



**T.C. İSTANBUL TİCARET  
ÜNİVERSİTESİ**

**FEN BİLİMLERİ ENSTİTÜSÜ**

**YAPAY SİNİR AĞLARI YÖNTEMİYLE TÜRKİYE'DE  
ELEKTRİK ENERJİSİ TÜKETİMİ TAHMİNLEMESİ**

**Havva Hilal METİN**

**Danışman  
Prof. Dr. Sibkat KAÇTIOĞLU**

**YÜKSEK LİSANS TEZİ  
ENDÜSTRİ MÜHENDİSLİĞİ ANA BİLİM DALI  
İSTANBUL - 2018**



**T.C. İSTANBUL TİCARET  
ÜNİVERSİTESİ**

**FEN BİLİMLERİ ENSTİTÜSÜ**

**YAPAY SİNİR AĞLARI YÖNTEMİYLE TÜRKİYE'DE  
ELEKTRİK ENERJİSİ TÜKETİMİ TAHMİNLEMESİ**

**Havva Hilal METİN**

**Danışman  
Prof. Dr. Sibkat KAÇTIOĞLU**

**YÜKSEK LİSANS TEZİ  
ENDÜSTRİ MÜHENDİSLİĞİ ANA BİLİM DALI  
İSTANBUL - 2018**

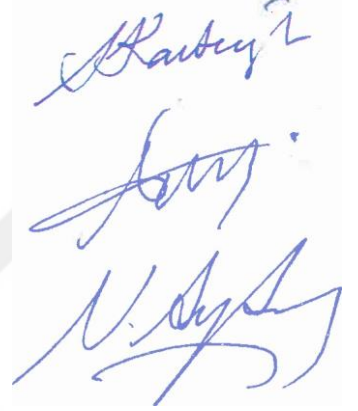
## KABUL VE ONAY SAYFASI

Havva Hilal METİN tarafından hazırlanan "YAPAY SİNİR AĞLARI YÖNTEMİYLE TÜRKİYE'DE ELEKTRİK ENERJİSİ TÜKETİMİ TAHMİNİ" adlı tez çalışması 13/07/2018 tarihinde aşağıdaki jüri üyeleri önünde başarı ile savunularak, İstanbul Ticaret Üniversitesi Fen Bilimleri Enstitüsü **Endüstri Mühendisliği Anabilim Dalı**'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

**Danışman** Prof. Dr. SİBKAT KAÇTIOĞLU  
İstanbul Ticaret Üniversitesi

**Jüri Üyesi** Dr. Öğretim Üyesi Berk AYVAZ  
İstanbul Ticaret Üniversitesi

**Jüri Üyesi** Dr. Öğretim Üyesi Nezir AYDIN  
Yıldız Teknik Üniversitesi



**Onay Tarihi : 23.07.2018**

  
Prof. Dr. Necip ŞİMŞEK  
Enstitü Müdürü

## AKADEMİK VE ETİK KURALLARA UYGUNLUK BEYANI

İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada,

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

beyan ederim.

Tarih  
23.07.2018

İmza



**Havva Hilal METİN**

## İÇİNDEKİLER

İÇİNDEKİLER .....	i
ÖZET .....	iii
ABSTRACT.....	iv
TEŞEKKÜR.....	v
ŞEKİLLER.....	vi
TABLolar .....	vii
KISALTMALAR .....	viii
BİRİMLER .....	viii
1. GİRİŞ .....	1
2. LİTERATÜR TARAMASI .....	2
3. TÜRKİYE VE DÜNYADA ENERJİ PİYASALARINA GENEL BAKIŞ.....	3
3.1. Türkiye ve Dünyada Genel Enerji Durumu .....	3
3.2. Enerji ve Ekonomik Büyüme İlişkisi .....	4
3.3. Enerji ve Nüfus İlişkisi .....	10
3.4. Enerji ve Dış Ticaret Hacmi İlişkisi.....	11
4. TÜRKİYE'DE ELEKTRİK TÜKETİMİ.....	12
5. TALEP TAHMİNİNDE KULLANILAN MODELLER.....	23
5.1. Basit Lineer Regresyon.....	23
5.2. Üstel Fonksiyonla Regresyon .....	24
5.3. Polinom Regresyon .....	24
5.4. Yapay Sinir Ağları ile Tahmin.....	24
5.5. Geri Beslemeli Ağlar .....	25
5.6. Öğrenme, Adaptif Öğrenme ve Test Etme.....	25
6. YAPAY SİNİR AĞLARI .....	27
6.1. Yapay Sinir Ağlarının Genel Özellikleri .....	27
6.2. Yapay Sinir Ağlarının Avantajları .....	29
6.3. Yapay Sinir Ağlarının Dezavantajları.....	30
6.4. Yapay Sinir Ağlarının Yapısı ve Temel Elemanları .....	31
6.4.1. Biyolojik sinir hücresi.....	31
6.4.2. Yapay sinir hücresi.....	32
6.5. Yapay Sinir Ağları Modelleri .....	33
6.5.1. İleri beslemeli ağlar.....	33
6.5.2. Geri beslemeli ağlar .....	33
6.6. Yapay Sinir Ağlarında Öğrenme Algoritmaları.....	34
6.6.1. Danışmanlı öğrenme .....	34

6.6.2. Danışmansız öğrenme .....	34
6.6.3. Takviyeli öğrenme .....	35
6.7. Yapay Sinir Ağlarında Öğrenme Kuralları .....	36
6.7.1. Hebb kuralı.....	36
6.7.2. Hopfield kuralı .....	36
6.7.3. Kohonen kuralı.....	37
6.7.4. Delta kuralı.....	38
6.8. Geri Yayılım Algoritması ve Çok Katmanlı Algılayıcılar .....	38
6.8.1. ÇKA'da ileri besleme aşaması.....	38
6.8.2. ÇKA'da geri besleme aşaması .....	40
6.9. Yapay Sinir Ağı Çalışma Prosedürü .....	40
6.10. Yapay Sinir Ağlarıyla Elektrik Tüketimi Tahmini .....	41
7. TÜKETİM TAHMİNİ UYGULAMASI .....	43
7.1. Tüketim Tahmini Probleminin Tanımlanması .....	43
7.2. Yapay Sinir Ağı Mimarisi.....	52
7.2.1. Ağın eğitilmesi.....	52
7.2.2. Verilerin normalizasyonu.....	52
7.2.3. Gizli katman ve nöron sayısının belirlenmesi.....	53
7.3. Yapay Sinir Ağı Matlab Uygulamaları .....	54
7.3.1. Öğrenme katsayısının belirlenmesi .....	55
7.3.2. Nöron sayısının ve momentum katsayısının belirlenmesi.....	56
7.4. Yapay Sinir Ağının Eğitilmesi.....	59
7.5. Sonuçların Test Edilmesi ve Değerlendirilmesi.....	65
7.6. YSA ile Tüketim Tahmini Uygulaması .....	68
7.7. Uygulama Sonucu.....	70
8. SONUÇ VE ÖNERİLER .....	75
KAYNAKLAR .....	77
ÖZGEÇMİŞ .....	82

## ÖZET

### YÜKSEK LİSANS TEZİ

## YAPAY SİNİR AĞLARI METODU İLE TÜRKİYE'DE ELEKTRİK ENERJİSİ TÜKETİM TAHMİNİ

Havva Hilal METİN

İstanbul Ticaret Üniversitesi  
Fen Bilimleri Enstitüsü  
Endüstri Mühendisliği Anabilim Dalı

Danışman : Prof. Dr. Sibkat KAÇTIOĞLU  
2018, 82 Sayfa

Dünya enerji tüketiminin önemli bölümünü geliştirmekte olan ülkeler gerçekleştirmektedir. Enerji ve Tabii Kaynaklar Bakanlığı (ETKB)'nin verilerine göre 2000 yılından bu yana elektrik ve doğalgaz tüketiminde, Çin'den sonra en çok talep artışı olan ülke konumundadır. Türkiye 1970 yılında toplam enerji üretiminin tüketimi karşılama oranı % 76 olarak gerçekleşmiştir. 2000 yılında ise oran % 35'e, 2010 yılında % 26'ya düşmüş ve 2020 yılında % 23'e düşeceği öngörülmektedir. Bu durum Türkiye'nin her geçen yıl enerji bağımlılığının arttığını ve bu bağımlılığı azaltacak çözümler geliştirmesi gerektiğini göstermektedir.

Elektrik, çok yönlü ve kolay kontrol edilen enerji biçimidir. Kullanım noktasında pratik olarak kayıpsızdır ve kirletici değildir. Üretim noktasında rüzgar, su ve güneş ışığı gibi tamamen yenilenebilir yöntemlerle temiz üretililebilir. Elektrik piyasasının diğer emtialara kıyasla benzersiz bir özelliği bulunmaktadır, bu da üretildiğinde tüketilmesi gerekliliğidir. Bu nedenle Türkiye'de ileriye yönelik elektrik tüketiminin tahmin edilmesi geleceğe yönelik stratejik planların yapılması ve gereken tedbirlerin alınması açısından önem taşımaktadır.

Türkiye'de elektrik tüketiminin tahminlemesi çalışmalarında genelde uzun dönemli elektrik enerjisi tüketimi tahmininde yapay sinir ağları (YSA) metodunun kullanıldığı gözlenmiştir. Bazı çalışmalarda YSA ile bulunan neticeler, Box-Jenkins modelleri ve regresyon tekniği ile karşılaştırılmıştır. Karşılaştırma sonucunda YSA'nın yapay sinir ağlarının elektrik enerjisi tüketiminde iyi bir tahmin aracı olduğunu göstermektedir. (Hamzaçebi (2013)) Bu çalışmamızda YSA yöntemini kullanarak elektrik tüketim talebi modellenmiş ve bulunan sonuçlar tartışılmıştır.

Uygulama çalışmamızda, Türkiye'de elektrik tüketimini etkileyen dört temel etken bağımsız değişken olarak ele alınmıştır. Bu bağımsız değişkenler; Nüfus, İthalat, İhracat, Gayri Safi Yurtiçi Hasıladır (GSYH). Bu bağımsız değişkenlerin, ülkedeki elektrik tüketimini ne ölçüde etkilediği yapılan testler sonunda bulunmuş olup, bulunan sonuçlar değerlendirilmiştir.

**Anahtar kelimeler:** Elektrik enerjisi, elektrik tüketim tahminlemesi, tahmin, yapay sinir ağları.

## **ABSTRACT**

### **Master's Thesis**

## **ESTIMATION OF THE ELECTRIC ENERGY CONSUMPTION OF TURKEY WITH ARTIFICIAL NEURAL NETWORK METHOD**

**Havva Hilal METİN**

**Istanbul Commerce University  
Institute of Science and Technology Department**

**Advisor: Prof. Dr. Sibkat KAÇTIOĞLU  
2018, 82 Pages**

A significant proportion of the world energy consumption is by developing countries. According to the data from the Ministry of Energy and Natural Resources, Turkey is the country with the greatest increase in demand after China in electricity and natural gas consumption since 2000. In 1970, the ratio of total energy production to consumption in Turkey was 76%. In year 2000, this ratio dropped down to 35%, in year 2010 to 26% and predicted to come down to 23% by year 2020. This situation indicates an increase in Turkey's energy dependency every passing year and the need to implement solutions to reduce this dependency.

Electricity is a versatile and easily controlled form of energy. Electricity is practically non-existent and non-polluting at the point of use. Electricity can be cleanly produced by completely renewable methods such as wind, water and sunlight at the production point. Electricity market has a unique feature compared to other commodities. This feature requires the consumption of electricity when it is produced. Forecasting the future consumption of electricity in Turkey is crucial in making strategic plans for the future and taking the necessary measures.

In Turkey, the consumption of electricity in the estimation studies were generally observed that the use of long-term electricity consumption prediction method of neural networks. In some studies, the results obtained by artificial neural network method are compared with Box-Jenkins models and regression technique. As a result of comparison, artificial neural networks seem to be a good predictor of electricity consumption. In this study, electrical consumption is modelled by using artificial neural network method and the results are discussed.

In the application, the four main factors that affect the electricity consumption in Turkey is considered as independent variables. These independent variables are; Population, Imports, Exports, Gross Domestic Product (GDP). How these independent variables affect the electricity consumption in the country was found as the result of the tests made and the results were evaluated.

**Key words:** Artificial neural networks, electric energy, electricity consumption estimation, prediction.



## TEŐEKKÜR

Bu arařtırma için beni yönlendiren, karşılařtıđım zorlukları bilgi ve tecrübesi ile ařmamda yardımcı olan deđerli Danıřman Hocam Prof. Dr. Sibkat Kaçtıođlu'na teőekkürlerimi sunarım.

Tezimin her ařamasında ve yařamım boyunca sevgi ve desteklerini benden esirgemeyen aileme teőekkürlerimi sunarım.

Havva Hilal METİN  
İSTANBUL, 2018

## ŞEKİLLER

Şekil 4.1. Yıllara göre elektrik toplam kurulu gücü (MW).....	13
Şekil 4.2. Yıllara göre brüt elektrik üretimi (GWh).....	14
Şekil 4.3. Yıllara göre net elektrik tüketimi (GWh).....	15
Şekil 4.4. Aylık toplam elektrik tüketimi (GWh) .....	15
Şekil 6.1. Biyolojik sinir sistemi.....	32
Şekil 6.2. Yapay sinir hücresi .....	33
Şekil 7.1. 1975-2016 Nüfus değişkeni.....	45
Şekil 7.2. İthalat hacmi değişimi 1975 – 2016.....	47
Şekil 7.3. İhracat hacmi değişimi 1975 – 2016.....	49
Şekil 7.4. Gayri safi yurt içi hasılanın değişimi 1975 – 2016.....	50
Şekil 7.5. Türkiye’de yıllara göre net elektrik tüketimi 1975 – 2016.....	51
Şekil 7.6. Matlab’ta yeni ağ yaratma penceresi .....	60
Şekil 7.7. Yapay Sinir Ağı Gösterimi .....	61
Şekil 7.8. Matlab’ta YSA eğitim ekranı.....	61
Şekil 7.9. Matlab’ta YSA eğitim sonuç ekranı .....	62
Şekil 7.10. Eğitim, doğrulama ve test kümelerine ilişkin hata performansları .....	63
Şekil 7.11. Matlab’ta öğrenme, doğrulama ve test kümelerine ilişkin regresyon grafiği .....	64
Şekil 7.12. Matlab’ta YSA test ekranı .....	66
Şekil 7.13. YSA ile bulunan tahmini değerler ile gerçek değerlerin grafik gösterimi .....	67
Şekil 7.14. Matlab’ta YSA test ekranı_2017-2030 dönemine ilişkin elektrik tüketimi tahmini için.....	69
Şekil 7.15. YSA ile oluşturulan elektrik tüketimi tahmini ile ETKB tarafından oluşturulan elektrik tüketimi projeksiyonu karşılaştırması .....	74

## TABLolar

Tablo 3.1. Çalışmada kullanılan değişken çiftleri .....	6
Tablo 4.1. Türkiye'nin toplam kurulu gücü, brüt elektrik üretimi, net elektrik tüketimi.....	12
Tablo 4.2. Elektrik tüketimi - Sektörlere göre oransal dağılımı, 1975-2016, Türkiye.....	17
Tablo 4.3. Tüketici sayısının tüketici türü bazında dağılımının dönemler arası karşılaştırılması .....	19
Tablo 4.4. Tüketici sayısının dağıtım bölgesi bazında dağılımının dönemler arası karşılaştırılması .....	20
Tablo 4.5. Tüketici sayısının il bazında dağılımının dönemler arası karşılaştırılması.....	21
Tablo 7.1. Nüfus değişimi, Türkiye, 1975-2016.....	44
Tablo 7.2. İthalat hacmi, Türkiye, 1975-2016 .....	46
Tablo 7.3. İhracat hacmi, Türkiye, 1975-2016.....	48
Tablo 7.4. GSYH, Türkiye, 1975-2015 .....	50
Tablo 7.5. Matlab programlama dili - YSA metodu'na ilişkin kabul parametreleri .....	54
Tablo 7.6. YSA metodunda kullanılacak parametrelerin kabul değerleri.....	55
Tablo 7.7. Öğrenme katsayısının tespiti için yapılan denemeler .....	56
Tablo 7.8. Nöron sayısı ve momentum katsayısı tespiti için yapılan denemeler örneklemeşi .....	57
Tablo 7.9. YSA parametreleri .....	65
Tablo 7.10. YSA sonucu bulunan tahmini değerler ile gerçek değerlerin karşılaştırılması... 67	67
Tablo 7.11. Girdi verilerinin 2017 – 2030 yıllarına ilişkin tahminleri.....	68
Tablo 7.12. Normalize tahminden gerçek değerlere dönüştürülen 'tahmini elektrik tüketim' verileri .....	70
Tablo 7.13. Çalışmamızın ve bu konuda yapılmış olan diğer çalışmaların tahmin performanslarının karşılaştırılması .....	72
Tablo 7.14. ETKB elektrik enerjisi talep projeksiyonu sonuçları-yıllık .....	73
Tablo 7.15. YSA metodu ile üretilen tahmin ile ETKB'nin üretimde üretilmiş olan geleceğe yönelik elektrik tüketimi karşılaştırması .....	73

## KISALTMALAR

ABD	: Amerika Birleşik Devletleri
ABD \$	: Amerikan Doları
Ar-Ge	: Araştırma ve Geliştirme
BP	: Back Propagation (Geri yayılım)
ÇKA	: Çok Katmanlı Ağlar ( Multi-Layer Networks)
ECM	: Error Correction Model (Hata Düzeltme Modeli)
EIA	: Energy Information Administration (Enerji Bilgi Yönetimi)
EPK	: Elektrik Piyasası Kanunu
ETKB	: Enerji ve Tabii Kaynaklar Bakanlığı
GDP	: Gross Domestic Product
GSYH	: Gayri Safi Yurtiçi Hasıla
IEA	: International Energy Agency (Uluslararası Enerji Ajansı)
MAE	: Mean Absolute Error (Ortalama Mutlak Hata)
MAPE	: Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hata)
MDP	: Markov Decision Process (Markov karar süreci)
MSE	: Mean Squared Errors (Hata Kareler Ortalaması)
OECD	: Organisation for Economic Co-operation and Development (Ekonomik İşbirliği ve Kalkınma Örgütü)
RGSYİH	: Reel Gayri Safi Yurt İçi Hasıla
RL	: Reinforcement Learning (Takviyeli Öğrenme)
RMSE	: Root of Mean Squared Errors (Hata Kareler Ortalamasının Karekökü)
SSE	: Sum of Standart Errors (Hata Kareleri Toplamı)
TEİAŞ	: Türkiye Elektrik İletim A.Ş.
TÜİK	: Türkiye İstatistik Kurumu
VAR	: Vector Autoregression (Vektör Özbağlanım Modeli)
YSA	: Yapay Sinir Ağları

## BİRİMLER

GW	: GigaWatt ( $1GW = 10^3MW = 10^6KW = 10^9W$ )
GWh	: GigaWatt Saat ( $1GWh = 10^3MWh = 10^6KWh = 10^9Wh$ )
MW	: MegaWatt ( $1MW = 10^3 KW = 10^6W$ )

# 1. GİRİŞ

Enerji sektörü, özellikle ekonomik açıdan gelişmekte olan ülkeler için oldukça önemli bir sektördür. Enerji sektörünün küresel ekonomi bağlamında çok önemli bir rol oynadığı da görülmektedir. Petrol fiyatları ve diğer enerji kaynakları gelişmekte olan bazı ülkelerin ekonomilerini etkilemekte ve bu ülkelerin ekonomilerinin şekillendirilmesinde önemli roller oynamaktadır. Türkiye'nin enerji ithalatı bağımlılığı, artan enerji talebi nedeniyle artmaktadır. Şu anda Türkiye, birincil kaynakların üretim ve tüketim dengesi açısından sadece %28'ini karşılayabilmektedir (Yılmaz, 2012, s. 33).

Elektrik enerjisi ise, çok yönlü ve kolay kontrol edilen bir enerji biçimidir. Kullanım noktasında pratik olarak kayıpsızdır ve kirletici değildir. Üretim noktasında rüzgar, su ve güneş gibi tamamen yenilenebilir kaynaklardan üretilebilen temiz enerji türüdür. Türkiye Elektrik İletim A.Ş. (TEİAŞ) tarafından yapılan son yedi yıllık projeksiyonlarda, yüksek talep varsayımı altında tepe değer talebi 2020 yılında karşılanamaz hale gelmektedir.

Elektrik piyasasının diğer emtialara kıyasla benzersiz bir özelliği; üretildiği anda tüketilmesi gerekliliğidir. Bu nedenle elektrik piyasasının koşulları kendine özgüdür.

Türkiye, enerji piyasasının özelleştirme ve serbestleştirilmesini içeren bir reform programını da başlatmıştır. 2001 yılında 4628 sayılı Elektrik Piyasası Kanunu (EPK) yürürlüğe girmiş ve tüketiciye maliyet etkinliğiyle yüksek kaliteyi sağlamak için düzenleyici çerçeveyi oluşturmuş ve piyasayı dengelemek ve denge fiyatını elde etmek için elektriğin talep tahmini önemli hale gelmiştir.

Türkiye ve dünya ekonomisindeki dalgalanmalar nedeniyle, elektrik tüketiminin kaotik ve doğrusal olmayan bir eğilimi vardır. Bu nedenle, net elektrik tüketimi ile ilgili tahmin çalışmaları, özellikle enerji talebinin hızla arttığı ülkeler için enerji politikasının belirlenmesinde hayati öneme sahiptir.

## 2. LİTERATÜR TARAMASI

Literatürde yer alan çalışmalarda YSA ve nöral bulanık mantıklar gibi elektrik tüketim talebini tahmin etmek için çeşitli yöntemler kullanılmıştır. Literatürde ayrıca, AutoRegressive Integrated Moving Average ve Error Correction modelleri (ECM), pürüzsüzleştirme yöntemleri, ayrıştırma ve hibrid yaklaşımlar yöntemi ve ayrıştırma ve zaman serisi modelleri nin yer aldığı çalışmalar da mevcuttur (Lu, Wang, Wang, Yan, & Lam, 2004, p. 79). Bu çalışma, YSA yöntemini kullanarak elektrik tüketim talebini modellemeyi amaçlamaktadır.

Literatüre bakıldığında (Sözen, Arcaklioğlu, & Özkaymak , 2005), Türkiye’de enerji tüketimini öngören Yapay Sinir Ağı modeli çalışmaları yürütmüştür. (Akay & Atak, Grey prediction with rolling mechanism for electricity demand forecasting of Turkey, 2007) Elektrik enerjisinin tüketimini tahmin etmek için bir yuvarlanma mekanizmasına sahip bir gri tahmin metodu kullanmışlardır. (Kavaklioglu K. , Ceylan, Ozturk, & Canyurt, 2009) Türkiye’de net enerji modelini tahmin etmek için bir Yapay Sinir Ağı modeli önerdi. 1975-2006 dönemi elektrik tüketim tahmininde kullanılan değişkenler; nüfus, gayri safi milli hasıla (GSMH), ithalat ve ihracat. (Kavaklioğlu, Modeling and prediction of Turkey’s electricity consumption using Support Vector Regression, 2011) Support Vector Regression (SVR) metodolojisi ile Türkiye’de elektrik tüketimini tahmin etmiştir. (Çunkaş & Taşkıran, 2011) Genetic Algoritmalar yöntemi ile Türkiye’de elektrik tüketimini tahmin etmiştir. (Hamzaçebi & Es, 2014) Optimize 2013-2025 yıllarında Türkiye’deki toplam elektrik enerjisi talebini tahmin etmek için tekrarlanabilir bir gri modelleme önermiştir. (Kaytez, Taplamacioglu, Cam, & Hardalac, 2015) least squares support vector machines (LS-svms) yöntemi ile Türkiye’de elektrik tüketimini tahmin etmiştir.

Türkiye ve dünyada elektrik enerjisinin durumu, enerji ve ekonomik büyüme ve çeşitli verilerle ilişkisi araştırılmış, yapay sinir ağları ve tüketim tahmini uygulamasına yer verilmiştir.

### 3. TÜRKİYE VE DÜNYADA ENERJİ PİYASALARINA GENEL BAKIŞ

Küresel piyasanın çeşitli olumsuzluklardan etkilendiği bu dönemde, dünyanın özellikle gelişmekte olan ülkelerin ekonomik ve sosyal ilerlemeyi desteklemek ve daha iyi bir yaşam kalitesi oluşturmak için enerjiye ihtiyaç duymaktadır. Bu bölümde Türkiye ve dünyada genel enerji durumu; ekonomik büyüme, nüfus ve dış ticaret hacmi değişkenleri ile ilişkilendirilerek açıklanacaktır.

#### 3.1. Türkiye ve Dünyada Genel Enerji Durumu

Dünyanın enerji gereksiniminin büyük bir bölümü petrol sayesinde giderilmektedir. Petrolün ardından kömür, doğal gaz, hidroelektrik, nükleer ve yenilenebilir enerji kaynakları gelmektedir. 2035 tahmini incelendiğinde, kömüre değil çevreye zarar vermeyen doğal gazın ikinci büyük kullanım alanına egemen olarak kömürün sırasını alacağı ön görülmektedir (Zachariadis, 2007, p. 1233).

