



**Sosyal Bilimler
Enstitüsü**

T.C.
MARMARA ÜNİVERSİTESİ

SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI
SAYISAL YÖNTEMLER BİLİM DALI

**GELECEK DÖNEMLERE AİT TÜRKİYE
ELEKTRİK TÜKETİMİ TAHMİNİNDE
YAPAY SİNİR AĞLARI MODELİNİN
KULLANILMASI**

Yüksek Lisans Tezi

YASİN ŞAHİN

İSTANBUL, 2020

T.C.
MARMARA ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI
SAYISAL YÖNTEMLER BİLİM DALI

**GELECEK DÖNEMLERE AİT TÜRKİYE
ELEKTRİK TÜKETİMİ TAHMİNİNDE
YAPAY SİNİR AĞLARI MODELİNİN
KULLANILMASI**

Yüksek Lisans Tezi

YASİN ŞAHİN

Danışman: Prof. Dr. Ömer ÖNALAN

İSTANBUL, 2020

ÖZET

GELECEK DÖNEMLERE AİT TÜRKİYE ELEKTRİK TÜKETİMİ TAHMINİNDE YAPAY SİNİR AĞLARI MODELİNİN KULLANILMASI

Dünya genelinde en çok ihtiyaç duyulan enerji türlerinden biri elektrik enerjisidir. Günlük yaşamımızın her noktasında elektrik enerjisine duyulan ihtiyacı görmekteyiz. Ulaşım, tıp, iletişim, sanayi, teknoloji gibi birçok alanda elektrik enerjisi insanlar için vazgeçilmez bir ihtiyaç olarak karşımıza çıkmaktadır. T.C. Enerji ve Tabii Kaynaklar Bakanlığı verilerine göre Türkiye elektrik tüketimi 2017 yılında 249 milyar kWh iken 2018 yılında 254 milyar kWh olarak büyük bir artış göstermiştir. Elektrik enerjisine duyulan ihtiyacın sürekli artması, elektriğin depolanamaması, elektriğin üretildiği an tüketilmesi gerekliliği gibi nedenlerden dolayı arz-talep dengesinin sağlanması gerekmektedir. Sürekli olarak artan bu talebin karşılanamaması ekonomik açıdan ülkelere problem yaratmaktadır. Bu talep etkin bir talep tahmin yöntemi ile desteklenmelidir. Elektrik piyasasında elektrik arzının talebi karşılaması için gerekli stratejik hedefler, planlama ve taktik kararların alınması önemli rol oynamaktadır. Ülkemizin ekonomi, refah seviyesi, üretim, teknoloji, sanayi gibi önemli unsurların artışı için elektrik tüketim tahminini yapmak oldukça önem arz etmektedir. Enerji arzının talepten çok düşük olması durumunda refah seviyesi düşecek, ekonomik krizlerin riski artacak, üretim ve diğer alanlarda problemler ortaya çıkacaktır. Çok düşük olmasının yanı sıra çok yüksek olması da elektrik enerjisinin israfına neden olacaktır. Bundan dolayı gerçek değere yakın talep tahmin değeri bulmak oldukça önemlidir. Son zamanlarda makine öğrenmesinin gelişimiyle birlikte geleneksel talep tahmini yöntemleri yerini yapay sinir ağlarına bırakmıştır. Yapılan çalışmada nicel tahmin metodlarından yapay sinir ağları yöntemi ile gelecek döneme ait elektrik tüketim miktarı tahmin edilmeye çalışılmıştır. Yapay sinir ağlarının özellikleri, yapısı, modelleri, avantaj ve dezavantajları detaylı olarak incelenmiştir. Daha önceden yapılan çalışmalara göre elektrik tüketimini etkileyen faktörler olarak nüfus, elektrik üretim miktarı, trafo sayısı, gayrisafi yurtiçi hasıla (GSYİH) ve elektrik enerjisine yapılan yatırım olarak belirlenmiştir. Bu

faktörler çalışmada yapay sinir ağının değişkenleri olarak kullanılmıştır. Öncelikle tahmin edilmek istenen senenin değişkenleri Holt metodu ile tahmin edilmeye çalışılmıştır. Holt metodu için Excel programı kullanılmıştır. Daha sonra verilerin büyüme oranları bulunarak ağın daha rahat öğrenmesine ortam hazırlanmıştır. Elde edilen veriler D_Min_Max normalizasyon yöntemiyle normalize edilerek 0,1-0,9 aralığından oluşan veri seti elde edilmiştir. Yapay sinir ağları yöntemi MATLAB R2018a programı kullanılarak uygulanmıştır. Uygulamada yapay sinir ağlarında en çok kullanılan model olan çok katmanlı algılayıcı modeli kullanılmıştır. Yapıda öğrenme kuralı olarak delta öğrenme kuralı, transfer fonksiyonu olarak sigmoid fonksiyonu, performans ölçümü olarak MSE yani hataların karelerinin toplamının ortalaması kullanılmıştır. Çalışma sonucunda yapay sinir ağları gerçek değere oldukça yakın tahmin değeri üretmiştir. Tahmin edilen değer 0,999308677 doğrulukta gerçek değere yakın olduğu görülmüştür. Gelecek dönemlere ait elektrik tüketimi tahmini ve benzer çalışmaların tahmini için uygun bir model olduğu gözlemlenmiştir.

Anahtar Kelimeler: (Yapay Sinir Ağları, Tahmin, Elektrik Tüketimi)

ABSTRACT

USING ARTIFICIAL NEURAL NETWORK MODELS IN TURKEY ELECTRICITY CONSUMPTION FORECAST FOR COMING PERIOD

One of the most needed types of energy worldwide is electric energy. We can see the need for electrical energy at every point of our daily lives. In many areas such as transportation, medicine, communication, industry and technology, electrical energy is an indispensable need for people. According to data from the Ministry of Energy and Natural Resources, electricity consumption in Turkey has increased to 254 billion kWh in 2018, while 249 billion kWh in 2017. The need for electrical energy needs to increase continuously, the electricity cannot be stored and the electricity needs to be consumed at the moment it is produced. Because of these reasons supply-demand balance needs to be maintained. Failure to supply with this continuously increasing demand creates problems for countries in economic terms. This demand should be supported by an effective demand forecasting method. Strategic goals, planning and tactical decisions required for electricity supply to meet demand play an important role in the electricity market. It is very important to estimate electricity consumption in order to increase important factors such as economy, welfare level, production, technology and industry of our country. If the energy supply is lower than the demand, the welfare level will decrease, the risk of economic crises will increase, problems in production and other areas will arise. In addition to being very low, too high will also cause waste of electrical energy. Therefore, it is important to find the demand forecast value close to the actual value. Recently, with the development of machine learning, traditional demand forecasting methods have been replaced by artificial neural networks. In the study, the amount of electricity consumption for the next period was tried to be estimated by artificial neural network method which is one of the quantitative estimation methods. Properties, structure, models, advantages and disadvantages of artificial neural networks have been examined in detail. According to previous studies, population, production, number of transformers, Gross Domestic Product (GDP) and investment in electricity were determined as factors affecting electricity consumption. These factors were used as variables of artificial neural network. Firstly, the variables of the year to be estimated were tried to be estimated by Holt method. Excel program was used for Holt

method. Then, the growth rate of the data was found and the environment was prepared for the network to learn more easily. The data obtained were normalized by D_Min_Max normalization method and a data set consisting of 0.1-0.9 range was obtained. Artificial neural network method was applied by using MATLAB R2018a program. In this study, multilayer perceptron (MLP) model, which is the most used model in artificial neural networks, is used. In this structure, delta learning rule was used as the learning rule, sigmoid function was used as the transfer function, MSE was the mean of mean squared error is used as the performance measurement. As a result of this study, artificial neural networks produced estimation value close to real value. It has been observed that the predicted value is so close to the real value with an accuracy of 0,999308677. It is observed that it is a suitable model for the estimation of electricity consumption for the future periods and for the estimation of similar studies.

Keywords: (Artificial Neural Network, Forecasting, Electricity Consumption)

İÇİNDEKİLER

1. GİRİŞ.....	1
2. ENERJİ	4
2.1 Elektrik Enerjisi.....	6
2.2 Türkiye’de elektrik enerjisi kullanımı	7
2.3 Elektrik Tüketimini Etkileyen Faktörler	9
2.3.1 Nüfus Miktarı.....	10
2.3.2 Elektrik Üretim Miktarı.....	12
2.3.3 Türkiye’de Bulunan Trafo Miktarı	15
2.3.4 Gayrisafi Yurtiçi Hasıla	16
2.3.5 Yatırım Miktarı.....	17
3. TAHMİN.....	19
3.1 Nitel Tahmin Yöntemleri.....	23
3.1.1 Deneyimsiz Tahmin Yöntemleri (Naive Forecasting).....	23
3.1.2 Delphi Tekniği.....	23
3.2 Nicel Tahmin Yöntemleri.....	24
3.2.1 Zaman Serisi Analizine Dayalı Metotlar.....	24
3.2.1.1 Hareketli Ortalamalar	25
3.2.1.2 Üstel Düzeltme	27
3.2.1.3 ARIMA.....	30
3.2.1.4 ARCH/GARCH.....	31
3.2.2 Sebep-Sonuç İlişkisine Dayanan Metotlar	32
3.2.2.1 Doğrusal Regresyon	32
3.2.2.2 Doğrusal Olmayan Regresyon.....	33
3.2.2.3 Çoklu Regresyon	33
3.2.2.4 Vektör Otoregresyon Yöntemi.....	35
4. YAPAY SİNİR AĞLARI	37
4.1 Yapay Sinir Ağlarına Giriş	37
4.1.1 Yapay Sinir Ağlarının Tanımı	37
4.1.2 Yapay Sinir Ağlarının Tarihçesi	37
4.1.3 Yapay Sinir Ağları Özellikleri	39

4.1.4	Yapay Sinir Ağlarının Dezavantajları	40
4.1.5	Yapay Sinir Ağlarının Kullanım Alanları	40
4.2	Yapay Sinir Ağlarının Yapısı ve Elemanları	41
4.2.1	Yapay Sinir Ağlarının Yapısı	41
4.2.2	Yapay Sinir Ağlarının Katmanları	44
4.3	Yapay Sinir Ağlarında Öğrenme	45
4.3.1	Danışmanlı (Supervised) Öğrenme	45
4.3.2	Danışmansız (Unsupervised) Öğrenme	46
4.3.3	Destekleyici (Reinforcement) Öğrenme	47
4.4	Yapay Sinir Ağları Modelleri	48
4.4.1	Çok Katmanlı Algılayıcı Modeli	48
4.4.1.1	Çok Katmanlı Algılayıcı Modelinde Öğrenme	49
4.4.1.1.1	İleriye Doğru Hesaplama	49
4.4.1.1.2	Geriye Doğru Hesaplama	50
4.4.1.2	ÇKA Ağlarının Çalışma Prensibi	51
5.	UYGULAMA	52
5.1	Veri setinin tanıtılması	52
5.2	Veri Setinin Hazırlanması	53
5.3	Yapay Sinir Ağı Mimarisi	64
5.4	Yapay Sinir Ağının Eğitilmesi ve Testi	67
5.5	Yapay Sinir Ağının Tahmini	72
6.	SONUÇ	74
7.	KAYNAKÇA	76
8.	EKLER	80

KISALTMALAR

ADALINE	: Adaptif Lineer Nöron
ANFIS	: Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi
AR	: Otoregresif
ARCH	: Otoregresif Koşullu Değişen Varyans
ARIMA	: Otoregresif Entegre Hareketli Ortalamalar
ARMA	: Otoregresif Hareketli Ortalamalar
ART	: Adaptif Resonans Teorisi
ÇKA	: Çok Katmanlı Algılayıcılar
EÜAŞ	: Elektrik Üretim A.Ş.
GARCH	: Genelleştirilmiş Otoregresif Koşullu Değişen Varyans
GSYİH	: Gayrisafi Yurtiçi Hasıla
IMF	: Uluslararası Para Fonu
KWH/MWH/GWH	: Kilowatt/Megawatt/Gigawatt
LVQ	: Learning Vector Quantization (Danışmanlı Bir Öğrenme Yöntemi)
MAD	: Ortalama Mutlak Sapma
MAPE	: Mutlak Sapma Oranlarının Ortalaması
MLP	: Çok Katmanlı Algılayıcı (Multilayer Perceptron)
MPE	: Hata Oranları Ortalaması
MSE	: Hata Kareleri Ortalamaları
TEAŞ	: Türkiye Elektrik Üretim-İletim A.Ş.
TEDAŞ	: Türkiye Elektrik Dağıtım A.Ş.
TEİAŞ	: Türkiye Elektrik İletim A.Ş.
TEK	: Türkiye Elektrik Kurumu
TETAŞ	: Türkiye Elektrik Ticaret Taahhüt A.Ş.
YSA	: Yapay Sinir Ağları

TABLÖLAR LİSTESİ

Tablo 2-1 2018 Yılı Aylık Enerji Tüketim Miktarları	5
Tablo 2-2 2017 Yılı Elektrik Enerjisi Üretiminin Kaynaklarına Göre Dağılımı.....	14
Tablo 5-1 Çalışmada Kullanılacak Değişkenlere Ait Veriler	55
Tablo 5-2 Holt Yöntemi ile 2018 Yılı Nüfus Değişkeninin Tahmini	58
Tablo 5-3 Holt Yöntemi ile 2018 Yılı Nüfus Değişkeninin Tahmininde Kullanılan Alfa ve Beta Değerleri	59
Tablo 5-4 Holt Yöntemi ile 2018 Yılı Değişkenlerin Tahmin Değerleri.....	59
Tablo 5-5 Büyüme Oranları	61
Tablo 5-6 Normalizasyon İşlemi Sonrası Veriler	64
Tablo 7-1 Holt Yöntemi ile 2018 Yılı Üretim Değişkeninin Tahmini	80
Tablo 7-2 Holt Yöntemi ile 2018 Yılı Üretim Değişkeninin Tahmininde Kullanılan Alfa ve Beta Değerleri	81
Tablo 7-3 Holt Yöntemi ile 2018 Yılı Trafo Miktarı Değişkeninin Tahmini.....	82
Tablo 7-4 Holt Yöntemi ile 2018 Yılı Trafo Miktarı Değişkeninin Tahmininde Kullanılan Alfa ve Beta Değerleri	83
Tablo 7-5 Holt Yöntemi ile 2018 Yılı GSYİH Değişkeninin Tahmini	84
Tablo 7-6 Holt Yöntemi ile 2018 Yılı GSYİH Değişkeninin Tahmininde Kullanılan Alfa ve Beta Değerleri	85
Tablo 7-7 Holt Yöntemi ile 2018 Yılı Yatırım Değişkeninin Tahmini	86
Tablo 7-8 Holt Yöntemi ile 2018 Yılı Yatırım Değişkeninin Tahmininde Kullanılan Alfa ve Beta Değerleri	87

ŞEKİLLER LİSTESİ

Şekil 2-1 Denizli’de bulunan RWE Turcas Güney Elektrik Üretim A.Ş.	6
Şekil 2-2 1914 yılında hizmete giren Silahtarağa Elektrik Üretim Tesisi.....	8
Şekil 2-3 2017 Yılı Elektrik Enerjisi Üretiminin Kaynaklarına Göre Dağılımı	14
Şekil 3-1 Tahmin Yöntemleri	22
Şekil 4-1 Yapay Sinir Ağlarının Yapısı	42
Şekil 4-2 Sigmoid Fonksiyonu	43
Şekil 4-3 Yapay Sinir Ağında Katmanlar	44
Şekil 4-4 Danışmanlı (Supervised) Öğrenme	46
Şekil 4-5 Danışmansız (Unsupervised) Öğrenme.....	47
Şekil 4-6 Destekleyici (Reinforced) Öğrenme	47
Şekil 4-7 ÇKA Ağlarının Çalışma Aşamaları	51
Şekil 5-1 α ve β değerleri EXCEL programı Çözücü Eklentisiyle Bulunması	56
Şekil 5-2 "nntool" komut penceresi	65
Şekil 5-3 Yeni Ağ Oluşturma Penceresi (MATLAB).....	66
Şekil 5-4 Oluşturulan YSA Mimarisi	67
Şekil 5-5 Hata-Ağırlık İlişkisi.....	68
Şekil 5-6 Oluşturulan Ağın Eğitim Parametreleri (MATLAB).....	69
Şekil 5-7 Oluşturulan Ağın Mimarisi, Algoritması ve Öğrenme Aşaması (MATLAB).....	70
Şekil 5-8 Uygulanan Eğitime Ait Performans.....	71
Şekil 5-9 Ağın Eğitimi Sonucu Oluşan Regresyon Grafiği.....	72
Şekil 5-10 2018 Yılına ait Tahminin Simülasyon Aşaması (MATLAB)	73

GRAFİK TABLOSU

Grafik 2-1 2018 Yılına Ait Aylık Enerji Tüketim Miktarları Grafiği	5
Grafik 2-2 Türkiye'de Yıllara göre Elektrik Tüketim Miktarları (mWh)	9
Grafik 2-3 Türkiye'de Yıllara Göre Nüfus Miktarları	11
Grafik 2-4 Türkiye'de Yıllara Göre Elektrik Üretim Miktarları	13
Grafik 2-5 Türkiye'deki Trafo Sayısının Yıllara Göre Dağılımı	15
Grafik 2-6 Türkiye'nin Yıllara Göre GSYİH Değerleri	17
Grafik 2-7 Elektrik Enerjisi Yatırım Miktarları	18



1. GİRİŞ

Tarih boyunca insanlar enerjinin çeşitli formlarına ihtiyaç duymuş ve kullanmışlardır. İlk zamanlarda insanlar kendi kas gücünü kullanarak üretim yaparken zamanla hayvanların enerjilerinden yararlanmaya başlamıştır. Daha sonra ateşi bularak enerjiyi ısıtmak amacıyla kullanmışlardır. Zamanla su değirmeni, rüzgar türbini gibi çeşitli enerji kaynaklarından yararlanarak daha fazla enerji elde edilmiş ve çeşitli kullanım alanlarına kavuşmuşlardır.

