



**T.C.
İZMİR KÂTİP ÇELEBİ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI**

**TÜRKİYE ELEKTRİK ENERJİSİ TALEBİNİN
YAPAY SİNİR AĞLARI MODELİ İLE TAHMİNİ**

Yüksek Lisans Tezi

GİZEM ÖZAYDIN

İZMİR – 2019

**T.C.
İZMİR KÂTİP ÇELEBİ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI**

**TÜRKİYE ELEKTRİK ENERJİSİ TALEBİNİN
YAPAY SİNİR AĞLARI MODELİ İLE TAHMİNİ**

Yüksek Lisans Tezi

GİZEM ÖZAYDIN

DANIŞMAN: DR. ÖĞR. ÜYESİ BERNA TEKTAŞ SİVRİKAYA

İZMİR – 2019



YEMİN METNİ

Yüksek Lisans Tezi olarak sunduğum “**TÜRKİYE ELEKTRİK ENERJİSİ TALEBİNİN YAPAY SİNİR AĞLARI MODELİ İLE TAHMİNİ**” adlı çalışmanın, tarafımdan, akademik kurallara ve etik değerlere uygun olarak yazıldığını ve yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve bunu onurumla doğrularım.

07/ 2019


Gizem ÖZAYDIN

İmza


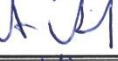

 TS EN ISO 9001:2015	T.C. İZMİR KÂTİP ÇELEBİ ÜNİVERSİTESİ Sosyal Bilimler Enstitüsü	
	TEZ SINAVI TUTANAK FORMU	Dok. No: FR/604/21
		İlk Yayın Tar.: 03.10.2017
		Rev. No/Tar.: 00/..
		Sayfa 1 / 1

GÖNDEREN : İşletme Anabilim Dalı Başkanlığı
GÖNDERİLEN : Sosyal Bilimler Enstitüsü

 Anabilim Dalımız Yüksek Lisans Programı öğrencisi Gizem ÖZAYDIN ile ilgili Tez Sınav Tutanağı aşağıdadır.

 Tarih: İşletme Anabilim Dalı Başkanı
 Sayı : 
 İmza

SINAV TUTANAĞI
 Tez Sınav Jürimiz tarafından incelenen “*Türkiye Elektrik Enerjisi Talebinin Yapay Sinir Ağları Modeli ile Tahmini*” başlıklı tezli yüksek lisans tezi ile ilgili olarak jürimiz 02.07.2019 tarihinde toplanmış ve adı geçen öğrenciyi Tez Sınavına tabi tutmuştur. Sınav sonucunda adayın tezi hakkında OYBİRLİĞİ/ÇOKLUĞU ile aşağıdaki karar verilmiştir.
 KABUL
 Kabul Edilen Tezli Yüksek Lisans tezi:
 i) Bilime yenilik getirmiştir
 ii) Yeni bir bilimsel yöntem geliştirmiştir
 iii) Bilinen bir yöntemi yeni bir alana uygulamıştır
 iv) Uygulama yapmıştır (sadece Yüksek Lisans'ta geçerlidir)
 RED
 DÜZELTME *

Tez Sınav Jürisi	Unvanı ve Adı Soyadı	İmza
Tez Danışmanı	Dr. Öğr. Üyesi Berna TEKTAŞ SİVRİKAYA	
Üye	Doç. Dr. Ayşegül ALAYBEYOĞLU	
Üye	Dr. Öğr. Üyesi Melih ENGIN	
Üye		
Üye		

Eki : Tez Değerlendirme Formu (Her bir jüri için).
 * Tez sınavında düzeltme kararı verilmesi halinde jüri tarafından öngörülen düzeltmelere ilişkin bir jüri raporu eklenmelidir. Düzeltmeler için Ek süre her defasında en fazla yüksek lisans öğrencileri için 3 ay, doktora öğrencileri için 6 aydır.

ÖZET

Yüksek Lisans Tezi

Yapay Sinir Ağları Modeli İle Elektrik Tüketim Tahmini: İzmir İli Örneği

Gizem ÖZAYDIN

İzmir Kâtip Çelebi Üniversitesi

Sosyal Bilimler Enstitüsü

İşletme Anabilim Dalı

Ülkelerin muasır medeniyetler seviyesine ulaşabilmesinin temel unsuru sanayidir. Sanayinin en büyük girdilerinden biri ise enerjidir. Sanayileşme yarışında bir adım öteye gidebilmek için ulusların uzun dönemli ve geniş perspektifli politikalar üretmesi gerekmektedir. Dünyada sık sık gündeme gelen enerji krizleri de bu politikaların daha akılcı ve hassas yapılması gerektiğinin kanıtıdır.

Elektrik tahmini hem sistem yönetimi hem de finansal işlemler açısından önemlidir. Kısa süreli elektrik talebi için yeterli miktarda arz olmadığında bölgesel bazlı kesintiler yaşanır. Arzın talepten fazla olduğu durumda ise santral işletmeleri liberal ekonomik koşullarda zarar edebilmektedir. Tüketicilere enerjiyi ekonomik, güvenilir ve sürekli sunabilecek şekilde tahminlemek arz ve talep dengesi sağlar. Elektrik borsasında işlem gören finansal kuruluşlar bu ekonominin içinde günlük ve gelecekteki zamanlara yönelik fiyatlarda spekülasyon yapabilmektedir. Operasyon birimlerinin karlılığı fiyatların da isabetli tahminine bağlıdır.

Türkiye elektrik enerjisi talebinin incelendiği bu çalışmada, 1960-2016 yılları arasında elektrik tüketiminin belirleyici verileriyle bir model öngörüsünde bulunarak 2017 yılı elektrik tüketimini tahminlemek amaçlanmıştır. Çalışmanın özgün yanı, modele daha yüksek açıklayıcılık sağlayacak tek bir parametre ile tahmin çalışması yapmaktansa, başarılı ilişki sağlayacak birçok değişkenin modelde çalışmaya dâhil edilmesidir. Böylece bu çalışma sayesinde, elektrik tüketimini etkileyecek değişkenleri tespit ederken tahmin performansında nasıl bir sonuç yarattığı görülecektir.

Çalışmanın giriş bölümünde elektrik enerjisi piyasası hakkında açıklama yapılmış, istatistiksel tahmin yöntemleri detaylandırılarak yapay sinir ağları kavramı açıklanmıştır. Uzun dönemleri kapsayan talep projeksiyonunda tahmin modeli için; kişi başına düşen GSMH, tüketici fiyat endeksi, ithalat, ihracat, şehir nüfusu, geniş kapsamlı para miktarı, sanayinin GSMH içindeki yeri, elektrik kurulu gücü ve motorlu taşıt sayısı değişkenleri girdi kabul edilerek yapay sinir ağları yöntemi uygulanmıştır. Uygulama sonucunda yapay sinir ağı yönteminin etkili bir talep tahmin yöntemi olduğu gösterilmiştir.

Anahtar Kelimeler: Elektrik Enerjisi, Yapay Sinir Ağları, Talep Tahmini

ABSTRACT

Master Thesis

**ELECTRICAL CONSUMPTION ESTIMATION WITH ARTIFICIAL
NEURAL NETWORKS MODEL: SAMPLE OF İZMİR PROVINCE**

Gizem ÖZAYDIN

İzmir Katip Çelebi University

Graduate School of Social Sciences

Department of Business Administration

Master of Business Administration Thesis Program

Industry is the main element of reaching the level of modern civilization. One of the biggest inputs of industry is energy. In order to go one step further in the industrialization race, nations must produce long-term and broad-based policies. The energy crises that are frequently discussed in the world are proof that these policies should be made more rational and sensitive.

Electricity forecasting is important both in terms of system management and financial transactions. When there is not enough supply for short-term electricity demand, there are regional disruptions. Incases where supply is more than demand, plant enterprises may suffer in liberal economic conditions. Estimating the energy in an economical, reliable and continuous way provides consumers with a balance of supply and demand. Financial institution traded on the electricity exchange can speculate on prices for daily and future times within this economy. The profitability of the operation units depends on the accurate estimation of the prices.

Turkey in the study of electricity demand in 2017 by filing a model prediction with decisive power consumption of the data between the years 1960-2016 aimed to forecasting electricity consumption. The original aspect of the study is that many variables that will provide a successful relationship are included in the model rather than estimating with a single parameter that will provide higher explanatory value to the model. Thus, this study will show how the estimation performance results when determining the variables that will affect the electricity consumption.

In the introduction part of the study, an explanation was made about the electric energy market, and the concept of artificial neural networks was explained by detailed statistical estimation methods. For the forecasting model in demand projection covering long periods; per capita GNP, consumer price index, import, export, urban population, broad money, the place of industry in GNP, electricity installed power and number of motor vehicles were accepted as inputs. As a result of the application, it has been shown that artificial neural network method is an effective demand estimation method.

Keywords: Electrical Energy, Artificial Neural Networks, Demand Forecasting

İÇİNDEKİLER

YEMİN METNİ.....	ii
TEZ ONAY SAYFASI	iii
ÖZET	iv
ABSTRACT	vi
İÇİNDEKİLER	viii
ŞEKİLLER LİSTESİ	xi
TABLolar LİSTESİ	xiii
KISALTMALAR LİSTESİ	xiv
ÖNSÖZ	xv
1. GİRİŞ	1
1.1. Türkiye’de Elektrik Enerjisinin Tarihsel Gelişimi	2
1.2. Elektrik Enerjisi Piyasasının Yapısı	5
1.3. Literatür Taraması	10
1.3.1. Talep Tahmini Literatür Taraması	10
1.3.2. Yapay Sinir Ağları Elektrik Talep Tahmini Literatür Taraması	12
2. TALEP TAHMİNİ VE MODELLERİ	22
2.1. Talep Tahmini	22
2.2. İstatistiksel Tahmin Yöntemleri	23
2.2.1. Regresyon ve Korelasyon Analizi	23
2.2.2. Zaman Serileri Analizi	27
2.2.2.1. Hareketli Ortalamalar Yöntemi	28
2.2.2.2. Üssel Düzeltim Yöntemi	30
2.2.2.3. Box Jenkins Yöntemleri	31
2.2.3. Yapay Zeka Çözümleri	32
2.2.3.1. Bulanık Mantık	33
2.2.3.2. Yapay Sinir Ağları	34

2.3. Tahmin Yöntemlerinin Performansının Ölçülmesi	34
--	----

3. YAPAY SİNİR AĞLARI 37

3.1. Yapay Sinir Ağlarına Giriş	37
3.1.1. Yapay Sinir Ağlarının Tarihçesi	38
3.1.2. Yapay Sinir Ağlarının Özellikleri.....	39
3.1.3. Yapay Sinir Ağlarının Avantaj ve Dezavantajları	40
3.2. Yapay Sinir Ağları Genel Yapısı	43
3.2.1. Biyolojik Sinir Hücresi.....	43
3.2.2. Yapay Sinir Hücresi.....	44
3.3. Yapay Sinir Ağlarının Sınıflandırılması	48
3.3.1. İleri Beslemeli Yapay Sinir Ağları	48
3.3.2. Geri Beslemeli Yapay Sinir Ağları	49
3.4. Yapay Sinir Ağlarının Öğrenme Algoritması	50
3.4.1. Öğrenme Kuralları	51
3.4.1.1. Çevrimiçi Öğrenme Kuralı	51
3.4.1.2. Çevrimdışı Öğrenme Kuralı	52
3.4.2. Öğrenme Yöntemleri	53
3.4.2.1. Danışmanlı Öğrenme	53
3.4.2.2. Danışmansız Öğrenme	54
3.4.2.3. Takviyeli Öğrenme	55
3.5. Yapay Sinir Ağlarının Eğitilmesi	56

4. YAPAY SİNİR AĞLARI MODELİ İLE ELEKTRİK TÜKETİM TAHMİNİ: İZMİR İLİ ÖRNEĞİ60

4.1. Veri Setinin Tanımlanması	60
4.2. Yapay Sinir Ağları Modelinin Mimarisi	70
4.3. Yapay Sinir Ağları Modelinin Eğitilmesi.....	72
4.4. Modelin Tahmin Sonuçları	78
4.5. Sonuçların Test Edilmesi ve Değerlendirilmesi.....	83

SONUÇLAR.....	86
KAYNAKÇA	89
EKLER	101



ŞEKİLLER LİSTESİ

Şekil 1.1. Ekim 2018 Döneminde Lisanslı Elektrik Üretiminin Kaynak Bazında Dağılımı (%)	7
Şekil 1.2. Türkiye Elektrik Enerjisi Sektörünün Yapısı	8
Şekil 1.3. Türkiye Elektrik Enerjisi Dağıtım Şirketleri Haritası	9
Şekil 2.1. En Küçük Kareler Yöntemi	24
Şekil 2.2. Korelasyon Katsayısı Eğrisi	25
Şekil 2.3. Korelasyon Katsayısının Yorumlanması	27
Şekil 2.4. Zamana Göre Çeşitli Talep Düzenleri	28
Şekil 2.5. Bulanık Mantığın Elemanları ve Çalışması	33
Şekil 3.1. Yapay Sinir Ağlarının Kara Kutu Benzetimi	41
Şekil 3.2. Biyolojik Sinir Hücresi	44
Şekil 3.3. Yapay Sinir Hücresinin Yapısı	45
Şekil 3.4. İleri Beslemeli Yapay Sinir Ağı	49
Şekil 3.5. Geri Beslemeli Yapay Sinir Ağı	50
Şekil 3.6. Danışmanlı Öğrenme	54
Şekil 3.7. Danışmansız Öğrenme	55
Şekil 3.8. Takviyeli Öğrenme	56
Şekil 3.9. Yapay Sinir Ağlarının Öğrenme Eğrisi	58
Şekil 4.1. Kişi Başına Düşen GSMH (Bin TL)	62
Şekil 4.2. Tüketici Fiyat Endeksi (2010 =100)	63
Şekil 4.3. İthalatın GSMH İçindeki Payı (%)	64
Şekil 4.4. İhracatın GSMH İçindeki Payı (%)	65
Şekil 4.5. Şehir Nüfusu (Milyon)	65
Şekil 4.6. Geniş Kapsamlı Para Miktarı (Trilyon)	66
Şekil 4.7. Sanayinin GSMH İçindeki Yeri (%)	67
Şekil 4.8. Elektrik Kurulu Gücü (MW)	68
Şekil 4.9. Motorlu Kara Taşıt Sayısı	69
Şekil 4.10. Elektrik Tüketimi (Kişi Başına kWh)	70
Şekil 4.11. Elektrik Tüketim Tahmini İçin Kurulan Modelin Mimarisi	72
Şekil 4.12. Oluşturulan Yapay Sinir Ağı	75

Şekil 4.13. Oluşturulan Yapay Sinir Ağı Modelinin Performans Grafiği	76
Şekil 4.14. Oluşturulan Yapay Sinir Ağı Modelinin Regresyon Grafikleri	77
Şekil 4.15. Gerçekleşen ile Tahminlenen Tüketimin Karşılaştırılması	81



TABLolar LİSTESİ

Tablo 1.1. Türkiye Kurulu Gücünün Yıllar İtibariyle Gelişimi.....	3
Tablo 1.2. Ekim 2018 Döneminde Lisanslı Elektrik Üretimini Kuruluşlara Göre Dağılımı Ve 2017 Yılı Ekim Ayı Değeriyle Karşılaştırılması (MWh-%)	6
Tablo 1.3. Türkiye’de Net Elektrik Tüketim Toplamı	9
Tablo 1.4. 2000-2018 Yılları Arasında Yapay Sinir Ağları Elektrik Talep Tahmini.....	12
Tablo 2.1. Korelasyon Katsayısı Değeri ve Yorumlamaları	26
Tablo 3.1. Biyolojik Sinir Ağı ve Yapay Sinir Ağının Karşılaştırılması	45
Tablo 3.2. Sık Kullanılan Aktivasyon Fonksiyonları	47
Tablo 4.1. Çalışmada Kullanılan Değişkenler Hakkında Bilgiler	61
Tablo 4.2. Oluşturulan Yapay Sinir Ağı Modelinin Ayrıntıları	75
Tablo 4.3. Modelin Ortalama Mutlak Yüzde Hatası Excel Çözümü	78
Tablo 4.4. Modelin Hata Karelerinin Ortalamasının Karekökü Excel Çözümü	79
Tablo 4.5. Modelin R^2 Değeri Excel Çözümü	80
Tablo 4.6. YYSa-2 Sonuçları	82
Tablo 4.7. 2017 yılı Gerçekleşen ve Tahmin Edilen Değeri Karşılaştırılması .	83
Tablo 4.8. Alternatif Modellerin Performans Ölçme Değeri	84

KISALTMALAR LİSTESİ

ANFIS	Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (Adaptive Network Based Fuzzy Inference System)
ANN	Yapay Sinir Ağları (Artificial Neural Network)
AR	Otoregresif (Autoregressive)
ARIMA	Otoregresif Entegre Hareketli Ortalama (Autoregressive Integrated Moving Average)
ARMA	Otoregresif Hareketli Ortalama (Autoregressive Moving Average)
BM	Bulanık Mantık
EPDK	Enerji Piyasası Düzenleme Kurumu
ETKB	Enerji ve Tabii Kaynaklar Bakanlığı
EÜAŞ	Elektrik Üretim Anonim Şirketi
GSMH	Gayri Safi Milli Hâsıla
GSYH	Gayri Safi Yurtiçi Hâsıla
GSYİH	Gayri Safi Yurt İçi Hâsıla
MA	Hareketli Ortalama (Moving Average)
MAE	Ortalama Mutlak Hata (Mean Absolute Error)
MAPE	Ortama Mutlak Yüzde Hata (Mean Absolute Percentage Error)
MATLAB	Matrix Laboratory
MSE	Ortalama Karesel Hata (Mean Squared Error)
RMSE	Hata Karelerinin Ortalamasının Karekökü (Root Mean Squared Error)
SSE	Toplam Karesel Hata (Sum Squared Error)
TEAŞ	Türkiye Elektrik Üretim İletim A.Ş.
TEDAŞ	Türkiye Elektrik Dağıtım Anonim Şirketi
TEİAŞ	Türkiye Elektrik İletim Anonim Şirketi
TEK	Türkiye Elektrik Kurumu
TEP	Türkiye Elektrik Piyasası
TETAŞ	Türkiye Elektrik Ticaret ve Taahhüt Anonim Şirketi
TÜİK	Türkiye İstatistik Kurumu
YSA	Yapay Sinir Ağı

ÖNSÖZ

Enerji planlaması ve tahmini konularının önemini kavrayan tüm analist ve akademisyenlerin en çok ihtiyaç duyacağı bilgi, enerjinin gelecekteki arz ve talep değerleridir. Tahminlerde yapılan hatalar piyasada dengesizlik yaratarak maliyetleri en aza indirmeyi engeller. Maliyet minimizasyonu ve rekabet avantajı sağlamak isteyen dağıtım şirketleri, üretim santral yetkilileri, kamu kurumları ve koordinasyon kurullarının konuyla ilgili çalışmaları hızla artmaktadır.

Enerji alanına yönelmemi sağlayan, çalışmamın her aşamasında yardımlarını esirgemeyen, iyi bir akademisyen olma hedefimde beni motive eden saygıdeğer danışman hocam Yrd. Doç. Dr. Berna TEKTAŞ SİVRİKAYA' ya,

Rutgers University, The State University of New Jersey' de görevini sürdüren ve MATLAB konusunda engin bilgilerine başvurduğum saygıdeğer hocam Teaching Assistant Ayça ALTAY' a,

Bana her zaman güvenen ve beni yüreklendiren saygıdeğer hocam Yrd. Doç. Dr. Aygülen KAYAHAN KARAKUL' a,

Akademik hayatta karşılaştığım her sıkıntımı rahatlıkla anlatabildiğim ve çözüm önerilerini dikkate aldığım, tabiri yerindeyse bana ablalık yapan saygıdeğer hocam Arş. Gör. Aynur KIRBAÇ' a,

Ayrıca yüksek lisans eğitimimi tamamlayana kadar tüm zorlu süreçlerde bana en iyi şartları sağlamak için hiçbir fedakârlıktan kaçınmayan sevgili aileme gönül dolusu teşekkürlerimi sunarım.

Gizem ÖZAYDIN

1. GİRİŞ

İş görme kapasitesi olarak adlandırılan enerji, gerek üretim gerek tüketim ve gerekse ticaret alanında önemli bir girdi kaynağıdır. Kalkınmışlığın bir göstergesi olan enerji; geçmişten günümüze bakıldığında tüm enerji krizlerin ardından dünya ülkelerinin önceliklerinin arasında ilk sırada yer almıştır. Özellikle gelişmekte olan ülkelerde oldukça kritik bir yere sahiptir.

Enerjinin en büyük basamağını elektrik enerjisi oluşturmaktadır. Elektrik enerjisi de çeşitli kaynaklardan elde edilip yine farklı tüketim alanlarında kullanılmaktadır. 2017 yılı sonu itibariyle elektrik üretimimizin %37'si doğalgazdan, %33'ü kömürden, %20'si hidrolik enerjiden, %6'sı rüzgârdan, %2'si jeotermal enerjiden ve %2'si diğer kaynaklardan sağlanmaktadır. Türkiye elektrik enerjisi üretimi 2017 yılında bir önceki yıla göre %7,7 oranında artarak 295,5 milyar kWh, elektrik tüketimi ise bir önceki yıla göre %5,6 oranında artarak 294,9 milyar kWh olarak gerçekleşmiştir (EÜAŞ, 2017). Ayrıca 2017 yılı sonu itibariyle elektrik kurulu gücü 83.872 mW iken %5,46 oranında bir artışla 2018 yılı sonu itibariyle 88.452 mW olduğu görülmüştür (TEİAŞ, 2018).

Türkiye'de elektrik enerjisi; artan teknoloji, nüfus, kentleşme ve yaşam standartlarına paralel olarak yükselmeye devam etmektedir. Bu nedenle elektriğe olan talebi belirlemek, talebe etki eden değişkenleri tespit etmek ve gerçekleşen talebi açıklayabilen bir sistem oluşturmak büyük önem taşımaktadır. Böyle mühim bir tabloda elektriğe olan talebi tahmin etmeye yönelik çalışmalar sektöre yatırım yapılmasını sağlayacaktır. Geçmiş verileri inceleyerek ve gelecekteki durumu öngörerek yapılan tahminlerin isabetli ve realist bakış açısıyla oluşturulması gereksiz yatırım maliyetlerinin önüne geçilmesini sağlayacaktır.

Elektrik enerjisi piyasasının oluşumu ve buna bağlı olarak elektriğin bir yatırım aracı olarak da kullanılabileceği göz önüne alınarak, tez konusu; "Türkiye Elektrik Enerjisi Talebinin Yapay Sınır Ağları ile Tahmini" olarak tespit edilmiştir. Bu kapsamda çalışmamızın ilk bölümünde; elektrik enerjisi kavramına yer verilmiş, elektrik enerjisinin tarihsel gelişimi anlatılmış, elektrik enerjisi piyasasının yapısı ve işleyişi hakkında kısaca bilgi verilmiştir. Ardından Türkiye'de ve dünyada talep

tahmini ve yapay sinir ağı konularına ilişkin olarak daha önce yapılmış olan çalışmaların literatür özetleri paylaşılmıştır.

İkinci bölüm talep tahmin yöntemlerine ayrılmıştır. Öncelikle istatistiksel yöntemlerle en çok kullanılan tahmin metotları açıklanmış, daha sonra uygulanan yöntemlerin performansını ölçmek için hangi kriterlerin ölçek olarak alındığı ayrıntılı olarak aktarılmıştır. Üçüncü bölümde yapay sinir ağlarına genel bir giriş yapılmış, yapay sinir ağlarının yapısı, sınıflandırılması, öğrenme algoritması ve eğitilmesi hususunda bilgi verilmiştir.

Dördüncü bölümde ise uygulamanın kapsamı, veri setinin girdi ve çıktıları detaylı bir şekilde anlatılmıştır. Değişkenlerin hangi kaynaklardan ve nasıl elde edildiği, analiz hesaplamaları ve modelin sonuçlarına yer verilmiştir. Son bölümde ise uygulama aşamasında elde edilen sonuçlar değerlendirilmiş, ilerideki çalışmalara yön verecek tavsiyelerde bulunulmuştur.

1.1. TÜRKİYE'DE ELEKTRİK ENERJİSİNİN TARİHSEL GELİŞİMİ

Ülkemizde II. Abdülhamid döneminde 1902 yılında Mersin'in Tarsus ilçesinde 2 kW gücündeki bir su değirmeninden yararlanılarak inşa edilmiş olan hidroelektrik enerji sayesinde ilk kez elektrik üretimi gerçekleşmiştir (Özkaya, 2012:94). Günümüzde mikro santral boyutunda olan bu projeden sonra Osmanlı Elektrik Üretim Anonim Şirketi tarafından İstanbul Silahtarağa semtinde 1913 yılında tamamlanması planlanan ancak aşırı yağışlar nedeniyle 1914'te resmen açılışı gerçekleşen 15 MW güce sahip ilk büyük termik santral olmuştur (Dinçel, 2007:61).

1950'li yıllara gelindiğinde karma ekonomi tercih edilerek, devlet ve özel sektör eliyle yap-işlet modeli elektrik santralleri yapılmaya başlandı. Yerli sermayeli dört özel şirketin kurulmasıyla o yıllarda Türkiye'nin elektrik kurulu gücü 407,8 MW' a, üretimimiz 789,5 milyon kWh'a ulaşmıştır (TEİAŞ, 2018).

Birinci (1963-1967) ve İkinci Beş Yıllık Kalkınma Planı (1968-1972) dönemlerinde artan elektrik üretim, iletim ve dağıtım miktarı nedeniyle faaliyetleri tek bir çatı altında kurumsal bir yapıyı zorunlu kılmış ve 1312 sayılı Kanun ile TEK

(Türkiye Elektrik Kurumu) kurulmuştur. 1970’li yıllarda Türkiye’nin elektrik potansiyeli 2.234,9 MW kurulu güçten 8.623 milyon kWh olarak gerçekleşmiştir (TEİAŞ, 2018).

Tablo 1.1. Türkiye Kurulu Gücünün Yıllar İtibariyle Gelişimi

YIL	KURULU GÜÇ (MW)	YIL	KURULU GÜÇ (MW)	YIL	KURULU GÜÇ (MW)
1913	17,3	1954	516,9	1986	10115,2
1923	32,8	1955	611,6	1987	12495,1
1924	32,9	1956	886,1	1988	14520,6
1925	33,4	1957	939,4	1989	15808,2
1926	48,6	1958	1030,0	1990	16317,6
1927	51,9	1959	1161,0	1991	17209,1
1928	65,9	1960	1272,4	1992	18716,1
1929	72,1	1961	1323,9	1993	20337,6
1930	78,0	1962	1370,8	1994	20859,8
1931	101,9	1963	1381,1	1995	20954,3
1932	103,3	1964	1418,3	1996	21249,4
1933	107,8	1965	1490,5	1997	21891,9
1934	117,4	1966	1644,3	1998	23354,0
1935	126,2	1967	1959,1	1999	26119,3
1936	138,5	1968	1966,6	2000	27264,1
1937	167,1	1969	1967,2	2001	28332,4
1938	178,5	1970	2234,9	2002	31845,8
1939	215,6	1971	2577,9	2003	35587,0
1940	217,0	1972	2711,3	2004	36824,0
1941	222,0	1973	3192,5	2005	38843,5
1942	226,7	1974	3732,1	2006	40564,8
1943	236,4	1975	4186,6	2007	40835,7
1944	241,9	1976	4364,2	2008	41817,2
1945	245,9	1977	4727,2	2009	44761,2
1946	247,5	1978	4868,7	2010	49524,1
1947	251,4	1979	5118,7	2011	52911,1
1948	305,5	1980	5118,7	2012	57059,4
1949	381,8	1981	5537,6	2013	64267,7

1950	407,8	1982	6638,6	2014	69519,8
1951	423,2	1983	6935,1	2015	73146,7
1952	437,8	1984	8461,6	2016	78497,4
1953	499,5	1985	9121,6	2017	85200,0

Kaynak: TEİAŞ, 2018

1980’li yıllara gelindiğinde ekonomik liberalleşme politikaları TEK’in hukuki bünyesi, organları ve yapısı düzenlenerek elektrik üretimi, iletimi, dağıtımı ve ticaretini yapmak üzere yaklaşık on sermaye şirketi görevlendirilmiştir. Dönemin sonlarında ortaya çıkan elektrik arz eksikliği ve kamu kaynaklarının yeni yatırımlar için yetersiz kalması sonucunda TEK kurulmuştur. Kuruluşundan 23 yıl sonra çıkan 13.8.1993 gün ve 513 sayılı Kanun Hükmünde Kararname ile Enerji ve Tabii Kaynaklar Bakanlığı ile ilişkisi devam etmek şartıyla özelleştirme kapsamına alınmıştır (Tutuş, 2005:318). Bu düzenlemenin bir devamı olarak da Bakanlar Kurulunun 93/4789 Sayılı Kararı ile kurum “Türkiye Elektrik Üretim İletim A.Ş.” (TEAŞ) ve “Türkiye Elektrik Dağıtım A.Ş.” (TEDAŞ) adı altında iki ayrı Kamu İktisadi Devlet Teşekkülüne ayrılmıştır.

