösterilebilir. Zaman aralıkları bakımından elektrik tahmini genelde kısa, orta ve uzun vadeli olarak üç şekilde sınıflandırılabilir. Bunlar için değişik zaman aralıkları verilebilir. Gelişen ülke ekonomileri ile kısa dönemli tahmin yapmak önemli bir hale gelmiştir. Özellikle elektrik yük tahmini yapılırken, elektriğin meteorolojik durumlardan, mevsimsel durumlardan ve özel olaylardan etkilenmesi kısa dönemli tahmin

yapmayı gerektirmektedir. Kısa dönemli tahmin yapmanın yanı sıra tek değişkenli analiz yapmak da tahmin doğruluğunu ve verimliliğini artırmaktadır. Aynı zamanda kısa dönem yük tahminleri güç sistemlerinin kontrol ve planlamasında gerekmektedir (Boltürk 2013). Tablo 2.1’ de Colin D. Lewis’in yapmış olduğu bir sınıflandırma gösterilmektedir.

Tablo 2.1: İçerdikleri veri miktarlarına dayanarak tahmin çeşitlerinin sınıflandırılması (Lewis 2012).

Tahmin Sınıfı	Zaman Aralığı	Örnek Uygulama	Kullanılan Tahmin Çeşitleri
Acil Dönem	1:4 saat-1 gün	Elektrik Talep Tahmini	Çeşitli
Kısa Dönem	1 hafta-1 ay	Ticarette Ve Endüstride Talep Tahmini	Üstel Ağırlıklı Ortalama ve Türevleri
Orta Dönem	1 ay- 1 yıl	Satış Ve Finans Tahmini	Regresyon, Eğri Uydurma, Zaman Serisi Analizi
Uzun Dönem	1 yıl- 10 yıl	Teknolojik Tahmin	DELPHİ, Think Tanks ve Benzeri

Bir başka kaynakta ise, zaman dönemleri; acil dönem 6 saat- 24 saat, kısa dönem tahmin 3 ay ile 1 yıl, orta dönem tahmin ise 1 ile 10 yıl, uzun dönem ise 10 ile 25 yıl şeklinde ele alınmıştır (Ziebig ve Hoinka 2013).

Başka bir kaynakta da kısa dönemli tahminler birkaç saatten birkaç haftaya kadar zaman dilimini içine alan tahminler olmaktadır. Bu tahminler işletmenin yapacağı ekonomik yük paylaşımı, hidro-termal koordinasyonu ve yük idaresi gibi günlük operasyonlarını belirlemede önemli rol oynamaktadır. Orta dönem tahminler birkaç haftadan birkaç aya, hatta birkaç yıla kadar yapılan çalışmalarını içine alır. Yakıt temini planlaması, ünitelerin bakım zamanlarının belirlenmesi gibi konularda etkilidir. Genellikle aylık yük ve enerji talebi tahminlerini içerir. Uzun vadeli tahminlerin beş ile yirmi beş yıl için geçerli ve sağlıklı öngörü sağlaması istenir. Dolayısı ile üretim ve iletim sistemlerinin genişletilmesine ait planlarda ihtiyaç duyulur (Gültekin 2009). Bildiğimiz gibi, her tahmin modeli sistem

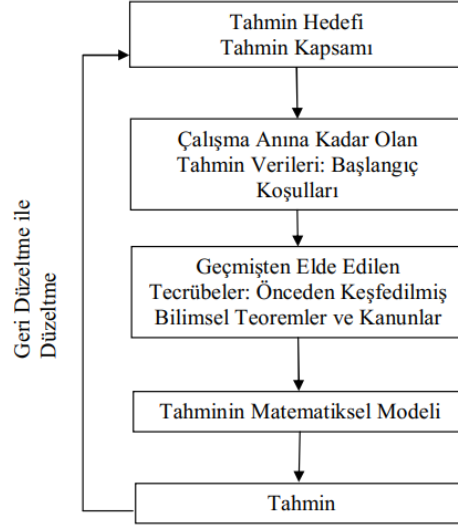
karakteristiğini elde etmeyi amaçlar. Sistem dinamikleri ile ilgili ne kadar çok bilgi olursa, tahmin o kadar iyi olur (Tsaur ve Kuo 2011).

Enerji kullanım oranlarının sürekli bir yükseliş içinde olması; enerji kaynaklarının önemli bir bölümünün tükenme sürecine girmesi, enerji fiyatları konjonktürel gelişmelere bağlı olarak büyük dalgalanmalar göstermektedir. Özellikle de, 1973-74 yıllarında petrol fiyatlarının 5 katına çıkmasıyla başlayan ve 1978-79 yıllarında tekrarlanan petrol krizlerinin ve fosil yakıtların yakın bir gelecekte tükeneceği beklentisinin yaygınlaşmasının etkisiyle, tüm dünyada enerji kaynaklarının ucuz ve sınırsız olduğu varsayımına dayanan politikalar terk edilmeye ve enerji planlamasına verilen önem artmaya başlamıştır. Bu kapsamda, yeni rezervlerin araştırılması, dışa bağımlılığın azaltılması, kaynak çeşitliliğinin artırılması, en ekonomik seçeneklerin ortaya konulması, enerjinin verimli kullanılması, enerji verimliliğini artırıcı yeni teknolojilerin geliştirilmesi ve arz-talep dengelerinin en optimum biçimde kısa, orta ve uzun vadeli olarak kurulmasına yönelik çalışmalar hız kazanmıştır (Gültekin 2009).

Talep tahmininin etkili yapılabilmesi de önemli bir konudur. Bunun için Chopra ve Meindi (2012) altı adımlı bir yaklaşım önermişlerdir.

1. Tahminin amacını anlamak,
2. Tedarik zincirine talep planlamasını ve tahmini entegre etmek,
3. Müşteri segmentlerini anlamak ve tanımlamak,
4. Talep tahminlerini etkileyen majör faktörleri tanımlamak,
5. Uygun tahmin tekniğine karar vermek,
6. Tahmin için performans ve hata ölçütlerini kurmak.

Talep tahmininde önemli bir konu da tahmin algoritmasını iyi anlamaktır. Tahmin yapılırken tahminin hedefi, kapsamı, uygun koşulların var olup olmaması gibi gerekli adımlar yer almaktadır. Şekil 2.1'de tahminin akış algoritması verilmiştir.



Şekil 2.1: Tahminin akış yapısı (Ziebig ve Hoinka 2013).

3. ELEKTRİK TALEP TAHMİNİ

3.1 Elektrik Talebini Etkileyen Faktörler

Elektrik tüketimi bölgesel, mevsimsel ve anlık dalgalanmalar göstermektedir. Yıl içinde en düşük tüketimle en yüksek tüketim miktarları arasında veya aynı gün içinde en düşük yükü en yüksek yük arasında %200'e varan farklar oluşabilmektedir (Gültekin 2009).

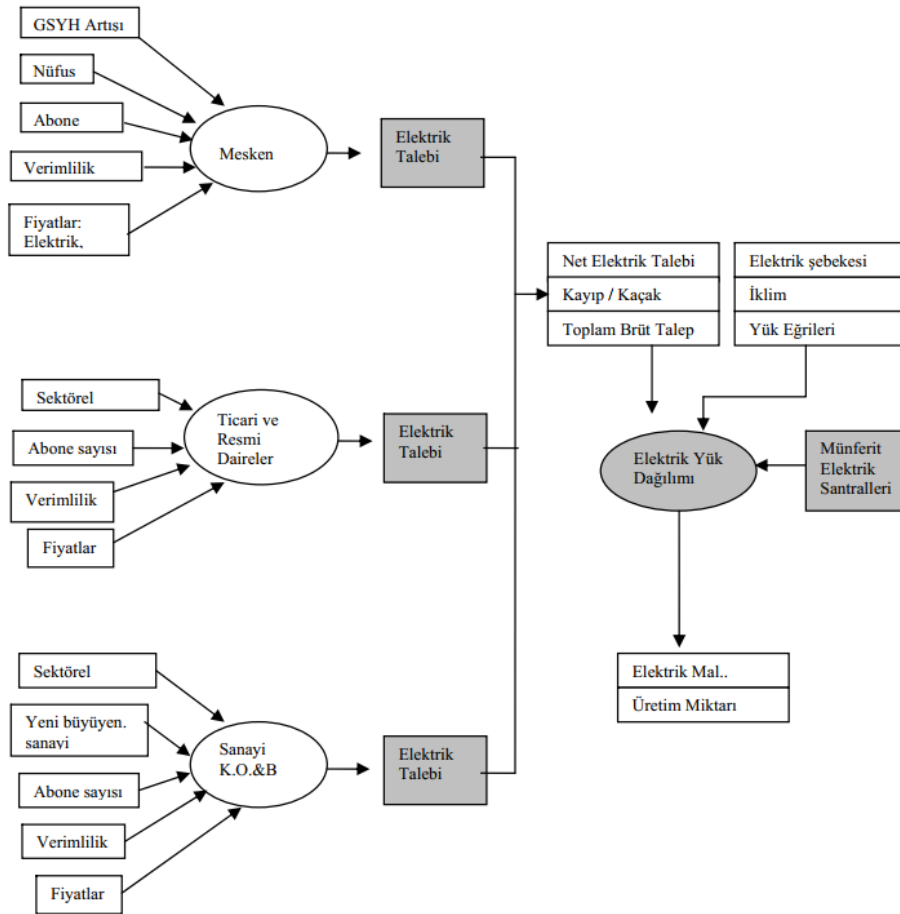
Elektrik talebinin aşırı değişkenliği ve elektriğin depolanamayan bir enerji kaynağı olması nedeniyle, elektrik arzının sürekli ve kesintisiz bir şekilde yapılması ve talebin anlık olarak karşılanabilmesi gerekmektedir. Bunun gerçekleştirilememesi halinde ise, Türkiye'de 1971–1983 yıllarında görüldüğü gibi, zorunlu tasarruf ve kesinti uygulamalarına gidilmesi gündeme gelecektir. Elektrik talebine etki eden faktörler ekonomik büyüme hızı ile sınırlı bulunmamaktadır. Talebi etkilediği saptanan faktörler, etki derecelerine bağlı olarak elektrik talep tahmin modellerinde 'girdi' olarak kullanılmaktadır (Gültekin 2009).

Talep tahminine etki eden faktörleri Gültekin (2009) şu şekilde sıralanmıştır.

- GSYH,
- Sektörel katma değerler,
- Kişi başına düşen milli gelir,
- Nüfus ve demografik değişiklikler,
- Hane halkı sayısı ve ortalama hane halkı büyüklüğü,
- Çok odalı konut yüzdesi ve konut sahipliği artış oranı,
- Şehirleşme oranı,
- Şehir ve köy gelirleri,
- Elektrikli hane ve köy oranı,
- Elektrikten yararlanan nüfus oranı,
- İstihdam verileri,
- Teknolojik gelişmeler ve elektrikli iş aletleri kullanımının yaygınlaşma oranları,
- Kişi başına düşen elektrikli alet sayısındaki değişmeler,

- Elektrikli aletler ve ilgili ikamelerinin fiyatları,
- Elektrik fiyatı,
- Alternatif enerji kaynaklarının fiyatları,
- Mevsimsel değişiklikler ve iklim koşulları,
- Ülkelerin coğrafi özellikleri,
- Zaman.

Bu faktörler haricinde ülkelere göre değişen ve elektrik talebini etkileyen değişkenler olabilmektedir. Gelişmiş elektrik talep tahmin modellerinde, yukarıda belirtilen faktörler dikkate alınarak, sektörel bazda net elektrik talepleri tahmin edilip, bunların toplamına kayıp ve kaçak öngörülürü eklenmek suretiyle brüt talep hesaplanmaktadır. Sektörel elektrik talep tahmin modeline ilişkin bir prosedür, Şekil 3.1’de yer alan şemada gösterilmektedir.



Şekil 3.1: Elektrik enerjisi talep tahmini model gösterimi (Gültekin 2009)

3.2 Elektrik Tahmininde Kullanılan Yöntemler

Elektrik tüketimi tahmininde kullanılan yöntemlerin açıklamaları aşağıda verilmiştir (Boltürk 2013).

Zaman Serisi Modelleri: Modellerin en basit olanıdır. Eğilim analizi yöntemi kullanılmaktadır. Elde bulunan verilerin gerçeği temsil edeceği varsayılmaktadır.

Regresyon Modelleri: Regresyon modellerinde bağımlı değişkenin bağımsız değişkenler tarafından etkilendiği ve bağımsız değişkenlerin bağımlı değişkenleri ne kadar ve ne yönde etkilediği bulunmaktadır. Regresyon modeli elektrik ihtiyacını tahmin etmek için kullanılmaktadır. Ayrıca bu model elektrik yük tahmininde de kullanılmaktadır. Az sayıda parametre gerektirmektedir.

Hareketli Ortalama: Zaman serisindeki uygun bir periyod seçilerek geleceği ortalama olarak tahmin etme yöntemidir.

Üstel Düzeltme: Burada sürecin sabit olduğu varsayılmaktadır. Verilere ağırlıklar verilmektedir. Daha gerçekçi bir sonuç elde etmek için veri setinde yer alan son verinin ağırlığı daha fazla olacak şekilde ağırlıklar atanmaktadır.

ARIMA Modelleri (Auto Regressive Integrated Moving Agerage): Yapay sinir ağları ve diğer hesaplama teknikleriyle beraber enerji talep tahmininin doğruluğunu geliştirmek için kullanılmaktadır. İstatistiksel bir yöntem olup OR (Oto Regresif) ve HO (Hareketli Ortalama)'nın birleşiminden meydana gelmektedir. ARIMA (p,d,q) şeklinde gösterilmektedir. Zaman serisinin özelliklerine göre p, d, q değerleri değişmektedir.

Box-Jenkins Modelleri: Kısa dönemli tahminlerde başarılıdır. Eşit zaman aralıklarında oluşan verinin kesikli ve durağan olması modelin bir özelliğidir. Amaç zaman serisine en iyi uyan modeli oluşturmaktır. ARIMA yöntemi olarak da geçmektedir.

Yapay Sinir Ağları Modelleri: Sinir ağlarından oluşturulan sistemlerdir. İnsanların nörolojik yapısı göz önüne alınmaktadır. Sisteme girdi ve çıktılar önceden verilir, böylece sistemin öğrenmesi sağlanmaktadır. Yani sistem veriye

göre kendine şekil verir. Sisteme en uygun nöron sayısı bulunmaktadır ve sistem eğitilmektedir. Eğitilen sistem tahmin yapabilmektedir.

Bulanık Mantık: Sistemlerin belirsiz olduğundan yola çıkarak bir tahmin yapılmaktadır. Bu yöntemde grafik ya da aralıklar oluşturulmaktadır. Verilerden oluşturulan bir üyelik fonksiyonu yer almaktadır. Üyelik fonksiyonlarına veriler yerleştirilmekte ve tahmin sisteme göre gerçekleştirilmektedir.

Gri Tahmin Modelleri: Girdilerin kesin olmadığı belirsiz durumlarda ve bilginin eksik olmasından kaynaklanan durumlarda kullanılan modeldir. Az sayıda parametre gerektirmektedir.

Ekonometrik Modeller: Bu modellerde girdi olarak nüfus, gelir, fiyat değişimleri yer almaktadır. Bu değişkenlerden yararlanarak istatistiksel yöntemler ile çözüme ulaşılmaktadır.

Baş Aşağı Modeller-MARKAL/TIMES/ UVEAPS: MARKAL bir çeşit lineer programlama modelidir. IEA tarafından geliştirilmiştir (Suganthia ve Anand 2012).

Metasezgisel Yöntemler: Metasezgisel yöntemler, yerel arama, benzetilmiş tavlama, tabu arama, genetik algoritmalar, evrimsel hesaplama, karınca kolonisi eniyilemesi gibi birçok farklı yöntemden oluşmaktadır. Bu yöntemler, farklı yönler göz önünde bulundurularak çeşitli şekillerde sınıflandırılabilir. Temel olarak metasezgisel yöntemler, doğadan esinlenen ve doğadan esinlenmeyen yöntemler, dinamik ve statik amaç fonksiyonuna sahip yöntemler, bir komşuluk yapısına ve değişken komşuluk yapısına sahip yöntemler, hafıza kullanan ve kullanmayan yöntemler ve tek çözüme dayalı ya da toplum tabanlı metasezgisel yöntemler olarak sınıflandırılabilir (Blum ve Roli 2003).

Bunların haricinde Hibrit Modeller, UVEAPS (Uzun Vadeli Enerji Alternatif Planlama Sistemi), Girdi-Çıktı Modelleri, Birleşik Modeller-Bayesian Vektör Otoregresyonu, Bayesian Vektör Otoregresyonu, eş-bütünleşim modelleri gibi modellerde tahmin modellerinde uygulanmıştır (Suganthia ve Anand 2012). Herhangi bir veri setinde tahmin yaparken tahmin doğruluğunu artırmak isteyen araştırmacılar birkaç model karması olan hibrit modelleri kullanmışlardır ve sonuçları hata oranlarına göre kıyaslamışlardır. Hibrit modeller tek yöntemli

modellere göre daha iyi sonuç verdiđi genel bir gözlemdir (Suganthia ve Anand 2012).

3.3 Literatürde Elektrik Tahmini İle İlgili Çalışmalar

Elektrik tüketim tahmini ile ilgili yapılmış olan literatürdeki bazı çalışmalar aşağıda belirtilmiştir.

Yuan ve diğ. (2018) çalışmalarında yapay sinir ađları ile Osaka Üniversite kampüsü için elektrik tüketim tahminlemesini yapmışlardır. Haftanın günü, saati, sıcaklık, saatlik küresel ışınım, elektrik tüketimi verileri ile YSA girdileri oluşturulmuştur. Levenberg Marquardt geri yayılım algoritması kullanılmıştır. YSA doğruluğunun tespiti korelasyon katsayısı(R) ve ortalama hata kareleri toplamı(RMSE) ile ölçümlenmiştir.