Dünya enerji tüketiminin önemli bölümünü geliştirmekte olan ülkeler gerçekleştirmektedir. Gelişmekte olan ülkelere birisi olan Türkiye, enerji talebinin en çok arttığı ülkelerin başında gelmektedir. ETKB'nin verilerine göre Türkiye'de 1990-2008 yılları arasında birincil enerji talebi artışı dünya ortalamasının 3 katı olarak % 4,3 düzeyinde gerçekleşmiştir. Diğer yandan, 2000 yılından bu yana elektrik ve doğalgaz tüketiminde, Çin'den sonra en çok talep artışı olan ülke konumundadır (ETKB, 2009, s. 6). Türkiye 1970 yılında toplam enerji üretiminin tüketimi karşılama oranı % 76 olarak gerçekleşmiştir. 2000 yılında ise oran % 35'e, 2010 yılında % 26'ya düşmüş ve 2020 yılında % 23'e düşeceği öngörülmektedir (ETKB, 2010, s. 5). Bu durum Türkiye'nin her geçen yıl enerji bağımlılığının arttığı ve bu bağımlılığı azaltacak çözümler geliştirmesi gerektiğini göstermektedir.

Yıllık enerji tüketiminin artırılması, kıt bir kaynak olan enerji kaynaklarının daha verimli kullanılmasını ihtiyaç haline getirmiştir. Bu nedenle enerji tüketiminin

azaltılması son yıllarda ele alınacak en önemli konulardan biri olarak görülmektedir. Teknolojik imkânlarla daha az enerji tüketerek çıktı elde etmek mümkündür. Bu da üretim maliyetlerini düşürmektedir. Mesela, son yıllarda beyaz eşyalarda görülen A +, A ++ gibi teknolojilerin uygulanması sonucu enerji tasarrufu sağlanmaktadır. Enerji gereksiniminin artışı en aza indirmeyi amaçlayan bu çalışmalar, dünya enerji üretimi ve tüketimine direkt olarak etki etmektedir. 40-50 yıl sonra en çok kullanılan enerji kaynağı olan petrolün tükeneceği üzerine yapılan araştırmalar bu çalışmaların ciddiyetini göstermiştir. Özel sektörün ve kamu sektörünün Ar-Ge çalışmaları, dünyanın her yerinde daha verimli enerji kullanımı için yürütülmektedir.

1980 sonrası ülkemizde hızlı nüfus artışı ve endüstriyelleşme ile enerji talebi ve tüketimi hızla artmıştır. 2008 krizinin etkileri Türkiye’de 2009 yılında enerji tüketiminde azalma görülmüş ve bu azalma ile birlikte sanayi sektöründe daralma gerçekleşmiştir. 2010 yılı itibari ile Türkiye enerji tüketiminin yaklaşık yüzde 83’ünü ithal ederek karşılamaktadır. Bu ithalatın cari açığıdaki payı yüzde 70 civarındadır (Yanar & Kerimoğlu, 2011, s. 191).

Bu pay cari açıkta 54 milyar dolar gibi önemli bir yere sahip olmakla birlikte oluşan yüksek maliyetten dolayı teknoloji ithalatı yeterli düzeyde gerçekleşmemektedir. Enerji tüketimi en fazla sanayi sektörünü etkilemekle birlikte tarım ve hizmetler sektörü için de önemlidir. Türkiye’de tarımda kullanılan enerji girdisinin tamamına yakını ithal edildiği için maliyetler yükselmektedir. Bu sebeple birçok tarım ürünü artık üretilmemekte, yurt dışından ithal edilmektedir. Türkiye 2014 yılı itibari ile dünya toplam birincil enerji tüketiminin yalnızca %1’ini gerçekleştirmektedir (World Bank, 2018, s. 1), (BP, 2015, s. 17).

### **3.2. Enerji ve Ekonomik Büyüme İlişkisi**

Enerji tüketimi ile ekonomik büyüme arasında bir ilişkinin yönü üzerine yapılan çalışmalarda, farklı bakış açıları ile değerlendirmeler yapılmaktadır. Bu araştırmalar daha önce yapılan ekonometrik analizlere bağlı olarak ülkelerin gelişim düzeylerine dayanarak değerlendirilmiştir.



Ülkeler için gelişim seviyelerine göre, enerji tüketimi ile büyüme arasındaki ilişkiyi değerlendiren çalışmalar dikkate alındığında sonuçların oldukça farklı olduğu görülmektedir. Farklı sonuçlara yol açan faktörler genelde ekonometrik yöntem, değişken sayısı, gözlem sayısı ve zaman fiktörleridir. Buna ek olarak, modele dahil edilmesi gereken veya enerji ile büyüme değişkenleri arasında yapılan eşleştirmeler de nihai sonuca etki edebilmektedir.

G-11 ülkeleri için (ABD, Birleşik Krallık, Almanya, Fransa, İtalya, Kanada, Japonya, Belçika, İsveç, İsviçre ve Hollanda) enerji tüketimi ve gayri safi yurt içi hasıla (GSYH) arasındaki ilişki araştırılmıştır. Araştırmada, Almanya için 1971-2001 dönemi, Kanada için 1965-2001 dönemi ve diğer ülkeler için 1960-2001 dönemi ele alınmıştır. Değerlendirilen değişkenler reel gayri safi yurt içi hasıla (RGSYİH) ve kişi başı enerji tüketimidir. Vector Autoregression (VAR) ekonometrik metodun incelenmesinde, ABD'deki ekonomik büyümenin enerji tüketimi ile birlikte büyüdüğü, İsviçre, Hollanda, Belçika ve Kanada'daki enerji tüketimi artarken tersine sonuç vermediği neticesi bulunmuştur. Bu sonuca göre, beş ülkedeki enerji tasarrufu olumsuz olarak sayılırsa büyümeye negatif açıdan tesirde bulunmaktadır. Fransa, İtalya ve Japonya'da büyümenin enerji tüketimini artırdığı sonucuna ulaşılmıştır. Bu sonuca bakıldığında, sürdürülebilir kalkınma için düşük karbon dioksit emisyonu sağlayan katı yakıt teknolojilerinin kullanılabilmesi ve büyümenin enerji tasarrufu üzerinde çok az veya hiç etkisinin olmadığı öngörülmüştür. Almanya, İngiltere ve İsveç'te tarafsız bir nedensellik ilişkisi bulunmuştur. Bu şekilde enerji tasarruf politikalarının ekonomik büyüme riskine girmeden uygulanabileceği belirtilmiştir. G-7 devletlerinde 1960-2004 dönemi verileri kullanarak enerji tüketimi ve ekonomik büyüme arasındaki ilişkiyi araştırmıştır. Toda Yamamoto'nun nedensellik testinin çalışmasında kullanılan ekonomik büyüme ve enerji çiftleri Tablo 3.1'de gösterilmiştir;

Tablo 3.1. Çalışmada kullanılan değişken çiftleri (Zachariadis, 2007)

<b>Enerji değişkeni</b>	<b>Ekonomik değişken</b>
Toplam birincil enerji tüketimi	RGSYİH
Toplam nihai enerji tüketimi	RGSYİH
Konut nihai enerji tüketimi	Reel kullanılabilir gelir veya hane halkının nihai tüketim harcamaları
Sanayi sektörü nihai enerji tüketimi	Sanayi sektörü reel katma değeri
Hizmetler sektörü nihai enerji tüketimi	Hizmetler sektörü reel katma değeri
Ulaşım sektörü nihai enerji tüketimi	RGSYİH

Ulaşılan sonuçlara göre, herhangi bir ülkenin nedensellik yönü ve varlığı ile ilgili sonuçlar net değildir. Araştırmalarda kullanılan örnek hacim, test yöntemi ve farklı dönemlerin sonucu nedensellik yönündeki farkı kısmen açıklayabilmektedir.

(Narayan & Smyth, 2008, s. 2331), G-7 ülkelerinde endüstriyel elektrik tüketimi ile RGSYİH arasındaki ilişkiyi araştırmışlardır. Değerlendirilen değişkenlerin büyüme oranları rapor edilmiştir. Model, Amerika Birleşik Devletleri (ABD) dışındaki G-7 ülkeleri için 1960-2002 dönemi ve ABD için 1970-2002 dönemi yıllık verilerinden yararlanılarak yapısal VAR ekonometrik yöntemi ile öngörülmüştür. Çalışma, ABD dışındaki diğer G-7 ülkelerindeki elektrik tüketiminin, kısa vadede RGSYİH üzerinde istatistiksel olarak önemli bir pozitif etki yarattığı, yani elektrik tasarrufu politikalarının RGSYİH'yi olumsuz etkileyeceği bulgusuna ulaşılmıştır. Ayrıca İtalya dışındaki diğer G-7 ülkelerinde RGSYİH arttıkça elektrik talebi de artmıştır. Böyle bir sonuca göre ilk olarak, politikacılar elektrik tüketimini tahmin ederken RGSYİH'nin elektrik tüketimi üzerindeki etkisini modellemiş ve ikincisi, yüksek büyüme oranlarına sahip ekonomilerde elektrik tüketiminin dağıtım ve etkin yönetimi için faydalı olacağını önermektedir.

(Menyah & Wolde-Rufael, 2010, s. 1374) dokuz gelişmiş ülkede 1971-2005 döneminde nükleer enerji tüketimi ile büyüme arasında nedensel bir ilişki olduğunu araştırmışlardır. Çalışma; enerji tüketimi ve RGSYİH değişkenlerine ek olarak, sermaye ve istihdam değişkenlerini modele eklemiştir. Ekonometrik yöntem olarak Toda ve Yamamoto tarafından geliştirilen Granger nedensellik testine başvurulmuştur.

Çalışmanın sonuçlarına göre Japonya, Hollanda ve İsviçre’de nükleer enerji tüketiminden büyümeye doğru, Kanada ve İsveç’te büyümeden nükleer enerji tüketimine doğru tek yönlü nedensellik bulunmuştur. Kanada’dan farklı olarak İsveç’te nükleer enerji tüketimi büyüme ile negatif ilişkilidir. Bu yüzden nükleer enerji sektörünü daha etkin hale getirmeye ihtiyaç vardır. İspanya, İngiltere ve ABD’de nükleer enerji tüketimindeki artışlar ekonomik büyümeye neden olur. Bu durumda alınan enerji tasarruf tedbirleri ekonomik büyümeyi negatif olarak etkiler. Fransa, Japonya, Hollanda ve İsviçre’de nükleer enerji tüketimindeki artışlar ekonomik büyümede bir düşüşe neden olduğu için, enerji tasarruf tedbirleri nükleer enerji tüketiminin ekonomik büyüme üzerindeki zıt etkilerini hafifletmeye yardım edebilir. Kanada ve İsveç’te nükleer enerji tüketimini azaltmak için alınan enerji tasarruf tedbirleri ekonomik büyümeye zarar vermeyebilir.

(Lee & Chien, 2010, s. 564), G-7 ülkelerinde enerji tüketimi, sermaye stoku ve reel gelir arasındaki ilişkiyi incelemişlerdir. Çalışmada ilişkiyi ortaya koyabilmek için Granger nedensellik testi, genelleştirilmiş etki tepki analizi ve varyans ayrıştırma ekonometrik yöntemleri kullanılmıştır. Genelleştirilmiş etki tepki analizi ve varyans ayrıştırma yöntemleri G-7 ülkelerinde söz konusu değişkenler arasındaki dinamik bağlantıları tespit etmek için kullanılmıştır. Veri seti 1960-2001 dönemini kapsamaktadır. Kullanılan değişkenler toplam RGSYİH, toplam enerji tüketimi ve reel sermaye stoku olup, yıllık değerlerdir. Çalışma sonucunda şu bulgulara ulaşılmıştır. Birincisi, sermaye stokunun ekonomik büyüme üzerindeki etkisi enerji tüketimi ile karşılaştırıldığında oldukça yüksektir. Reel gelir eşitliğinde bütün değişkenlerin nispi gücü değerlendirildiğinde, ABD hariç bütün ülkelerde enerjinin reel gelir üzerindeki etkisi, sermaye stokunun etkisinden daha küçüktür. İkincisi, enerji stoğu, İtalya, ABD, İngiltere ve Kanada’da reel gelir üzerinde önemli pozitif etkiye sahiptir. Ama diğer üç ülkede sonuç önemli değildir. Reel gelir şokunun enerji tüketimi üzerindeki etkisi yalnızca Kanada ve ABD’de pozitiftir. Üçüncüsü, Kanada, İtalya ve İngiltere’de enerji tüketiminden RGSYİH’ya doğru tek yönlü bir ilişki bulunmuştur. Buna göre enerji tasarrufu bu üç ülkede ekonomik büyümeyi olumsuz yönde etkiler. Fransa ve Japonya’da büyümeden enerji tüketimine doğru nedensellik ilişkisi bulunmuştur.

Bu durumda uygulanacak enerji tasarrufu ekonomik gelişmeyi olumsuz etkilemeksizin bu iki ülkede uygulanabilir. Almanya ve ABD için ise değişkenler arasında bir nedensellik bulunamamıştır. Bu sonuç nötr hipotezini destekler. Bu ekonomilerde büyüme, enerji kullanımını etkilemez. Öte yandan Fransa, Japonya, Almanya ve ABD’de enerji tüketimi büyümeyi etkilemediği için, enerji politikasını idare edenlerin karbondioksit emisyonuna dikkat etmeleri önemlidir. Dördüncüsü, enerji tüketiminin etkisinin, sermayenin tam kullanımı durumunda, ABD hariç bütün ülkelerde reel sermayenin etkisinden daha küçüktür. Ampirik sonuçlara göre ABD’de enerji tüketiminin etkisinin sermayenin eksik kullanımı durumunda, reel sermaye stokunun etkisinden daha küçüktür. Daha önceki çalışmalarla karşılaştırıldığında bulunan sonuçlar, sermaye stokunun nispi olarak enerji girdisinden daha önemli olduğunu gösterir. G-7 ülkelerinde sermaye stoku bol ve nispi olarak ucuz bir faktör olmasına rağmen, sonuçlar, yüksek ekonomik büyüme oranını sürdürmek için bu ülkelerin yine de sermaye stokunda artışa ihtiyaç duyduğunu gösterir.

(Tugcu, Ozturk, & Aslan, 2012, s. 1942) çalışmalarında 1980-2009 dönemi G-7 ülkelerinde yenilenebilir ve yenilenemez enerji tüketimi ile ekonomik büyüme arasındaki uzun dönemli ilişkiyi araştırmayı amaçlamıştır. Bunu üretim fonksiyonunu klasik ve genişletilmiş haliyle kullanarak ve yenilenebilir ve yenilenemez enerji kaynakları arasında karşılaştırma yaparak gerçekleştirmeye çalışmıştır. Çalışmada RGSYİH, reel gayri safi sabit sermaye birikimi, işgücü, kamu ve özel yükseköğretim kurumlarında kayıtlı tam ve yarı zamanlı toplam öğrenci sayısı, Avrupa Patent Ofisine yapılan patent başvurularının toplam sayısı, Patent İşbirliği Anlaşması altında yapılan patent başvuruları ile yenilenebilir ve yenilenemez enerji tüketimi değişkenleri kullanılmıştır. Granger nedensellik ilişkisine bakılarak elde edilen sonuçlar şöyledir: Yenilenebilir enerji kaynakları ile büyüme arasında nedensellik ilişkisi gözlemlenmiştir. Fakat bu sonuca, klasik üretim fonksiyonu ve yenilenebilir enerji kaynağı kullanıldığında Kanada, Fransa ve Japonya dahil değildir. Öte yandan klasik üretim fonksiyonu ve yenilenemeyen enerji tüketimi değişkeni kullanıldığında bütün ülkeler için geri besleme hipotezi

geçerlidir. Yani yenilenemeyen enerji tüketimi ile ekonomik büyüme arasında iki yönlü nedensellik ilişkisi mevcuttur. Ayrıca genişletilmiş üretim fonksiyonu ve yenilenebilir enerji kaynağı kullanıldığında Fransa, Almanya ve İngiltere için bu ilişki gözlemlenmemiştir. Genişletilmiş üretim fonksiyonu kullanıldığında yenilenemeyen enerji kaynağı ile ekonomik büyüme arasında Japonya hariç diğer ülkelerde nedensellik ilişkisi mevcut değildir. Japonya için büyüme hipotezi geçerlidir. Kısa dönemde yenilenemeyen enerji tüketiminden büyümeye doğru nedensellik ilişkisi tespit edilmiştir. Genişletilmiş üretim fonksiyonu kullanıldığında, yenilenebilir enerji tüketimi ile büyüme arasında Fransa, İtalya, Kanada ve ABD’de nedensel ilişki bulunamazken, Almanya için korunum hipotezi ve İngiltere ile Japonya için ise geri besleme hipotezi geçerlidir.

İnsanoğlunun taşıma kapasitesi için ölçüt Gayri Safi Yurtiçi Hasıla (GSYH)’dır. GSYH insan nüfusunun ve kişi başına tüketimin bir göstergesidir. Bir diğer ifadeyle GSYH insan ekonomik hacminin yani toplam mal ve hizmet üretim ve tüketim seviyesinin makul iyi bir göstergesidir. Bunun gibi ekonominin hacminin ekosistemin hacmine oranlanmasında iyi bir başlangıç noktasını oluşturur. Burada GSYH fiziksel bir ölçüt olarak değil değer olarak düşünülür. GSYH fiziksel mal ve hizmetlerin değer olarak toplamıdır. Ölçek konusu, ekonomi/ekoloji ilişkisinin kirlilik, kalabalık ve iklim istikrarı gibi bütün yönlerini kapsar. Yani biyolojik çeşitliliğin korunması önemli bir yöndür (Stern, 1993, s. 137).

Burada son olarak şuna değinmekte fayda var ki enerji ve ekonomi ilişkisi, kaynak ekonomisi ve çevre ekonomisi birbirine yakın olmakla birlikte farklı kavramlardır. Kaynak ekonomisi ve çevre ekonomisi neoklasik ekonominin alt alanlarıdır. Bu iki ekonomi ölçek konusunu düşünmez. Hammadde (madde ve enerji) kavramlarına sahip değildirler. Bölüşümde etkinlik konusu üzerine odaklanmışlardır. Kaynak ekonomisi, maden endüstrisinde kullanılan emek ve sermayenin bölüşümünde etkinlik konusyla ilgilendir. Çevre ekonomisi de bölüşümde etkinlik ve onun dışsal kirlilik tarafından nasıl bozulduğu üzerinde yoğunlaşır. Çeşitli kavramlar geliştirmelerine rağmen, sürdürülebilir ölçekte olmasa bile bölüşüm etkinliği çevre ekonomisinin de amacıdır. Ekolojik ekonomi kaynak ve çevre ekonomilerini,

hammadde kavramıyla nüfusun azalmasını ilişkilendirerek birbirine bağlar. Ekolojik ekonomi, dikkatleri, ekosistemin geri kalanı üzerine çeker. Kirliliğe, doğal kaynakların tükenmesine, entropik bozulmaya ve hepsinden daha önemlisi insan ekonomisinin büyümesine neden olan ekonomik aktiviteler ekosistemin geri kalanını etkiler (Daly, 2007, s. 27).

### **3.3. Enerji ve Nüfus İlişkisi**

Birleşmiş Milletler Nüfus Bölümü, 2050 yılında 9 milyar insandan oluşan küresel bir nüfusu öngörmektedir. Bu verilerle, dünyanın iki ana enerji ajansı olan Uluslararası Enerji Ajansı (IEA) ve Enerji Bilgi Yönetimi (EIA), enerji tüketimindeki geçmiş ve mevcut eğilimleri değerlendirerek gelecekte ne kadar enerji ihtiyacı ortaya çıkacağını tahmin etmektedir. Bu nedenle nüfus artışı, enerji tüketim tahminlerini belirlemektedir. Dünya nüfusunun büyüklüğü ve büyümesi, enerji talebini beklenenden daha az etkilediğine dair görüşler olsa da nüfus-enerji bağlantısının kapsamı ne olursa olsun, artan enerji kullanımının, temeldeki enerji kaynağı tabanının sürdürülebilirliğini tehdit ettiği endişesi bulunmaktadır (Zabel, 2009, s. 1).

Nüfus arttıkça enerji tüketimi artmaktadır. Öte yandan, enerjinin mevcudiyeti, nüfusun büyümesine olanak sağlar. Enerji tüketimi ve enerji kaynakları talebi enerji kaynağı çıkarmada deneyimleri azalan marjinal getiriye ortaya çıkarmaktadır. Bu, yeni enerji kaynaklarının sömürülmesine yol açar ve bu da dünyanın taşıma kapasitesini, ardından nüfusu artırır. Nüfus büyüklüğünün enerji talebi üzerindeki etkisinin ele alınması için, nüfus ve enerji arasındaki bağın iki ara bağlantı unsuru içermesi gerçeğinin farkına varılmalıdır. İlk bağlantı, kişi başına düşen gelir veya GSYH yaklaşımıyla ekonomik kalkınmadaki seviyeler ile ilgilidir. Bir bölgenin kişi başına düşen geliri ne kadar büyük olursa, kişi başına düşen enerji tüketimi de o kadar büyüktür: Dünyadaki gelişmekte olan ülkelerin kişi başına düşen GSYH ve enerji tüketimi, sırasıyla, sanayi bölgelerinin yalnızca sekizde biri kadardır. Bu eşitsizliğe rağmen, gelişmekte olan bölgelerin (dünya toplamının dörtte üçünden fazla) büyük nüfus büyüklüğü göz önüne alındığında, mutlak enerji tüketimi ve GSYH miktarı nispeten büyüktür (Darmstadter, 2004, s. 24).

### 3.4. Enerji ve Dış Ticaret Hacmi İlişkisi

Araştırmacılar büyüme ve gelişmenin, büyüme sürecine göre artan makroekonomik değişkenler arasındaki dinamik ilişkilere ilgilerini yönlendirmek için çeşitli ekonomik değişkenleri ele almaktadır. En önemli makroekonomik değişkenlerden üçü çıktı, enerji tüketimi ve ticarettir. İlgili değişkenler de dahil olmak üzere literatürün incelenmesi ve bunların çift yönlü bağlantıları, en geniş çalışma alanlarının, üretim-üretim büyümesi ile bağlantılı olarak enerji tüketimi-çıktı büyüme katsayısı olduğunu göstermektedir (Dedeoğlu & Kaya, 2013, s. 469).

1970'lerde özellikle petrol krizinden sonra enerjinin önemi oldukça artmıştır. Enerji, üretim faktörü olarak görülmeye başlanmış ve üretim fonksiyonlarına dahil edilmiştir. Üretim süreci bir bütün olarak maddenin dönüşümü ve hareketini içerdiğinden, neredeyse tüm üretim süreçleri enerji gerektirir. Buna göre, ticaretin genişlemesi enerji tüketimini artırmaktadır. Ek olarak, ihraç edilen malların taşınması da enerji gerektirir. (Sadorsky, 2012, s. 476) araştırmasında tartışıldığı gibi ihracattaki artış, ihracata yönelik ve ilgili sektörlerdeki ekonomik aktiviteyi arttırmakta ve bu da enerji talebini artırmaktadır.

Ayrıca, ithalatın ithal malların taşınması için enerji kullanımını gerektirmesi nedeniyle, ticaret girişlerindeki artış enerji tüketiminde artışa neden olmaktadır. 2009 yılında Ekonomik İşbirliği ve Kalkınma Örgütü'ndeki (OECD) toplam nihai enerji tüketiminin yaklaşık üçte biri olacağı rapor edilmektedir (IEA, 2011, s. 2). Buna ek olarak, özellikle de ithalat, otomobiller, makineler, bulaşık makineleri, klimalar vb. gibi enerji yoğun ürünler olduğunda, ithalat bileşimi enerji kullanımını artırabilecek bir başka faktördür. Enerji yoğun malların ithalatı ne kadar fazla olursa, enerji talebi de o kadar fazladır.

## 4. TÜRKİYE’DE ELEKTRİK TÜKETİMİ


Türkiye’de elektrik tüketimi teknolojinin gelişimi ve çağa ayak uydurmanın getirileri sebebiyle gün geçtikçe artmaktadır. Fakat elektrik üretimi konusunda hala büyük problemler bulunmaktadır. Bu açıdan gerekli olan elektrik miktarını tahmin edip ona göre bir yol haritasının çizilmesi büyük önem arz etmektedir.

Tablo 4.1. Türkiye’nin toplam kurulu gücü, brüt ve net elektrik üretimi  
(TÜİK\_a, 2017), (Erişim tarihi: 01.05.2018)

Yıl	Toplam kurulu güç (MW)	Brüt Üretim (GWh)	Net tüketim (GWh)	Yıl	Toplam kurulu güç (MW)	Brüt Üretim (GWh)	Net tüketim (GWh)
1975	4 186,6	15 622,8	13 491,7	1996	21 249,4	94 861,7	74 156,6
1976	4 364,2	18 282,8	16 078,9	1997	21 891,9	103 295,8	81 885,0
1977	4 727,2	20 564,6	17 968,8	1998	23 354,0	111 022,4	87 704,6
1978	4 868,7	21 726,1	18 933,8	1999	26 119,3	116 439,9	91 201,9
1979	5 118,7	22 521,9	19 633,1	2000	27 264,1	124 921,6	98 295,7
1980	5 118,7	23 275,4	20 398,2	2001	28 332,4	122 724,7	97 070,0
1981	5 537,6	24 672,8	22 030,0	2002	31 845,8	129 399,5	102 948,0
1982	6 638,6	26 551,5	23 586,8	2003	35 587,0	140 580,5	111 766,0
1983	6 935,1	27 346,8	24 465,1	2004	36 824,0	150 698,3	121 141,9
1984	8 461,6	30 613,5	27 635,2	2005	38 843,5	161 956,2	130 262,9
1985	9 121,6	34 218,9	29 708,6	2006	40 564,8	176 299,8	143 070,5
1986	10 115,2	39 694,8	32 209,7	2007	40 835,7	191 558,1	155 135,2
1987	12 495,1	44 352,9	36 697,3	2008	41 817,2	198 418,0	161 947,6
1988	14 520,6	48 048,8	39 721,5	2009	44 761,2	194 812,9	156 894,1
1989	15 808,2	52 043,2	43 120,0	2010	49 524,1	211 207,7	172 050,6
1990	16 317,6	57 543,0	46 820,0	2011	52 911,1	229 395,1	186 099,6
1991	17 209,1	60 246,3	49 282,9	2012	57 059,4	239 496,8	194 923,4
1992	18 716,1	67 342,2	53 984,7	2013	64 007,5	240 154,0	198 045,2
1993	20 337,6	73 807,5	59 237,0	2014	69 519,8	251 962,8	207 375,1
1994	20 859,8	78 321,7	61 400,9	2015	73 146,7	261 783,3	217 312,3
1995	20 954,3	86 247,4	67 393,9	2016	78.497,4	274.407,7	231.203,7



Tablo 4.1.'e göre 1975 yılından 2017 yılına gelindiğinde elektrik tüketiminde büyük bir artış gözlemlenmektedir. Elektrik tüketimi hemen her yıl artış göstermiştir. Elektrik üretimi de elektrik tüketimine bağlantılı olarak gün geçtikçe yükselmiştir. Elektrik tüketiminin bu sürekli ve hızlı artışı elektrik tüketim tahminlerinin yapılmasını daha önemli bir alan haline getirmiştir. Bu açıdan, bu konudaki çalışmaların derinleşmesi ve elektrik tüketim tahminlerinin en doğru ve net bir biçimde yapılabilmesi büyük önem arz etmektedir.