1994-1997 yılları arasında Yap-İşlet-Devret (YİD), Yap-İşlet (Yİ) ve İşletme Hakkı Devri (İHD) modelleri hakkında çıkarılan çeşitli kanunlarla kamunun kaynak yetersizliği nedeniyle gerçekleştiremediği yatırımları özel teşebbüsler tarafından teşvik etmek amaçlanmıştır (Karamustafaoğlu, 2006:30).

Enerji sektörünün revizesine yönelik 3 Mart 2001 tarihli Resmi Gazetede yayımlanan 4628 Sayılı Elektrik Piyasası Kanunu ile elektriğin yüksek kaliteli, çevreyle uyumlu tüketici alanı yaratarak maliyet minimizasyonu ve süreklilik sağlayacak bağımsız bir piyasa denetimi amaçlanmıştır. Tüm bu faaliyetler ile diğer mali işlemlere ilişkin olarak kanunda tanımlara yer verilmiş ve Enerji Piyasaları İşletme Anonim Şirketi (EPIAŞ) tarafından yürütüleceği kararlaştırılmıştır. 6446 sayılı kanununun 11. Maddesinde EPIAŞ’ın hak ve yükümlülükleri aşağıdaki şekilde tanımlanmıştır;

*Piyasanın gelişimi doğrultusunda görev alanına giren organize toptan elektrik piyasalarında yeni piyasalar kurulmasına yönelik çalışmaları yapmak ve Enerji Piyasası Düzenleme Kurumuna sunmak.

*Bakanlıkça uygun görülmesi hâlinde; görev alanına giren organize toptan elektrik piyasalarının işletilmesi amacıyla oluşturulan veya ileride oluşturulabilecek uluslararası elektrik piyasalarına taraf olarak katılmak, bu amaçla kurulan uluslararası elektrik piyasası işletmecisi kuruluşlara ortak veya üye olmak.

*Enerji Piyasası Düzenleme Kurumunun belirlediği usul ve esaslar çerçevesinde piyasa işletim tarifelerini belirleyerek Enerji Piyasası Düzenleme Kurumuna sunmak.

1.2. ELEKTRİK ENERJİSİ PİYASASININ YAPISI

Bu başlıkta Türkiye Elektrik Piyasasında Üretim, İşletim ve Dağıtım faaliyetlerinin piyasada nasıl işleyeceği anlatılmıştır.

Elektrik enerjisi sistemi planlamasında iki önemli unsur vardır. Birincisi, maksimum tüketimi karşılayacak üretim, iletim ve dağıtım kapasitesinin bulundurulmasıdır. İkincisi ise sistemde meydana gelebilecek herhangi bir arızada, elektrik arzının devamlılığının sağlanabilmesi için yeterli üretim yedek kapasitesi, iletim ve dağıtım yedeği bulundurulmasıdır (Polater, 2013: 4).

Türkiye Elektrik Piyasasında üretim faaliyetinde bulunabilmek için Enerji Piyasası Düzenleme Kurumu EPDK' dan üretim lisansı alınması gerekmektedir. Türkiye'de Elektrik Üretim Anonim Şirketi, bağlı ortaklıklar, özel ve kamu şirketleri üretim lisansına sahiptir.


Tablo 1.2. Ekim 2018 Döneminde Lisanslı Elektrik Üretimine Kuruluşlara Göre Dağılımı Ve 2017 Yılı Ekim Ayı Değeriyle Karşılaştırılması (MWh-%)

KURULUŞ TÜRÜ	2017 EKİM		2018 EKİM		DEĞİŞİM (%)
	ÜRETİM (MWh)	ORAN (%)	ÜRETİM (MWh)	ORAN (%)	
SERBEST ÜRETİM ŞİRKETİ	15.837.001,31	67,26	16.039.148,16	69,44	1,28
YAP İŞLET SANTRALLERİ	4.059.090,48	17,24	3.357.253,07	14,53	-17,29
EÜAŞ SANTRALLERİ	2.760.206,58	11,72	3.046.766,86	13,19	10,38
İŞLETME HAKKI DEVREDİLEN SANTRALLER	322.286,75	1,37	531.710,16	2,30	64,98
YAP İŞLET DEVRET	566.249,80	2,40	124.206,10	0,54	-78,07
Genel Toplam	23.544.834,92	100,00	23.099.084,35	100,00	-1,89

Kaynak: EPDK Ekim Sektör Raporu, 2018

Tablo 1.2.' de son iki yıla ait lisanslı elektrik üretiminin kuruluşlara göre dağılımı ve karşılaştırması verilmiştir. Buna göre ülkemizde serbest üretim şirketleri, EÜAŞ santralleri ve işletme hakkı devredilen santrallerin elektrik üretimi yıllar itibariyle artış göstermektedir. Ayrıca Yap İşlet santralleri ile Yap İşlet Devret santrallerinin elektrik üretiminin yıllar içinde azalma gösterdiği gözlemlenmiştir. Elektrik üretiminin kuruluşlara göre dağılımı incelendiğinde, üretimde en yüksek paya serbest üretim şirketleri sahip olup, toplam üretimdeki yeri yaklaşık %70' dir (Enerji Piyasası Sektör Raporu, 2018:9).

Şekil 1.1 Ekim 2018 Döneminde Lisanslı Elektrik Üretiminin Kaynak Bazında Dağılımı (%)

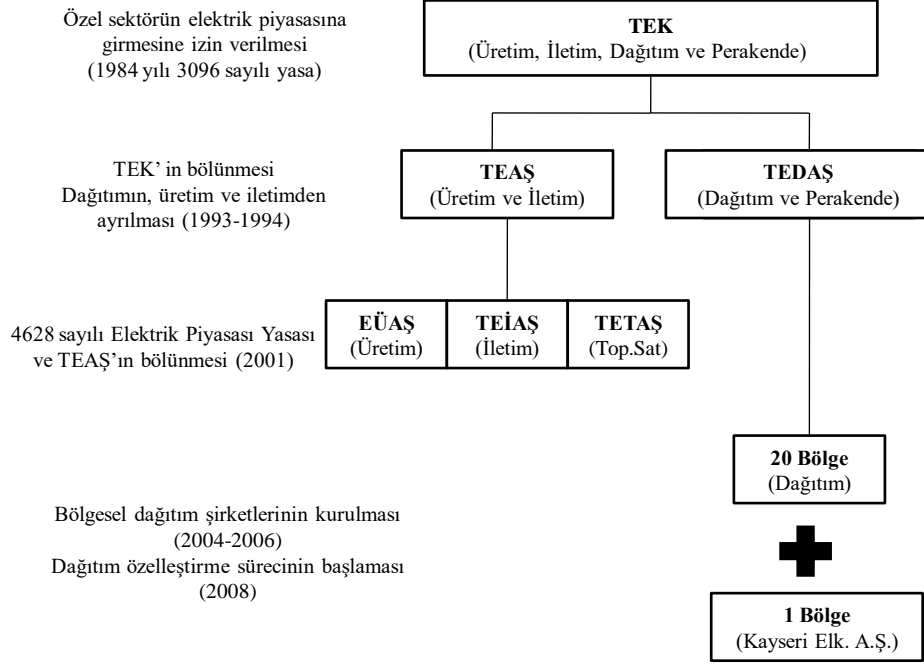


Kaynak: EPDK Ekim Sektör Raporu, 2018

Elektrik Enerjisi enerji dönüşüm tesislerinde çeşitli enerji türleri (doğalgaz, kömür, petrol, su, güneş, rüzgâr) kullanılarak elde edilen enerji türüdür. Ekim 2018 itibariyle lisanslı elektrik üretiminin kaynak bazında dağılımına Şekil 1.1.'e bakıldığında; doğalgazın %34,74 ile ilk sırada yer aldığı görülmektedir. Doğalgazı %24,89 ile ithal kömür izlerken, üçüncü sırada linyit yer almaktadır (Enerji Piyasası Sektör Raporu, 2018:13).

Türkiye elektrik enerjisi sektörünün yapısı Şekil 1.2.' de özetlenmiştir. İletim faaliyetleri Türkiye Elektrik İletim Anonim Şirketi tarafından gerçekleştirilmektedir. TEİAŞ' da var olan ve yeni inşa edilecek tüm iletim tesisleri üzerinden iletim faaliyeti yürütebilmek için EPDK' dan lisans almak durumundadır. Bu lisansa iletim lisansı denir. İletim lisansı sayesinde yatırım planı yapılır, elektrik tedarikinin rekabet koşullarına uyulur, yürütülen faaliyetlere ilişkin tarife teklifleri kanuna uygun standartlarda hazırlanarak onaya sunulur. Ek olarak yük dağıtımı, frekans kontrolü, piyasa dengelemesi ve sistem güvenilirliğine yönelik gerekli tedbirlerin alınması talep edilebilir.

Şekil 1.2. Türkiye Elektrik Enerjisi Sektörünün Yapısı



Kaynak: Türkiye Sınai Kalkınma Bankası, 2018: 20

Türkiye’de elektrik dağıtım şirketleri itibariyle faaliyet göstermektedir. TEDAŞ 02.04.2004 tarih ve 2004/22 sayılı Özelleştirme Yüksek Kurulu Kararı ile özelleştirme kapsamına alınarak dağıtım bölgeleri yeniden belirlenmiş ve Şekil 1.3.’de Türkiye 21 dağıtım bölgesine ayrılmıştır. Dağıtım şirketleri belirli bir bölgede dağıtım faaliyeti gösterebilmek için EPDK’ dan dağıtım lisansı almak zorundadırlar. Dağıtım şirketleri lisansta belirtilen bölgede; sayaçların okunması ve bakımı, verimlilik artışı sağlayacak piyasa dışı bir faaliyet yürütmemek, rekabet ortamına ve mevzuat hükümlerine uygun davranmak gibi hizmetlerden sorumludur.

Şekil 1.3. Türkiye Elektrik Enerjisi Dağıtım Şirketleri Haritası



Kaynak: Elektrik Dağıtım Şirketleri, www.enerjibes.com, Ocak, 2019

Özellikle 1980 sonrasında nüfus artışı ve sanayi faaliyetlerinin çoğalmasıyla beraber Türkiye’de enerji tüketimi hızla yükselen bir ivme kazanmıştır. Bu süreçte tarım aktiviteleri önemini yitirmiş, sanayi ve hizmet sektörleri ön plana çıkmıştır. (Mucuk ve Uysal, 2009:157).

Tablo 1.3. Türkiye’de Net Elektrik Tüketim Toplamı

Yıl	Toplam (GWh)	Yıl	Toplam (GWh)	Yıl	Toplam (GWh)
1970	7.308	1986	32.210	2002	102.948
1971	8.289	1987	36.697	2003	111.766
1972	9.527	1988	39.722	2004	121.142
1973	10.530	1989	43.120	2005	130.263
1974	11.359	1990	46.820	2006	143.071
1975	13.492	1991	49.283	2007	155.135
1976	16.079	1992	53.985	2008	161.948
1977	17.969	1993	59.237	2009	156.894
1978	18.934	1994	61.401	2010	172.051

1979	19.633	1995	67.394	2011	186.100
1980	20.398	1996	74.157	2012	194.923
1981	22.030	1997	81.885	2013	198.045
1982	23.587	1998	87.705	2014	207.375
1983	24.465	1999	91.202	2015	217.312
1984	27.635	2000	98.296	2016	231.204
1985	29.709	2001	97.070	2017	249.023

Kaynak: TEİAŞ, Ocak, 2019

Türkiye Elektrik İletim A.Ş. Genel Müdürlüğü'ne (TEİAŞ) ait Tablo 1.3. incelendiğinde, 1970-2017 yılları arasında Türkiye'de tüketilen net elektrik enerjisini göstermektedir. Görüldüğü üzere 2009 ekonomik krizi hariç diğer yıllarda elektrik tüketim miktarında ortalama %5'lik bir artış meydana gelmiştir.

1.3. LİTERATÜR TARAMASI

Literatür özeti, tüketim tahmini literatür özeti ve yapay sinir ağları literatür özeti olmak üzere iki bölümde incelenmiştir.

1.3.1. Talep Tahmini Literatür Taraması

İşletmelerin gelecekteki değişikliklerle ilgilenmeleri ve bu değişimi yakalayacak güce hazırlanmaları gerekmektedir. Geleceğe hazırlanmanın ilk yolu öngörü yapmaktan geçmektedir. Talep öngörümü ise gelecekte talep edilecek mal ya da hizmetlerin üretebilmek için gerekli kaynakların önceden kestirilmesidir. Talep tahmini; yönetim, üretim, planlama ve lojistik gibi birçok işletme alanında oldukça önemli bir konudur. Çok geniş bir yelpazede kullanılan tahminleme, piyasa koşullarına ayak uydurabilme ve faaliyetlerin kolaylıkla yapılabilmesini sağlar. Günümüze kadar geçen süreçte yaşanan bu gelişmelerin yansıtmak üzere istatistiksel yöntemlerle yapılan talep tahmini çalışmalarından bazıları aşağıda özetlenmiştir.

Kirby (1966) çalışmasıyla, kısa ve orta vadeli istatistiksel talep tahmin metotlarını karşılaştırmıştır. Dikiş makinesi üretimi için, beş farklı ülkeden alınan

satış verileriyle zaman serisi analizlerine dayanan yöntemleri kullanarak tahmin yapmıştır. Çalışmasının sonucunda hem tahmin döneminin doğruluğu için zaman diliminin önemini vurgulamış hem de trend analizi ve mevsimsel üstel düzeltim yöntemlerinin daha iyi sonuçlar verdiğini tespit etmiştir.

Carlson ve Umble (1980), farklı türlerde otomobillerin beş yıllık talep tahminini yaptığı çalışmasıyla; gelir, fiyat ve işçi grevlerinin piyasayı etkileyen faktörler olduğu sonucuna ulaşmıştır. Bhattacharya (1997) doğrusal regresyon ve hareketli ortalamalar yöntemleri kullanılarak telefon talebi tahmini yapmıştır.

Akbay ve diğerleri (1999), çalışmalarıyla yoğunlaştırılmış meyve suyu tüketimi ve tüketim üzerindeki değişkenlerin etkisini sınırlı bağımlı değişken modeli (Tobit) ile belirlemeyi amaç edinmişlerdir. Araştırma sonuçları; 12-17 yaş grubundaki aile bireylerinin varlığı talebi pozitif etkilerken, annenin eğitim düzeyi talebi negatif etkilemiştir.

Gavcar ve diğerleri (1999), SEKA kağıt fabrikasında yaptıkları araştırmayla farklı kağıt türlerine olan talebi tahminlemek için çoklu regresyon analizi kullanmıştır. Çalışmalarında fiyat endeksleri, ithalat, ihracat, GSMH ve nüfus değişkenlerini dikkate almışlardır.

Chen (2000), Amerikan milli parklarını örnek alarak yaptığı çalışmasıyla ziyaretçi sayılarını ARIMA (Otoregresif Bütünleşik Hareketli Ortalamalar) yöntemiyle tahmin etmiş, mevsimselliği göz önüne alarak yapılan çalışmaların daha doğru sonuçlar vereceğini açıklamıştır.

Cahow (2004), evde bakıma muhtaç hastalara yardımcı hemşire sayısını tahminlemeye yönelik Amerika'da yaptığı çalışmasında Çoklu Regresyon ve Monte Carlo simülasyonu yöntemlerini kullanmış, anketlerden elde ettiği veri setinin sonuçlarına göre ise Amerika'da bu talebin 2025 yılına kadar artacağını öngörmüştür.

Yumurtacı ve Asmaz (2004), regresyon yöntemiyle yaptıkları elektrik talep tahmini çalışmalarında, Türkiye'nin elektrik enerjisi ihtiyacının 2050 yılında 1,173 milyar kWh olacak şekilde tahminlemişlerdir.

Satır ve Köksal (2006) çalışmalarında, tavuk üretimi yapan bir fabrikanın geçmiş iki yılın verilerini alarak zaman serisi analizi ve ARIMA modeli ile fabrikanın yeni kurulacak organizasyonlarındaki finansal planlamayı tahmin etmiştir.

Ediger ve diğeri (2006) ilk olarak yaptıkları çalışmayla Türkiye'deki fosil kaynakların üretim tahmininde regresyon ve ARIMA yöntemlerini kullanmışlar ve çalışma sonucunda kömür üretiminin 2019'da, doğalgaz üretiminin 2024'te sona ereceğini öngörmüşlerdir. Ediger ve Akar (2007) bir başka çalışmayla Türkiye'nin birincil elektrik üretimini ARIMA metoduyla tahminlemişlerdir. Bu çalışmalarının sonuçlarına göre ise gelecekte Türkiye için fosil yakıtlar önemli bir paya sahip olacakken en az artış oranı linyitte olacaktır.

Avcı (2009), yapay sinir ağı modeli ile Borsa İstanbul'da işlem gören ve piyasa değeri en yüksek 30 şirketin hisse senetlerinden oluşan IMKB-30 endeksi içinden seçilmiş bazı şirketleri incelemiştir. Araştırmasında hisse senedi getiri tahmininde yapay sinir ağları modelinin etkili bir yöntem olduğu sonucuna varmıştır.

Tsai ve diğeri (2009), Tayland'daki medikal turizme olan talebi ve yabancı hastalardan sağlanacak gelirleri tahmin ettikleri çalışmada, zaman serisi modeliyle tahmin performanslarını karşılaştırmıştır.

Griffiths ve diğeri (2010), Avustralya'daki farklı eyaletlerden alınan verileri kullanarak yerel buğday verimliliğini mevsimsel yağın yağış bilgileri baz alınarak regresyon modeliyle tahmin çalışması yapmışlardır.

Karaca ve Karacan (2016), çoklu regresyon modeliyle Türkiye'de ne kadar elektrik tüketileceğini tahmin etmeye yönelik yaptıkları çalışmayla; gayri safi milli hâsıla ve ekonomik büyüme politikalarının elektrik enerjisi tüketimini doğrudan etkilediği sonucuna ulaşmışlardır.

1.3.2. Yapay Sinir Ağları Elektrik Talep Tahmini Literatür Taraması

Literatürde yapay sinir ağları ile ilgili çeşitli alanlara uygulanmış birçok tahmin çalışması mevcuttur. Çalışma konumuzla ilgili olan bu uygulamalardan bazıları literatür araştırması sonucunda incelenip aşağıda özetlenmiştir.

Tablo 1.4. 2000-2018 yılları arasında Yapay Sinir Ağları Elektrik Talep Tahmini

Tarih	Çalışmanın Yazarları	Kullanılan Yöntem	Veri Seti	Değişkenler	Hedef
2003	Karacasu ve Hocaoglu	Yapay Sinir Ağları	1994-1998	Elektrik Tüketimi ve Nüfus	Gaziantep Yöresi İçin Yük Tahmini
2004	Hamzaçebi ve Kutay	Yapay Sinir Ağları	1970-1990	Elektrik Tüketimi ve Nüfus	Türkiye'nin Net Elektrik Tüketimini 2010 Yılına Kadar Tahminlemek
2006	Pao	Doğrusal ve Doğrusal Olmayan Regresyon, Yapay Sinir Ağları	1993-2005	Nüfus, GSMH ve TÜFE	Tayvan İçin Elektrik Tüketim Tahmini
2006	Aslan vd	Yapay Sinir Ağları	2000-2004	Nüfus ve Sıcaklık	Kütahya İli İçin Elektrik Puant Yük Tahmini
2007	Azadeh vd.	Yapay Sinir Ağları ile Genetik Algoritma	1981- 2005	Fiyat, Katma Değer, Müşteri Sayısı	İran'ın Ziraat Sektörünün Elektrik Tüketim Tahmini
2007	Özpinar	Yapay Sinir Ağları, Bulanık Mantık	1968- 2006	Güneş ve Debi Faktörleri	Yenilenebilir Enerji Santralleri İçin Kısa, Orta ve Uzun Vadeli Tahmin

2010	Ekonomou	Yapay Sinir Ağları	1992-2008	Ortam sıcaklığı, Kurulu Güç Kapasitesi, GSMH ve Yerleşim Yeri Elektrik Tüketimi	Yunanistan'ın Toplam Enerji Tüketim Tahmini
2011	Kankal vd	Yapay Sinir Ağları ve Regresyon Modelleri	1980-2007	GSMH, Nüfus, İthalat-İhracat Miktarları ve İstihdam	Türkiye'nin Elektrik Tüketiminin Modellemesi
2013	Turhan vd	Yapay Sinir Ağları	2013	İmar Durumu, Isıtma Sistemi Tipi, İzolasyon Varlığı, Duvar Toplam Isı Transfer Katsayısı, Cam Tipi, Alan/Hacim Oranı, Toplam Dış Yüzey Alanı ve Kat Sayısı	İzmir'deki Çok Katlı Binaların Toplam Enerji Tüketimlerinin Tahmini
2014	Uzlu vd	Yapay Sinir Ağları	2014	GSMH, Nüfus, İthalat ve İhracat	Türkiye'nin Net Elektrik Enerjisi Talebini Tahmin Etmek
2014	Hamzaçebi vd	Yapay Sinir Ağları	1970-2010	GSMH, Nüfus, İthalat, İhracat, Bina Yüz Ölçümü ve Taşıt Sayısı	Türkiye Net Enerji Talebini Tahmini
2015	Uygun	Yapay Sinir Ağları	Nisan 2015-Mart 2016	Biyoyakıt, Rüzgâr Gücü, Güneş Enerjisi, Jeotermal ve Nehir Tipi Hidro Kapasite Artışları, Dolar Kuru, Doğalgaz İthalat Fiyatı ve GSMH Artışı	Türkiye Net Enerji Talebini Tahmini

2016	Makas ve Karaatlı	Yapay Sinir Ağları	2007-2014	Aylık Ortalama Yağış, Aylık Ortalama Nisbi Nem ve Aylık Ortalama Debi	Antalya Havzasındaki Bir Hidroelektrik Santralının Elektrik Üretimini Çok Dönemli Tahmini
2016	Masaebi	Yapay Sinir Ağları	1978-2014	Büyüme Oranı, Elektrik Satış Fiyatı, İthalat, İhracat, GSMH ve Nüfus	İran Elektrik Enerjisinin Tüketim Tahmini
2017	Dalgın	Yapay Sinir Ağları	01.06.2016 ile 28.11.2016	Piyasa Takas Fiyatları	Türkiye Elektrik Piyasası Gün Öncesi Fiyat Tahmini
2017	Başoğlu ve Bulut	Yapay Sinir Ağları, Uzman Sistemler	Ocak 2005-Mayıs 2011	Sıcaklık, Nüfus Yoğunluğu, GSMH, Sanayi-Üretim Endeksi	Türkiye'nin Kısa Vadeli Elektrik Talep Tahmini
2017	Kocadayı vd	Yapay Sinir Ağları	2002-2014	Nüfus, İthalat, İhracat ve Bina Yüzölçümü	TR81 (Zonguldak, Karabük, Bartın) Bölgesinin Yıllık Elektrik Enerjisi Tüketim Tahmini
2018	Özden ve Öztürk	Yapay Sinir Ağları, Zaman Serileri Analizleri	2014-2016	Elektrik Tüketimi ve Sıcaklık	İvedik OSB Endüstri Alanının Elektrik Enerjisi Tahmini

2018	Kiki	Yapay Sinir Ağları	2012-2015	Dolar Kuru, Toplam Elektrik Üretiminde Yenilenebilir Enerji Oranı, Piyasadaki İkili Anlaşmalar, Piyasa Marjinal Fiyatı, Toplam Talep	Türkiye Elektrik Piyasası Gün Sonrası Fiyatının Tahmini
2018	Haliloğlu ve Tutu	Yapay Sinir Ağları	2012-2017	Elektrik Tüketimi ve Sıcaklık	Türkiye'nin Günlük Elektrik Tüketim Tahmini

Karacasu ve Hoccoğlu (2003), yapay sinir ağılarıyla Gaziantep Yöresi için yük tahmin analizi gerçekleştirmişlerdir. 1994–1998 yılları arasındaki enerji verileri incelenmiş, geri yayılım algoritması ve 5 katman kullanılarak oluşturulan ağ sonuçları isabetli olmuştur. Yapay sinir ağlarının yük puant tahmininde faydalı bir yöntem olduğu sonucuna varılmıştır.

Hamzaçebi ve Kutay (2004) yapay sinir ağı yöntemiyle Türkiye'nin net elektrik tüketimini 2010 yılına kadar tahminlemişlerdir. 1970-1990 yıllarına ait nüfus bilgileri ve elektrik enerjisi tüketim verileri alınmış, tek gizli katman ve Powell-Beale algoritması kullanılmıştır. Yapay sinir ağı yöntemiyle bulunan sonuçlar Box-Jenkins modelleri ve regresyon tekniği ile karşılaştırılmıştır. Bulunan sonuçlar yapay sinir ağlarının elektrik enerjisi tüketiminde iyi bir tahmin aracı olduğunu göstermiştir.

Pao (2006), doğrusal ve doğrusal olmayan regresyon modelleriyle yapay sinir ağı yöntemini birlikte kullanarak Tayvan için elektrik tüketim tahmin modeli kurmuştur. 1993-2005 yılları arasındaki modelde nüfus, GSMH ve tüketici fiyat endeksi değişkenlerinden faydalanmıştır. Modelin en etkili parametresi nüfus ve en az etkili parametresi GSMH olarak görülmüştür. Elektrik tüketim tahmin modellerinden yapay sinir ağlarının daha iyi sonuçlar verdiği ulaşılmıştır.

Aslan ve diğerleri (2006), Kütahya ili için elektrik puant yük tahmini çalışmalarında yapay sinir ağı yöntemini kullanmışlardır. 2000-2004 arası baz alınarak nüfus ve sıcaklık gibi parametrelerin puant yük tahminine etkisini araştırmışlardır. Geri yayılım öğrenme algoritması, üç katman ve Sigmoid aktivasyon fonksiyonundan yararlanarak bir ağ oluşturmuşlardır. Sonuç olarak ekonomik verilerin değişmesi veya puant yükündeki aşırı farklılığın tahmini olumsuz etkilediğini, ayrıca birkaç farklı yöntemle yük tahmini yapılmasının daha gerçekçi sonuçlar vereceği kanısına ulaşılmıştır.

Azadeh ve diğerleri (2007), 1981- 2005 tarih aralığında İran'ın ziraat sektörünün elektrik tüketim tahmini için fiyat, katma değer, müşteri sayısı ve geçmiş tüketim verileri değişken olarak ele alınmış ve yapay sinir ağı ile genetik algoritma bütünleşik kullanılmıştır. Minimum hataya sahip değişkenler genetik algoritmalar ile belirlenmiş, her değişken yapay sinir ağı ile 2008 yılına kadar tahmin edilmiştir. Zaman serileri analizleri içinde genetik algoritma ve yapay sinir ağlarının daha düşük

ortalama mutlak hata yüzdesine (MAPE) sahip olduğu ve yapay sinir ağıları sonuçlarının daha başarılı sonuçlar verdiği görülmüştür.