Günümüzde teknolojinin ilerlemesiyle ve elektrik ihtiyacının zamanla günlük yaşamımızda olmazsa olmaz bir enerji türü olmasıyla birlikte en çok ihtiyaç duyulan enerji türü elektrik enerjisi olmuştur. Ulaşım, tıp, haberleşme, üretim, sanayi, teknoloji gibi birçok alanda elektrik enerjisinden yararlanılmaktadır. T.C. Enerji ve Tabii Kaynaklar Bakanlığı verilerine göre Türkiye elektrik tüketimi 2017 yılında 249 milyar kWh iken 2018 yılında 254 milyar kWh olarak büyük bir artış göstermiştir. Elektriğin birçok enerji kaynağından üretilabiliyor olması, çevreye herhangi bir zarar vermemesi, kullanım alanının fazla olması, nüfusun artması ve teknolojinin gelişmesiyle birlikte bu enerji türünün tüketim miktarı da günden güne artmaktadır. Bunun yanı sıra üretilen enerjinin depolanamaması, üretildiği an tüketilmesi gerektiği gibi sebeplerden dolayı ülkelerin arz-talep dengesini sağlaması gerekmektedir. Sürekli olarak artan bu talebin karşılanamaması ekonomik açıdan ülkelere problem yaratmaktadır. Bu talep etkin bir talep tahmin yöntemi ile desteklenmelidir. Elektrik piyasasında elektrik arzının talebi karşılaması için gerekli stratejik hedefler, planlama ve taktik kararların alınması önemli rol oynamaktadır.

Ülkemizin ekonomi, refah seviyesi, üretim, teknoloji, sanayi gibi önemli unsurların artışı için elektrik tahminini yapmak oldukça önem arz etmektedir. Enerji arzının talepten çok düşük olması durumunda refah seviyesi düşecek, ekonomik krizlerin riski artacak, üretim ve diğer alanlarda problemler ortaya çıkacaktır. Çok düşük olmasının yanı sıra çok yüksek olması da elektrik enerjisinin israfına neden olacaktır. Bundan dolayı gerçek değere yakın talep tahmin değeri bulmak önemlidir.

Son zamanlarda makine öğrenmesinin gelişimiyle birlikte geleneksel talep tahmini yöntemleri yerini yapay sinir ağlarına bırakmıştır. Bu alanda çeşitli çalışmalar bulunmaktadır. Çalışmalar yapay sinir ağlarının tahmin konusunda gerçek değere yakın çıktılar ürettiği belirtilmiştir.

Benan Başıoğlu ve Mehmet Bulut çalışmalarında, Türkiye'nin kısa vadeli elektrik talep tahminini oluşturan bir hibrit sistem geliştirilmiştir. EPSİM-NN isimli sistemde, günlük ortalama saatlik talep miktarı ve 24 saatlik talep şekli iki farklı yapay sinir ağı kullanılarak belirlenmiştir. Buradaki çıktılar ile günlük talep tahmini elde edilmiştir. Bu sistem kullanılarak oluşturulan tahmin değerlerinin oldukça yüksek doğruluk derecesinde olduğu gözlenmiştir (Başıoğlu & Bulut, 2016).

Ümit Şenol ve Zabit Musayev yaptıkları çalışmada, çeşitli rüzgar türbinlerinin verileriyle yapay sinir ağları yöntemi kullanılarak rüzgar enerjisinden elektrik üretim tahminini yapmışlardır. Yapılan tahminlerin güvenilir ve tutarlı olduğu yapılan testler ile anlaşılmıştır. Bu alanda yapılan planlama çalışmalarında geleneksel tahmin yöntemlerine alternatif olarak yapay sinir ağlarının kullanılabileceği görülmüştür (Şenol & Musayev, 2017).

Burak Taşkınler tez çalışmasında, Ankara ilinin büyük çoğunluğu yurt dışından tedarik edilen doğalgaz tüketiminin yapay sinir ağları ile öngörüsü yapılmıştır. Doğalgaz tüketim talebinin öngörüsü planlama bakımından oldukça önemlidir. Yapılan çalışmada tahmin amacıyla kullanılan yapay sinir ağları gerçek çıktı ile yakın değerler üretmiştir (Taşkınler, 2018).

Fatih Adıyaman tez çalışmasında, şirketlerin gelecekte planlı bir şekilde ilerleyebilmelerinde önemli bir role sahip olan talep tahmini çeşitli tahmin yöntemleri ile tespit edilmeye çalışılmıştır. Çalışmada tahmin yöntemi olarak yapay sinir ağları, regresyon analizi ve eğri uydurma yöntemleri kullanılarak sonuçlar kıyaslanmıştır. Uygulama sonucunda oluşturulan yapay sinir ağı modelinin etkin bir talep tahmin yöntemi olduğu görülmüştür (Adıyaman, 2007).

Lambros Ekonomou ise çalışmasında, Yunanistan'ın uzun dönem enerji tahmini yapay sinir ağları yöntemiyle tahmin etmeye çalışmıştır. Model olarak çok katmanlı algılayıcı (MLP) kullanılmış ve birçok deneme yapılarak en uygun olan mimari seçilmiştir. Çıktı değerleri gerçek değerlerle karşılaştırılarak büyük bir doğruluk ile tahmin edildiği görülmüştür. Bu yöntemin enerji politikalarında uygulanması yararlı olacağı gösterilmiştir. Çalışmaya göre Yunanistan'ın uzun dönem enerji talep tahmin problemi için yapay sinir ağları uygun bir araçtır (Ekonomou, 2010).

Hsiaotien Pao yaptığı yapay sinir ağı çalışmasında elektrik fiyat tahminini ele almıştır. Elektrik fiyat tahmini üreticiler ve bütün piyasadaki kişiler için kısa, orta ve uzun vadede planlarını belirlemede önemli bir unsurdur. Tahmin hatalarını önlemek amacıyla yapay sinir ağı yönteminin en uygun yöntem olduğu belirtilmektedir. Çalışmada yapay sinir ağlarının tahmin için potansiyeli incelenmiştir. Yapay sinir ağlarının tahminlerinde tahmin ufkunun uzunluğu kısa veya uzun olsa bile doğru çıktılar verdiği görülmüştür (Hsiaotien , 2007).

Yapay sinir ağıları, insanlar tarafından daha önce gerçekleştirilen örnekler yardımıyla kendini eğiterek daha sonra karşılaştığı problemlere öğrendikleriyle karşılık üretebilen bilgisayar sistemleridir (Öztemel, Yapay Sinir Ağları, 2016) . Bu çalışmada 1980-2017 yılları arasındaki nüfus, elektrik üretimi, trafo sayısı, gayrisafi yurtiçi hasıla, elektrik enerjisine olan yatırım miktarları ve elektrik tüketimi verileri kullanılarak yapay sinir ağıları tahmin metodu ile 2018 yılı elektrik tüketimi tahmin değeri bulunması hedeflenmiştir.

İkinci bölümde elektrik enerjisi üzerine durulmuş ve Türkiye'nin elektrik tüketimi verileri ele alınmıştır. Enerji çeşitlerinden biri olan elektriğin Türkiye'deki gelişim süreci gösterilmiştir. Ayrıca elektrik tüketimini etkileyen ve çalışmamızda kullanacağımız nüfus, elektrik üretimi, trafo sayısı, GSYİH ve yatırım değişkenleri detaylı olarak incelenmiştir.

Üçüncü bölümde tahminin öneminden ve tahmin metotlarından bahsedilmiştir. Tahmin yönteminin faydaları, eksik noktaları, matematiksel işlemleri çok detaylı olmayacak şekilde incelenmiştir. Zaman serisi analizine dayalı metotlardan Üstel düzeltme ve Holt metodu çalışmada kullanıldığı için ayrıca incelenmiştir.

Dördüncü bölümde uygulamada kullanılacak olan yapay sinir ağıları metodu ele alınmıştır. Yapay sinir ağlarının çalışma prensibi, öğrenmesi, modelleri, kullanım alanları gibi başlıklara yer verilmiştir.

Beşinci bölümde uygulama kısmı detaylı bir şekilde anlatılmıştır. Kullanılan EXCEL ve MATLAB programındaki çıktılar yorumlanmıştır. Oluşturulan ağ sonucu elde edilen tahmin değerleri gerçek değerler ile karşılaştırılmıştır.

Çalışmamızın son bölümde ise uygulama kısmında elde ettiğimiz değerler ve karşılaştırmalar değerlendirilmiştir. Bu değerlendirme sonucunda daha sonraki tahmin çalışmalarında önerilerde bulunulmuştur.

2. ENERJİ

Enerjinin Türk Dil Kurumunca tanımı, maddede var olan ve ısı, ışık biçiminde ortaya çıkan güç anlamına gelmektedir. (Türk Dil Kurumu, 2019) Enerji birincil ve ikincil enerji kaynakları olmak üzere ikiye ayrılmaktadır. Birincil enerji kaynakları: kömür, ham petrol, doğalgaz, rüzgar gibi doğada bulunan enerji kaynaklarıdır. İkincil enerji kaynakları ise birincil enerji kaynaklarını kullanarak bazı işlemler sonucu elde edilen enerji türüdür (Spurgeon & Flood, 2014). Enerji yaratılamaz ve yok edilemez bir özelliğe sahiptir. Aynı zamanda enerji üretilemez ama biçim değiştirilebilir, bir biçimden başka bir biçime dönüştürülebilir. Örnekle açıklamak gerekirse elektrik enerjisi üretiminde kullanılan rüzgar türbinleri, rüzgardaki kinetik enerjiyi önce mekanik enerjiye daha sonra elektrik enerjisine dönüştürür. Birçok enerji çeşidi vardır. Bunlardan bazıları nükleer enerji, elektrik enerjisi, kimyasal enerji, elektromanyetik ışıyım enerjisidir.

Enerji ülkelerin gelişmesi ve kalkınması için büyük bir öneme sahiptir. Enerji insan hayatının her alanında bulunmakta ve tüketilmektedir. Dolayısıyla yaşanan kısa süreli bir enerji kesintisi bile büyük maddi kayıplara yol açmaktadır (Karagöl & Tür, Türkiye'de Elektrik Enerjisi, 2017). Bunun için kamu hizmetleri şirketleri enerji talebini sağlamak ve geliştirmekten sorumludur. Bu şirketler gelecek enerji taleplerini tahmin etmek için çeşitli tahmin metotlar kullanmaktadır (Tso & Yau, 2007). Böylelikle iyi bir tahmin metodu sonucu oluşan çıktı değerine göre geleceğe dair planlar, stratejik hamleler ve uygulanması gereken politikalar belirlenmektedir.


Türkiye Enerji ve Tabii Kaynaklar Bakanlığı'nın 2015-2019 stratejik planı, enerji alanında güncel ihtiyaçları ve geleceğe yönelik beklentileri karşılayan bir tema üzerine yapılandırılmıştır (Enerji ve Tabii Kaynaklar Bakanlığı, 2019).

Türkiye Enerji ve Tabii Kaynaklar Bakanlığı verilerine göre enerji tüketiminde en fazla doğalgaz, elektrik ve motorin tüketimi yer almıştır. 2018 yılı enerji tüketim miktarı 93875 ktoe'dir. Tablo 2-1'de 2018 yılı aylık enerji tüketim miktarları verilmiştir.

	Doğalgaz	Elektrik	Motorin	Diğer	TOPLAM
Ocak	5808,4	2253	1149	496,4	9706,8
Şubat	4830,2	2015,1	1156,8	420,2	8422,3
Mart	3993,9	2127,1	1278,6	421,2	7820,8
Nisan	3214,7	2050,2	1516,4	506,4	7287,7
Mayıs	2584,6	1994,4	1496,7	479,4	6555,1
Haziran	2505,1	1978,1	1388,5	1070,9	6942,6
Temmuz	3262,6	2430,4	1741,5	561,8	7996,3
Ağustos	2606,8	2290,4	1646,4	545	7088,6
Eylül	3033,5	2081,9	1547,1	553,6	7216,1
Ekim	3315,1	1949	1533,9	540,5	7338,5
Kasım	4273,3	2006,5	1391,6	514,6	8186
Aralık	5472,7	2162,7	1181,7	497,1	9314,2

Tablo 2-1 2018 Yılı Aylık Enerji Tüketim Miktarları

2018 yılına ait aylık enerji tüketim miktarları grafiği aşağıdaki Grafik 2-1’de bulunmaktadır.



Verilerden anlaşılacağı üzere Türkiye’de en fazla tüketilen enerji kaynağı doğal gazdır. Çünkü doğal gaz elektrik üretiminde de kullanılmaktadır. Sürekli artan elektrik ihtiyacımızın büyük bir bölümü doğalgaz dönüşüm santrallerinde gerçekleşmektedir.

Doğalgaz, renksiz, kokusuz ve havadan hafif bir gazdır. Petrole benzer şekilde yeryüzüne çıkartılır. 1980’lerde elektrik enerjisi elde etmek için oluşturulan santraller nükleer güç santralleri veya kömürün yardımıyla oluşturulan termik güç santralleriydi. Kömür elektrik üretimi için kullanılan oldukça ucuz bir yakıt olmasına karşın gerekli önlemler alınmadığı takdirde havaya yüksek düzeyde kirli maddeler salıyordu. Günümüzde elektrik üretimi için kullanılan doğalgaz santralleri havayı kömür kadar olumsuz yöne etkilememektedir. Doğalgazın yanması ile birlikte havaya su buharı ve CO₂ (karbondioksit) gazı yayılır (Ceylan , 2016).

Örneğin Denizli’de bulunan RWE Turcas Güney Elektrik Üretim A.Ş.’ ye ait doğalgaz çevrim santrali tek başına Türkiye’nin toplam elektrik talebinin %2’sini karşılayabilme gücüne sahiptir (RWE&Turcas Güney Elektrik Üretim A.Ş., 2019).



Şekil 2-1 Denizli’de bulunan RWE Turcas Güney Elektrik Üretim A.Ş.