Şekil 4.1. Yıllara göre elektrik toplam kurulu gücü (MW)

(Tablo 4.1. verileri baz alınarak tarafımızca hazırlanmıştır.)

Şekil 4.1'de görüldüğü üzere elektrik kurulu gücü son 8 yılda oldukça artmış ve 40000 MW'ın üstünden, 80000 MW'a çıkarak iki katına yükselmiştir.

Şekil 4.2'de yıllara göre brüt üretime yer verilmiştir.




Şekil 4.2. Yıllara göre brüt elektrik üretimi (GWh)

(Tablo 4.1. verileri baz alınarak tarafımızca hazırlanmıştır.)

Şekil 4.2’de görüldüğü üzere yıllara göre brüt elektrik üretimi, 2001 ve 2009 yılları dışında sürekli artmıştır. Bu duruma sebep olarak kriz dönemi ve sonrası azalan endüstriyel aktiviteler gösterilebilir.


Şekil 4.3’te yıllara göre net elektrik tüketimine yer verilmiştir.



Şekil 4.3. Yıllara göre net elektrik tüketimi (GWh)

(Tablo 4.1 verileri baz alınarak tarafımızca hazırlanmıştır.)

Şekil 4.3'te görüldüğü üzere yıllara göre net elektrik tüketimi, dalgalı bir seyir izlese de çok büyük değişikliklere sahne olmamıştır. Öte yandan 2017 yılında yüksek bir artış gerçekleşmiştir.



Şekil 4.4. Aylık toplam elektrik tüketimi (GWh), (Enerji Enstitüsü, 2017), Erişim tarihi: 26.03.2018

Şekil 4.4'e göre 2010-2017 yılları arası elektrik tüketim oranları aylar bazında doğrusal bir artış göstermiştir. Genelde her yıl bir öncekinden daha fazla elektrik tüketilmiş ve aylara göre de bu tüketim miktarları değişim göstermiştir. Özellikle Ağustos ve Aralık aylarında en yüksek seviyelere çıkan elektrik tüketim oranları Şubat ve Nisan aylarında en düşük seviyelerde seyretmiştir.

Tablo 4.2'de 1975-2016 arası elektrik tüketiminin sektörlere göre dağılımına yer verilmektedir.



Tablo 4.2. Elektrik tüketimi - Sektörlere göre oransal dağılımı, 1975-2016, Türkiye  
(TÜİK\_b, 2017), Erişim Tarihi: 26.03.2018

Yıl	Mesken	Ticarethane	Resmi daire	Sanayi	Aydınlatma	Diğer	Toplam
1975	17,5	4,9	3,7	64,8	1,9	7,2	100%
1976	17,5	4,7	3,5	65,3	1,6	7,4	100%
1977	17,7	5,0	3,1	66,7	1,4	6,1	100%
1978	18,9	4,9	3,2	65,5	1,5	6,0	100%
1979	20,1	5,7	3,2	63,9	1,5	5,6	100%
1980	21,5	5,6	3,0	63,8	1,4	4,7	100%
1981	20,9	5,7	2,9	64,5	1,4	4,6	100%
1982	20,9	5,8	2,5	64,4	1,3	5,1	100%
1983	21,0	5,7	2,8	63,7	1,2	5,6	100%
1984	19,8	5,7	2,8	65,2	1,2	5,3	100%
1985	19,0	5,5	3,0	66,0	1,4	5,1	100%
1986	19,0	5,2	3,2	64,8	2,1	5,7	100%
1987	18,9	4,8	3,2	65,1	2,1	5,9	100%
1988	20,0	5,0	3,2	63,6	2,1	6,1	100%
1989	19,6	5,3	3,0	64,0	2,1	6,0	100%
1990	19,6	5,5	3,1	62,4	2,6	6,8	100%
1991	22,0	6,2	3,8	57,9	2,9	7,2	100%
1992	21,3	6,1	3,7	58,4	3,4	7,1	100%
1993	21,2	6,1	3,8	57,8	3,8	7,3	100%
1994	21,9	6,0	5,4	55,6	4,1	7,0	100%
1995	21,5	6,2	4,5	56,4	4,6	6,8	100%
1996	22,1	7,7	4,0	54,8	4,2	7,2	100%
1997	22,6	8,4	4,6	53,1	4,0	7,3	100%
1998	22,8	8,8	4,9	52,6	4,2	6,7	100%
1999	24,8	9,0	4,1	51,0	4,6	6,5	100%
2000	24,3	9,5	4,2	49,7	4,6	7,7	100%
2001	24,3	10,2	4,5	48,4	5,0	7,6	100%
2002	22,9	10,6	4,4	49,0	5,0	8,1	100%
2003	22,5	11,5	4,1	49,3	4,5	8,1	100%
2004	22,8	12,9	3,7	49,2	3,7	7,7	100%
2005	23,7	14,2	3,6	47,8	3,2	7,5	100%
2006	24,1	14,2	4,2	47,5	2,8	7,2	100%
2007	23,5	14,9	4,5	47,6	2,6	6,9	100%
2008	24,4	14,8	4,5	46,2	2,5	7,6	100%
2009	25,0	15,9	4,5	44,9	2,5	7,2	100%
2010	24,1	16,1	4,1	46,1	2,2	7,4	100%
2011	23,8	16,4	3,9	47,3	2,1	6,5	100%

Tablo 4.2. Elektrik tüketimi - Sektörlere göre oransal dağılımı, 1975-2016, Türkiye  
(Devam) (TÜİK\_b, 2017), Erişim Tarihi: 26.03.2018

Yıl	Mesken	Ticarethane	Resmi daire	Sanayi	Aydınlatma	Diğer	Toplam
2012	23,3	16,3	4,5	47,4	2,0	6,5	100%
2013	22,7	18,9	4,1	47,1	1,9	5,3	100%
2014	22,3	19,2	3,9	47,2	1,9	5,5	100%
2015	22,0	19,1	3,7	47,6	1,9	5,7	100%
2016	22,2	18,8	3,9	46,9	1,8	6,4	100%

Tablo 4.2’de elektrik tüketiminin sektörel dağılımına yer verilmiştir. Burada görüldüğü üzere, elektrik tüketiminin dağılımı yıllar içinde değişse de sıralama aynı kalmıştır. Sanayi en büyük paya sahipken onu mesken takip etmiştir. Ticaret ise üçüncü sırada gelmektedir. Öte yandan, meskenin artış oranı kişisel kullanımların artması ile ilgilidir. Sanayi oranının yüksek çıkması elektrik talebinin ülke ekonomisi ile ilişkisini gözler önüne sermektedir.

Tablo 4.3’te ise, 2017 ve 2018 yılı Ocak ayına ilişkin bu dalda (sektör bazında) elektrik tüketiminin değişimine yer verilmiştir.

Tablo 4.3. Tüketici sayısının tüketici türü bazında dağılımının dönemler arası karşılaştırılması (EPDK, 2018, s. 22)

Tüketici Türü	2017 Ocak		2018 Ocak		Değişim (%)
	Adet	Pay(%)	Adet	Pay(%)	
Aydınlatma	329.473	0,800	338.067	0,790	2,61
Mesken	33.591.691	81,606	34.828.937	81,406	3,68
Sanayi	60.477	0,147	61.723	0,144	2,06
Tarımsal Sulama	609.676	1,481	631.859	1,477	3,64
Ticarethane	6.572.086	15,966	6.923.636	16,183	5,35
<b>Genel Toplam</b>	<b>41.163.403</b>	<b>100</b>	<b>42.784.222</b>	<b>100</b>	<b>3,94</b>

Tablo 4.3'te görüldüğü üzere 2017'den 2018'e köklü değişiklikler olmasa da, ticarethanenin payının arttığından bahsedilebilir.

Tablo 4.4'te ise, 2017 ve 2018 yılı Ocak ayında elektrik tüketiminin bölgeler bazında değişimine yer verilmiştir.

Tablo 4.4. Tüketici sayısının dağıtım bölgesi bazında dağılımının dönemlerarası karşılaştırılması (EPDK, 2018, s. 23)

Dağıtım Bölgesi	Tüketici Sayısı (Adet)		Değişim (%)
	2017 Ocak	2018 Ocak	
BOĞAZİÇİ	4.885.227	5.055.506	3,49
BAŞKENT	4.112.590	4.228.316	2,81
TOROSLAR	3.682.067	3.824.188	3,86
GDZ	3.067.630	3.174.272	3,48
ULUDAĞ	2.990.888	3.099.226	3,62
İSTANBUL ANADOLU YAK.	2.758.317	2.843.078	3,07
AKDENİZ	2.005.199	2.083.809	3,92
MERAM	1.968.795	2.031.223	3,17
YEŞİLIRMAK	1.943.510	2.004.246	3,13
DİCLE	1.681.356	1.918.588	14,11
ADM	1.791.308	1.838.428	2,63
SAKARYA	1.660.485	1.745.157	5,10
OSMANGAZİ	1.666.067	1.725.292	3,55
ÇORUH	1.271.270	1.306.214	2,75
TRAKYA	993.454	1.043.015	4,99
ARAS	935.747	964.639	3,09
ÇAMLİBEL	920.566	948.387	3,02
FIRAT	890.409	919.562	3,27
KAYSERİ VE C.	675.560	697.792	3,29
AKEDAŞ	637.445	680.009	6,68
VANGÖLÜ	625.506	653.275	4,44
<b>Genel Toplam</b>	<b>41.163.396</b>	<b>42.784.222</b>	<b>3,94</b>

Tablo 4.4'te dağıtım bölgesi bazında kapsamlı değişiklikler olmamış en büyük dağıtımını gerçekleştiren Boğaziçi bölgesi % 3 civarında değişim göstermiştir. En büyük değişim ise %14,11 ile Dicle bölgesinde gözlenmektedir.

Tablo 4.5'te ise, 2017 ve 2018 yılı Ocak ayında bu dalda elektrik tüketiminin dönemler bazında değişimine yer verilmiştir. Bir yıl gibi kısa bir zaman diliminde ortaya çıkan değişimin il bazında görülmesi enerji talebinin boyutlarının anlaşılması açısından önemlidir.



Tablo 4.5. Tüketici sayısının il bazında dağılımının dönemler arası karşılaştırılması  
(EPDK, 2018, s. 24)

İl Adı	Tüketici sayısı (adet)		Değişim (%)	İl Adı	Tüketici sayısı (adet)		Değişim (%)
	2017 Ocak	2018 Ocak			2017 Ocak	2018 Ocak	
İSTANBUL	7.643.544	7.898.584	3,34	MARDİN	250.572	266.440	6,33
ANKARA	2.883.082	2.963.976	2,81	EDİRNE	236.651	256.165	8,25
İZMİR	2.300.545	2.380.136	3,46	YOZGAT	248.430	256.034	3,06
ANTALYA	1.566.984	1.631.585	4,12	RİZE	233.252	239.461	2,66
BURSA	1.523.833	1.587.172	4,16	OSMANİYE	221.979	229.659	3,46
KONYA	1.105.117	1.140.502	3,20	ADIYAMAN	209.631	222.590	6,18
ADANA	1.038.142	1.070.621	3,13	UŞAK	210.719	219.362	4,10
MERSİN	963.864	998.621	3,61	KIRKLARELİ	198.477	210.567	6,09
BALIKESİR	906.396	930.800	2,69	AKSARAY	201.424	208.521	3,52
KOCAELİ	847.766	882.819	4,13	NİĞDE	195.000	202.763	3,98
MANİSA	767.085	794.136	3,53	AMASYA	195.791	202.496	3,42
SAMSUN	762.530	784.836	2,93	YALOVA	194.933	201.765	3,50
HATAY	711.763	742.819	4,36	NEVŞEHİR	181.839	186.080	2,33
GAZİANTEP	683.258	716.778	4,91	DÜZCE	176.054	185.975	5,64
KAYSERİ	670.854	693.046	3,31	BOLU	167.278	173.826	3,91
AYDIN	654.939	669.085	2,16	BURDUR	168.042	172.922	2,90
MUĞLA	589.973	609.504	3,31	AĞRI	162.105	167.307	3,21
ŞANLIURFA	567.330	589.953	3,99	KARABÜK	159.500	164.097	2,88
TEKİRDAĞ	558.322	576.281	3,22	SİNOP	158.968	163.978	3,15
ESKİŞEHİR	546.638	570.348	4,34	KIRIKKALE	151.956	157.332	3,54
DENİZLİ	546.396	559.839	2,46	ERZİNCAN	145.073	149.122	2,79
TRABZON	528.829	544.403	2,94	KARAMAN	143.886	148.132	2,95
DİYARBAKIR	502.214	514.265	2,40	KIRŞEHİR	141.533	145.227	2,61
ORDU	494.029	510.996	3,43	BARTIN	134.240	138.189	2,94
SAKARYA	469.387	502.537	7,06	BİLECİK	128.379	132.880	3,51
K.MARAŞ	427.814	457.419	6,92	ÇANKIRI	125.427	129.851	3,53
MALATYA	407.188	419.424	3,01	MUŞ	120.005	125.437	4,53
A.KARAHİSAR	406.763	419.219	3,06	ARTVİN	117.487	120.285	2,38
ZONGULDAK	381.595	388.869	1,91	BİNGÖL	112.791	120.023	6,41
KÜTAHYA	373.568	383.483	2,65	KARS	113.972	118.037	3,57
ÇANAKKALE	365.726	379.489	3,76	ŞIRNAK	102.755	109.084	6,16
SİVAS	359.007	371.211	3,40	BİTLİS	103.962	108.560	4,42
ERZURUM	344.304	354.605	2,99	SİİRT	89.552	92.730	3,55
VAN	334.743	348.874	4,22	GÜMÜŞHANE	87.404	89.688	2,61
BATMAN	168.933	346.116	104,88	İĞDIR	71.094	72.943	2,60
ÇORUM	332.192	341.940	2,93	HAKKARİ	66.796	70.404	5,40
TOKAT	317.835	325.888	2,53	KİLİS	63.061	65.690	4,17
ELAZIĞ	314.489	322.771	2,63	TUNCELİ	55.941	57.344	2,51
GİRESUN	304.298	312.377	2,65	ARDAHAN	52.589	54.269	3,19
KASTAMONU	276.790	286.002	3,33	BAYBURT	46.610	48.356	3,75
ISPARTA	270.173	279.302	3,38	Genel Toplam	41.163.396	42.784.222	3,94

Tablo 4.5'te görüldüğü üzere iller bazında kapsamlı değişiklikler yaşanmamış en büyük tüketimi gerçekleştiren İstanbul, Ankara ve İzmir bölgesi % 3 civarında değişim göstermiştir. Değişim oranı %104,88 ile en yüksek olan il Batman olarak dikkat çekmektedir.

Türkiye'de elektrik tüketiminin ve ihtiyacının artması yeni arayışları gündeme getirmektedir. Nükleer enerji santralının kurulması da bunlardan biridir. Akkuyu Nükleer Santral, Rus Devleti Nükleer Enerji Ajansı Rosatom tarafından inşa edilecek ve her biri 1.200 megawatt (MW) gücünde dört üniteden oluşacaktır. Toplam yatırım maliyeti yaklaşık 20 milyar dolar olan tesisin, yılda 8.000 saatlik çalışma ömrüne sahip olması planlanmaktadır. İnşaatın ilk aşamasında, 2 adet 2.400 MW'lık bir kapasite planlanmıştır. Akkuyu'nun, tam kapasite ile 35 milyar kilowatt (kW) elektrik üretmesi planlanmış ve ilk ünitenin 2019 senesinde, diğer ünitelerin de birer sene arayla aktif olacağı tahmin edilmektedir (NEPUD, 2014, s. 19).

## 5. TALEP TAHMİNİNDE KULLANILAN MODELLER

Talep tahmini özellikle enerji söz konusu olduğunda oldukça önemli hale gelmekte ve özellikle enerjide dışa bağımlı olan ülkeler için hayati olmaktadır. Bu bağlamda çeşitli modeller kullanılmaya başlanmıştır. Bunlardan bazılarına bu bölümde yer verilecektir.

### 5.1. Basit Lineer Regresyon

Regresyon modelleri ile yük tahmini çok kullanılan bir yöntem olup, hava durumu ve takvim bilgileri ya da müşteri tipleri benzeri yük ve dış etmenler bağlamındaki ilişkiyi modellemek adına kullanılmaktadır. Regresyon metotlarının uygulanması diğer yöntemlere göre daha kolaydır. En yaygın kullanılanı ise doğrusal regresyon olmaktadır. Bu değişkenlerin katsayıları, en küçük kareler veya diğer regresyon teknikleri ile hesaplanmaktadır. Diğer bir taraftan ise, girdi ve çıktı değişkenleri arasındaki bağlamın idrak edilmesi daha kolay olmaktadır (Aksel, 2000, s. 28).

Regresyon tabanlı metotlar elektrik tahmini ile ilgili yaygın olarak kullanılmasına karşın, çeşitli olumsuzluklar da barındırmaktadır. Yük talebi ve etkileyen etmenler bağlamında doğrusal olmayan ve komplike ilişki sebebiyle, doğru bir model ortaya çıkarmak oldukça zordur. Regresyon temelli metotların yerine gerçekleştirilen testlerde, ani hava durumu değişiklikleri ve yük olayları sebebiyle yükün saptığı hallerde performans bozulma ortaya çıkarmıştır. Bu sorunun ana nedenlerinden birisi de, katsayılarını tahmin etmek için modelin doğrusal hale getirilmesidir. Bununla beraber, yük desenleri doğrusal olmamakta ve lineerleştirilmiş bir model kullanarak türlü zaman periyodlarında yük talebini temsil etmek olası olmamaktadır. Bu problemi kısmen azaltmak adına, tahmincinin ani hava durumu değişiklikleri ve özel olaylar nedeniyle yük sapmalarını açıklamasını sağlamak için istatistiksel teknikler kullanmak çoğu zaman daga gereklidir (Kyriakides & Polycarpou, 2007, s. 391).

Basit regresyon, değişkenler arasındaki lineer ilişkiyi açıklamak için kullanılır.

$$y=a+bx+\varepsilon$$

Lineer fonksiyonda a, fonksiyonun y eksenini kestiği noktayı, b ise doğrunun eğimini ifade etmektedir. Denklemden x bağımsız değişken olmakta ve y bağımlı değişkeninin değerini tahmin etmekte kullanılmaktadır. “a” sabit, “b” ise bağımsız değişkenin katsayısıdır. Bu analizde hedef; ε hatasını en az olacak biçimde tespit edecek şekilde a ve b katsayılarının belirlenmesidir. (Palit & Popovic, 2005, s. 17).

## 5.2. Üstel Fonksiyonla Regresyon

Doğrusal olmayan regresyon modellerinin en bilinen örneklerinden biri de üstel fonksiyon modelleridir. Aşağıda bu modelin örneği verilmiştir (Goldstein & Schneider, 2006, s. 29):

$$y_i = \beta_0 + \beta_1 \exp(\beta_2 x_{i,1} + \dots + \beta_{p+1} x_{i,1}) + \epsilon_i$$

$y_i$  : bağımlı değişken

$x_{1,1}, \dots, x_{i,1}$ : bağımsız değişkenler

$\beta_{0,1}, \dots, \beta_i$ : katsayılar

$\epsilon_i$  : hata terimi

## 5.3. Polinom Regresyon

İstatistikte, polinom regresyonu, bağımsız değişken x ve bağımlı değişken y arasındaki ilişkinin, x'de bir (n) derece polinomu olarak modellendiği bir regresyon analizi şeklindedir. Polinom regresyonu, x değeri ile denk düşen E (y | x) koşullu ortalama değeri arasında doğrusal olmayan bir ilişkiyi tanımlar (Fan, 1996, s. 42).

$$\beta_0 + \beta_1 x_1^1 + \beta_2 x_2^2 + \dots + \beta_i x_i^i$$

## 5.4. Yapay Sinir Ağları ile Tahmin

Yapay sinir ağı insan beyninin fonksiyonlarını kopya etmek adına meydana getirilen bir algoritma olmaktadır. Temel birimi, birtakım giriş düğümleri ile bilgi alan yapay sinir hücresi şeklinde görev yapmakta, dâhili olarak işleme koymakta ve cevap vermektedir. Yapay Sinir Ağları modelleme yöntemi günümüzde pek çok dalda kullanımı gerçekleştiren bir yöntemdir. Basit bir şekilde insan beyninin çalışma

yöntemini kopya eden bu metot yapay zeka çalışmaları açısından da önemlidir. “Evrensel Fonksiyon Yakınsayıcı Yöntem (Universal Function Approximators)” biçiminde de ifade edilen bu yöntem veriden öğrenme yapmakta, genellemelerle ve limitsiz sayıda değişkenle çalışabilme vb. gibi nitelikleri bünyesinde barındırmaktadır. Bu özellikleri ile oldukça önemli avantajları bulunan YSA yöntemi diğer alanlarda bulunduğu gibi tahmin yapma bakımından da yaygın bir biçimde kullanılmaktadır (Yurtoğlu, 2005, s. 4).

### **5.5. Geri Beslemeli Ağlar**

Geri beslemeli YSA’da, en az bir hücrenin çıkışı kendisine ya da diğer hücrelere giriş şeklinde aktarılır ve genellikle geri besleme bir geciktirme etmeni üstünden gerçekleştirilir. Geri besleme, bir katmandaki hücreler ile ilişkili olabileceği gibi düzeyler arasındaki hücreler arasında da gerçekleşebilir. Bu yapısı ile geri beslemeli YSA, doğrusal olmayan dinamik bir davranış ortaya çıkarabilmektedir. Dolayısıyla, geri beslemenin yapılış şekli bağlamında farklı yapıda ve davranışta geri beslemeli YSA yapıları ortaya çıkarabilir (Kabalıcı, 2013, s. 2).

### **5.6. Öğrenme, Adaptif Öğrenme ve Test Etme**

Yapay sinir ağlarının bir durumu öğrenmeleri için örnekler kullanılarak genelleme kabiliyetine kavuşturulması ağın eğitilmesi olarak adlandırılmaktadır. Ağ her örneği aldığı anda süreç faktörlerinin bağlantı değerlerinde değişiklikler gerçekleştirmektedir. Bütün örneklere doğru çıktılar ortaya çıkarıncaya dek bu işlem sürdürülür. Ağın eğitiminin bitmesinin ardından performansını ölçmek adına gerçekleştirilen denemeler ise test etme olarak adlandırılmaktadır. Test etmek için ağın görmediği örnekler ortaya çıkarılır ve ağ eğitim sırasında ortaya çıkardığı bağlantı değerlerini kullanmaktadır. Her hangi bir biçimde bağlantı değerlerinde değişim gerçekleştirilmez. Test örneklere verdiği yanıtlar eğitimin performansını ortaya çıkarır. Eğitimde kullanılan örnek dizisine eğitim seti, test için kullanılan diziye ise test seti adı verilmektedir.

Adaptif öğrenme, yapay sinir ağlarının tanıdık örneklerden belirli bilgileri meydana getirerek bilinmeyen örnekler hakkında yorum kabiliyetini ifade etmektedir. Bu yeteneklerini öğrenme sırasında zamanla edinirler. Diğer bir deyişle zamanla kendilerini ilgili olaya uyumlayarak genelleme yapabilecek kabiliyete erişebilirler (Ho, Hsu, & Yang, 1992, s. 141).



## 6. YAPAY SİNİR AĞLARI

Önceki bölümlerde bahsedildiği üzere enerji talep tahmininde bir çok yöntem kullanılmaktadır. Yapay Sinir Ağları da bu yöntemlerden biridir. Bu bölümde; YSA'nın genel özellikleri, avantajları, dezavantajları, YSA yapısı ve temel elemanları ele alındıktan sonra, YSA modelleri ve YSA'da öğrenme algoritmaları ile öğrenme kuralları anlatılacaktır. Sonrasında YSA'ya ilişkin geri yayılım algoritması ve çok katmanlı algılayıcılar (ÇKA) açıklanacak, ardından YSA'nın çalışma prosedürü detaylandırılacaktır. Tüm bu bilgiler ışığında YSA ile elektrik tüketimi tahmini konusuna giriş yapılacaktır.