Özpınar (2007), rüzgâr, su ve güneşe dayalı yenilenebilir enerji santralleri için yapay sinir ağıları ve bulanık mantık kullanarak kısa, orta ve uzun vadeli tahmin yapmıştır. REHES Türkiye Raporu, Meteoroloji Genel Müdürlüğü ve BEST A.Ş.’den 1968- 2006 yılları arasındaki verileri almıştır. Ardışık Beslemeli Geri Yayılım algoritması ve iki katmanlı ağ üzerinde karar kılınmıştır. Rüzgâr enerjisi için güneş ve debi faktörleriyle daha hassas sonuçlar alındığını, Şubat ve Temmuz aylarının en etkin aylar olduğu sonucuna ulaşılmıştır.

Ekonomou (2010), yapay sinir ağıları çok katmanlı algılayıcı modelini kullanarak Yunanistan’ın toplam enerji tüketimini tahmin etmiştir. Ortam sıcaklığı, kurulu güç kapasitesi, GSMH ve yerleşim yeri elektrik tüketimi verileriyle 1992-2008 yıllarında tahmin modeli kurulmuştur. Sonuçlara göre, regresyon modeli ve destek vektör yöntemini karşılaştırarak kurulan modelin daha iyi sonuçlar verdiği ulaşılmıştır.

Kankal ve diğerleri (2011), 1980–2007 yılları arasındaki GSMH, nüfus, ithalat-ihracat miktarları ve istihdam değişkenleriyle Türkiye’nin elektrik tüketiminin modellenmesi için yapay sinir ağıları ve regresyon modelleri ile analiz yapılmıştır. Resmi kuruluşlardan alınan sonuçlarla karşılaştırma yapılmış ve en iyi model bağımsız değişkenlerle yapılan yapay sinir ağıları modeli olmuştur.

Turhan ve diğerleri (2013), yapay sinir ağıları ile İzmir’deki çok katlı binaların toplam enerji tüketimlerini tahmin etmişlerdir. İzmir’e bağlı Konak, Karabağlar ve Balçova ilçelerinde bulunan 148 adet çok katlı binanın toplam enerji tüketimi; imar durumu, ısıtma sistemi tipi, izolasyon varlığı, duvar toplam ısı transfer katsayısı, cam tipi, alan/hacim oranı, toplam dış yüzey alanı ve kat sayısı değişkenleri kullanılarak analiz edilmiştir. Levenberg-Marquardt eğitim algoritması, Sigmoid transfer fonksiyonu ve 4 gizli katman ile uygulanma gerçekleştirmişlerdir. Analiz sonuçlarına göre tüm binanın enerji tüketimine en çok etki eden değişken ısıtma sistemi tipi ve en az etki oranına sahip değişken de cam tipi ile Alan/Hacim oranı olduğu görülmüştür.

Uzlu ve diğerleri (2014), çalışmalarında Türkiye’nin net elektrik enerjisi talebini tahmin etmek için yapay sinir ağıları yönteminden faydalanmışlardır. Gayri safi milli hâsıla, nüfus, ithalat ve ihracat değişkenlerini kullanarak geri yayılım algoritmasına sahip bir model kurmuşlardır. Modelde danışmanlı öğrenme metodunu

kullanmışlardır ancak analiz sonuçlarına göre bu metodun başarılı bir sonuç üretmediğine ulaşılmıştır.

Hamzaçebi ve diğerleri (2014), yapay sinir ağları ile Türkiye net enerji talebini tahmin etmişlerdir. 1970-2010 yılları arasındaki GSMH, nüfus, ithalat, ihracat, bina yüz ölçümü ve taşıt sayısı değişkenleri kullanılarak çoklu doğrusal regresyon ile karşılaştırmalı olarak ortaya konmuştur. Karşılaştırmalar sonucunda yapay sinir ağlarının üstünlükleri gösterilerek 2011-2025 yılları arası Türkiye net enerji talebi tahmin edilmiştir.

Uygun (2015), Nisan 2015- Mart 2016 arası saatlik elektrik enerji talep tahmini için biyoyakıt, rüzgâr gücü, güneş enerjisi, jeotermal ve nehir tipi hidro kapasite artışlarını, dolar kuru, doğalgaz ithalat fiyatı ve GSYİH artışı gibi değişkenleri kullanarak yapay sinir ağları yöntemiyle Türkiye net elektrik enerji talebi tahmin edilmiştir. İleri beslemeli geri yayılım algoritması, Sigmoid fonksiyonu ve iki gizli katmanla ağın başarılı bir şekilde oluşturulduğu ve tahmin işlemlerinde kullanılabileceği sonucuna varmıştır.

Makas ve Karaatlı (2016), çalışmalarında Antalya Havzasında beslenen bir hidroelektrik santralinin 12 aylık elektrik üretiminin çok dönemli tahminini yapay sinir ağları yöntemini kullanarak gerçekleştirmişlerdir. 2007-2014 yılları arasında aylık ortalama yağış, aylık ortalama nisbi nem ve aylık ortalama debi verilerinden yararlanılarak ileri beslemeli geri yayılım algoritması kullanılmıştır. Kurulan modelin 12 aylık tahminde başarılı olduğu ortaya konularak, gelecek çalışmalara öncü olduğu ileri sürülmüştür.

Masaebi (2016), İran elektrik enerjisinin tüketim tahminini 1978-2014 yılları arasındaki büyüme oranı, elektrik satış fiyatı, ithalat, ihracat, GSYH ve nüfus değişkenlerini yapay sinir ağları kullanarak gerçekleştirmiştir. Modelin sonuçları ile İran Enerji Bakanlığı'nın gelecek yıllardaki net elektrik tüketim tahmin değerleri ile de karşılaştırılmıştır.

Dalgın (2017), Enerji Piyasaları İşletme Anonim Şirketi tarafından kamuya açık olan Piyasa Takas Fiyatlarını ele almış, Levenberg-Marquardt geriye yayımlı algoritma ve tek katmanlı yapay sinir ağı yöntemiyle 01.06.2016 ile 28.11.2016 tarihleri arasında günlük verilerle Türkiye elektrik piyasası gün öncesi fiyat tahmin modeli oluşturmuştur. Ağdaki ağırlık değerleri incelendiğinde, hafta içi günler,

Ramazan ayı ve Bayram günü tiplerinin doğalgaz maliyetinde etkin olduğu görülmüştür.

Başoğlu ve Bulut (2017) yaptıkları çalışmada Türkiye'nin piyasa ve mevsimsel koşullarını göz önüne alıp, yapay sinir ağları ve uzman sistemleri birlikte kullanarak, kısa vadeli elektrik talep tahminlerinde yüksek doğruluk derecesi sağlayan bir hibrit sistem geliştirmişlerdir. Kısa vadeli dönemler için, gerçekleşen değerlere yakın tahmin sonuçları elde edilmiştir.

Kocadayı ve diğerleri (2017) Zonguldak, Karabük, Bartın bölgesine ait 2002-2014 yılları arasında yıllık elektrik enerjisi tüketim tahmininde yapay sinir ağları kullanmışlardır. Nüfus, ithalat, ihracat ve bina yüzölçümü verilerini değişken olarak ele almış, geri yayılım algoritması ve 7 gizli katmanın olduğu bir model oluşturulmuştur. Yapay sinir ağları yöntemiyle uzun dönemli elektrik enerjisi tüketiminde oldukça başarılı sonuçlar alınabildiği ispatlanmıştır.

Özden ve Öztürk (2018) yapay sinir ağları ve zaman serileri yöntemi ile İvedik OSB endüstri alanının elektrik enerjisi ihtiyacını tahmin etmişlerdir. 2014-2016 günlük verilerine ait tüketim verileri ve sıcaklık değişkeni olarak alınmıştır. Çalışmanın sonucunda zaman serileri yöntemi veri kısıtlılığı sebebiyle yapay sinir ağlarına göre daha kötü bir tahmin gerçekleştirmiştir.

Kiki (2018), 2012-2015 yılları arasında yılın en soğuk, en yağışlı ve en sıcak dönemleri tespit edilmiş, bu dönemlere ait dolar kuru, toplam elektrik üretiminde yenilenebilir enerji oranı, piyasa da mevcut olan ikili anlaşmalar, bir gün öncesine ait piyasa marjinal fiyatı, toplam talep, gün ve saat değişkenleri kullanılarak yapay sinir ağları yöntemleriyle Türkiye elektrik piyasası gün sonrası fiyatının tahmini yapılmıştır. Özellikle havza alanı az olan santrallerde elektrik fiyatlarında daha büyük kazanç sağlandığı ve fiyatların ucuz olduğu saatlerde üretim kapasitesinin arttırılmasının maliyetleri düşüreceği sonucuna varılmıştır.

Haliloğlu ve Tutu (2018) yayınladıkları çalışmalarında, Türkiye'nin günlük elektrik tüketimini yapay sinir ağlarıyla tahminleyen bir model oluşturmuşlardır. Hem sıcaklığı hem de mevsimselliği modellemek adına eşik sıcaklık değeri adı altında bir değişken tanımlamışlardır. 2012-2017 yılları arası günlük frekanstaki verileri kullanarak Ocak – Nisan 2018 dönemine ait veriler test edilmiştir.

Gerçekleşen elektrik tüketimi ile tahmin edilen elektrik tüketimi arasında aylık ortalama sapma oranlarının %1,3 ile %1,6 arasında olduğu sonucuna ulaşmışlardır.



2. TALEP TAHMİNİ VE MODELLERİ

2.1. TALEP TAHMİNİ

Talep, tüketicilerin belirli bir fiyat seviyesindeki ürün veya hizmeti almaya hazır oldukları miktardır (Tekin, 1996).

Tahmin, yönetimde karar verme süreçlerinin bir parçasıdır. Örgütteki değişimlere karşı bağlılığın azalması ve çevresiyle daha bilimsel ilişkiler kurabilmesi için etkin tahminlere ihtiyaç duyulur. Bir örgütün içindeki tüm bölümlerin diğer bölümlerle etkileşim halinde olduğu bilindiğine göre doğru ya da yanlış yapılan bir tahmin paralel olarak örgütün tamamını etkileyecektir (Makridakis ve diğerleri, 1998).

Talep tahmini ise, şirketin bir veya birden fazla ürünü için talep düzeyini gelecekteki zaman diliminde tespit etmektir (Acar, 1989).

Talep tahmini belirli kural ve usullere göre yapılır. Fakat hangi yöntem uygulanırsa uygulansın, yapılan tüm talep tahminlerinin belli bir doğruluk payı söz konusudur ve hiç bir tahmin %100'lük bir doğruluk oranına sahip olamaz. Bu nedenle tahmin sürecinin her bir adımı kritik öneme sahiptir ve yapılan tahminlerde genellikle tek bir yöntem kullanılmaz. Başarılı bir talep tahmini için; öncelikle talebin mevcut ve gelecekteki projeksiyon durumunun planlaması yapılmalı, talebi etkileyen değişkenler belirlenmeli, bu değişkenlerin talebi hangi koşul ve oranda etkilediği tespit edilerek değişkenlere uygulanacak olan yöntem titizlikle seçilmelidir. Oluşturulan modelin geçerliliği kontrol edilir ve çözüm uygulanır.

Doğru elektrik talep tahmini, etkin bir elektrik sistem planlamasında önemli rol oynamaktadır. Ancak, uzun vadeyi kapsayan elektrik talebini doğru tahmin etmek oldukça güçtür. Bu güçlük tahmin sürecinin belirsizliklerinden kaynaklanmaktadır. Uzun vadeli elektrik talep tahminleri genellikle hatalıdır çünkü uzun vadeli hava tahminlerinin hata payı oldukça yüksektir. Ayrıca yeni elektrik üretim santralleri veya enerji nakil hatlarının yapımı uzun zaman alabilir ve bu tesisler pek çok nedenden ötürü zamanında işletmeye giremeyebilir. Dolayısıyla, uzun dönemde yapılan elektrik talep tahminleri genellikle hatalıdır. Önemli olan bu hatanın minimum seviyelere çekilebilmesidir.

Talep tahmini yapmak için başvurulan yöntemler ürün veya hizmetin farklı olması nedeniyle hem yöntemlerin hem de tüketicilerin farklı olmasını gerektirmektedir. Dolayısıyla tek bir tahmin yönteminin kullanılmasını mümkün değildir. Günümüzdeki piyasada yeniliklerine göre yöntemler de başkalaşmaktadır. Zaman periyotlarına, karar kriterlerine ve ulaşılabilir veri gibi birçok ölçüte göre tahmin yöntemleri çeşitlenmektedir. Talep tahmin yöntemleri; istatistiksel modeller ve yapay zekâ çözümleri olarak iki sınıfa ayrılmaktadır.

2.2. İSTATİSTİKSEL TAHMİN YÖNTEMLERİ

2.2.1. Regresyon ve Korelasyon Analizi

Regresyon analizi; aralarında neden-sonuç ilişkisi bulunan herhangi bir değişkeni, iki (basit regresyon) veya daha fazla açıklayıcı değişken (çoklu regresyon) ile belirlemek ve bu ilişkiyi matematiksel bir fonksiyonla yazmaktır. Bu fonksiyona regresyon denklemi adı verilmektedir. Regresyon denklemi sayesinde bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi kuran parametrelerin değerleri tahmin edilir. Bağımlı değişkeni etkileyen bağımsız değişkenlerin tahmin edilmesi, bu değişken üzerinde yürütülecek plan ve politikalarda hangi değişkenlerin önemli olduğunun belirlenmesine yardımcı olmaktadır (Çağlar, 2007:25).

İki veya daha fazla değişken arasındaki ilişki doğrusal ya da eğrisel olmaktadır. Temelde basit doğrusal regresyon, çoklu doğrusal regresyon, üssel regresyon ve eğrisel regresyon denklemleri bulunmaktadır. Bu denklemler matematiksel olarak aşağıda ifade edilmektedirler.

Basit Doğrusal Regresyon:

$$Y=a+bX \quad (2.1)$$

Çoklu Doğrusal Regresyon:

$$Y = a + b_1X_1 + b_2X_2 + \dots + b_nX_n \quad (2.2)$$

Üssel Regresyon:

$$Y = a + b_1^x \quad (2.3)$$


Eğrisel Regresyon:

$$Y = a + b_1X + b_2X^2 + \dots + b_nX^n \quad (2.4)$$

Basit doğrusal regresyon, iki değişken arasındaki ilişkinin doğrusal olduğu kabul edildiğinde denklem $Y = a + bX$ şeklinde ifade edilir ve bağımsız değişkenin değeri yerine konularak tahmin değeri elde edilir. Basit doğrusal regresyon modelindeki a, b parametrelerinin tahmininde En Küçük Kareler yöntemi (EKK) kullanılır.

En küçük kareler yöntemindeki matematiksel ifadeleri grafik olarak aşağıda Şekil 3.2' deki gibi göstermek mümkündür.

Şekil 2.1. En Küçük Kareler Yöntemi



Kaynak: Adıyaman, 2007


Yukarıda Şekil 2.1.' deki doğruya ait grafikte görüldüğü gibi, çizilen doğru üzerindeki bağımlı değişken değerleriyle gerçek değerler arasındaki farkın karelerinin toplamını minimum yapacak en uygun doğru bulunmaya çalışılmaktadır.

Korelasyon ise, iki deęişken arasındaki ilişkinin derecesini ifade eden bir kavram olup, deęişkenlerin birlikte deęişimlerini ölçmektedir. Korelasyon “R” ile simgelenir. Başka bir deyişle, denklemin ilişkiyi ne ölçüde tanımladığını gösterir. İlişki ne kadar güçlü ise oluşturulan tahminlerin doğruluğunun da o derece artması beklenir (Üreten, 2005:137).

Basit korelasyon, iki deęişken arasındaki ilişkinin yakınlığını korelasyon katsayısı cinsinden ifade etmektedir. Bir deęişkenin birden fazla deęişkenle birlikte deęişiminin incelenmesine ise “çoklu korelasyon katsayısı” adı verilir. Şekil 2.2.’de gerçekleşen deęerlerle tahmin edilen deęerler arasındaki korelasyonu gösteren eğrinin grafięi görölmektedir. Korelasyon katsayısı, gözlem noktalarının regresyon doğrusu karşısında gösterdiği deęişkenlięin dolaylı bir ölçüsüdür (Monks, 1996:47).

$$R = \frac{n \sum x_i y_i - \sum x_i \sum y_i}{\sqrt{[n \sum x^2 - (\sum x)^2][n \sum y^2 - (\sum y)^2]}} \quad (2.5)$$

Şekil 2.2. Korelasyon Katsayısı Eğrisi



Kaynak: Karahan, 2011

Yukarıda Şekil 2.2.’de bağımlı deęişkenin gerçek deęerlerinin oluşturduğu Korelasyon eğrisi görölmektedir. Korelasyonu incelenen iki deęişken arasındaki

etkileşim sürekli 1'den küçük olmaktadır. Aşağıda Tablo 2.1' de, Korelasyon katsayısının aldığı değerlerin yorumlanmasında kullanılan ölçütler verilmiştir.

Tablo 2.1. Korelasyon Katsayısı Değerleri ve Yorumlamaları

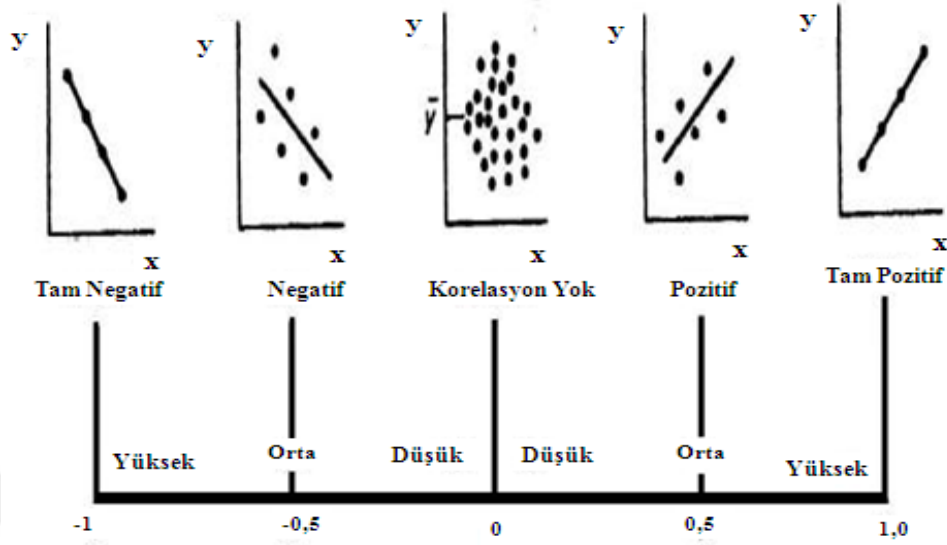
Korelasyon Katsayısı Değerleri	Yorumlamaları
0.90 - 1.00	Çok yüksek korelasyon
0.70 - 0.90	Yüksek korelasyon
0.40 - 0.70	Normal korelasyon
0.20 - 0.40	Düşük korelasyon
0.00 - 0.20	Çok düşük korelasyon

Kaynak: Tekin, 2009

Tablo 2.1'de görüldüğü üzere korelasyon katsayısı değerlerinin $-1 \leq R \leq +1$ arasında bir değer alır. Bu değerlerin 1'e yaklaşması, yüksek korelasyona; 0'a yaklaşması düşük korelasyon ilişkisine işaret etmektedir. $R > 0$ ise değişkenler arasında düz ilişki vardır. $R < 0$ ise değişkenler arasında ters ilişki vardır. İki değişken arasında bir ilişki olmaması durumunda $R=0$ değerini alır.

Korelasyon katsayısının işareti, her zaman b katsayısınınkiyle aynıdır; bir başka ifadeyle regresyon doğrusunun eğiminin negatif olması durumunda, korelasyon katsayısının değeri de negatif olacaktır (Üreten, 2005:137). Şekil 2.3.' de korelasyon katsayısı değerlerine göre oluşan doğrular ve yorumlamaları gösterilmektedir.

Şekil 2.3. Korelasyon Katsayısının Yorumlanması



Kaynak: Monks, 1996: 50


Şekil 2.3.' te görüldüğü gibi korelasyon değeri 1'e yaklaştıkça etkileşim yükselmekte ve grafiklerdeki dağılım bir doğru etrafında yoğunlaşmaktadır. Tam tersine 0'a yaklaştıkça da dağılım yayılmaktadır.

2.2.2. Zaman Serileri Analizi

Zaman serisi; herhangi bir olayın zaman dilimleri sırasına konularak oluşturulan gözlem değerlerinin kümesidir. Zaman serileri analizi ise, belli zaman aralıklarında gözlenen bir olay hakkında, gözlem serisinin inşasını sağlayan stokastik süreci modellemeyi ve geçmiş dönemlere ait gözlemler sayesinde geleceğe yönelik tahminler yapmayı esas alan bir yöntemdir (Kaynar ve Taştan, 2009:161-172).

Zaman serisi analizi yapılırken, belirli dönemlerde gözlemlenen talep bilgileri bir ölçeğe göre sıralanarak oluşturulan talep doğrusunun belirli bir düzen gösterip göstermediğine bakılır. Aşağıda Şekil 2.4.'de zamana göre değişebilen çeşitli talep düzenleri gösterilmiştir.

Şekil 2.4. Zamana Göre Çeşitli Talep Düzenleri



Kaynak: Üreten, 2005: 139

Yukarıda Şekil 2.4.' de, zaman serisi analizine dayanan talep tahminlerindeki eğilimlerden, doğrusal eğilim, mevsimsel değişimler eğrisi ve değişmeyen sabit talep düzenleri bir grafik üzerinde gösterilmiştir.

Zaman serisi analizine dayanan tahmin yöntemlerinden en çok kullanılanları; Hareketli Ortalamalar Yöntemi, Üssel Düzeltme Yöntemi ve Box-Jenkins yöntemleri şeklinde sıralanabilir.

2.2.2.1. Hareketli Ortalamalar Yöntemi

Mevsimsel dalgalanmaların talep üzerindeki etkisinin belirlenmesinde kullanılan bir yöntem olarak bilinmektedir. Geçmiş dönemlerdeki verilerin incelenerek ve bu verilerin zaman içindeki gösterdiği eğilim doğrusundan faydalanılarak, gelecek dönemlerdeki talep tahmini yapılabilmektedir. Yöntemin esası, zaman serisini kümelerle ayırmak ve her kümenin aritmetik ortalamasını hesaplayarak kümenin ortasına isabet eden yılın üzerinde bir nokta işaretlemektir. Daha sonra bu noktaları birleştirerek hareketli ortalamalar eğilim (trend) çizgisini çizmektir. Kümeler oluşturulurken zaman serisindeki fiili gözlem değerleri her seferinde bir yıl aşağıya

kaydırılarak ortalamalar hesaplandığı için bu yönteme "hareketli ortalamalar" adı verilir.

Hareketli ortalamalar yöntemi, aritmetik ortalama metodu gibi kendisinden önceki dönemlerin ortalamasının bir sonraki dönemin ortalamasına eşit olacağı varsayımı üzerine kuruludur. Ancak bu metod uzak geçmişten çok, yakın geçmişi göz önüne alır ve belirlenen n adet dönemin ortalamasını alarak yalnızca bir dönem için tahminini yapar.

$$F_{t+1} = \frac{y_t + y_{t-1} + \dots + y_{t-n+1}}{n} \quad (2.6)$$

Hareketli ortalamalar yönteminde seçilecek n döneminin tespiti çok önemlidir. Bu dönem sayısı arttıkça seride düzgünleştirme sağlanacaktır, dönem sayısının az seçilmesi durumunda ise tahmin son dönem taleplerinden gereğinden fazla etkilenebilir.

Ağırlıklı hareketli ortalamalar yönteminde ise, basit hareketli ortalamalar yönteminde kullanılan mantık geçerlidir. Ancak basit hareketli ortalama alınırken değerlerin etkisi eşitken bu yöntemde değerlere ağırlıklar verilerek etkilerinin farklılaşması sağlanır. Eğer ürünün talebinde son dönemlerde gerçekleşen değişimlerin etkisi büyük ise son dönemlere daha büyük ağırlıklar verilerek etkisi güçlendirilir. Bunun yanı sıra zaman serisini oluşturan veriler arasından uç değerler yani genel ortalamanın çok üstünde ve altında değerler bulunuyorsa bu değerlerin ağırlıkları düşürülerek tahmin değeri üzerindeki etkisinin azaltılması sağlanabilir.

$$F_{t+1} = \frac{w_1 * y_t + w_2 * y_{t-1} + \dots + w_n * y_{t-n+1}}{w_1 + w_2 + \dots + w_n} \quad (2.7)$$

w_n , n. dönemde gerçekleşen talebe verilen ağırlık olduğundan ağırlıklı hareketli ortalama yönteminde belirlenecek ağırlık değerleri de önem teşkil etmektedir. Ağırlık değerleri doğrusal olarak belirlenebilir. Geçmiş taleplere verilen ağırlıklar düzgün bir azalış gösterecektir. Son dönemlerin farklı ağırlıklarda olacağı düşüncesi ya da belirli dönemlerin etkisinin daha fazla olacağını düşüncesi ağırlıkların sezgisel olarak da verilebileceği durumlardır.

2.2.2.2. Üssel Düzeltim Yöntemi

Üssel düzeltim yöntemi; geçmiş dönem verilerine eşit ağırlık verilmesiyle basit hareketli ortalamalar yöntemine benzerken, geçmiş verilere farklı ağırlıkların verilmesiyle oluşur. Üssel kelimesinin anlamı, veriler eskidikçe ağırlıkların da üstel bir şekilde azalmasıdır. Bir başka deyişle bu yöntem, geçmiş zamandaki taleplere belirli ağırlıklar vermek yerine geçmiş dönemlere ait ortalama talep ile mevcut döneme ait talebi belirli oranlarda tekrar ağırlıklandırarak bir sonraki dönemin talebini hesaplar (Çağlar, 2007:39).

Yöntemin kullanılmasında geçmiş dönemlerin talep ortalaması ve mevcut dönemin talep değeri yeterli olur.

$$X = \frac{1}{\left(\frac{n}{2}\right) - 1} \quad (2.8)$$

$$F_{t+1} = \left[(1 - X) * \frac{\sum_{n=1}^{t-1} y_n}{n} \right] + [(1 - X) * y_t] \quad (2.9)$$

$$F_{t+1} = F_t + a(y_t - F_t) \quad (2.10)$$

X değeri, en son dönem ile geçmiş dönemler arasında ağırlıklandırmayı belirten katsayı iken a katsayısı 0 ile 1 arası değer alan düzgünleştirme katsayısıdır. Denklemdaki a değeri dönemlere verilen ağırlıklara etki etmektedir. Yani a büyüdükçe son dönemlere ait gerçekleşen taleplere daha fazla ağırlık verilir. Böylece son dönem verisinin tahmin üzerindeki etkisi daha büyük olacaktır.

$(y_t - F_t)$ ifadesi, gerçek gözlem değeri ile tahminin gözlem değeri arasındaki farktır. Bu fark tahminin hatasıdır ve tahmindeki doğruluk açısından önem taşımaktadır. Bu hata pozitif çıktığında gerçekleşen tahminden daha büyüktür, böylece düzgünleştirme katsayısı gelecekteki tahminleri arttıracak yönde etki eder. Tam tersi durumda ise, tahmin gerçekleşenden büyüktür yani hata negatiftir ve düzgünleştirme katsayısı tahmini azaltma yönündedir (Mann, 1995).