2.1 Elektrik Enerjisi

Enerji türlerinden biri olan elektrik enerjisi modern dünyanın vazgeçilmez bir unsurudur. Birçok alanda kolaylıkla kullanılması, artık ve koku bırakmaması, teknolojik gelişmelerin vazgeçilmez bir unsuru olması ve diğer avantajları sebebiyle ülkelerin elektrik enerjisine olan talebini daima canlı tutmuştur. Gelişen teknoloji ile birlikte ihtiyaç duyulan bu enerji türünün ekonomiye olan katkıları büyük öneme sahiptir. Elektrik tüketimi bir ekonomide kalkınmanın bir yansımasıdır. Üretim sürecinde oldukça büyük öneme sahip olan elektrik enerjisi bu yönüyle istihdam yaratma etkisine de dolaylı olarak sahiptir. Bu durum ülkenin ekonomik anlamda büyümesine neden olacaktır. Aynı zamanda insanların

ısı, ışık ve elektrik aletlerinin kullanımıyla yaşam kalitesinin yükselmesinde etkisi vardır (Şengönül & Koşaroğlu, 2018).

Elektrik enerjisi petrol, kömür, doğal gaz, nükleer ve yenilenebilir enerji kaynakları (güneş, rüzgar, biyokütle vb.) ile elde edilebilmektedir. Ancak elektrik enerjisi depolanamayan bir enerji türü olduğundan dolayı üretildiği anda tüketilmesi gerekmektedir. Bu durum ülkelerin bir sonraki dönemde üretilmesi gereken elektrik enerji miktarının iyi bir şekilde planlanmasını ve gerekli stratejilerin oluşturulmasını şart koşmaktadır (Haliloğlu & Tutu, 2018).

Elektrik üretimi oldukça yüksek maliyetler gerektirmektedir. Elektriğin depolanamamasından dolayı elektrik üretimine yapılan fazla ve yanlış yatırımlar sonucu talep edilenden çok daha fazla elektrik üretimi yapılması israfa neden olacaktır. Elektrik talebi oldukça değişkendir. Bu değişkenliğin üretilen enerji ile kesintisiz olarak karşılanması gerekmektedir. Bunun için kurulu olan elektrik santrallerinin gücü bu talebi her zaman karşılayabilecek seviyede olmalıdır. Elektrik üretimi planlaması yapılırken talebin en düşük kayıp ve maliyetle karşılayabilecek en optimal çözüm hedeflenmelidir (Akan & Tak, 2003).


2.2 Türkiye’de elektrik enerjisi kullanımı

Dünya üzerinde birçok alanda kullanılan enerji türlerinden biri olan elektrik enerjisi ülkelerin büyüme ve gelişmesinde büyük öneme sahiptir. Çünkü elektrik enerjisi bir ülkenin ekonomik büyümesine, istihdam oranının artmasına, toplumun refah seviyesinin yükselmesine, teknoloji alanındaki gelişmelere vb. gibi dolaylı veya direkt olarak birçok yararı bulunmaktadır. Bu faydanın ölçümü bazı çalışmalarla desteklenmiştir.

Yapraklı ve Yurttaçıkılmaz’ın ele aldıkları çalışmada Türkiye’de elektrik tüketimi ile ekonomik büyüme arasındaki nedenselliği incelemiştir. Buna benzer birçok çalışmada çeşitli yöntemler kullanılmış ve Türkiye’de elektrik tüketimi ve ekonomik büyüme arasında kuvvetli bir ilişki olduğu tespit edilmiştir. Yapraklı ve Yurttaçıkılmaz çalışmalarında Granger nedensellik testi kullanmış ve birçok çalışmada olduğu gibi aralarında kuvvetli bir ilişki olduğu tespit edilmiştir. Ayrıca analiz sonuçlarında ekonomik büyüme sonucu artan gelirin büyük bölümünün elektrik tüketen mal ve hizmetlere harcandığı tespit edilmiştir. Dolayısıyla Türkiye’de elektrik enerjisinin ekonomik büyüme için önemli bir faktör olduğu ve herhangi bir kısılma politikası izlendiğinde ekonomik büyümeyi olumsuz etkileyeceği tespit edilmiştir (Yapraklı & Yurttaçıkılmaz, 2012) .

Türkiye diğerk birçok ÷lke gibi elektrik enerjisinden bu anlamda faydalanmak istemiřtir. Türkiye’de ilk elektrik üretimi 1902 yılında su değirmenine bağlanan 2 kW gücünde bir dinamoyla Tarsus’ta başlamıřtır.

1914 yılında ilk kayda değerk elektrik üretim tesisi olan Silahtarağık Elektrik Santrali İstanbul’un Eyüp ilçesinde kurulmuřtur.




řekil 2-2 1914 yılında hizmete giren Silahtarağık Elektrik Üretim Tesis

Türkiye’de imtiyazlı řirketlerin görev bölgeleri ve belediye sınırları dışında tüm ÷lkedeki elektriğink üretimi, iletimi, dağıtımını ve satıř hizmetleri tek bir noktada toplanmasına karar verilmiř ve 1970 yılında Türkiye Elektrik Kurumu (TEK) kurulmuřtur.

Topluma sunulan elektrik hizmetinin daha etkin ve verimli çalıřması adına 1993 yılında Türkiye Elektrik Kurumu iki ayrı İktisadi Devlet Teřekk÷l÷ olarak yeniden yapılandırılmıřtır. Bunlar Türkiye Elektrik Üretim-İletim A.ř. (TEAř) ve Türkiye Elektrik Dağıtım A.ř. (TEDAř) ‘dir.

2001 yılında TEAř iletim, üretim ve ticaret faaliyetlerini birbirinden ayırarak iletim için Türkiye Elektrik İletim A.ř. (TEİAř), üretim için Elektrik Üretim A.ř. (EÜAř) ve ticaret faaliyetleri için Türkiye Elektrik Ticaret Taahh÷t A.ř. (TETAř) olarak üç farklı İktisadi Devlet Teřekk÷l÷ kurulmuřtur (Türkiye Elektrik İletim A.ř. , 2020).

Türkiye’de elektrik enerjisi talebi yıllar geçtikçe nüfusun artması, teknolojinin ilerlemesi, şehirleşme, sanayileşme ve refah seviyesinin artışına paralel olarak artmaktadır. Aşağıdaki grafikte Türkiye elektrik tüketim miktarlarının yıllar itibariyle artışı gösterilmiştir. 1980-2017 yılları arasında sadece 2001 ve 2009 yıllarında düşüş yaşamış olsa da genel olarak sürekli bir artış olduğu gözlemlenmektedir. Bu yıllar arasında en fazla büyüme 1987 yılında %13,93 ile, en fazla azalma ise 2009 yılında % -3,12 ile gerçekleşmiştir. Bu yıllar arasında gerçekleşen ortalama büyüme oranı ise %6,92 ile artmaktadır.



Grafik 2-2 Türkiye’de Yıllara göre Elektrik Tüketim Miktarları (mWh)

2.3 Elektrik Tüketimini Etkileyen Faktörler

Geleceğe yönelik tahmin çalışmalarında yapay sinir ağı yöntemi kullanılacak ise çalışmanın önemli noktalarından birisi değişkenlerin yani örneklerin belirlenmesidir. Çünkü belirlenen örnekler dikkate alınarak yapay sinir ağı ağırlıklarını değiştirmektedir. Dolayısıyla bu örneklerin problem uzayını temsil edecek nitelikte olması gerekmektedir. Örnek olarak belirtmek gerekirse bir öğrenciye toplama

işlemini öğrettikten sonra o öğrenciye bölme işlemi ile ilgili soru sorarsanız, öğrenci daha önce böyle bir örnek görmediği ve genelleme yapacak durumda olmadığı için doğru yorumlar yapması beklenemez. Özetle ağı ne gösterilirse ağı ancak o konuda yorum yapılabilir ve görmediği örneklere çözümler üretebilir (Öztemel, Yapay Sinir Ağları, 2016).

Bu çalışmada ele alınan problem Türkiye'nin 2018 yılı elektrik tüketim miktarını tahmin etmektir ve böylece 2018 yılı için ilgili kişilerce daha iyi bir planlama yapılmasına yardımcı olmaktır. Dolayısıyla bu aşamada Türkiye'de elektrik tüketimini etkileyen faktörler incelenecektir. Bu konuda yapılmış bazı çalışmalar bulunmaktadır. Daha önceden yapılmış çalışmalar ve çeşitli analizler sonucu bu çalışmada elektrik tüketimini etkileyen faktörler şu şekilde belirlenmiştir;

- Nüfus miktarı
- Elektrik üretim miktarı
- Kurulu trafo sayısı
- Gayrisafi yurtiçi hasıla
- Elektrik enerjisine olan yatırım miktarı

Belirtilen değişkenler detaylı olarak incelenmiş ve konu ile yapılan çalışmalar ilgili başlık altında gösterilmiştir. Uygulamada elektrik tüketimini etkileyen faktörler yapay sinir ağıımızın değişkenlerini oluşturmaktadır. Değişkenler belirlenirken bu alanda yapılan çalışmalar ve uzman görüşlerinden yararlanılmıştır.


Veriler, data.worldbank.org, Türkiye Cumhuriyeti Cumhurbaşkanlığı strateji ve bütçe başkanlığı resmi sitesinden ve TEDAŞ resmi sitesinden alınan veriler ile oluşturulmuştur. Çalışmada Türkiye 1980-2018 yılları arasındaki döneme ait verilerinin analizi yapılmıştır. Değişkenlere ait grafikler incelenmiş ve yorumları yapılmıştır.

2.3.1 Nüfus Miktarı

Refah seviyesinin artması ülkelerin olmazsa olmaz kriterlerinden ve amaçlarından biridir. Ülkelerin bu refah seviyesini arttırabilmesi veya istenilen noktaya getirebilmeleri toplumdaki bireylerin gerekli ve önemli ihtiyaçlarının karşılanması ile sağlanabilir. Elektrik enerjisine ihtiyaç duyan teknolojik

aletlerin insan hayatında önemli bir yer alması ve elektrik enerjisinin ısıtma, aydınlatma gibi kullanım alanlarının fazlalığı elektriğe olan bağımlılığı günden güne artırmaktadır. Günümüzde toplumlar için en önemli ihtiyaçlardan biri elektrik enerjisi olmaktadır. Ülkelerin elektrik tüketim planlaması yaparken göz önünde bulundurulması gereken kriterlerden birisi elektriği kullanan kişinin yani o ülkedeki nüfusun miktarıdır.

Aşağıdaki grafikte Türkiye'nin 1980-2018 yılları arasındaki nüfus miktarları görülmektedir. Nüfus artış hızı zaman zaman düşmesine rağmen Türkiye'de nüfus sürekli olarak artış trendi göstermiştir.



Grafik 2-3 Türkiye'de Yıllara Göre Nüfus Miktarları

Betül İsmiç 2015 yılında yaptığı çalışmada elektrik tüketimi, ekonomik büyüme ve nüfus miktarı arasındaki ilişkiyi ortaya koymaya çalışmışlardır. Yapılan çalışmada 1990-2012 yılları arasındaki veriler kullanılarak IMF listesine göre Türkiye'nin de içinde bulunduğu sekiz ülke için panel veri analizi yapılmıştır. Yapılan çalışmaya göre Türkiye için; nüfusta meydana gelebilecek %1'lik artış, elektrik tüketimini ortalama %5,24 artırdığı görülmüştür. Sonuç olarak nüfus miktarının elektrik tüketiminde oldukça önemli bir faktör olduğu tespit edilmiştir (İsmiç, 2015).

Yapılan başka bir çalışmada 2030 yılına gelindiğinde enerji tüketiminin dünyada %60 ve Türkiye'de %100'den daha fazla oranda artması öngörülmektedir. Bu artışın arkasındaki ana sebep ülkelerde elektrik tüketimindeki artıştır. Elektrik tüketimindeki bu artış yıllar geçtikçe artan nüfusun, gelişen teknolojinin ve sanayileşmenin etkisine bağlı olduğu belirtilmiştir (Satman, 2017).

Bu çalışmada elektrik tüketimini etkileyen değişkenlerden birisi olarak Türkiye'nin yıllara göre nüfusu ele alınmıştır. Türkiye'de elektrik tüketimi ile nüfus arasındaki ilişkiyi incelemek için korelasyon katsayısına bakılmıştır.

X ve Y değişkenleri arasında ilişkinin var olup olmadığına ve bu ilişkinin gücüne kovaryans ve korelasyon ile bakılır (Wasserman, 2003). Aşağıda kovaryans ve korelasyon formülleri gösterilmektedir. Çalışmada belirlenen diğer değişkenlerin de korelasyon katsayısına bu formüller yardımıyla bakılmıştır.

$$Cov(X, Y) = \mathbb{E}((X - \mu_X)(Y - \mu_Y))$$

$$p_{X,Y} = p(X, Y) = \frac{Cov(X, Y)}{\sigma_X \sigma_Y}$$

Nüfus değişkeni için hesaplanan korelasyon katsayısı 0,98106 çıkmıştır. Çıkan bu sonuçtan Türkiye'de elektrik tüketimi ile nüfus arasında oldukça güçlü ve pozitif yönde ilişki olduğu bulunmuştur.

2.3.2 Elektrik Üretim Miktarı


Elektrik tüketiminin incelendiği bir çalışmada oluşan tüketimi karşılayacak üretim miktarının da el e alınması ve değerlendirilmesi gerekmektedir. Sosyo-ekonomik kalkınmanın en önemli girdilerinden biri olan elektrik enerjisinin zamanında, kaliteli ve yeterli miktarda, ekonomik şartlar ve çevre etkileri de dikkate alınarak temini büyük önem taşımaktadır. Dolayısıyla üretim/tüketim dengesinin sağlanması için üretim tarafında sürekli ve belli miktarın üzerinde rezerv olmalıdır. Bu sonuçla üretimden elde edilecek veriler o bölgenin tüketimi hakkında bizlere bilgi vermektedir.

Elektrik üretim ile tüketimi arasında anlamlı ve güçlü bir ilişki olduğu bazı çalışmalarla desteklenmektedir.

Özkan Demirel ve arkadaşları yaptıkları çalışmada elektrik tüketim miktarını ANFIS ve ARMA modellerini kullanarak tahmin etmeye çalışmış ve hangi modelin talep tahmininde başarılı olduğu tespit edilmeye çalışılmıştır. Çalışmada üretilen enerji değişkenler arasında yer almaktadır. Çalışma

sonucunda ANFIS modelinin en ekonomik ve en doğru tercih olduğu tespit edilmiştir (Demirel, Kakilli, & Tektaş, ANFIS ve ARMA Modelleri ile Elektrik Enerjisi Yük Tahmini, 2010).

Üretim ile tüketim arasında ilişkiyi ölçmek için 1980-2017 yılları arasındaki veriler yardımıyla korelasyon katsayısına bakılmıştır. Şekil 5.2’de ki grafikte Türkiye’nin 1980-2018 yılları arasındaki elektrik üretim miktarları görülmektedir. 2001 ve 2009 seneleri haricinde Türkiye’de elektrik üretimi sürekli olarak artmıştır. Elektrik üretimi ile tüketimi arasındaki korelasyon katsayısı 0,999337 çıkmıştır. Bu değer bize elektrik tüketimi ile üretimi arasında pozitif yönde çok güçlü bir ilişki olduğunu göstermektedir.




Grafik 2-4 Türkiye’de Yıllara Göre Elektrik Üretim Miktarları

Elektrik Üretim A.Ş.(EÜAŞ)’ın amaçlarından birisi ülkemizdeki elektrik enerjisi ihtiyacını yerli kaynaklara dayalı bir enerji politikası oluşturmaktır. Türkiye Elektrik İletim A.Ş. (TEİAŞ) verilerine göre 2017 yılı elektrik enerjisi üretiminin kaynaklarına göre dağılımı aşağıdaki grafik ve tabloda görülmektedir.