### 6.1. Yapay Sinir Ağlarının Genel Özellikleri

Yapay Sinir Ağları beyin nöröl yapısına dayanan elektronik modellerdir. Beyin temelde deneyimden öğrenmektedir. Bu durum, mevcut bilgisayarların kapsamı dışında kalan bazı problemlerin küçük enerji-verimli paketler tarafından çözülebileceğinin doğal bir kanıtıdır. Bu beyin modellemesi ayrıca makine çözümlerini geliştirmek için daha az teknik olan bir yol vaat etmektedir. Bu yeni yaklaşım, geleneksel muadillerine göre daha avantajlı olmaktadır (Yegnanarayana, 2009, s. 4).

Bu biyolojik olarak esinlenerek yapılmış hesaplama yöntemlerinin, bilgisayar endüstrisinde önemli gelişmeler gerçekleştirdiği düşünülmektedir. En basit formda hayvan beyinleri dahi, şu anda bilgisayarlar için imkansız olabilecek fonksiyonlara sahiptir. Bilgisayarlar; defterleri tutmak veya karmaşık matematik yapmak gibi işler konusunda iyi olsa da, basit desenleri dahi tanımakta zorlanabilmektedir (Hagan, Demuth, & Beale, 1996, s. 38).

Günümüzde, biyolojik araştırmalardaki ilerlemeler, doğal düşünce mekanizmasını anlama konusunda başarı sağlamaktadır. Bu araştırma, beyinlerin bilgiyi kalıp olarak sakladığını göstermektedir. Bu modellerin bazıları çok karmaşıktır ve bireysel yüzleri farklı açılardan tanımamızı sağlamaktadır. Bilgiyi kalıp olarak depolamak, bu

kalıpları kullanmak ve sonra problemleri çözmek, bilgisayar ortamında yeni bir alanı kapsamaktadır. Bu alan, daha önce de bahsedildiği gibi, geleneksel programlamayı kullanmaz, fakat büyük ölçüde paralel ağların oluşturulmasını ve bu problemlerin çözülmesi için bu ağların eğitilmesini içermektedir. Bu alan aynı zamanda geleneksel hesaplamaadan çok farklı kelimeler, davranışlar, tepki verme, kendini organize etme, öğrenme, genelleme ve unutma gibi kelimeleri kullanmaktadır (Yao, 1999, s. 1423).

Öte yandan, insan beyninin tam çalışması bir gizem oluşturmaktadır. Yine de, bu şaşırtıcı işlemcinin bazı yönleri bilinmektedir. Özellikle, insan beyninin en temel unsuru, vücudun geri kalanının aksine, yeniden ortaya çıkmadığı görülen spesifik bir hücre türüdür. Bu tip bir hücrenin yavaş yavaş değiştirilmeyen tek parçası olduğu için, bu hücrelerin bize önceki eylemleri hatırlamak, düşünmek ve uygulamak için yeteneklerimizi sağlayan her şey olduğu varsayılmaktadır. Bu hücreler nöronlar olarak bilinir. Bu nöronların her biri, genelde 1000 ile 200.000 kadar başka nöronla bağlantı kurabilir. İnsan aklının gücü, bu temel bileşenlerin arasındaki çoklu bağlantılardan gelmektedir. Aynı zamanda genetik programlama ve öğrenmeden gelmektedir.

Bireysel nöronlar karmaşık yapıdadır. Çok sayıda parça, alt sistem ve kontrol mekanizmaları bulunmaktadır. Bir dizi elektrokimyasal yolla bilgi aktarımı sağlayan bu hücreler, kullanılan sınıflandırma yöntemine bağlı olarak yüzlerce farklı nöron sınıflarına ayrılmaktadır. Birlikte bu nöronlar ve bağlantıları, ikili olmayan, kararlı olmayan ve senkron olmayan bir süreç oluşturur. Kısacası, şu anda mevcut elektronik bilgisayarlar, hatta yapay sinir ağlarına benzememektedir. Bu yapay sinir ağları, bu karmaşık, çok yönlü ve güçlü organizmanın sadece en temel öğelerini çoğaltmaya çalışmaktadırlar (Graupe, 2013, s. 45).

İnsan beyninin öğrenme, benimseme, ilişkilendirme ve genelleme yeteneği, herhangi bir bilgisayarın yeteneğinden daha üstündür. Bu yetenek, araştırmacıların insan beynini basitleştirilmiş bir formda modellemeye çalışmalarına neden olmuştur (Karna, 1989, s. 5). Bu modellemeler aracılığıyla oluşturulan yapay sinir ağları, çeşitli çizelgeleme problemlerine çözüm bulmada olumlu katkılar sağlamıştır.



Yapay sinir ağlarının tahmin kalitesinin regresyon modellerinden önemli oranda iyi olduğu görülmüştür. (Ekici, Yıldırım, & Poyraz, 2008, s. 2937), kaynakların mevcudiyeti, gelen siparişlerin teslim tarihi atamaları ve çizelgede kullanılacak olan öncelik kuralları belirlemede karar vermek için paralel sinir ağlarını kullanan bir sistem önerdiler. YSA araştırmalarının odağındaki soru, yüklerin, sinyalleri nasıl değiştirmesi gerektiğidir. Bu noktada herhangi bir formdaki bilgi girişinin, ne tür bir çıkışa çevrileceği, değişik modellerde farklılık göstermektedir. Diğer önemli bir farklılık ise, verilerin sistemde depolanma şeklidir. Nöral bir tasarımda, bilgisayarda saklı olan bilgiyi, tüm sisteme yayılmış küçük yük birimlerinin birleşerek oluşturduğu bir bütün evre temsil etmektedir. Ortama yeni bir bilgi aktarıldığında ise, yerel büyük bir değişiklik yerine tüm sistemde küçük bir değişiklik yapılmaktadır.

Günümüzde sinirsel ağ uygulamaları ya geleneksel bilgisayarlar üzerinde yazılım simülatörleri kullanılarak veya özel donanım içeren bilgisayarlar kullanarak gerçekleştirilmektedir. Kredi risk değerlemesinden imza kontrolü, mevduat tahmini ve imalat kalite kontrolüne kadar uzanan uygulamalar yazılım paketlerinden faydalanılarak yapılmaktadır (Samarasinghe, 2016, s. 57).

## **6.2. Yapay Sinir Ağlarının Avantajları**

YSA, istatistiksel yöntemlere kıyasla kullanımı ve anlaşılması kolay doğrusal olmayan bir modeldir. YSA paramaterik olmayan bir model iken, diğer istatistiksel yöntemlerin çoğu parametrik modeldir. Geri yayımlı (BP) öğrenme algoritması ile YSA, çeşitli sınıflandırma ve tahmin problemlerinin çözümünde yaygın olarak kullanılmaktadır. YSA'ların, belirli sorunlar ve durumlar için onları en uygun hale getiren bazı önemli avantajları vardır (Tu, 1996, s. 1225):

- YSA'ların doğrusal olmayan, karmaşık ilişkileri öğrenme ve modelleme yeteneği vardır; bu gerçekten önemlidir, çünkü gerçek hayatta girdiler ve çıktılar arasındaki ilişkilerin çoğu doğrusal değildir ve karmaşıktır.
- YSA'lar girdilerden yola çıkarak genelleme yapabilme özelliğine sahiptir. Girdileri ve aradaki ilişkileri öğrendikten sonra, görünmeyen veriler üzerinde

de görünmeyen ilişkileri bulabilir. Böylece model, görünmeyen verileri genelleştirip tahmin edebilir.

- Diğer birçok tahmin tekniğinden farklı olarak YSA, girdi değişkenleri üzerinde herhangi bir kısıtlama getirmemektedir. Literatürde, verilerde herhangi bir sabit ilişkiyi göstermeden verilerdeki gizli ilişkileri öğrenebilme yeteneği göz önüne alındığında, YSA'ların sabit olmayan varyansı daha iyi modellediğini göstermiştir. Bu, veri oynaklığının çok yüksek olduğu finansal zaman serileri tahmininde (örneğin hisse senedi fiyatları) çok yararlı bir modeldir.

### 6.3. Yapay Sinir Ağlarının Dezavantajları

İstatistiksel modellerin geliştiricileri çoğunlukla birincil hedeflerini nedensel çıkarsama olarak tanımlamaktadırlar. Bir bağımsız değişken ile tek başına bir sonuç arasındaki istatistiksel ilişkinin varlığı nedensellik anlamına gelmese de, lojistik regresyon modelleri olası nedensel ilişkilerin tanımlanması için nöral ağlardan üstündür. Lojistik regresyonda, hangi değişkenlerin, katsayılarının büyük olduğunu ve ilgili oranlara dayanan bir sonucu en güçlü şekilde kestirebildiğini belirleyebilmektedir. Dahası, aşamalı olarak değişken bir seçim süreci yoluyla, model geliştirici, belirli bir ilgi ile ilişkili olmayan birçok bağımsız değişkeni ortadan kaldıracaktır. Aşağıda yapay sinir ağlarının dezavantajlara yer verilmiştir (Tu, 1996, s. 1226):

- Nöral ağ modellerinin sahada kullanılması daha zor olabilir: Sinir ağı modelleri, aynı veri kümesi kullanılarak geliştirilen lojistik regresyon modellerinden daha zor olabilir. Eğitimli bir sinir ağı modelini kullanabilen diğer kullanıcılar için, ya her bir son kullanıcıya eğitimli ağ yazılımının bir kopyasının yapılması ya da eğitimli bağlantı ağırlığı matrislerinin yayınlanması gerekmektedir.


- Nöral ağ modellemesi, daha büyük hesaplama kaynakları gerektirir: Yapay sinir ağı modeli gelişimi, çok daha fazla hesaplama süresi gerektiren, hesaplama yoğun bir prosedürdür. Standart kişisel bilgisayar donanımı ve back-propagation algoritması ile, bir ağın en az hata ile optimum bir öğrenme durumuna yakınsaması günler sürebilmektedir. Buna karşılık, nispeten büyük veri setlerinin lojistik regresyon modelleri standart bilgisayarlarda saniyeler içinde test edilebilir ve yeni modeller daha sonra değerlendirilebilir.
- Nöral ağ modelinde girdilerin etkileşimleri ve doğrusal olmayan ilişkileri örtük olarak modelleme kabiliyeti bir dezavantaj olarak görülebilir. Çünkü harici test veri setlerinde zayıf performansa sahip bir eğitim verisinin aşırı yüklenmesine yol açabilir. Bu durum genel olarak üç ana yolla önlenir: gizli düğümlerin sayısını sınırlayarak, büyük ağırlıklar için amaç işlevine bir ceza terimi ekleyerek veya çapraz doğrulama kullanarak ve eğitim miktarını sınırlayarak.
- Sinir ağı modeli gelişimi ampiriktir ve pek çok metodolojik soruna çözümlenme çalışmaları devam etmektedir: Sinir ağı modellemesi, çeşitli disiplinlerden ortaya çıkmış olan nispeten yeni bir tekniktir ve çözüme kavuşturulması için önemli metodolojik meseleler hala gündemdedir.

#### **6.4. Yapay Sinir Ağlarının Yapısı ve Temel Elemanları**

Yapay sinir ağlarının çalışmasının dayanağı olan çeşitli unsurları bulunmaktadır. Bu unsurlar bu bölümde açıklanmaktadır.

##### **6.4.1. Biyolojik sinir hücresi**

Biyolojik sinir sistemi, merkezinde devamlı biçimde bilgiyi alan, yorumlayan ve uygun bir karar ortaya çıkaran beynin (merkezi sinir ağı) bulunduğu üç katmanlı bir yapı şeklinde açıklanabilmektedir (Kabalcı, 2013, s. 2).



Şekil 6.1. Biyolojik sinir sistemi (Kabalıcı, 2014)


Alıcı sinirler organizmada dahili ya da harici ortamda aldıkları uyarıları, beyne bilgi aktaran elektriksel sinyallere dönüştürür. Tepki sinirleri ise, beyinin ürettiği elektriksel darbeleri organizma çıktısı şeklinde uygun tepkilere dönüştürür. Merkezi sinir ağında bilgiler, alıcı ve tepki sinirlerinde ileri ve geri besleme yönünde analiz ederek uygun tepkiler meydana getirir. Bu şekilde biyolojik sinir sistemi, kapalı çevrim denetim sisteminin özelliklerini barındırır. Merkezi sinir sisteminin ana işlem faktörü, sinir hücresidir ve insan beyinde yaklaşık 10 milyar sinir hücresi şeklinde öngörülmektedir. Sinir hücresi; hücre gövdesi, dendritler ve aksonlar olmak üzere 3 faktörden oluşmaktadır. Dendritler, diğer hücrelerden edindiği bilgileri hücre gövdesine bir ağaç yapısı biçiminde ince yollarla aktarır. Aksonlar ise elektriksel darbeler biçimindeki bilgiyi hücreden dışarı aktaran daha uzun bir yol şeklinde açıklanmaktadır. Aksonların bitimi, ince yollara dönüşebilir ve bu yollar, diğer hücreler için dendritleri meydana getirir (Kabalıcı, 2013, s. 3).

#### 6.4.2. Yapay sinir hücresi

Yapay bir nöron, biyolojik nöronların bir modeli olarak algılanan sinirsel bir işlevdir. Yapay nöronlar yapay sinir ağındaki temel birimlerdir. Yapay nöron, bir veya daha fazla girdiyi (nöral dendritlerde eksitatör postsinaptik potansiyelleri ve inhibitör postsinaptik potansiyelleri temsil eder) alır ve bunları bir çıktı (veya aksonu boyunca iletilen bir nöronun eylem potansiyelini temsil eden aktivasyon) üretmeye ayırır.

Biyolojik sinir hücresinin girdi, işlem ve çıktı karakteristiğini gerçeklemek üzere oluşturulmuş bir yapay sinir hücresi şekilde yer almaktadır. Şekilde görüldüğü üzere

yapay sinir hücresi altı birimden meydana gelmektedir. Bunlar girişler ( $x_i$ ), ağırlıklar ( $\omega_i$ ), esikler ( $b_i$ ), toplam fonksiyonları ( $\Sigma$ ), aktivasyon fonksiyonu ( $f$ ) ve çıkış değeri ( $y$ )'dir.



Şekil 6.2. Yapay sinir hücresi

Bu hücrelerin paralel bağlanmasıyla katmanlar, katmanların seri bağlanmasıyla çok katmanlı yapay sinir ağları meydana gelir (Bolat, Kalenderli, & Önal, 2004, s. 215).

## 6.5. Yapay Sinir Ağları Modelleri

Yapay Sinir ağları modelleri ileri ve geri beslemeli ağlar olarak sınıflandırılmıştır. Bu ağlar bu bölümde detaylandırılacaktır.

### 6.5.1. İleri beslemeli ağlar

İleriye dönük bir sinir ağı, birimler arasındaki bağlantıların bir döngü oluşturmadığı yapay bir sinir ağıdır. Bu nedenle, tekrarlayan sinir ağlarından farklıdır. İleriye dönük sinir ağı, tasarlanan yapay sinir ağının ilk ve en basit şeklini oluşturmaktadır. Bu ağda, bilgi, giriş düğümlerinden, gizli düğümlerden (varsa) ve çıkış düğümlerinden ileri doğru, sadece bir yönde hareket eder (Bebis & Georgiopoulos, 1994, s. 27).

### 6.5.2. Geri beslemeli ağlar

Son yıllarda yapay sinir ağı yapısı çoğu alanda kullanılmaktadır. İlk etapta sadece doğrusal sistemler için kullanımı gerçekleşse de günümüzde doğrusal olmayan sistemlerin analizi için de kullanılabilir. Elman ve Jordan tarafından ortaya çıkarılan yinelemeli (recurrent) yapay sinir ağları, nöronları kendi aralarında geri besleme şeklinde bilgi gönderebilen sinir ağı türü olarak tanımlanabilmektedir.

## 6.6. Yapay Sinir Ağlarında Öğrenme Algoritmaları

Yapay sinir ağları öğrenme algoritmaları, danışmanlı, danışmansız ve takviyeli öğrenme olarak sınıflandırılmıştır. Bu algoritmalar aşağıda detaylandırılmıştır.

### 6.6.1. Danışmanlı öğrenme

Pratik makine öğreniminin çoğunluğu danışmanlı öğrenmeyi kullanır. Danışmanlı öğrenme, giriş değişkenleri (X) ve bir çıkış değişkeni (Y) buldurmaktadır ve eşleme işlevini girişten çıktıya öğrenmek için bir algoritma kullanır. Aşağıda fonksiyon gösterimine yer verilmiştir:

$$Y = f(X)$$

Burada amaç, eşleme fonksiyonunu yaklaşık olarak tahmin etmektir ki, yeni giriş verisi (X) olduğunda, bu veriler için çıkış değişkenlerini (Y) tahmin edebilmektedir. Bu öğrenme danışmanlı (denetimli) öğrenme olarak adlandırılır çünkü eğitim veri kümesinden bir algoritma öğrenme süreci, öğrenme sürecini denetleyen bir öğretmen olarak düşünülebilir. Algoritma kabul edilebilir bir performans seviyesine ulaştığında öğrenme durur (Brownlee, 2016, s. 1).

Denetimli makine öğrenimi algoritmalarının bazı popüler örnekleri şunlardır:

- Regresyon problemleri için doğrusal regresyon.
- Sınıflandırma ve regresyon problemleri için rasgele orman.
- Sınıflandırma problemleri için vektör makineleri desteği.

### 6.6.2. Danışmansız öğrenme

Danışmansız (Denetimsiz) öğrenme, yalnızca giriş verisine (X) ve karşılık gelen çıktı değişkenlerine sahip olunmadığı durumu ifade etmektedir. Denetimsiz öğrenmenin amacı, verilerle ilgili daha fazla bilgi edinmek için verilerdeki temel yapıyı veya dağılımı modellemektir. Bunlara denetimsiz öğrenme denir, çünkü yukardaki denetlenen öğrenmeden farklı olarak doğru cevap yoktur ve öğretmen yoktur. Algoritmalar, verilerdeki ilginç yapıyı keşfetmek ve sunmak için kendi planlarına bırakılmıştır (Brownlee, 2016, s. 1).

Denetimsiz öğrenim algoritmalarının bazı popüler örnekleri şunlardır:

- K-kümeleme problemleri için araçlar.
- İlişkilendirme kuralı öğrenme problemleri için Apriori algoritması.

### **6.6.3. Takviyeli öğrenme**

Takviyeli öğrenme (RL), davranışçı psikolojiden esinlenen, kümülatif ödül kavramını en üst düzeye çıkaracak şekilde yazılım ajanlarının bir ortamda nasıl harekete geçmeleri gerektiği ile ilgili bir makine öğrenim alanıdır. Sorun, genelliği nedeniyle, oyun teorisi, kontrol teorisi, yöneylem araştırması, bilgi teorisi, simülasyon temelli optimizasyon, çok ajanlı sistemler, sürü zekası, istatistik ve genetik algoritmalar gibi diğer birçok disiplinde incelenmektedir. Operasyon araştırma ve kontrol literatüründe, takviye öğrenmeye yaklaşık dinamik programlama veya nöro dinamik programlama denir. Takviye öğrenmeye ilginin sorunları, optimal çözümün varlığı ve karakterizasyonu ile ilgili olan optimal kontrol teorisinde ve kesin hesaplamaları için algoritmalar ve özellikle de yokluğunda öğrenme veya yakınlaştırma ile daha az çalışılmıştır. Ekonomide ve oyun teorisinde, takviyeli öğrenme, sınırlı rasyonalite altında dengenin nasıl ortaya çıkabileceğini açıklamak için kullanılabilir (Sutton, 1996, s. 1038).

Makine öğrenmesinde, bu bağlamda pek çok pekiştirme öğrenme algoritması dinamik programlama teknikleri kullandığından, çevre genellikle bir Markov karar süreci (MDP) olarak formüle edilir. Klasik dinamik programlama yöntemleri ve

pekiştirme öğrenme algoritmaları arasındaki temel fark, ikincisinin MDP'nin tam bir matematiksel modelini bilmediği ve tam yöntemlerin mümkün olmadığı yerlerde büyük MDP'leri hedef aldıklarıdır. Takviye öğrenimi standart denetimli öğrenmeden farklıdır. Odak noktası, keşif (keşfedilmemiş topraklar) ile sömürü (mevcut bilginin) arasında bir denge bulmayı içeren performans üzerinedir (Cavaioni, 2017, s. 1).

## **6.7. Yapay Sinir Ağlarında Öğrenme Kuralları**

Yapay sinir ağlarında çeşitli öğrenme kuralları bulunmaktadır. Bu bölümde, Hebb, Hopfield, Kohenon ve Delta kuralları açıklanacaktır.

### **6.7.1. Hebb kuralı**

Hebbian öğrenme, en eski öğrenme algoritmalarından biridir ve büyük ölçüde biyolojik sistemlerin dinamiğine dayanır. Sinapsın her iki tarafındaki (giriş ve çıkış) nöronlar yüksek korelasyonlu çıkışlara sahip olduğunda, iki nöron arasındaki bir sinaps güçlenir. Özünde, bir giriş nöronu patladığında, sıklıkla çıkış nöronunun ateşlenmesine yol açarsa, sinaps güçlenir. Yapay bir sisteme benzetmenin ardından, iki ardışık nöron arasındaki yüksek korelasyon ile dal katsayılarını artırılır. Hebbian öğrenme algoritması yerel olarak gerçekleştirilir ve genel sistem girdi-çıkışı özelliği dikkate alınmaz (Jain, Mao, & Mohiuddin, 1996, s. 31).

### **6.7.2. Hopfield kuralı**

Bu model ilk olarak Hopfield tarafından önerilmiştir. Bu modelde, her nöron diğer nöronlardan gelen bilgilere göre çalışır. Hopfield ağları, çağrışımsal bir bellek olarak kullanılabilir bir tür tekrarlayan sinir ağlarıdır. Birleştirici bellek, içerik adreslenebilir bellek olarak bilinir. İçerik adresli belleğin ana görevi, bellekte saklanan bir deseni iptal etmektir. Tamamlanmamış bir paterni tamamlama veya paternin gürültülü versiyonunu temizleme taleplerini yanıtlar. Birleştirici hafıza, beynin temel işlevlerinden biridir. Çok çeşitli somut veya somut olmayan şeyleri birleştirir. Örneğin, adresleri isimleri, renkleri olan harfleri, kokulu sesleri, vb. ile



ilişkilendirir. İlişkili anılar ya ileri besleme veya tekrarlayan sinir ağları kullanılarak uygulanabilir. Tüm otomasyon ağları arasında, Hopfield ağı en yaygın olarak bilinir. Birleştirici hafıza özelliği, ağırlıkların uygun şekilde seçilmesi durumunda, bellek modellerinden birine yakın olan giriş durumlarının, bu bellek modeline daha da yakın olan çıkış durumları ile eşleştirileceği gerçeğini ifade eder (Hopfield, 1982, s. 2554).

### 6.7.3. Kohonen kuralı

Bu bölümde Kohonen ağları olarak bilinen yapıların bazı örnekleri ele alınmaktadır. Hesaplama öğeleri örgüsü, bir birimin yakın birimlerini tanımlamamıza izin verir. Bu çok önemlidir, çünkü öğrenme sırasında bilgisayar birimlerinin ağırlıkları ve yakın birimleri güncellenir. Böyle bir öğrenme yaklaşımının amacı, yakın (komşu) birimlerin yakından ilişkili sinyallere tepki vermeyi öğrenmeleridir. Kohonen birimlerinin bir boyutlu zincirini kullanarak n boyutlu bir alanı listeleme problemi düşünüldüğünde, üniteler sırayla düzenlenmiştir ve 1'den m'ye kadar numaralandırılmıştır. Her ünite, boyutsal x girişine dönüşür ve karşılık gelen uyarımı hesaplar. Hesaplama için boyutsal ağırlık vektörleri  $w_1, w_2, \dots, w_m$  kullanılmıştır. Çizelgeleme sürecinin amacı, her bir birimin giriş alanının farklı bölgelerinde uzmanlaşmayı öğrenmesidir. Böyle bir bölgeden bir giriş ağı beslendiğinde, ilgili birim maksimum uyarımı hesaplamalıdır. Kohonen'in öğrenme algoritması, bu etkinin elde edildiğini garanti etmek için kullanılır. Bir Kohonen birimi, bir giriş x ve onun ağırlık vektörü w arasında Euclidian mesafesini hesaplar. Bu yeni uyarım tanımı, belirli uygulamalar için daha uygundur ve görselleştirilmesi daha kolaydır. Kohonen tek boyutlu ağında, k-th konumunda bir birimin yarıçapı 1 olan k - 1 ve k + 1 konumlarındaki birimlerden oluşur. Zincirin her iki ucundaki birimler asimetric konuma sahiptir. Birim k'nin yarıçapı r, zincire kadar k'dan sola veya sağa doğru r pozisyonlarına kadar yer alan tüm birimlerden oluşur. Kohonen öğrenimi,  $\phi(i, k)$  değeri, eğitim süreci boyunca birim i ve birim k arasındaki bağlantının gücünü temsil eden bir komşuluk fonksiyonunu kullanır. Basit bir seçim, tüm birimler için  $\phi(i, k) = 1$  i, birim k'nin yarıçapı r biriminde ve diğer tüm birimler için  $\phi(i, k) = 0$ 'ı tanımlamaktır (Karacaören, 2017, s. 12).