Marvuglia ve Messineo (2011) çalışmalarında yapay sinir ađları ile İtalya-Palermo kenti için mesken abonelerinde saatlik elektrik tüketim tahminlemesi yapmışlardır. Elektrik tüketimi ve hava durumu verileri girdi olarak kullanılmıştır. Ayrıca, incelenen alandaki klimaların varlığı ve kullanımıyla ilgili özel bir girdi modele eklenmiştir. 1 haftalık saatlik gerçek ve tahmin verileri karşılaştırılmış ve duyarlılık analizi yapılmıştır.

Ođurlu (2011) çalışmasında elektrik enerjisinin son kullanıcılara ekonomik, kaliteli ve sürekli olarak sağlanabilmesi için yapılan planlama çalışmalarının önemi vurgulanmıştır. Yapılacak planlamanın en önemli unsuru olan geleceđe dönük tahmin yöntemleri detaylı biçimde incelenmiş ve 2010 – 2025 yılları arasındaki yıllık tüketilen toplam enerji miktarları ve puant günde tüketilen enerji miktarları tahmin edilmiştir. Buna göre geçmiş yıllara ait, enerji tüketimi ile ilişkili olan verilerden uygun matematiksel modeller oluşturulmuş ve gelecek yıllara ait sonuçlar elde edilmeye çalışılmıştır. MAED, Regresyon analizi ve yapay sinir ađları yöntemleri kullanılmıştır. Yapılan tahminden elde edilen veriler daha önceden farklı yöntemler kullanılarak yapılmış olan diđer akademik çalışmalar ile kıyaslanmıştır.

Ekonomou (2010) çalışmasında yapay sinir ađlarını kullanarak Yunanistan için uzun dönem elektrik tüketim tahminlemesi yapmıştır. 2005-2008 tüketim verileri tahminleme çalışması yapılmış ve gerçek verileri ile karşılaştırılmıştır.

2010,2012 ve 2015 için ileri dönem tahminlemesi yapılmıştır. Çok katmanlı yapay sinir ağı kullanılmıştır.

Akın (2010) çalışmasında Türkiye’de hane halklarının elektrik enerjisi tüketimini etkileyen faktörleri araştırmıştır. Hanenin anket ayındaki elektrik fatura giderinin, hane halkına ait konut özelliklerinin, hane halkı yapısının ve gelirinin elektrik talebini belirleyen etkenler olduğu tespit edilmiştir. Ayrıca bahsedilen bu etkenlerin marjinal etkileri hesaplanmıştır. Çalışmada Türkiye İstatistik Enstitüsü tarafından yayınlanan Türkiye Hane Halkı Bütçe Anketi 2008 verileri kullanılmış ve sıralı logit modeli uygulanmıştır.

Yılmaz (2010) çalışmasında Tokat ili elektrik enerjisi talep tahmini en küçük kareler yöntemi ile yapılmıştır. Tahminler yapılırken geçmiş yıllara ait elektrik tüketim miktarı, fiyatları, abone sayısı ve kişi başına düşen elektrik talep miktarı gibi değişkenler kullanılarak 1994–2009 yılları arası Tokat ili elektrik enerjisi talep tahmini, 2010 – 2015 dönemi için elektrik, nüfus ve kişi başına düşen Tokat ili elektrik enerjisi talep tahmin projeksiyonları yapılarak, Tokat ili ile Türkiye geneli ve komşu illerin mukayesesi yapılmıştır.

Azede ve diğ. (2007) çalışmalarında yapay sinir ağları, zaman serisi ve Anova yöntemini kullanarak İran-Tahran elektrik tüketim tahminlemesi yapmışlardır. 20 yılın aylık elektrik tüketimi ele alınmıştır. Son 12 ay girdi verisi olarak çıktı bir sonraki tahmin için girdiyi oluşturacak şekilde modellenmiştir. Gerçek tüketim verileri ile karşılaştırma yapılmıştır. Varyans analizi ile yapay sinir ağları tahminlemesi doğrulanmıştır.

Erdoğdu (2006) çalışmasında eşbütünleşme analizi ve otoregresif entegre hareketli ortalama (ARIMA) modellemesi kullanılarak, hem elektrik talebi tahmini hem de tahmini sağlayarak ve tahminleri resmi sonuçlar ile karşılaştırılmıştır. 1923-2004 yılları arası toplam 82 gözlem verileri ile çalışma yapılmıştır. Tüketicilerin fiyat ve gelir değişikliklerine cevap vermesinin oldukça sınırlı olduğu Türkiye elektrik piyasasında, ekonomik düzenlemeye ihtiyaç olduğu sonucuna varılmıştır.

Geoffrey ve diğ. (2005) çalışmalarında regresyon analizi, karar ağacı yöntemi, yapay sinir ağları metodu ile Çin-Hong Kong elektrik enerjisi tüketimini tahmin edilmesini ve bu metodların karşılaştırmasını yapmışlardır. Bir anket çalışması ile aylık tüketimi 100 kWh üzeri olan hane halkları için veri

düzenlenmiştir. Yaz ve kış olarak iki fazlı tahminleme çalışması yapılmıştır. Elektrik tüketimini etkileyen faktörler de incelenmiştir. Yaz için klimanın önemli bir faktör olduğu, kış dönemi için ise konut tipi, hane halkı sayısı ve su ısıtıcısı faktörlerinin etkili olduğu ve kış dönemi için bu etkili faktörler ile oluşturulan YSA modelinin iyi sonuçlar verdiği belirtilmiştir.

Lise ve Montfort (2005) çalışmalarında Türkiye'deki enerji tüketimi ve GSYİH arasında ilişkiyi 1970 ve 2003 yılları arasındaki yıllık verileri kullanarak eş bütünlük analizi ile birlikte incelemişler. Analizde enerji tüketimi ve GSYİH arasındaki nedenselliğin çift yönlü olduğunu, ikisinin arasında sebep sonuç ilişkisi olduğunu belirtmişlerdir. Türkiye'de enerji tüketimi ve GSYİH'nın 2025 yılına kadar yılda % 5,9 ve % 7 büyümesinin bekleneceğini ifade etmişlerdir.

Hamzaçebi ve Kutay (2004) çalışmalarında 1970–1990 yıllarına ait veriler kullanarak regresyon tekniği ve yapay sinir ağları ile Türkiye'nin elektrik enerjisi tüketiminin 2010 yılına kadar tahmini yapılmıştır. Geçmiş yıllara ait elektrik enerjisi tüketimi değerleri ve nüfus bilgileri kullanılmıştır. YSA tekniklerinin bir tahmin aracı olarak kullanılabilirliği ve oldukça iyi sonuç verdiği belirlenmiştir.

Kalaitzakis ve diğ. (2002) çalışmasında Yunanistan'nın Girit adasındaki güç istasyonundan alınan saatlik elektrik tüketim verileri kullanılarak, 24 saat sonrası için tahmin edilen değerler YSA modelinin farklı algoritmaları yardımıyla bulunmuştur. Elde edilen sonuçlar tartışılmıştır.

Yalçınöz ve diğ. (2002) çalışmalarında 1991 -2001 yılları aylık tüketim değerlerini ele alarak 2001–2004 yılları için tüketim tahminlemesi yapmışlardır. Hareketli ortalamalar yöntemi ve yapay sinir ağları ile Niğde bölgesinin elektrik enerjisi yük tahminini yapmışlardır. 2001 yılı gerçek verileri ile karşılaştırma yapılmıştır.

Hengirmen (1999) çalışmasında, Gaziantep ili için beş yıllık elektrik enerjisi tüketimi tahminini basit doğrusal regresyon, üstel regresyon ve hareketli ortalamalar yöntemi kullanarak gerçekleştirmiştir. Çalışmada girdi değişkeni olarak geçmiş yıllara ait tüketim değeri kullanılmıştır. Uygulanan tahmin yöntemleri karşılaştırılmış ve en iyisi araştırılmıştır. Sonuç olarak Gaziantep ili için en iyi yöntemin hareketli ortalamalar yöntemi olduğunu belirtmiştir.

4. YAPAY SINİR AĞLARI

Yapay sinir ağı (YSA), insan beyninden esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapılarıdır. Yapay sinir ağı, bir başka deyişle, biyolojik sinir ağını taklit eden bilgisayar programlarıdır. Yapay sinir ağı zaman zaman bağlantıcılık (connectionism), paralel dağıtılmış işlem, sinirsel-işlem, doğal zeka sistemleri ve makine öğrenme algoritmaları gibi isimlerle de anılmaktadır. Yapay sinir ağı bir programcının geleneksel yeteneklerini gerektirmeyen, kendi kendine öğrenme düzenekleridir. Bu ağı öğrenmenin yanı sıra, ezberleme ve bilgiler arasında ilişkiler oluşturma yeteneğine de sahiptir. Yapay sinir ağı insan beyninin bazı organizasyon ilkelerine benzeyen özellikleri kullanmaktadırlar. Yapay sinir ağı bilgi işleme sistemlerinin yeni neslini temsil ederler. Genel olarak yapay sinir ağı model seçimi ve sınıflandırılması, işlev tahmini, en uygun değeri bulma ve veri sınıflandırılması gibi işlerde başarılıdır. Geleneksel bilgisayarlar ise özellikle model seçme işinde verimsizdir ve sadece algoritmaya dayalı hesaplama işlemleri ile kesin aritmetik işlemlerde hızlıdırlar (Elmas 2007).

4.1 Yapay Sinir Ağlarının Tarihçesi

Yapay sinir ağlarının tarihçesi nörobiyoloji konusuna insanların ilgi duyması ve elde ettikleri bilgileri bilgisayar bilimine uygulamaları ile başlamaktadır. İnsan beyninin nasıl çalıştığı ve fonksiyonları uzun yıllar araştırılmıştır. 1940' dan önceki yıllarda bazı bilim adamlarının yapay sinir ağı kavramı üzerinde çalışmalar yapılmıştır ancak bu çalışmaların mühendislik değerinin olduğu pek söylenememektedir. 1940'lı yıllardan sonra Hebb (1949), McCulloch ve Pitts (1943) gibi bilim adamlarını yapılan araştırmaları mühendislik alanına kaydırmaya ve günümüzdeki yapay sinir ağlarının temelini oluşturmaya başlamışlardır. İlk yapay sinir hücresinin yapısını oluşturmuşlar ve yapay sinir hücreleri ile her türlü mantıksal ifadeyi formüle etmenin mümkün olduğunu göstermişlerdir. Hücrelerin birbiri ile paralel çalışması fikrini ortaya atarak öğrenme kurallarını belirlemeye başlamışlardır.

1949 yılında Donald Hebb, yapay hücrelerden oluşan bir yapay sinir ağının değerlerini değiştiren bir öğrenme kuralı geliştirmiştir. “Hebbian öğrenme” kuralı denilen bu kural günümüzde de birçok öğrenme kuralının temelini oluşturmaktadır (Hebb 1949).

1954 yılında Farley ve Clark (1954) tarafından rassal ağlar ile adaptif tepki üretme kavramı ortaya atılmıştır ve bu kavram sonraları 1958 yılında Rosenblatt ve Caianiello tarafından geliştirilmiştir. Özellikle tarafından geliştirilen algılayıcı model (perceptron) yapay sinir ağları tarihinde önemli bir gelişmeye öncülük etmiştir. Bu model daha sonra çok katmanlı algılayıcıların temelini oluşturmuştur (Farley and Clark 1954).

1956’lı yıllarda Widrow ve Holf (1956) tarafından, Adaline ve Widrow öğrenme algoritmasının geliştirmesi çalışmaları yapılmıştır (Widrow and Holf 1956). 1960’lı yıllarda Nilson tarafından “Öğrenen makineler” adlı ilk makine öğrenme kitabı yazılmıştır (Nilson 1960).

1970’lerin sonlarına doğru Fukushima görsel şekil ve örüntü tanıma amaçlı geliştirdiği Neocognitron modelinin tanıtmıştır (Fukushima 1982). Bu modelde ara katmanlar kullanılarak öğrenme konusuna değinilmiştir. 1982 ve 1984 yıllarında Hopfield tarafından yayınlanan çalışmalarda yapay sinir ağlarının genelleştirilebileceği ve özellikle bilgisayar programlama ile çözülmesi zor olan problemlere çözüm üretilebileceği gösterilmiştir (Hopfield 1982).


1987 yılından bu yana her sene değişik sempozyum ve konferanslar ile yapay sinir ağları tartışılmakta ve yeni modeller ve öğrenme teknikleri ortaya atılmaktadır (Öztemel 2003).

4.2 Yapay Sinir Ağlarının Yapısı ve Temel Elemanları

4.2.1 Biyolojik Sinir Hücresi

Biyolojik sinir ağları beynimizde bulunan birçok sayıda sinir hücresinin bir koleksiyonudur. Bir sinir ağı milyarlarca sinir hücresinin bir araya gelmesi ile oluşmaktadır. Biyolojik sinir ağlarının performansları küçümsenemeyecek kadar yüksek ve karmaşık olayları işleyebilecek yetenektedir. Yapay sinir ağları ile bu yeteneğinin bilgisayara kazandırılması amaçlanmaktadır (Öztemel 2003).

Yapay sinir ağları biyolojik sinir ağlarının modellenmesi olduğu için, öncelikle biyolojik sinir sisteminin yapısına bakmak gerekir. Biyolojik sinir sisteminin temel yapı taşı olan nöronların yapısı dört ana bölümden oluşmaktadır; dendrit, akson, çekirdek ve bağlantılar. Dendritler sinir hücresinin ucunda bulunan ve ağaç kökü görünümüne sahip bir yapıya sahiptir. Dendritlerin görevi bağlı olduğu diğer nöronlardan veya duyu organlarından gelen sinyalleri çekirdeğe iletmektir. Çekirdek dendrit tarafından gelen sinyalleri bir araya toplayarak ve aksona iletir. Toplanan bu sinyaller akson tarafından işlenerek nöronun diğer ucunda bulunan bağlantılara gönderilir. Bağlantılar ise yeni üretilen sinyalleri diğer nöronlara iletir.



Şekil 4.1: Bir biyolojik sinir hücresinin yapısı (Öztemel 2003)

4.2.2 Yapay Sinir Hücresi

Yapay sinir hücreleri de biyolojik sinir hücrelerine benzer yapıdadır. Yapay nöronlar da aralarında bağ kurarak yapay sinir ağlarını oluştururlar. Aynı biyolojik nöronlarda olduğu gibi yapay nöronların da giriş sinyallerini aldıkları, bu sinyalleri toplayıp işledikleri ve çıktılarını ilettikleri bölümleri bulunmaktadır. Bir yapay sinir hücresi beş bölümden oluşmaktadır;

- Girdiler
- Ağırlıklar
- Toplama Fonksiyonu (Birleştirme Fonksiyonu)
- Aktivasyon fonksiyonu
- Çıktılar

Girdiler: Girdiler nöronlara gelen verilerdir. Girdiler yapay sinir hücresine bir diğer hücreden gelebileceği gibi direk olarak dış dünyadan da gelebilir. Bu girdilerden gelen veriler biyolojik sinir hücrelerinde olduğu gibi toplanmak üzere nöron çekirdeğine gönderilir.

Ağırlıklar: Yapay sinir hücresine gelen bilgiler girdiler üzerinden çekirdeğe ulaşmadan önce geldikleri bağlantıların ağırlığıyla çarpılarak çekirdeğe iletilir. Bu sayede girdilerin üretilen çıktı üzerindeki etkisi ayarlanabilmektedir. Bu ağırlıkların değerleri pozitif, negatif veya sıfır olabilir. Ağırlığı sıfır olan girdilerin çıktı üzerinde herhangi bir etkisi olmamaktadır.

Toplama Fonksiyonu: Toplama fonksiyonu bir yapay sinir hücresine gelen girdileri ağırlıkları ile çarpıp toplayarak o hücrenin net girdisini hesaplayan bir fonksiyondur.

Tablo 4.1: Bazı toplama fonksiyonları (Öztemel 2003)

Toplam $Net = \sum_{i=1}^N X_i * W_i$	Ağırlık değerleri girdiler ile çarpılır ve bulunan değerler birbiriyle toplanarak net girdi hesaplanır.
Çarpım $Net = \prod_{i=1}^N X_i * W_i$	Ağırlık değerleri girdiler ile çarpılır ve bulunan değerler birbiriyle çarpılarak net girdi hesaplanır.
Maksimum $Net = \text{Max}(X_i * W_i)$	n adet girdi içinden ağırlıklar girdilerle çarpıldıktan sonra içlerinden en büyüğü net girdi olarak kabul edilir.
Minimum $Net = \text{Min}(X_i * W_i)$	n adet girdi içinden ağırlıklar girdilerle çarpıldıktan sonra içlerinden en küçüğü net girdi olarak kabul edilir.
Çoğunluk $Net = \sum_{i=1}^N \text{Sgn}(X_i * W_i)$	n adet girdi içinden ağırlıklar girdilerle çarpıldıktan sonra pozitif ile negatif olanların sayısı bulunur. Büyük olan sayı hücrenin net girdisi olarak kabul edilir.
Kümülatif Toplam $Net = \text{Net}(\text{eski}) + \sum_{i=1}^N X_i * W_i$	Hücreye gelen bilgiler ağırlıklı olarak toplanır. Daha önce hücreye gelen bilgilere yeni hesaplanan girdi değerleri eklenerek hücrenin net girdisi hesaplanır.