KAYNAK	ÜRETİM (GWh)	KATKISI (%)
İthal Kömür	51.118,1	17,20
Taşkömürü + Asfaltit	5.663,8	1,91
Linyit	40.694,4	13,69
Doğal Gaz	110.490,0	37,17
Sıvı Yakıtlar	1.199,9	0,40
Barajlı	41.312,6	13,90
D.Göl ve Akarsu	16.905,9	5,69
Rüzgar	17.903,8	6,02
Yenilenebilir Atık+Atık	2.124,0	0,71
Atık Isı	848,3	0,29
Jeotermal	6.127,5	2,06
Güneş	2.889,3	0,97
TOPLAM	297.277,5	100,00

Tablo 2-2 2017 Yılı Elektrik Enerjisi Üretiminin Kaynaklarına Göre Dağılımı




Şekil 2-3 2017 Yılı Elektrik Enerjisi Üretiminin Kaynaklarına Göre Dağılımı

2.3.3 Türkiye’de Bulunan Trafo Miktarı

Alternatif akım üreten elektrik santralleri çoğu zaman linyit ve taş kömürü havzalarında veya baraj ve akarsuların bulunduğu yere inşa edilir. Üretilen bu enerjinin kilometrelerce uzaktaki tüketicilere iletilmesi gerekmektedir. Elektrik enerjisini en ucuz ve en az kayıpla iletilmesini sağlayan makineler elektrik trafolarıdır. Trafo sayısının artması bir semt halkının veya bir köy halkının üretilen elektrik enerjisinden faydalanabilme imkanı vermektedir. Dolayısıyla elektriğin üretimi kadar iletilmesi de elektrik enerjisi tüketimini etkilemektedir. Sonuç olarak trafolar elektrik tüketiminde oldukça önemli etkenlerden birisidir.

Elektrik tüketimi ve trafo sayısı arasındaki korelasyon katsayısı 0,99104 çıkmıştır. Bu çıktı değeri trafo sayısının elektrik tüketim ile pozitif yönde ve güçlü bir ilişkisi olduğunu göstermektedir. Şekil 5.3’de Türkiye’deki trafo sayısının yıllara göre dağılımı görülmektedir.



Grafik 2-5 Türkiye’deki Trafo Sayısının Yıllara Göre Dağılımı


2.3.4 Gayrisafi Yurtiçi Hasıla

Gayrisafi Yurtiçi Hasıla, bir ülkenin ekonomik büyüklüğünün göstergelerinden biridir. Bir ülkenin GSYİH değeri o ülkede belirli bir zaman içerisinde üretilen tüm nihai mal ve hizmetlerin parasal değerini temsil etmektedir. Ülkelerin en önemli hedeflerinden bir tanesi gayrisafi yurtiçi hasıla değerinin artmasıdır. Böylelikle ülkeler toplumsal refahı arttırmayı hedeflemektedir.

GSYİH ile elektrik enerjisi tüketiminin ilişkisi sanayi devrimine dayanmaktadır. Sanayi ve teknolojik gelişmelerin oluşmasıyla elektrik tüketimi de artmıştır. Bir ülkede gelişim ve büyüme üretime, üretim ise başta elektrik enerjisi olmak üzere diğer enerji kaynaklarına bağlıdır (Yanar & Kerimoğlu, 2011).

Ayhan Kapusuzoğlu ve Mehmet Baha Karan, 2010 yılında yaptıkları çalışmada Türkiye’de elektrik tüketimi ve gayrisafi yurtiçi hasıla arasındaki ilişkiyi incelemiştir. Çalışmada Granger nedensellik testi uygulanmıştır. Yapılan bu çalışma sonucunda elektrik tüketimi ile gayrisafi yurtiçi hasıla miktarı arasında tek yönlü (Gayrisafi yurtiçi hasıla => elektrik tüketim miktarı) nedensellik ilişkisi bulunduğu tespit edilmiştir (Kapusuzoğlu & Karan, 2010).

Elektirik tüketimi ile GSYİH arasındaki korelasyon katsayısı 0,925472 çıkmıştır. Bu çıktı değeri, elektrik tüketimi ile GSYİH arasında güçlü ve pozitif yönde bir ilişkinin olduğunu göstermektedir. Şekil 5.4’de Türkiye’nin yıllara göre GSYİH değerleri görülmektedir.




Grafik 2-6 Türkiye'nin Yıllara Göre GSYİH Değerleri

2.3.5 Yatırım Miktarı

Elektrik tüketim tahmininde kullanacağımız son değişken ülkemizde elektriğe olan yatırım miktarlarıdır. Ülkemizde gelişen teknoloji, sanayi vb. ile birlikte elektriğin birçok alanda kullanılması bu alanda yatırım yapılmasında büyük etkindir.

Elektrik enerjisi toplumlar tarafından en fazla tüketilen ve birçok alanda kullanılabilir bir enerji çeşididir. Artan elektrik enerjisine olan talebi karşılamak adına ülkeler yeni üretim kaynaklarına ve yenilenebilir enerji kaynaklarına yönelik birçok alanda yatırımlar yapmaktadır. Türkiye'de izlenen politikalarda ise enerji alanında dışa bağımlılığı azaltma konusunda sağlanan destekler ön plana çıkmaktadır. Bu doğrultuda elektrik üretiminde gerekli yatırımların yapılmasıyla küresel enerji piyasasında daha etkin bir rol üstlenmesi hedeflenmektedir (Karagöl & Tür, Türkiye'de Elektrik Enerjisi, 2017).

Elektrik tüketimi ile yatırım arasındaki ilişki incelenmiş ve korelasyon katsayısı 0,75209 bulunmuştur. Bu değer diğer değişkenlerin korelasyon katsayılarına nazaran daha düşüktür. Fakat korelasyon katsayısı yorumlanırken -1 ile 1 değerleri arasına bakıldığında elektrik tüketimi ve yatırım arasında güçlü ve pozitif yönde bir ilişkiden bahsetmek mümkündür.



Grafik 2-7 Elektrik Enerjisi Yatırım Miktarları

3. TAHMİN

Bir ticari işletmede veya kuruluştaki yönetimin en önemli görevlerinden birisi gelecek için planlama yapmaktır. Yapılacak bu planlamanın en kritik noktası ise gelecekteki durumu en iyi ve gerçeğe yakın şekilde tahmin etmektir. Tahmin (forecasting) ile kestirim (estimation) sürekli karıştırılan iki kelimedir. Kestirim var olanı değerlendirirken tahmin var olacak olanı belirlemedir yani gelecekte bahsediyorsak söz konusu tahmindir (Armutlulu, İşletmelerde Uygulamalı İstatistik, 2008).

Tahmin kelimesinin sözlük anlamı; akla, sezgiye veya bazı verilere dayanarak gelecekte olması muhtemel olayların önceden görülmesidir. Özel veya kamu kuruluşlarının gelecekte sağlıklı bir şekilde ilerleyebilmeleri için geleceği tahmin edebilmeleri ve bu doğrultuda plan ve strateji geliştirmeleri gerekmektedir. Bu kararları verirken yapılacak olan tahminin doğruluğu önem arz etmektedir. Yapılacak kötü tahminler geleceğin yanlış yorumlanmasına ve kötü tahmin üzerine kurulan plan ve stratejilerin kuruluşu olumsuz yönde etkilenmesine neden olacaktır.

Tahmin için belirlenen ilke ve kullanılabilir birçok yöntem vardır. Tahmin yöntemi seçilirken veri setinin özelliklerine bakılmalıdır. Ancak şu unutulmamalıdır ki hangi yöntem kullanılırsa kullanılsın yapılan tahminler %100 doğru olmayacaktır. Fakat gerçek değere olabildiğince yakın değerlerin tahmin edilmesi yapılacak planlamanın kalitesini belirleyecek en büyük etken olacaktır.

Zaman aralığına göre tahminleri sınıflandırmak mümkündür.

- **Çok Kısa Vadeli Tahminler;** ticari işletmelerde veya kuruluşlarda şirket içi veriler ile haftalık veya günlük olarak yapılan tahminlerdir.
- **Kısa Vadeli Tahminler;** genellikle 4-6 ay arası süreleri içeren tahminlerdir.
- **Orta Vadeli Tahminler;** 6 ay ile 5 yıl arasındaki süreci kapsayan tahminlerdir
- **Uzun Vadeli Tahminler;** beş yıl ve üzeri süreleri kapsayan çalışmalardır.

Bazı tahmin ilkeleri aşağıdaki gibidir.

- Tahmin işlemi yapılırken, sonucu etkileyecek bütün faktörler incelenmelidir.
- Miktar bakımından büyük olan gruplar için yapılan tahminler, az miktardaki grupların tahminlerine nazaran daha doğru sonuçlar verirler.

- Kısa bir zaman dönemi için yapılan tahminler daha uzun dönemler için yapılan tahminlere kıyasla daha doğru sonuçlar verir. Çünkü uzun dönemde belirsizlik daha fazladır.

Tahmin sürecinde uygulanan tahmin yönteminin performansını ölçmek için çeşitli hata ölçüm hesaplamaları bulunmaktadır. Bu ölçümler tahmin edilen değer ile gerçekleşen değerlerin karşılaştırılmasına dayanmaktadır. Bazı hata ölçüm teknikleri aşağıda gösterilmiştir.

1. Ortalama Mutlak Sapma (mean absolute deviation)
2. Hata kareleri ortalamaları (mean squared error)
3. Mutlak sapma oranlarının ortalaması (mean absolute percentage error)
4. Hata oranları ortalaması (mean percentage error)

$$e_t = G_t - Y_t$$

e_t = Tahmin Hatası

G_t = Gerçek Değer

Y_t = Tahmin Değeri

Ortalama mutlak sapma (MAD): Bir veri setinin ortalama mutlak sapması o veri setindeki her bir veri noktasıyla ortalama arasındaki farktır. Bu yöntem veri setindeki değerlerin ne kadar yayılmış olduğunu anlamamızı yardımcı olur.

$$MAD = \frac{\sum |e_t|}{n}$$

Hata kareleri ortalamaları (MSE): Bir regresyon çizgisinin bir dizi noktaya ne kadar yakın olduğunu gösterir. Bu noktalar regresyon çizgisine ne kadar yakın ise hata o kadar azalır. Negatif değerlerin elde edilen sonucu yanıltmaması için hataların karelerinin alınması gerekmektedir. Bu çalışmada da hata ölçüm tekniklerinden hata kareleri ortalaması tekniği uygulanmıştır.

$$MSE = \frac{\sum e_t^2}{n}$$


Mutlak sapma oranlarının ortalaması (MAPE): Zaman serilerinde tahmin yapıldığında oluşan hataların mutlak değerinin, gözlem verilerinin mutlak değerine oranlarının ortalamasının yüzdelik değeridir.

$$MAPE = \frac{\sum \frac{|e_t|}{Y_t}}{n}$$

Hata oranları ortalaması (MPE): Tahmin sonucu elde edilen tahminin yanlı olup olmadığı önemlidir. Yansızlığın olup olmadığını bilmek istiyor ve büyüklüklere önem veriyorsak bu yöntemin kullanılması daha uygundur.

$$MPE = \frac{\sum \frac{e_t}{Y_t}}{n}$$

Birçok tahmin yöntemi bulunmaktadır. Bunları sayısal olmayan, tahmin çalışmasını yapan kişi veya kişilerin görüş ve yargılarıyla yapılan **nicel tahmin yöntemleri** ve geçmişe ilişkin sayısal verilerin analiz edilmesiyle yapılan **nitel tahmin yöntemleri** olmak üzere iki ayrı başlıkta incelenmelidir. Bu yöntemler ve bu yöntemlerin alt başlıkları aşağıdaki tabloda gösterilmiştir. Tablonun ardından yöntemler ayrı ayrı incelenecektir.



Şekil 3-1 Tahmin Yöntemleri

3.1 Nitel Tahmin Yöntemleri

Nitel tahmin yöntemleri temel olarak uzmanlık, deneyim, sezgi ve insan yargısına dayanmaktadır. Geçmiş dönemlere ait verilerin mevcut olmadığı durumlarda veya koşulların çok hızlı değiştiği ve matematiksel tahmin yöntemlerinin uygun olmayan veya şüpheli sonuçlar doğurabileceği durumlarda kullanılabilir. Matematiksel hesaplamalara dayanmazlar. Nitel tahmin yöntemleri deneyimsiz tahmin yöntemi ve delphi tekniği olarak ikiye ayrılır.

3.1.1 Deneyimsiz Tahmin Yöntemleri (Naive Forecasting)

Birçok yönetici tarafından bilinçli veya bilinçsiz olarak kullanılan en basit tahmin yöntemidir. (n) zamanındaki değer (n+1) zamanının tahmini olarak kullanılır. Ancak zaman serisinde trend veya mevsimsel dalgalanma söz konusu ise bu yöntemin kullanılmaması gerekir. Henüz yeni kurulmuş işletmeler için birkaç döneme ait veri olması durumunda bu yöntem kullanılabilir (Armutlulu, İşletmelerde Uygulamalı İstatistik, 2008).

3.1.2 Delphi Tekniği

Delphi tekniği, araştırılan veya tahmin edilmesi istenen bir konuda konunun uzmanı olan kişilere anketler gönderilerek elde edilen sonuçların analizine dayanan bir tahmin sürecidir. Öncelikle konu ile ilgili uzman kişiler belirlenir ve belirlenen bu kişilere sorunlara bakış açıları ve çözüm önerileri hakkında anketler gönderilir. Anketler doldurulduktan sonra geri gönderilir. Her turun sonunda tüm anketler tekniği yöneten moderatörde toplanır ve başka bir turun gerekli olup olmadığına karar verilir. Bu turlar genel bir fikir birliği elde edilene kadar devam eder. Bu yöntemde uzman katılımcılar yüz yüze görüşmezler. Böylece kişiler fikirlerini sunarken sürü psikolojisi etkisinden kurtulurlar. Bu yöntemin dezavantajları ise paneldeki uzman kişilerin seçimi ve tekniğin oldukça fazla zaman almasıdır (Lancaster & Massingham, 2011).

3.2 Nicel Tahmin Yöntemleri

Nicel tahmin yöntemleri öznel yargılardan ziyade matematiksel modellerin üzerine kurulu yöntemlerdir. Matematiksel modellerin ve hesaplama gücünün büyük avantajları sayesinde nicel tahmin yöntemleri tahmin yöntemleri içerisinde büyük bir öneme sahiptir. Nicel tahmin yöntemleri zaman serisi analizine dayalı metotlar ve sebep-sonuç ilişkisine dayalı metotlar olmak üzere iki grupta incelemek mümkündür.

Nicel tahmin yöntemlerinden yapay sinir ağları bölümleri tezde uygulanan yöntem olduğundan dolayı detaylı olarak ayrı bir bölümde ele alınmıştır.

3.2.1 Zaman Serisi Analizine Dayalı Metotlar

Ülkelerin ve işletmelerin gelecek ile ilgili planlama ve stratejilerini oluşturması için ileriye yönelik yapılacak tahminlerin en uygun şekilde yapılması gerekmektedir. Bu tahminlerin yapılabilmesi için geçmiş dönemler hakkında bilgi elde etmenin en uygun yollarından bir tanesi zaman serisi analizleridir.

Zaman serisi analizi, geçmiş dönemlerdeki verilerin incelenerek ileriye yönelik tahminlerin yapılmasına dayanan bir yöntemdir (Bülbül, 1994).

Zaman serisinin söz konusu olabilmesi için o seride zaman bağlı bir durumun olması gerekmektedir. Örneğin n zamanındaki borsa değeri hesaplanırken $(n+1)$ zamanındaki kapanış değerlerinden etkilenmektedir. Bundan dolayı borsa değeri bir zaman serisidir. Yani zaman serisi analizi yapılırken verilerin zamana bağlı olarak değişimleri gerçekleşir.

Zaman serilerinin çeşitli kullanım amaçları vardır.

- **Aykırı verileri yakalama:** elde bulunan veriler zamanlarına göre bir sıraya dizildiğinde serinin uzağında bulunan değerler aykırı verilerdir. Verilen seride aykırı veriyi yakalamak o serinin hareketini yakalamayı gerektirir (Barnett & Lewis, 1980). Aykırı veriyi yakalamak eldeki veriler ile zaman serisi analizi yapılarak verilerin zaman üzerindeki hareketlerindeki farklılıkları yakalamaktır. Aykırı veriler, değeri hatalı girilmiş veriler veya belli bir olaya bağlı olarak elde edilen veriler olabilir. Bu verilerin yakalanması aykırı verinin neden oluştuğunu anlamak ve o olaya çözüm üretebilmek adına oldukça önemlidir (Şeker, 2015).