#### 6.7.4. Delta kuralı

Widrow ve Hoff tarafından geliştirilen, aynı zamanda En Küçük Ortalama Kareler (LMS) yöntemi olarak adlandırılan delta kuralı, en yaygın kullanılan öğrenme kurallarından biridir. Verilen bir giriş vektörü için çıktı vektörü doğru cevabı ile karşılaştırılmaktadır. Fark sıfır ise, öğrenme gerçekleşmez; aksi takdirde, ağırlıklar bu farkı azaltmak için ayarlanır.  $u_i$ 'den  $u_j$ 'ye olan ağırlıktaki değişim şu şekilde verilir:  $dw_{ij} = r \cdot a_i \cdot e_j$ , burada öğrenme hızı,  $a_i$ ,  $u_i$ 'nin aktivasyonunu temsil eder ve  $e_j$ , beklenen çıktı ile  $u_j$ 'nin gerçek çıkışı arasındaki farktır. Eğer girdi modellerinin kümesi doğrusal olarak bağımsız bir set oluşturuyorsa, o zaman delta kuralını kullanarak keyfi ilişkilendirmeler öğrenilebilir.

Doğrusal aktivasyon fonksiyonları olan ve hiçbir gizli birimi olmayan ağlarda (ikiden fazla katmana sahip ağlarda gizli birimler bulunur), ağırlık grafiğine karşılık gelen hata karesi n-uzaydaki bir paraboloiddir. Orantı sabiti negatif olduğu için, böyle bir fonksiyonun grafiği içbükeydir ve minimum bir değere sahiptir. Bu paraboloidin köşesi, hatanın en aza indirildiği noktayı temsil eder. Bu noktaya karşılık gelen ağırlık vektörü, ideal ağırlık vektörüdür. Bu öğrenme kuralı, ağırlık vektörünü sadece ideal ağırlık vektörüne yaklaştırmakla kalmaz, bunu en verimli şekilde yapar. Delta kuralı, ağırlık vektörünü paraboloidin yüzeyindeki noktadan en alt noktaya, tepe noktasına doğru hareket ettirir (Widrow & Lehr, 1990, s. 1415).

### 6.8. Geri Yayılım Algoritması ve Çok Katmanlı Algılayıcılar

Geri yayılım algoritması ve çok katmanlı algılayıcılar (ÇKA) ve bu algılayıcıların ileri ve geri besleme aşaması aşağıda detaylandırılmıştır.

#### 6.8.1. ÇKA'da ileri besleme aşaması

Bu ağ sınıfı, genellikle ileriye dönük olarak birbirine bağlı birden fazla hesaplama birimi katmanından oluşur. Tek bir katmandaki her nöron, sonraki tabakanın

nöronlarına bağlantılar yönelmiştir. Birçok uygulamada, bu ağların birimleri bir aktivasyon fonksiyonu olarak bir sigmoid fonksiyonu uygular. Nöral ağlar için evrensel yaklaşım teoremi, gerçek sayıların aralıklarını gerçek sayıların bazı çıkış aralıkları ile eşleyen her sürekli fonksiyonun, sadece bir gizli tabakayla bir ÇKA tarafından keyfi olarak yakınlştırılabileceğini belirtir (Popescu, Balas, Perescu-Popescu, & Mastorakis, 2009, s. 579).

Çok katmanlı ağlar, en popüler geri yayılım olan çeşitli öğrenme teknikleri kullanır. Burada, çıkış değerleri, önceden tanımlanmış bazı hata fonksiyonlarının değerini hesaplamak için doğru cevapla karşılaştırılır. Çeşitli tekniklerle, hata daha sonra ağ üzerinden geri beslenir. Bu bilgiyi kullanarak, algoritma hata fonksiyonunun değerini azaltmak için her bağlantının ağırlığını biraz küçük miktarlarda ayarlar. Yeterli sayıda eğitim döngüsü için bu işlemi tekrarladıktan sonra, ağ genellikle hesaplama hatalarının küçük olduğu bazı durumlara yakınlşacaktır. Bu durumda, ağın belirli bir hedef işlevi öğrendiği söylenebilir. Ağırlıkları uygun şekilde ayarlamak için, gradyan alçalma olarak adlandırılan doğrusal olmayan optimizasyon için genel bir yöntem uygulanır. Bunun için, ağ, ağ ağırlıkları ile ilgili olarak hata fonksiyonunun türevini hesaplar ve hatanın azaldığı, böylece hata fonksiyonunun yüzeyinde aşağıya incek şekilde ağırlıkları değiştirir. Bu nedenle, geri yayılım sadece farklılaştırılabilir aktivasyon fonksiyonlarına sahip ağlarda uygulanabilir (Jain, Mao, & Mohiuddin, 1996, s. 32).

Genel olarak, iyi bir performans göstermesi için bir ağın öğretilmesi sorunu, eğitim numuneleri olarak kullanılmayan örneklerde bile, ek teknikler gerektiren oldukça ince bir sorundur. Bu özellikle çok sınırlı sayıda eğitim örneğinin bulunduğu durumlarda önemlidir. Tehlike, ağın eğitim verilerine uyduğu ve verileri üreten gerçek istatistiksel süreci yakalayamamasıdır. Hesaplamalı öğrenme teorisi, sınırlı miktarda veri üzerinde eğitim sınıflandırıcıları ile ilgilidir. Sinir ağları bağlamında, erken durdurma denilen basit bir sezgisel sıklık, ağın, eğitim setinde olmayan örneklere genel olarak iyi bir şekilde genelleştirilmesini sağlar. Geri yayılma algoritmasının diğer tipik problemleri, yakınsama hızı ve hata fonksiyonunun yerel minimumda sona erme olasılığıdır. Günümüzde, ÇKA'larda, pek çok makine

öğrenimi görevi için tercih edilen takımın geri yayılmasını sağlayan pratik yöntemler bulunmaktadır (Popescu, Balas, Perescu-Popescu, & Mastorakis, 2009, s. 579).

### **6.8.2. ÇKA'da geri besleme aşaması**

Geri yayılım ağının özlü Nöral Ağ olarak kabul edilir. Geri Yayılım, ağın kendisinden ziyade eğitim veya öğrenme algoritmasıdır. Ağı eğitmek için belirli bir girdi için Hedef denilen çıktıyı vermesi gerekmektedir. Giriş ve buna karşılık gelen hedefe Eğitim Çifti denir. Ağ eğitildikten sonra, herhangi bir giriş paterni için istenen çıktıyı sağlayacaktır. Ağ ilk önce tüm ağırlıkları küçük rastgele sayılar olacak şekilde ayarlıyor - yani -1 ve +1 arasındadır. Ardından, giriş modeli uygulanır ve çıktı hesaplanır, buna ileri geçiş adı verilir. Hesaplama, tüm ağırlıklar rastgele olduğu için, beklenenden tamamen farklı bir çıktı verir (hedef). Daha sonra, her bir nöronun hatası hesaplanmakta, bu hata ağırlıkları daha küçük olacak şekilde ağırlıkları değiştirmek için matematiksel olarak kullanılır. Diğer bir deyişle, her bir nöronun çıktısı hedefine daha yakın olacaktır. Hata en az olana kadar işlem tekrarlanır (Amardeep & ThippeSwamy, 2017, s. 19860).

### **6.9. Yapay Sinir Ağı Çalışma Prosedürü**

Bir sinir ağının ardındaki temel fikir, bir bilgisayar içinde çok sayıda birbirine bağlı beyin hücrelerinin benzetimini yapmak (basit ama makul bir şekilde sadık bir biçimde kopyalamak), böylece bir şeyler öğrenmesi, kalıpları tanıması ve insani bir şekilde kararlar almasını sağlamaktır. Sinirsel bir ağ hakkındaki önemli olan husus, açıkça öğrenmek için programlamak zorunda kalmamanızdır.

Tipik bir sinir ağı, her biri iki taraftaki katmanlara bağlanan bir dizi tabaka halinde düzenlenmiş birimler olarak adlandırılan birkaç düzine ila yüzlerce, hatta milyonlarca yapay sinir hücresine sahiptir. Bazıları giriş birimleri olarak bilinen, dış dünyadan, ağ hakkında bilgi edinmek, tanımak veya başka bir şekilde işlemeye çalışacak çeşitli bilgi formlarını almak üzere tasarlanmıştır. Diğer birimler ağın karşı tarafında oturmakta ve öğrendikleri bilgiye nasıl cevap verdiğini işaret etmektedir;

bunlar çıkış birimleri olarak bilinir. Giriş birimleri ve çıkış birimleri arasında, birlikte, yapay beynin çoğunluğunu oluşturan bir veya daha fazla gizli birim tabakası bulunur. Çoğu sinir ağları tamamen bağlıdır, yani her bir gizli birim ve her çıkış birimi her iki tarafa da her iki tarafa da bağlıdır. Bir birim ile diğeri arasındaki bağlantılar, ağırlık olarak adlandırılan bir sayı ile gösterilir; bu, pozitif olabilir (bir birim başka birini heyecanlandırır) veya negatiftir (bir birim diğeri bastırır veya engellerse). Ağırlık ne kadar yüksek olursa, bir birim bir diğere daha fazla nüfuz eder.

Bilgi, bir sinir ağından iki şekilde akar. Öğrenirken (eğitildikten) veya normal olarak (eğitildikten sonra) çalışırken, bilgi kalıpları, gizli birimlerin katmanlarını tetikleyen giriş birimleri aracılığıyla ağa beslenir ve bunlar da çıktı birimlerine ulaşır. Bu ortak tasarım, ileri besleme ağı olarak adlandırılır.

#### **6.10. Yapay Sinir Ağlarıyla Elektrik Tüketimi Tahmini**

YSA, insan beyninden esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapılarıdır. Bir başka deyişle YSA, biyolojik sinir ağlarını taklit eden bilgisayar programlarıdır. YSA zaman zaman bağlantıcılık (connectionism), paralel dağıtılmış işlem, sinirsel-işlem, doğal zeka sistemleri ve makine öğrenme algoritmaları gibi isimlerle de anılmaktadır. YSA bir programcının geleneksel yeteneklerini gerektirmeyen, kendi kendine öğrenme düzenekleridir. Bu ağlar öğrenmenin yanı sıra, ezberleme ve bilgiler arasında ilişkiler oluşturma yeteneğine de sahiptir. YSA yönteminde insan beyninin bazı organizasyon ilkelerine benzeyen özellikler kullanılmaktadır. YSA bilgi işleme sistemlerinin yeni neslini temsil ederler. Genel olarak YSA model seçimi ve sınıflandırılması, işlev tahmini, en uygun değeri bulma ve veri sınıflandırılması gibi işlerde başarılıdır. Geleneksel bilgisayarlar ise özellikle model seçme işinde verimsizdir ve sadece algoritmaya dayalı hesaplama işlemleri ile kesin aritmetik işlemlerde hızlıdırlar (Yegnanarayana, 2009, s. 17).

Birçok yapay sinir ağı tipi bulunmakla birlikte, bazılarının kullanımı diğerlerinden daha yaygındır. En çok kullanılan yapay sinir ağı, geri yayımlı yapay sinir ağı olarak bilinir. Bu tip yapay sinir ağı tahmin ve sınıflandırma işlemlerinde çok iyi sonuçlar vermektedir. Bir başkası Kohonen Öz Örgütlemeli Harita'dır. Bu tip sinir ağları, karışık bilgi kümeleri arasında ilişki bulma konusunda başarılı sonuçlar vermektedir. Belirsiz, gürültülü ve eksik bilgilerin işlenmesinde YSA başarıyla kullanılmaktadır. Teknolojik gelişme olarak da görülmesi gereken YSA metodolojisi, özellikleri ve yapabildikleri sayesinde önemli üstünlükler sunmaktadır. YSA'nın hesaplama ve bilgi işleme gücünü, paralel dağılmış yapısından, öğrenbilme ve genelleme yeteneğinden aldığı söylenebilir. Genelleme, eğitim ya da öğrenme sürecinde karşılaşılmayan girişler için de YSA'nın uygun tepkileri üretmesi olarak tanımlanır. Bu üstün özellikleri, YSA'nın karmaşık problemleri çözebilme yeteneğini gösterir (Lek & Guégan, 1999, s. 67).

Türkiye'de ileriye yönelik elektrik tüketiminin tahmin edilmesi geleceğe yönelik stratejik planların yapılması ve gereken tedbirlerin alınması açısından önem taşımaktadır. Bu amaçla Türkiye genelinde yapay sinir ağları yöntemiyle elektrik tüketim tahminlemesi yapılmıştır.

## 7. TÜKETİM TAHMİNİ UYGULAMASI

Bu bölümde YSA'nın "Türkiye'de elektrik tüketimi tahmini" problemi için uygulama adımları anlatılmış ve tüketim talebinin etkenleri incelenmiştir. YSA'nın performansı ile, YSA modelinin verileri ne derecede iyi öğrendiği ölçülmektedir. En çok kullanılan doğruluk ölçütleri şunlardır:

- Ortalama Mutlak Hata (MAE, MAD)  $= (\sum |e_t|) / N$
- Hata Kareleri Toplamı (SSE)  $= \sum (e_t)^2$
- Hata Kareler Ortalaması (MSE)  $= (\sum (e_t)^2) / N$
- Karekök Hata Kareler Ortalaması (RMSE)  $= \sqrt{MSE}$
- Ortalama Mutlak Yüzde Hata (MAPE)  $= (\sum |e_t / y_t| (100)) / N$

$e_t$ , kestirim hatası,

$y_t$ , t dönemi gözlem değeri,

N, hata terimleri sayısı

Bu ölçütlerden en yaygın kullanılanı MSE'dir. Bu ölçütün önemli bir özelliği, tahmin hatasının varyans toplamalarına ayrıştırılabilmesidir (Zhang, Patuwo, & Hu, 1998, s. 52).

Çalışmamızın performansını ölçmek için MSE ölçütü kullanılacaktır.

### 7.1. Tüketim Tahmini Probleminin Tanımlanması

Türkiye'de 1975 – 2016 yıllarında tüketilen net elektrik enerjisi verileri mevcut olup, YSA metodu ile Türkiye'de 2017 – 2030 yıllarına dair elektrik tüketimi tahmin edilecektir. Elektrik tüketimini etkileyebilecek etkenlerin olduğu doğaldır. Bu çalışmamızda girdi olarak kullanacağımız dört adet etkeni ve bu dört etkenine ek olarak elektrik tüketimi verilerini şu şekilde sıralayabiliriz;

1. **Nüfus:** Sınırları belli bir bölgede yaşayan insan sayısına nüfus denir. Bölgedeki nüfusun artması veya azalmasının, o bölgedeki elektrik tüketimini etkilemesi beklenmektedir. Ülkemizde 1975-2016 yılları bazında nüfus değişimi Tablo 7.1’de verilmiştir.


Tablo 7.1. Nüfus değişimi, Türkiye, 1975-2016 (ETBK, TÜİK, 2018)

Yıl	Nüfus (bin)	Yıl	Nüfus (bin)
1975	40.078	1996	62.697
1976	40.915	1997	62.480
1977	41.768	1998	62.464
1978	42.640	1999	63.364
1979	43.530	2000	64.269
1980	44.438	2001	65.166
1981	45.540	2002	66.003
1982	46.688	2003	66.795
1983	47.864	2004	67.599
1984	49.070	2005	68.435
1985	50.306	2006	69.295
1986	51.433	2007	70.158
1987	52.561	2008	71.052
1988	53.715	2009	72.039
1989	54.893	2010	73.142
1990	56.203	2011	74.224
1991	57.305	2012	75.176
1992	58.401	2013	76.055
1993	59.491	2014	76.903
1994	60.576	2015	77.738
1995	61.644	2016	79.815

Tablo 7.1’de görüldüğü üzere Türkiye’de nüfus, 1975 yılından bu yana geçen 40’ı aşkın senede iki katına yükselmiştir.

Bu verilerden derlenen Şekil 7’deki grafik incelenebilir.





Şekil 7.1. 1975-2016 Nüfus değişkeni

(Tablo 7.1. esas alınarak tarafımızca hazırlanmıştır.)

Şekil 7.1’de görüldüğü üzere, nüfus değişkeninin artışı sabit bir seyirde ilerlemektedir.


**2. İthalat:** Yurtdışında üretilmiş malların, ülkedeki alıcılar tarafından satın alınmasıdır. Ülkenin dış ticaret dengesini oluşturan ana unsurlardandır. Bölgedeki ithalat hacminin artması veya azalmasının, o bölgedeki elektrik tüketimini etkilemesi beklenmektedir. Ülkemizde 1975-2016 yılları bazında ithalat hacmi Tablo 8’de verilmiştir.

Tablo 7.2. İthalat hacmi, Türkiye, 1975-2016 (Hazine\_Bakanlığı, TÜİK, 2018)

Yıl	İthalat (bin ABD \$)	Yıl	İthalat (bin ABD \$)
1975	4.738.558	1996	43.626.642
1976	5.128.647	1997	48.558.721
1977	5.796.278	1998	45.921.392
1978	4.599.025	1999	40.671.272
1979	5.069.432	2000	54.502.821
1980	7.909.364	2001	41.399.083
1981	8.933.374	2002	51.553.797
1982	8.842.665	2003	69.339.692
1983	9.235.002	2004	97.539.766
1984	10.757.032	2005	116.774.151
1985	11.343.376	2006	139.576.174
1986	11.104.771	2007	170.062.715
1987	14.157.807	2008	201.963.574
1988	14.335.398	2009	140.928.421
1989	15.792.143	2010	185.544.332
1990	22.302.126	2011	240.841.676
1991	21.047.014	2012	236.545.141
1992	22.871.055	2013	251.661.250
1993	29.428.370	2014	242.177.117
1994	23.270.019	2015	207.234.359
1995	35.709.011	2016	198.618.235

Tablo 7.2’de görüldüğü üzere Türkiye’de ithalat hacmi, 1975 yılından bu yana geçen inişli çıkışlı bir grafik sergilese de, özellikle son 10 yılda hacmin hızlı bir ivme ile arttığı gözlenmektedir.

Bu verilerden derlenen Şekil 7.2’deki grafik incelenebilir.



Şekil 7.2.İthalat hacmi değişimi 1975 – 2016

(Tablo 7.2 esas alınarak tarafımızca hazırlanmıştır.)

Şekil 7.2’de yer alan grafik incelendiğinde, son 10 yıla ait yüksek ithalat hacminin 2001 ve 2009 krizlerinden etkilendiği, bu dönemlerde ithalatta keskin düşüş yaşandığı gözlenebilmektedir. Buna ek olarak 2015 ve 2016 yıllarında da ithalat hacminin düşmüş olduğu gözlenmektedir.


3. **İhracat:** Ülkede üretilen bir malın döviz karşılığında yabancı bir ülkeye satılması işlemidir. Ülkenin dış ticaret dengesini oluşturan ana unsurlardan diğeridir. Bölgedeki ihracat hacminin artması veya azalmasının, o bölgedeki elektrik tüketimini etkilemesi beklenmektedir. Ülkemizde 1975-2016 yılları bazında ihracat hacmi Tablo 7.3’de verilmiştir.

Tablo 7.3. İhracat hacmi, Türkiye, 1975-2016 (Hazine\_Bakanlığı, TÜİK, 2018)

Yıl	İhracat (bin ABD \$)	Yıl	İhracat (bin ABD \$)
1975	1.401.075	1996	23.224.465
1976	1.960.214	1997	26.261.072
1977	1.753.026	1998	26.973.952
1978	2.288.163	1999	26.587.225
1979	2.261.195	2000	27.774.906
1980	2.910.122	2001	31.334.216
1981	4.702.934	2002	36.059.089
1982	5.745.973	2003	47.252.836
1983	5.727.834	2004	63.167.153
1984	7.133.604	2005	73.476.408
1985	7.958.010	2006	85.534.676
1986	7.456.726	2007	107.271.750
1987	10.190.049	2008	132.027.196
1988	11.662.024	2009	102.142.613
1989	11.624.692	2010	113.883.219
1990	12.959.288	2011	134.906.869
1991	13.593.462	2012	152.461.737
1992	14.714.629	2013	151.802.637
1993	15.345.067	2014	157.610.158
1994	18.105.872	2015	143.838.871
1995	21.637.041	2016	142.529.584

Tablo 7.3’de görüldüğü üzere Türkiye’de ihracat hacmi, ithalat hacminden daha düşük olduğu gözlenmektedir. İhracat hacmi de 1975 yılından bu yana geçen inişli çıkışlı bir grafik sergilese de, özellikle son 10 yılda hacmin hızlı bir ivme ile arttığı gözlenmektedir.

Bu verilerden derlenen Şekil 7.3.’deki grafik incelenebilir.



Şekil 7.3. İhracat hacmi değişimi 1975 – 2016

(Tablo 7.3 esas alınarak tarafımızca hazırlanmıştır.)

Yukarıda görüldüğü üzere, ithalat ve ihracat değerleri, ithalat lehine gün geçtikçe artmaktadır. İhracat hacminin 2009 krizinden olumsuz yönde etkilendiği ve 2015, 2016 yıllarında da hacimde küçülme yaşandığı gözlenmektedir.


4. **Gayri Safi Yurtiçi Hasıla (GSYH):** Belli bir dönem (genelde bir yıl) içinde yurt içinde üretilen nihai mal ve hizmetlerin para birimi ile piyasa değerini ifade etmektedir. Halkın alım ve üretim gücünü arttırdığı için, GSYH değeri arttıkça elektrik enerjisi tüketimini arttırması beklenmektedir. Tablo 7.4'te 1975 – 2016 yılları arası Türkiye'deki GSYH'nin yıl bazında değişimi yer almaktadır.

Tablo 7.4. GSYH, Türkiye, 1975-2015

(Hazine\_Bakanlığı, TÜİK\_1, 2018); (Hazine\_Bakanlığı, TÜİK\_2, 2018)

Yıl	GSYH (milyon TL)	Yıl	GSYH (milyon TL)
1975	0,67	1996	14.772,11
1976	0,86	1997	28.835,88
1977	1,10	1998	70.203,15
1978	1,63	1999	104.595,92
1979	2,85	2000	166.658,02
1980	5,23	2001	240.224,08
1981	7,90	2002	350.476,09
1982	10,49	2003	454.780,66
1983	13,91	2004	559.033,03
1984	22,00	2005	648.931,71
1985	35,10	2006	758.390,79
1986	51,08	2007	843.178,42
1987	74,72	2008	950.534,25
1988	129,22	2009	952.558,58
1989	227,32	2010	1.098.799,35
1990	393,06	2011	1.297.713,21
1991	630,12	2012	1.416.798,49
1992	1.093,37	2013	1.567.289,24
1993	1.981,87	2014	1.748.167,82
1994	3.868,43	2015	2.237.530,41
1995	7.762,46	2016	2.590.517,32

Tablo 7.4'te görüldüğü üzere Türkiye'de GSYH 1975 yılından bu yana artan bir ivme sergilemektedir. Bu verilerden derlenen Şekil 7.4'deki grafik incelenebilir.




Şekil 7.4. Gayri safi yurt içi hasılanın değişimi 1975 – 2016

(Tablo 7.4 esas alınarak tarafımızca hazırlanmıştır.)

Yukarıda görüldüğü üzere, GSYH değişimi şoklar haricinde gelişmekte olan bir ülke olan Türkiye için uygun olacak biçimde artarak ilerlemektedir.

5. **Net Elektrik Tüketimi (GWh):** Yukarıda bahsi geçen nüfus, ithalat, ihracat ve GSYH parametrelerinin elektrik tüketimini etkilediği öngörülmektedir. Türkiye’de 1975-2016 yılları arasında net kurulu güç, brüt ve net elektrik tüketimi, bölgeler bazında tüketim vs konularına “3. TÜRKİYE’DE ELEKTRİK TÜKETİMİ” bölümünde detaylı bir şekilde yer verilmiştir.

Şekil 7.5’de ilgili yıllara dair net elektrik tüketimini gözlemleyebiliriz.



Şekil 7.5. Türkiye’de yıllara göre net elektrik tüketimi 1975 – 2016

(Tablo 4.1’deki net tüketim sütunu esas alınarak tarafımızca hazırlanmıştır.)

Türkiye’de elektrik tüketimi tahminlemesi için uzun dönemli elektrik enerjisi tüketimi tahmininde yapay sinir ağlarını kullanılmış, yapay sinir ağları teknikleri ile bulunan neticeler, Box-Jenkins modelleri ve regresyon tekniği ile karşılaştırılmıştır. Bulunan sonuçlar yapay sinir ağlarının elektrik enerjisi tüketiminde iyi bir tahmin aracı olduğunu göstermiştir. (Hamzaçebi (2013))

## 7.2. Yapay Sinir Ağı Mimarisi

En uygun YSA mimarisi oluşturulması için kullanılacak parametreler belirlenirken bazı tekniklere başvurulmaktadır. Bu yöntemler karmaşık ve uygulanması zordur. Aynı zamanda, gerçek tahmin problemleri için en uygun çözümü sunacakları da kesin değildir. Bu özelliğinden dolayı YSA tasarımının bir bilimden ziyade bir sanat olduğu sıklıkla vurgulanmaktadır (Zhang, Patuwo, & Hu, 1998, s. 42).

### 7.2.1. Ağın eğitilmesi

YSA'ların nöron bağlantılarının ağırlık değerlerinin belirlenmesi sırasında "ağın eğitilmesi" gerçekleştirilir. Başlangıç değerleri rastgeledir. YSA'ya örnekler gösterildikçe ağırlık değerleri değiştirilir (Oztemel, 2006, s. 18).

Literatürde veri sayısının, eğitim ve test veri seti dağılımının genelde %90 - %10, %80 - %20 ya da %70 - %30 oranlarında ayrıldığı gözlenmektedir. Bu kurala göre eğitim veri seti YSA modelini geliştirmek için kullanılırken, test veri seti modelin tahmin yeteneğinin geliştirilmesinde kullanılır. Eğitim ve test veri setinin seçimi sırasında yapılan hatalar ağ performansını etkilemektedir. Bu nedenle örnek uzayı temsil eden veriler kullanılmalıdır (Zhang, Patuwo, & Hu, 1998, s. 50).