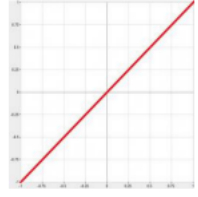
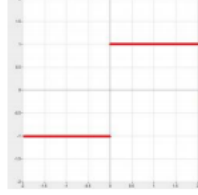
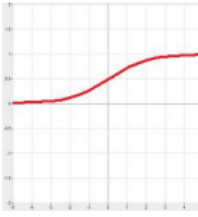
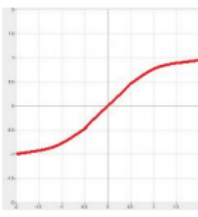
Aktivasyon Fonksiyonu: Bu fonksiyon hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Aktivasyon fonksiyonu olarak genellikle doğrusal olmayan bir fonksiyon seçilir. Yapay sinir ağlarının bir özelliği olan “doğrusal olmama” aktivasyon fonksiyonlarının doğrusal olmama özelliğinden gelmektedir. Aktivasyon fonksiyonu seçilirken dikkat edilmesi gereken bir diğer nokta ise fonksiyonun türevinin kolay hesaplanabilir olmasıdır. Geri beslemeli ağlarda aktivasyon fonksiyonunun türevi de kullanıldığı için hesaplamaların yavaşlamaması için türevi kolay hesaplanır bir fonksiyon seçilir. Günümüzde en yaygın olarak kullanılan “Çok katmanlı algılayıcı” modelinde genel olarak aktivasyon fonksiyonu olarak “Sigmoid fonksiyonu” kullanılır (Öztemel 2003).

Bu fonksiyon (4.1) eşitliği yardımıyla hesaplanmaktadır:

$$F(\text{Net}) = \frac{1}{1 + e^{-\text{Net}}} \quad (4.1)$$

Bazı aktivasyon fonksiyonları aşağıdaki tabloda gösterilmiştir.

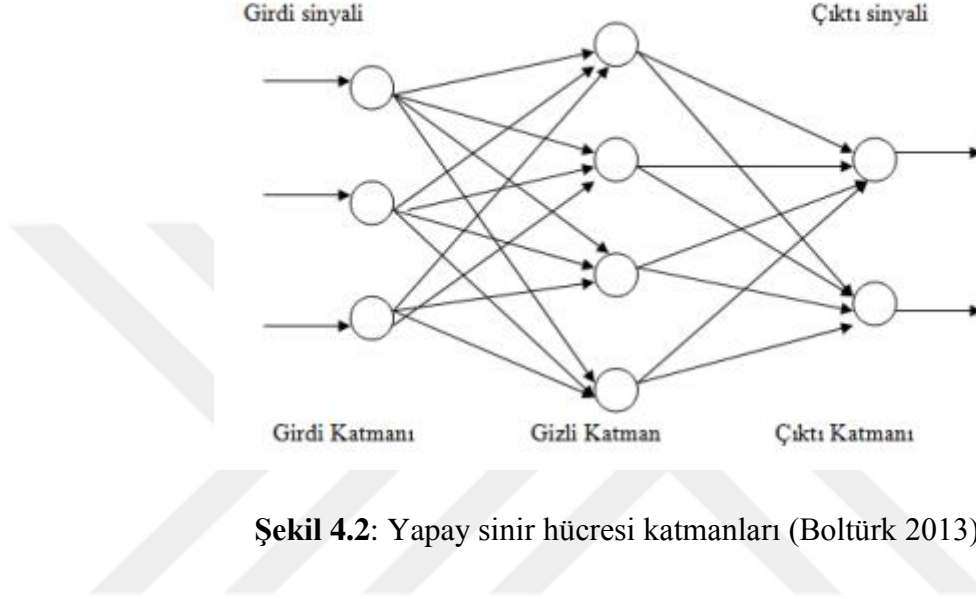
Tablo 4.2: Aktivasyon fonksiyonu örnekleri (Öztemel 2003)

Doğrusal (Lineer) Aktivasyon Fonksiyonu		$F(\text{NET})=A * \text{NET}$ (A sabit bir sayı)	Doğrusal problemler çözmek amacıyla aktivasyon fonksiyonu doğrusal bir fonksiyon olarak seçilebilir. Toplama fonksiyonundan çıkan sonuç, belli bir katsayı ile çarpılarak hücrenin çıktısı olarak hesaplanır.
Adım (Step) Aktivasyon Fonksiyonu		$F(\text{Net})= \begin{cases} 1 & \text{if Net} > \text{Eşik Değer} \\ 0 & \text{if Net} \leq \text{Eşik Değer} \end{cases}$	Gelen Net girdinin belirlenen bir eşik değerinin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerini alır.
Sigmoid Aktivasyon Fonksiyonu		$F(\text{Net})= \frac{1}{1+e^{-\text{Net}}}$	Sigmoid aktivasyon fonksiyonu sürekli ve türevi alınabilir bir fonksiyondur. Doğrusal olmayışı dolayısıyla yapay sinir ağı uygulamalarında en sık kullanılan fonksiyondur. Bu fonksiyon girdi değerlerinin her biri için 0 ile 1 arasında bir değer üretir.
Tanjant Hiperbolik Aktivasyon Fonksiyonu		$F(\text{Net})= \frac{e^{\text{Net}} + e^{-\text{Net}}}{e^{\text{Net}} - e^{-\text{Net}}}$	Tanjant hiperbolik fonksiyonu, sigmoid fonksiyonuna benzer bir fonksiyondur. Sigmoid fonksiyonunda çıkış değerleri 0 ile 1 arasında değişirken hiperbolik tanjant fonksiyonunun çıkış değerleri -1 ile 1 arasında değişmektedir.
Eşik Değer Fonksiyonu		$F(\text{Net})= \begin{cases} 0 & \text{if Net} \leq 0 \\ \text{Net} & \text{if } 0 < \text{Net} < 1 \\ 1 & \text{if Net} \geq 1 \end{cases}$	Gelen bilgilerin 0 dan küçük-eşit olduğunda 0 çıktısı, 1 den büyük-eşit olduğunda 1 çıktısı, 0 ile 1 arasında olduğunda ise yine kendisini veren çıktılar üretilebilir.
Sinüs Aktivasyon Fonksiyonu		$F(\text{Net}) = \text{Sin}(\text{Net})$	Öğrenilmesi düşünülen olayların sinüs fonksiyonuna uygun dağılım gösterdiği durumlarda kullanılır.

Çıktılar: Aktivasyon fonksiyonundan çıkan değer hücrenin çıktı değeridir. Bu değer ister yapay sinir ağının çıktısı olarak dış dünyaya verilsin isterse tekrardan ağın içinde kullanılabilir. Her hücrenin birden fazla girdisi olmasına rağmen bir tek çıktısı olmaktadır. Bu çıktı istenilen sayıda hücreye bağlanabilir (Öztemel 2003).

4.2.3 Yapay Sinir Ağının Yapısı

YSA her katmanda yapay sinir hücrelerinin yoğun bağlantılarla birbirine ilişkilendirildiği katmanlardan oluşur. Bir YSA'nda üç katman bulunmaktadır. Birincisi girdi katmanı, ikincisi gizli katman ve üçüncüsü de çıktı katmanıdır. Şekil 4.2' de bir yapay sinir ağı örneğine yer verilmiştir.



Şekil 4.2: Yapay sinir hücreleri katmanları (Boltürk 2013)

Girdi Katmanı: Bu katmandaki proses elemanları dış dünyadan bilgileri alarak ara katmanlara transfer etmekle sorumludurlar. Dış dünyadan gelecek giriş sayısı kadar hücre bulundurmalarına rağmen genelde girdiler herhangi bir işleme uğramadan alt katmanlara iletilmektedir.

Ara Katmanlar: Ara katmanlara gizli katman da denilmektedir. Girdi katmanından gelen bilgiler işlenerek çıktı katmanına gönderilirler. Bu bilgilerin işlenmesi ara katmanda gerçekleşmektedir. Ara katman sayısı ağdan ağa değişebilir. Bazı yapay sinir ağlarında ara katman bulunmadığı gibi bazı yapay sinir ağlarında ise birden fazla ara katman bulunmaktadır. Ara katmanlardaki nöron sayıları giriş ve çıkış sayısından bağımsızdır. Birden fazla ara katman olan ağlarda ara katmanların kendi aralarındaki hücre sayıları da farklı olabilir. Ara katmanların ve bu katmanlardaki nöronların sayısının artması hesaplama karmaşıklığını ve süresini arttırmasına rağmen yapay sinir ağının daha karmaşık problemlerin çözümünde de kullanılabilmesini sağlar.

Çıktı Katmanı: Bu katmandaki proses elemanları ara katmandan gelen bilgileri işleyerek ağın girdi katmanından sunulan girdi seti için üretmesi gereken çıktıyı üretirler. Üretilen çıktı dış dünyaya gönderilir (Öztemel 2003).

4.2.4 Yapay Sinir Ağlarının Özellikleri

Yapay sinir ağlarının karakteristik özellikleri ağın modeline göre değişiklik göstermektedir ancak Öztemel (2003) çalışmasında yapay sinir ağlarının genel özelliklerini aşağıdaki gibi sıralamıştır:

- Yapay sinir ağları makine öğrenmesi gerçekleştirirler.
- Programları çalışma stili bilinen programlama yöntemlerine benzememektedir.
- Bilginin saklanması sağlarlar.
- Yapay sinir ağları, örnekleri kullanarak öğrenirler.
- Yapay sinir ağlarının güvenle çalıştırılabilmesi için önce eğitilmeleri, daha sonra performanslarının test edilmesi gerekir.
- Görülmemiş örnekler hakkında bilgi üretebilirler.
- Algılamaya yönelik olaylarda kullanılabilirler.
- Örüntü ilişkilendirme ve sınıflandırma yapabilirler.
- Örüntü tamamlama gerçekleştirebilirler.
- Kendi kendini organize etme ve öğrenebilme yetenekleri vardır.
- Eksik bilgi ile çalışabilmektedirler.
- Hata toleransına sahiptirler.
- Belirsiz, tam olmayan bilgileri işleyebilmektedirler.
- Dereceli bozulma gösterirler.
- Dağıtık belleğe sahiptirler.
- Sadece nümerik bilgiler ile çalışabilmektedirler.

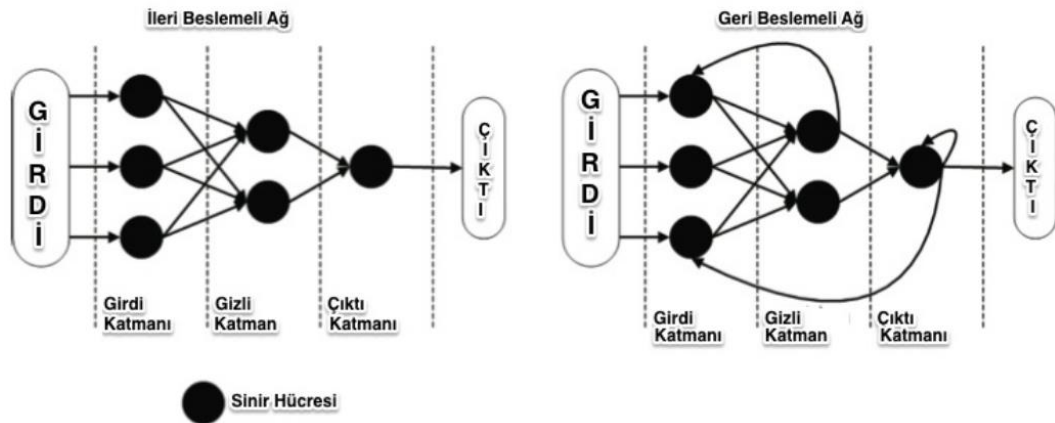
Yukarıda belirtilen özelliklere ek olarak geliştirilmiş olan her modelin kendisine özgü özellikleri olabilmektedir (Öztemel 2003).

4.2.5 Yapay Sinir Ağlarının Sınıflandırılması

Birbirlerinden ayrı yapay sinir hücrelerinin birbirlerine bağlanma şekline “Topoloji” adı verilmektedir. Bağlantının çeşitli yollardan yapılabilir olmasından dolayı çok sayıda farklı topolojiler söz konusu olmakla birlikte genellikle ileri beslemeli ve geri beslemeli olmak üzere iki ana topoloji ayrımı yapılmaktadır. Şekil 4.3’ te bu iki topoloji örneği gösterilmektedir (Krenker ve diğ. 2011)

İleri Beslemeli Ağlar: Bir ileri beslemeli ağda, yapay sinir hücreleri katmanlara yerleştirilmiştir. Şekil 4.3’ te gösterildiği gibi bir katmanın her yapay sinir hücresi bir önceki katmanın yapay sinir hücreleriyle bağlantı halindedir. Sinyal yayılımı girdi katmanından çıktı katmanına doğru ağın gizli katmanlarından geçerek gerçekleşmektedir. Gizli yapay sinir hücreleri girdi özelliklerini temsil ederken, çıktı sinir hücreleri ağın tepkilerini ortaya çıkarmaktadır. Tek katmanlı algılayıcılar, çok katmanlı algılayıcılar ve radyal tabanlı fonksiyon ağları ileri beslemeli ağlardandır.

Geri Beslemeli Ağlar: Geri beslemeli bir ağı ileri beslemeli bir ağdan ayıran en önemli özellik en az bir geri besleme döngüsünün olmasıdır (Haykin 1999). Geri beslemeli ağlarda yapay sinir hücreleri çıktılarının ağı geri dönüşümü sağlanarak bu çıktılar girdi olarak kullanılmaktadır ve doğrusal olmayan çağrışımsal bellek gibi çalışmaktadır. İleri doğru bağlantılarla birlikte yapay sinir hücrelerinin kendi ya da kendinden önceki katmanda yer alan yapay sinir hücreleriyle de bağlantısı olmaktadır ve dinamik davranış sergilemektedirler (Alpaydın 2012).



Şekil 4.3: İleri ve geri beslemeli ağ yapısı (Krenker ve diğ. 2011)

4.2.6 Yapay Sinir Ağları Modelleri

Yapay sinir ağının genelleme yeteneği ağın topolojinin doğru seçilmesi ile birebir ilişkilidir. Ağ için en uygun mimari, problemi öğrenmek için yeterince büyük, genelleme yapabilmek için ise bir o kadar küçük olmalıdır. En uygun mimariden daha küçük bir ağ problemi iyi öğrenemez diğer taraftan daha büyük bir ağ ise eğitim verisini aşırı öğrenir ki bu da ezberlemesine neden olduğundan genelleme yeteneği zayıf kalır. Ağın yapısının belirlenmesinde temel olarak büyüyen/yapıcı ve budama/yıkıcı olmak üzere iki açgözlü yaklaşım bulunmaktadır. Ağın yapısı küçük seçilip öğrenme sürecinde büyüyor ise büyüyen/yapıcı bir yaklaşım, aksine büyük seçilip öğrenme süresince küçülüyor ise budama/yıkıcı bir yaklaşım izlenmiştir (Aran 2009).

YSA' lar genel olarak tek katmanlı algılayıcılar ve çok katmanlı algılayıcılar olarak ikiye ayrılmaktadır.

4.2.6.1 Tek katmanlı algılayıcılar

Tek katmanlı yapay sinir ağları doğrusal problemlerin çözümünde kullanılıp sadece girdi ve çıktı katmanından oluşmaktadır. Katmanlarda bir veya daha fazla nöron bulunabilmektedir. Şekil 4.4 'te basit bir tek katmanlı algılayıcı modeli gösterilmiştir.



Şekil 4.4: Tek katmanlı algılayıcı (TKA) modeli (Arı ve Berberler 2017)

Eşik girdisi, bu tip ağlarda nöron elemanlarının değerlerinin ve de ağın çıktısının 0 olmasını önler. Değeri daima 1'dir. Ağın çıktısı denklem (4.2)'de

gösterildiği gibi ağırlıklandırılmış girdi değerlerinin eşik değeri ile toplanması sonucu elde edilir.

$$\zeta = f(\sum_{i=1}^n w_i x_i + \phi) \quad (4.2)$$

Denklem (4.2)'de x_i , $i = 1, 2, \dots, n$ ağırlık girdilerini, w_i , $i = 1, 2, \dots, n$ bu girdilere karşılık gelen ağırlık değerlerini, ϕ ile eşik değerini göstermektedir. Tek katmanlı algılayıcıda çıktı fonksiyonu doğrusaldır. Böylelikle, ağa gösterilen örnekler eşik değer fonksiyonu iki sınıf arasında paylaştırılarak iki sınıfı birbirinden ayıran doğru bulunmaya çalışılır. Ağırlık çıktısı 1 veya -1 değeri alır. Eşik değer fonksiyonu Denklem (4.3)'te gösterilmiştir.

$$f(g) = \begin{cases} 1, & \zeta > 0 \\ -1, & \zeta \leq 0 \end{cases} \quad (4.3)$$

Sınıf ayırıcı doğrusu denklem (4.4)'teki gibi tanımlanmaktadır.


$$W_1 X_1 + W_2 X_2 + \phi = 0 \quad (4.4)$$

Buradan;

$$X_1 = -\frac{W_2}{W_1} X_2 - \frac{\phi}{W_1} \quad (4.5)$$

$$X_2 = -\frac{W_1}{W_2} X_1 - \frac{\phi}{W_2} \quad (4.6)$$

olarak elde edilir. Denklem (4.5) ve Denklem (4.6) kullanılarak Şekil 4.5' te geometrik gösterimi verilen sınıf ayırıcı doğrusu çizilebilmektedir.



Şekil 4.5: Sınıf ayırıcı doğrusu (Arı ve Berberler 2017)

Ağırlık değerleri, sınıf ayırıcı doğrusunun her iki grubu en iyi ayıracak şekilde belirlenmesi için her iterasyonda denklem (4.7)'deki formül ile değiştirilir.

$$W_i(t+1) = W_i(t) + \Delta W_i(t) \quad (4.7)$$

Eşik değeri de sınıf ayırıcı doğrusunu sınıflar arasında kaydırmak için her iterasyonda Denklem (4.8)'deki formül ile güncellenir (Arı ve Berberler 2017).

$$\phi(t + 1) = \phi(t) + \Delta\phi(t) \quad (4.8)$$

Tek katmanlı algılayıcılarda başlıca iki modelden söz edilebilir. Bunlar: Perceptron Modeli ve Adaline/Madaline Modeli' dir.