- **Tahmin etme:** Zaman serisi analizi yapılarak geleceğe yönelik tahminler yapılabilir. Birçok tahmin çalışmasında bir sonraki bölümde detaylı bir şekilde açıklanacak olan zaman serisi analizleri kullanılmaktadır. Bu analizin doğru bir şekilde yapılması borsa analizi gibi finansal sistemlerde ve stratejik planlamalarda oldukça önemlidir (Şeker, 2015).

- **Eksik verileri tamamlama:** Bir veri setinde eksik veri mevcut ise kullanılabilir en iyi imputasyon yöntemi zaman serisi analizidir (Honaker & King, 2010). Bir veri setinde çalışabilmek için eksik verilerin tamamlanması gerekmektedir. Bu verilerin tamamlanabilmesi için zaman serisi analizi kullanılarak eksik olan bilgi tahmin edilebilir. Bu yöntem ile verilerin zamana bağlı hareketleri yakalanır ve bu doğrultuda eksik veriler tahmin edilebilir.

- **Aykırı değerlerin tespiti:** bir veri setinde kayıp veya aykırı değerlerin düzeltilmesi veya tamamlanması gerekir. Bunun için zaman serisi analizi kullanılabilir (Crosswhite, 2003).

3.2.1.1 Hareketli Ortalamalar

Zaman serisi analizlerinden biri olan hareketli ortalama hesaplama tekniği tahmin amacıyla kullanılabilir bir yöntemdir. Çeşitli özel hareketli ortalama teknikleri vardır. Bunlar basit hareketli ortalama, ağırlıklı hareketli ortalama ve çift hareketli ortalamadır (Armutlulu, İşletmelerde Uygulamalı İstatistik, 2008).

- *Basit hareketli ortalama:* Bu yöntemde son m kadar dönemin ortalaması bir sonraki dönemin tahmini değeri olarak alınır. Bu işlemi yaparken yöntemi uygulayacak kişinin kaç dönemlik hareketli ortalama alacağı önemlidir. Yeni dönemin verisi ortalamaya dahil edildiğinde en eski veri hesaplamadan çıkarılır ve yeni hareketli ortalama hesaplanır. Hesaplanan bu değer bir sonraki dönemin tahmin değerini oluşturur (Armutlulu, İşletmelerde Uygulamalı İstatistik, 2008).

$$M_{t+1} = \frac{Y_t + Y_{t-1} + \dots + Y_{t-m+1}}{m}$$

- *Ağırlıklı hareketli ortalama:* Basit hareketli ortalama tekniği ile karşılaştırıldığında bazı farklılıklar haricinde benzer şekilde hesaplanmaktadır. Basit hareketli ortalama bütün dönemleri ağırlıkları eşittir. Her dönemin aynı etkiye sahip olmadığı zamanlarda ağırlıklı hareketli ortalama tekniği kullanılmaktadır. Her dönemde farklı ağırlıklar bulunabilir. w_i değeri (i) döneminin ağırlığını ifade etmektedir (Armutlulu, İşletmelerde Uygulamalı İstatistik, 2008).

$$M_{t+1}^w = \frac{w_m Y_t + w_{m-1} Y_{t-1} + \dots + w_1 Y_{t-m+1}}{w_m + w_{m-1} + \dots + w_1}$$

- *Çift hareketli ortalama:* Elimizde bulunan verilerin birinci veya ikinci dereceden bir polinom şeklinde trende sahip olması durumunda çift hareketli ortalama tekniği kullanılabilir (Armutlulu, İşletmelerde Uygulamalı İstatistik, 2008).

$$M_t = \text{Basit Hareketli Ortalama}$$

$$M_t^d = \text{Çift Hareketli Ortalama}$$

$$M_t^d = \frac{M_t + M_{t-1} + \dots + M_{t-n+1}}{n}$$

$$a_t = 2M_t - M_t^d$$

$$b_t = \frac{2}{n-1} (M_t - M_t^d)$$

Buradan t+1 dönemi için tahmin değeri;

$$M_{t+1}^d = a_t + b_t$$

formülü ile bulunur.

3.2.1.2 Üstel Düzeltme

Hareketli ortalamalar metodunda iki durum elde edeceğimiz tahmin sonucu için sakıncalı olabilecek niteliktedir. Bunlardan ilki hareketli ortalamalar yönteminde kaç periyodun hesaplamaya dahil edilmesi gerektiğine dair belirli bir sistem yoktur ve deneme/yanılma ile bu miktar belirlenmektedir. Diğeri ise hareketli ortalamalar yönteminde hesaplamaya dahil edilecek dönemlere eşit ağırlıklar sunulmaktadır. Bu iki sakıncalı durumu ortadan kaldırmak için üstel düzeltme yöntemi önerilmektedir.

Çok eski bir yöntem olmasına karşın günümüzde tahmin yöntemi olarak en fazla kullanılan modellerden birisi üstel düzeltme yöntemidir. Bunun asıl nedeni modelin basit, şeffaf ve birçok duruma uyum sağlama özelliğinde gelmektedir.

Üstel düzeltmenin temel fikri elimizde bulunan verilerin ağırlıklarına bakıldığında son dönemdeki verinin ağırlığı daha eski dönemin ağırlığına nazaran daha fazla olmalıdır (Bergmeir, Hyndman, & Benitez, 2016). Fakat bu en eski döneme ait ağırlığın sıfır değeri alacağı anlamına gelmez. Bu yöntemde ne kadar geçmişe gidilirse gidilsin ağırlık asla sıfır olmaz. Bu çalışmada üstel düzeltme yöntemi de kullanıldığı için bu bölüm detaylı olarak incelenecektir.

Üstel düzeltme yöntemi 3'e ayrılmaktadır.

- Basit üstel düzeltme tekniği
- Holt üstel düzeltme tekniği
- Winter üstel düzeltme tekniği

❖ *Basit üstel düzeltme tekniği:* Bu yöntemde sadece bir ortalama düzey etrafında hareket eden serilerin analizinde kullanılmaktadır. Kullanılacak olan veri seti belirli bir trende veya mevsimsel dalgalanmaya sahipse bu yöntemi kullanmak doğru olmayacaktır (Hyndman & Athanasopoulos, 2014).

$$A = t \text{ dönemin ağırlığı}$$

$$(1 - A) = (t - 1) \text{ döneminin ağırlığı}$$

$$A(1 - A)^2 = (t - 2) \text{ döneminin ağırlığı}$$

şeklinde ilgili dönemin ağırlığı devam eder.

$$Y_n = n'nci \text{ dönemin değeri}$$

$$S_n = n'nci \text{ dönemin tahmin değeri}$$

t=1;

$$S_1 = Y_1$$

t=2;

$$S_2 = AY_1 + (1 - A)S_1$$

t=3;

$$S_3 = AY_2 + (1 - A)S_2$$

Bu yöntemde A değerini belirlemek oldukça büyük önem taşır. A değeri 0 ile 1 arasındadır. Eğer A değeri 1'e oldukça yakın bir değer seçilmiş ise elde edilen tahmin sonucunun son dönemdeki değere yakın bir değer olarak karşımıza çıkacağı bilinmelidir. Eğer A değeri 0'a oldukça yakın bir değer seçilmiş ise bu yöntem ile elde edeceğimiz tahmin değeri en eski dönemdeki değere yakın bir değer olacağı bilinmelidir. Ayrıca yukarıda belirtildiği üzere ilk dönem tahmini o dönemin gerçek değeridir (Armutlulu, İşletmelerde Uygulamalı İstatistik, 2008).

❖ *Holt Üstel Düzeltme Tekniği:* Elimizdeki veri seti bir trende sahip ise hareketli ortalama ve basit üstel düzeltme yöntemi kullanılamamaktadır. Böyle bir durumda kullanmamız gereken yöntem Holt yöntemi olacaktır. Çünkü Holt yöntemi hareketli ortalama ve basit üstel düzeltme yöntemlerinden farklı olarak verideki trendi de göz önüne almaktadır (Soysal & Ömürgönülşen, 2010). Fakat veri setinde mevsimsel değişimler söz konusu ise bunun için Holt yöntemi uygun bir teknik olmayacaktır. Bunun için Winter üstel düzeltme metoduna bakılmalıdır. Bu iki model gelecek döneme ait tahminde bulunurken belirli aralıkta alınan güncel verilerin hata oranlarını da göz önünde bulundurmaktadır (Yağımlı & Ergin, Türkiye’de İş Kazalarının Üstel Düzeltme Metodu ile Tahmin Edilmesi, 2017).

Holt yöntemi uygulanırken her dönemde trend ve seri güncellenmektedir. Seri her dönem sonundaki düzleştirilmiş tahmini değerdir. Trend ise her dönem sonundaki düzleştirilmiş tahmini değerdir. Trend ise her dönem sonundaki düzleştirilmiş tahmini ortalama büyüme değeridir (Maia & Carvalho, 2011).

Modelde iki farklı katsayı kullanılmaktadır. Bunlardan bir tanesi düzleştirme katsayısını belirlerken diğeri trend tahmini için kullanılan düzleştirme katsayısıdır.

Bu yöntemin formülleri aşağıdaki gibidir (Armutlulu, İşletmelerde Uygulamalı İstatistik, 2008).

$$S_t = aY_t + (1 - a)(S_{t-1} + c_{t-1})$$

$$c_t = b(S_t - S_{t-1}) + (1 - b)c_{t-1}$$

Burada ilk dönemden daha eski veri olmadığı ve formüle yerleştiremeyeceğimiz için düzeltilmiş istatistiğin başlangıç değeri olarak gözlemlenen birinci dönemin değeri alınır. Yani formül ile göstermek istenirse formül aşağıdaki gibi olur.

$$S_1 = Y_1$$

Bu yöntemde c_t katsayısının ilk dönemdeki değeri aşağıdaki gibi hesaplanır.

$$c_1 = \frac{Y_2 - Y_1}{2} + \frac{Y_4 - Y_3}{2}$$

Formüllerdeki ifadeler;

$S_t = \text{Düzeltilmiş istatistiğin } t \text{ dönemindeki değeri}$

$Y_t = t \text{ dönemindeki gerçek değeri,}$

$c_t = t \text{ dönemindeki eğim tahminini,}$

$a = \text{Seri için belirlenen katsayıyı,}$

$b = \text{trend için belirlenen katsayıyı,}$

İfade etmektedir.

❖ *Winter üstel düzeltme tekniği:* Üstel düzleştirme yöntemi temel olarak tahmin sırasında son verilerin önemini artıran önemli bir zaman serisi tahmin yöntemidir. Fakat basit üstel düzeltme tekniği hem serilerin hem de mevsimselliğin söz konusu olduğu veri setlerinde kullanılamaz. Bu durum için Holt-Winters yöntemi gibi daha yetenekli yaklaşımlar getirilmiştir. Ayrıca yapılan çalışmalara göre Holt-Winters modelinin az sayıda örnekle bile tutarlı tahmin sonuçları verdiği görülmüştür (Jiang, Wu, Gong, Yu, & Zhong, 2020). Winter üstel düzeltme tekniğinin Holt tekniğinden en önemli farkı verilerin mevsimsel dalgalanmalardan etkilendiği durumda kullanılabilir olmasıdır.

Winter üstel düzeltme yönteminin iki önemli sorunu vardır.

- Bu sorunlardan birincisi veri seti konjonktürel yapıya sahip olması durumunda bu modeli kurmak oldukça zor olacaktır.
- Diğer bir sorunu ise modeli oldukça önemli ölçüde etkileyen üstel düzeltme katsayılarının değerlerinin belirlenmesidir. Winter yönteminde Holt yöntemindekine benzer şekilde üç üstel düzeltme katsayısı belirlenmelidir. Bu katsayılar deneme/yanılma yöntemi ile belirlenmektedir (Armutlulu, İşletmelerde Uygulamalı İstatistik, 2008).

3.2.1.3 ARIMA

ARIMA, ARMA modellerinin dört üyesinden bir tanesidir. AR, MA, ARMA ve ARIMA olmak üzere bu dört model ARMA modelleri olarak bilinmektedir.

Elimizdeki veri setinde herhangi bir durağanlık söz konusu ise ve bir zaman serisinin varlığı yok ise AR, MA ve ARMA modelleri bu veri seti için uygun modellerdir. ARIMA’da ise zaman serisi söz konusudur. Yani zaman serisinin ortalama ve varyansında zamana bağlı olarak bir değişim gözlemlenir. Bu durum için ARIMA modeli kullanılmaktadır (Demirel, Kakilli, & Tektaş, ANFIS ve ARMA Modelleri ile Elektrik Enerjisi Yük Tahmini, 2010).

Üstel düzeltme ve ARIMA modelleri zaman serisi tahmininde en yaygın kullanılan iki yaklaşımdır ve sorunu tamamlayıcı yaklaşımlar sağlarlar. Üstel düzeltme modelleri verilerdeki trend ve mevsimsellik tanımlamasına dayanırken, ARIMA modeli verilerdeki otokorelasyonları tanımlamayı amaçlamaktadır (Hyndman & Athanasopoulos, 2014).

3.2.1.4 ARCH/GARCH

Geleneksel ekonomik modeller varyansın gecikmeli değerlerinin sabit olduğunu varsaymaktadır. Fakat günümüzdeki finansal piyasalarda değişkenlerin birbirleri ile çok yönlü bir ilişkisinin olması parametreleri volatil bir yapıya çevirmiştir. Bu durumda geleneksel ekonomik modellerin kullanılması uygun değildir. Bunun üzerine Engle 1982 yılında ARCH (Autoregressive Conditional Heteroscedasticity) yani otoregresif koşullu değişen varyans modelini geliştirmiştir. ARCH modeli zaman serisi değişkenlerinin varyansının sabit olmadığı, aksine dinamik bir yapıya sahip olduğu için sürekli olarak değiştiği varsayımına dayanmaktadır (Engle & Ng, 1993).

Engle’nin ARCH modelinde eleştirilmeye açık bazı noktalar bulunmaktaydı. Bunlardan bir tanesi, ARCH modelinin volatilitiyi yakalamak için birçok parametreye ihtiyaç duymasıydı.

Bollerslev 1986 yılında ARCH modelinin kısıtlamalarını ortadan kaldırmak ve negatif varyans parametre tahminlerini önlemek amacıyla GARCH (Generalized Autoregressive Conditional Heteroscedasticity) modelini yani genelleştirilmiş otoregresif koşullu değişen varyans modelini sundu. Bollerslev’in bu yaklaşımı, mevcut volatilitiyi etkileyen geçmiş volatilitelere izin vermektedir (Kuzu, 2018).

ARCH modeline benzer şekilde GARCH modelinde de geliştirilmesi gereken noktalar vardır. Gelişmekte olan finansal piyasalara ait varlıkların volatilitesi her zaman aynı tepkiyi vermemesi gerekmektedir. Fakat GARCH modelinde piyasalardan gelen bilgilere simetrik tepki verme varsayımına

dayandığından dolayı asimetrik durumlar için bu model yeterli olamamaktadır. Bunun sebebi GARCH modeli piyasadan gelen bilgileri etkileri bakımından bağımsız bir şekilde ayıramamaktadır.

3.2.2 Sebep-Sonuç İlişkisine Dayanan Metotlar

3.2.2.1 Doğrusal Regresyon

Aralarında sebep-sonuç ilişkisi bulunan ve iki veya daha fazla değişken arasındaki ilişkiyi incelemek amacıyla kullanılan yöntem regresyon denmektedir. Bu yöntem değişkenler arasındaki ilişki yardımıyla tahminler veya kestirimler yapmak amacıyla kullanılan yöntemdir. Bağımlı ve bağımsız olmak üzere iki değişken bulunmaktadır.

Bağımlı değişken, regresyon modelinde açıklanan ya da tahmin edilen değişkene verilen isimdir. Bağımlı değişkenin bağımsız değişken ile ilişkisi olduğu varsayılır.

Bağımsız değişken ise modelde açıklayıcı değişkendir ve bağımlı değişkenin değerini tahmin etmek amacıyla kullanılır.