2.2.2.3. Box Jenkins Yöntemleri

Zaman serisi analizine dayanan yöntemlerde doğrusal filtreleme tekniği olarak bilinen Box Jenkins yöntemleri; Otoregresif (Auto Regressive-AR), Hareketli Ortalama (Moving Average-MA), Otoregresif-Hareketli Ortalama (Auto Regressive-Moving Average-ARMA) ve Birleştirilmiş Otoregresif-Hareketli Ortalama (Auto Regressive Integrated Moving Average-ARIMA) olarak sınıflandırılır. Oluşturulan modelde seri durağan ise ARMA, seri durağan değilse ARIMA yöntemlerinin kullanılması gerekir.

Box-Jenkins modellerinin metodolojisi; ilk aşamada serinin durağan hale getirilmesini, ikinci aşamada modelin belirlenmesini ve üçüncü aşamada belirlenen modelin parametrelerinin hesaplanmasını ifade etmektedir. Son aşama ile modelin ileriye yönelik tahmini gerçekleştirilmektedir (Box ve Jenkins, 1976).

Otoregresif model (AR); süreç zaman içinde verilerin değişmeyeceği duruma dayanır. Burada p değeri geçmiş dönem sayısını verir. Model, geçmiş p dönemdeki zaman serisi değerlerinin ağırlıklı toplamının ve rastsal hata değerinin bir fonksiyonudur. AR(p) modelinin genel gösterimi aşağıdaki gibidir:

$$y_t = a + \sum_{i=1}^p \beta_i y_{t-i} + \varepsilon_t \quad (2.11)$$

P: Otoregresif terimlerin sayısıdır.

y_t : Gecikmeli değerleri ve hata terimidir.

a: Bilinmeyen otoregresif parametrelerdir.

ε_t : Ortalaması sıfır, varyansı sabit, ilişkisiz rastsal bir hata terimidir.

Hareketli ortalama (MA); y_t değeri serinin geriye doğru q dönem geçmiş hata terimlerinin ve ortalamasının doğrusal fonksiyonudur (Kutlar, 2000). q'uncu dereceden bir hareketli ortalama süreci aşağıda denklem (2.12)'de gösterilmektedir.

$$y_t = \mu + \sum_{i=1}^q \beta_i \varepsilon_{t-i} \quad (2.12)$$

q: Hareketli ortalama terimlerinin sayısıdır.
μ : Sürecin ortalaması olan bir sabittir.

Zaman serileri analizi sadece otoregresif olabileceği gibi hareketli ortalama da içerebilir veya her ikisinin de gözlenebildiği koşullar ortaya çıkabilmektedir. Bu nedenle durağan süreçler yalnızca otoregresif ya da yalnızca hareketli ortalama yöntemi ile açıklanamayabilir. Buna benzer koşullarda zaman serilerinin modellenmesine esneklik sağlamak ve en az sayıda parametre ilkesini gerçekleştirmek amacıyla model p'inci dereceden otoregresif ve q'uncu dereceden bileşenleri ile p ve q'uncu dereceden ARMA(p,q) biçiminde ifade edilebilir. Denklem (2.13)'te modelin matematiksel ifadesi gösterilmektedir.

$$y_t = a + \sum_{i=1}^p \beta_i y_{t-i} + \sum_{i=1}^q \beta_i \varepsilon_{t-i} + \varepsilon_t \quad (2.13)$$

Zaman serileri analiz yöntemlerinden ARMA(p,q) modellerinden farklı olarak durağan olmayan serinin d'inci mertebede türevi alınarak durağan hale getirilmesiyle sıkça kullanılan ARIMA(p,d,q) yapısı oluşmaktadır.

Bu bütünleşmiş model belirli sayıda farkı alınmış serilere uygulanan AR ve MA modellerinin birleşimidir. Eğer AR modelinin derecesi p, MA modelin derecesi q ve serinin de d'inci mertebede farkı alınmışsa bu modele (p, d, q) dereceden Otoregresif Bütünleşik Hareketli Ortalamalar modeli denir. Burada p otoregresif terimlerin sayısını, d seriyi durağan duruma getirmek için alınan fark parametresini, q ise hareketli ortalama terimlerinin sayısını gösterir (Baran, 2010:39).

2.2.3. Yapay Zekâ Çözümleri

İlk kez 1950'lerde ortaya çıkan yapay zekâ kavramı çağımızın ilgi odağı olmuş ve günümüze kadar gelen zaman aralığında hayatın en gerekli parçası olan sistemlerin oluşumuna zemin hazırlamıştır (Öztemel, 2003). Talep tahmini teriminin değişkenliği ve belirsizliği de yapay zekâ yöntemlerinin talep tahmin sorunlarının çözülmesinde büyük katkısı olduğunu göstermiştir. Talep tahmini uygulamalarında

en sık kullanılan yapay zekâ yöntemlerinden bulanık mantık ve yapay sinir ağları özetlenerek anlatılmıştır.


2.2.3.1. Bulanık Mantık

Bulanık mantık (Fuzzy Logic), makine dilinde insanların tecrübelerinin ve sezinlemelerinin işlenmiş halidir. Bu işlem matematiksel bir neden sonuç fonksiyonunun çalışma prensibine dayanır. Matematiksel zemin bulanık kümeler hipotezidir. Bulanık kümeler, istatistikî olmayan belirsizlikte veri ve bilgilerin ifadesi için Azerbaycan asıllı bir İranlı olan Lotfi Zadeh tarafından 1965’de ortaya atılmış tekniktir. Zadeh çalışmasında girdi verilerinin farklı küme ve üyelik derecelerini belirterek girdinin çıktıya dönüşümünde bu kümelerden faydalanılabileceğinden bahsetmiştir. Bu çalışmalar başlangıçta pek değer görmese de zamanla önem kazanmış ve bulanık mantık araştırmaları yaygınlaşmıştır. Zadeh’ in ufuk açan fikri “Bulanık Mantık” bilinen klasik mantık gibi (0 ve 1) olmak üzere iki seviyeyi değil (0 - 1) gerçek sayılar arasından işlem yapan üyelik fonksiyonunu ifade etmektedir (Kubat, 2014).

Bulanık mantık sisteminin başlıca iki özelliği vardır:

- Bulanık mantık özellikle istatistiksel model çıkartmanın zor olduğu belirsiz durumlar için uygundur.
- Bulanık mantık verilerin eksik ya da belirsiz olduğu durumda ise tahmini veriler ile karar verilmesine olanak sağlar.

Şekil 2.5. Bulanık Mantığın Elemanları ve Çalışması



Kaynak: Öztemel, 2016:19

Bulanık mantık, Şekil 2.5.' de gösterilen sürece göre çalışır. Girdi ve çıktı değerlerinin uygun bulanık değer yapılarına dönüştürüldüğü 'Bulanıklaştırma' aşaması, bulanık değerlerin kurala göre işlendiği 'Bulanık Önermeyi İşleme' aşaması ve son olarak elde edilen bulanık sayıların durulaştırıldığı yani gerçek sayılara dönüştürüldüğü 'Durulaştırma' aşamasıdır (Onur ve diğerleri, 2016:371). Durulaştırma aşamasından sonra elde edilen sayılar doğrultulmuş sonuç olarak kullanılacak sisteme aktarılır.

Bulanık mantığın üstünlükleri; insan düşünme tarzında işlemesi, bu işleyişte matematiksel modele ihtiyaç duyulmaması ve uygulanmasının basitliğinden dolayı oldukça düşük maliyetli olmasıdır. Buna karşın, modelde kullanılacak kuralların tespitinde uzman görüşüne ihtiyaç duyulması, üyelik fonksiyonlarının deneme - yanılma yoluyla yapılmasının uzun zaman alması ve karar analizi ile denetlenebilirliğinin zor olması bulanık mantığın dezavantajlarıdır (Özpinar, 2007).

2.2.3.2. Yapay Sinir Ağları

Yapay sinir ağları, talep tahmini çalışmalarında sıklıkla kullanılan bir yöntemdir. Bu çalışmada, yapay sinir ağları kullanılarak elektrik talep tahmin problemi çözülmüştür. Yapay sinir ağları yöntemi üçüncü bölümde ayrıntılı olarak ele alınacaktır.

2.3. TAHMİN YÖNTEMLERİNİN PERFORMANSININ ÖLÇÜLMESİ

Bir tahmin modeli kurmayı amaçlayıp değişkenleri belirleyip, uygun yöntemi de kullanıp sonuç beklemek aslında işin yeterliliklerini bilenler için kolay olabilir. Ancak oluşturulan modelin başarısını izleyip, kontrol ve denetlemesini yapmak oldukça büyük bir öneme sahiptir. Tahmin yöntemlerinin performansını ölçmemizi sağlayan hata testleri, tahmin ile gerçekleşen talep arasındaki farkı bulmamızı sağlar. Sonuç olarak tahmin hatasını minimize edecek birçok hata tahmin ölçütü geliştirilmiştir.

i : Herhangi bir ayırık veri indeksi

Y_i : i inci gerçek değer

\hat{Y}_i : Modelin i inci tahmin değeri

e_i : i inci hata

n : Ayırık veri (ölçüm) sayısı

- Birinci ölçüt, hatadır. Matematiksel ifadesi Denklem (2.14)' de verilmiştir.

$$e_i = Y_i - \hat{Y}_i \quad (2.14)$$

- İkinci ölçüt, mutlak hatadır. Matematiksel ifadesi Denklem (2.15)' de verilmiştir.

$$|e_i| = |Y_i - \hat{Y}_i| \quad (2.15)$$

- Üçüncü ölçüt, mutlak yüzde hatadır. Matematiksel ifadesi Denklem (2.16)' da verilmiştir.

$$\%|e_i| = \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| * 100 \quad (2.16)$$

- Dördüncü ölçüt, ortalama mutlak hatadır (Mean Absolute Error - MAE). Mutlak değerle ifade edilerek işaretlerden arındırılan hata değerlerinin talep değerlerine olan uzaklıkları tespit edilmiş olur. Matematiksel ifadesi Denklem (2.17)' de verilmiştir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (2.17)$$

- Beşinci ölçüt, ortalama karesel hatadır (Mean Squared Error - MSE). Bu ölçüt de ortalama mutlak hata gibi hataları işaretlerden arındırır ve yalnızca büyüklüklerine bakar. Matematiksel ifadesi Denklem (2.18)' de verilmiştir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \frac{1}{n} \sum_{i=1}^n (e_i)^2 \quad (2.18)$$

- Altıncı ölçüt, ortalama mutlak hata yüzdesidir (Mean Absolute Percentage Error - MAPE). Hataları yüzdesel olarak ifade ederek hataların birbirleriyle kıyaslanmasını sağlar. Matematiksel ifadesi Denklem (2.19)' da verilmiştir.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| * 100 \quad (2.19)$$

- Yedinci ölçüt, hata karelerinin ortalamasının kareköküdür (Root Mean Squared Error - RMSE). Tahmin değerleri ile gerçekleşen değerler arasındaki uzaklığı ölçerek büyüklüklerine bakar. Matematiksel ifadesi Denklem (2.20)' de verilmiştir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} = \sqrt{\frac{1}{n} \sum_{i=1}^n (e_i)^2} \quad (2.20)$$

- Sekizinci ölçüt, R^2 ' dir (R Square). R^2 hesabını bulmak için SSE, SST hesaplarını da bulmamız gerekmektedir. Modelin performans değerlerinin 0 ile 1 arası çıkması beklenmektedir. Matematiksel ifadesi Denklem (2.21)' de verilmiştir.

$$R^2 = 1 - \frac{SStotal}{SSerror} = 1 - \frac{\sum(Y_i - \hat{Y}_i)^2}{\sum(Y_i - \bar{Y})^2} \quad (2.21)$$

Tahmin modellerinin performansı ölçülüyorken hangi ölçüt kullanılıyorsa, o ölçüt değerinin en aza indirgenmesi amaçlanır. Ayrıca tahmin modelleri de birbirleri arasında kıyaslanacaksa bu belirtilen ölçütler kullanılır. Hangi modelin ölçüt değeri düşük ise o model isabetli tahmin olarak kabul edilir.

Bu çalışmada, oluşturulan tahmin modellerinin kıyaslanmasında MAPE ve R^2 ölçütüne bakılmıştır. Hangi modelin değeri düşük ise o model en başarılı model kabul edilmiştir.

3. YAPAY SİNİR AĞLARI

3.1. YAPAY SİNİR AĞLARINA GİRİŞ

Çalışmanın bu bölümünde talep tahmininde kullanılacak olan Yapay Sinir Ağları (YSA) yöntemi genel hatlarıyla anlatılacak, uygulamaya geçmeden önce teorik altyapı incelenecektir.

Üzerine birçok tanım yapılan yapay sinir ağları en temel anlamıyla, insan beyninin özelliklerinden yola çıkarak geliştirilmiş, yeni bilgiler yaratma yeteneğini hiçbir yardıma gerek duymadan otomatik olarak yapmayı hedefleyen bir bilgisayar sistemidir.

Yapay sinir ağları insan beyninin;

- Öğrenme
- İlişkilendirme
- Sınıflandırma
- Genelleme
- Özellik belirleme
- Optimizasyon

gibi fonksiyonel özelliklerine benzer konularda başarılı bir şekilde uygulanmaktadır (Öztemel, 2003).

Yapay sinir ağlarının mantığında, geçmiş olaylardan esinlenerek ortaya çıkacak örnekler üzerinden tahmin yapabilme kabiliyeti vardır. İnsanın düşünebilen ve öğrenebilen bir varlık olması sebebiyle yapay sinir ağları sistemi insan beynini taklit etmiştir. Yapay sinir ağları, yapısının en küçük birimi olan sinir hücrelerinden oluşur. Sinir hücrelerinin işleyişini matematiksel olarak ifade etmek amacıyla geliştirilen yapay sinir hücreleri çeşitli hipotezlere dayanmaktadır:

- I. Süreç nöron olarak adlandırılan basit elemanlardan oluşur.
- II. Nöronlar arası bağlantılarda sinyal gönderilir.
- III. Her bir bağlantının ağırlık değeri vardır.

IV. Nöronun net girdisinin bir aktivasyon değerinden geçirilmesiyle net çıktı elde edilir (Hamzaçebi, 2011: 11).

3.1.1. Yapay Sinir Ağlarının Tarihçesi

Bilim insanlarının nörobiyolojik alana yönelmeleri ve elde ettikleri sonuçları bilgisayar bilimine uygulamaları ile yapay sinir ağları çalışmalarının zemini hazırlanmıştır. YSA ile ilgili çalışmalar kronolojik olarak aşağıda sıralanmıştır (Hamzaçebi, 2011:14).

- **1943:** Yapay sinir hücrelerine dayalı aritmetiksel metotlar teorisinin ortaya atılması: Warren McCulloch/Walter tarafından Pitts “Sinir Aktivitesinde Düşüncelere Ait Bir Mantıksal Hesap” modeli.
- **1948:** Wiener’in, Sibernetik kitabı ile kontrol, iletişim ve istatistiksel sinyal işleme kavramları.
- **1949:** Öğrenebilen ve uyum sağlayabilen sinir ağlarının bağlantı sayısındaki değişiklik ile ağın öğrenebileceğini Hebb Kuralı.
- **1956-1962:** Adaline ve Windrow öğrenme algoritmasının ve Tek Katmanlı Algılayıcının (Perceptron) geliştirilmesi.
- **1965:** İlk makine öğrenme kitabının yazılması.
- **1967:** Bazı gelişmiş öğrenme algoritmalarının geliştirilmesi: Grosberg öğrenme algoritması.
- **1969:** Tek katmanlı algılayıcıların problemleri çözme yeteneklerinin olmadığını gösterilmesi.
- **1972:** Doğrusal ilişkilendiriciler ile Korelasyon-matriks belleğinin geliştirilmesi ve Çağrışımlı Bellek (Associative memory) konusunda çalışmalar: Kohonen ve Anderson çalışmaları.
- **1974:** Geri Yayılım modelinin (Çok katmanlı algılayıcıların ilk çalışmaları) geliştirilmesi.
- Öğretmensiz Öğrenmenin geliştirilmesi:
 - **1978:** Adaptif rezonans teorisinin geliştirilmesi.

- **1982:** Kohonen Öğrenmesi ve Özörgütlemeli Harita modelinin geliştirilmesi.
- **1982:** Hopfield Ağları ve Çok Katmanlı algılayıcılarının geliştirilmesi.
- **1984:** Boltzman makinesinin geliştirilmesi.
- **1985:** Çok katmanlı algılayıcıların Genelleştirilmiş Delta Öğrenme Kuralı ile geliştirilmesi.
- **1988:** Radyal Tabanlı Fonksiyon modeli ve Olasılıksal Sinir Ağları modelinin geliştirilmesi.
- **1991:** Genelleştirilmiş Regresyon modeli geliştirilmiştir.

Tüm dünyada yapay sinir ağları ile ilgili çalışmalar günümüzde hâlâ devam etmektedir. Araştırmaların yoğunlaştığı başlıca konulardan biri yapay sinir ağlarındaki öğrenme algoritmasının zaman almasıdır. Geliştirilmesi planlanan yeni algoritmalarda daha hızlı ve daha etkin bir işlev hedeflenmiştir. Gelişen teknoloji ile birlikte akıllı binalar, sürücüsüz otomobiller, robot kuryeler, ultra yüksek hızlı trenler ve yapay organlar gibi çalışmalar ortaya çıkacaktır. İleri teknolojiyi kontrol ve tahmin eden sanal zekâ yerine daha önce karşılaşılmayan durumlara dahi çözüm üretebilen bir model daha başarılı olacaktır. Makinelerin yapısal temelinde akıl yürütmeyi ve çevreye uyum sağlamayı mümkün kılan yapay sinir ağları bu çalışmalarda yararlanılacak temel yöntemlerden biridir (Yılmaz, 2017:71).

3.1.2. Yapay Sinir Ağlarının Özellikleri

Her modelin kendine has özellikleri vardır. Yapay sinir ağlarının özellikleri de kullanılan ağın yapısı ve algoritmasına göre değişkenlik göstermekle beraber, genel hatlarıyla aşağıdaki gibi sıralanmaktadır (Öztemel, 2012:31-33):

- Yapay sinir ağlarının temel işlevi makine öğrenmesini gerçekleştirmek yani bilgisayarların öğrenmesini sağlamaktır.
- Geleneksel bilgi işleme yöntemlerinden farklı bir program çalışma prensipleri vardır.

- Geleneksel yöntemlerde herhangi bir elemanın değişmesiyle sistemin çalışması bozulur. Ancak yapay sinir ağlarında bilginin tüm bağlantılara yayılmasını sağlayan paralel yapı sayesinde hücrede hangi değişiklik olursa olsun ağ doğru bilgiyi üretir ve hata tolerans yeteneği vardır.
- Geleneksel yöntemler eksik bilgi ile çalışamazken önemli nitelikte bir eksik bilgi değilse yapay sinir ağının performansında ciddi bir düşüş olmaz. Yapay sinir ağları eğitildikten sonra daha fazla veriye ihtiyaç bile sadece gerekli bilgiler girilerek iyi sonuçlar elde edilebilir.
- Yapay sinir ağları gerçekleşmiş olaylardan örneklerle kendisine gösterilen yeni durumlara kolayca uyum sağlayabilme ve kendi kendine sürekli yeni olayları öğrenebilme yeteneğine sahiptir.
- Yapay sinir ağlarında bilgi bütünüyle ağa yayılmış haldedir ve ağdaki bilgi durumu hücreler arası bağlantı değerleriyle ölçülür. Fakat ağın bellek yapısı dağınık bir durumda olduğundan tek başına bir bağlantı hiçbir anlam ifade etmez. Bu nedenle ağdaki bilgilerin kullanıcılara açıklanması da mümkün olmamaktadır.
- Yapay sinir ağları yalnızca sayısal veriler ile çalışabilmektedir. Sembolik ifadelerle gösterilen verilerin kodlanarak nümerik hale çevrilmesi gerekmektedir.
- Yapay sinir ağlarını güvenle çalıştırabilmek için performanslarını test etmek gerekmektedir. Çünkü daha önce hiç görmediği örneklerle ağ eğitilir ve ağın sonuçları kontrol edilerek performansı test edilir. Ağ performansı yeterli düzeyde değilse ağın yeni bir veri setiyle tekrar eğitilmesi gerekmektedir.
- Yapay sinir ağları örnekler halinde verilen örüntülerle ilişkilendirme ve sınıflandırma yapmaktadır. Böylece belirli özellikteki örnekleri ayırıştırıp kümeleyerek daha sonra gelecek olan örneklerin hangi sınıfa dâhil olacağına karar vermektedir.

3.1.3. Yapay Sinir Ağlarının Avantaj ve Dezavantajları

Yapay sinir ağlarının öngörülemler, tahminleme ve öğrenebilme yeteneği sayesinde istatistiksel yöntemlere göre hem kolayca çözüm üretebilir hem de

geleneksel yöntemlere kıyasla daha avantajlıdır. Bu nedenle finans, tıp, otomotiv, uzay ve savunma sanayi gibi çözümü karmaşık olan birçok alanda uygulanma imkânına sahiptir. Yapay sinir ağları kullanılarak gerçekleştirilen analizlerde elde edilebilecek üstünlüklerden bazıları aşağıdaki gibi sıralanabilir:

Yapay sinir ağları kullanılarak modellenme imkânı olmayan veya oldukça güç olan karmaşık problemleri rahatlıkla çözülebilmektedir. Yapay sinir ağlarının geleneksel yöntemlerden farklı bir bilgi işleme yönteminin olması, eksik ve muğlak veriler üzerinden bile işlem yapabilmesi, hızlıca adaptasyon sağlayabilmesi ve genelleme yapabilmesi, eğitildikten sonra öğrendiği bilgiyi dağıtık hafızasında saklama gibi yeteneklerini sayabilmekteyiz.

Yapay sinir ağları dışarıdan bilgileri alıp kendi sonuçlarını oluştururlar. Diğer bir deyişle içeride ne olduğu bilinmemektedir. Bununla birlikte yapay sinir ağlarının karmaşık problemleri nasıl çözüme kavuşturduğu tam olarak açıklanamaz. Tüm bu belirsizliklerinden dolayı bazıları yapay sinir ağlarını “kara kutu” olarak tanımlamıştır. Yöntem, sonsuz sayıda değişkenden sadece gerektiği kadarını, gerektiği zamanda kullanarak çözüm tahminlerini mükemmelere yakın üretebilmektedir. İnsan beynindeki sinir hücreleri öldüğü takdirde hücrelerde muhafaza edilen bilgilerin de kaybolma riskine karşı, yapay sinir ağlarındaki matematiksel nöronların yok olma ihtimali olmadığından hafızaya alınan bilgiler asla kaybolmaz (Çelik, 2008:26).

Şekil 3.1. Yapay sinir ağlarının kara kutu benzetimi



Kaynak: Öztemel, 2012:19

Yapay sinir ağırları yöntemi, giriş verisi miktarındaki artmaya paralel olarak daha isabetli sonuçlar üretebilmektedir. Yapay sinir ağırları diğer yöntemlerle karşılaştırılarak incelendiğinde özellikle sabit olmayan ve kesikli veriler üzerindeki örneklerde daha tutarlı ve güvenilir sonuçlar yarattığı görülmüştür (Kellova, 2008:35-38).

Yapay sinir ağırları modeli, her biri büyük bir problemin farklı parçasıyla ilişkili çok sayıda işlemciden oluşması ve bağlantı ağırlıklarının ayarlanabilir olması özelliklerinden dolayı, esnek bir yapıya sahiptir. Ağın bir kısmı zarar görse dahi esnek yapısı sayesinde model yine de çalışmaya devam eder. Bu durum yalnızca performansın düşmesine neden olur, ancak modelin işlevini tamamen kaybetmesi söz konusu değildir.

Yapay sinir ağırlarının yukarıda sayılan avantajlarının yanında bazı dezavantajları da vardır. Bunlardan bazılarını aşağıdaki gibi özetlemek mümkündür (Öztemel, 2006:34-35):

Yapay sinir ağırlarının donanıma bağlı çalışması önemli bir sorun olarak görülebilir. Yapay sinir ağırları yöntemiyle etkin bir analiz yapılabilmesi için paralel çalışabilen işlemcilerin varlığına ihtiyaç duyulmaktadır. Günümüzdeki bilgisayarların çoğunun sadece tek bir bilgiyi işlemesinden dolayı paralel işlemleri bilgisayarlarda yapmak vakit kaybına yol açmaktadır. Bilgisayarların hem yazılımının hem de çok çekirdekli işlemcilerinin yeterliliği yapay sinir ağırları yönteminin uygulanacağı çalışmalarda avantaj sağlamaktadır.

Her türlü problemin çözülmesinde yapay sinir ağırları modeli uygun olmayabilir. Probleme uygun ağ yapısının tespit edilmesi genellikle deneme yanılma yoluyla yapılmaktadır ve bu durum çok önemli bir problemdir. Çünkü eğer probleme yönelik bir model oluşturulamaz ise ya problem çözülemez ya da performansı düşük bir çözüm elde edilmiş olur. Diğer bir deyişle yapay sinir ağırları kabul edilebilir çözümler üretir fakat en iyi çözümü garanti altına almaz.

Bazı ağlarda ağın parametre değerlerini belirlemeye yönelik kuralların olmayışı, belirleme işleminde objektifliği de engelleyecek bir problemdir. Problemin çözümünde ağda kullanılacak nöron sayısı, gizli katman sayısı, öğrenme algoritması gibi değişkenlerin seçimi kullanıcının tecrübesine ve her değişken için belirli standartların oluşturulmasına bağlıdır. Bu da değişkenlerin ayrı ayrı

değerlendirilmesini gerektirdiğinden modelin önemli bir dezavantajı olarak görülmektedir.

Yapay sinir ağları kullanıcılarının ağa problemi göstermeleri de çok önemli bir sorundur. Çünkü yapay sinir ağları yalnızca nümerik verilerle çalışır ve değişkenlerin nümerik ifadeye dönüştürülmesi gerekmektedir. Bu konuda kullanıcının tecrübesi de yeterli olmayabilir.

Eğitime başlanan ağın eğitim süresinin ne zaman bitirileceği belirsizdir. Ayrıca bitirmeye karar vermek için geliştirilmiş bir yöntem de yoktur. Ağ eğitiminin kabul edilebilir bir hata düzeyine gelmesi eğitimi bitirmek için yeterli görülmektedir. Bu durum ağın ezberlemesi yani aşırı uyum sorununun çıkmasına yol açmaktadır. Sonuçta ağın ürettiği çözüme olan güven azalmaktadır.

Son dezavantaj ise ağın öğrenmesi süresinin çok zaman almasıdır. Eğitime ayrılan sürenin kısaltılması kritiktir; çünkü yapay sinir ağı ile tahminleme bir deneme yanılma sürecidir ve kullanıcının sınırlı zaman aralığında çok fazla deneme yapması sonuçtan o kadar emin olması anlamına gelmektedir.

3.2. YAPAY SİNİR AĞLARININ GENEL YAPISI

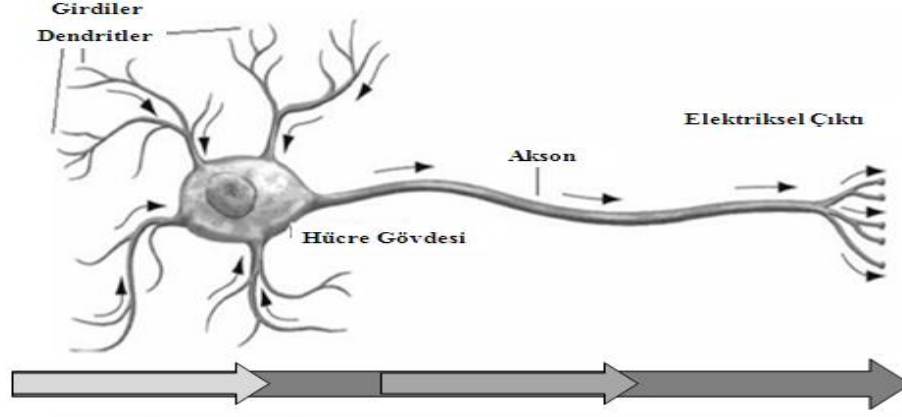
3.2.1. Biyolojik Sinir Hücresi

Yapay sinir ağlarının daha iyi anlaşılması için biyolojik sinir ağlarının yapısının ve çalışma prensiplerinin iyi bilinmesi gerekmektedir. Bilim insanları tarafından beynin kendi kendini nasıl eğittiği hala bilinemediğinden konuyla ilgili birçok teori ortaya atılmıştır.