Perceptron Modeli

1958 yılında psikolog Frank Rosenblatt tarafından “zeki sistemlerin temel özelliklerinden bazılarını simüle etmek” amacıyla geliştirilen perceptron modeli, bir sinir hücresinin birden fazla girdiyi alarak bir çıktı üretmesi prensibine dayanır. Ağın çıktısı, girdi değerlerinin ağırlıklı toplamının bir eşik değer ile karşılaştırılması sonucu elde edilir. Toplam eşikten eşit veya büyük ise çıktı değeri 1, küçük ise 0 seçilir. Rosenblatt, algılayıcı eğitimi için desen tanıma problemlerini çözen bir öğrenme kuralı geliştirdi (Rosenblatt 1958). Bu kuralın, eğer problemi çözen ağırlıklar varsa, daima doğru ağırlıklara yakınsayacağını kanıtladı. Marvin

Minsky ve Seymour Papert algılayıcılar üzerinde yaptıkları derin matematiksel incelemeler sonucunda, algılayıcıların çok sınırlı alanlarda kullanılabileceğini ve algılayıcının çözemeyeceği çok fazla problem sınıfı olduğunu yayınladıkları “Perceptrons” kitabıyla kamuya göstermişlerdir (Minsky and Papert 1969).

ADALINE Modeli

Bernard Widrow, 1950’lerin sonlarında, Frank Rosenblatt’ın perceptronu geliştirdiği sırada, sinir ağları üzerine çalışmaya başlamıştır. 1960 yılında Widrow ve onun lisansüstü öğrencisi Marcian Hoff, ADALINE ağı ile En Küçük Kareler (Least Mean Square) algoritması olarak adlandırılan bir öğrenme kuralı geliştirdiler. Açık adı ’ADaptive LInear NEuron’ veya ’ADaptive LInear Element’ olan bu sinir hücresi modeli yapısal olarak algılayıcıdan farklı değildir. Ancak, algılayıcı aktivasyon fonksiyonu olarak eşik fonksiyonu kullanırken ADALINE doğrusal fonksiyon kullanır. Her iki modelde yalnızca doğrusal olarak ayrılabilen problemlere çözüm üretebilmektedir.


Widrow-Hoff kuralı da denilen En Küçük Kareler algoritması, perceptronun öğrenme kuralından daha güçlüdür. Perceptron öğrenme kuralı bir çözüme yakınsamayı garanti etse dahi, eğitim kalıplarının sınır çizgisine yakınlığından dolayı gürültüye duyarlı olabilir. En küçük kareler algoritması, ortalama karesel hatayı minimize ettiğinden eğitim kalıplarını sınır çizgisinden olabildiğince uzak tutmaya çalışır. Widrow ve Hoff, birden fazla adaptif eleman içeren MADALINE yapay sinir ağı modellini de geliştirmişlerdir (Arı ve Berberler 2017).

4.2.6.2 Çok katmanlı algılayıcılar

Tek katmanlı algılayıcıların doğrusal olmayan problemlerin çözümünde başarısız olmasının üzerine geliştirilen çok katmanlı algılayıcılar (ÇKA), bilgi girişinin yapıldığı girdi katmanı, bir veya daha fazla gizli (ara) katman ve bir çıktı katmanından oluşmaktadır. ÇKA’ da katmanlar arası ileri ve geri yayılım olarak adlandırılan geçişler bulunur. İleri yayılım safhasında, ağın çıktısı ve hata değeri

hesaplanır. Geri yayılım safhasında ise hesaplanan hata değerin minimize edilmesi için katmanlar arası bağlantı ağırlık değeri güncellenir.

Şekil 4.6' da ÇKA yapısı gösterilmiştir.



Şekil 4.6: ÇKA modeli (Arı ve Berberler 2017)

ÇKA modeli doğrusal perceptrondaki en küçük kareler algoritmasının geliştirilmesi olan geri yayılım (backpropagation) öğrenme algoritmasını kullanır.

Geri Yayılım Algoritması

Geri yayılım (backpropagation), algoritması, ağıın çıktısının belirlendiği ileri besleme ve oluşan hatanın gradiyenti azaltacak şekilde geri yayılarak ağırlıkların güncellendiği geri besleme safhalarından oluşmaktadır. İleri besleme safhasında, eğitim setinin girdileri ağıın giriş katmanına sunulur. Giriş katmanı, bu girdileri alan nöronları içerir. Bu sebeple giriş katmanındaki nöron sayısının veri setindeki girdi değeri sayısı ile aynı olması gerekir. Giriş katmanındaki nöronlar girdi değerlerini doğrudan gizli katmana iletir. Gizli katmandaki her bir nöron, ağırlıklandırılmış girdi değerlerine eşik değeri de ekleyerek toplam değeri hesap eder ve bunları bir aktivasyon fonksiyonu ile işleyerek bir sonraki katmana veya doğrudan çıkış katmanına iletir. Katmanlar arasındaki ağırlıklar başlangıçta genellikle rasgele seçilir. Çıkış katmanındaki, her bir nöronun net girdisi, ağırlıklandırılmış girdi değerlerine eşik değerin eklenmesiyle hesaplandıktan sonra, bu değer yine aktivasyon fonksiyonu ile işlenerek çıktı değeri belirlenir. Ağıın çıktı değeri beklenen çıktı değeri ile karşılaştırılarak hata değeri hesaplanır.

Bu sebeple, çıkış katmanında bulunacak nöronların sayısı veri setindeki çıktı sayısı ile örtüşmelidir.

j . çıktı hücresi için n 'inci eğitim verisi sonrası, $d_j(n)$ beklenen değer olmak üzere hata şu şekilde tanımlanır;

$$e_j(n) = d_j(n) - y_j(n) \quad (4.9)$$

Çıktı katmanındaki toplam hata denklem (4.10)'daki gibi ifade edilir.

$$E(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (4.10)$$

C kümesi çıktı katmanındaki tüm nöronları içermektedir. Burada delta kuralındakine benzer bir yaklaşımla $E(n)$ en düşük hale getirilmeye çalışılır. Çıktı katman hücresine gelen girdiler toplamı denklem (4.11) ile ifade edilir.

$$v_j(n) = \sum_{i=0}^m w_{ji}(n) x_i(n) \quad (4.11)$$

$X=(x_0, \dots, x_n)$, j . nörona uygulanan m girdi değerini, w_j , x_i girdisinin ağırlığını ve f aktivasyon fonksiyonunu göstermektedir. w_{j0} sapma elemanını gösterir ve böylece $x_0 = +1$ olur. Ağın çıktı hücrelerinin ürettiği sonuç denklem (4.12)'deki formül ile hesaplanır.

$$y_j(n) = f(v_j(n)) \quad (4.12)$$

Ağın gradyeni hata fonksiyonunun ağırlıklara göre türevi alınarak bulunabilir. Zincir kuralına göre, gradyen aşağıdaki şekilde ifade edilebilir:

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)} \quad (4.13)$$

Tek tek türevler alınırsa,

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = -e_j(n) f'(v_j(n)) x_i(n) \quad (4.14)$$

Ağırlık düzeltme miktarı, $\Delta w_{ji}(n)$ delta kuralına göre uygulanır.

$$\Delta W_{ji}(n) = -\eta \frac{\partial E(n)}{\partial w_{ji}(n)} \quad (4.15)$$

η öğrenme oranıdır. Denklem (4.15)'deki $-$ işareti ağırlık uzayındaki dik inişi temsil eder. Böylece geriye yayılma algoritması için ağırlık düzeltme miktarı, denklem (4.16)'daki gibi ifade edilir.

$$\Delta W_{ji}(n) = \eta \delta_j(n) x_i(n) \quad (4.16)$$

Yerel gradyen $\delta_j(n)$ ise şöyle tanımlanır.

$$\delta_j(n) = e_j(n) f'(v_j(n)) \quad (4.17)$$

Gizli katmanda bulunan herhangi bir j nöronu için, çıkış katmanındaki nöronlar gibi istenen çıktı değeri belirtilmemiştir. Bu nedende gizli bir j nöronunun hata değeri, o nöronun direk bağlı olduğu tüm nöronların hata değerinden geri dönük olarak etkilenecektir. Gizli katmandaki herhangi bir j nöronu için, yerel gradyen $\delta_j(n)$ şu şekilde tanımlanır.

$$\delta_j(n) = f'(v_j(n)) \sum_{j=0}^1 \delta_j(n) w_{ji}(n) \quad (4.18)$$

1986 yılında Rumelhart, geriye yayılım algoritmasının ağırlık güncelleme denklemine, α momentum terimi ekleyerek, ağırlık yerel minimuma takılması olasılığını azaltmıştır. Momentum terimi eklendikten sonra ağırlık güncelleme denklemi aşağıdaki hali alır.

$$w_{ji}(n+1) = w_{ji}(n) + \Delta w_{ji}(n) \quad (4.19)$$

$$\Delta w_{ji}(n) = \eta \delta_j(n) x_i(n) + \alpha \Delta w_{ji}(n) \quad (4.20)$$

Geri yayılım algoritmasında eğitim setinin hesaplamaya dahil edilmesinde kullanılan iki öğrenme yöntemi vardır. Bu yöntemler tekil eğitim ve toplu eğitimidir. Tekil eğitimde ağırlıkların güncelleştirilmesi işlemi eğitim veri setindeki her bir örnek ağırlığa uygulandığında oluşan hatanın geri yayılımı ile gerçekleştirilir. Toplu eğitimde ise eğitim veri setinin tamamı ağırlığa uygulandıktan sonra elde edilen ortalama hatanın geri yayılımı ile ağırlıkların güncelleştirilmesi yapılır. Toplu eğitim paralelleştirilebilirken, tekil eğitim paralelleştirilememektedir (Haykin 1999).

Eğitim sürelerini azaltmak için sezgisel yaklaşım yöntemleri kullanılmaktadır. Geri yayılım algoritmasında yakınsamayı hızlandırmak ve ağırlık performansını iyileştirecek birkaç teknikten biri olan sezgisel yaklaşım teknikleri momentum katsayısı kullanılarak yapılır. Momentum katsayısı YSA'nın daha hızlı toparlanmasına yardım eden bir faktördür. Temel olarak daha önceki değişimin bir kısmını işlem gören değişime eklemeye dayanır. Momentum katsayısı ağırlık yerel gradientleri aşmasını sağladığı gibi aynı zamanda hatanın düşmesine de yardımcı olur (Bayındır ve Sesveren 2008).

Öğrenme oranı (η), bir öğrenme prosedürünün hızı ve doğruluğu ile orantılı olup bunları kontrol eden bir sabittir. Öğrenme oranı, YSA'nın ağırlıklarının

değişiminde kullanılmaktadır. Öğrenme oranı çok büyük seçilirse hata yüzeyinde geniş atlamalar meydana gelir, öğrenmenin gerçekleşeceği dar alanlar atlanabilir. Ayrıca, hata yüzeyi boyunca hareketler çok kontrolsüz olur. Çok küçük seçilmesi durumunda ise öğrenme süresi çok zaman alabilir. Tecrübeler $0.01 \leq \eta \leq 0.9$ aralığında seçilen öğrenme oranını iyi sonuçlar verdiğini göstermektedir. Büyük bir öğrenme oranı, başlangıçta iyi sonuçlara yol açar, ancak daha sonra yanlış sonuçlar verebilir. Daha küçük bir öğrenme oranı ile ise öğrenme daha zaman alıcıdır, ancak sonuç daha nettir. Böylece, öğrenme sürecinde öğrenme oranının başlangıçta büyük seçilerek zamanla (her iterasyonda veya birkaç iterasyonda bir) azaltılması gerekir (Kriesel 2007).

Levenberg-Marguardt metodu (LMM)

Temel olarak bu algoritma maksimum komşuluk fikri üzerine kurulmuştur ve yavaş yakınsama problemlerinden etkilenmez. İleri beslemeli ağlarda en hızlı öğrenme metodudur. $E(w)$ 'nin bir amaç fonksiyonu olduğu düşünülürse m tane hata terimi için $e_i^2(w)$ eşitlik Denklem (4.21)'de verilmiştir.

$$E(w) = \sum_{i=1}^m e_i^2(w) = \|f(x)\|^2 \quad (4.21)$$

bu eşitlikte;

$$e_i^2(w) = (y_i - y_{d_i})^2 \text{ dir} \quad (4.22)$$

Burada amaç fonksiyonu $f(.)$ ve onun jakobiyeni j' 'nin bir noktada w bilindiği farz edilir. LMM' de hedef, parametre vektörü w' nin $E(w)$ minimum iken bulunmasıdır. LMM'nin kullanılmasıyla yeni vektör w_{k+1} farz edilen vektör w_k 'dan eşitlik denklem (4.23)'teki gibi hesaplanır.

$$w_{k+1} = w_k + \delta w_k \quad (4.23)$$

burada δw_k eşitlik aşağıdaki gibi verilir.

$$(J_k^T J_k + \lambda I) \delta w_k = -J_k^T f(w_k) \quad (4.24)$$

eşitlikte;

J_k : f 'nin(hatanın) w_k değerlendirilmiş Jakobiyeni

λ : Marquardt parametresi

I : birim veya tanımlama matrisi

Levenberg-Marquardt algoritması aşağıdaki gibi özetlenebilir.

- i) $E(w_k)$ 'yi hesapla
 - ii) Küçük bir λ değeri ile başla(mesela $\lambda=0.01$)
 - iii) δw_k 'yi eşitlik (4.24) çöz ve $E(w_k + \delta w_k)$ değerini hesapla
 - iv) şayet $E(w_k + \delta w_k) \geq E(w_k)$ λ 'yi 10 kat artır ve (iii)'ye git
 - v) şayet $E(w_k + \delta w_k) < E(w_k)$ λ 'yi 10 kat azalt
- w_k : $w_k + \delta w_k$ 'yi güncelleştir ve (iii)'ye git.

Hedef çıkışı hesaplamak için birçok katmanlı nöronun LMM kullanılarak öğretilmesi ağırlık dizisi w_0 'a bir başlangıç değerinin atanması ile başlar ve hataların karelerinin toplamı e_i^2 'nin hesaplanmasıyla devam eder. Her e_i^2 terimi, hedef çıkışı (y) ile gerçek çıkış (yd) arasındaki farkın karelerini ifade eder. Bütün veri seti için e_i^2 hata terimlerinin tamamının elde edilmesiyle, ağırlık dizileri (i)'den (v)'e kadar olan LMM adımlarının uygulanmasıyla açıklandığı gibi adapte edilir.

4.3 Yapay Sinir Ağları Konulu Literatürdeki Çalışmalar

Calp (2018) çalışmasında işletmeler için yapay sinir ağları kullanarak günlük yemek talebini tahmin eden yapay zekâ tabanlı bir model önermiştir. Veriler, günlük yemek çıkaran ve farklı kademelerde görev alan 110 kişilik bir personel kapasitesine sahip özel bir işletmenin yemekhane veri tabanından elde edilmiş olup, son iki yıllık (2016-2018) veriyi kapsamaktadır. Model, MATLAB

paket programı kullanılarak oluşturulmuştur. Modelin performansı, Regresyon değerleri, Ortalama Mutlak Hata Yüzdesi (MAPE) ve Ortalama Karesel Hata (MSE) dikkate alınarak belirlenmiştir. Ağın eğitiminde, ileri beslemeli geri yayımlı ağ mimarisi kullanılmıştır. Deney sonuçları, modelin hata oranının düşük, performansının yüksek olduğunu ve talep tahmini için yapay sinir ağları kullanımının olumlu etkisini ortaya koymuştur.

Özden ve Öztürk (2018) çalışmasında; zaman serileri ve yapay sinir ağları olmak üzere iki farklı yaklaşım kullanarak Türkiye'deki bir endüstri bölgesi için enerji ihtiyaç tahmini üzerinde çalışmıştır. Daha önceki çalışmalardan farklı olarak, kısıtlı veri ile kısa dönem tahmini için basit bir model geliştirilmiştir. Model, giriş parametresi olarak geçmiş günlere ait tüketim verileri ve sıcaklığı içermektedir. Sıcaklık verisi, endüstri bölgelerinde ısıtma amaçlı enerji tüketiminde kullanıldığı için anahtar rol oynamaktadır. Zaman serileri yaklaşımında sadece geçmişe ait enerji tüketim verileri kullanılmıştır. Her iki yaklaşım enerji ihtiyaç tahmininde kullanılmış, sonuçlar tartışılmış ve karşılaştırılmıştır. Zaman serileri yöntemi veri kısıtlılığı sebebiyle yapay sinir ağlarına göre daha kötü bir tahmin gerçekleştirmiştir.

Aydın ve Toros (2018) çalışmasında sıcaklık değişkenlerini kullanarak yapay sinir ağları ile kısa vadede elektrik tüketim tahminini ele almıştır. Türkiye elektrik tüketiminin sıcaklık ile ilişkisi Ocak 2012- Kasım 2016 tarihleri arasında incelenmiştir. Aylık ve mevsimlik dönemlerde, tüketimin sıcaklık nedeniyle nasıl değiştiği, ne kadar değiştiğinin araştırılması amaçlanmıştır. MATLAB programında Levenberg-Marquardt algoritması ile modellenen veriler için kısa vadede elektrik tahminleri yapılmıştır. Model sonuçlarında, hata oranlarının makul olduğu saptanmıştır.