Normal dağılım gösteren sayısal bir değişken ile aralarında ilişkinin söz konusu olduğu başka bir normal dağılım gösteren değişkenin tahmini veya kestirimi için kullanılırsa bu yöntem basit doğrusal regresyon (simple linear regression) olarak tanımlanır. Tahmin veya kestirim için birden fazla değişkenden yardım alınıyorsa bu yöntem çoklu doğrusal regresyon (multiple linear regression) olarak tanımlanır (Kılıç, 2013). Fonksiyon türüne göre ise doğrusal regresyon ve doğrusal olmayan regresyon olarak ikiye ayrılmaktadır.

Bu bölümde belirtilen basit doğrusal regresyon modeli aşağıdaki gibidir:

$$y = \beta_0 + \beta_1 x + \varepsilon$$

Bu formülde kullanılan β_0 kesim noktasını, β_1 eğim noktasını ve ε rasgele hata bileşenini ifade etmektedir. β_0 ve β_1 parametrelerini kestirebilmek için en küçük kareler yöntemi kullanılmaktadır. En küçük kareler yönteminde gerçek değer ile tahmin edilen değer farkının 0 olması

ve sapmaların karelerinin toplamının minimum değere sahip olması hedeflenmektedir. Bu durumu matematiksek olarak gösterecek olursak:

$$\sum [y_i - (\beta_0 + \beta_1 x_i)] = 0$$
$$\sum [y_i - (\beta_0 + \beta_1 x_i)]^2 = \min$$

Oluşturulan bu denklem yardımı ile bağımsız değişkenin değeri yerine koyularak tahmin değeri elde edilir.

3.2.2.2 Doğrusal Olmayan Regresyon

Doğrusal regresyon modeli her durumda uygun değildir. Değişkenler arasındaki ilişkinin diferansiyel olması veya bağımlı değişken ile bağımsız değişkenler arasındaki ilişkinin şekli ile doğrudan bilgi sahibi olunamaması durumunda doğrusal olmayan bir model incelenmelidir. Bilinmeyen parametrelerde doğrusal olmayan herhangi bir model doğrusal olmayan regresyon modeli (nonlinear regression model) olarak bilinmektedir.

3.2.2.3 Çoklu Regresyon

Regresyon modelleri birçok alanda kullanılmaktadır. Genellikle herhangi bir bağımlı değişkeni bir adet bağımsız değişken ile açıklamak mümkün olmamaktadır. Birçok değişken bir araya gelerek diğer bir değişkeni etkileyebilmektedir. Bir araya gelen bu değişkenler aynı zamanda endi aralarında da birbirlerini etkileyebilmektedir. Bundan dolayı birden fazla değişkenin kullanılması gerektiği durumlarda tek basit doğrusal regresyonun kullanılması mümkün değildir. Birden fazla bağımsız değişken kullanılarak yapılan regresyon analizine çoklu regresyon analizi (multiple regression analysis) denilir.

Çoklu regresyonda, bağımlı değişken ile bağımsız değişken arasında iki veya daha yüksek dereceden polinom ilişkileri de aranabilir.

$$y = \beta_0 + \beta_1 x + \beta_2 x^2 + \varepsilon$$

Parabolik modelde iki bağımsız değişken olduğu düşünülerek, $x_1 = x$ ve $x_2 = x^2$ alınarak çok değişkenli model ile çözüme ulaşılabilir.

Basit regresyon modelinde de olduğu gibi parametrelerin kestirimi en küçük kareler yöntemi kullanılarak yapılmaktadır. En küçük kareler yöntemi ile elde edilen istatistikler regresyon doğrusundaki katsayıların tarafsız kestiricileridir.

Aşağıda gösterilen denklemlerden ilki gözlem değerlerinden elde edilen, örnekleme ait doğrusal regresyon hesaplaması, diğer denklem ise hesaplanan değerlerin matematiksel gösterimidir.

$$y = b_0 + b_1 x_1 + b_2 x_2 + \dots + b_k x_k + \varepsilon$$

$$\hat{y} = b_0 + b_1 x_1 + \dots + b_k x_k$$

Elde edilen bu değerlerin farkı alınarak hata değeri bulunur.

$$e_i = y_i - \hat{y}_i$$

Hata değeri olarak belirttiğimiz e_i değerlerinin toplamı sıfır, kareler toplamını da minimum değer olacak şekilde b_i değerleri hesaplanır.

Çoklu regresyon yönteminde hata değişkeni olan e 'nin dağılımının sıfır ortalamalı ve σ_e^2 varyanslı normal dağılıma sahip olduğu varsayılmaktadır. Çoklu regresyon yöntemi ile basit doğrusal regresyon yönteminin ortak noktalarından biri bu özelliktir.

Çoklu regresyon yönteminde parametrelerin kestirimi genellikle matrislerin yardımı ile yapılmaktadır. Çünkü bilinmeyen sayısı ve denklem sayısı çoğaldıkça basit doğrusal regresyon yönteminde olduğu gibi formülleri türetmek kolay olmamaktadır (Armutlulu, İşletmelerde Uygulamalı İstatistik, 2008).

Regresyon modelleri bağımlı olan değişkenin tahmini için kullanılmaktadır. Eğer kullandığımız veriler zaman serisi olarak düzenlenmiş ise bağımlı değişken değerinin bir sonraki dönemde ne olacağı veya kullandığımız veriler zamandan bağımsız ise (yani zaman serisi söz konusu değil ise) $k+1$ boyutlu uzayda bir noktanın bağımlı değişkene ait boyutunun ne olacağı, kestirilen modelden hesaplanabilir.

3.2.2.4 Vektör Otoregresyon Yöntemi

Vektör otoregresyon yöntemi 1980 yılında Christopher Simms tarafından geliştirilmiştir. Simms'in geliştirdiği bu model Granger nedensellik testi modelini temel almaktadır. Vektör otoregresyon modelinde bütün değişkenler, model üzerindeki değişkenin kendi gecikmeleri ve diğer tüm değişkenlerin gecikmelerine bağlı olarak, değişkenin gelişimini açıklayan her bir değişken için bir denklem ile, simetrik olarak ele alınır. Vektör otoregresyon modelinde bağımlı değişkenlerin gecikmeli değerlerinin yer alması geleceğe yönelik güçlü tahminlerin yapılmasını mümkün kılmaktadır. Y_t ve X_t serilerini ele alacak olursak vektör otoregresyon modeli aşağıdaki gibi tanımlanmaktadır (Akyüz, 2018).

$$Y_t = a + \sum_{j=1}^m \beta_j Y_{t-j} + \sum_{j=1}^m \delta_j X_{t-j} + \varepsilon_{1t}$$

$$X_t = a + \sum_{j=1}^m \theta_j Y_{t-j} + \sum_{j=1}^m \vartheta_j X_{t-j} + \varepsilon_{2t}$$

Yukarıdaki modelde görüleceği üzere X 'in gecikmeli değerleri Y değişkenini, Y 'nin gecikmeli değerleri X değişkenini etkilemektedir. ε_{1t} ve ε_{2t} hata terimlerini ifade etmektedir.

Vektör otoregresyon metodunda gecikme uzunlukları tespit edildikten sonra etki-tepki fonksiyonları incelenir. Bu fonksiyonlar tablolar veya grafikler yardımıyla şokların değişkenler üzerindeki etkilerini ve hangi zamanda ne kadarlık bir etkisinin olduğunu gösterir. Bu işlem sonucunda şokların hangi değişkende meydana geldiği ve meydana gelen bu şoklar karşısında değişkenlerin nasıl tepki verdiği anlaşılır (Tarı, 2014).

Varyans ayrıştırma analizinde değişkenlerin varyanslarının birbirlerini nasıl etkilediği gözlemlenmektedir. İncelenen değişkenler arasında her değişkenin varyansında gerçekleşen değişimin yüzde kaçının kendi gecikmeleriyle, yüzde kaçının ise diğer değişkenler ile açıklandığı belirtilir. Bunun sonucunda değişkenlerin dışsal mı içsel mi olduğuna karar verilir (Tarı, 2014).



4. YAPAY SİNİR AĞLARI

4.1 Yapay Sinir Ağlarına Giriş

4.1.1 Yapay Sinir Ağlarının Tanımı

Yapay sinir ağları, insan beyninin çalışma sistemine benzer şekilde çalışan, insanlar gibi öğrenebilen ve daha sonra öğrendikleri ile çıkarımlar yapan bilgisayar sistemleridir.

Başka bir tanımla yapay sinir ağları, insanlar tarafından gerçekleştirilmiş örnekleri kullanarak olayları öğrenebilen, çevreden gelen olaylara karşı nasıl tepkiler üreteceğini belirleyebilen bilgisayar sistemleridir. İnsan beyninin fonksiyonel özelliklerine benzer şekilde,

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

gibi konularda başarılı bir şekilde uygulanmaktadır. Örneklerden elde ettikleri bilgiler ile kendi deneyimlerini oluşturur ve daha sonra, benzer konularda benzer kararları verirler (Öztemel, Yapay Sinir Ağları, 2016).

Yapay sinir ağlarının en temel görevi, insanlar tarafından girdi olarak verilen veriler ile kendini eğiterek benzer olaylara karşılık gelen çıktı setlerini belirlemektir.

Örneğin, bir öğrenci integral ile ilgili eğitimler alarak o konuda bilgi sahibi olur ve daha sonra karşısına gelecek integral sorularına öğrendiği bilgiler yardımı ile çıkarımlar yapabilir. Yapay sinir ağları da verdiğimiz örnekteki öğrenci gibi veriler yardımıyla kendini eğiterek benzer konu ile ilgili karşılık gelen olaylarda çıktı setleri üretir.

4.1.2 Yapay Sinir Ağlarının Tarihçesi

İnsanlar tarih boyunca insan beyninin nasıl çalıştığını merak etmiş ve nasıl çalıştığına dair çalışmalar yapmışlardır. Bu merak ile bilgisayarlar hayatımıza girmiştir. Bilgisayarlar başlangıçta

sadece aritmetik işlemler yapmak amacı ile geliştirilmiş iken, bugün olayları öğrenmeleri ve çevre şartlarına göre karar vermeleri istenmektedir. Bundan sonraki aşama ise bilgisayarların çok yüksek oranda beyin gücü gereken işleri yapmaları beklenmektedir. Yapay sinir ağları bu gelişmeyi tetikleyen bilim dallarından birisidir ve gelecekte de en önemli bilim dallarından birisi olmaya devam edecektir.

Bu zamana kadar yapılan çalışmaların bazıları kronolojik olarak aşağıdaki gibi listelenebilir:

- 1890 - İnsan beyninin yapısı ve fonksiyonları ile ilgili ilk yayının yazılması
- 1911 - İnsan beyninin bileşenlerinin belirli bir düzenek ile sinir hücrelerinden oluştuğu fikrinin benimsenmesi
- 1943 - Yapay sinir hücrelerine dayalı hesaplama teorisinin ortaya atılması ve eşik değerli mantıksal devrelerin (threshold logic device) geliştirilmesi
- 1949 - Biyolojik olarak mümkün olabilen öğrenme prosedürünün bilgisayarlar tarafından gerçekleştirilecek biçimde geliştirilmesi
- 1956-1962 - ADALINE ve Widrow öğrenme algoritmasının geliştirilmesi
- 1957-1962 - Tek katmanlı algılayıcının (perceptron) geliştirilmesi
- 1965 - İlk makine öğrenmesi kitabının yayınlanması
- 1967-1969 - Bazı gelişmiş öğrenme algoritmalarının (Grosberg öğrenme algoritması gibi) geliştirilmesi
- 1969 - Tek katmanlı algılayıcıların problemleri çözme yeteneklerinin olmadığı gösterilmesi
- 1969 - DARPA 'nın yapay sinir ağlarını desteklemeyi durdurup diğer yapay zeka çalışmalarına destek vermesi
- 1969-1972 - Doğrusal ilişkilendiricilerin geliştirilmesi
- 1972 - Korelasyon Matriks belleğinin geliştirilmesi
- 1974 - Çok katmanlı algılayıcının ilk çalışmalarının geliştirilmesi
- 1978 - ART modelinin geliştirilmesi
- 1982 - Hopfield ağlarının ve çok katmanlı algılayıcının geliştirilmesi
- 1988 - RBF ve PNN modellining geliştirilmesi
- 1991 - GRNN modellining geliştirilmesi
- 1991 ' den günümüze sayısız çalışma ve uygulamalar geliştirilmiştir.

Yapay sinir ağlarının tarihsel gelişimine bakıldığında 1970 yılının bir dönüm noktası olduğu görülmektedir. Bu tarihten önce birçok araştırmanın yapıldığı ve 1969 yılında XOR probleminin

öz lemedi ni neni ile arařtırmaların durduęu g r lmektedir.1970 yılından sonra sınırlı sayıda arařtırmacının alıřmalarını s rd rmeleri ve XOR problemini  zmeleri sonucunda yapay sinir aęlarına olan ilgi yeniden alevlenmiřtir ( ztemel, Yapay Sinir Aęları, 2016).

Geliřen teknolojiiler ile birok alıřmalar ortaya ıkmıřtır. Bu alıřmalarda kontrol ve tahmin edilebilen sanal zeka yerine geliřen yeni durumlara  z m  retebilen modeller daha bařarılı olacaktır. Yapay sinir aęları ise bu alıřmalarda kullanılacak  ncelikli y ntemlerden biridir.

G n m zde yapay sinir aęları birok alanda kullanılmaktadır. Dolayısıyla bu konudaki alıřmalar desteklenmektedir. İnsanoglu artık makinelerinde  ğrenebileceęini kabul etmiřtir ve bu konuda alıřmalara devam etmektedir.

4.1.3 Yapay Sinir Aęları  zellikleri

Yapay sinir aęları kurulan aę modeline g re farklı  zelliklerde olmasına karřın, dięer yapay sinir aę modelleri ile bazı ortak  zellikleri bulunmaktadır. Bunları ařaęıdaki gibi sıralayabiliriz:

- Yapay sinir aęlarının temel g revi bilgisayarların  ğrenmesini saęlamaktır.
- Geleneksel programlama ve yapay zeka y ntemlerinin uygulandıęı bilgi iřleme y ntemlerinden tamamen farklı bir bilgi iřleme y ntemi vardır.
- Yapay sinir aęlarında bilgi aęın baęlantılarının deęerleri ile  l lmekte ve baęlantılarda saklanmaktadır.
- Yapay sinir aęları  rnekleri kullanarak  ğrenir.  rnekleri kullanarak ilgili olay hakkında genelleme yapabilecek yeteneęe kavuřturulurlar. İlgili  rnekler sunulmaz ise bařarılı sonular elde edilemez.
- Yapay sinir aęlarının g venle kullanılabilmesi iin  nce eęitilmeleri ve sonrasında performansının test edilmesi gerekmektedir.
- Aęın eęitiminde kullanılan veriler yardımıyla genellemeler yaparak g rmedięi  rnekler hakkında bilgi  retir.
- řekil iliřkilendirme ve sınıflandırma yapabilirler.
- Yapay sinir aęlarının kendi kendini organize edebilme ve  ğrenebilme yetenekleri vardır.
- Yapay sinir aęlarının belirsiz bilgileri iřleyebilme yetenekleri vardır.
- Yapay sinir aęlarında bilgi aęa yayılmış durumdadır. H crelerin birbirleri ile baęlantılarının deęerleri aęın bilgisini g sterir.

- Yapay sinir ağıları sadece nümerik bilgiler ile çalışır. Sembolik ifadeler ile gösterilen bilgilerin nümerik gösterime çevrilmeleri gerekmektedir (Öztemel, Yapay Sinir Ağları, 2016).

4.1.4 Yapay Sinir Ağlarının Dezavantajları

Yapay sinir ağlarının birçok avantajı olmasına karşın bazı dezavantajları da bulunmaktadır.

- Yapay sinir ağlarının en önemli sorunlarından birisi donanım bağımlısı olmasıdır
- Yapay sinir ağları oluşturulurken öğrenme katsayısı, hücre yapısı, katman sayısı gibi ağın parametrelerinin ve ağın yapısının belirlenmesi için belirli kurallar yoktur.
- Yapay sinir ağlarında sadece sayısal bilgiler ile hesaplama yapılabilmektedir. Yapay sinir ağlarına sunulmadan önce örneklerin sayısal değerlere çevrilmesi zorunludur.
- Yapay sinir ağları için eğitimin ne zaman sonlanacağına ilişkin belirli bir kural yoktur (Yılmaz, 2017).