Tüketim tahminlerine dair yapılan araştırmalarda yaygın olarak geri yayılım algoritması kullanıldığı gözlenmiş olup, bu çalışmamızda çok katmanlı ileri beslemeli geri yayılım algoritması kullanılmıştır. 1975 – 2016 yıllarına ilişkin 42 döneme ait verilerin; %70'i ağ eğitimi, %15'i ağ doğrulaması ve %15'i ağın test edilmesi için kullanılmıştır.

### 7.2.2. Verilerin normalizasyonu

YSA'nın öğrenme sürecinde uygulanan "veri normalleştirme" işlemi konusunda araştırmalar yapılmış ve normalleştirmenin faydalı olduğu, ancak örnek büyüklüğü arttığında faydanın azaldığı sonucuna ulaşılmıştır. Çalışmamızda kullanacağımız



data büyüklüğü normalizasyon yöntemi için uygun bulunmaktadır. Normalize işlemi ile uç değerlerden kurtularak veriler daha iyi modellenebilmektedir. Normalleştirme aralığının seçimi, çıktı katmanındaki nöronların transfer fonksiyonuna bağlıdır. Eğer çıktı katmanında Sigmoid fonksiyonu kullanılmış ise normalleştirme aralığı [0,1], hiperbolik tanjant fonksiyonu kullanılmış ise normalleştirme aralığı [-1,1] olarak seçilir (Zhang, Patuwo, & Hu, 1998, s. 50). Bizim çalışmamızda sigmoid fonksiyon kullanıldığı için , normalizasyon yöntemi [0 - 1] aralığında yer alacak şekilde dönüştürülerek aktarılmıştır.

Kullanılan Normalizasyon Formülü:

[0, 1] aralığında doğrusal dönüşüm:

$$x_n = (x_0 - x_{\min}) / (x_{\max} - x_{\min})$$

$x_n$ : normalleştirilmiş veri,

$x_0$ : orijinal veri,

$x_{\min}$ : satır veya sütün boyunca minimum değeri

$x_{\max}$ : satır veya sütün boyunca maksimum değerleri ifade etmektedir.

### 7.2.3. Gizli katman ve nöron sayısının belirlenmesi

Araştırma yapılan konuya, veri büyüklüğüne ve tasarıma bağlı olarak gizli katman sayısı değişmektedir. Genellikle bir ya da iki gizli katman yeterlidir. Gizli katman sayısının artması ağıın hızını düşürmekte ve ağıın ezberlemesine sebep olabilmektedir. Oysa ki amacımız, ağıın öğrenmesini sağlamaktır. Giriş-gizli-çıkış olacak şekilde genelde üç katmanlı yapı tercih edilmektedir. Sonuç yeterince tatmin edici olmazsa iki ya da üç ara katman denenebilmektedir. Birçok tahmin problemi çözümünde ikiden fazla gizli katmanlı yapılara ihtiyaç olmadığını gözlenmiştir (Zhang, Patuwo, & Hu, 1998, s. 44). Ayrıca, uygulamalar göstermiştir ki, toplamda dört katmandan fazlası ağıın başarı performansını ters yönde etkilemektedir (Kaastra & Boyd, 1996, s. 215).

Nöron sayısı için de net bir kural yoktur. Nöron sayısı belirleme işleminin başarısının, tasarımcının yeteneğiyle kısıtlı olduğunu ifade edebiliriz. Genellikle az

sayıda nöron ile çalışma tercih edilir. Böylece genelleştirme yeteneği daha güçlü olmaktadır. Bu konuda kesinlik içermeyen çeşitli kurallar geliştirilmiştir. üç katmanlı, n giriş hücreli (düğüm) ve m çıkış hücreli bir ağ için gizli katmandaki nöron sayısı minimum  $\sqrt{n \times m}$ , maksimum  $2n$  kadar olabilir. Buna geometrik piramit kuralı denmektedir. Baily ve Thompson üç katmanlı bir ağ için gizli hücre sayısını giriş katmanındaki hücre sayısının %75'i olarak önermektedirler (Kaastra & Boyd, 1996, s. 225).

Gizli katmandaki nöron sayısının belirlenmesi konusunda kesin kural olmamakla beraber, en uygun değer; ağın yapısına, verinin miktarına, problemin türüne, tasarımcının tecrübesine kalmıştır. Gizli katmandaki nöron sayısı deneme yanılma yoluyla belirlenmektedir. Çalışmamızda deneme yanılma yolunu benimseyerek nöron sayısını belirlemekteyiz. Modelimiz; girdi katmanı, gizli katman ve çıktı katmanından oluşmaktadır. Girdi katmanında dört, çıktı katmanında bir hücre (düğüm) bulunmaktadır. Gizli katmana verilecek en uygun nöron sayısını elde etmek için testler yapılmıştır. YSA ile yapılan araştırmalar incelendiğinde genelde bir veya en fazla iki gizli katman tercih edildiği gözlenmiştir. Çalışmamızda tek gizli katman kullanılmıştır.

### 7.3. Yapay Sinir Ağı Matlab Uygulamaları

Matlab uygulaması Tablo 7.5’de belirtilen kabullerle yürütülmüştür.

Tablo 7.5. Matlab programlama dili - YSA metodu’na ilişkin kabul parametreleri

<b>Ağ Tipi (Network Type)</b>	İleri beslemeli geri yayılım Algoritması (Feed-forward backprop)
<b>Eğitim Fonksiyonu (Training function)</b>	Traingdx
<b>Öğrenme Fonksiyonu (Adaption learning function)</b>	Learngdm
<b>Aktivasyon Fonksiyonu (Transfer fonksiyonu)</b>	Tansig – Tanjant Sigmoid Fonksiyonu
<b>Performans</b>	MSE – Mean Square Errors (Hata Kareleri Ortalaması)

Yapılan çalışmada devir sayısı ve çevrim sayısı sabit tutularak öğrenme katsayısı, momentum katsayısı ve nöron sayısı denenmiş, en uygun değerler saptanmıştır. Matlab uygulamasında kullanılmak üzere Tablo 7.6’da sabit tutulan değerler listelenmiştir.

Tablo 7. 6. YSA metodunda kullanılacak parametrelerin kabul değerleri

<b>Devir Katsayısı</b>	1000
<b>Çevrim Sayısı</b>	1000
<b>Gizli Katman Sayısı</b>	1
<b>Katman Sayısı</b>	3

Devir sayısı, çevrim sayısı, gizli katman sayısı ve katman sayısı Tablo 7.6’da verilen değerler kabul edilerek girilecek ve sırasıyla;

- Öğrenme katsayısı,
- Nöron sayısı
- Momentum katsayısı

Değerleri bulunacaktır.

Öğrenme katsayısı, momentum katsayısı ve nöron sayısındaki değişimlerinin sonuçları etkilediği gözlenmiş olup, çok sayıda deneme yapılarak sonuca varılmıştır.

### 7.3.1. Öğrenme katsayısının belirlenmesi

Nöron sayısı 8, momentum katsayısı 0.9 verilerek “öğrenme katsayısı” denemeleri yapılmıştır. Girilen değerler sonucu elde edilen Hata Kareler Ortalaması (MSE) değerleri Tablo 7.7’de gösterilmiştir.

Tablo 7.7. Öğrenme katsayısının tespiti için yapılan denemeler

Öğrenme Katsayısı	MSE
0,01	0,000147
0,02	0,000224
0,03	0,000174
0,04	0,000190
0,05	0,000154
0,06	0,000279
0,07	0,000267
0,08	0,000163
0,09	0,000273

Yapılan denemelerin sonunda 0,000147 ile en küçük MSE değerini veren öğrenme katsayısının 0,01 olduğu görülmüştür.

### 7.3.2. Nöron sayısının ve momentum katsayısının belirlenmesi

Momentum katsayısı bir önceki iterasyondaki değişimin belirli bir oranının yeni değişim miktarına eklenmesidir. Öğrenme performansında etkileyici faktördür. Bu değer küçük olması bölgesel çözümlerden kurtulmayı zorlaştırırken, çok büyük olması tek bir çözüme ulaşmakta sorun çıkartabilir (Yücesoy, 2011, s. 16).

Bir katmanda kullanılacak nöron sayısının olabildiğince az olmasının YSA'nın genelleme yeteneğini arttırdığı bilinmektedir. Nöron sayısının fazla olması ağır verileri ezberlemesine yol açabilmektedir. Bu da çok tercih edilen bir durum değildir. Tablo 7.8'de nöron sayısı ve momentum katsayısı tespiti için yapılan denemeler yer almaktadır.

Tablo 7.8. Nöron sayısı ve momentum katsayısı tespiti için yapılan denemeler örnekleme

Deneme Sayısı	Öğrenme Katsayısı	Nöron Sayısı	Momentum Katsayısı	MSE
1	0,01	2	0,1	0,000221
2	0,01	2	0,2	0,000205
3	0,01	2	0,3	0,000244
4	0,01	2	0,4	0,000186
5	0,01	2	0,5	0,000165
6	0,01	2	0,6	0,000203
7	0,01	2	0,7	0,000248
8	0,01	2	0,8	0,000324
9	0,01	2	0,9	0,000215
10	0,01	3	0,1	0,000343
11	0,01	3	0,2	0,000327
12	0,01	3	0,3	0,000282
13	0,01	3	0,4	0,000276
14	0,01	3	0,5	0,000318
15	0,01	3	0,6	0,000284
16	0,01	3	0,7	0,000413
17	0,01	3	0,8	0,000347
18	0,01	3	0,9	0,000350
19	0,01	4	0,1	0,000207
20	0,01	4	0,2	0,000279
21	0,01	4	0,3	0,000291
22	0,01	4	0,4	0,000219
23	0,01	4	0,5	0,000336
24	0,01	4	0,6	0,000306
25	0,01	4	0,7	0,000340
26	0,01	4	0,8	0,000357
27	0,01	4	0,9	0,000242
28	0,01	5	0,1	0,154000
29	0,01	5	0,2	0,000349
30	0,01	5	0,3	0,000352
31	0,01	5	0,4	0,000330
32	0,01	5	0,5	0,000401
33	0,01	5	0,6	0,000222
34	0,01	5	0,7	0,000265
35	0,01	5	0,8	0,000154
36	0,01	5	0,9	0,000197
37	0,01	6	0,1	0,000216
38	0,01	6	0,2	0,000181
39	0,01	6	0,3	0,000189
40	0,01	6	0,4	0,000270
41	0,01	6	0,5	0,000262

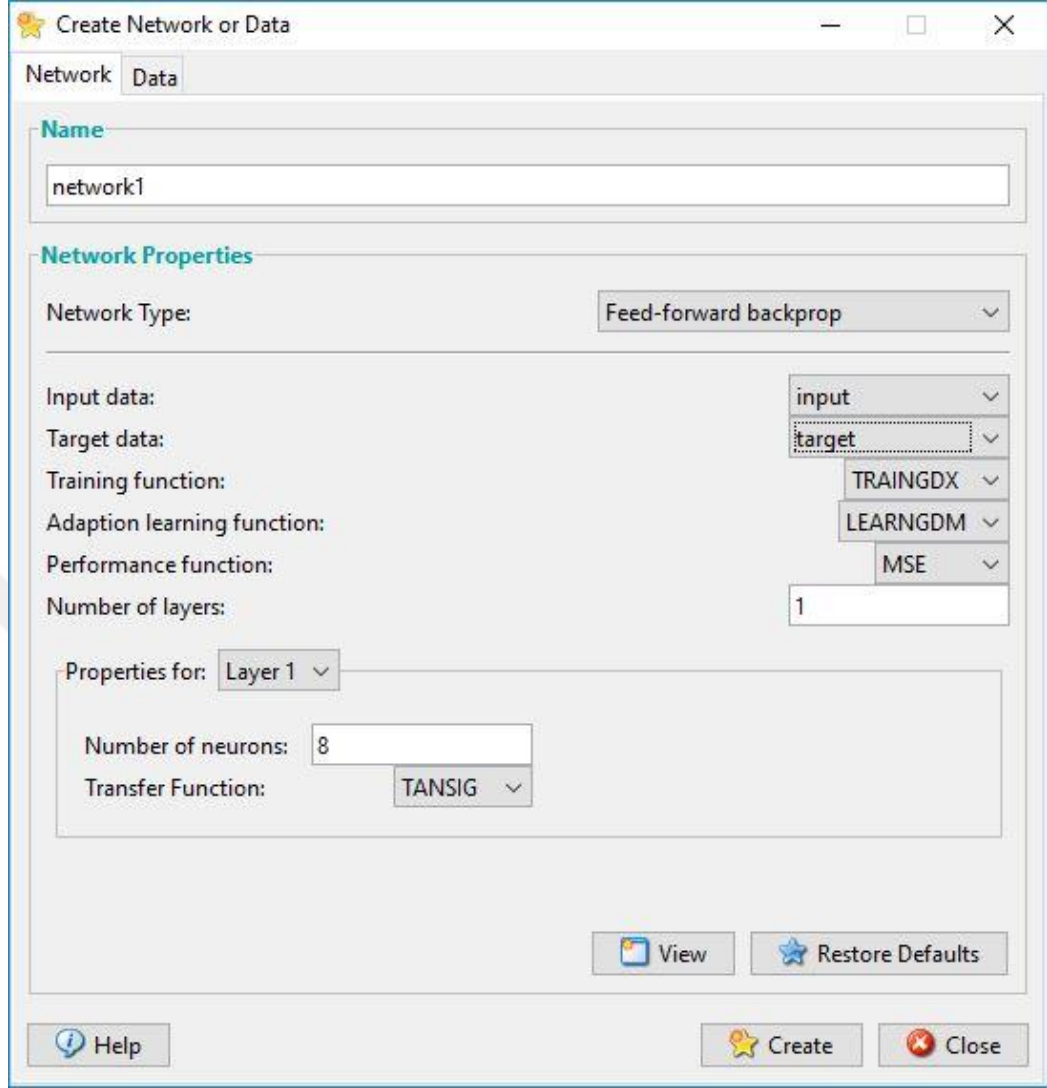
Tablo 7.8. Nöron sayısı ve momentum katsayısı tespiti için yapılan denemeler örnekleme (Devam)

Deneme Sayısı	Öğrenme Katsayısı	Nöron Sayısı	Momentum Katsayısı	MSE
42	0,01	6	0,6	0,000261
43	0,01	6	0,7	0,000343
44	0,01	6	0,8	0,000363
45	0,01	6	0,9	0,000380
46	0,01	7	0,1	0,000271
47	0,01	7	0,2	0,000187
48	0,01	7	0,3	0,001580
49	0,01	7	0,4	0,000464
50	0,01	7	0,5	0,000177
51	0,01	7	0,6	0,000514
52	0,01	7	0,7	0,005130
53	0,01	7	0,8	0,000315
54	0,01	7	0,9	0,000348
55	0,01	8	0,1	0,000380
56	0,01	8	0,2	0,000532
57	0,01	8	0,3	0,000549
58	0,01	8	0,4	0,000800
59	0,01	8	0,5	0,000471
60	0,01	8	0,6	0,000477
61	0,01	8	0,7	0,000621
62	0,01	8	0,8	0,000261
63	0,01	8	0,9	0,000130*
64	0,01	9	0,1	0,000556
65	0,01	9	0,2	0,000644
66	0,01	9	0,3	0,000297
67	0,01	9	0,4	0,000291
68	0,01	9	0,5	0,000418
69	0,01	9	0,6	0,000288
70	0,01	9	0,7	0,000168
71	0,01	9	0,8	0,000178
72	0,01	9	0,9	0,000222
73	0,01	10	0,1	0,000205
74	0,01	10	0,2	0,000169
75	0,01	10	0,3	0,000201
76	0,01	10	0,4	0,000224
77	0,01	10	0,5	0,000187
78	0,01	10	0,6	0,000174
79	0,01	10	0,7	0,000161
80	0,01	10	0,8	0,002340
81	0,01	10	0,9	0,000611

Bulunan öğrenme katsayısı 0,01 sabit bir şekilde kullanılarak, nöron sayısını [2-10] aralığında tutarak momentum katsayısına [0.1-0.9] aralığında değerler sırasıyla verilmiştir. Bu denemeler sonucunda en küçük MSE değeri 0,000130 ile; nöron sayısı 8, momentum katsayısı 0.9 olarak saptanmıştır.

#### **7.4. Yapay Sinir Ağının Eğitilmesi**

Ağ eğitimi için Matlab programının Neural Network uygulaması kullanılmıştır. Ağ yaratma ekranı Şekil 7.6'da gösterilmektedir. Ekranın "Data" kısmında normalize edilmiş olan eğitim girdi ve çıktı seti girilir. Daha sonra yine aynı yerden test girdi verisinin normalize edilmiş haliyle girişi yapılır.

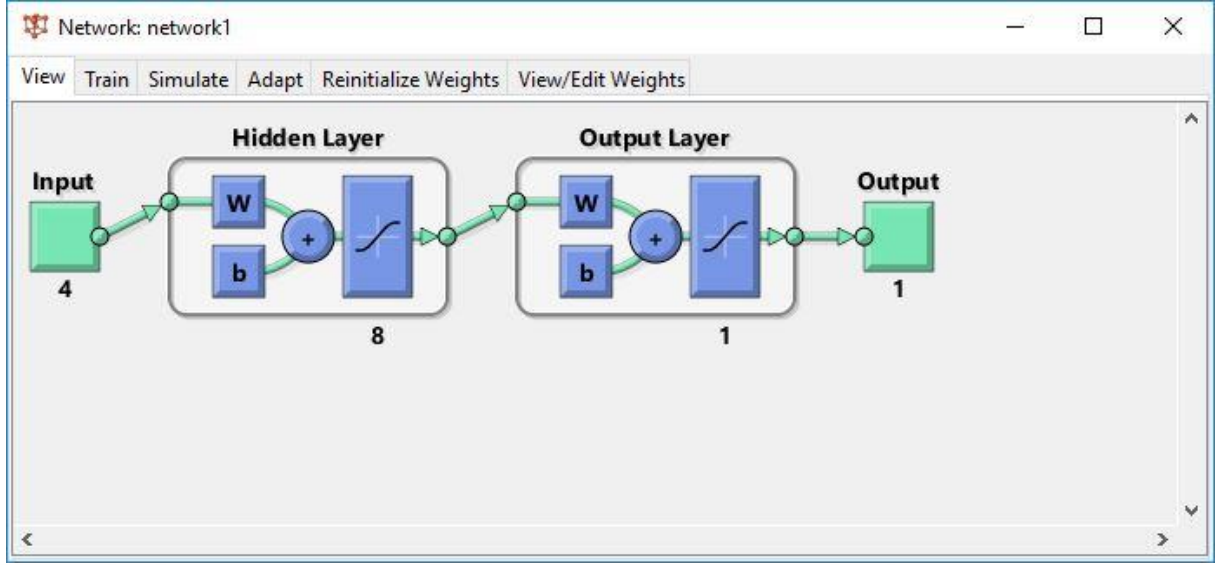


Şekil 7.6. Matlab'ta yeni ağ yaratma penceresi

“Network” kısmında oluşturmak istediğimiz ağ ile ilgili ağ tipi, eğitim girdi- çıktı verisi, eğitim ve öğrenme algoritmaları, performans fonksiyonu, katman sayısı, gizli hücre sayısı, nöron sayısı ve aktivasyon fonksiyonu girişleri yapılır ve “Create” butonuna basılarak ağ yaratma işlemi gerçekleştirilir.

Şekil 7.7’de oluşturulan yapay sinir ağı modelinin görüntüsü yer almaktadır.

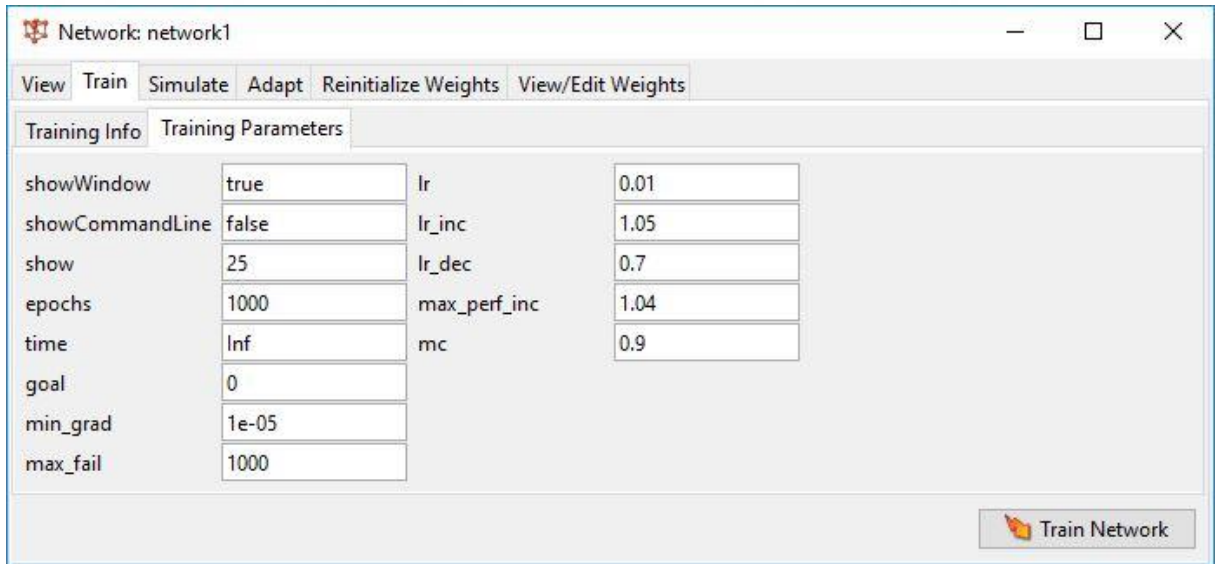




Şekil 7.7. Yapay Sinir Ağı Gösterimi

Şekil 7.7’de Matlab ekranının “Train” sekmesinde ağın eğitim işlemi gerçekleştirilir.

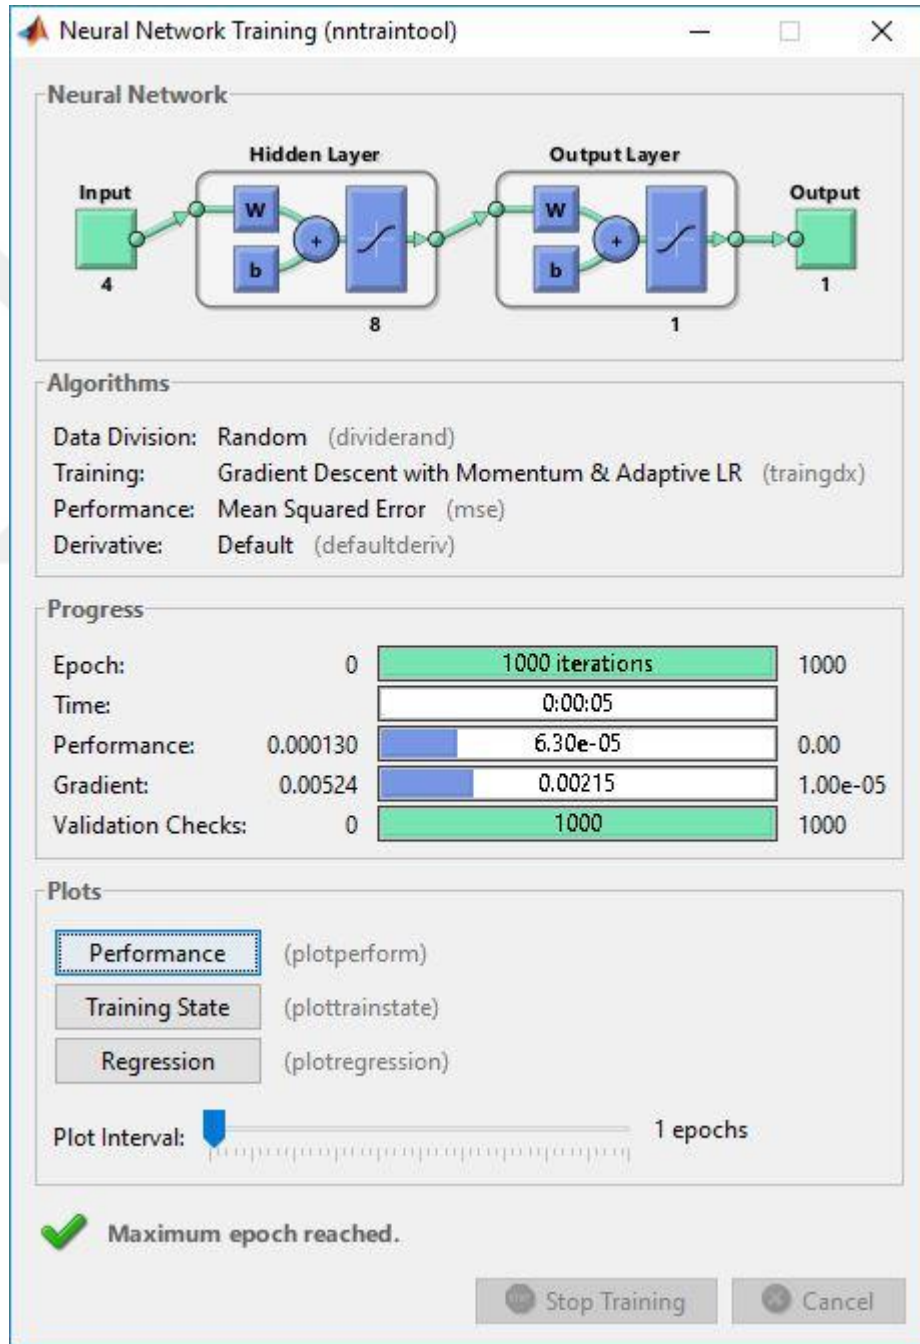
Şekil 7.8’de Train sekmesi görünmektedir.