Bu teorilerin çoğunluğuna göre; insan beyni karmaşık ilişki içinde olan milyarlarca sinir hücresi (nöron) ve bedenin faaliyetlerini kontrol eden bir mekanizmadır. 10 milyardan fazla sinir hücresi ve her bir hücre ortalama 10.000 hücreyle insan beyinde koordineli olarak çalışmaktadır. Nöron olarak adlandırılan bu sinir hücrelerinde sinyaller, çok karmaşık elektro-kimyasal olaylar zinciriyle oluşan ve sayısı saniyede 1000 taneye kadar çıkabilen titreşimler halinde iletilmektedir (Yüksek, 2007:15). Dendrit adı verilen sinir hücresi, ince kılcak yollar aracılığıyla diğer sinir hücrelerinden aldığı işaretleri toplayarak sinir hücresinin

binlerce dala ayrılan aksonlarıyla beyne iletirler. Beyne gönderilen bu veriler sayesinde, öğrenme olayı gerçekleşir (Stergiou ve Siganos, 2010).

Şekil 3.2. Biyolojik Sinir Hücresi



Kaynak: Çelik, 2008:6

Yukarıda Şekil 3.2.'de görülen sinir hücreleri dendrit, hücre gövdesi, akson ve sinapslardan oluşmaktadır. Sinir hücrelerinin birbirlerine dendrit ve aksonlarla bağlandıkları noktalara sinaps denir. Sinaps, bir diğer sinir hücresinin aksonundan aldıkları elektrik akımını elektro-kimyasal yolla dendrite iletir. Dendrit de bu akımı hücre gövdesine gönderir. Hücre gövdesi hücrenin yaşamasını sağlar ve alınan tüm elektrik sinyalleri burada toplanır (Bayır, 2006).

3.2.2. Yapay Sinir Hücresi

Yapay sinir ağları, biyolojik sinir ağlarında olduğu gibi sinir hücrelerine sahiptir. Yapay sinir ağları, biyolojik sinir hücrelerinden esinlenerek modellenmiş ve aralarında benzerlikler bulunmaktadır. Bu benzerlikler Tablo 3.1.'de verilmiştir.

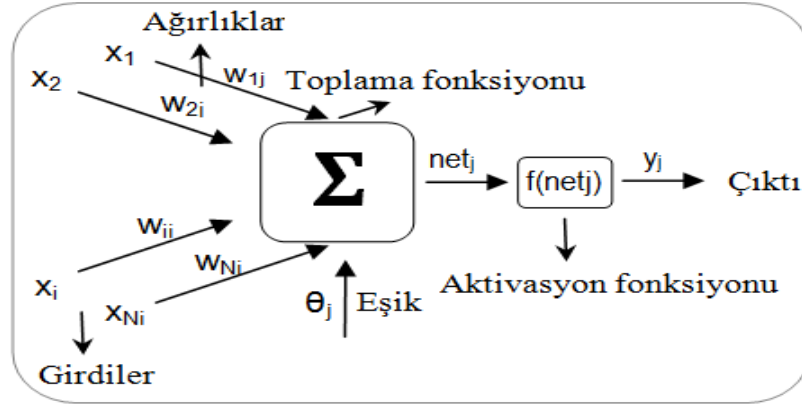
Tablo 3.1. Biyolojik Sinir Ağı ve Yapay Sinir Ağı'nın Karşılaştırılması

Biyolojik Sinir Sistemi	Yapay Sinir Ağları
Nöron	İşlemci Eleman
Dendrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Yapay Nöron Çıkışı
Sinapsler	Ağırlıklar

Kaynak: Fausett, 1994

Yapay sinir ağlarının beş temel elemandan oluşmaktadır. Bunlar; girdiler, ağırlıklar, toplama fonksiyonu, transfer fonksiyonu ve çıkış olmak üzere beş eleman olarak sıralanmaktadır.

Şekil 3.3. Yapay Sinir Hücresinin Yapısı



Kaynak: Özşahin, 2013

1. **Girdiler:** Yapay sinir hücresine dışarıdan veya başka hücrelerden gelen bilgilerden oluşur.
2. **Ağırlıklar:** Yapay sinir hücresine gelen bilgilerin hücreye olan etkisini ve önemini gösteren katsayılardır. Ağırlık değerinin küçük olması o girişin yapay sinire zayıf

bağlandığını veya değerin büyük olması önemli olduğu anlamına gelmemektedir (Elmas, 2003).

3. *Toplama Fonksiyonu:* Biyolojik sinir hücresinde dendritin yaptığı görevi üstlenen bu fonksiyon hücreye ulaşan net girdiyi hesaplar. Bunun için toplama fonksiyonlarının içinden en uygun olanı seçilir. En yaygın olanı ağırlıklı toplam fonksiyondur. Bu fonksiyon aşağıdaki şekilde gösterilir:

$$Net = \sum G_i . A_i (n = 1, \dots, n) \quad (3.1)$$

Fonksiyondaki girdi katmanına gelen bilgileri (A_i), her bir girdinin kendi ağırlık değeri de (G_i) olarak ifade edilerek net girdi bulunur. Toplama fonksiyonuna aşağıdaki fonksiyonlar örnek olarak verilebilir:

$$\text{Çarpım: } Net = \prod G_i . A_i \quad (3.2)$$

$$\text{Maksimum: } Net = \text{Max} (G_i . A_i) \quad (3.3)$$

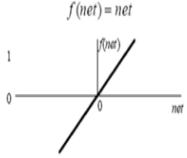

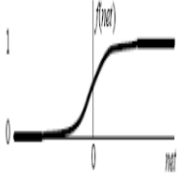
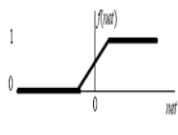
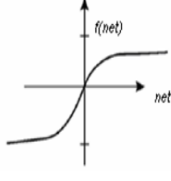
$$\text{Minimum: } Net = \text{Min} (G_i . A_i) \quad (3.4)$$

$$\text{Çoğunluk: } Net = \sum \text{sgn} (G_i . A_i) \quad (3.5)$$

$$\text{Kümülatif Toplam: } Net = Net_{(eski)} + \sum (G_i . A_i) \quad (3.6)$$

4. *Aktivasyon Fonksiyonu:* Transfer fonksiyon olarak da adlandırılmaktadır. Yapay sinir hücresine gelen net girdiyi işlemde geçirerek hücrenin bu girdiye karşılık ortaya koyacağı çıktıyı tespit eder. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonunda da değişik fonksiyonlar kullanılır. Aktivasyon fonksiyonuna aşağıdaki fonksiyonlar örnek olarak verilebilir:

Tablo 3.2. Sık Kullanılan Aktivasyon Fonksiyonları

Lineer fonksiyon	$F(\text{NET}) = \text{NET}$	Gelen girdiler hücrenin çıktısı olarak kabul edilir.	
Step Fonksiyonu	$F(\text{NET}) = 1 \text{ Net} > \text{eşik değeri}$ $F(\text{NET}) = 0 \text{ NET} \leq \text{eşik değeri}$	Gelen net girdi değerinin belirlenen bir eşik değeri altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerlerini alır.	
Sigmoid fonksiyonu	$F(\text{NET}) = \frac{1}{1 + e^{-net}}$	Sigmoid aktivasyon fonksiyonu, sürekli, doğrusal olmayan ve türevi alınabilir olmasından dolayı en çok kullanılan aktivasyon fonksiyonudur. Girdinin her değeri için 0 ile 1 arasında bir değer hesaplar.	
Eşik Değer Fonksiyonu	$F(\text{NET}) = 0 \text{ NET} \leq 0$ $F(\text{NET}) = \text{NET} \text{ } 0 < \text{NET} < 1$ $F(\text{NET}) = 1 \text{ NET} > 1$	Gelen bilgilerin 0 veya 1'den büyük olmasına göre bir değer alır.	
Hiperbolik Tanjant Fonksiyonu	$F(\text{NET}) = \frac{e^{net} - e^{-net}}{e^{net} + e^{-net}}$	Gelen net girdi değerinin tanjant fonksiyonundan geçirilmesi ile hesaplanır.	

Kaynak: Demuth vd., 2008

5. *Hücrenin Çıktısı*: Çıktı değeri, yapay sinir ağları probleminin çözümüdür. Transfer fonksiyonu tarafından belirlenen çıktı değeridir. Bu değer ya başla bir sinir hücresine ya da dış dünyaya gönderilmektedir.


3.3. YAPAY SİNİR AĞLARININ SINIFLANDIRILMASI

Yapay sinir ağları, farklı şekillerle birbirlerine bağlanan sinir hücrelerinden oluşmaktadır. Hücrelerin bağlantı şekillerine, öğrenme algoritmalarına ve transfer fonksiyonlarına göre çeşitli modeller geliştirilmiştir. Bağlantının türüne, nöronların durumlarındaki ayırımına göre adlandırmak mümkündür. Bağlantı yönlerine göre veya ağ işaretlerinin akış yönüne göre ağ mimarisi incelendiğinde ileri beslemeli (feedforward) ve geri beslemeli (feedback) ağlardan söz edilmektedir (Yılmaz, 2017:78).

3.3.1. İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli (feedforward) yapay sinir ağlarında, giriş katmanından çıkış katmanına doğru tek yönde hareket eden nöron yapısından oluşur. Yani bu ağ modelinde nöronlar ileri yönlü bağlantılarını kendilerinden önceki katmanlara geri gönderemezler. Şekil 3.4.' de ileri beslemeli yapay sinir ağının mimarisi gösterilmektedir.

Şekil 3.4. İleri Beslemeli Yapay Sinir Ağı



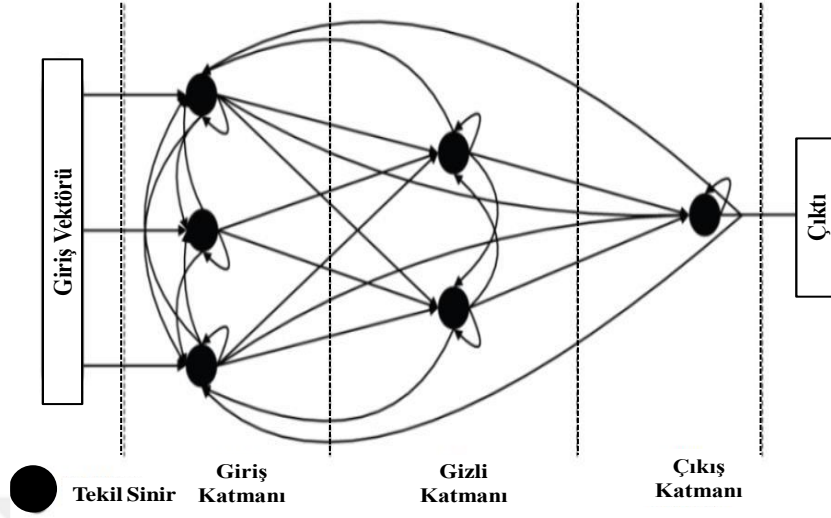
Kaynak: Yetkin, 2014: 16

Yukarıda Şekil 3.4.' de ileri beslemeli yapay sinir ağının veri girişinin yapıldığı girdi katmanı, bilgi işlemin yapıldığı gizli katman ve işlenmiş verinin çıkışının yapıldığı çıkış katmanları gösterilmiştir. Giriş katmanı dışarıdan aldığı bilgiyi hiçbir değişikliğe uğratmadan gizli katmandaki hücreye iletir. Veriler bu katmanda işlem görür ve çıktı katmanına gönderilir. Ara katmanlardaki her bir çıkış değeri bir sonraki katman için giriş değeri olarak adlandırılır (Yetkin, 2014:15).

3.3.2. Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli yapay sinir ağlarında bilgi akışı hem katmandaki hücrelerin kendi arasında hem de katmandaki hücreler arasında olabilmektedir. İşlem elemanları arasında dönüşler ya da geri besleme bağlantıları sayesinde doğrudan girdi katmanına gönderilen herhangi bir hücrenin çıktısı tekrar girdi olarak kullanılabilir (Zhang, 2003). Veri akışının yalnızca ileriye doğru değil, geriye doğru da olduğu bir ağ yapısıdır. Şekil 3.5.' de geri beslemeli yapay sinir ağının mimarisi gösterilmektedir.

Şekil 3.5. Geri Beslemeli Yapay Sinir Ağı



Kaynak: Krenker, 2002

İleri beslemeli yapay sinir ağları statik bir yapıya sahipken geri beslemeli yapay sinir ağları dinamik bir yapıya sahiptir. İleri beslemeli yapay sinir ağları girdilere karşı tek bir çıktı grubu üretmektedir ancak geri beslemeli yapay sinir ağı her bir girdi işleme koyulduğunda çıktıları tekrar hesaplamaktadır. Ayrıca ileri beslemeli yapay sinir ağının belli bir belleği yoktur ve her girdiye kendinden önceki ağdan bağımsız bir cevap verirler. Diğer taraftan geri beslemeli yapay sinir ağları her bir girdiyi tekrar düzenlediğinden ağ yeni bir çıktıya dönüşür (Weron, 2014:1030).

3.4. YAPAY SİNİR AĞLARININ ÖĞRENME ALGORİTMASI

Yapay sinir ağları çevreden aldıkları bilgi birikimini ağdaki ağırlıklar ile belirlemektedir. Yapay sinir ağı birikimini arttırıp, en iyi performansa ulaşmak için algoritmadaki ağırlıklar üzerinden değişiklik yapar. Yapay sinir ağlarında istenilen sonucu elde edebilmek amacıyla ağın ağırlıklarının probleme göre şekillenmesi ile öğrenme işlemi başlamaktadır. Öğrenme örneklerden öğrenme yoluyla gerçekleşmektedir. Bir problemde geçmişteki örnekleri kullanarak, problemin girdi ve çıktı arasındaki bağlantısından faydalanarak gelecekte oluşacak yeni çıktıyı tespit etmek örnekler öğrenmenin temelidir.

Günümüze kadar farklı bağlantılarla iletişim kurabilen yapay sinir ağı modelleri tasarlanmıştır, fakat her bir ağ modelinin öğrenme süreci benzer değildir. Yapay sinir ağları modelin öğrenme sürecine ve matematiksel denklemlerle tanımlanmış öğrenme kurallarına göre işlem yapmaktadır. Öğrenme şekilleri de tıpkı insanda olduğu gibi farklılık gösterebilmektedir (Kartalopoulos, 1996:43).

Yapay sinir ağları örneklerle öğrenmeyi gerçekleştirene kadar çevrimiçi ve çevrimdışı öğrenme kurallarını kullanır. Ayrıca öğrenme algoritmalarının kullanımına göre de danışmanlı, danışmansız ve takviyeli öğrenme yöntemleri vardır.

3.4.1. Öğrenme Kuralları

3.4.1.1. Çevrimiçi Öğrenme Kuralı

Çevrimiçi öğrenme kuralları gerçek olarak çalışmaktadırlar. Bu kurala göre çalışan sistemler gerçek zamanda çalışırken bir taraftan fonksiyonlarını yerine getirirler diğer taraftan öğrenme işlemine devam ederler. Bu gruba Kohonen öğrenme kuralı örnek olarak verilebilir (Öztemel, 2003).

- *Kohonen Öğrenme Kuralı:* Teuvo Kohonen tarafından 1982 yılında ortaya atılan bu kuralda sinir hücreleri ağırlıklarını, elverişli durum ve ölçülerini değiştirmek için aralarında yarışır. Bu nedenle Yarışmacı Öğrenme Kuralı (Competitive) da denmektedir. En uygun çıktıyı üreten sinir hücresi yarışmayı kazanan hücre olur. Hem kendisine komşu hücrelere nazaran daha kuvvetli hale gelir hem de bağlantı ağırlıklarını güncelleştirmektedir. Yakınındaki hücre sayısı eğitim süresince değişiklik göstermektedir. Bağlantı ağırlıklarını değiştirmek en büyük çıktıyı üretebilme şansını arttırdığından yakındaki hücrelerin de bağlantı ağırlıklarının değiştirilmesine izin vererek onların da şansını arttırmış olur (Öztemel,2003; Aydın,2012).

3.4.1.2. Çevrimdışı Öğrenme Kuralı

Çevrimdışı öğrenme kuralının temel felsefesinde test verisiyle eğitime vardır. Bu kurala dayanan sistemler eğitildikten sonra gerçek hayata alındığında artık öğrenme mümkün olmamaktadır. Sistemin öğrenmesi gereken yeni bilgiler olduğunda sistem öğrenimden çıkarılır ve çevrimdışı olarak yeniden eğitilir. Eğitim tamamlanınca sistem tekrar kullanıma hazır hale gelmektedir. Yapay sinir ağlarında yaygın olarak Hebb, Hopfield ve Delta çevrimdışı öğrenme kuralları kullanılır.

- *Hebb Öğrenme Kuralı:* Hebb Kuralı 1949 yılında Donald Hebb tarafından geliştirilmiş ve bilinen en eski öğrenme kuralıdır. Bu kural Hebb'in "The Organization of Behaviour" adlı kitabında; "Eğer sinyal alan ile gönderen nöronlar arasındaki sinaptik ağırlıkların ikisi de matematiksel olarak aynı işarete sahip ise, bu iki nöron arasındaki bağ kuvvetlendirilmelidir. Aksi halde bağ kuvveti azaltılmalıdır." şeklinde tanımlanmıştır (Hebb, 1949). Başka bir deyişle, öğrenme sinyali hücre çıkışına eşittir. Yani bir hücre aktif ise bağlı olduğu hücreyi de aktif, pasif ise hücreyi de pasif yapma eğilimindedir.
- *Hopfield Öğrenme Kuralı:* Hebb kuralına benzer bir kuraldır ancak bir ayrımı vardır. Bu kural Hebb kuralından farklı olarak ağ bağlantı ağırlıklarının ne derece güçlendirileceğini ne derece zayıflatılacağını da belirtir. Eğer beklenen girdi ve çıktılar aktif veya pasifse bağlantı ağırlığı öğrenme oranı kadar artar veya azalır. Bağlantı ağırlıklarının kuvveti veya zayıflığı öğrenme katsayısı sayesinde gerçekleşir. Bu katsayı kullanıcı tarafından belirlenen genellikle 0 ile 1 arasında sabit pozitif bir değerdir (Tebekis, 1995).
- *Delta Öğrenme Kuralı:* Widrow ve Hoff tarafından geliştirilen bu kural Hebb kuralının gelişmiş şeklidir ve günümüzde en yaygın kullanılan öğrenme kullarından birisi olmuştur. Bu kurala göre yapay sinir hücresinin gerçek çıktısı ile tahminlenen çıktısı arasındaki farkı azaltmak için ağ elemanlarının bağlantı ağırlık değerlerinin sürekli yeniden hesaplanmasıdır. Amaç gerçek

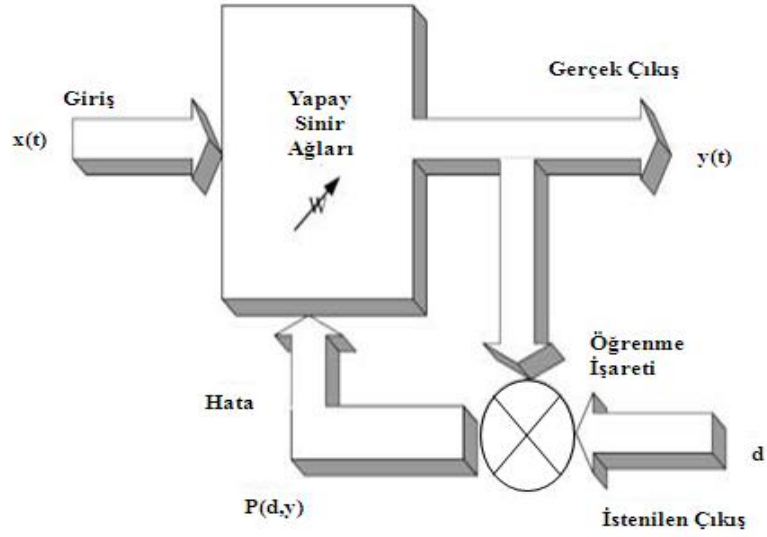
çıkıtı ile tahminlenen çıkıtı arasındaki hata karelerinin ortalamasını minimize etmektir (Karahana, 2011).

3.4.2. Öğrenme Yöntemleri

3.4.2.1. Danışmanlı (Öğretmenli- Eğiticili- Denetimli- Gözetimli) Öğrenme

Yapay sinir ağlarında çoğunlukla tercih edilen öğrenme yöntemlerinden olan danışmanlı öğrenmede; ağın üretilen çıkış değeri ile beklenen çıkış değeri karşılaştırılır. İlk olarak rastgele ağırlıklar seçilir, daha sonra tekrarlanan değerler göz önünde bulundurularak ağırlıklar yeniden hesaplanır. Böylece belirli örnek gözlem girdileri için üretilen ve beklenen çıkış değerleri birbirlerine yaklaşır ve işlem elemanlarındaki hatanın en aza indirgenmesi amaçlanır. Bu metotta ağ kullanışlı hale getirmeden önce eğitmek gerekir. Giriş ve çıkış bilgilerinin ağa sunulmasıyla eğitim oluşmaktadır. Ağ, giriş verilerini ve tekrarlanarak ayarlanan ağırlıkları kullanarak, beklenen çıkış değerleri ile üretilen çıkış değerleri üstündeki işlemlerini kullanıcının belirlediği performans değerine ulaşana kadar gerçekleştirir. Ağın eğitimi için faydalanılacak eğitim setinin özü ağ performansı ve öğrenmenin gerçekleşme süreci açısından önemlidir (Sevinçtekin, 2014:21). Şekil 3.6' da danışmanlı eğitim yapısı görülmektedir.

Şekil 3.6. Danışmanlı Öğrenme




Kaynak: Adıyaman, 2007

3.4.2.2. Danışmansız (Öğretmensiz- Eğitici-siz- Denetimsiz- Gözetimsiz) Öğrenme:

Danışmanlı öğrenmede girdiler ve çıktılar biliniyorken aralarındaki bağlantıyı ortaya koymak amaçlanmıştır. Danışmansız öğrenmede ise yalnızca girdiler bilinir, çıktılar bilinmez. Çünkü girdiler aynı zamanda çıktı görevi görmektedir. Parametreler arasındaki ilişkileri sistemin kendi kendine öğrenmesi beklenir. Danışmanlı öğrenmeye göre çok daha hızlıdır ve matematiksel algoritmaları daha basittir (Deveci, 2012). Bu yöntemde ağı eğitilmesi; girdiler ve çıktılar arasındaki düzen ve ilişkileri araştırarak, en uygununun bulunmasıdır. Yani, çıktıların istenilen değerleri ağa tanıtılmıyorsa danışmansız öğrenme söz konusudur. Danışmansız öğrenmenin temelinde çevresel müdahaleler olmadan girdilerin ağ tarafından analiz edilmesi ve analiz sonuçlarına göre bağlantıların oluşturulmasıdır.

Şekil 3.7. Danışmansız Öğrenme

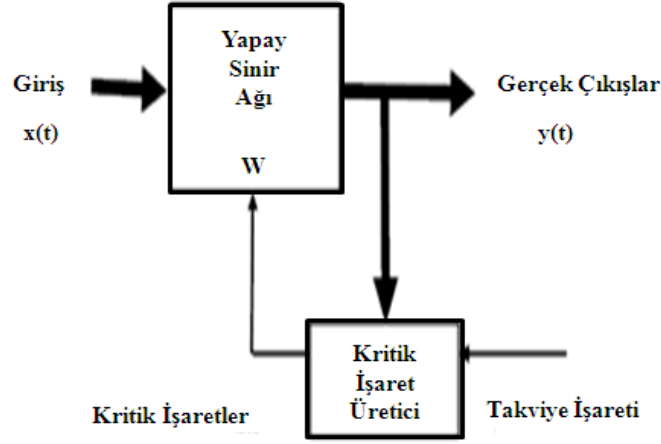


Kaynak: Adıyaman, 2007

3.4.2.3. Takviyeli (Destekleyici- Karma) Öğrenme

Bu öğrenme yöntemi danışmanlı öğrenme ile danışmansız öğrenmenin karması şeklindedir. Ağa bir danışman yardımcı olur fakat danışman, her girdi seti için üretilmesi gereken çıktı setini sisteme göstermek yerine, sistemin kendisine gösterilen girdilere karşılık çıktı üretmesini bekler ve üretilen çıktının doğru veya yanlış olduğunu gösteren bir sinyal üretir. Danışmandan gelen bu sinyali dikkate alan sistem, öğrenme sürecini devam ettirir (Öztemel, 2003).

Şekil 3.8. Takviyeli Öğrenme



Kaynak: Adıyaman, 2007

3.5. YAPAY SİNİR AĞLARININ EĞİTİLMESİ

Ağın eğitilmesi, yapay sinir ağlarındaki işlemci elemanlarının bağlantı ağırlık değerlerinin belirlenmesi işlemidir. Başlangıçta bu değerler gelişigüzel seçilirken, daha sonra ağa sunulan örneklerle ağırlık değeri değiştirilir. Ağa sunulan örneklerin doğru çıkışları üretecek ağırlık değerlerini bulmak amaçlanmıştır. Ağın doğru ağırlık değerlerine ulaşması, örneklerin temsil ettiği olay hakkında genellemeler yapabilme yeteneğine kavuşması demektir. Yapay sinir ağlarının eğitilmesinde iki aşama vardır. İlk aşama, ağa sunulan örnek için ağın üreteceği çıkış belirlenir. Çıkış değerinin doğruluk derecesine göre ikinci aşamada, ağın bağlantılarının sahip olduğu ağırlıklar değiştirilir (Öztemel, 2003:56).

Yapay sinir ağlarının eğitimi ve testi için toplanan veriler, sistemin düzgün çalışma uzayını kapsamalıdır. Örnek kayıtlarının çalışma uzayının sınırlarını belirlediği ve yapay sinir ağlarının yalnızca eğitildiği çalışma aralığı için güvenilir sonuç verebildiği unutulmamalıdır. Genel özelliklerin net olarak belirlenmesi için örnek kümesinin geniş olması tercih edilir. Bu kümenin bir kısmı eğitim aşamasında kullanılırken, bir kısmı test aşamasında ağın genelleştirme yeteneğinin onayı amacıyla kullanılır. Testin başarısızlığı durumunda, test amacıyla kullanılan kayıtların bir kısmı eğitim verilerine aktarılarak, eğitim ve test işlemleri kabul

edilebilir bir performans düzeyine ulařıncaya kadar bu işlem tekrarlanır (Efendigil, 2008:44-46).

Yapay sinir ađlarının eđitiminde genel hatlarıyla ařađdaki adımlar izlenmektedir (Rajpal ve diđerleri, 2006:812; Gungör, 2007:41):

- Sistemin ihtiyaç duyduđu operasyonel parametreleri kapsayan girdi parametreleri tanımlanır.
- Sistem performansını ölçebilecek çıktı parametreleri güvenilirlik, kullanılabilirlik ve dayanıklılık gibi etkenler tanımlanmalıdır.
- Sistem çıktısının basit bir ölçümü içinde bu parametreler birleřtirilmelidir.
- Eđitim ve sađlama veri grubu çok sayıda girdi ve çıktı çiftlerinden hazırlanmalıdır.
- Gizli hücre ve gizli katman sayısının dođru olabilmesi deneme yanılma yoluna bađlı olduđu için öncelikle bir gizli katman ve birkaç gizli hücreyle başlanmalı, ardından bu sayı optimum sonucu verene kadar arttırılmalıdır.
- Farklı řartlarda davranıřları belirlemek için eđitilen ve sađlaması yapılan yapay sinir ađları modelinin simülasyonu yapılmalıdır.
- Optimal sonuca ulařabilmek için yukarıdaki adımlar yerine getirildiđinde ulařılan sonuçlar beklenildiđi gibi deđilse, yukarıdaki adımlar tekrar edilerek en iyi sonuç alınıncaya kadar tekrarlanmalıdır.