Tealab (2018) çalışmasında yapay sinir ağı metodolojilerini kullanan zaman serisi tahmin modellerinde kaydedilen ilerlemeleri incelemiştir. Sistematik derleme, 2006-2016 yılları arasında yayınlanan makalelerin araştırılması ve incelenmesi ile oluşturulmuştur ve 17 çalışma incelenmiştir. İncelenen bu 17 çalışmadan sadece üç çalışma farklı bir süreç olarak kabul edilmiştir. Doğrusal olmayan zaman serilerinin öngörülmesi için yapay sinir ağlarına dayanan yeni modeller üzerinde durulmuştur. Analiz edilen makalelerin her biri için çözülmesi gereken mevcut sorunlar tartışılmıştır.

Nasıroğlu ve diğ. (2016) çalışmasında yapay sinir ağı kullanılarak hava sıcaklığı tahmini yapmıştır. Yapay sinir ağda ay, yükseklik, enlem, boylam, aylık ortalama yer yüzey sıcaklıkları girdi olarak kullanılırken, aylık ortalama hava sıcaklığı çıktı olarak elde edilmiştir. Girdi parametrelerinden yer yüzey sıcaklığı, NOAA/AVHRR verilerinden sağlanmıştır. Ağda öğrenme algoritmaları olarak; tarinlm, trainscg, trainoss kullanılırken transfer fonksiyonu olarak tansig, logsig ve lineer kullanılmıştır. Ocak 1995'den Aralık 2005'e kadar zaman aralığı, çalışma periyodu olarak belirlenmiştir. Ağın eğitilmesi için 1995- 2004 yılları arası veriler kullanılırken, test verisi olarak 2005 yılı verileri kullanılmıştır. Tahmin sonuçlarının, gerçek verilerle istatistiksel olarak değerlendirilmesi yapılmış olup hata değeri oldukça az çıkmıştır. El edilen en iyi modellemede, korelasyon katsayısı ve kök ortalama kare hatası sırasıyla 0.996 ve 1.253 K olarak hesaplanmıştır.

Param ve diğ. (2016) çalışmasında tarihsel talep girdi verilerini kullanarak enerji tahmin problemini ele almışlardır. Çalışmada, 2009-2015 tarihsel verileri kullanılmıştır. Yapay sinir ağı, Arima ve regresyon yöntemleri ile tahminleme yapılmış en doğru sonuca yapay sinir ağları ile varılmıştır.

Deo ve Şahin (2015) çalışmasında Avustralya'nın sekiz farklı bölgesinde yağış ve buharlaşma endeksi tahmininde kullanmak üzere en iyi sonucu veren YSA modelinin belirlenmesini amaçlamışlardır. Öğrenme katsayısı, aktivasyon fonksiyonları, katmanlardaki nöron sayısı değiştirilerek en az hata payına sahip modelin kurulması sağlanmıştır. 18 girdi nöronuna, 43 ara katman nöronuna, bir çıktı nöronuna, Levenberg–Marquardt öğrenme algoritmasına, sigmoid aktivasyon ve çıktı fonksiyonuna sahip olan model en iyi sonuçları vermiştir.

Sordoni ve diğ. (2015) çalışmasında twitter konuşmaları için uçtan uca eğitilebilecek yeni bir yanıt oluşturma sistemi kurgulamışlardır. İçeriksel bilgiyi klasikle bütünleştirirken ortaya çıkan az sayıdaki sorunları ele almak için bir sinir ağı mimarisi kullanılmıştır. Model, sistemin önceki diyalog ifadelerini dikkate almasını sağlamıştır. Çalışma gelecekteki çalışmalara yön verir nitelikte olmuştur. Mesaj ve bağlam ifadelerinde sözcük sırasını hesaba katan karmaşık sinir ağı modelleri kullanılırsa iyileştirme için yeterli olacağı düşünülmektedir.

Ghiassi ve diğ. (2015) çalışmasında filmlerin gişe hâsılatlarının, film yapımından önce tahmin edecek YSA modelinin kurulmasını amaçlamıştır.

Oluşturulan dinamik yapay sinir ağında gizli katman sayısı dört olarak belirlenmiştir, ancak klasik YSA modellerinden farklı olarak ara katmandaki nöron sayısı en iyi sonuca göre değişmiştir. Model girdileri yapım bütçesi, planlanan reklam harcamaları, film süresi, sezon, devam filmi olup olmaması olarak belirlenmiştir. MPAA (Motion Picture Association of America) puanı kurulan model sonucunda çıktı olarak dokuz adet gelir aralığı belirlenmiştir ve mevcut filmin hangi aralığa düşeceği belirlenmiştir. Model doğruluğu olarak % 94.1 olarak tespit edilmiştir.

Staub ve diğ. (2015) çalışmasında yapay zeka teknikleri, yapay sinir ağları, temel yapıları ve çeviklikleri incelemiştir. Yapay sinir ağlarının karmaşık problemlere hızlı ve makul çözümler sunma yeteneğine sahip olduğundan bahsedilmiştir. Yapay sinir ağlarının insan beynindeki nöronlarla aynı şekilde bir araya getirilen yapay nöronlar tarafından bilgi toplayan bir model ve modelin uygulanabilir olduğundan bahsedilmiştir.

Abbot ve Marohasy (2014) çalışmasında Avustralya'nın üç bölgesi için YSA yöntemi kullanılarak yağmur yağışı miktarının bir, iki ve üç ay ilerisi için tahmin edilmesini amaçlamıştır. Yağış miktarı, en yüksek sıcaklık, en düşük sıcaklık gibi bölgesel değerleri; SOI, IPO, DMI ve Nino gibi iklim endekslerini 1,2,3 ve 4'erli gruplar yaparak girdileri oluşturmuşlar. Oluşturulan model ile mevcutta kullanılan POAMA sistemi karşılaştırılmış ve YSA kullanılarak oluşturulan yeni model daha az hatalı sonuçlar vermiştir.

Amrouche ve Pivert (2014) çalışmasında YSA ağları yöntemini kullanarak Fransa'da iki bölge için global ışıyım değerlerinin (GHI) hesaplanması amaçlamışlardır. Bir dönem ilerisini tahmin etmek için tekil, 8 dönemlik tahminler yapmak için 8'li veri grupları oluşturulmuştur. Her birisinde 20 ve 12 nöron bulunan iki gizli katman oluşturulmuştur. Kurulan YSA modeli test edilmiş ve testler sonucu kabul edilebilir çıkmıştır.

Boltürk (2013) çalışmasında bir şirketin 12 yıllık elektrik tüketim verisi ele almıştır. Elektrik tüketimleri aylık olarak 156 periyottan oluşmaktadır. Bu tüketimlerde sezonsallık yer almamaktadır. Böylece uygulanan modellerde matematiksel olarak sezonsallık faktörü göz önüne alınmamıştır. Ayrıca zaman

serisini kendi içerisinde üç kısma ayrılmış bulunmaktadır. Bunlar; Kısa Dönem (2011 senesi), Orta Dönem (2009-2011 arası) ve Uzun Dönem (2000-2011 arası) şeklindedir. Yapılan çalışmada kullanılan yöntemler, Hareketli Ortalama, Üstel Düzeltme, Holt Modeli, Regresyon, ARIMA, Bulanık Mantık, Yapay Sinir Ağları, Gri Sistem ve bunların bazı türevlerini ele alınmıştır. Öncelikle 2000-2011 elektrik tüketimlerinden bir zaman serisi oluşturulmuştur. Bu zaman serisinden 2012 yılı elektrik tahmini gerçekleştirilmiştir. Bu tahmin değerleri ile gerçek 2012 elektrik tüketim verisi karşılaştırılmıştır. Tahmin sonuçları ve modellerin etkinlikleri Tahmin Performans Ölçülerine göre bakılmıştır. Bunlar Ortalama Kare Hatası, Ortalama Mutlak Hata, Ortalama Mutlak Yüzdeler Hata ve İzleme Sinyalidir. İzleme Sinyali haricinde diğer değerlerin modeller içinde küçük çıkması o modelin diğerine göre daha iyi sonuç verdiği anlamına gelmektedir. Sonuçta her bir dönem için bazı modeller önerilmiştir. Ayrıca şirketlerin her zaman bir sektör uzmanına danışmalarında fayda görüleceği belirtilmiştir.

Azmira ve diğ. (2013) çalışmasında kısa vadeli elektrik fiyat tahmini için yapay sinir ağları kullanmışlardır. Doğru fiyat tahmini ile güç üreticileri karlarını maksimuma çıkarabileceğinden ve kısa vadede operasyonun ve uzun vadede planlamanın iyi yönetileceğinden bahsedilmiştir. Altı girdi türü ile altı model oluşturulmuştur. 24 saat önceden fiyat tahmini yapan 24 model diğer modellere göre daha iyi sonuç verdiği gözlenmiştir. Her saat için geliştirilen modelde %18.74 oranında ortalama mutlak yüzde hatası (Mape) ölçümlenmiştir.

Hatipoğlu ve diğ. (2013) çalışmada galvaniz sektöründe faaliyet gösteren bir firmada YSA yardımıyla galvaniz işlemi sonucunda elde edilecek kaplama kalınlığı tahmin etmeye çalışmışlardır. Tahmin edilen değerlerin gerçek verilerle uygunluğunu test etmek açısından hipotez testi uygulanmış; modelden elde edilen değerlerle gerçek değerlerin ortalaması arasında istatistiksel olarak anlamlı bir fark olmadığı görülmüştür.

Ho ve diğ. (2012) çalışmasında hepatik rezeksiyon olan hepatosellüler karsinoma (HCC) hasta grubu için bir veri tabanından bir dizi klinik parametreye dayanarak 1,3 ve 5 yıllık hastalısız sağ kalım için tahmin modelleri geliştirmek için kullanmışlardır. Tahminlemede Regresyon yöntemi, karar ağacı yöntemi ve YSA metodu kullanmışlar ve sonuç olarak yapay sinir ağları modeli, regresyon ve

karar ağacı yöntemlerine göre daha iyi performans göstermiştir. Bu çalışma hepatik reaksiyon alan hepatosellüler karsinoma (HCC) hastaları için yapay sinir ağları kullanılarak tahminleme çalışmasının mümkün olduğunu göstermiştir.

Kaytez ve diğ. (2012) çalışmasında elektrik talep tahminlemede en küçük kareler yöntemi, yapay sinir ağlarını ve regresyon analizi kullanmış ve karşılaştırmasını yapmışlardır. Modellemede 1970 ve 2009 yılları arasındaki brüt elektrik üretimi, kurulu kapasite, toplam abonelik ve nüfus bilgileri ele alınmıştır. Sonuçlar önerilen en küçük kareler yönteminin doğru ve hızlı bir yöntem olduğunu göstermiştir.

Kaynar ve diğ. (2011) çalışmasında, yapay sinir ağları ve klasik zaman serileri (ARIMA modelleri) yardımıyla doğalgaz tüketimine ilişkin kısa dönemli öngöründe bulunmuşlardır. Ayrıca çalışmada her iki model ile elde edilen tahmin değerleriyle gözlenen değerler karşılaştırılarak modellerin performansını kıyaslamışlardır. Bu çalışmada, yapay sinir ağları ve ARIMA zaman serisi analiz yöntemleri kullanılarak Ankara ilinin doğalgaz tüketimini tahmin etmişlerdir. Her iki yöntem içinde farklı modeller oluşturularak eğitim ve test verileri için en küçük MSE değerlerine sahip modeller, en iyi modeller olarak seçilmiş ve bu modeller yardımıyla 10 adet test verisi için tahminler gerçekleştirilmiştir. Her iki yöntem yardımıyla elde edilen tahmin sonuçları MSE ve MAPE performans kıstasları yardımıyla karşılaştırılmıştır. Her iki performans ölçütü içinde yapay sinir ağı modelleri ARIMA modellerinden daha iyi tahmin performansı sergilemişlerdir.

Karlık ve Kızılaslan (2009) çalışmasında YSA algoritmaları kullanılarak İstanbul doğalgaz talep tahmini çalışması yapmışlardır. İstanbul geneli, Anadolu yakası ve Avrupa yakası için ayrı ayrı günlük, haftalık ve aylık olarak tahmin modelleri üretilmiştir. Tahmin modellerinde YSA algoritmaları kullanılmıştır. Yedi değişik YSA algoritması uygulanıp bunların karşılaştırılması yapılmıştır. Çalışma sonucunda YSA modellerinin çok iyi tahmin sonuçları verdiği görülmüştür.

Gültekin (2009) Bursa ili için orta dönem elektrik enerjisi talebi tahmini çalışmasında; 2002–2006 yılları aylık tüketim verileri kullanılarak lineer, eksponansiyel ve kuadratik eğriye yaklaşım metotları ile 2007 yılı tahmini yapılmıştır. Sonuçlar incelendiğinde, geçmiş veriler için en iyi modellemenin kuadratik yaklaşımla elde edildiği görülmüştür. 2007 yılı için en iyi tahmin

sonuçlarını ise lineer yaklaşım vermiştir. Ortalama yüzde hata oranları her üç yöntem için de %7'nin altında kalmıştır. Yıllık toplam tüketim verileri için de aynı yöntemlerle regresyon analizi yapılmıştır. Ayrıca, giriş ve çıkış değerleri arasında lineer olmayan bağıntı kurarak esnek tahminde bulunma imkânına sahip YSA zaman serisi yaklaşımı ile eğitilmiş ve 2007 yılı için % 3.36 sonucu elde edilmiştir.

Geem ve Roper (2009) çalışmasında GSYH, nüfus, ithalat ve ihracat değişkenleri ele alınarak enerji talebi tahmin çalışması yapılmıştır. YSA yardımıyla yapılan bu çalışmada 1980-2007 yılları arasındaki verileri kullanılmış, 2008-2025 yılları toplam enerji talebi tahmin edilmiştir.

Hamzaçebi (2007) çalışmasında elektrik enerjisi talep tahmin çalışması yapmıştır. YSA metodu kullanılan çalışmada 2005-2020 yılları için tahminleme çalışması yapılmıştır.

Sattari ve diğ. (2007) çalışmasında rezervuar işletmesinde depolanan, savaklanan, hazne alanı üzerine düşen yağış ve buradan buharlaşan su miktarları tahmin edilmiştir. İleri beslemeli geriye yayılım YSA kullanılarak tahmin edilmiştir. Rezervuar için süreklilik denklemi hem ölçülmüş ve hem de simüle edilmiş akımlarla çözümlenerek rezervuar parametreleri araştırılmıştır. Sonuçlar, gözlenmiş değerler ve simülasyonundan elde edilen değerler arasında genellikle uyum sağladığını göstermiştir.

Lawrence ve diğ. (1997) çalışmasında yapay sinir ağları yaklaşımı ile yüz tanıma problemini ele almıştır. Girdi ve çıktı verileri için bir kişinin 10 farklı profil fotoğrafı kullanılmıştır. Resmin üzerine bir pencere gibi küçük hücreler oluşturulmuştur. Bu pencerelerdeki her konum bir vektör anlamına gelmektedir. Resimde dolan vektörler ile hesaplama yapılmıştır. Kişi sayısı arttıkça hata oranının yükseldiği gözlemlenmiştir.

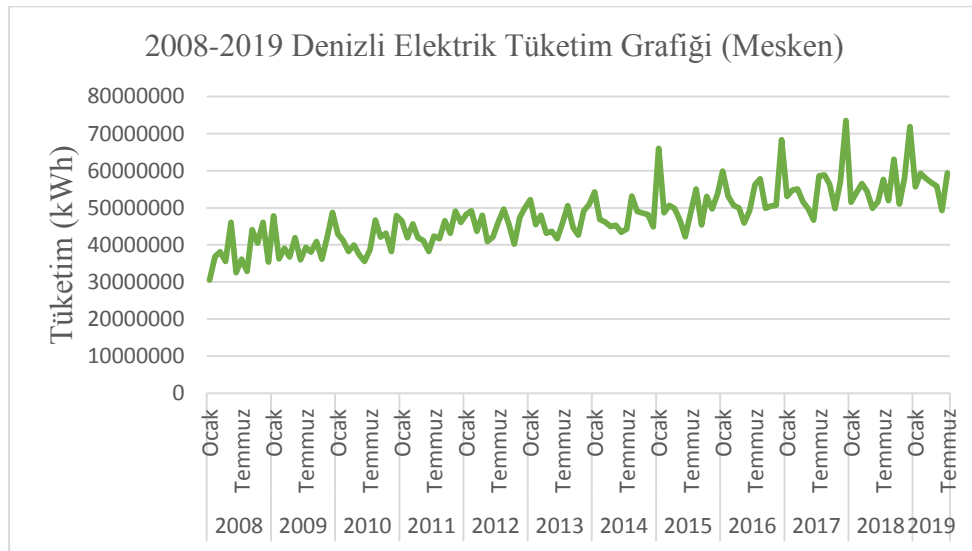
Literatürde konu ile ilgili çalışmalara bakıldığında, önceki çalışmalarda Denizli ili için YSA kullanılarak elektrik tüketim tahmini çalışmasının olmadığı gözlenmiştir. Bu nedenle bu tez çalışması literatüre katkı sağlayan bir çalışma olmuştur.

5. YÖNTEM VE UYGULAMA

Bu tez çalışmasında, 2008-2019 yıllarına ait Denizli mesken aboneleri elektrik tüketim miktarı, nüfus, elektrik birim fiyatları, işsizlik, sıcaklık gibi elektrik tüketimine etkisi olduğu bilinen değişkenler kullanılarak; YSA metodu ile MATLAB programı yardımı ile Denizli ili tüketim tahmini yapılmıştır. Tahminleme çalışmasında kullanılacak olan parametrelerin belirlenmesinde literatürde yapılmış olan çalışmalardan yararlanılmış ve elektrik talep tahmin çalışmalarında sıklıkla kullanılan parametreler seçilmiştir. Gerçek veriler ile tahmin verileri karşılaştırılarak gerçeğe yakınlığı ölçülmüştür. Gerçek veri ile tahmin verisi arasındaki korelasyon ve hata değerleri hesaplanmıştır.