Şekil 7.8. Matlab’ta YSA eğitim ekranı

Şekil 7.8’deki ekranda momentum katsayısı, öğrenme katsayısı ve çevrim sayısı gibi öğrenme performansını etkileyen parametreler girilir ve “Train Network” butonuna basılarak ağ eğitilir.

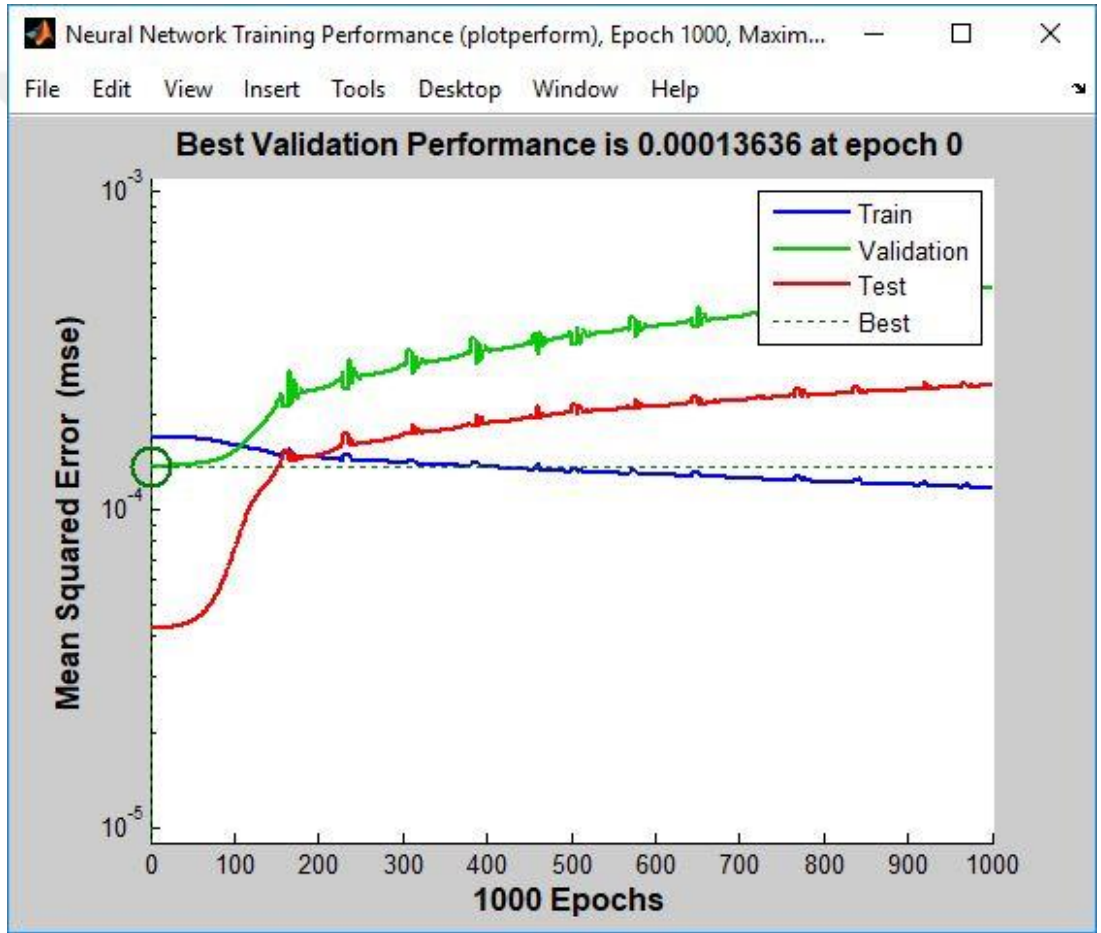
Eğitim sonucunda her iterasyondaki eğitim, doğrulama ve test kümelerine ilişkin hata değerlerinin ne şekilde değiştiği Şekil 7.9’da yer almaktadır.



Şekil 7.9. Matlab'ta YSA eğitim sonuç ekranı

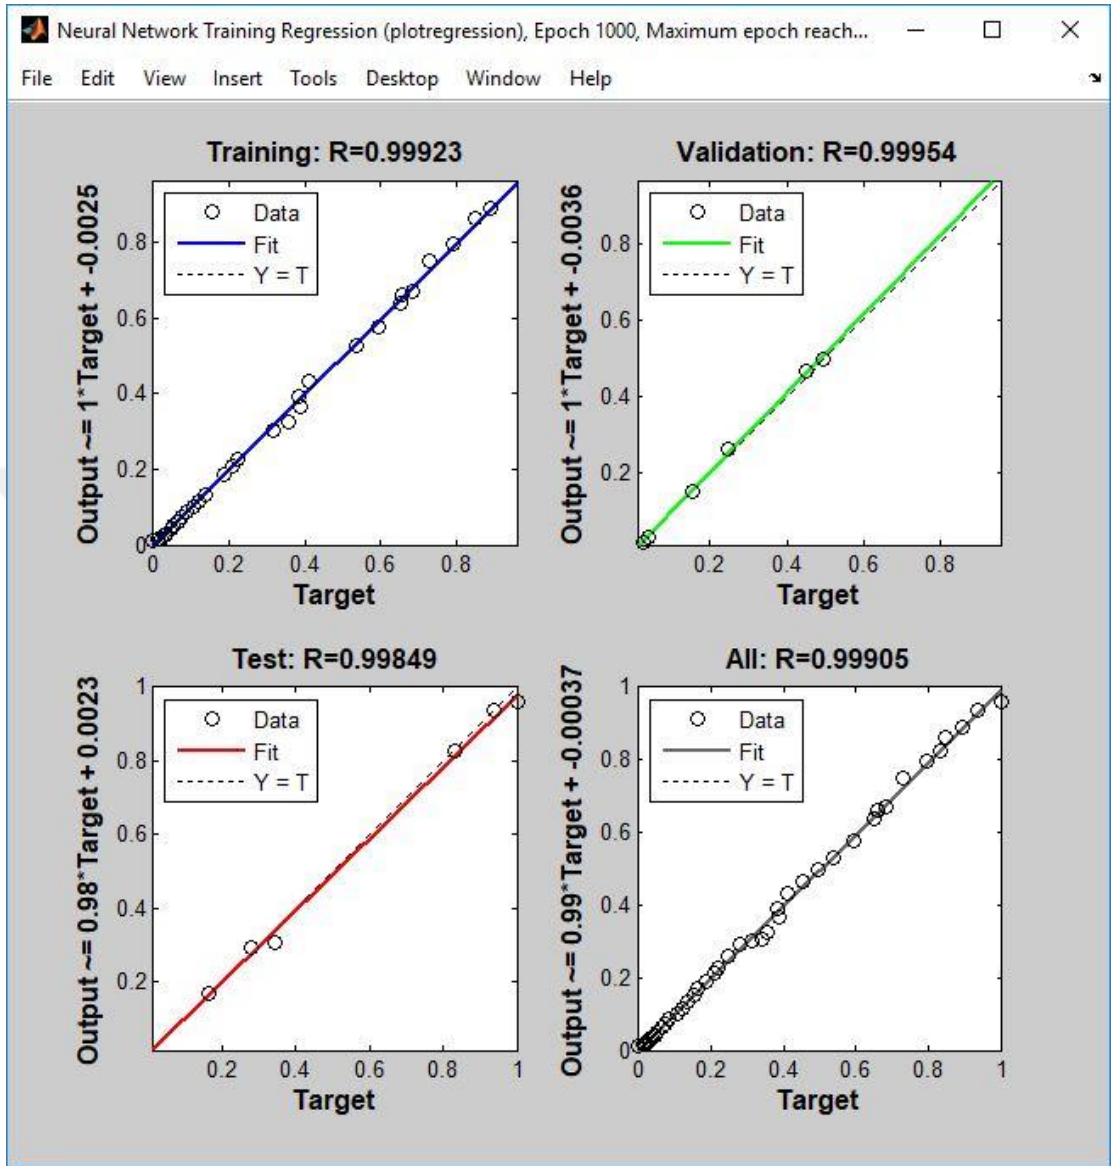
Şekil 7.9'daki ekran resminden görüldüğü üzere ağıın eğitimi 1000 iterasyonda optimum sonuca ulaştığı görülmektedir.

Matlab'da öğrenmeden sonra elde edilen regresyon grafiği Şekil 7.11'de gösterilmektedir. Bu grafiğe göre en düşük değer 0.99923 olan eğitim kümesine aittir. Buradan da anlaşılacağı üzere doğrulama işlemi büyük başarıyla gerçekleştirilmiştir. Bağımsız değişken olarak belirlediğimiz faktörler en az 0.99 oranında tüketim talebini etkilemektedir.



Şekil 7.10. Eğitim, doğrulama ve test kümelerine ilişkin hata performansları

Şekil 7.10'daki eğitim sonucunda bulunan hata kareleri ortalamasının (MSE) 0,000136 gibi minimum bir değere sahip olduğunu görülmektedir.



Şekil 7.11. Matlab'ta öğrenme, doğrulama, test kümelerine ilişkin regresyon grafiği

Tablo 7.9'da eğitim sonucunda belirlemiş olduğumuz minimum hata değerini veren YSA parametreleri yer almaktadır. Ağı test etme işlemi bu parametreleri kullanarak yapılmaktadır.

Tablo 7.9. YSA parametreleri

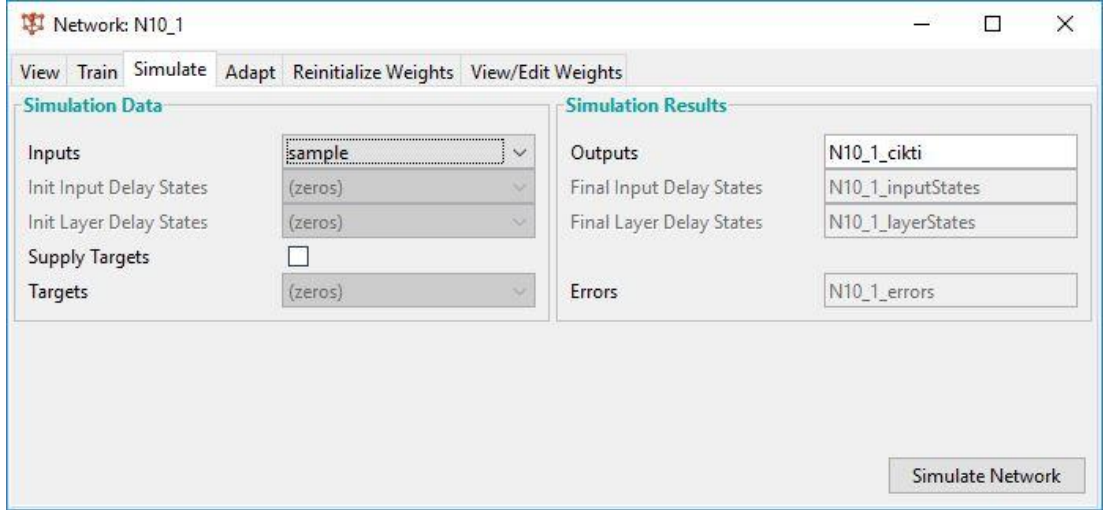
Ağ Tipi (Network Type)	İleri beslemeli geri yayılım Algoritması (Feed-forward backprop)
Eğitim Fonksiyonu (Training function)	Traingdx
Öğrenme Fonksiyonu (Adaption learning function)	Learngdm
Aktivasyon Fonksiyonu (Transfer fonksiyonu)	Tansig – Tanjant Sigmoid Fonksiyonu
Performans	MSE – Mean Square Errors (Hata Kareleri Ortalaması)
Öğrenme Katsayısı	0,01
Devir Katsayısı	1000
Çevrim Sayısı	1000
Gizli Katman Sayısı	1
Katman Sayısı	3
Momentum Katsayısı	0,9
Gizli Katmandaki Nöron Sayısı	8

Yapay sinir ağı eğitiminin tamamlanmasıyla ağ, öğrenme işlemini gerçekleştirir.

Ağın eğitilmesinden sonra ağın öğrenip öğrenmediğini ölçmek için denemeler yapılarak ağın testi yapılmıştır. Test için seçtiğimiz 15 döneme ait veriler kullanılmıştır. Tahmin etmek istediğimiz dönemlere en yakın olan son 15 yıla ait verilerdir. Bu veriler ağı gösterilir ve ağ eğitimi sırasında, ağın belirlemiş olduğu değerleri kullanarak yeni çıktılar üretir (Kargı, 2015, s. 36).

### 7.5. Sonuçların Test Edilmesi ve Değerlendirilmesi

Ağ eğitildikten sonra YSA tahmin ekranında “Simulate” sekmesinden test girdi seti için ağın tahmini test verilerini üretmesi sağlanır. Şekil 7.12’de “Simulate” penceresi yer almaktadır. Burada test girdi verisi seçilir ve “Simulate Network” butonuna basılarak ağın test edilmesi işlemi gerçekleştirilir.



Şekil 7.12. Matlab'ta YSA test ekranı


Test işleminden sonra ağın verdiği tahmini test çıktı verileri ile gerçek değerler, normalize değerlerden gerçek değerlere dönüştürülerek karşılaştırılmıştır. Buna göre MSE değeri  $6,17E+07$  olarak bulunmuştur. Tablo 7.8 ve 7.9'te belirtilen YSA parametreleri,  $6,17E+07$  hata payıyla kullanılmaktadır. Bu hata payının yeterince düşük olduğu gözlenmekte olup, 2017 – 2030 yılları arasındaki elektrik tüketimi tahmini yine bu parametrelerle gerçekleştirilecektir.

Tablo 7.10'da tahmini ve gerçek elektrik tüketim değerlerinin hem normalize hali hem de dönüştürülmüş hali yer almaktadır. Test verileri ile tahmin verileri arasında  $6,17E+07$ 'lük bir hata payı vardır.

Tablo 7.10. YSA sonucu bulunan tahmini değerler ile gerçek değerlerin karşılaştırılması

Yıl	Gerçek değer (normalize)	Tahmin değeri (normalize)	Gerçek değer	Tahmin değeri
2002	0,410892019	0,413996862	102.948	103.624
2003	0,451395125	0,447768088	111.766	110.976
2004	0,494461253	0,482724168	121.142	118.587
2005	0,536356108	0,518353689	130.263	126.344
2006	0,595186203	0,569085398	143.071	137.389
2007	0,650598934	0,661000563	155.135	157.400
2008	0,681892613	0,726277714	161.948	171.611
2009	0,658678427	0,75382554	156.894	177.609
2010	0,72829802	0,753509078	172.051	177.540
2011	0,792828314	0,83105055	186.100	194.421
2012	0,833354386	0,849768432	194.923	198.497
2013	0,847694451	0,862369319	198.045	201.240
2014	0,890549291	0,869397325	207.375	202.770
2015	0,936192221	0,902064276	217.312	209.882
2016	1,000000000	0,95850592	231.204	222.170

Ağın eğitilmesi sonucu yapılan test ile elde edilen sonuçlarla gerçek değerlerin karşılaştırmasını daha iyi gözleyebilmek için Şekil 7.13’da grafik gösterimine yer verilmektedir.



Şekil 7.13. YSA ile bulunan tahmini değerler ile gerçek değerlerin grafik gösterimi

Şekil 7.13’de test kümesi için ayırdığımız 15 döneme ilişkin verinin gerçek değerleri ile YSA ağının üretmiş olduğu tahmini değerlerin grafiksel gösterimi yer almaktadır. Grafikten de görüleceği üzere gerçek değerler iyi bir şekilde tahmin edilmiştir.

## 7.6. YSA ile Tüketim Tahmini Uygulaması

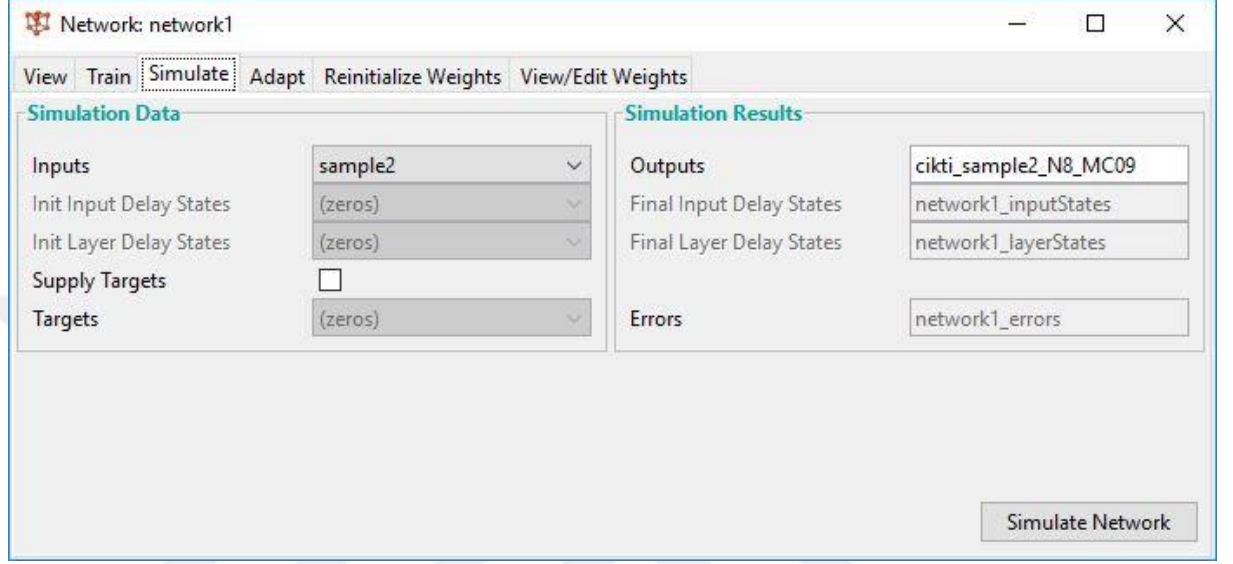
Elimizdeki 42 döneme ilişkin veri ile eğitilen ağımızın, belirlenen parametreler eşliğinde 15 döneme ilişkin veri ile test edilerek  $6,17E+07$  hata payı ile ideal bir performans sergilediği görülmektedir. Bu varsayımlar altında şimdiki adımda 2017 – 2030 yıllarına ilişkin elektrik tüketim tahmin işlemi için ağ test edilecektir. Bu döneme ilişkin tahmin edilen verilerimiz Tablo 17’de verilmektedir. Bu değerlerden Nüfus değerleri Türkiye İstatistik Kurumu (TÜİK) nüfus projeksiyonlarından ve GSYH değerleri Hazine Bakanlığı (<https://hazine.gov.tr>) yıllık beklenen değişim yüzdeleri ile hesaplanan datalarından alınmış olup, ithalat ve ihracat dataları ise matlab uygulamasının time series (zaman serisi) metodu ile tarafımca üretilmiştir.

Tablo 7.11. Girdi verilerinin 2017 – 2030 yıllarına ilişkin tahminleri

Yıl	İhracat (bin ABD \$)	İthalat (bin ABD \$)	Nüfus	GSYH (bin TL)
2017	168.388.006	214.513.564	80.810.525	2.764.831.228,15
2018	107.596.412	211.641.206	81.867.223	2.888.321.638,18
2019	109.997.011	221.692.427	82.886.421	2.965.038.495,54
2020	133.949.849	211.230.582	83.900.373	3.175.352.338,26
2021	147.432.245	216.050.154	84.908.658	3.339.633.703,98
2022	162.092.602	220.898.256	85.911.035	3.618.253.130,43
2023	130.109.153	218.805.436	86.907.367	3.911.581.155,27
2024	162.459.978	211.741.639	87.885.571	4.219.988.316,59
2025	112.342.599	220.699.729	88.844.934	4.543.845.151,86
2026	123.587.307	221.671.710	89.784.584	4.883.522.199,46
2027	144.920.689	222.653.101	90.703.600	5.239.389.996,58
2028	157.484.152	218.640.708	91.601.117	5.611.819.081,12
2029	142.732.707	219.632.462	92.476.323	6.001.179.990,78
2030	169.205.061	217.626.974	93.328.574	6.407.843.263,61



Bu deęerler, test için YSA'da kullanılmak üzere [0-1] aralıęında normalizasyon işleme tabi tutulmuş bulunmaktadır. Normalize edilmiş veriler Şekil 7.14'de gösterilen "Simulate" ekranından tanımlandıktan sonra "Simulate Network" butonuna basılarak test edilecektir.



Şekil 7.14. Matlab'ta YSA test ekranı\_2017-2030 dönemine ilişkin elektrik tüketimi tahmini için

Test işleminden sonra aęın tahmin olarak verdięi normalize test çıktı verilerinin, gerçek deęere dönüştürülmüş halleri Tablo 7.12'de yer almaktadır.

Tablo 7.12. Normalize tahminden gerçek deęerlere dnştrlen ‘tahmini elektrik tktim’ verileri

Yıl	Elektrik tktim tahmini (GWh)
2017	296.018
2018	302.304
2019	292.293
2020	325.232
2021	341.088
2022	346.650
2023	323.958
2024	376.443
2025	386.557
2026	363.355
2027	384.993
2028	396.672
2029	422.833
2030	431.077

Trkiye’de 1975-2016 dnemine iliřkin yıllık nfus sayısı, ithalat ve ihracat hacmi, GSYH deęeri verileri ile net elektrik tktim verileri kullanılarak eęitilen yapay sinir aęının, 2017 – 2030 yıllarına iliřkin rettięi tahmin deęerleri Tablo 7.12’de gsterilmektedir.

### 7.7. Uygulama Sonucu

Tahmin, ileriki tarihte neyin nasıl olacaęının řimdiden kestirilmesidir. İřletmelerde ynetimsel kararlar geleceęe ynelik tahminlerle verilmektedir. İřletmelerin gelecekte karřılařabileceęi belirsiz durumları bugnden tahmin ederek, bugnden nlemler alması, planlar hazırlaması, stratejiler belirlemesi gerekmektedir. alıřmalarını gerekleřtirdięimiz probleminin zmnde bir tahmin aracı olarak yapay sinir aęlarına ait geri yayılım algoritması denenmiřtir. YSA teorisi ile tahmin yapılacak olan uygulamalar incelenmiřtir.

Uygulama alıřmamızda, 1975-2016 yılları arasında elektrik tktimini GWh birimi ile verilmiřtir. Elektrik tktimini etkileyen etmenler, alıřma ncesinde grřlen

uzman kişilerin görüşleri alınarak belirlenmiştir. Bu etmenlere ait bilgiler, TÜİK, TEİAŞ, ETKB, Hazine Bakanlığı vb. kurum kaynaklarından elde edilmiştir. Elektrik tüketimi tahmininde Türkiye’de yıl bazında tüketilen net elektrik tüketim verileri dikkate alınmıştır. Türkiye’de elektrik tüketimini etkileyen dört temel etken ele alınmıştır. Bu etkenler; Nüfus, İthalat, İhracat, GSYH’dir. Bu bağımsız değişkenlerin, ülkedeki elektrik tüketimini ne ölçüde etkilediği yapılan testler sonunda bulunmuş olup, bulunan sonuçlar değerlendirilmiştir.

Bahsi geçen dört etkene dair 1975-2016 yılları arasındaki 42 döneme ait 168 adet veri “girdi” olarak, elektrik tüketimine dair 42 adet veri ise “tahmin” olarak [0 - 1] aralığında normalleştirilerek eğitim ve test amacıyla ağa sunulmuştur. Böylece ağın eğitilmesi gerçekleşmiş olup, uygulamanın hangi parametrelerle en uygun şekilde test edileceğine karar verilmiştir. Bu parametreler kullanılarak, son 15 yıla ait veriler yeniden ağa girilmiştir. Çıkan tahmin değerleri normalize değerden normal değerlere dönüştürülerek gerçekleşen değerlerle karşılaştırılmış ve hata kareler ortalaması değeri hesaplanmış,  $6.17E+07$  şeklinde bir hata payı bulunmuştur. Araştırmamızın ana hedefi olan 2017–2030 dönemine ilişkin elektrik tüketimi tahmini için aynı parametrelerle ve  $6.17E+07$  hata payıyla ağ çalıştırılarak beklenen tahminlere ulaşılmıştır.

Bu çalışma ve literatürde aynı konuya ilişkin farklı dönemlerde yapılmış diğer çalışmaların tahmin performanslarını karşılaştırabiliriz. Şöyle ki; Türkiye’de elektrik tüketimi için yeni bir tahmin aracını modellemeyi amaçlayan dört çalışma ile bu çalışmamız Tablo 7.13’de listelenmiştir.

Tablo 7.13. Çalışmamızın ve bu konuda yapılmış olan diğer çalışmaların tahmin performanslarının karşılaştırılması

Dönem	Kaynak	MSE
1994-2004	Akay ve Atak (2007)	6,83E+07
2007-2013	Kavaklıoğlu (2011)	6,83E+07
2007-2013	Kavaklıoğlu ve diğerleri (2009)	1,35E+08
2011-2013	Hamzacebi and Es (2014)	7,79E+07
2002-2016	Bu çalışma	6,17E+07
<b>Min MSE</b>		<b>6,17E+07</b>

(Akay & Atak, Grey prediction with rolling mechanism for electricity demand forecasting of Turkey, 2007); (Kavaklıoğlu, Modeling and prediction of Turkey's electricity consumption using Support Vector Regression, 2011); (Kavaklıoğlu K. , Ceylan, Ozturk, & Canyurt, 2009); (Hamzacebi & Es, 2014)

Tablo 7.13'deki MSE değerleri karşılaştırıldığında; Türkiye'de 2002-2016 dönemine ilişkin yıllık nüfus sayısı, ithalat ve ihracat hacmi, GSYH değeri verileri ile net elektrik tüketim verileri kullanılarak eğitilen yapay sinir ağı modellenmesi ile gerçekleştirilen çalışmamızın en iyi tahmini verdiği sonucuna varılmıştır.