Yapay sinir ađlarının eđitilmesi esnasında bazen ađın takıldıđı hata seviyesinin istenilenin üzerinde olması durumunda, ađın olayı öğrenme sürecinde belli deđiřiklikler yaparak ađın tekrar eđitilmesi gerekebilir. Bu tarz durumlarda süreçte yapılabilecek deđiřiklikler řunlardır:


- Bařka eđitim bařlangıç deđerleri kullanılabilir,
- İşlemci eleman sayısını veya ara katman sayısını deđiřtirmek gibi ađ topolojisinde deđiřiklikler yapılabilir,
- Öğrenme ve momentum katsayılarının deđiřtirilmesi gibi parametre deđiřiklikleri yapılabilir,

- Problemin sunum şekli ve örnekleri değiştirilerek yeni örnek seti oluşturulabilir,
- Öğrenme setindeki örneklerin sayısı artırılabilir veya azaltılabilir.

Sinir ağlarının eğitilmesi esnasında karşılaşılan önemli sorunlardan birisi de, öğrenme süresinin çok uzun olmasıdır. Ağırlık değerlerinin başlangıçta büyük olması, ağın lokal sonuçlara düşmesi ve bir lokal sonuçtan diğerine sıçramasına neden olmaktadır. Eğer işlemci elemanların ağırlıkları küçük aralıklarda seçilirse o zaman da ağırlıkların doğru değerleri bulması uzun zamanlar almaktadır. Bazı problemlerin çözümü sadece 200 iterasyon sürerken bazıları 5-10 milyon iterasyon gerektirmektedir. Başlama koşullarının tamamen deneme yanılma yolu ile belirlenmesi ve en uygun başlama koşullarının böylelikle bulunması gerekmektedir (Öztemel, 2006:84).

Yapay sinir ağının eğitiminin tamamlanması ve hata düzeyinin istenen düzeye indirilmesi için işlemci elemanın ağırlık değerinde yapılacak değişim sayısı (iterasyon) ilişkisi Şekil 3.9.' da gösterilmiştir.

Şekil 3.9. Yapay Sinir Ağlarının Öğrenme Eğrisi



Kaynak: Öztemel, 2006:84

Yukarıdaki Şekil 3.9.' da görüldüğü gibi, iterasyon sayısı arttıkça ağın öğrenmesi de artmakta ve bu öğrenme zamanıyla birlikte hata oranı da düşmektedir. Ancak, şekilde görüldüğü gibi, iterasyon sayısı belli bir düzeye ulaştıktan sonra hata oranında artık daha fazla azalma olmadığı görülmektedir. Bu durum, ağı eğitiminin tamamlandığını, öğrenmenin artık durduğunu ve bundan daha iyi sonuca ulaşamayacağını göstermektedir.



4. YAPAY SİNİR AĞLARI MODELİ İLE ELEKTRİK TÜKETİM TAHMİNİ: İZMİR İLİ ÖRNEĞİ

Bu bölümde Türkiye'nin ekonomi ve enerji verileri kullanılarak bir tahmin çalışması yapılmıştır. Farklı parametreler ile yapay sinir ağları yöntemi uygulanarak Türkiye'nin gelecek yıllardaki net elektrik tüketim tahmini gerçekleştirilmiştir.

4.1. VERİ SETİNİN TANIMLANMASI

Bu çalışmada kullanılan veriler, literatürde sıkça faydalanılan değişkenlerdir. Bunlardan GSMH, ithalat ve ihracat parametrelerine birçok çalışmada yer verilmiştir. Yapay sinir ağları ile kurulacak modelin elektrik talebini güvenilir bir şekilde yansıtması adına, modele eklenebilecek bağımsız değişkenler araştırılmış ve yeterli sayıya ulaşan geçmiş değerleri kapsayan tüketici fiyat endeksi, şehir nüfusu, geniş kapsamlı para miktarı, sanayinin GSMH içindeki yeri, elektrik kurulu gücü ve motorlu kara taşıt sayısı değişkenleri modele eklenmiştir. Çalışmada Türkiye'nin elektrik tüketim tahmininde kullanılan bağımlı ve bağımsız değişkenler ile bu değişkenlerin açıklamalarına ilişkin bilgiler Tablo 4.1.' de yer almaktadır.


Tablo 4.1. Çalışmada Kullanılan Değişkenler Hakkında Bilgiler

Değişken Sembolü	Değişken Adı	Kaynağı	Değişken Kullanılma Sebebi
X1	Kişi Başına Düşen GSMH	Dünya Bankası (URL-1, 2018)	GSMH bir büyüme göstergesi olduğundan paralel olarak elektrik enerjisi tüketimi de etkilemektedir.
X2	Tüketici Fiyat Endeksi (2010=100)	Dünya Bankası (URL-2, 2018)	Tüketici fiyat endeksi elektrik enerjisi tüketimini etkilemektedir. Çünkü elektrik fiyatı artıkça elektrik tüketimi azalmaktadır.
X3	İthalatın GSMH İçindeki Payı	Dünya Bankası (URL-3, 2018)	İthalat verileri ülkenin ekonomisini dolayısıyla elektrik tüketimini de etkilemektedir.
X4	Sanayinin GSMH İçindeki Payı	Dünya Bankası (URL-4, 2018)	Sanayileşme bir büyüme göstergesi olduğundan paralel olarak elektrik enerjisi tüketimi de etkilemektedir.
X5	Geniş Kapsamlı Para Miktarı	Dünya Bankası (URL-5, 2018)	Finansal gelişmeler; sanayi ve ticareti, ekonomik büyümeyi kolaylaştıracağından enerji tüketiminde artışa neden olmaktadır. Bu nedenle elektrik enerjisini etkileyen bir faktör olarak ele alınmıştır.
X6	Şehir Nüfusu	Dünya Bankası (URL-6, 2018)	Şehir nüfusu, sanayide de zenginleşmeyi sağlayıp daha fazla enerjiye neden olacağından değişken olarak alınmıştır.
X7	İhracatın GSMH İçindeki Payı	Dünya Bankası (URL-7, 2018)	Ülkenin ihracat miktarı paralel olarak üretime bağlıdır. Dolayısıyla elektrik tüketiminin bir göstergesidir.
X8	Elektrik Kurulu Gücü	TEİAŞ (URL-8, 2018)	Elektrikte sürekliliğin sağlanması kurulu güç sayesinde. Hızla artan kurulu güç kapasitesinin elektrik tüketimini etkilemektedir.
X9	Motorlu Kara Taşıt Sayısı	TÜİK (URL-9, 2018)	Motorlu kara taşıt sayısı, ekonomik kalkınma politikalarına ışık tuttuğundan elektrik tüketimindeki etkisi görülmek istenmiştir.
Y	Elektrik Tüketimi	TEİAŞ (URL-10, 2018)	Bağımlı değişken

Veri sınırlılığı nedeniyle ilgili analiz dönemini genişletmek mümkün olamadığından 1960'dan 2016 yılına kadar dokuz girdi ve bir çıktı değişkeninden her bir değişkene ait (57 yıllık) resmi kaynaklardan sağlanan veriler bağımsız ve bağımlı değişkenler olarak tespit edilerek eğitime tabii tutulmuştur. 2017 yılı verisi ise test amaçlı kullanılmış ve ardından MATLAB.2012a yazılımı ile elektrik enerjisi tüketim tahmini için modeller kurulmuştur.

Elektrik tüketimi ile gayri safi milli hâsıla ilişkisi en temel ilişkilerden biri olarak ele alınmaktadır. Enerjinin bir üretim faktörü olarak görülmesi ve milli hâsıla üzerindeki etkisi özellikle Türkiye gibi enerji tüketiminde dışa bağımlı ülkelerde incelenmesi enerji politikalarının belirlenmesinde önem arz etmektedir. Bu nedenle *gayri safi milli hâsıla (GSMH) değişkeni* modele eklenmiştir.

Şekil 4.1. Kişi Başına Düşen GSMH (Bin TL)




Kaynak: URL-1, 2018

Şekil 4.1.' de 1960-2016 yılları arasında kişi başına düşen GSMH gösterilmektedir. Milli hâsıla bu yıllar arasında istikrarlı bir şekilde artmaktadır. Türkiye'de, 1960 ve 1980 yılları arasında ithalat ikame politikası uygulanırken 2003 yılından itibaren ihracata yönelik sanayileşmeye geçilmesiyle birlikte sanayide bir dönüşüm yaşandı ve bu yüzden 2001 yılındaki ekonomik krizde bir azalma eğilimi göze çarpmaktadır.

Geleneksel talep teorisi temelde fiyat tarafından belirlenir. Fiyat ile enerji tüketimi arasında ilişkisinin negatif olması beklenmektedir. Çünkü daha yüksek bir fiyat her zaman tüketicilerin tüketim seviyelerinin düşmesine neden olur. Bu nedenle *tüketici fiyat endeksi (TÜFE) değişkeni* modele eklenmiştir.

Şekil 4.2. Tüketici Fiyat Endeksi (2010 =100)




Kaynak: URL-2, 2018

Şekil 4.2.' de 2010 yılı baz alınarak oluşturulmuş tüketici fiyat endeksi 1960-2016 yılları arasında gösterilmektedir. Fiyat endeksi 2000 yılından sonra artmış ve keskin bir şekilde artmaya devam etmiştir. Türkiye, özellikle 1970'lerde, 1980'lerde ve 1990'larda yüksek enflasyon yaşamıştır. Çok yüksek enflasyon oranları fiyatları temsil etme kabiliyetini azaltmaktadır.

İhracata yönelik mal üretmek için enerjiye ihtiyaç duyulur ve ithal edilen malları bir ekonominin diğer bölgelerine taşımak için enerji gerekir. Bu ticari faaliyetlerde bir enerji tüketimini artırır. Bununla birlikte işletmeler ithalat için kullanılacak enerji tasarruflu ekipmana sahip olduğunda, enerji tüketimini azaltabilir. Bu bağlamda, ticaretin Türkiye ekonomisi için elektrik tüketiminin önemli belirleyicileri olduğu düşünülmektedir. Elektriğin sanayi için değişken bir girdi olduğu düşünülürse, sanayi sektörünün genişlemesiyle elektrik tüketiminde bir artışa neden olması beklenmektedir. (Kwakwa, 2017; s:9) Ticarete ithalat ve ihracat çok fazla şey

ifade ettiğinden Türkiye elektrik tüketimi için de önemli olduğu düşünölmüş ve modele eklenmiştir.


Şekil 4.3. İthalatın GSMH İçindeki Payı (%)



Kaynak: URL-3, 2018

Şekil 4.3.' de mal ve hizmetlerin ithalatı 1960-2016 yılları için GSMH' nın yüzdesi olarak gösterilmektedir. 1980'den sonra ithalat ve ihracat listelerinde temel bir değışiklik görölmektedir. 1980'deki politika değışikliğı, ithalat payında istikrarlı bir artış olarak ortaya çıkmıştır.

Şekil 4.4. İhracatın GSMH İçindeki Payı (%)




Kaynak: URL-7, 2018

Şekil 4.4.' de mal ve hizmet ihracatı, 1960-2016 yılları arasındaki GSMH' nin yüzdesi olarak gösterilmektedir. 1980 yılında Türkiye'nin ihracata yönelik bir sanayileşmeyi benimsemesi nedeniyle 1979 yılında keskin bir artış söz konusudur.

Hızla gelişen kentleşme ve nüfus artışı gibi etkenler elektrik enerjisi tüketimini artırmıştır. Kentler yüksek miktarda enerji tüketmeye devam ederken bu ilişkiyi incelemek adına modele *şehir nüfusu değişkeni* de eklenmiştir.

Şekil 4.5. Şehir Nüfusu (Milyon)




Kaynak: URL-6, 2018

Şekil 4.5.' de kentsel nüfus 1960-2016 yılları arasında gösterilmektedir. Kentsel nüfus yıllar içinde istikrarlı bir artış göstermiştir. 1960'lı yıllardan beri Türkiye'nin kentleşmesi hızla devam ediyor. Bugün, şehir nüfusu doyma noktasına ulaşmak üzeredir.

Çalışmada finansal gelişmeyi temsil etmek için *geniş kapsamlı para miktarı değişkeni* kullanılmıştır. Geniş kapsamlı para miktarı; bankaların dışındaki tasarruf mevduatları, dövizler, çekler ve tüm menkul kıymetlerin para birimlerinin toplamıdır. Finansal gelişmelerin ve elektrik tüketiminin pozitif ilişkili olması beklenmektedir ve bu nedenle modele eklenmiştir.

Şekil 4.6. Geniş Kapsamlı Para Miktarı (Trilyon)




Kaynak: URL-5, 2018

Şekil 4.6.'da para miktarının 1960-2016 yılları için GSMH'nin yüzdesi olarak gösterilmektedir. Yıllar içinde para arzının GSMH'nin yüzdesinde artış eğilimi olduğu görülmektedir.

Sanayileşmenin enerji üretimine dayanması nedeniyle; *sanayinin GSMH içindeki payı değişkeni* Türkiye'deki elektrik tüketim modeline dâhil edilmiştir. Elektrik, endüstri için değişken bir girdi ise, bir ekonominin sanayi sektörünün genişlemesinde elektrik tüketiminde bir artışa neden olması beklenmektedir. Ancak, sanayi sektörü enerji açısından daha verimli hale geldiğinde, elektrik tüketiminde azalmaya neden olacaktır. Türk sanayi sektörünün hızlı büyümesi, enerji sektöründeki üretim artışının önemine işaret etmiştir.

Şekil 4.7. Sanayinin GSMH İçindeki Payı (%)




Kaynak: URL-4, 2018

Şekil 4.7.' de endüstri ve katma değerın 1960-2016 yılları için GSMH' nın yüzdesi olarak gösterilmektedir. GSMH içindeki sanayi payı sanayileşme olarak bilinmektedir. Sanayi sektörü ekonomik büyümenin ana belirleyicisi olarak kabul edilmektedir. Türkiye'de 1960 ve 2016 yılları arasında sanayi sektörü dalgalı bir seyir izlemiştir. Sanayi sektörünün GSMH payı 1980-2000 yılları arasında artarken, 2002'den sonra hizmetler sektöründeki gelişmelere bağlı olarak azalmıştır.

Kişi başına düşen gelir arttıkça enerji tüketiminin artması beklenmektedir. Endüstriyel faaliyetler arttıkça daha fazla enerjiye ihtiyaç duyulmaktadır. Ancak aynı zamanda gelişen endüstriler enerjide verimliliği de sağlayacağından elektrik tüketimi azalmaktadır. Sanayinin olduğu yerde yoğunlaşan nüfus kentleşmeyi de beraberinde getirirken elektrik tüketiminin de artacağı varsayılmaktadır. Tüm bunların yanı sıra fiyat ile elektrik tüketimi arasında negatif bir ilişki olduğu öngörülürken, elektrik kurulu gücünün ve motorlu kara taşıt sayısının elektrik tüketim modeline eklenmiştir.

Elektrik enerjisinin büyük bir bölümünün ithal ediliyor olması dikkate alındığında elektrik enerjisine olan talebin ciddi bir unsur olduğu, öyle ki bir saniyelik elektrik kesintisi bile ülkemizde büyük ölçekli sanayi şirketlerine ortalama 171.000 ABD Doları ciro kaybettirir (Çeliker, 2011). Bu nedenle modele *elektrik kurulu gücü* değişkeni eklenmiştir.

Şekil 4.8. Elektrik Kurulu Gücü (MW)




Kaynak: URL-8, 2018

Şekil 4.8. incelendiğinde Türkiye elektrik enerjisi kurulu gücünün 1998 yılında 23.354 MW, 2008 yılında 41.817,2 MW iken 2018 yılında 88.550 MW seviyesine yükseldiği görülmektedir. On yıllık dilimlerde incelenen elektrik kurulu gücünün hızla artmaya devam ettiği göze çarpmaktadır.

Motorlu taşıta sahip olanlardan aracın değerine karşılık gelen bir servet vergisi alınması, motorlu kara taşıtı sayısının bir ödeme gücü göstergesi olarak kabul edildiğini açıklamaktadır. Dolayısıyla bu sayı birçok ülkede ulaşım ve enerji politikalarının belirlenmesinde önem arz etmektedir. Enerji tasarrufu sağlama ve belli yakıt türlerini tüketmeye özendirme yönüyle taşıtlar pek çok araştırmada kullanılmıştır. Bu nedenle modele *motorlu kara taşıt sayısı* değişkeni eklenmiştir.

Şekil 4.9. Motorlu Kara Taşıt Sayısı




Kaynak: URL-9, 2018

Şekil 4.9.'da 1960-2016 yılları arasında motorlu kara taşıt sayısı gösterilmektedir. Yıllar içinde motorlu kara taşıt sayısının artış eğiliminde olmasının nedeni otomotiv sektöründe ihracatın ithalata bağımlılığından kaynaklanmaktadır.

Açıklanan değişkenlerle elektrik tüketimi bağımlı, diğerleri bağımsız değişkenlerdir. Bağımsız değişkenlerin, bağımlı değişken olan elektrik tüketimleri yapay sinir ağlarıyla analiz edilmiştir.

Şekil 4.10. Elektrik Tüketimi (Kişi Başına kWh)



Kaynak: URL-10, 2018

Şekil 4.10.' da elektrik tüketimi 1960-2016 yılları arasında kWh olarak gösterilmektedir. Elektrik tüketiminin yıllar içinde kademeli olarak arttığı görülmektedir. 1960 yılında en düşük nokta 87,00 kWh, 2016'da en yüksek nokta 2896,78 kWh' ye ulaşmıştır.

4.2. YAPAY SİNİR AĞLARI MODELİNİN MİMARİSİ

Bu çalışmada YSA simülatörü olarak MATLAB (R2012a) - Neural Network Tool Box kullanılmıştır. Uygulamada oluşturulan YSA aşağıdaki özelliklere göre hazırlanmıştır:


- Levenberg-Marquardt (LM) algoritması ile eğitimin daha hızlı tamamlanmasını sağlamak ve eğitim daha fazla bellek gerektirmektedir. Eğitim sürecinde genelleştirmenin iyileşmediği durumlarda eğitim algoritması “*trainlm*” fonksiyonu kullanılırsa eğitim otomatik olarak sonlandırılmaktadır.

- b) Çıktı değerleri ile hedeflenen değerler arasındaki korelasyonu ölçen regresyon değerlerinin 1'e yakın olması aralarında yakın ilişki olduğunu göstermektedir.
- c) Modeldeki verilerin %70' i ağız eğitimi, %15 Doğrulama ve geriye kalan %15'i test için kullanılmıştır.
- d) Model tek gizli katmanda ve on gizli katman nöron sayısı olacak şekilde dizayn edilmiştir. Ek olarak girdi katmanında Sigmoid aktivasyon fonksiyonu ve çıktı katmanında Doğrusal (Linear) Purelin transfer fonksiyonu belirlenmiştir.
- e) Çalışmada Mean Absolute Percentage Error (MAPE) ve R^2 performans ölçütü kullanılmıştır.
- f) Yazılımda verilerin işlenmesinde max-min normalizasyon yöntemi kullanılmıştır. Bu yöntemde en küçük değeri 0 ve en büyük değeri 1 olacak şekilde normalleştirmek ve diğer değerleri de 0-1 aralığında ifade etmek amaçlanarak veri grubunun içindeki en büyük ve en küçük değerler alınır, diğer değerler bu değerlere göre normalleştirilir. x_1, x_2, \dots, x_n , n adet veriyi gösterir. X_{max} (max = 1,2,...,n) veri setindeki en büyük değeri, X_{min} (min = 1,2,...,n) veri setindeki en küçük değeri, $X_{normal\ i}$; X_i (i = 1, 2, ..., n) 'nin normalize edilmiş hali ise aşağıda matematiksel olarak ifade edilmiştir (Arı ve Berberler, 2017:64):

$$X_{normal\ i} = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (4.1.)$$

Geliştirilen yapay sinir ağızları modeli aşağıda Şekil 4.11. 'de gösterilmiştir.

Şekil 4.11. Elektrik Tüketim Tahmini İçin Kurulan Modelin Mimarisi



4.3. YAPAY SİNİR AĞLARI MODELİNİN EĞİTİLMESİ

Girdi Değişkenleri:

x_t : Eğitim girdisi

x_v : Doğrulama girdisi

x_{tn} : Normalize edilmiş eğitim girdisi

x_{vn} : Normalize edilmiş doğrulama girdisi

Çıktı Değişkenleri:

y_t : Eğitim çıktısı

y_v : Doğrulama çıktısı

y_{tn} : Normalize edilmiş eğitim çıktısı

y_{vn} : Normalize edilmiş doğrulama çıktısı

y_e : Sinir ağı çıktısı

Parametreler:

Training rate: Eğitim oranı

Learning rate: Öğrenme oranı

n1: Gizli katman nöron sayısı

n2: İkinci gizli katmandaki nöron sayısı

Yapay sinir ağı analizi için yazılan Matlab “m.” dosyası aşağıdaki şekilde kodlanmıştır.

```
function [net ye yv MAPE R2 ] = neuralnetwork(training_rate,n1,n2, lrate)
veri=xlsread('gizem1.xlsx');
idx=randperm(size(veri,1));
veri=veri(idx,:);
input=veri(:,1:9);
target=veri(:,end);
noofdata=size(input,1);
ntd=round(noofdata*training_rate);
xt=input(1:ntd,:);
xv=input(ntd+1:end,:);
yt=target(1:ntd);
yv=target(ntd+1:end);
xt=xt'
xv=xv'
yt=yt'
yv=yv'
xtn=mapminmax(xt);
xvn=mapminmax(xv);
ytn=mapminmax(yt);
[ytn,ps]=mapminmax(yt);
net=newff(xtn , ytn , [n1,n2], {}, 'trainlm')
net.trainParam.lr=lrate
net.trainParam.epochs=10000
```


```
net.trainParam.goal=1e-20
net.trainParam.show=NaN
net=train(net, xtn, ytn);
yen=sim(net, xvn);
ye=mapminmax('reverse',yen, ps);
ye=ye';
yv=yv';
MAPE=mean((abs(ye-yv))./yv);
SStotal=sum((yv-mean(yv)).^2);
SSerror=sum((ye-yv).^2);
R2=1-(SSerror/SStotal);
```

Bağımlı ve bağımsız değişkenler için resmi kaynaklardan elde edilen veriler 1960'dan 2016 yılına kadar toplanarak Matlab'da neden-sonuç ilişkisine dayalı bir yapay sinir ağı modeli oluşturulmuştur.

Çalışmada elde edilen verilerin %70'i ağına eğitimi, %15 doğrulama ve geriye kalan %15'i test için seçilmiştir. Max-min normalizasyon işlemiyle hem girdi hem de çıktı değişkenleri [0,1] aralığına dönüştürülmüştür. Böylece farklı birimlerde ölçülen veri setinin girdileri ve çıktısı aynı birimlere indirgenerek sayısal olarak çok büyük ya da çok küçük dağılımının düzenlenmesiyle değerler etkiden arındırılarak ağ performansını arttırmaktadır. Normalizasyon işlemi eğitim aşamasından önce gerçekleştirilir.

Ağ yapısıyla ilgili izlenen yol ve son olarak ortaya çıkan model şöyledir: Girdi katmanında dokuz bağımsız değişken, tek gizli katman ve on nöron sayısı, çıktı katmanında ise bir adet nöron belirlenmiştir. Matlab üzerinden oluşturulan yapay sinir ağı modeli Şekil 4.12'de görülmektedir.

Şekil 4.12. Oluşturulan Yapay Sinir Ağı



Modelin eğitim aşamasında girdi ve çıktı değerleri düzenlenir. Model eğitime başlamadan önce gerekli tanımlamaların yapılması gerekmektedir. Yapay sinir ağı modelinin katmanları ve oluşturulan parametre ayrıntıları aşağıda Tablo 4.2.'de verilmiştir.

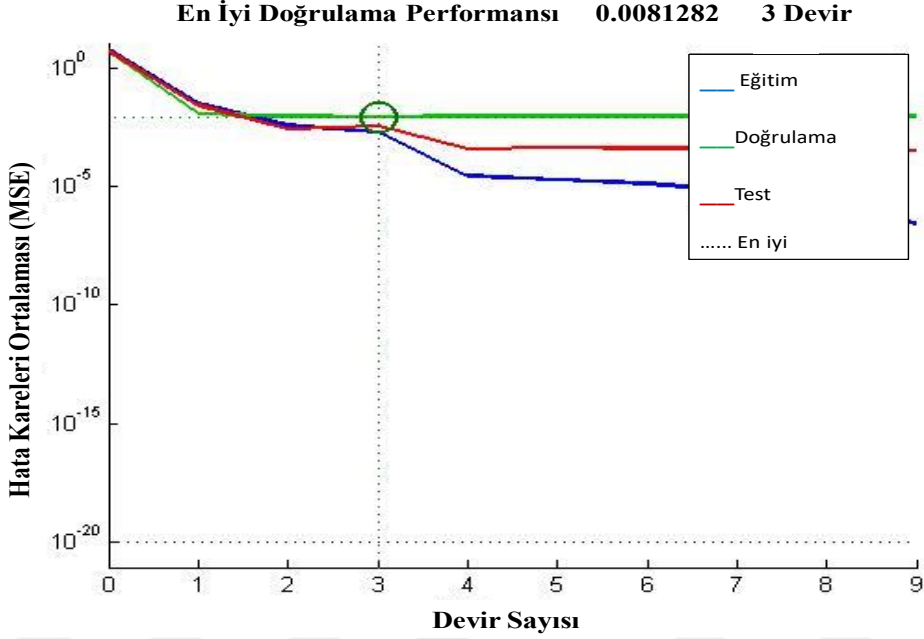
Tablo 4.2. Oluşturulan Yapay Sinir Ağı Modelinin Ayrıntıları

Ağ Mimarisi	Levenberg-Marquardt (LM) algoritması
Eğitim Tipi	Danışmanlı Öğrenme
Performans Fonksiyonu	MAPE
Gizli Katman Sayısı	1
Nöron Sayısı	10
Girdi Katmanı Aktivasyon Fonksiyonu	Sigmoid
Çıktı Katmanı Aktivasyon Fonksiyonu	Doğrusal (Lineer) Purelin
Eğitim Katsayısı	0,70
Öğrenme Katsayısı	0,85
Ölçekleme	Mapminmax Normalizasyonu

Yapay sinir ağının eğitimi, eğitim seti için MSE performans fonksiyonunu minimize eden ağırlık değerlerinin bulunmasıdır. Bu durumda eğitim seti ağı sunularak en küçük hata seviyesine ulaşılmaya çalışılmaktadır. Ağın eğitimi için denemeler sonucunda eğitim oranı 0,7 olarak alınmıştır. Ağın eğitim aşamasından sonra diğer önemli aşama ise test aşamasıdır. Test aşamasının ilk adımında eğitim aşamasındaki veriler tekrar ağı sunular ve programın en az hata payı ile tahmin yapması beklenir. Test aşamasında algoritmanın gerçek sonuçlara yaklaşım yaklaşmadığı denetlenir.

Modelin eğitim ve test aşamasına ilişkin performans grafiği Şekil 4.13’de gösterilmiştir.