5.1 Veriler

Yapay sinir ağları ile elektrik tüketim tahmini çalışmasında kullanılan veriler Ek A' da belirtilmiştir. Ek A' da belirtilen Girdi1, Girdi2, Girdi3, Girdi4 verileri TÜİK'ten, Girdi5 verileri MGM'den elde edilmiştir. Hedef verisi olan elektrik tüketim miktarları ADM Elektrik Dağıtım Şirketi'nden elde edilmiştir. Hedef verisi olarak kullanılan tüketim miktarlarının yıllar içerisindeki değişimi Şekil 5.1'teki grafikte belirtilmiştir.



Şekil 5.1: 2008-2019 Denizli elektrik tüketim grafiği

Grafiđi incelediđimizde gemiřten gnmze elektrik tketimleri aylık bazda dalgalanmalar gsterse de yıllar bazında artış eđiliminde olduđunu syleyebiliriz. Hane halkı oranı yıllar bazında azalış gsterse bile nfusun yıllar bazında artması, elektrik tketimlerinin yıllık bazda artışında nemli bir etkiye sahip olduđunu gstermektedir. Nfusun artmasına ynelik hane halkı sayısının azalması ise inřaat sektrnn hızlanması ile konut sayılarındaki artış olduđu dřnlmektedir. Bu nedenle elektrik tketimine etkisi olan deđiřkenler arasına konut yapım oranları eklenerek, oluřturulan modelin geliřtirilebileceđi dřnlmektedir. Sıcaklık deđerlerinin elektrik tketimine etkisi, zellikle yaz ve kış aylarında olmuřtur. zellikle yaz ve kış aylarındaki artışın sebebi sıcaklıđa bađlı elektrikli kaynakların kullanımının artması gsterilebilir.

2019 yılının girdi verileri henz kurumlar tarafından aıklanmamıřtır. Gemiř yılların verileri gz nne alınarak yıllık artış ve azalış yzdeliklerinin ortalaması alınmıřtır. Bu ortalama deđer zerinden verilerin artıp azalacađı varsayılarak hesaplama yapılmıřtır. Sadece sıcaklık deđerleri yıllar bazında deđiřmeyen bir deđiřken verisidir. Bu nedenle sıcaklık verisi gemiř yılların verisi ile aynı alınmıřtır.

Kullanılan verilerin detayları ařađıdaki gibidir:

1. Denizli mesken abonelerinin tketimleri

ADM Elektrik Dađıtım Anonim řirketinden alınan; Denizli ili aylık elektrik enerjisi tketim deđerleri kullanılarak elektrik enerji talebi tahmini yapılmıřtır.

2. Denizli Nfusu

Elektrik tketim miktarı, nfus deđiřim hızına bađlı olarak deđiřmektedir. Nfusun tahmin deđerlerini etkileyecek nemli bir parametre olmasından dolayı nfus parametresi ele alınmıřtır.

3. Denizli Hane Halkı Sayısı/oranı (Ortalama hane halkı byklđ)

Mesken abonelerinin elektrik tketimlerinde hane ierisinde yařayan kiři sayısının nemi bulunmaktadır. Hane iinde yařayan kiři sayısına bađlı olarak elektrik tketimleri deđiřkenlik gstermektedir.

4. Elektrik Birim Fiyatı

Türkiye elektrik tarifelerindeki birim elektrik fiyatları ve bedelleri Enerji Piyasası Düzenleme Kurumu (EPDK) tarafından belirlenir. EPDK'nın belirlediği fiyatlar, tavan fiyatlardır. Piyasada bu fiyatların üzerinden elektrik satışının yapılması yasaktır. Elektrik birim fiyatı ve tüketime bağlı olarak hesaplanan fatura tutarları değişmektedir. Bu da tüketicilerin elektrik tüketimlerini etkilemektedir. Elektrik birim fiyatı, 1 kilowatt-saat enerji tüketimine ödenen tutardır.

EPDK kontrolündeki mesken tarifeleri tek zamanlı ve üç zamanlı olarak ikiye ayrılır. Tüm mesken aboneleri olağan olarak tek zamanlı tarifieden elektrik alır. Üç zamanlı tarifesinin, tek zamanlıdan temel farkı, gün içinde elektrik talebinin yoğunluğuna göre, üç farklı birim enerji fiyatı uygulanmasıdır. Birim enerji bedelinin, gündüz, puant, gece adındaki zaman dilimlerine göre artıp azalması dışında, kalan bileşenler tek zamanlı tarifeye tamamen aynıdır. Üç zamanlı tarifiede bu zaman dilimlerindeki tüketimler ayrı hesaplanarak toplanır ve faturayı oluşturur. Genellikle gece tüketimi çok yoğun olan tüketiciler (gece üretim yapan iş yerleri) bu tarifeyi tercih eder. Ev tüketicileri için ise genellikle tek zamanlı tarife uygundur. Bu nedenle çalışmamıza tek zamanlı elektrik birim fiyatı konu edilmiştir.

Elektrik birim fiyatlarında vergi, fon ve yasal yükümlülükler dahil edilmemiştir.

5. Denizli İşsizlik Oranı

İşsizlik oranına bağlı olarak tüketim değerlerinin değişkenlik göstereceği literatürdeki çalışmalarda belirtilmiştir (Aktaş 2009). İşsizlik oranı hane halkı sayısına etki etkilediği gibi elektrik tüketim değerlerini de etkilemektedir.

6. Denizli Sıcaklık Değerleri

Meteoroloji Genel Müdürlüğü'nden alınan bilgilere göre Denizli aylık ortalama sıcaklık bilgileri kullanılmıştır. Sıcaklık verilerinin elektrik tüketimine etkisi olduğu incelenen çalışmalar ile bilinmektedir (Uslu 2013).

5.2 Uygulama

Uygulamanın bu bölümünde belirlenen girdi verileri ile hedef verilerini tahminleme çalışması yapılmıştır.

Genellikle bir sinir ağını eğitmeden önce gizli katmandaki nöron sayısı gibi ağıın özelliklerine karar verilmesi gerekmektedir. Ancak doğru veya uygun sayıda gizli katman tanımlamak için kesin kurallar yoktur. Ağıın tasarımı deneme yanılma yöntemi ile bulunmaktadır.

Çalışmada üç katmanlı (giriş katmanı-bir gizli katman-çıkış katmanı) sinir kullanılmıştır. Yapay sinir ağı için, MATLAB'ın nntool komutu kullanılmıştır. Bu çalışmada çıktı elektrik tüketim miktarı, girdiler ise elektrik miktarını tahmin etmek için kullanılan değişkenlerdir. Kullanılan girdi ve hedef verileri tablosu EK A'da verilmiştir.

Daha iyi bir sınıflandırma işlemi için denklem (5.1) kullanılarak verilerin normalizasyon işlemi gerçekleştirilmiş ve veriler 0-1 aralığına getirilmiştir.

$$X_{normalized} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (5.1)$$

Normalize edilen girdi ve hedef verileri MATLAB programına alınmış ve nntool komutunda veriler tanıtılmıştır.

Ağıın eğitimi için verilerin %70'i kullanılmış ve kalan veriler test ve doğrulama için ayrılmıştır. Gizli katmandaki optimum nöron sayısını bulmak için denemeler yapılmıştır. İlk önce eğitim sürecine gizli katmandaki 10 adet nöron sayısı ile ağı eğitime başlanmıştır. Nöron sayısı artırılarak (10-12-15) denemelere devam edilmiştir. Performans ölçüsüne göre en etkili nöron sayıları seçilmiştir. Çalışmada ortalama karesel hata (MSE) performans ölçümü olarak ele alınmıştır. En iyi yapay sinir ağı seçimi MSE'nin değerine bağlıdır. Minimum MSE değeri tahmin değerinin gerçeğe yaklaştığını göstermektedir.

Çalışmada, literatürde en sık kullanılan ve tahmin için en yakın sonuçlar veren Levenberg-Marquardt algoritması kullanılmıştır. Bu algoritma ile

simülasyonlar yapılmış ve sonuçlar incelenmiştir. Aşağıdaki tabloda simülasyonu yapılan bazı ağ yapıları ve MSE sonuçları verilmiştir. Bu tabloda ağ mimarisi ile kullanılan nöron sayısı, gizli katman sayısı gösterilmektedir. Örneğin ag1'deki 5-10-1, giriş, gizli ve çıkış katmanlarındaki nöron sayılarını ifade etmektedir.

Tablo 5.1: Simülasyon sonuçları


Eğitim sonuçları						
Ağ	ag1	ag2	ag3	ag4	ag5	ag6
Ağ mimarisi	5-10-1	5-12-1	5-15-1	5-10-1	5-12-1	5-15-1
Aktivasyon fonksiyonu	Levenberg-Marguardt	Levenberg-Marguardt	Levenberg-Marguardt	Levenberg-Marguardt	Levenberg-Marguardt	Levenberg-Marguardt
Gizli Katman	1	1	1	1	1	1
Eğitim algoritması	logsig	logsig	logsig	tansig	tansig	tansig
Minimum MSE	0,0014072	0,006304	0,008381	0,0067833	0,0037764	0,0070064
Ağ	ag7	ag8	ag9	ag10	ag11	ag12
Ağ mimarisi	5-10-1	5-12-1	5-15-1	5-10-1	5-12-1	5-15-1
Aktivasyon fonksiyonu	Levenberg-Marguardt	Levenberg-Marguardt	Levenberg-Marguardt	Levenberg-Marguardt	Levenberg-Marguardt	Levenberg-Marguardt
Gizli Katman	2	2	2	2	2	2
Eğitim algoritması	logsig	logsig	logsig	tansig	tansig	tansig
Minimum MSE	0,005391	0,0087594	0,005639	0,0028871	0,0049961	0,0080361

Analiz edilen tabloya göre en iyi sonucu Levenberg-Marquardt algoritmasında, 10 nöronlu, tek gizli katmanda, aktivasyon fonksiyonu logsig olan ağ yapısı vermiştir. Sonuçlar Tablo 5.2'de gösterilmiştir.

Tablo 5.2: Optimum ağ yapısı

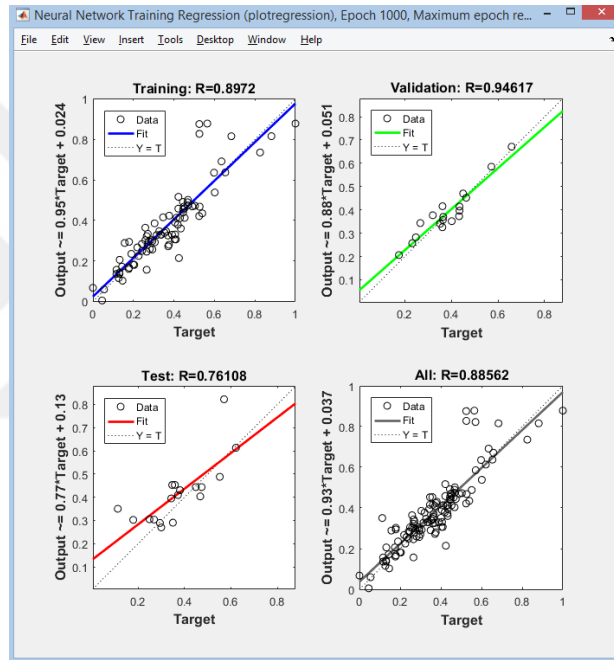
Eğitim sonuçları	
Ağ mimarisi	5-10-1
Aktivasyon fonksiyonu	logsig
Eğitim algoritması	Levenberg-Marguardt
Minimum MSE	0,0014072

Optimum ağ yapısı MATLAB’ da Şekil 5.2’de gösterildiği gibi oluşmuştur.



Şekil 5.2: Optimum ağ yapısı

Ağın eğitim, test ve doğrulama sonuçları ile oluşan regresyon grafiği şekil 5.3’te belirtilmiştir.



Şekil 5.3: Regresyon grafiği

R^2 değerinin 1’e yakın olması gerçek verileri ile tahmin verileri arasındaki ilişkinin yakın olduğu, 0’a yakın olması rasgele ilişki olduğu anlamına gelmektedir. Modelin sonucunda eğitim R^2 değeri: 0,8049, test R^2 değeri: 0,5792, doğrulama R^2 değeri: 0,8952 olarak bulunmuştur. Buradan YSA’nın eldeki veriler ile kötü sonuçlar vermediğini göstermektedir.

Optimum ağ modeli kullanılarak; 2018 ve 2019 verileri eğitilen ağa verilmiş ve tahmin sonuçları elde edilmiştir. Tahmin sonuçları normalize olan değerler ile ortaya çıkmıştır. Gerçek değerlere ulaşmak için denormalizasyon çalışması yapılmış ve Tablo 5.3’teki tahmin sonuçları elde edilmiştir.

Tablo 5.3: 2018-2019 Elektrik tüketim tahmin sonuçları

Yıl	Ay	Tüketim (kWh)
2018	Ocak	49359958
2018	Şubat	49415109
2018	Mart	49849399
2018	Nisan	51414858
2018	Mayıs	56633092
2018	Haziran	50104011
2018	Temmuz	53249571
2018	Ağustos	53235311
2018	Eylül	53249750
2018	Ekim	50569789
2018	Kasım	50790005
2018	Aralık	51497255
2019	Ocak	69481817
2019	Şubat	69259290
2019	Mart	64003191
2019	Nisan	60151769
2019	Mayıs	60790991
2019	Haziran	53954114
2019	Temmuz	62239264

Elde edilen tahmin sonuçları ile gerçek tüketim verileri karşılaştırılmıştır. Gerçek ve tahmin verileri arasındaki uyumu gözleyebilmek için korelasyon sayısı ölçülmüştür. Tahmin verileri ile hedef verileri arasındaki korelasyon sayısı 0,6094 olarak bulunmuştur. Bu da verilerin ortalama bir uyum içerisinde olduğunu göstermektedir.

Tablo 5.4: Gerçek ve tahmin değerlerinin karşılaştırılması

Yıl	Ay	Gerçek (kWh)	Tahmin (kWh)
2018	Ocak	51508345	49359958
2018	Şubat	54116483	49415109
2018	Mart	56544759	49849399
2018	Nisan	54466230	51414858
2018	Mayıs	49864868	56633092
2018	Haziran	51639441	50104011
2018	Temmuz	57621188	53249571
2018	Ağustos	51979365	53235311
2018	Eylül	63086669	53249750
2018	Ekim	51036912	50569789
2018	Kasım	57949835	50790005
2018	Aralık	71907610	51497255
2019	Ocak	55700708	69481817
2019	Şubat	59301551	69259290
2019	Mart	57932631	64003191
2019	Nisan	56784178	60151769
2019	Mayıs	55803264	60790991
2019	Haziran	49283800	53954114
2019	Temmuz	59385493	62239264

Sonuçlardan da görüleceği üzere tahmin ve gerçek verileri arasında bir uyum söz konusudur. Tüketim değerlerinde 2019 yılının başında bir artış gerçekleştiği gözlenmiştir. Mevsimselliğinde etkisi ile tüketim sonuçlarında bir dalgalanma olduğu görülmektedir. Özellikle yaz ve kış aylarındaki elektrik tüketiminin artış sebebi sıcaklığa bağlı olarak elektrikli kaynakların kullanımı olarak düşünülmektedir.

Yapay sinir ağlarının performansını ölçme için hata sapmalarında kullanılan yöntemlerden; MAPE (Mean Absolution Percantage Error) yöntemi kullanılmıştır. MAPE yöntemi ile ortalama mutlak yüzde hataları hesaplanmıştır.

Elde edilen MAPE değeri 0,1028 ile yaklaşık %10 olarak hesaplanmıştır. Bu değer ortalama %10 oranında bir sapma oluştuğunu göstermektedir. MAPE değerleri %10'un altında olan tahmin modellerini "yüksek doğruluk" derecesine sahip, %10 ile %20 arasında olan modelleri ise "doğru tahminler" olarak sınıflandırılmıştır. Benzer şekilde, MAPE değerleri %10'un altında olan modelleri "çok iyi", %10 ile %20 arasında olan modelleri "iyi", %20 ile %50 arasında olan

modelleri “kabul edilebilir” ve %50’nin altında olan modelleri ise “yanlıř ve hatalı” olarak sınıflandırılmıřtır (Karaatlı ve Albeni 2011).

MAPE deęeri %10,28 ile yapılan tahmin iyi veya doęru tahmin diyebileceğimiz sınıfa girmektedir. Yapılan tahminler gerek deęerlerle karřılařtırıldıęında genelde tahmin edilen ve gerekleřen deęerlerin birbirlerine uzak olmadıęı grlmektedir.



6. SONUÇLAR VE DEĞERLENDİRME

Ülkemizde elektrik talep tahminleri yapılmakta olup, tahminler özellikle yatırım ve kapasite belirleme amaçlı kullanılmaktadır. Aynı zamanda, elektrik üretim ve dağıtım şirketlerinin elektrik üretim ve iletim planlamalarını yapabilmeleri için de tahmin çalışmaları yapılmaktadır. Söz konusu şirketlerin, sürdürülebilir ve etkin bir yol haritası çizebilmeleri, tüketicilere kesintisiz, sürekli ve uygun fiyatlı hizmet verebilmeleri yapılan tahminlerin başarısına bağlıdır.