6446 sayılı EPK'nın 20.maddesi, 3.fıkrası, a bendinde yer alan "Gelecek yirmi yılı kapsayan Türkiye Elektrik Enerjisi Talep Projeksiyonu Raporu, her iki yılda bir Kalkınma Bakanlığı ve Kurum görüşleri de alınmak suretiyle Bakanlık tarafından hazırlanır ve yayımlanır" hükmüne istinaden ETKB tarafından 2017 yılında hazırlanan "Gelecek yirmi yılı kapsayan Türkiye Elektrik Enerjisi Talep Projeksiyonu Raporu" Tablo 7.14'de bulunmaktadır.

- Nüfus
- Ekonomi
- Takvim etkisi
- Sıcaklık
- Enerji verimliliği
- Elektrikli araçlar
- Şebeke kaybı ve iç tüketim

konuları göz önünde bulundurularak hazırlanan tablo, 10'ar yıllık 2 dönemi kapsamakta olup, senaryo 1 kapsamında ilk 10 yıl için %4, ikinci 10 yıl için ise %2,9 oranında yıllık ortalama elektrik talep artışı varsayımına dayanmaktadır.

Tablo 7.14. ETKB elektrik enerjisi talep projeksiyonu sonuçları-yıllık (EPDK, 2017)

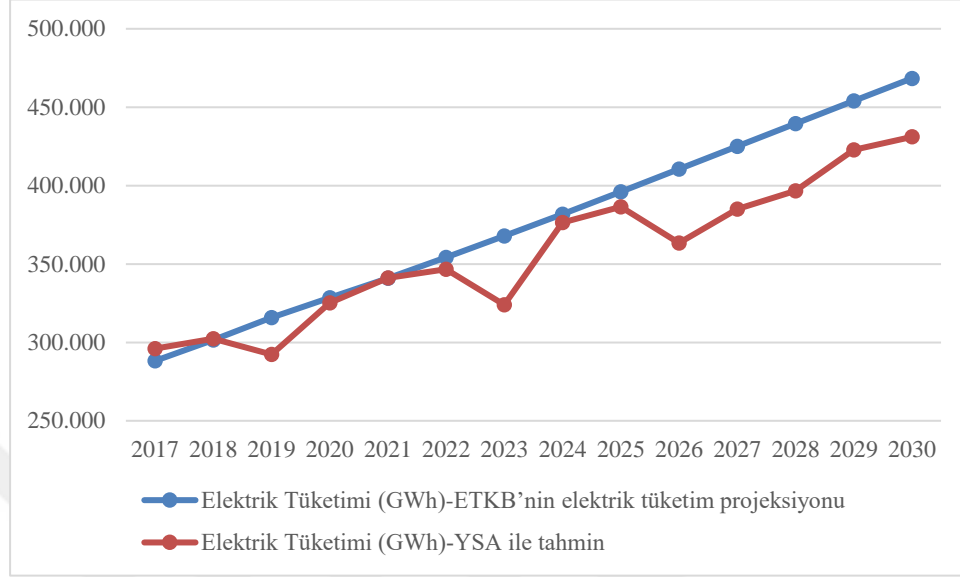
Yıl	Elektrik Talep Tahmini (GWh)	Yıl	Elektrik Talep Tahmini (GWh)
2017	288.210	2028	439.496
2018	301.512	2029	454.136
2019	315.807	2030	468.399
2020	328.409	2031	482.749
2021	341.037	2032	497.110
2022	354.156	2033	511.417
2023	367.876	2034	525.303
2024	381.814	2035	539.010
2025	396.139	2036	553.143
2026	410.530	2037	567.683
2027	424.973		

Bu projeksiyonun 2017-2030 dönemine ilişkin tahminleri ile, tez çalışmamızda YSA metodu ile aynı döneme ilişkin elde ettiğimiz tahminleri karşılaştırabiliriz.

Tablo 7.15. YSA metodu ile üretilen tahmin ile ETKB'nin prodüksiyonda üretilmiş olan geleceğe yönelik elektrik tüketimi karşılaştırması

Yıl	Elektrik Tüketimi (GWh)- ETKB'nin projeksiyonu	Elektrik Tüketimi (GWh)- YSA ile tahmin
2017	288.210	296.018
2018	301.512	302.304
2019	315.807	292.293
2020	328.409	325.232
2021	341.037	341.088
2022	354.156	346.650
2023	367.876	323.958
2024	381.814	376.443
2025	396.139	386.557
2026	410.530	363.355
2027	424.973	384.993
2028	439.496	396.672
2029	454.136	422.833
2030	468.399	431.077

Tablo 7.15’de listelenen YSA tahmini ile ETKB projeksiyonu dataları dikkate alınarak oluşturulan Şekil 7.15’deki grafik incelenebilir.



Şekil 7.15. YSA ile oluşturulan elektrik tüketimi tahmini ile ETKB tarafından oluşturulan elektrik tüketimi projeksiyonu karşılaştırması

Grafik üzerinde karşılaştırma incelendiğinde, YSA tahmininde ağ; önceki verilerde zaman zaman (2001 ve 2009 kriz dönemleri) düşüş yaşandığını algıladığından, ağın gelecekte de bu gibi düşüşlerin olabileceğini öngörerek sonuç üretmiş olduğunu söyleyebiliriz. ETKB'nin projeksiyonuna göre tahmine konu olan bu süreçte herhangi bir kriz dönemi beklenmediğini; ya da kriz olsa bile, elektrik tüketiminin bu krizden etkilenmeyeceğini söyleyebiliriz.

## 8. SONUÇ VE ÖNERİLER

Enerji, üretimin kaynağını oluşturur. Bu nedenle ulaşılabilir bir enerji politikası yürütmek önemlidir. Tek bir enerji kaynağına bağlılık, uzun vadede risk olarak görülebilir. Riski azaltmak için belli bir enerji kaynağı kullanmak yerine enerji kaynakları çeşitlendirilebilir. Günümüz koşullarına baktığımızda doğal kaynakların (petrol, doğalgaz vb.) azaldığını ve maliyetinin de aynı oranda yükseldiğini görebiliyoruz. Bu nedenle uzun vadede yenilenebilir enerji kaynaklarına yatırım yapılması, ulaşılabilir alternatif enerji seçeneklerinin sağlanmasına da katkı sağlayacaktır. Yenilenebilir enerji kaynakları potansiyeli olan ülkelerin bu potansiyeli değerlendirmesi gerekir. Ülkelerin bu konuda Ar-Ge bütçesi ayırması, yenilenebilir enerji kaynaklarından enerji üretiminin yapılabilmesi açısından kritik öneme sahiptir. Bunun en büyük nedeni, teknolojik olanakların ancak Ar-Ge çalışmaları ile sağlanabileceğidir. Yenilenebilir enerji kaynaklarının kullanımının son yıllarda artmasının en büyük nedeni, üretimin yapılabilmesi için teknolojik olanakların elverişli bir noktaya gelmiş olmasıdır.

Tahmin, ileriki tarihte neyin nasıl olacağını şimdiden kestirilmesidir. İşletmelerde yönetsel kararlar, geleceğe yönelik tahminlerle verilmektedir. İşletmelerin gelecekte karşılaşılabileceği belirsiz durumları bugünden tahmin ederek, bugünden önlemler alması, planlar hazırlaması, stratejiler belirlemesi gerekmektedir. Literatürde çeşitli tahmin metodları yer almaktadır. Çalışmalarını gerçekleştirdiğimiz probleminin çözümünde bir tahmin aracı olarak yapay sinir ağlarına (YSA) ait geri yayılım algoritması denenmiştir.

Uygulama çalışmamızda, 1975-2016 yılları arasında Türkiye’de yıl bazında tüketilen net elektrik tüketim verileri kullanılmıştır. Ve bununla birlikte elektrik tüketimini etkileyen etkenler, çalışma öncesinde görüşülen uzman kişilerin görüşleri alınarak belirlenmiştir. Bu etkenler; Nüfus, İthalat, İhracat, GSYH’dir. Bu etkenlere ait bilgiler, TÜİK, TEİAŞ, ETKB, Hazine Bakanlığı vb. kurum kaynaklarından elde edilmiştir. Bu bağımsız değişkenlerin, ülkedeki elektrik tüketimini ne ölçüde

etkilediđi yapılan testler sonunda bulunmuş olup, bulunan sonuçlar deđerlendirilmiştir.

Bahsi geen dđrt etkene dair 1975-2016 yılları arasındaki 42 dđneme ait 168 adet veri “girdi” olarak, elektrik tđketime dair 42 adet veri ise “tahmin” olarak [0 - 1] aralıđında normalleştirilerek eđitim ve test amacıyla ađa sunulmuştur. Bđylece ađın eđitilmesi gerekleşmiş olup, uygulamanın hangi parametrelerle en uygun şekilde test edileceđine karar verilmiştir. Bu parametreleri kullanarak, son 15 yıla ait veriler ađa girilerek ve ıkan tahmin deđerleri, gerekleşen deđerlerle karşılaştırılarak MSE deđerleri hesaplanmıştır.  $6,17E+07$  gibi oldukça kabul edilebilir bir hata payı bulunduđundan, araştırmamızın ana hedefi olan 2017 – 2030 yılları arasındaki elektrik tđketimi tahmini iin aynı parametrelerle ve  $6,17E+07$  hata payıyla ađ alıştırılarak beklenen tahminlere ulaşılmıştır.

Tđrkiye’de elektrik tđketimi iin yeni bir tahmin aracını modellemeyi amalayan dđrt alıřma ile bu alıřmamızın tahmin performansları karşılaştırılmış, Tđrkiye’de 2002-2016 dđnemine iliřkin yıllık nđfus sayısı, ithalat ve ihracat hacmi, GSYH deđerleri verileri ile net elektrik tđketim verileri kullanılarak eđitilen yapay sinir ađı modellemesi ile gerekleştirilen alıřmamızın en iyi tahmin sonucunu verdiđi gđrđlmüştür.

Elde edilen tahmin deđerleri, ETKB tarafından hazırlanan elektrik tđketim projeksiyonunun aynı dđnemleri ile de karşılaştırılmıştır. Karşılaştırma incelendiđinde, YSA tahmini iin modellenen ađ; nceki dđnemlerde zaman zaman (2001 ve 2009 kriz dđnemleri) dđřüş yařadıđını algıladıđından, gelecekte de bu gibi dđřüşlerin olabileceđini ngorerek sonu retmiş olduđunu sđyleyebiliriz. ETKB’nın projeksiyonuna gore bu sđrete herhangi bir kriz dđnemi beklenmediđini, veya kriz olsa bile, elektrik tđketiminin bu krizden etkilenmeyeceđini sđyleyebiliriz.



## KAYNAKLAR

- Akay, D., & Atak, M. (2007). Grey prediction with rolling mechanism for electricity demand forecasting of Turkey. *Energy* 32, 1670–1675.
- Akay, D., & Atak, M. (2007). Grey prediction with rolling mechanism for electricity demand forecasting of Turkey. *Energy* 32, 1670–1675.
- Aksel, F. (2000). Regresyon analizi ve yapay sinir ağı yöntemleri ile uzun dönem yük tahmini . İstanbul: İTÜ.
- Amardeep, R., & ThippeSwamy, D. K. (2017). Training Feed forward Neural Network With Backpropogation Algorithm. . *International Journal Of Engineering And Computer Science*, 6(1), 19860-19866.
- Bebis, G., & Georgiopoulos, M. (. (1994). Feed-forward neural networks. . *IEEE Potentials*, 13(4), 27-31.
- Bolat, S., Kalenderli, Ö., & Önal, E. (2004). Yapay Sinir Ağı İle Gaz Karışımında Elektrot Açıklığına Ve Karışım Yüzdelereine Bağlı Olarak Delinme Gerilimlerinin Belirlenmesi. *ASYU-INISTA 2004 Akıllı Sistemlerde Yenilikler ve Uygulamaları Sempozyumu.*, 215-218.
- BP. (2015). *Statistical Review of World Energy*. BP.
- Brownlee, A. (2016). *Machine Learning*. <https://machinelearningmastery.com/supervised-and-unsupervised-machine-learning-algorithms/> adresinden alındı
- Cavaioni, M. (2017). *Medium*. <https://medium.com/machine-learning-bites/machine-learning-reinforcement-learning-markov-decision-processes-431762c7515b> adresinden alındı.
- Çunkaş, M., & Taşkıran, U. (2011). Turkey's electricity consumption forecasting using genetic programming. *Energy Sources Part B* 6, 406–416.
- Daly, H. E. (2007). *Ecological economics and sustainable development*. Cheltenham: Edward Elgar Publishing.
- Darmstadter, J. (2004). *Energy and population*. Washington: Resources for the Future.
- Dedeoğlu, D., & Kaya, H. (2013). Energy use, exports, imports and GDP: New evidence from the OECD countries. *Energy Policy*, 57, 469-476.
- Ekici, S., Yıldırım, S., & Poyraz, M. (2008). Energy and entropy-based feature extraction for locating fault on transmission lines by using neural network and wavelet packet decomposition. *Expert Systems and Applications*, 2937-2944.

- Enerji Enstitüsü. (2017). <https://enerjienstitusu.org/elektrik-tuketim-istatistikleri/> adresinden alındı
- EPDK. (2017). [https://www.teias.gov.tr: https://www.teias.gov.tr/sites/default/files/2018-02/Taleprapor\\_2017.pdf](https://www.teias.gov.tr: https://www.teias.gov.tr/sites/default/files/2018-02/Taleprapor_2017.pdf) adresinden alındı
- EPDK. (2018). Ocak Ayı Sektör Raporu. Ankara, Çevrimiçi,  
[http://www.tuik.gov.tr/PreIstatistikTablo.do?istab\\_id=1579](http://www.tuik.gov.tr/PreIstatistikTablo.do?istab_id=1579): EPDK.
- ETBK. (2018). TÜİK. 2000-2016 arası:  
[http://www.tuik.gov.tr/PreIstatistikTablo.do?istab\\_id=1590](http://www.tuik.gov.tr/PreIstatistikTablo.do?istab_id=1590) adresinden alındı
- ETBK. (2018). TÜİK. 1975-2000 arası:  
[http://www.tuik.gov.tr/PreIstatistikTablo.do?istab\\_id=201](http://www.tuik.gov.tr/PreIstatistikTablo.do?istab_id=201); adresinden alındı
- ETKB. (2009). Elektrik Üretim Sektör Raporu. Ankara: Elektrik Üretim Anonim Şirketi.
- ETKB. (2010). Elektrik Üretim Sektör Raporu. Ankara: Elektrik Üretim Anonim Şirketi.
- Fan, J. (1996). Local Polynomial Modelling and Its Applications: From linear regression to nonlinear regression. Monographs on Statistics and Applied Probability. Londra: Chapman & Hall/CRC.
- Goldstein, L., & Schneider, A. (2006). Brief calculus and its applications (11th ed.). New Jersey: Prentice–Hall.
- Graupe, D. (2013). Principles of artificial neural networks (Vol. 7). Singapur: World Scientific.
- Hagan, M. T., Demuth, H. B., & Beale, M. H. (1996). Neural network design (Vol. 20). Boston: Boston: Pws Pub.
- Hamzacebi, C., & Es, H. A. (2014). Forecasting the annual electricity consumption of Turkey using an optimized grey model. Energy 70, 165–171.
- Hamzacebi, C., & Es, H. (2014). . Forecasting the annual electricity consumption of Turkey using an optimized grey model. Energy 70, 165–171.
- Hazine\_Bakanlığı. (2018). TÜİK: [http://www.tuik.gov.tr/PreIstatistikTablo.do?istab\\_id=621](http://www.tuik.gov.tr/PreIstatistikTablo.do?istab_id=621) adresinden alındı
- Hazine\_Bakanlığı. (2018). TÜİK\_1: 1975-2014 yılları arası:  
[http://www.tuik.gov.tr/PreIstatistikTablo.do?istab\\_id=2218](http://www.tuik.gov.tr/PreIstatistikTablo.do?istab_id=2218) adresinden alındı
- Hazine\_Bakanlığı. (2018). TÜİK\_2: 2015 ve 2016 yılları:  
<http://www.tuik.gov.tr/PreHaberBultenleri.do?id=24566> adresinden alındı
- Hazine\_Bakanlığı. (2018). TÜİK. [http://www.tuik.gov.tr/PreIstatistikTablo.do?istab\\_id=621](http://www.tuik.gov.tr/PreIstatistikTablo.do?istab_id=621) adresinden alındı

- Ho, K. L., Hsu, Y. Y., & Yang, C. C. (1992). Short term load forecasting using a multilayer neural network with an adaptive learning algorithm. *IEEE Transactions on Power Systems*, 7(1), 141-149.
- Hopfield, J. J. (1982). Neural networks and physical systems with emergent collective computational abilities. . *Proceedings of the national academy of sciences*, 79(8), 2554-2558.
- IEA. (2011). *World Energy Outlook*. Paris: IEA.
- Jain, A., Mao, J., & Mohiuddin, K. (1996). Artificial neural networks: A tutorial. . *Computer*, 31-44.
- Kaastra, I., & Boyd, M. (1996). Designing a neural network for forecasting financial and economic time series. . *Neurocomputing*, 10(3), 215-236.
- Kabalcı, E. (2013). Yapay Sinir Ağları. <https://ekblc.files.wordpress.com/2013/09/ysa.pdf> adresinden alındı
- Karacaören, M. (2017). *Stability Analysis Of Neural Networks With Piecewise Constant Argument*. Ankara: METU.
- Kargı, V. (2015). *Yapay Sinir Ağ Modelleri ve Bir Tekstil Firmasında Uygulama*, 1.Cilt. Bursa: Ekin Yayınevi.
- Karna, K. N. (1989). An artificial neural networks tutorial: part 1-Basics. *Neural Networks*, 1(1), 5-23.
- Kavaklıoğlu, K., Ceylan, H., Ozturk, H., & Canyurt, O. E. (2009). Modeling and prediction of Turkey's electricity consumption using artificial neural networks. *Energy Convers. Manage.* 50, 2719–2727.
- Kavaklıoğlu, K., Ceylan, H., Ozturk, H. K., & Canyurt, O. E. (2009). Modeling and prediction of Turkey's electricity consumption using artificial neural networks. *Energy Convers. Manage.* 50, 2719-2727.
- Kavaklıoğlu, K. (2011). Modeling and prediction of Turkey's electricity consumption using Support Vector Regression. *Appl. Energy* 88, 368-375.
- Kavaklıoğlu, K. (2011). Modeling and prediction of Turkey's electricity consumption using Support Vector Regression. *Appl. Energy* 88, 368-375.
- Kaytez, F., Taplamacıoğlu, M. C., Cam, E., & Hardalac, F. (2015). Forecasting electricity consumption: A comparison of regression analysis, neural networks and least squares support vector machines. *Electrical Power and Energy Systems* 67, 431–438.
- Kyriakides, E., & Polycarpou, M. (2007). Short term electric load forecasting: A tutorial. *Trends in Neural Computation*, 391-418.

- Lee, C. C., & Chien, M. S. (2010). Dynamic modelling of energy consumption, capital stock, and real income in G-7 countries. . *Energy Economics*, 564-581.
- Lek, S., & Guégan, J. F. (1999). Artificial neural networks as a tool in ecological modelling, an introduction. . *Ecological modelling*, 65-73.
- Lu, W. Z., Wang, W. J., Wang, X. K., Yan, S. H., & Lam, J. C. (2004). Potential assessment of a neural network model with PCA/RBF approach for forecasting pollutant trends in Mong Kok urban air, Hong Kong. *Environmental Research*, 79-87.
- Menyah, K., & Wolde-Rufael, Y. (2010). Energy consumption, pollutant emissions and economic growth in South Africa. *Energy Economics*, 1374-1382.
- Narayan, P. K., & Smyth, R. (2008). Energy consumption and real GDP in G7 countries: new evidence from panel cointegration with structural breaks. *Energy Economics*, 2331-2341.
- NEPUD. (2014). Nükleer Güç Santralleri ve Türkiye. Ankara, Çevrimiçi, [https://nepud.enerji.gov.tr/File/?path=ROOT%2f2%2fDocuments%2fYay%C4%B1n%2fNukleer\\_Enerji\\_ve\\_Turkiye.pdf](https://nepud.enerji.gov.tr/File/?path=ROOT%2f2%2fDocuments%2fYay%C4%B1n%2fNukleer_Enerji_ve_Turkiye.pdf) Erişim Tarihi: 27.03.2018: EPDK.
- Oztemel, E. (2006). Yapay Sinir Ağları. İstanbul: Papatya Yayıncılık.
- Palit, A. K., & Popovic, D. (2005). Traditional Problem Definition. *Computational Intelligence in Time Series Forecasting*, Springer, 17-75.
- Popescu, M. C., Balas, V. E., Perescu-Popescu, L., & Mastorakis, N. (2009). Multilayer perceptron and neural networks. *WSEAS Transactions on Circuits and Systems*, 8(7), 579-588.
- Sadorsky, P. (2012). Energy consumption, output and trade in South America. *Energy Economics*, 476-488.
- Samarasinghe, S. (2016). *Neural networks for applied sciences and engineering: from fundamentals to complex pattern recognition*. Florida: CRC Press.
- Sözen, A., Arcaklioğlu, E., & Özkaymak, M. (2005). Turkey's net energy consumption. *Appl. Energy* 81, 209–221.
- Stern, D. I. (1993). Energy and economic growth in the USA: a multivariate approach. *Energy economics*, 137-150.
- Sutton, R. S. (1996). Generalization in reinforcement learning: Successful examples using sparse coarse coding. *Advances in neural information processing systems*, 1038-1044.
- Tu, J. V. (1996). Advantages and disadvantages of using artificial neural networks versus logistic regression for predicting medical outcomes. . *Journal of clinical epidemiology*, 49(11), 1225-1231.

- Tugcu, C. T., Ozturk, I., & Aslan, A. (2012). Renewable and non-renewable energy consumption and economic growth relationship revisited: evidence from G7 countries. *Energy economics*, 1942-1950.
- TÜİK\_a. (2017). TÜİK. [http://www.tuik.gov.tr/PreIstatistikTablo.do?istab\\_id=129](http://www.tuik.gov.tr/PreIstatistikTablo.do?istab_id=129) adresinden alındı
- TÜİK\_b. (2017). TÜİK. Çevrimiçi, [http://www.tuik.gov.tr/PreIstatistikTablo.do?istab\\_id=1579](http://www.tuik.gov.tr/PreIstatistikTablo.do?istab_id=1579) adresinden alındı
- Widrow, B., & Lehr, M. A. (1990). 30 years of adaptive neural networks: perceptron, madaline, and backpropagation. *roceedings of the IEEE*, 78(9), 1415-1442.
- World Bank. (2018, April 24). DataBank: World Bank. World Bank Web Site: <http://databank.worldbank.org/data/reports.aspx?source=world-development-indicators#> adresinden alındı
- Yanar, R., & Kerimoğlu, G. (2011). Türkiye'de Enerji Tüketimi, Ekonomi ve Cari Açık İlişkisi. *Ekonomi Bilimleri Dergisi*, 191-201.
- Yao, X. (1999). Evolving artificial neural networks. . *Proceedings of the IEEE*, 87(9), 1423-1447.
- Yegnanarayana, B. (2009). *Artificial neural networks*. New Delhi: PHI Learning Pvt. Ltd.
- Yılmaz, M. (2012). Türkiye'nin Enerji Potansiyeli ve Yenilenebilir Enerji Kaynaklarının. *Ankara Üniversitesi Çevre Bilimleri Dergisi* , 33-54.
- Yurtoğlu, H. (2005). *Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği*. Ankara: Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü.
- Yücesoy, M. (2011). *Temizlik Sektöründe Yapay Sinir Ağları ile Talep Tahmini*. İstanbul: İTÜ.
- Zabel, A. (2009, April 20). *Stories: Resilience*. Resilience Web Site: <http://www.resilience.org/stories/2009-04-20/peak-people-interrelationship-between-population-growth-and-energy-resources> adresinden alındı
- Zachariadis, T. (2007). Exploring the relationship between energy use and economic growth with bivariate models: New evidence from G-7 countries. . *Energy economics*, 29(6), 1233-1253.
- Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. *International journal of forecasting*, 35-62.

## ÖZGEÇMİŞ

Adı Soyadı : Havva Hilal METİN  
Doğum Yeri ve Yılı : Osmaniye, 03/11/1980  
Yabancı Dil : İngilizce  
E-posta : hilallmetin@gmail.com

### Eğitim Durumu

Lise : Malatya Lisesi, 1998  
Lisans : Gazi Üniversitesi, Fen Fakültesi, İstatistik, 2005

### Mesleki Deneyim

Merkezi Kayıt Kuruluşu AŞ., Sistem Geliştirme Müdürlüğü, 2006 - 2015  
Imagine Codes Yazılım ve Animasyon Ltd. Şti., Kurucu Ortak, 2015 - ...(devam ediyor)

### Yayımları

Kaçtıoğlu, S., Metin, H.H., 2018. Power Consumption Estimation Using Artificial Neural Networks: The Case of Turkey, Journal of International Trade, Logistics and Law, Vol 4, No 1 (2018): June, 81-91