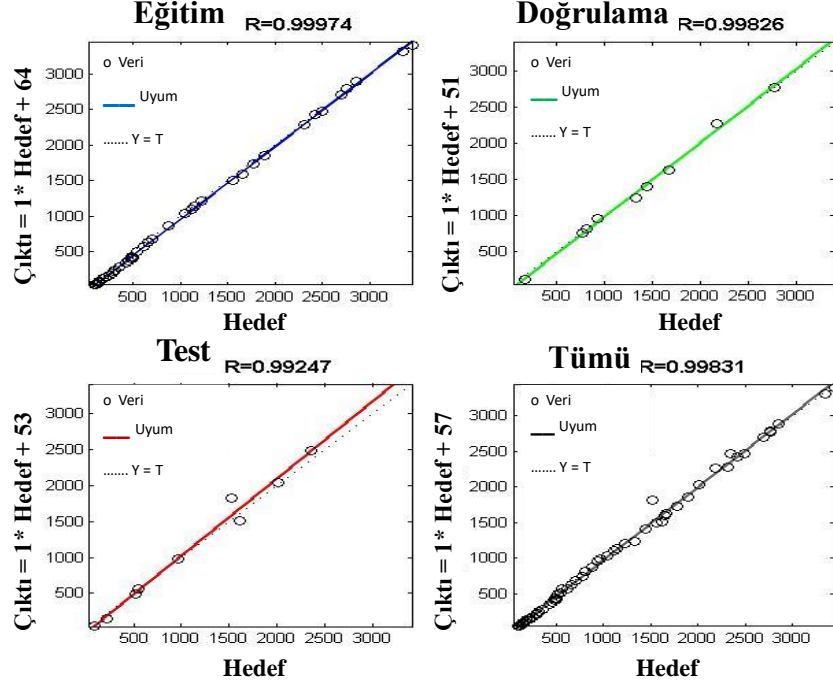
Şekil 4.13. Oluşturulan Yapay Sinir Ağı Modelinin Performans Grafiği



Şekil 4.13’deki performans grafiğinde üç çizgiden oluşmaktadır. Eğitim seti mavi, doğrulama seti yeşil ve test seti kırmızı renk çizgi ile temsil edilmiştir. Ağ grafikte görüldüğü üzere, 3.iterasyonda sıfıra yakın hataya inmiştir. MSE değeri 0,01’in altına indiğinde eğitim durmaktadır. Eğitim setindeki hatanın 0,01’in altına düşmesi sonuçların kabul edilebilir aşamada olduğunu göstermektedir. Ayrıca, doğrulama hatası arttığında eğitim 9.iterasyonda durmuştur (Sönmez, Zontul ve Bülbül, 2015).

Kurulan tahmin modeli ile gerçek değerler arasındaki ilişkinin kararı regresyon sonuçları ile değerlendirilmiştir. Çünkü regresyon tekniği, değişkenler arasındaki ilişkiyi belirlemede en yaygın kullanılan teknikler arasında yer almaktadır (Tolon ve Tosunoğlu, 2018:253). Girdiler ve çıktılar arasındaki korelasyonu gösteren R değerinin 1’e yaklaşması oldukça iyi bir uyum olduğunu göstergesidir. Şekil 4.14. modeldeki çıktı varyasyonlarının hedefler tarafından ne kadar ilişkili olduğunu göstermektedir.

Şekil 4.14. Oluşturulan Yapay Sinir Ağı Modelinin Regresyon Grafikleri



Şekil 4.14. incelendiğinde ağıın çıktısı ile hedef değerlerin regresyon doğrusu üzerinde kümелendiği görülmektedir. Test verilerinin tamamında R değeri 0,99831 olarak gerçekleşmiştir. Bu değer 1' e oldukça yakın bir değer olduğu için ağıın hem öğrenme, hem de test aşamasında oldukça başarılı olduğu anlaşılmaktadır. Elektrik talebinin modellenmesinde ağıın ezberlemediği ve bu sonuçlar doğrultusunda ağıın eğitiminin başarılı olduğu sonucuna varılabilir.

4.4. YAPAY SİNİR AĞLARI MODELİNİN TAHMİN SONUÇLARI

Yapay sinir ağı modelinin eğitiminin ardından kurulan modelin başarısını yorumlamak adına performans ölçme kriterleri dikkate alınmıştır. Performans ölçme kriterlerinden Ortalama Mutlak Yüzde Hata (MAPE) ve Hata Kareleri Ortalamasının Karekökü (RMSE) Microsoft Excel yardımıyla da detaylı olarak aşağıdaki tablolarda görülmektedir.

Tablo 4.3. Modelin Ortalama Mutlak Yüzde Hatası Excel Çözümü

Yıllar	Sinir Ağı Çıktısı	Gerçekleşen Çıktı	$(Y_i - \hat{Y}_i)$	$\left \frac{(Y_i - \hat{Y}_i)}{Y_i} \right $
1963	74,682	115,000	40,318	0,350595373
1970	174,406	207,000	32,594	0,157457615
1973	256,034	277,000	20,966	0,075690974
1976	381,888	420,582	38,694	0,092000762
1978	455,106	479,520	24,414	0,050913124
1979	431,427	488,533	57,107	0,116894388
1981	491,464	519,201	27,737	0,053422396
1985	667,505	659,748	7,757	0,011756834
1986	660,392	698,704	38,313	0,054834211
1989	798,422	874,748	76,326	0,087254358
1992	1.041,934	1.044,362	2,428	0,002325006
1993	1.236,575	1.115,196	121,379	0,108841029
1995	1.198,137	1.227,328	29,192	0,023784867
2003	1.634,521	1.771,924	137,403	0,077544588
2011	2.317,470	2.490,492	173,022	0,069473036
2012	2.518,942	2.577,431	58,489	0,022692719
2016	2.968,702	2.896,781	71,920	0,024827695
MAPE				0,081194646

Tablo 4.3.' de Excel ile hesaplanmış MAPE değeri ve Şekil 4.19.' da Matlab programındaki çıktı değeriyle aynı olan MAPE değeri görülmektedir. Çalışmada yapay sinir ağı modelinin MAPE değeri 0,0812 (% 8,1) olarak hesaplanmıştır.

MAPE değeri % 10'un altında olan tahmin değerleri "yüksek doğruluk" seviyesinde ve % 10 ile % 20 arasındaki değerler ise "doğru" tahmin modelleri olarak değerlendirilmektedir (Zeren ve Ergüzel, 2014). Hesaplanan bu performans ölçme değeri de sinir ağının yaptığı tahminde düşük bir oranda hata yaptığını, dolayısıyla tahminin tutarlılığının ve isabetliliğinin çok yüksek olduğunu göstermektedir. Tablo 4.4.' de performans ölçme kriterlerinden RMSE hata değeri ile devam edilmektedir.

Tablo 4.4. Modelin Hata Karelerinin Ortalamasının Karekökü Excel Çözümü

Yıllar	Sinir Ağı Çıktısı	Gerçekleşen Çıktı	$(Y_i - \hat{Y}_i)^2$
1963	74,682	115,000	1.625,579
1970	174,406	207,000	1.062,351
1973	256,034	277,000	439,590
1976	381,888	420,582	1.497,218
1978	455,106	479,520	596,037
1979	431,427	488,533	3.261,188
1981	491,464	519,201	769,339
1985	667,505	659,748	60,164
1986	660,392	698,704	1.467,879
1989	798,422	874,748	5.825,588
1992	1.041,934	1.044,362	5,896
1993	1.236,575	1.115,196	14.732,876
1995	1.198,137	1.227,328	852,164
2003	1.634,521	1.771,924	18.879,610
2011	2.317,470	2.490,492	29.936,619
2012	2.518,942	2.577,431	3.420,954
2016	2.968,702	2.896,781	5.172,544
RMSE			72,6010838

Tablo 4.4.' de modeldeki RMSE değeri her bir veri başına 72 birim hata yapıldığını göstermektedir. Son olarak R^2 değerine de bakılarak modelin performans ölçüsü hakkında yorum yapılmaktadır.

Tablo 4.5. Modelin R^2 Değeri Excel Çözümü

Yıllar	Sinir Ağı Çıktısı	Gerçekleşen Çıktı	*SSTOTAL	**SSERROR
1963	74,682	115,000	875.716,311	1.625,579
1970	174,406	207,000	711.993,635	1.062,351
1973	256,034	277,000	598.762,033	439,590
1976	381,888	420,582	397.170,666	1.497,218
1978	455,106	479,520	326.357,303	596,037
1979	431,427	488,533	316.140,543	3.261,188
1981	491,464	519,201	282.594,456	769,339
1985	667,505	659,748	152.919,138	60,164
1986	660,392	698,704	123.969,248	1.467,879
1989	798,422	874,748	30.993,446	5.825,588
1992	1.041,934	1.044,362	41,413	5,896
1993	1.236,575	1.115,196	4.147,184	14.732,876
1995	1.198,137	1.227,328	31.163,303	852,164
2003	1.634,521	1.771,924	520.023,485	18.879,610
2011	2.317,470	2.490,492	2.072.720,321	29.936,619
2012	2.518,942	2.577,431	2.330.611,944	3.420,954
2016	2.968,702	2.896,781	3.407.657,348	5.172,544
$R^2 = 1 - (SSERROR / SSTOTAL)$			0,992645019	


*SSTOTAL: $\sum(Y_i - \hat{Y}_i)^2$

**SSERROR: $\sum(Y_i - \hat{Y})^2$

R^2 değerinin 0 ile 1 arasında olması beklenmektedir ve Tablo 4.5.' de R^2 değerinin 0,99 olması modeldeki değişkenlerin % 99' unun açıklandığı anlamına gelmektedir. Bu durumdan hareketle, hangi değişkenin elektrik tüketimini ne şekilde etkilediğinin bilinmemesine rağmen, modele dâhil edilen 9 değişkenin elektrik tüketimini açıklamada ne derece başarılı olduğu görülmektedir.

Yapay sinir ağları modelinin ürettiği tahmin değerleri ile gerçekleşen değerlerin karşılaştırıldığı ve aynı zamanda modelin performansının da görsel olarak ifade edildiği grafik Şekil 4.15.'de görülmektedir.

Şekil 4.15. Gerçekleşen ile Tahminlenen Tüketimin Karşılaştırılması



Şekil 4.15.' den de anlaşılacağı üzere gerçek değerler ile modelin ürettiği değerler arasındaki fark oldukça azdır.

Literatürden farklı olarak modele girdi değişkeni olarak eklenen elektrik kurulu gücü ve motorlu kara taşıt sayısı değişkenlerinin tahmin performansına katkısını görebilmek amacıyla yalnızca GSMH, ithalat, ihracat, tüketici fiyat endeksi, şehir nüfusu, geniş kapsamlı para miktarı, sanayinin GSMH içindeki yeri değişkenleri kullanılarak yeni bir yapay sinir ağı modeli kurulmuştur. Modelin kurulma aşamasında tek gizli katman tercih edilmiştir. En uygun parametreler deneme yanılma yoluyla belirlenmiştir. Girdi katmanında Sigmoid ve çıktı katmanında Doğrusal (Linear) Purelin transfer fonksiyonu belirlenmiştir. Öğrenme algoritması olarak Levenberg-Marquardt (LM) algoritması kullanılmıştır. Eğitim katsayısı 0,70 ve öğrenme katsayısı 0,85 olarak tespit edilmiştir. Kurulan yeni yapay sinir ağı modeline YYS-2 adı verilmiş ve modele ilişkin sonuçlar Tablo 4.5.'de verilmiştir.

Tablo 4.6. YYS-2 Sonuları

Yıllar	Sinir Ađı ıktısı	GerekleŒen ıktı
1963	149,060	115,000
1964	64,217	124,000
1966	150,406	148,000
1968	167,276	175,000
1974	409,230	291,000
1975	504,206	358,579
1978	367,095	479,520
1979	470,473	488,533
1980	730,657	495,544
1983	614,872	555,409
1984	681,408	613,666
1992	1.368,111	1.044,362
1993	1.560,769	1.115,196
1994	1.597,603	1.145,505
2000	2.127,223	1.652,748
2004	2.238,490	1.891,927
2010	2.655,226	2.333,744
*MAPE		0,2545
** R²		0,8492

$$*MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| * 100$$

$$** R^2 = 1 - \frac{SS_{total}}{SS_{error}} = 1 - \frac{\sum (Y_i - \hat{Y}_i)^2}{\sum (Y_i - \bar{Y})^2}$$

Tablo 4.6.'da grldđ zere, YYS-2 modeli asıl alıŒmada oluŒturulan yapay sinir ađı modelinden daha dŒk performans gerekleŒtirmiŒ ve daha yksek hata deđeri ile tahmin etmiŒtir. Bylece, YYS-2 modelinde kullanılan deđiŒkenlere ek olarak asıl alıŒma modeline ilave edilen elektrik kurulu gc ve motorlu kara taŒıt sayısı deđiŒkenleri elektrik tahmin modelini aıklamada nemli katkı sađlamıŒtır.

4.5. SONUÇLARIN TEST EDİLMESİ VE DEĞERLENDİRİLMESİ

Uygulamanın bu kısmında ağı eğitilmesinin ardından modelde ele alınan değişkenlerin 2017 yılı sinir ağı çıktı tahmini ve gerçekleşen çıktı değeri karşılaştırılmıştır. Yapay sinir ağları modeline tahmin yapmak istediğimiz 2017 yılı veri girişi yapılarak ağı tahmin üretmesi istenmiştir. Buna göre % 99,15 başarıyla 2017 yılı kişi başına elektrik tüketimi kWh cinsinden tahmin edilmiş ve Tablo 4.7.'de gösterilmiştir.

Tablo 4.7. 2017 yılı Gerçekleşen ve Tahmin Edilen Değerlerin Karşılaştırılması

	Sinir Ağı Çıktısı	Gerçekleşen Çıktı	MAPE
Elektrik Tüketimi (Kişi Başına kWh)	3152,002	3081,544	0,17

Yapay sinir ağları yönteminden uygun bir mimari yaratabilmek adına çeşitli kaynaklardan faydalanarak parametreler belirlenmiş ve en başarılı modeli elde etmek amaçlanmıştır. 1960-2016 yılları arasındaki veriler ağı eğitimi ve doğrulanmasında kullanılmış, 2017 yılı ise model sonucunun test edilmesi için ayrılmıştır. Yapılan tahminin sonucunda 0,17' lik bir hatayla % 99,15 başarı sağlanmıştır.

Elektrik tahmininde uygun sinir ağı yapısını tespit etmede istatistiksel olarak anlamlı bir sonuca ulaşabilmek için model tekrar çalıştırılmıştır. En iyi sonucu bulana kadar deneme yanılma yöntemiyle farklı yapay sinir ağı modellerinin alternatif çözümler olarak kullanılabilceği görülmektedir. Tahminde hangi modelden faydalanılabileceğine karar vermek için tüm alternatif modeller test veri grubu ile denenmiştir ve 13 adet MAPE ve R^2 değeri bulunmuştur. Bu 13 senaryo model arasında en düşük hata (MAPE) değerine ve en yüksek korelasyon ölçüsüne (R^2) sahip olan sinir ağı alternatifleri verilmiştir.

- Senaryo Model 1: tek gizli katmanlı model (n1=15)
- Senaryo Model 2: tek gizli katmanlı model (n1=5)
- Senaryo Model 3: iki gizli katmanı olan model (n2=5)
- Senaryo Model 4: iki gizli katmanı olan model (n2=10)

- Senaryo Model 5: iki gizli katmanı olan model (n2=15)
- Senaryo Model 6: (eđitim oranı= 0,60)
- Senaryo Model 7: (eđitim oranı= 0,80)
- Senaryo Model 8: (öđrenme oranı= 0,75)
- Senaryo Model 9: (öđrenme oranı= 0,90)
- Senaryo Model 10: (öđrenme algoritması traingda)
- Senaryo Model 11: (öđrenme algoritması trainoss)
- Senaryo Model 12: (transfer fonksiyonu tansig)
- Senaryo Model 13: (transfer fonksiyonu hardlim)

Tablo 4.8. Alternatif Modellerin Performans Ölçme Deđerleri

Alternatif Modeller	MAPE	R^2
MODEL 1	0.2887	0.8191
MODEL 2	0.4944	0.1899
MODEL 3	0.2541	0.9851
MODEL 4	0.2293	0.8407
MODEL 5	0.4510	0.6299
MODEL 6	0.4142	0.9214
MODEL 7	0.7068	-0.0833
MODEL 8	0.2652	0.7575
MODEL 9	0.1508	0.9511
MODEL 10	0.2539	0.9674
MODEL 11	0.3996	0.8677
MODEL 12	0.2362	0.8075
MODEL 13	22.859	-0.0056

Deneme yanılma yoluyla yapılan analizlerden senaryo modeli 3' e bakılarak ilk tespit yapılmıştır. Eđer iki gizli katmanlı bir ađ oluşturulacaksa; ilk katmandaki nöron sayısının ikinci katmandaki nöron sayısından fazla olması MAPE hata ölçütünü düşük ve R^2 deđerinin oldukça yüksek olduğunu göstermiştir. Ayrıca senaryo model 7 ve senaryo model 13 sonuçlarına bakıldığında MAPE hata deđerinin yüksek ve R^2 deđerinin negatif olduğu görülmektedir. Modelde eđitim oranı deđerini

yüksek veya transfer fonksiyonunu hardlim belirlemekten kaynaklı olduğu düşünülmektedir.

Sektörde merak edilen sorulara cevap verebilmek ve rehber olmasını sağlamak adına oluşturulan yapay sinir ağı ile elektrik tüketim tahmini çalışmasında sonuç olarak doğrusal olmayan veri örüntüsü nedeniyle Sigmoid transfer fonksiyonu tercih edilmiştir. Evrensel Yaklaşımlar Teorisi'ne (Universal Approximation Theorem) göre tek gizli katmanlı yapıya sahip bir ağda; eğer gizli katmanda yeterli nöron sayısı varsa, girdi-çıkı ilişkilerinin verimli bir şekilde yorumlanmasını sağlayacağından çalışmada da model tek gizli katmandan oluşturulmuştur. Gizli katmandaki en iyi nöron sayısını bulmak için yapılan denemeler Tablo 4.8.' de gösterilmiştir. Denemeler sonucunda MAPE ve R^2 performans ölçme kriterleri de göz önünde bulundurularak on nöron sayısına karar verilmiştir.

SONUÇLAR

Enerji sektörü, artan nüfus, sanayileşme ve gelişen teknolojilerin de etkisiyle sanayi devriminden bu yana gündelik yaşam kalitesinin vazgeçilmez bir parçası olarak stratejik bir öneme sahiptir. Ülkelerin milli gelirleri arttıkça elektrik enerjisi kullanımı da artmış ve dolayısıyla beraberinde bir takım sıkıntılar getirdiğinden çeşitli politikalar geliştirilmiştir. Elektriğin halen depolanamıyor ve tüketildiği anda üretilmesi gereken bir kaynak olması sebebiyle bu politikaların başında isabetli tahminleme kavramı gün geçtikçe önem kazanmaktadır.

Elektrik enerjisi piyasasında hayati bir öneme sahip olan elektrik talep tahmininin; olması gerekenden düşük tahmini ve buna bağlı olarak yanlış sistem planlaması durumunda elektrik kesintileri kaçınılmazdır. Bu yüzden ekonomide büyüme ve kişi başına refah artışı sekteye uğramaktadır. Tam tersi eğer elektrik talebi olması gerekenin üzerinde tahmin edildiyse; yatırım kararlarının uzun vadeli alınması, atıl kapasitenin yüksek miktarda olması ve adaletsiz kaynak dağılımı yani kaynak israfı durumları ortaya çıkmaktadır.

Bu çalışmada nicel tahmin yöntemlerinden yapay sinir ağları modeli ile Türkiye'nin elektrik enerjisi tüketim tahmini gerçekleştirilmiştir. Elektrik enerjisi tüketimini doğrudan veya direkt etkileyecek değişkenler belirlenerek bir model kurulmuştur. Model sonucunun başarısını değerlendirmek adına MAPE ve R^2 performans ölçütlerinden yararlanılmıştır.

Geçmişe dair olaylardan yola çıkarak yeni örnekler üzerinde tahmin yapabilme yetisine sahip yapay sinir ağları, doğrusal olmayan problemleri modellemesi ve tahmin çalışmalarında oldukça başarılı sonuçlar vermesi nedeniyle diğer yöntemlerin önüne geçmektedir. Tüm bu özellikler göz önüne alınarak çalışmada yapay sinir ağları ile tahmin yapılmıştır.

1960-2016 yılları arasında elektrik tüketimini etkileyen değişkenlere ait veriler toplanmıştır. Elektrik tüketimini etkileyen değişkenler gerek literatür taramasında yapılan araştırmalar neticesinde gerekse çeşitli kaynaklarda yapılan çalışmaların sonucunda netleşmiştir. Dünya Bankası, Türkiye Elektrik İletim A.Ş. ve Türkiye İstatistik Kurumu kaynaklarından elde edilen verilerle bir model oluşturulmuştur. Toplanan veriler, normalizasyon işleminden geçtikten sonra ağa sunulmuştur.

Çalışmada geri yayılım algoritması kullanılarak tahmin modeli oluşturulmuş, tüm girdi değişkenleri için 1960-2016 arası yıllık veriler ağı eğitim ve doğrulama aşamasında kullanılmış, 2017 yılı verisi ise test için ayrılmıştır. Kişi başına düşen GSMH, tüketici fiyat endeksi, ithalat, ihracat, şehir nüfusu, geniş kapsamlı para miktarı, sanayinin GSMH içindeki yeri, elektrik kurulu gücü ve motorlu taşıt sayısı değişkenleri girdi kabul edilmiş ve elektrik tüketimi tahminlenmiştir. Tek gizli katmanlı, on gizli katman nöron sayısı, eğitimde Sigmoid transfer fonksiyonu, testte purelin transfer fonksiyonu ve trainlm geri yayılım algoritmasından faydalanılmıştır. Öğrenme oranı 0,85 ve eğitim oranı 0,70 olarak alınmıştır. Eğitimi tamamlanan modelin test aşamasına geçildiğinde sonuçlar doğrultusunda ele alınan girdi-çıkı değerleri arasında yüksek bir R^2 ilişkisi ve düşük hata oranı MAPE ölçütü olduğu ortaya çıkmıştır. Eğitim modelinin açıklayıcılığı %99, model tarafından belirlenen en iyi tahmin oranı %99 olarak bulunmuştur. Bu sonuçlara göre, oluşturulan yapay sinir ağının hem eğitimde hem de test aşamasında oldukça başarılı olduğu görülmektedir.

Bu çalışmada uygulanan metot ve semptomlar ışığında bu alanda yeni çalışmalar yürüteceklere aşağıdaki öneriler verilebilir:

- ✓ Gelecekteki yatırımların planlanmasında ve elektrik enerjisi politikalarının belirlenmesinde tahmin çalışmaları oldukça büyük öneme sahip olduğundan tahmin performansını arttırmada farklı algoritmalar ve fonksiyonlar kullanılabilir.
- ✓ Genetik algoritmalar yöntemi ile modelinin girdi parametreleri belirlenebilir.
- ✓ Genetik algoritmalar ile belirlenen girdi değişkenleri ile yapay sinir ağları yöntemi birleştirilerek daha az hata oranı yaratacak hibrit bir tahmin modeli oluşturulabilir.
- ✓ Yapay sinir ağları modelindeki ağırlıkların belirlenmesinde optimizasyondan yararlanılabilir.
- ✓ Uzak geleceğin tahmininde yapay sinir ağları modeli kullanılırken, yakın geleceğin tahmininde sürenin kısaltılması ve verilerin değişkenliği öngörüldüğünde yapay sinir ağları zaman serileri modellerinden faydalanılması daha uygun olabilir.
- ✓ Model parametrelerin seçiminde denemeleri azaltmak ve hassasiyeti arttırmak için duyarlılık analizlerinin yapılabileceği programlar aracılığıyla makro

değişkenler ağırlıklandırılarak modelin genelden özele indirgenmesi sağlanabilir.



KAYNAKÇA

- Acar, N., (1989). Üretim Planlaması Yöntem ve Uygulamaları, Yeniçağ, Ankara
- Adıyaman, F., (2007). “*Talep Tahmininde Yapay Sinir Ağlarının Kullanılması*”, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul
- Akbay, A.Ö., Aktaş, E. ve Koç, A., (1999). “Konsantre Meyve Suyu Talebinin “Tobit” Modeli ile Analizi”, *Turkish Journal of Agriculture and Forestry*, 23: 493-499
- Arı, A, ve Berberler, E, M. (2017). “Yapay Sinir Ağları İle Tahmin ve Sınıflandırma Problemlerinin Çözümü için Arayüz Tasarımı”, *Acta Infologica*, s. 12
- Aslan, Y., Yaşar, C. ve Nalbant, A. (2006). “Kütahya İlinin Yapay Sinir Ağları Kullanılarak Elektrik Puant Yük Tahmini”, *Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 11. Sayı, s. 102-124
- Avcı, E., (2009). “Yapay Sinir Ağları Modelleri ile Hisse Senedi Getiri Tahminleri”, *Marmara Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 26(1), s. 443-461
- Aydın, D. (2012). “*Yapay Sinir Ağları Yardımı İle Talep Tahmin Analizi ve Deniz Taşımacılığı Sektöründe Bir Uygulama*”, Yayınlanmamış Yüksek Lisans Tezi, Marmara Üniversitesi Sosyal Bilimler Enstitüsü, s. 35
- Azadeh, A., Ghaderi, S., F., Tarverdian, S. ve Saberi, M., (2007). “Integration of Artificial Neural Networks and Genetic Algorithm to Predict Electrical Energy Consumption”, *Applied Mathematics and Computation*, 186:2, s. 1731–1741

- Baran, G., 2010, “*Türkiye Turizm Talebinin Zaman Serisi Analizi ile Tahmini*”, Uzmanlık Tezi, Kültür ve Turizm Bakanlığı, s. 39-70
- Başođulu, B. ve Bulut M. (2017). “Kısa Dönem Elektrik Talep Tahminleri İçin Yapay Sinir Ağları ve Uzman Sistemler Tabanlı Hibrit Sistem Geliştirilmesi”, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 32:2, s. 575-583
- Bayır, F., (2006). “*Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama*”, Yüksek Lisans Tezi, İstanbul Üniversitesi, Sosyal Bilimleri Enstitüsü, İstanbul
- Bhattacharya, S., (1997). “*A Comparative Study of Different Methods of Predicting Time Series*”, Yüksek Lisans Tezi, Concordia University, Canada
- Box, G. E. P., ve Jenkins, J. M., (1976). *Time Series Analysis: Forecasting and Control*. Holden-Day, San Francisco, CA
- Cahow, E. E., (2004). “*Forecast of Demand for Chronic Care Nursing Home Services:2005-2025*”, Doktora Tezi, Brandeis University, Waltham Massachusetts, USA
- Carlson, R. L., ve Umble, M., (1980). “Statistical Demand Functions for Automobiles and Their Use for Forecasting in an Energy Crisis”, *The Journal of Business*, 53:2-10
- Chen, J., (2000). “*Forecasting Method Applications to Recreation and Tourism Demand*”, Doktora Tezi, North Carolina State University, USA
- Çağlar, T., (2007). “*Talep Tahmininde Kullanılan Yöntemler ve Fens Teli Üretimi Yapan Bir İşletmede Uygulanması*”, Yüksek Lisans Tezi, Kırıkkale Üniversitesi, Fen Bilimleri Enstitüsü, Kırıkkale