Bu çalışmada yapay sinir ağları yöntemi kullanılarak Denizli mesken abonelerinin elektrik tüketimi tahmin edilmiştir. Ocak-2008 ile Temmuz-2019 yılları arasındaki aylık veriler dikkate alınmıştır. Denizli mesken aboneleri elektrik tüketim miktarı, nüfus, elektrik birim fiyatları, işsizlik, sıcaklık gibi elektrik tüketimine etkisi olduğu bilinen değişkenler kullanılarak; yapay sinir ağları metodu ile MATLAB programı yardımı ile Denizli ili tüketim tahmini yapılmıştır. Yapılan tahminler ile gerçek veriler karşılaştırılmıştır. Yapay sinir ağlarının yapılarının davranışı incelenmiş, gerçek veriler ile tahmin verileri arasındaki uyum gözlenmiştir. Korelasyon değeri 0,6094 ile makul seviyede olduğu söylenebilir. Daha anlamlı tahmin değerlerinin elde edilebilmesi için gözlem sayısı artırılarak çok daha önceki yıllara ait verilerin elde edilerek kullanılmasının uygun olacağı düşünülmektedir.

Gelecekteki araştırmalarda daha farklı sayıda ve türde değişkenler kullanılarak elektrik tüketimi tahmin edilebilir. Yaz ve kış aylarındaki klima kullanımı, kışın doğalgaz tüketimi, konut yapım oranları gibi değişkenlerden yararlanılarak farklı çalışmalar yapılabilir. Gelecekte elektrik üretim ve dağıtım firmaları bazında daha ayrıntılı çalışmalar yapılarak elektrik sektörü açısından faydalı bilgiler sağlanabilir. Bu çalışma elektrik sektörü yöneticileri için ileriye yönelik karar alma ve planlama çalışmalarında yardımcı bir kaynak olarak kullanılabilir.

7. KAYNAKLAR

Abbot, J., Marohasy, J., “Input selection and optimisation for monthly rainfall forecasting in Queensland, Australia, using artificial neural networks”, *Atmospheric Research*, 138, 166-178, (2014).

Akın, E., “Hane Halkları Elektrik Talebi”, Yüksek Lisan Tezi, *Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü*, İktisat Anabilim Dalı, Denizli, (2010).

Aktaş, C., “Türkiye’de Elektrik Tüketimi, İstihdam ve Ekonomik Büyüme Arasındaki İlişkinin Hata Düzeltme Modeliyle Analizi”, *Dumlupınar Üniversitesi, Sosyal Bilimler Dergisi*, 25, 61-68, (2009).

Alpaydın, E., “*Yapay Öğrenme*”, 2. Baskı, İstanbul: Boğaziçi Üniversitesi Yayınevi, İstanbul, (2012).

Amrouche, B., Pivert, X.L., “Artificial neural network based daily local forecasting for global solar radiation. *Applied Energy*”, 130, 333-341,(2014).

Aran O., Yıldız O. T., and Alpaydın E., “an Incremental Framework Based on Cross-Validation for Estimating the Architecture of a Multilayer Perceptron,” *Int. J. Pattern Recognit. Artif. Intell.*, 23(2), 159–190, (2009).

Arı A., ve Berberler M. E., “Yapay Sinir Ağları ile Tahmin ve Sınıflandırma Problemlerinin Çözümü İçin Arayüz Tasarımı”, *Acta Infologica*, Dokuz Eylül Üniversitesi, Bilgisayar Bilimleri Bölümü, İzmir, 2602-3563 (2017).

Aydın D., Toros H., “Prediction of Short-Term Electricity Consumption by Artificial Neural Networks Using Temperature Variables” , *European Journal of Science and Technology*, 14, 393-398, (2018).

Azmira, W. A. R., Rahman T. K. A., Zakaria Z, Arfah A., “Short term electricity price forecasting using neural network”, *Proceedings of the 4th International Conference on Computing and Informatics, ICOCI*, (2013).

Bayındır R. and Sesveren Ö., “Ysa Tabanlı Sistemler İçin Görsel Bir Arayüz Tasarımı,” *Mühendislik Bilimleri Dergisi*, 14(1), 101– 109, (2008).

Boltürk, E., “Elektrik Talebi Tahmininde Kullanılan Yöntemlerin Karşılaştırılması”, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi Fen bilimleri Enstitüsü*, Endüstri Mühendisliği Anabilim Dalı, İstanbul, (2013).

BP, “*Statistical Review of World Energy – Electricity Section*”, Haziran, (2018).

Blum, C. ve Roli, A., “Metaheuristics in Combinatorial Optimization: Overview and Conceptual Comparison”, *ACM Computing Surveys*, 35(3), 268-308, (2003)

Calp M. H., “İşletmeler için Personel Yemek Talep Miktarının Yapay Sinir Ağları Kullanılarak Tahmin Edilmesi”, *Politeknik Dergisi*, Araştırma Makalesi, (2018).

Chopra, S., Meindi, P., “Supply chain management, strategy, planning and operation”, Fifth Edition, Global Edition. Pearson, (2012).

Deo, C. R., Şahin, M., “Application of the Neural Network model for prediction of monthly Standardized Precipitation and Evapotranspiration Index using hydrometeorological parameters and climate indices in eastern Australia”, *Atmospheric research*, 161, 162, 65-81, (2015).

Elmas Ç., “*Yapay Zeka Uygulamaları*”, Seçkin Yayıncılık, Ankara, 978-975, (2007).

Erdoğan, E.. “Electricity Demand Analysis Using Cointegration and ARIMA Modelling: A case study of Turkey”, *Munich Personal RePEc Archive*, 19099, 22, (2009).

EÜAŞ, Elektrik Üretim A.Ş., “2018 Elektrik Üretim Sektör Raporu”, Sektör Raporu, (2019).

Farely, B. G., And Clark, W. A. “Simulation of self-organizing systems by digital computers”, *IEE Transaction of Professional Group of Information Theory*, PGIT-4, 76-84 (1954).

Fukushima, K., “Neocognitron: a self-organizing neural network model for amechenism of pattern recognition, 15, 455-469, (1982).

Geem, Z.W. Roper, W.E., “Energy demand estimation of South Korea using artificial neural network”, *Energy Policy*, 37, 10, 4049- 4054, (2009).

Ghiassi, M., Lio, D., Brian M.,. “Pre-production forecasting of movie revenues with a dynamic artificial neural network”, *Expert Systems with Applications*, 42, 3176-3193, (2015).

Gültekin, Ö., “Bursa ili orta dönem elektrik talep tahmini”, Yüksek lisans tezi, *Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü*, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Kütahya, (2009).

Hamzaçebi, C., “Forecasting of Turkey’s net electricity energy consumption on sectoral bases”, *Energy Policy*, 35, 3, (2007).

Hamzaçebi, C., Kutay, F., “Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini”, *Gazi Üniversitesi, Mühendislik Mimarlık Fakültesi Dergisi*, 19(3), 227–233, Ankara, (2004).

Hatipoğlu, T., Boran, S., Özcan, B., Fırlı, A., “Yapay sinir ağı yaklaşımıyla çinko kalınlığının tahminlenmesi”, *Sakarya Üniversitesi Fen Bilimleri Dergisi*, 17, 61-69, (2013).

Haykin, S., “*Neural Networks: A Comprehensive Foundation*”, 2. Baskı, Pearson. Upper Saddle River, NJ, USA (1999).

Hengirmen M. O., “Comparison of Three Forecast Methods for Power Demand in Gaziantep”, *Eleco 99*, 85-188, Bursa, (1999).

Hebb, D. O., “The organization of behavior” , New York: Wiley introduction and Chapter4 “The first stage of perception: growth of the assembly”, Xi-xix, 60-78, (1949).

Ho, W-H., Lee, K-T., Chen, H-Y., Ho, T-W., Chiu, H-C., “Disease-Free Survival after Hepatic Resection in Hepatocellular Carcinoma Patients: A Prediction Approach Using Artificial Neural Network”, 7(1), (2012).

Hopfield, J. J., “Neurons with graded response have collective computational properties like those of two state neurons”, *Proc. Natl. Acad. Sci.*,81, 3088-3092, (1982).

Kalaitzakis, K., Stavrakakis, G.S., Anagnostakis, E. M., “Short-term load forecasting based on artificial neural networks parallel implementation”, Technical University of Crete, Elsevier Science B.V., Chania, Greece, (2002).

Karlık, B., Kızılaslan, R., “Yapay Sinir Ağları Yöntemiyle İstanbul Doğalgaz İhtiyacının Tahmin Edilmesi Ve Gaz Tüketim Hesaplama Programının Yazılması”, Araştırma Projesi, (2009).

Karaatlı M., Albeni M., “Gül Çiçeği Dikim Alanlarının Yapay Sinir Ağları Yöntemiyle Tahmini” Akdeniz Üniversitesi, *Uluslararası Alanya İşletme Fakültesi Dergisi*, 3(2), 137-149, (2011).

Kaynar, O., Taştan, S., Demirkoparan, F. “Yapay Sinir Ağları İle Doğalgaz Tüketim Tahmini”, *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 25, (2011).

Kaytez, F.. “En Küçük Kareler Destek Vektör Makineleri İle Türkiye'nin Uzun Dönem Elektrik Tüketim Tahmini ve Modellemesi”, Yayınlanmamış Doktora Tezi, *Gazi Üniversitesi Fen Bilimleri Enstitüsü*, Ankara, (2012).

Krenker, A., Janez B. ve Andrej K., “Introduction To Artificial Neural Networks”, *Artificial Neural Networks-Methodological Advances and Biomedical Applications*, InTech, 3-19, (2011).

Kriesel D., “*A Brief Introduction to Neural Networks*”, (2007).

Lawrence, S., Giles, L., Tsoi, A.C., Back, A. D., “Face Recognition: A Convolutional Neural-Network Approach”, *IEEE transactions on neural networks*, 8(1), (1997).

Lewis, C.D., “*Demand Forecasting & Inventory Control*”, Routledge., (2012).

Lise, W., and Montfort K. V., “Energy Consumption And Gdp in Turkey: is There a Cointegration Relationship? İstanbul, (2005).

McCulloch, W. S. and Pitts W. A. “Alogical calculus of the ideas immanent in nervous activity” , *Buttein of Mathematics and Biophysics*, 5, 1151-133, (1943).

Mete, T., “Kesikli Bir Biyoreaktörde Yapay Sinir Ağlarının Kullanımı”, Yüksek Lisans Tezi, *Ankara Üniversitesi Fen Bilimleri Enstitüsü*, Ankara, (2008).

Minsky M., and Papert S., “*Perceptrons*”. (1969).

MGM, Meteoroloji Genel Müdürlüğü, <https://www.mgm.gov.tr/veridegerlendirme/il-ve-ilcelerstatistik.aspx?k=A&m=DENIZLI>, (2018).

Nasıroğlu, H., Nasıroğlu, B., Şahin, M., Yıldız B.Y., Peştemalci, V., “Yapay sinir ağı ve noaaavhrr uydu verilerini kullanarak hava sıcaklığının tahmini”, *Uzaktan Algılama-CBS sempozyumu*, (2016).

Nilson, N. J., “*learning Mechines*”, McGraw-Hill, (1965).

Oğurlu, H.. “Matematiksel Model Kullanarak Türkiye’nin Uzun Dönem Elektrik Yük Tahmini”, Yüksek Lisans Tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Konya, (2011).

Özden, S., Öztürk A., “Yapay Sinir Ağları ve Zaman Serileri Yöntemi ile Bir Endüstri Alanının (İvedik OSB) Elektrik Enerjisi İhtiyaç Tahmini”, *Bilişim Teknolojileri Dergisi*, 11, 3, (2018).

Öztemel, E., “*Yapay Sinir Ağları*”, 1. Baskı, İstanbul: Papatya yayıncılık, (2003).

Param, S., Chowdhury M., Lampl D., Dass P., Nygard K. E., “Energy Demand Prediction Using Neural Networks”, North Dakota State University, (2016).

Pınarbaşı, M., “Elektrik Enerji Sistemlerinde Talep Tahmin Yöntemleri ve Yapay Sinir Ağları Uygulaması” ,Yüksek Lisans Tezi, *İstanbul Üniversitesi Fen Bilimleri Enstitüsü*, Elektrik-Elektronik Mühendisliği Anabilim Dalı, İstanbul, (2009).

Rosenblatt, F., “The perceptron: A probabilistic model for information storage and organization in the brain”, *Psychoanalytic Review* , 65,386-408, (1958).

Rumelhart, D.E., and J.L. McClelland, eds., “*Parallel Distributed Processing: Explorations in the Microstructure of Cognition*”, Cambridge, MA: MIT Press, 1, (1986).

Sattari, M. T., Fard, A. F., Docherkhesaz, M., Öztürk, F., “Yapay Sinir Ağları Yöntemi ile Savalan Sulama Rezervuarının Simülasyonu”, *Tarım Bilimleri Dergisi*, 13 (4), 337-345, (2007).

Sordoni, A., Galley M., Auli M., Brockett C., Ji Y., Mitchell M., Nie J., Gao J., Dolan B., “A Neural Network Approach to Context-Sensitive Generation of Conversational Responses”, (2015).

Staub, S., Karaman E., Kaya S., Karapınar H., Güven E., “Artificial Neural Network and Agility”, World Conference on Technology, Innovation and Entrepreneurship, 195, (2015).

Suganthia, L., Anand, A.S., “Energy models for demand forecasting A review”, *Renewable and Sustainable Energy Reviews*, 16, 1223– 1240, (2012).

T.C. Enerji ve Tabii Kaynaklar Bakanlığı, “Enerji ve Tabii Kaynaklar Bakanı Sayın Fatih Dönmez’ in 2019 Yılı Bütçesini TBMM Plan ve Bütçe Komisyonuna Sunuşu”, (2018).

T.C. Enerji ve Tabii Kaynaklar Bakanlığı, “2014 Yılı Genel Enerji Denge Tablosu”, <http://www.eigm.gov.tr/tr-TR/Denge-Tablolari/Denge-Tablolari>, (29 Mayıs 2017).

T.C. Enerji ve Tabii Kaynaklar Bakanlığı, “2015 Yılı Genel Enerji Denge Tablosu – Rev 01”, <http://www.eigm.gov.tr>, (15 Kasım 2016).

Tealab A., “Time series forecasting using artificial neural networks methodologies: A systematic review”, *Future Computing and Informatics Journal*, 3, 334-340, (2018).

TEİAŞ, “Türkiye Elektrik Üretim-İletim 2017 Yılı İstatistikleri”, <http://www.teias.gov.tr/tr/turkiye-elektrik-uretim-iletim-2017-yili-istatistikleri>, son erişim: 21 Mayıs, (2019).

TEİAŞ, “Türkiye Elektrik Enerjisi 5 Yıllık Üretim Kapasite Projeksiyonu (2018-2023)”, Mayıs (2018).

TEİAŞ Yük Tevzi Bilgi Sistemi, “2018 Yılı Genel İşletme Neticesi”, <http://ytbs.teias.gov.tr/>, son erişim: 21 Mayıs, (2019).

Tsaur, R.C., Kuo, T.C., “The adaptive fuzzy time series model with an application to Taiwan’s tourism demand”, *Expert Systems with Applications*, 38, 8, 9164-9171, (2011).

TÜİK, Türkiye İstatistik Kurumu, <http://www.tuik.gov.tr>, (2019).

US Environmental Protection Agency, “Global Greenhouse Gas Emissions Data”, <https://www.epa.gov/ghgemissions/global-greenhouse-gas-emissions-data>, (29 Mayıs 2017).

Uslu, M.F., Şanlı, B., Temur, T., “Türkiye Aylık elektrik Talep Modeli”, Araştırma Makalesi, (2013).

Widrow, B. And Hoff, M. E. “Adaptive switching circuits”, West-Con Convention, Record Part IV, 96-104 (1960).

Yalçınöz, T., Herdem, S., Eminoğlu, U., “Yapay Sinir Ağları ile Niğde Bölgesinin Elektrik Yük Tahmini”, Eleco 2002, *Elektrik-Elektronik- Bilgisayar Mühendisliği Sempozyumu*, Bursa, (2002).

Yılmaz V.. “Enerji Talebi Ve Tokat’ta Elektrik Enerjisi Talebi Üzerine Bir Uygulama” Yüksek Lisans Tezi, *Gaziosmanpaşa Üniversitesi Sosyal Bilimler Enstitüsü*, İktisat Ana Bilim Dalı, Tokat, (2010).

Yurtoğlu H., “Yapay Sinir Ağları Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler için Türkiye Örneği”, Uzmanlık Tezi, *Ekonomik Modeller Ve Stratejik Araştırmalar Genel Müdürlüğü*, Ankara, (2005).

Ziebig, A., Hoinka, K., “Energy Systems of Complex Buildings Green Energy and Technology”, Springer, 345, (2013).