Bu dezavantajlardan dolayı yapay sinir ağlarını hayatımızdan çıkarmamak gerekir. Dezavantajlarına rağmen yapay sinir ağları birçok alanda kullanılmakta ve başarılı sonuçlar elde edilmektedir. Dezavantajlarının belirtilmesindeki amaç her durum için yapay sinir ağlarını kullanmanın doğru bir çıkarım olmayacağını belirtmektir.

4.1.5 Yapay Sinir Ağlarının Kullanım Alanları

Gelişen bilgi ve iletişim teknolojileri ile veriye ulaşmak oldukça kolay hale gelmiştir. Pek çok veri toplayan cihaz ve uygulamalar günümüzde mevcuttur. Toplanan bu veriler ile işletme, finans, mühendislik, tıp, savunma sanayi, üretim gibi birçok alanda yapay sinir ağlarından yararlanılmaktadır.

Makro ekonomik tahminler, banka kredilerinin değerlendirilmesi, döviz kuru tahminleri, risk analizleri gibi örnekler finansal konularda uygulama alanı bulmaktadır. Tıp biliminde tıbbi sinyallerin ve kanserli hücrelerin analizinde, savunma sanayi uygulamalarında hedef izleme, nesneleri ve görüntüleri ayırma ve tanıma, askeri uçakların uçuş yörüngelerinin belirlenmesi gibi alanlarda kullanılmaktadır. Üretim sisteminin optimizasyonu, ürün analizi ve tasarımı, ürünlerin kalite analizi ve

kontrolü, planlama ve yönetim analizi gibi alanların aynı sıra, robot sistemlerin kontrolü, doğrusal olmayan sistem modelleme, resim işleme, karakter el yazısı ve imza tanıma, veri madenciliği gibi alanlarda kullanılmaktadır.

Genel olarak yapay sinir ağlarının kullanım alanlarını aşağıdaki gibi sınıflandırmak mümkündür:

- Tahmin
- Sınıflandırma
- Veri Birleştirilmesi
- Veri Kavramlaştırılması
- Veri Süzülmesi
- Resim ve Görüntü İşleme

Birkaç örnek vermek gerekirse, petrol şirketlerinde yer altındaki gaz ve petrol bölgelerinin tespit edilmesinde yapay sinir ağlarından yararlanılmaktadır.


NASA'da, uzay mekiği ile yolculuklarda manevra denetimi sinir ağları çalışmaları ile yapılmaktadır.

İlaç sanayinde daha ucuz ilaç geliştirilmesinde, ilaçların insanlar ve hayvanlar üzerindeki tepkilerinin incelenmesinde sinir ağlarından yararlanılır (Elmas, 2016).

4.2 Yapay Sinir Ağlarının Yapısı ve Elemanları

4.2.1 Yapay Sinir Ağlarının Yapısı

Yapay sinir ağları insan beynindeki hücrelerin çalışma prensibine benzer şekilde çalışmaktadır. İnsan beynindeki hücrelere karşılık olarak yapay sinir ağlarında prosesler vardır. Prosesler 5 temel elemanı vardır. Bunlar girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktıdır.



Şekil 4-1 Yapay Sinir Ağlarının Yapısı

Girdiler ($X_1, X_2, X_3, \dots, X_n$) , prosesin dış dünyadan, başka proses elemanından veya kendi kendisinden aldığı bilgilerdir.

Ağırlıklar ($W_1, W_2, W_3, \dots, W_n$) , girdilere gelen bilgilerin proses üzerindeki etkisinin ne oranda olduğunu gösterir. Ağırlıklar pozitif, negatif veya sıfır değerlerini alabilir. Ağırlığın pozitif değer alması alınan bilginin pozitif etkisinin olduğunu, negatif olması alınan bilginin negatif etkisinin olduğu ve sıfır değeri alması alınan bilgi değerinin herhangi bir etkinin olmadığı anlamına gelmektedir.

Ağırlık değerinin büyük olması, o giriş verisinin ağ için önemli olduğu, küçük olması, o giriş verisinin ağ için daha az öneme sahip olduğu anlamına gelmektedir (Elmas, 2016).

Toplama fonksiyonu, prosese gelen verilerin ağırlık değerleri ile işleme girerek net girdinin hesaplandığı yerdir. En yaygın olarak kullanılan işlem ağırlıklı toplamı bulmaktır. Her bir girdi ağırlık değerleri ile çarpılarak toplanır. Bunun sonucunda prosesin net girdisi bulunmuş olur.

$$NET = \sum_i^n G_i A_i$$


Yukarıda net girdi formülü verilmiştir. Burada G girdi değerlerini, A ağırlık değerlerini, n prosese giren bilgilerin sayısını, i ise ilgili bilgiyi ifade etmektedir. Birçok toplama fonksiyonu çeşidi

bulunmaktadır. Bunlardan bazıları maksimum, minimum, kümülatif toplam, çoğunluk fonksiyonlarıdır. Bu çalışmada yukarıda da formülü verilen toplama fonksiyonu kullanılacaktır.

Toplama fonksiyonunda işlenerek elde edilen net girdi değeri aktivasyon fonksiyonunda işlenerek çıktıyı belirler. Toplama fonksiyonuna benzer olarak burada da birçok değişik formüller kullanılmaktadır. Bunlardan bazıları sigmoid fonksiyonu, lineer fonksiyon, step fonksiyonu, sinüs fonksiyonu, eşik değer fonksiyonu, hiperbolik tanjant fonksiyonudur (Öztemel, Yapay Sinir Ağları, 2016).

Günümüzde en yaygın olarak kullanılan çok katmanlı algılayıcı modelinde ve bu çalışmada da kullanacağımız aktivasyon fonksiyonu sigmoid fonksiyonu olacaktır. +Sigmoid fonksiyonunun formülü ve grafiği aşağıda gösterilmiştir (Haykin, 2009).

$$F(NE T) = \frac{1}{1 + e^{-NE T}}$$




Şekil 4-2 Sigmoid Fonksiyonu

Son kısım ise prosesin çıktı kısmıdır. Burada aktivasyon fonksiyonu tarafından belirlenen çıktı değeri dış dünyaya, başka prosese veya kendi çıktısını kendi girdisine gönderebilir. Bir prosesin birden fazla çıktısı olamaz. Fakat bir çıktı değeri birçok proses elemanına girdi olarak gidebilir.

4.2.2 Yapay Sinir Ağlarının Katmanları

İnsan beynindeki gibi yapay sinir ağlarında da nöronlar devasa bir yapıya sahiptir ve birbirleriyle bağlanarak çeşitli ağları oluştururlar (Kim, 2017) .Yapay sinir ağları 3 temel katmandan oluşmaktadır. Bu katmanlar paralel olarak bir araya gelerek ağı oluştururlar. Bu katmanlar girdi katmanı, ara katman ve çıktı katmanı olarak ayrılmaktadır.



Şekil 4-3 Yapay Sinir Ağında Katmanlar

Girdi katmanındaki elemanlar dış dünyadan alınan bilgileri ara katmana göndermekle sorumludurlar. Bilgi burada herhangi bir işleme tabi tutulmaz.

Girdi katmanından gönderilen bilgiler burada işlenerek çıktı elde edilir. Elde edilen bu çıktı değeri çıktı katmanına gönderilir. Bir ağda birden fazla ara katman görmek mümkündür.

Ara katmandaki sinir sayısı optimal seviyede olmalıdır. Yani ağın en iyi çalışabileceği bir sayıda olmalıdır. Bu katmandaki sinir sayısı fazla artırıldığı durumda ağda genelleşme sorunu ortaya çıkar. İstenen sonuç değeri üzerinde çıktı elde ederiz (Elmas, 2016).

Çıktı katmanını sistemin çıkışı ile kullanıcı veya dış çevreye ileten sinirleri içerir. Ara katmandan gönderilen çıktı değerleri dış dünyaya çıktı katmanından gönderilir.

4.3 Yapay Sinir Ağlarında Öğrenme


Yapay sinir ağlarında öğrenme işlemi sinirler arasındaki ağırlıkların değiştirilmesi ile gerçekleşmektedir. Buna göre ağdaki bağlantı üzerindeki ağırlıklar, belirli bir öğrenme kuralı ile dinamik olarak değiştirilebilen ağlar eğitilebilir.

Yapay sinir ağlarında öğrenme yöntemi danışmanlı (supervised) , danışmansız (unsupervised) ve destekleyici (reinforced) olmak üzere üç gruba ayrılmıştır (Öztemel, Yapay Sinir Ağları, 2016).

4.3.1 Danışmanlı (Supervised) Öğrenme

Danışmanlı öğrenmede veri, giriş-çıkış verisi şeklinde organize edilmelidir. Bu öğrenme sırasında giriş değerine karşılık gelen çıkış değerleri de verilmelidir. Bu giriş ve çıkış verilerine eğitim seti denilmektedir. Sunulan bu eğitim seti probleme uygun olarak seçilmelidir. Aksi takdirde sistem eğitim sonrasında daha önce karşılaşmadığı değerlere karşılık mantıklı çıktılar sunamayabilir.

Sisteme giriş ve çıkış değerlerinin verilmesinin sebebi sistemin hatasını bulmak ve minimum seviyeye indirmektedir. Öğrenme sırasında ağırlıklar giriş-çıkış verilerine göre hesaplanarak güncellenir (Yılmaz, 2017).



Şekil 4-4 Danışmanlı (Supervised) Öğrenme

Bu yöntemin en önemli özelliği kullanılan giriş-çıkış verilerinin gerçek olmasıdır. Dört danışmanlı öğrenme kuralı vardır. Bunlar,


1. Algılayıcı (Perceptron) Öğrenme Kuralı
2. Delta Öğrenme Kuralı
3. Genişletilmiş Delta Öğrenme Kuralı
4. Geri Yayımlı Öğrenme Kuralıdır (Ataseven, 2013) .

Bu öğrenme şeklini kullanan ağlara örnek olarak, bu tez çalışmasında da kullanılacak olan çok katmanlı algılayıcı ağını verebiliriz.

4.3.2 Danışmansız (Unsupervised) Öğrenme

Danışmanlı öğrenme yönteminde sisteme giriş-çıkış verileri verilir iken danışmansız öğrenme yönteminde sisteme sadece giriş verileri verilir. Danışman tarafından girişe karşılık gelen çıkış verilmediği için sistem parametreler arasındaki ilişkiyi kendi kendine öğrenmesi beklenir. Danışmansız öğrenme yöntemi daha çok sınıflandırma problemlerine uygulanmaktadır (Yılmaz, 2017) .

Bu öğrenme yöntemini kullanan ağlara örnek olarak Adaptif Rezonans Teori (ART) Ağlarını verebiliriz.




Şekil 4-5 Danışmansız (Unsupervised) Öğrenme

4.3.3 Destekleyici (Reinforcement) Öğrenme

Bu öğrenme türü hem danışmanlı hem de danışmansız öğrenme yöntemleriyle benzerlik göstermektedir. Sisteme danışmansız öğrenmede olduğu gibi sadece giriş verileri verilir. Aynı zamanda sistemin içinde sistem çıkışının doğru veya yanlış olduğunu gösteren danışman bulunmaktadır. Çıkış verilerinin doğru hesaplanması için danışman tarafından takviye yapılmış olmaktadır. Dolayısıyla sistem içerisindeki danışman öğrenen sisteme yardımcı olmaktadır.

Bu öğrenme mantığını kullanan yöntemlerden birisi LVQ (Linear Vector Quantization) ağlarıdır. LVQ ağları daha çok sınıflandırma problemlerinde uygulanmaktadır (Yılmaz, 2017).



Şekil 4-6 Destekleyici (Reinforced) Öğrenme

4.4 Yapay Sinir Ağları Modelleri

Ağın bir olayı öğrenmesi, o problemin çözümü için en uygun yapay sinir ağı modelini seçmekle mümkündür. Yapay sinir ağlarında proses elemanlarının bağlanmasıyla oluşan topoloji, ağdaki toplama ve aktivasyon fonksiyonları ve ağda kullanılan öğrenme stratejisi ve öğrenme kuralı ağın modelini oluşturan unsurlardır. Dolayısıyla birçok yapay sinir ağı model geliştirilmiştir. Bunlardan en yaygın olanları şunlardır (Öztemel, Yapay Sinir Ağları, 2016) ;

- Tek Katmanlı Algılayıcılar
- Çok Katmanlı Algılayıcılar
- Vektör Kuantizasyon Modelleri (Learning Vector Quantization)
- Adaptif Rezonans Teorisi Modelleri (Adaptive Resonance Theory)
- Kendi Kendini Organize Eden Modeller (Self-Organizing Map)
- Hopfield Ağları
- Counterpropagation Ağı
- Boltzman Makinesi
- Elman Ağı

Yukarıdaki ağlardan farklı olarak birçok ağ modeli bulunmaktadır. Kullanılacak olan model yapılan çalışmanın türüne uygun olacak şekilde seçilir. Bu çalışmada yapay sinir ağlarında en çok kullanılan modellerden biri olan Çok Katmanlı Algılayıcı modelini ele alacağız.

4.4.1 Çok Katmanlı Algılayıcı Modeli

Günlük hayatımızda çoğunlukla doğrusal olmayan problemler ile karşı karşıya kalmaktayız. Bu doğrusal olmayan problemleri çözmek için basit algılayıcı ve ADALINE modelleri yeterli olmamıştır. Bunun üzerine çok katmanlı algılayıcı modeli geliştirilmiştir.

Bu modelin gelişimi yapay sinir ağı tarihi için oldukça büyük öneme sahiptir. Çok katmanlı algılayıcı modeli geliştirilmeden önce XOR problemi daha önce geliştirilen modeller ile çözülemiyordu. XOR probleminin çözülememesinden sonra yapay sinir ağına olan çalışmalar durma noktasına gelmiş

ve sadece birkaç araştırmacı çalışmalara devam etmiştir. XOR probleminin çözilememesinin altındaki neden problemin doğrusal olmayan bir nitelik taşımasından kaynaklanmaktaydı.

Bu problemin çözülmesinde Rumelhart, Hinton, ve McClelland'ın 1986 yılında geliştirdiği çok katmanlı algılayıcı modeli kullanılmış ve problem çözülmüştür. Bunun üzerine yapılan çalışmalar tekrar hız kazanmıştır. Geliştirilen bu modele hata yayma modeli veya geriye yayım modeli de denilmektedir. Çok katmanlı algılayıcı modeli delta öğrenme kuralı denilen bir öğrenme yöntemini kullanmaktadır. Bu kural ADALINE ve basit algılayıcı modellerinin öğrenme kurallarının geliştirilmiş şeklidir. Amacı ağırlık beklenen çıktı değerleri ile üretilen değerler arasındaki hatayı en aza indirmeye çalışmaktadır (Öztemel, Yapay Sinir Ağları, 2016).

4.4.1.1 Çok Katmanlı Algılayıcı Modelinde Öğrenme

Çok katmanlı algılayıcı ağlarının eğitiminde girdiler ve girdilere karşılık gelen çıktılar ağırlık gösterilir. Çok katmanlı algılayıcı ağının öğrenme kuralı en küçük kareler yöntemine dayalı delta öğrenme kuralının genelleştirilmiş halidir. Delta öğrenme kuralı iki bölümden oluşur. İlk bölüm ileriye doğru hesaplama yani ağırlık çıktısını hesaplama safhasıdır. İkinci bölüm ise geriye doğru hesaplama yani ağırlıkları değiştirme safhasıdır.