- Çelik, Burak (2008). “YSA Metodolojisi ile Zaman Serisi Analizi: Teori ve Uygulama”, Yüksek Lisans Tezi, Marmara Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul
- Çeliker, M. (2011). “Türkiye Elektrik Enerjisi Piyasalarında Serbestleşme Sürecinde Karşılaşılan Sorunlar Ve Çözüm Önerileri”, Yayınlanmamış Uzmanlık Tezi, Hazine Müsteşarlığı, Ankara
- Dalgın, A., (2017). “Yapay Sinir Ağları Kullanılarak Türkiye Gün Öncesi Piyasası Elektrik Fiyat Tahmini”, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Enerji Enstitüsü, İstanbul
- Demuth, H., Beale, M. ve Hagan, M., (2008). Neural Network. Toolbox 6 User's Guide, Natick, MA: The Math Works
- Deveci, M., (2012). “Yapay Sinir Ağları ve Bekleme Süresinin Tahminimde Kullanılması”, Yüksek Lisans Tezi, Gazi Üniversitesi, Sosyal Bilimleri Enstitüsü, Ankara
- Dinçel, Adnan (2007). “Türkiye'de Elektriğin İlkleri ve Silahtarağa Santralistanbul”, *Kaynak Elektrik Dergisi*, Sayı Ağustos, s. 61
- Ediger, V.Ş. ve Akar, S., (2007). “ARIMA Forecasting of Primary Energy Demand by Fuel in Turkey”, *Energy Policy*, 35, s. 1701-1708
- Ediger, V.Ş., Sertaç, A. ve Uğurlu, B., (2006). “Forecasting Production of Fosil Fuel Sources in Turkey Using a Comparative Regression and ARIMA Model”, *Energy Policy*, 34, s. 3836-3846
- Ekonomou, L., (2010). “Greek Long-Term Energy Consumption Prediction Using Artificial Neural Networks”, *Journal of Energy*, 35, s. 512-517

Elektrik Dağıtım Şirketleri, <https://www.enerjibes.com/elektrik-dagitim-sirketleri/>
Erişim: Ocak 2019

Elmas Ç., (2003). Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama). Seçkin Yayıncılık, Ankara

EPDK Sektör Raporu, Enerji Piyasası Düzenleme Kurumu Strateji Geliştirme Dairesi Başkanlığı
<https://www.epdk.org.tr/Detay/DownloadDocument?id=MX2VHH6jD4E>
Erişim: Ocak 2019

EÜAŞ, Elektrik Üretim Yıllık Faaliyet Raporları, <http://www.euas.gov.tr/Sayfalar/Y%C4%B11l%C4%B1k-Raporlar.aspx>,
Erişim: Ocak, 2019

Fausett, L., (1994). Fundamentals of Neural Networks, Prentice-Hall, New Jersey

Gavcar, E., Şen, S. ve Aytekin, A., (1999). “Türkiye’de Kullanılan Kağıt-Karton Türlerinin Talep Tahminlerinin Belirlenmesi”, *Tr. Journal of Agriculture and Forestry*, TÜBİTAK, 23: 203-211, Kocaeli

Griffiths, W.E., Newton, L.S. ve O’Donnell, C.J. (2010). “Predictive Densities For Models with Stochastic Regressors and Inequality Constraints: Forecasting Local-Area Wheat Yield”, *International Journal Of Forecasting*, s. 397–412

Güngör, E. (2007). “Yapay Sinir Ağları Yardımı ile Makine Arızalarının Önceden Tahmin Edilmesi”, Yüksek Lisans Tezi, Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü, Kocaeli

Haliloğlu, E.Y. ve Tutu, B.E. (2018). “Türkiye İçin Kısa Vadeli Elektrik Enerjisi Talep Tahmini”, *Journal of Yasar University*, 13/51, s. 243-255

- Hamzaçebi, C. (2011). Yapay Sinir Ağları Tahmin Amaçlı Kullanımı MATLAB ve Neurosolutions Uygulamalı. Bursa: Ekin Yayınevi
- Hamzaçebi, C. ve Kutay, F. (2004). “Yapay Sinir Ağları İle Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini”, *Gazi Üniv. Müh. Mim. Fak. Der.*, Cilt 19, No 3, s. 67-82
- Hamzaçebi, C., Es, H.A. ve Kalender, Y. (2014). “Yapay Sinir Ağları İle Türkiye Net Enerji Talep Tahmini”, *Gazi Üniv. Müh. Mim. Fak. Der.*, Cilt 29, No:3, s. 87-102
- Hebb, D.O., (1949). The Organization of Behaviour, A Neuropsychological Theory. John Wiley & Sons Inc, New York
- Kankal, M., Akpınar, A., Kömürcü, M. ve Özaşhin T., Ş., (2011). “Modeling and Forecasting of Turkey’s Energy Consumption Using Socio-Economic and Demographic Variables”, *Applied Energy*, 88, s. 1927-1939
- Karaca, C., Karacan, H. (2016). “Çoklu Regresyon Metoduyla Elektrik Tüketim Talebini Etkileyen Faktörlerin İncelenmesi”, Selçuk Üniversitesi Mühendislik Fakültesi, s. 183-195
- Karacasu, Ö. ve Hocaoğlu, H. (2003). “Yapay Sinir Ağları İle Gaziantep Yöresi İçin Yük Tahmini Analizi”, *International XII. Turkish Symposium on Artificial Intelligence and Neural Networks*, TANN
- Karahan, M. (2011). “İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu İle Ürün Talep Tahmini Uygulaması”, Yayınlanmamış Doktora Tezi, Selçuk Üniversitesi Sosyal Bilimler Enstitüsü, s. 45

Karahan, M., (2011), “İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu ile Ürün Talep Tahmini Uygulaması”, Doktora Tezi, Selçuk Üniversitesi Sosyal Bilimler Enstitüsü, Konya

Karamustafaoğlu, Mert (2006). “Elektrik Üretimi Pazarındaki Mevcut Sözleşmelerin Pazarın Rekabetçi Yapısı Üzerindeki Etkileri”, Rekabet Kurumu Uzmanlık Tezi, s. 30

Kartalopoulos, Stamatios V. (1996). Understanding Neural Networks and Fuzzy Logic. Basic Concepts and Applications. New York: IEEE Press

Kaynar, O. ve Taştan, S., (2009) “Zaman Serisi Analizinde MLP Yapay Sinir Ağları ve ARIMA Modellerinin Karşılaştırılması”, *Erciyes Üniversitesi İİBF Dergisi*, Sayı:33, s. 161-172

Kellova, A., (2008). “Statistical Approach to Short-Term Electricity Forecasting, Dissertation”, Doktora Tezi, Charles University, Prague

Kiki, M., (2018). “Yapay Sinir Ağları Kullanılarak Türkiye Elektrik Piyasası Gün Sonrası Fiyat Tahmini”, Yüksek Lisans Tezi, Erzincan Üniversitesi, Fen Bilimleri Enstitüsü, Erzincan

Kirby, Robert M. (1966). “A Comparison of Short And Medium Range Statistical Forecasting Methods, Management Science”, 13(4) , s. 202-210

Kocadayı, Y., ErKaymaz, O. ve Uzun, R. (2017). “Yapay Sinir Ağları ile Tr81 Bölgesi Yıllık Elektrik Enerjisi Tüketiminin Tahmini”, *Bilge International Journal of Science and Technology Research*, 1 (Special Issue), s. 59-64

Krenker, A., Bešter, J. ve Kos, A. (2002). “Artificial Neural Networks - Methodological Advances and Biomedical Applications: Introduction to the Artificial Neural Networks”, <http://goo.gl/JtrS9M>, Erişim Tarihi: 22.02.2019

- Kubat, C. (2014). *Matlab Yapay Zeka ve Mühendislik Uygulamaları*, Pusula Yayınevi, İstanbul
- Kutlar, A., (2000). *Ekonometrik Zaman Serileri Teori ve Uygulama*. Gazi Kitabevi, Ankara
- Kwakwa, P. A. (2017). “Electricity Consumption in Egypt: A Long-Run Analysis of Its Determinants”, *OPEC Energy Review*, 41(1), s. 3-22
- Makas, Y. ve Karaatlı, M. (2016). “Yapay Sinir Ağlarıyla Hidroelektrik Enerji Üretimini Çok Dönemli Tahmini”, *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, Cilt 21:3, s. 757-772
- Makridakis, S., Wheelwright S.C., ve McGee V. E., (1998). *Forecasting: Methods and Applications*. John Wiley & Sons Inc., USA
- Mann, P. S., (1995). *Statistics for Business and Economics*. John Wiley & Sons Inc, USA
- Masaebi, P., (2016). “*Yapay Sinir Ağları ile İran Elektrik Tüketim Tahmini*”, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, s. 87
- Monks, Joseph G. (1996). *İşlemler Yönetimi Teori ve Problemler* (Çeviren: Sevinç Üreten). Nobel Yayın Dağıtım, Ankara
- Mucuk, M. ve Uysal, D. (2009). “Türkiye Ekonomisinde Enerji Tüketimi ve Ekonomik Büyüme”, *Maliye Dergisi*, s. 157-165
- Onur, F., Ergün, B., ve Şahin, C. (2016). “Bulanık Mantık Yaklaşımı ile Baraj Gölü Doluluk Tahmini Çalışması”, *6. Uzaktan Algılama- CBS Sempozyumu*, Adana, s. 371-380

- Özden, S. ve Öztürk, A. (2018). “Yapay Sinir Ağları ve Zaman Serileri Yöntemi ile Bir Endüstri Alanının (İvedik OSB) Elektrik Enerjisi İhtiyaç Tahmini”, *Bilişim Teknolojileri Dergisi*, Cilt:11, Sayı:3, s. 81-97
- Özkaya, Ali (2012). “*Elektrik Piyasasında Etkin Regülasyon ve İzleme*”, Enerji Piyasası Düzenleme Kurumu, Uzmanlık Tezi, s. 94
- Özpınar, M.A., (2007). “*Yenilenebilir Enerji Santrallerinde Yapay Sinir Ağları Yöntemiyle Enerji Üretiminin Modellenmesi ve Planlanması*”, Doktora Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul
- Özşahin, Ş., (2013). “Optimization of Process Parameters in Oriented Strand Board Manufacturing with Artificial Neural Network Analysis”, *European Journal of Wood and Wood Products*, 71:6, s. 769-777
- Öztemel, E. (2012). *Yapay Sinir Ağları*, 2. Baskı, Papatya Yayıncılık, İstanbul, s. 72-75
- Öztemel, E. (2016). *Yapay sinir ağları*, 1 st, Papatya Bilim, İstanbul, s. 15-61
- Öztemel, E., (2003). *Yapay Sinir Ağları*. Papatya Yayınevi, İstanbul, s. 3-15
- Pao, H., T., (2006). “Comparing Linear and Nonlinear Forecasts for Taiwan’s Electricity consumption”, *Journal of Energy*, 31:12, s. 2129–2141
- Polater, H.Murat (2013). “*Long Term Elektrical Supply-Demand Balance of Turkey*”, Orta Doğu Teknik Üniversitesi, Elektrik ve Elektronik Mühendisliği, Yüksek Lisans Tezi, s. 4
- Rajpal, P.S., Shishodia, K.S. ve Sekhon, G.S. (2006). “An Artificial Neural Network for Modeling Reliability, Availability and Maintainability of a Repairable System”, *Reliability Engineering and System Safety*, 91,s. 809-819

Satır, B. ve Köksal, M. (2006). “Entegre Tavuk Organizasyonları için Genel Üretim ve Finansal Planlama Modeli”, <http://academic.cankaya.edu.tr/~benhur/cv/yaem2004.doc> Erişim Tarihi: 18.12.2018

Sevinçtekin, E. (2014). “İmalat Sektöründe Yapay Sinir Ağları Uygulaması”, Yayınlanmamış Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, s. 21

Sönmez F., Zontul M. ve Bülbül, Ş. (2015). “Mevduat Bankalarının Kârlılığının Yapay Sinir Ağları İle Tahmini: Bir Yazılım Modeli Tasarımı”, *BDDK Bankacılık ve Finansal Piyasalar Dergisi*, 9(1), s. 9-45

Stergiou, Christos ve Siganos, Dimitrios (2010). “Neural Networks”, http://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html, Erişim Tarihi: 11.06.2018

Tebelkis J., (1995). “*Speech Recognition using Neural Networks*”, Phd Thesis, School of Computer Science Carnegie Mellon University, Pennsylvania

TEİAŞ, Türkiye Elektrik İletim A.Ş. Genel Müdürlüğü <https://www.teias.gov.tr/tr/iii-elektrik-enerjisi-uretimi-tuketimi-kayıplar> Erişim: Ocak 2019

TEİAŞ, Türkiye Elektrik İstatistikleri, <http://www.teias.gov.tr/istatistikler.aspx> , Erişim: Ocak, 2019

Tekin, M., (1996). Üretim Yönetimi, Arı Ofset Matbaacılık, Konya

Tekin, M., (2009). Üretim Yönetimi Cilt 1, 6. Baskı, Günay Ofset, Konya

Tolon, M, ve Tosunođlu, G.N. (2008). “Tüketici Tahmini Verilerinin Analizi: Yapay Sinir Ağları ve Regresyon Analizi Karşılaştırması”, *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, s. 247-259

Tsai, L.C., In-Fun, L. ve Huang, Y. (2009). “Forecasting Thailand's Medical Tourism Demand and Revenue From Foreign Patients”, *The Journal of Grey System*, s. 4: 369-376

Turhan, C., Gökçen, G. ve Kazanasmaz T. (2013). “Yapay Sinir Ağları İle İzmir’deki Çok Katlı Binaların Toplam Enerji Tüketimlerinin Tahmin Edilmesi”, *11. Ulusal Tesisat Mühendisliği Kongresi*, İzmir

Tutuş, Ali (2005). “Türkiye’de Elektrik Enerjisinin Tarihsel Gelişimi ve Yeni Piyasa Düzeni İçerisinde Hidroelektrik Enerjinin Yeri”, *TMMOB Su Politikaları Kongresi*, Ankara, s. 318-320

Türkiye Sınai Kalkınma Bankası A.Ş., Sektörel Enerji Görünümü Raporu, <http://www.tskb.com.tr/i/assets/document/pdf/enerji-sektorel-gorunumu.pdf>
Erişim: Aralık 2018, s.20

URL-1: Dünya Bankası (2018)
<https://data.worldbank.org/indicator/NY.GDP.PCAP.KN?locations=TR>
Erişim: Ocak 2018

URL-2: Dünya Bankası (2018)
<https://data.worldbank.org/indicator/FP.CPI.TOTL?locations=TR> Erişim:
Ocak 2018

URL-3: Dünya Bankası (2018)
<https://data.worldbank.org/indicator/NE.IMP.GNFS.ZS?locations=TR>
Erişim: Ocak 2018

URL-4: Dünya Bankası (2018)
<https://data.worldbank.org/indicator/NV.IND.TOTL.ZS?locations=TR>
Eriřim: Ocak 2018

URL-5: Dünya Bankası (2018)
<https://data.worldbank.org/indicator/FM.LBL.BMNY.GD.ZS?locations=TR>
Eriřim: Ocak 2018

URL-6: Dünya Bankası (2018)
<https://data.worldbank.org/indicator/SP.URB.TOTL?locations=TR> Eriřim:
Ocak 2018

URL-7: Dünya Bankası (2018)
<https://data.worldbank.org/indicator/NE.EXP.GNFS.ZS?locations=TR>
Eriřim: Ocak 2018

URL-8: TEİAŞ (2018) ELEKTRİK ÜRETİM-İLETİM İSTATİSTİKLERİ/ Kurulu
Güç / Türkiye Kurulu Gücünün Yıllar İtibariyle Geliřimi
<https://www.teias.gov.tr/tr/i-kurulu-guc-0> Eriřim: Ocak 2018

URL-9: TÜİK (2018) Motorlu Kara Tařıtları Haber Bülteni/ Tablo:3
<http://www.tuik.gov.tr/PreHaberBultenleri.do?id=24601> Eriřim: Ocak 2018

URL-10: TEİAŞ (2018) ELEKTRİK ÜRETİM-İLETİM İSTATİSTİKLERİ/ Türkiye
ve Kiři Bařına Kurulu Güç Brüt Üretim ve Net Tüketimin Yıllar İtibariyle
Geliřimi [https://www.teias.gov.tr/tr/iii-elektrik-enerjisi-uretimi-tuketimi-
kayıplar-0](https://www.teias.gov.tr/tr/iii-elektrik-enerjisi-uretimi-tuketimi-kayıplar-0) Eriřim: Ocak 2018

Uygun, İ., (2015). “*Yapay Sinir Ağları Yardımıyla Enerji Sektöründe Talep Tahmini*”, Yüksek Lisans Tezi, Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul

- Uzlu, E., Kankal, M., Akpınar, A. ve Dede, T., (2014). “Estimates of Energy Consumption in Turkey Using Neural Networks with The Teaching learning-Based Optimization Algorithm”, *Journal of Energy*, 75, s. 295-303
- Üreten, S. (2005). Üretim/İşlemler Yönetimi, Stratejik Kararlar ve Karar Modelleri, 5. Baskı, Gazi Kitabevi, Ankara
- Weron, R. (2014). “Electricity Price Forecasting: A Review of The State of The Art with a Look Into The Future”, *International Journal of Forecasting*, 30, s. 1030-1081
- Yetkin, M. (2014). “Tanker Şamandıra Bağlama Sistemlerinin Yapay Sinir Ağları Tekniğiyle Optimizasyonu”, Yüksek lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul
- Yılmaz, A. (2017). Yapay Zeka. İstanbul: İnkilap Kitabevi
- Yumurtacı, Z. ve Asmaz, E., (2004). “Electric Energy Demand of Turkey for the Year 2050”, *Energy Sources*, 26, s. 1157-1164
- Yüksek, A. G., (2007). “Hava Kirliliği Tahmini YSA Çoklu Regresyon”, Doktora Tezi, Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü, Sivas
- Zeren, F. ve Ergüzel, O.Ş. (2014). “Forecast Share Prices With Artificial Neural Network in Crisis Periods”, *Journal of Business Research-Türk*, 6/3, s. 16-28
- Zhang, P. G., (2003). Neural Networks in Business Forecasting. Idea Group Publishing, USA

EKLER

EK 1a.					
Yıllar	Elektrik Tüketimi (kişi başına kWh)	GSMH İçindeki Geniş Kapsamlı Para Miktarı Oranı (Trilyon)	Kişi Başına Düşen GSMH (Bin TL)	Sanayinin GSMH İçindeki Payı (%)	Tüketici Fiyat Endeksi (2010=100)
1960	87,000	14,699	4.458,779	17,327	0,000
1961	92,000	15,208	4.402,232	17,175	0,000
1962	106,000	14,944	4.536,939	17,061	0,000
1963	115,000	14,592	4.831,225	16,953	0,000
1964	124,000	15,934	4.974,870	17,893	0,000
1965	136,000	17,721	4.994,983	19,349	0,000
1966	148,000	18,442	5.424,666	19,591	0,000
1967	161,000	19,227	5.548,357	20,426	0,000
1968	175,000	19,829	5.785,745	21,460	0,000
1969	194,000	20,862	5.880,598	22,089	0,000
1970	207,000	22,673	5.927,856	21,934	0,000
1971	229,000	23,541	6.109,930	22,722	0,000
1972	257,000	24,886	6.408,165	23,729	0,000
1973	277,000	25,382	6.460,926	23,709	0,000
1974	291,000	23,418	6.662,723	22,549	0,000
1975	358,579	23,057	6.975,824	22,557	0,000
1976	420,582	22,285	7.530,661	23,907	0,000
1977	461,684	23,237	7.613,168	23,384	0,000
1978	479,520	21,185	7.556,331	22,915	0,001
1979	488,533	19,509	7.342,539	25,643	0,001
1980	495,544	18,034	7.002,903	23,494	0,002
1981	519,201	22,488	7.177,760	26,694	0,002
1982	543,353	25,596	7.266,035	27,783	0,003
1983	555,409	25,051	7.457,419	26,629	0,004
1984	613,666	25,133	7.785,835	25,623	0,006
1985	659,748	24,446	7.947,609	26,366	0,009
1986	698,704	27,896	8.336,151	30,988	0,012
1987	771,161	29,238	8.953,206	31,394	0,016
1988	809,184	27,906	8.993,298	32,821	0,027
1989	874,748	26,815	8.859,628	32,975	0,045

EK 1b.					
Yıllar	Elektrik Tüketimi (kişi başına kWh)	GSMH İçindeki Geniş Kapsamlı Para Miktarı Oranı (Trilyon)	Kişi Başına Düşen GSMH (Bin TL)	Sanayinin GSMH İçindeki Payı (%)	Tüketici Fiyat Endeksi (2010=100)
1990	929,700	23,740	9.513,742	31,061	0,072
1991	965,308	27,090	9.421,720	31,541	0,119
1992	1.044,362	27,812	9.734,920	31,179	0,202
1993	1.115,196	25,197	10.312,386	29,823	0,336
1994	1.145,505	31,601	9.675,507	32,081	0,689
1995	1.227,328	32,156	10.273,180	32,020	1,304
1996	1.328,353	36,590	10.857,394	30,618	2,352
1997	1.439,977	37,075	11.496,473	30,780	4,367
1998	1.520,098	28,153	11.578,277	31,128	8,064
1999	1.556,336	38,150	11.013,862	28,425	13,294
2000	1.652,748	33,694	11.568,242	26,903	20,595
2001	1.613,018	44,604	10.717,280	25,597	31,798
2002	1.667,423	38,957	11.239,802	24,611	46,096
2003	1.771,924	34,231	11.700,834	24,833	56,054
2004	1.891,927	33,537	12.652,755	25,130	60,874
2005	2.013,890	39,056	13.610,849	25,302	65,853
2006	2.178,862	40,732	14.396,218	26,109	72,173
2007	2.197,818	42,070	14.939,247	26,457	78,493
2008	2.264,463	46,479	14.885,271	26,237	86,690
2009	2.162,237	52,131	14.006,216	24,056	92,109
2010	2.333,744	53,232	14.987,464	24,602	100,000
2011	2.490,492	51,015	16.407,519	26,936	106,472
2012	2.577,431	50,044	16.925,872	26,774	115,939
2013	2.583,153	52,588	18.068,112	27,696	124,626
2014	2.669,058	51,756	18.694,940	28,195	135,661
2015	2.759,836	52,717	19.518,286	27,904	146,068
2016	2.896,781	55,604	19.825,392	28,183	157,425
2017	3.081,544	54,325	20.975,486	29,158	174,969

EK 1c.					
Yıllar	İthalatın GSMH İçindeki Payı (%)	Şehir Nüfusu (Milyon)	İhracatın GSMH İçindeki Payı (%)	Elektrik Kurulu Gücü (MW)	Motorlu Kara Taşıt Sayısı
1960	3,671	8.657.905	2,056	1.272,400	174.331
1961	6,787	9.025.020	5,125	1.323,900	185.125
1962	7,970	9.398.918	5,604	1.370,800	209.607
1963	6,974	9.785.801	4,185	1.381,100	222.842
1964	5,467	10.186.257	4,473	1.418,300	227.021
1965	5,395	10.601.117	4,558	1.490,500	243.482
1966	5,665	11.084.941	4,091	1.644,300	259.250
1967	4,965	11.613.794	4,113	1.959,100	213.005
1968	5,079	12.164.205	3,683	1.966,600	349.221
1969	4,737	12.737.046	3,596	1.967,200	387.945
1970	6,361	13.334.592	4,427	2.234,900	403.454
1971	8,247	13.911.375	5,320	2.577,900	442.065
1972	8,544	14.488.541	6,019	2.711,300	508.777
1973	9,093	15.085.598	7,033	3.192,500	604.388
1974	11,275	15.701.103	5,728	3.732,100	745.486
1975	11,232	16.333.821	4,421	4.186,600	917.958
1976	10,666	16.914.559	4,859	4.364,200	1.081.187
1977	10,707	17.474.294	3,815	4.727,200	1.232.403
1978	7,289	18.048.164	4,147	4.868,700	1.371.338
1979	5,882	18.640.045	3,218	5.118,700	1.566.405
1980	11,928	19.252.658	5,162	5.118,700	1.696.681
1981	12,905	20.329.788	8,237	5.537,600	1.802.742
1982	15,017	21.630.537	11,864	6.638,600	1.901.926
1983	16,558	22.977.479	12,473	6.935,100	2.041.244
1984	19,674	24.362.096	15,607	8.461,600	2.215.174
1985	18,966	25.769.739	15,861	9.121,600	2.391.357
1986	16,102	27.034.294	13,312	10.115,200	2.641.353
1987	17,757	28.238.856	15,581	12.495,100	2.887.287
1988	17,553	29.455.629	18,654	14.520,600	3.140.265
1989	17,781	30.682.086	16,203	15.808,200	3.388.259

EK 1d.					
Yıllar	İthalatın GSMH İçindeki Payı (%)	Şehir Nüfusu (Milyon)	İhracatın GSMH İçindeki Payı (%)	Elektrik Kurulu Gücü (MW)	Motorlu Kara Taşıt Sayısı
1990	17,578	31.923.263	13,365	16.317,600	3.750.678
1991	16,635	32.891.157	13,841	17.209,100	4.101.975
1992	17,345	33.738.104	14,392	18.716,100	4.584.717
1993	19,343	34.589.934	13,674	20.337,600	5.250.622
1994	20,384	35.453.749	21,362	20.859,800	5.606.712
1995	24,351	36.333.494	19,892	20.954,300	5.922.859
1996	27,827	37.230.423	21,543	21.249,400	6.305.707
1997	30,389	38.142.741	24,582	21.891,900	6.863.462
1998	19,706	39.068.789	20,568	23.354,000	7.371.541
1999	18,824	40.002.789	18,578	26.119,300	7.758.511
2000	22,552	40.942.287	19,449	27.264,100	8.320.449
2001	22,821	41.942.709	26,578	28.332,400	8.521.956
2002	23,000	42.977.478	24,461	31.845,800	8.655.170
2003	23,358	44.014.467	22,243	35.587,000	8.903.843
2004	25,369	45.046.031	22,751	36.824,000	10.236.357
2005	24,419	46.065.671	21,018	38.843,500	11.145.826
2006	26,501	47.068.551	21,650	40.564,800	12.227.393
2007	26,069	48.059.010	21,220	40.835,700	13.022.945
2008	27,080	49.062.187	22,826	41.817,200	13.765.395
2009	23,359	50.109.357	22,574	44.761,200	14.316.700
2010	25,450	51.225.537	20,449	49.524,100	15.095.603
2011	30,401	52.415.819	22,262	52.911,100	16.089.528
2012	28,578	53.670.916	23,667	57.059,400	17.033.413
2013	28,078	54.969.310	22,272	64.007,500	17.939.447
2014	27,650	56.291.672	23,764	69.519,800	18.828.721
2015	25,954	57.616.413	23,346	73.146,740	19.994.472
2016	24,851	58.945.742	21,965	78.497,382	20.887.427
2017	29,318	60.271.313	24,804	85.200,000	22.218.945

ÖZGEÇMİŞ

Adı ve Soyadı: Gizem Özaydın

Doğum Tarihi ve Yeri: 25.07.1994 Türkiye - İzmir

E-postası: gizem.ozaydin@hotmail.com / ozaydin.gizem@gmail.com

Derece	Bölüm/Program	Üniversite	Yıl
Önlisans	İşletme Yönetimi	Ege Üniversitesi	2014
Lisans	İşletme	Dokuz Eylül Üniversitesi	2017
Y. Lisans	İşletme	İzmir Kâtip Çelebi Üniversitesi	2019

Uluslararası Hakemli Dergilerde Yayımlanan Makaleler:

Karakul, A. ve Özaydın, G. “BIST Elektrik Endeks (XELKT) Hisselerinin Finansal Performanslarının TOPSİS ve VIKOR Yöntemleriyle İncelenmesi”, Dumlupınar Üniversitesi Sosyal Bilimler Dergisi, Sayı 60, Nisan 2019, s: 68 - 86

İş Tecrübeleri:

Muhasebe Sorumlusu (Prenses Yağmur Gıda Şans Oyunları LTD. ŞTİ.)

11.2017-02.2019 (15 ay) İzmir - Türkiye

Haberleşme Sorumlusu (Polibak Plastik Film Sanayi Ve Ticaret A.Ş.)

06.2012-09.2012 (3 ay) İzmir - Türkiye Tam Zamanlı

Burslar/Projeler:

Türkiye Eğitim Vakfı (TEV) Yüksek Başarı Bursu

Ege Üniversitesi Öğrenci Destek Bursu