8. EKLER

EK A

Girdi ve Hedef verileri

Yıl	Ay	Girdi1	Girdi2	Girdi3	Girdi4	Girdi5	Hedef
		Nüfus	Hane halkı sayısı	Yıllara göre (TL/Kwh)	İşsizlik oranı(%)	Sıcaklık(C°)	Denizli Mesken (Kwh)
2008	Ocak	917836	3,39	0,15	9,40	5,90	30555838
2008	Şubat	917836	3,39	0,15	9,40	7,10	36832516
2008	Mart	917836	3,39	0,15	9,40	10,20	38138041
2008	Nisan	917836	3,39	0,15	9,40	14,80	35530821
2008	Mayıs	917836	3,39	0,15	9,40	19,80	46051728
2008	Haziran	917836	3,39	0,15	9,40	24,70	32496660
2008	Temmuz	917836	3,39	0,17	9,40	27,60	36194432
2008	Ağustos	917836	3,39	0,17	9,40	27,00	32903413
2008	Eylül	917836	3,39	0,17	9,40	22,50	44058329
2008	Ekim	917836	3,39	0,20	9,40	16,90	40490394
2008	Kasım	917836	3,39	0,20	9,40	11,50	46051728
2008	Aralık	917836	3,39	0,20	9,40	7,60	35363022
2009	Ocak	926362	3,38	0,20	13,20	5,90	47780673
2009	Şubat	926362	3,38	0,20	13,20	7,10	36222869
2009	Mart	926362	3,38	0,20	13,20	10,20	39084345
2009	Nisan	926362	3,38	0,19	13,20	14,80	36721744
2009	Mayıs	926362	3,38	0,19	13,20	19,80	41954374
2009	Haziran	926362	3,38	0,19	13,20	24,70	36017834
2009	Temmuz	926362	3,38	0,19	13,20	27,60	39315287
2009	Ağustos	926362	3,38	0,19	13,20	27,00	38042598
2009	Eylül	926362	3,38	0,19	13,20	22,50	40939996
2009	Ekim	926362	3,38	0,21	13,20	16,90	36172443
2009	Kasım	926362	3,38	0,21	13,20	11,50	41954374
2009	Aralık	926362	3,38	0,21	13,20	7,60	48783663
2010	Ocak	931823	3,33	0,22	11,20	5,90	42870454
2010	Şubat	931823	3,33	0,22	11,20	7,10	41234858
2010	Mart	931823	3,33	0,22	11,20	10,20	38229289
2010	Nisan	931823	3,33	0,22	11,20	14,80	39975530
2010	Mayıs	931823	3,33	0,22	11,20	19,80	37285462
2010	Haziran	931823	3,33	0,22	11,20	24,70	35552068
2010	Temmuz	931823	3,33	0,22	11,20	27,60	38695752
2010	Ağustos	931823	3,33	0,22	11,20	27,00	46668456
2010	Eylül	931823	3,33	0,22	11,20	22,50	42079342
2010	Ekim	931823	3,33	0,22	11,20	16,90	43152957
2010	Kasım	931823	3,33	0,22	11,20	11,50	38211759

2010	Aralık	931823	3,33	0,22	11,20	7,60	47869923
2011	Ocak	942278	3,22	0,22	7,20	5,90	46445648
2011	Şubat	942278	3,22	0,22	7,20	7,10	41982500
2011	Mart	942278	3,22	0,22	7,20	10,20	45632611
2011	Nisan	942278	3,22	0,25	7,20	14,80	41951715
2011	Mayıs	942278	3,22	0,25	7,20	19,80	41156300
2011	Haziran	942278	3,22	0,25	7,20	24,70	38227548
2011	Temmuz	942278	3,22	0,25	7,20	27,60	42382959
2011	Ağustos	942278	3,22	0,25	7,20	27,00	41662492
2011	Eylül	942278	3,22	0,25	7,20	22,50	46511067
2011	Ekim	942278	3,22	0,24	7,20	16,90	43164089
2011	Kasım	942278	3,22	0,24	7,20	11,50	49141358
2011	Aralık	942278	3,22	0,24	7,20	7,60	46069271
2012	Ocak	950557	3,17	0,24	6,90	5,90	48256116
2012	Şubat	950557	3,17	0,24	6,90	7,10	49209946
2012	Mart	950557	3,17	0,24	6,90	10,20	43627667
2012	Nisan	950557	3,17	0,26	6,90	14,80	47988182
2012	Mayıs	950557	3,17	0,26	6,90	19,80	40939546
2012	Haziran	950557	3,17	0,26	6,90	24,70	42127022
2012	Temmuz	950557	3,17	0,26	6,90	27,60	46147653
2012	Ağustos	950557	3,17	0,26	6,90	27,00	49663362
2012	Eylül	950557	3,17	0,26	6,90	22,50	45571841
2012	Ekim	950557	3,17	0,28	6,90	16,90	40226658
2012	Kasım	950557	3,17	0,28	6,90	11,50	47337705
2012	Aralık	950557	3,17	0,28	6,90	7,60	49994757
2013	Ocak	963464	3,14	0,28	6,50	5,90	52182100
2013	Şubat	963464	3,14	0,28	6,50	7,10	45436512
2013	Mart	963464	3,14	0,28	6,50	10,20	47947580
2013	Nisan	963464	3,14	0,28	6,50	14,80	43170232
2013	Mayıs	963464	3,14	0,28	6,50	19,80	43688078
2013	Haziran	963464	3,14	0,28	6,50	24,70	41669307
2013	Temmuz	963464	3,14	0,28	6,50	27,60	45763917
2013	Ağustos	963464	3,14	0,28	6,50	27,00	50599834
2013	Eylül	963464	3,14	0,28	6,50	22,50	44603101
2013	Ekim	963464	3,14	0,28	6,50	16,90	42614672
2013	Kasım	963464	3,14	0,28	6,50	11,50	49190296
2013	Aralık	963464	3,14	0,28	6,50	7,60	50890102
2014	Ocak	978700	3,12	0,28	7,20	5,90	54251934
2014	Şubat	978700	3,12	0,28	7,20	7,10	46882374
2014	Mart	978700	3,12	0,28	7,20	10,20	46210317
2014	Nisan	978700	3,12	0,28	7,20	14,80	44994507
2014	Mayıs	978700	3,12	0,28	7,20	19,80	45267421
2014	Haziran	978700	3,12	0,28	7,20	24,70	43407516
2014	Temmuz	978700	3,12	0,28	7,20	27,60	44286644
2014	Ağustos	978700	3,12	0,28	7,20	27,00	53181384
2014	Eylül	978700	3,12	0,28	7,20	22,50	49002162

2014	Ekim	978700	3,12	0,31	7,20	16,90	48553872
2014	Kasım	978700	3,12	0,31	7,20	11,50	48137335
2014	Aralık	978700	3,12	0,31	7,20	7,60	44909967
2015	Ocak	993442	3,08	0,31	6,90	5,90	65986333
2015	Şubat	993442	3,08	0,31	6,90	7,10	48678099
2015	Mart	993442	3,08	0,31	6,90	10,20	50636286
2015	Nisan	993442	3,08	0,31	6,90	14,80	49799557
2015	Mayıs	993442	3,08	0,31	6,90	19,80	46514021
2015	Haziran	993442	3,08	0,31	6,90	24,70	42182461
2015	Temmuz	993442	3,08	0,31	6,90	27,60	48659450
2015	Ağustos	993442	3,08	0,31	6,90	27,00	55091730
2015	Eylül	993442	3,08	0,31	6,90	22,50	45433011
2015	Ekim	993442	3,08	0,31	6,90	16,90	53069577
2015	Kasım	993442	3,08	0,31	6,90	11,50	49679202
2015	Aralık	993442	3,08	0,31	6,90	7,60	53737618
2016	Ocak	1005687	3,07	0,33	6,70	5,90	59892435
2016	Şubat	1005687	3,07	0,33	6,70	7,10	53117049
2016	Mart	1005687	3,07	0,33	6,70	10,20	50688571
2016	Nisan	1005687	3,07	0,33	6,70	14,80	49946808
2016	Mayıs	1005687	3,07	0,33	6,70	19,80	45924919
2016	Haziran	1005687	3,07	0,33	6,70	24,70	49205813
2016	Temmuz	1005687	3,07	0,33	6,70	27,60	56225365
2016	Ağustos	1005687	3,07	0,33	6,70	27,00	57811277
2016	Eylül	1005687	3,07	0,33	6,70	22,50	49870609
2016	Ekim	1005687	3,07	0,33	6,70	16,90	50449764
2016	Kasım	1005687	3,07	0,33	6,70	11,50	50640533
2016	Aralık	1005687	3,07	0,33	6,70	7,60	68384303
2017	Ocak	1018735	3,04	0,33	7,10	5,90	53094372
2017	Şubat	1018735	3,04	0,33	7,10	7,10	54803358
2017	Mart	1018735	3,04	0,33	7,10	10,20	55046379
2017	Nisan	1018735	3,04	0,33	7,10	14,80	51630009
2017	Mayıs	1018735	3,04	0,33	7,10	19,80	49635628
2017	Haziran	1018735	3,04	0,33	7,10	24,70	46702537
2017	Temmuz	1018735	3,04	0,33	7,10	27,60	58622084
2017	Ağustos	1018735	3,04	0,33	7,10	27,00	58827802
2017	Eylül	1018735	3,04	0,33	7,10	22,50	56378076
2017	Ekim	1018735	3,04	0,33	7,10	16,90	49826404
2017	Kasım	1018735	3,04	0,33	7,10	11,50	57240330
2017	Aralık	1018735	3,04	0,33	7,10	7,60	73481703
2018	Ocak	1027732	3,02	0,36	6,90	5,90	51508345
2018	Şubat	1027732	3,02	0,36	6,90	7,10	54116483
2018	Mart	1027732	3,02	0,36	6,90	10,20	56544759
2018	Nisan	1027732	3,02	0,37	6,90	14,80	54466230
2018	Mayıs	1027732	3,02	0,37	6,90	19,80	49864868
2018	Haziran	1027732	3,02	0,37	6,90	24,70	51639441
2018	Temmuz	1027732	3,02	0,37	6,90	27,60	57621188

2018	Ağustos	1027732	3,02	0,40	6,90	27,00	51979365
2018	Eylül	1027732	3,02	0,44	6,90	22,50	63086669
2018	Ekim	1027732	3,02	0,48	6,90	16,90	51036912
2018	Kasım	1027732	3,02	0,48	6,90	11,50	57949835
2018	Aralık	1027732	3,02	0,48	6,90	7,60	71907610
2019	Ocak	1039425	2,99	0,51	6,81	5,90	55700708
2019	Şubat	1039425	2,99	0,51	6,81	7,10	59301551
2019	Mart	1039425	2,99	0,51	6,81	10,20	57932631
2019	Nisan	1039425	2,99	0,55	6,81	14,80	56784178
2019	Mayıs	1039425	2,99	0,55	6,81	19,80	55803264
2019	Haziran	1039425	2,99	0,55	6,81	24,70	49283800
2019	Temmuz	1039425	2,99	0,59	6,81	27,60	59385493



EK B

Literatür Taraması

Yıl	Yazarlar	Konu	Yöntem
2018	Yuan ve diğ.	Yapay sinir ağları ile Osaka Üniversite kampüsü için elektrik tüketim tahminleme çalışması, Japonya	Yapay Sinir Ağları
2011	Marvuglia ve diğ.	Yapay sinir ağları ile İtalya Palermo kenti için mesken abonelerinde saatlik elektrik tahminleme çalışması	Yapay Sinir Ağları
2011	Hayri Oğurlu	Türkiye geneli elektrik yük tahmini (GSYİH , Nüfus, Yük bilgileri) Daha önce yapılmış olan Maed modülü, Particle Swarm Optimization modeli ve YSA ile karşılaştırma yapılmıştır. Oluşturulan matematiksel model maed ve ysa modeline daha yakın tahmin sonuçları ortaya koymuştur.	Matematiksel Model
2010	Lambros Ekonomou	Yapay sinir ağları kullanılarak uzun dönemli Yunanistan elektrik tüketim tahmini çalışması	Yapay Sinir Ağları
2010	Emre Akın	Hane halklarının elektirik enerjisinin nelere bağlı olarak değiştiği, değişkenlerin elektrik tüketimine etkisi ortaya konmuştur.	Sıralı Logit Modeli
2010	Veysel Yılmaz	Tokat ili elektrik enerjisi talep tahmini (Abone bazında tüketim kWh, fiyatlandırma, abone sayısı)	En küçük kareler yöntemi Doğrusal Trend Analizi
2007	Azedeh ve diğ.	Yapay Sinir Ağı, zaman serisi ve ANOVA entegrasyonu ile elektrik tüketimi tahminleme çalışması, İran, Tahran	Yapay Sinir Ağları Zaman Serileri Anova
2007	Erkan Erdoğan	Elektrik Talep Tahmini (1923-2004 Türkiye Tüketim verileri)	ARIMA
2005	Geoffrey ve diğ.	Elektrik enerjisi tüketimini tahmin edilmesi: Regresyon analizi, karar ağacı ve sinir ağlarının karşılaştırılması	Yapay Sinir Ağları Regresyon Analizi Karar Ağacı

2005	Lise ve diğ.	Türkiye' deki enerji tüketimi ve GSYİH arasındaki ilişkinin incelenmesi	Eş Bütünleşme
2004	Hamzaçebi ve diğ.	Yapay sinir ağları ile Türkiye elektrik tüketim tahminleme çalışması, Uzun vadeli (MATLAB Toolbox), geri yayılım algoritması	Yapay Sinir Ağları
2002	Kalaitzakis ve diğ.	Yunanistan Girit adasındaki 24 saatlik elektrik talep tahmini, Kısa vadeli, geri yayılım algoritması,(saatlik yük verileri)	Yapay Sinir Ağları
2002	Yalçınöz ve diğ.	Elektrik Tüketim verileri kullanılarak Niğde ili elektrik tahminin yapılması	Hareketli Ortalamalar Yöntemi Yapay Sinir Ağları
1999	M.Oğuz Hengirmen	Elektrik Tüketim verileri kullanılarak Gaziantep ili elektrik tahminin yapılması, uygulanan yöntemlerin karşılaştırılması	Doğrusal Regresyon Üstel Regresyon Hareketli Ortalamalar Yöntemi
2018	M.Hanefi Calp	İşletmeler için Personel Yemek Talep Miktarının Yapay Sinir Ağları Kullanılarak Tahmin Edilmesi	Yapay Sinir Ağları
2018	Özden ve diğ.	Yapay Sinir Ağları ve Zaman Serileri Yöntemi ile Bir Endüstri Alanının Elektrik Enerjisi İhtiyaç Tahmini, iki yöntemin karşılaştırılması	Yapay Sinir Ağları Zaman Serileri Yöntemi
2018	Aydın ve diğ.	Sıcaklık Değişkenlerini Kullanan Yapay Sinir Ağları ile Kısa Vadeli Elektrik Tüketimi Tahmini, Türkiyenin bazı şehirleri	Yapay Sinir Ağları
2018	Ahmed Tealab	Yapay sinir ağları metodolojilerini kullanarak zaman serisi tahmini: Sistematik bir inceleme, Makale inceleme çalışması	Yapay Sinir Ağları
2016	Nasıroğlu ve diğ.	Yapay sinir ağları ve uydu verilerini kullanarak haca sıcaklığı tahmini	Yapay Sinir Ağları
2016	Param ve diğ.	Yapay sinir ağları ile enerji talep tahminleme çalışması, İngiltere saatlik tüketim verileri kullanılmıştır.	Yapay Sinir Ağları ARIMA Regresyon Analizi

2015	Deo ve diğ.	Meteorolojik parametreler ve iklim endekslerini kullanarak aylık standart yağışın yapay sinir ağları ile öngörülmesi, Avustralya örneği	Yapay Sinir Ağları
2015	Sordoni ve diğ.	Twitter konuşmaları için otomatik yeni bir yanıt oluşturma sistemi kurgulanması	Yapay Sinir Ağları
2015	Ghiassi ve diğ.	Filmlerin gişe hâsılatlarının, film yapımından önce tahmin edecek YSA modelinin kurulması	Yapay Sinir Ağları
2015	Staub ve diğ.	Yapay sinir ağları analizi ve çeviklik konusu ile ilişkisi	Yapay Sinir Ağları
2014	Abbot ve diğ.	Avustralya'nın üç bölgesi için YSA yöntemi kullanılarak yağmur yağış miktarının orta dönem tahmin edilmesi	Yapay Sinir Ağları
2012	Kaytez ve diğ.	Elektrik talep tahminlemede en küçük kareler yöntemi, yapay sinir ağlarını ve regresyon analizi kullanılması ve yöntemlerin karşılaştırılması, Türkiye Genel	Yapay Sinir Ağları En küçük kareler yöntemi Regresyon Analizi
2014	Amrouche ve diğ.	Yapay sinir ağları ile bölgesel güneş ışığı tahminleme,Fransa	Yapay Sinir Ağları
2013	Eda Boltürk	Yapay sinir ağları ve diğer belirtilen yöntemler ile elektrik tüketim tahminlemesi,Türkiye bölgesel	Yapay sinir Ağları Hareketli Ortalama ARIMA
2013	Azmira ve diğ.	Yapay sinir ağları ile elektrik fiyat tahminlemesi,Kanada Ontario	Yapay Sinir Ağları
2013	Hatipoğlu ve diğ.	Yapay sinir ağı yaklaşımıyla çinko kalınlığının tahminlenmesi	Yapay Sinir Ağları
2012	Ho ve diğ.	Hepatosellüler karsinoma hastalarında hepatik rezeksiyon sonrası hastalısız sağkalım: yapay sinir ağı kullanan bir tahmin yaklaşımı	Yapay Sinir Ağları Regresyon Analizi
2011	Kaynar ve diğ.	Yapay sinir ağları ile doğalgaz tüketim tahminlemesi, Ankara	Yapay sinir Ağları ARIMA

2009	Karlık ve diğ.	Yapay sinir ağırları yöntemiyle İstanbul doğalgaz ihtiyacının tahmin edilmesi ve gaz tüketim hesaplama programının yazılması	Yapay Sinir Ağları
2009	Ömer Gültekin	Yapay sinir ağırları ile Bursa ili orta dönem elektrik talep tahminlemesi	Yapay Sinir Ağları
2009	Geem ve diğ.	Yapay sinir ağırları ile Güney Kore' de enerji talep tahminleme çalışması	Yapay Sinir Ağları
2007	Coşkun Hamzaçebi	Türkiye' de sektörel bazda elektrik enerjisi tahminlemesi	Yapay Sinir Ağları
2007	Sattari ve diğ.	Yapay sinir ağırları yöntemi ile Savalan sulama rezervuarının simülasyonu	Yapay Sinir Ağları
1997	Lawrence ve diğ.	Yapay sinir ağırları yaklaşımı ile yüz tanıma problemi	Yapay Sinir Ağları

9.ÖZGEÇMİŞ

Adı Soyadı : Sevgi ÖKSÜZ

Doğum Yeri ve Tarihi : BURDUR/Bucak 23.04.1993

Lisans Üniversite : Pamukkale Üniversitesi

Elektronik posta : sevgikorkmaz01@gmail.com

İletişim : Kervansaray Mah. 3030 Sok. No:13

Daire: 8 Kat:4 DENİZLİ