4.4.1.1.1 İleriye Doğru Hesaplama

Eğitim için ağırlık gösterilen veriler girdi katmanında herhangi bir işleme girmeden ara katmana gönderilir. Girdi katmanındaki değerler (G_k) ve girdi katmanındaki k'nci elemanın çıktısı (ζ_k^i) ile gösterecek olursak;

$$G_k = \zeta_k^i \text{ 'dir.}$$

Ara katmanda her bir proses elemanı gelen bilgileri bağlantı ağırlıklarına (A_{kj}) göre alır. Buna göre ara katmandaki proses elemanlarının NET girdileri (NET_j^a) hesaplanır. Bu hesaplama aşağıda gösterilmiştir.

$$NET_j^a = \sum_{k=1}^n A_{kj} \zeta_k^i$$

Ara katmanın net girdileri hesaplandıktan sonra çıktıları hesaplanmalıdır. Hesaplanan net girdi aktivasyon fonksiyonundan geçirilerek ilgili ara katman elemanının çıktısı hesaplanır. Birçok

aktivasyon fonksiyonu bulunmaktadır. Bu çalışmada sigmoid fonksiyonu kullanıldığı için sigmoid fonksiyonunun formülü aşağıda gösterilmiştir. j'nci ara katmanın çıktısı aşağıdaki gibi olacaktır.

$$\zeta_j^a = \frac{1}{1 + e^{-(NET_j^a + B_j^a)}}$$

Burada B_j değeri, ara katmanda bulunan j'nci elemana bağlanan eşik değer elemanının ağırlığını göstermektedir.

Ara katmandaki bütün proses elemanlarının çıktı değerleri bulununca ($\zeta_1, \zeta_2, \zeta_3, \zeta_4 \dots$) ağırlık ileri hesaplama işlemi tamamlanmış olur.

4.4.1.1.2 Geriye Doğru Hesaplama

Ağa sunulan girdiler sonucu elde edilen çıktılar beklenen çıktı değerleri ile karşılaştırılır. Burada amaç aralarındaki farkı en aza indirmektir. Geriye hesaplamada, oluşan hata ağırlıklarının değerlerine dağıtılarak bir sonraki iterasyonda daha az hata ile karşılaşmak hedeflenmektedir. Çıktı katmanındaki k.'nci proses elemanı için hata değeri;

$$E_k = B_k - \zeta_k$$

$$E_k = \text{k.'nci proseste oluşan hata sayısı}$$

$$B_k = \text{k.'nci proseste beklenen çıktı değeri}$$


$$\zeta_k = \text{k.'nci proseste üretilen çıktı değeri}$$

Bu işlem sonucunda bazı hata değerleri negatif değer olacaktır. Bu durum toplam hata hesaplanırken toplamın sıfır olmasına ve ağırlık yanılmaya neden olabilir. Bunun önüne geçmek için ağırlıkların kareleri alınır ve sonucun karekökü alınır.

Toplam hata değerinin en aza indirilmesi ağırlık amaçlarından biridir. Bunun için oluşan hatanın proses elemanlarına dağıtılması gerekmektedir. Bu durum proses elemanlarının ağırlıklarının değiştirilmesi anlamına gelmektedir.

4.4.1.2 ÇKA Ağlarının Çalışma Prensibi

Aşağıda çok katmanlı algılayıcı ağının çalışma prensibi şema ile gösterilmiştir. Bu işlemler sonucunda toplam hata sayısı istenilen veya hedeflenen miktara ininceye kadar devam eder. Ağın öğrenmesi için bir durdurma kriteri belirlenmelidir. Çünkü ağ probleme çözüm üretecek ağırlıkları bulduktan sonra eğitime devam edilirse bulunan ağırlıklarda değişimlere neden olabilir. Bunu sonucunda en iyi çözümü üreten yani performansı oldukça iyi olan bir ağ düşük performanslı bir ağa dönüşebilir.



Şekil 4-7 ÇKA Ağlarının Çalışma Aşamaları

En önemli aşamalardan biri örneklerin toplanması aşamasıdır. Her şeyden önce çözümlenmesi istenen problem ile ilgili veriye sahip olunması gereklidir. Verilerin doğruluğu ve problem ile ilgili olması inşa edilecek olan yapay sinir ağının kalitesini belirleyecektir.

Veriler toplandıktan ve düzenlendikten sonra veriler normalizasyon işlemine sokulur. Ağın topolojik yapısının belirlenmesinden sonra ağdaki parametreler probleme uygun olacak şekilde seçilir. Ağın eğitimi esnasında kullanılan veriler ile aynı zamanda test işlemi yapılmaz. Genellikle veriler üçe bölünerek eğitim için, test için ve validasyon işlemi için kullanılır (Marsland, 2009).

5. UYGULAMA

Bu bölümde, Türkiye elektrik tüketim tahmini için yapay sinir ağı modeli kurulmuştur. Bu yöntemin tahmin gücünü görmek amacıyla 1980-2017 yılları arasındaki veriler ağı eğitilmesi amacıyla kullanılmış olup 2018 yılının verileri ağı hiçbir adımda gösterilmemiştir. Oluşturulan ağı 2018 yılı elektrik tüketim miktarını tahmin edebilmesi için 2018 yılına ait değişken verilerinin tahmin edilmesi gerekmektedir. Bunun için Holt tahmin yöntemi kullanılmıştır. Elde edilen verilere baktığımızda ağı öğretilen çıktı değerlerinin sürekli artış gösterdiği tespit edilmiştir. Bu ağıda eksik öğrenme problemine yol açacaktır. Yani ağı olabilecek en büyük değer olarak 2017 yılındaki çıktıyı öğrenecektir. Bu soruna çözüm olarak değerlerin bir önceki yıla göre büyümeleri hesaplanmıştır. Böylelikle ağı öğrenmesi kolaylaştırılmış ve doğru çıktılar üretmesine olanak sağlanmıştır. Büyüme miktarlarından oluşan veri setinin 0,1-0,9 aralığında dağılması için d_{min_max} normalizasyon formülü kullanılarak veriler normalize edilmiştir. Normalize olmuş veriler ve MATLAB R2018a programı ile yapay sinir ağı oluşturulmuş ve eğitilmiştir. Daha önceden Holt metodu yardımıyla elde ettiğimiz 2018 yılına ait değişkenler ile oluşturulan ağıda tahmin simülasyonu yapılarak elektrik tüketim tahmini yapılmıştır. Elde edilen çıktı değeri ile gerçek değer karşılaştırılarak bu alanda yapay sinir ağı tahmin metodunun tahmin gücü test edilmiştir. Yapay sinir ağları ile Türkiye 2018 yılı elektrik tüketim tahmini aşamaları aşağıdaki gibi uygulamış ve detaylı şekilde açıklanmıştır.

5.1 Veri setinin tanıtılması

Uygulamada elektrik tüketimini etkileyen faktörler yapay sinir ağıımızın değişkenlerini oluşturmaktadır. Bu değişkenler; nüfus, elektrik üretimi, trafo sayısı, gayrisafi yurtiçi hasıla ve elektrik enerjisine olan yatırım olarak belirlenmiştir. Değişkenler belirlenirken bu alanda yapılan çalışmalar ve uzman görüşlerinden yararlanılmıştır.

Veriler, data.worldbank.org, Türkiye Cumhuriyeti Cumhurbaşkanlığı strateji ve bütçe başkanlığı resmi sitesinden ve TEDAŞ resmi sitesinden alınan veriler ile oluşturulmuştur. Çalışmada Türkiye 1980-2018 yılları arasındaki döneme ait verilerinin analizi yapılmıştır. Değişkenlere ait grafikler incelenmiş ve yorumları yapılmıştır.

5.2 Veri Setinin Hazırlanması

Toplanan veriler 1980-2018 yılları arasındaki verilerden oluşmaktadır. Bu çalışmada ağı 2018 yılının verileri ağı gösterilmeyip tahmin edilmeye çalışılacaktır. Çıkan sonuç gerçek değerler ile karşılaştırılıp uygulanan modelin ne derece güçlü olduğu incelenecektir. Dolayısıyla veri setimizden 2018 yılına ait veriler çıkartılmıştır.

Yapay sinir ağının eğitilmesi ve eğitimden sonra ve eğitiminden sonra sunulacak değişken değerlerine karşılık gelecek çıktı değerlerinin elde edilebilmesi için tahminini yapacağımız çıktının o döneme ait değişken değerlerini bilmemiz gerekmektedir. Bu çalışmada senaryo olarak 1980-2017 yılları arasındaki değerleri bilirken 2018 yılına ait değişken değerlerini bilmiyoruz. 2018 yılına ait elektrik tüketim tahminini yapabilmemiz için bu değişken değerlerine ihtiyaç duymaktayız. Bu değerlerin tahmini için çalışmada Holt tahmin yöntemi kullanılmıştır.

Holt yöntemi bir üstel düzeltme yöntemidir. Bu yöntem zaman serilerinin, doğrusal trend ile izlenmesi için tasarlanmış bir yöntemdir. Yöntemde α (seri için) ve β (trend için) olmak üzere iki düzeltme katsayısının belirlenmesi gerekmektedir. S_t (seri) her dönemin sonunda verilerin değerlerinin düzeltilmiş bir tahminidir. b_t (trend) ise her dönemin sonunda ortalama büyümenin düzeltilmiş bir tahminidir. (Kalekar, 2004)

$$S_t = \alpha * y_t + (1 - \alpha) * (S_{t-1} + B_{t-1}) \quad 0 < \alpha < 1$$

$$B_t = \beta * (S_t - S_{t-1}) + (1 - \beta) * B_{t-1} \quad 0 < \beta < 1$$

Üstel düzeltme yönteminde geçmiş dönem verileri arasında yakın tarihli olan verilere üstel olarak daha yüksek ağırlıklar verilirken, daha eski verilere üstel olarak daha düşük ağırlıklar verilmektedir. Bu katsayıların belirlenmesi tahmin değeri için oldukça büyük öneme sahiptir. Bundan dolayı yöntem uygulanırken düzeltme katsayısı olarak en uygun değer seçilmelidir (Yağımlı & Ergin, Türkiye’de İş Kazalarının Üstel Düzeltme Metodu ile Tahmin, 2017).

İlk olarak değişkenlere ait elimizdeki veriler aşağıdaki tabloda gösterilmiştir.

Yıl	Nüfus	Üretim	Trafo adet	GSYİH	Enerji Yatırım (milyon tl)	Tüketim
1980	43.905.790	23.275.400	594	5.231	1,26	20.398.200
1981	44.936.836	24.672.800	610	7.901	3,92	22.030.000
1982	45.997.940	26.551.500	629	10.492	6,01	23.586.800
1983	47.072.603	27.346.800	651	13.906	12,96	24.465.109
1984	48.138.191	30.613.500	682	21.997	17,16	27.635.160
1985	49.178.079	34.218.900	693	35.095	32,33	29.708.627
1986	50.186.914	39.694.800	647	51.079	66,33	32.209.674
1987	51.168.270	44.352.900	667	74.722	48,88	36.697.362
1988	52.125.597	48.048.800	686	129.225	34,72	39.721.500
1989	53.065.801	52.043.200	711	227.324	99,41	43.120.000
1990	53.994.605	57.543.000	743	393.060	156,16	46.820.000
1991	54.911.233	60.246.300	783	630.117	165,33	49.282.900
1992	55.815.175	67.342.200	834	1.093.368	237,32	53.984.700
1993	56.713.073	73.807.500	840	1.981.867	393,97	59.237.000
1994	57.613.441	78.321.700	864	3.868.429	331,02	61.400.917
1995	58.522.320	86.247.400	889	7.649.029	1.222,20	67.393.851
1996	59.442.502	94.861.700	914	14.772.110	1.084,63	74.156.638
1997	60.372.413	103.295.800	962	28.835.883	1.649,87	81.884.912
1998	61.308.204	111.022.400	1.006	52.224.945	4.389,73	87.704.617
1999	62.243.779	116.439.900	1.038	77.415.272	3.894,60	91.201.877
2000	63.174.483	124.921.604	1.065	124.583.458	11.363,81	98.295.712
2001	64.100.297	122.724.700	1.090	178.412.439	12.440,00	97.070.041
2002	65.022.300	129.399.500	1.055	277.574.057	14.033,00	102.947.862
2003	65.938.265	140.580.500	1.072	359.762.926	14.316,00	111.766.067

2004	66.845.635	150.698.300	1.089	430.511.477	23.872,00	121.141.852
2005	67.743.052	161.956.200	1.088	648.931.712	16.762,00	130.262.759
2006	68.626.337	176.299.800	1.130	758.390.785	20.373,00	143.070.499
2007	70.586.256	191.558.100	1.173	843.178.421	19.046,00	155.135.260
2008	71.517.100	198.418.000	1.241	950.534.250	18.300,00	161.947.528
2009	72.561.312	194.812.900	1.272	952.634.797	19.897,00	156.894.070
2010	73.722.988	211.207.700	1.317	1.160.013.978	20.537,00	172.050.628
2011	74.724.269	229.395.100	1.357	1.394.477.166	39.748,00	186.099.551
2012	75.627.384	239.496.800	1.425	1.569.672.115	84.690,00	194.923.349
2013	76.667.864	240.154.000	1.505	1.809.713.087	35.286,00	198.045.181
2014	77.695.904	251.962.800	1.550	2.044.465.876	58.528,00	207.375.078
2015	78.741.053	261.783.300	1.595	2.338.647.494	71.543,00	217.312.250
2016	79.814.871	274.407.700	1.675	2.608.525.749	128.868,00	231.203.746
2017	80.810.525	297.277.500	1.750	3.106.536.751	229.379,00	249.022.646

Tablo 5-1 Çalışmada Kullanılacak Değişkenlere Ait Veriler

Holt metodu ile yukarıdaki veriler yardımıyla 2017 yılına ait değişken değerleri bulunmaya çalışılmış ve bu metot bütün değişkenler için ayrı ayrı uygulanmıştır.

Örnek olarak aşağıda 2018 yılındaki nüfus miktarı Holt yöntemi ile tahmin edilmeye çalışılmıştır.

Burada diğer üstel düzeltme tekniklerinde olduğu gibi düzeltilmiş istatistiğin başlangıç değeri olarak, gözlenmiş olan birinci dönemin değeri alınır. Yani, S_1 değeri ilk satırdaki gerçek nüfus değerine eşittir. Ayrıca ilk dönemdeki B_t değeri de aşağıdaki formül kullanılarak bulunur (Armutlulu, İşletmelerde Uygulamalı İstatistik, 2008).

$$B_t = \frac{Y_2 - Y_1}{2} + \frac{Y_4 - Y_3}{2}$$

Holt yönteminde α ve β değerlerinin belirlenmesi Holt yöntemi sonucunda tahmin edilecek değişken değerlerinin doğruluğunda büyük bir öneme sahiptir. Bu değerleri belirlerken MSE (Mean Squared Error) yani Ortalama Hata Karesinin minimum değere sahip olması hedeflenmiştir. Bunun için aşağıdaki formül kullanılmıştır.

$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2$$

MSE değerini en küçük şekilde bizlere sunan α ve β değerleri EXCEL programı ÇÖZÜCÜ eklentisiyle bulunmuştur. Çözücü eklentisinde hedef değer yani MSE değeri en küçük olması istenerek α ve β değerlerinin 0 ile 1 değerleri arasında olması kısıtlama olarak eklenmiştir.

41		
42	α	0,944034251
43	β	0,099334614
44	MSE	32279765983
45	n	37
46	GERÇEK DEĞER	82.003.882
47	TAHMİN DEĞERİ	81834423,4
48	FARK	169.459
49		
50		
51		
52		
53		
54		
55		
56		
57		
58		
59		
60		
61		
62		
63		
64		
65		
66		
67		

Çözücü Parametreleri

Hedef Ayarla:

Hedef: ☐ En Büyük ☒ En Küçük ☐ Değeri:

Değişken Hücreleri Değiştirerek:

Kısıtlamalara Bağlıdır:

☒ Kısıtlanmamış Değişkenleri Pozitif Yap

Çözme Yöntemi Seçin:

Çözüm Yöntemi

Düzgün doğrusal olmayan Çözücü Problemleri için GRG Doğrusal Olmayan altyapısını seçin. Doğrusal Çözücü Problemleri için Basit LP altyapısını seçin ve düzgün olmayan Çözücü problemleri için Açılım altyapısını seçin.

Şekil 5-1 α ve β değerleri EXCEL programı Çözücü Eklentisiyle Bulunması

Bunun sonucunda nüfus değişkeni için uygulanan holt yönteminde α değeri 0,944304251 ve β değeri 0,099334614 olarak belirlenmiştir. Bu değerler bütün değişkenler için ayrı ayrı olarak bulunmuştur. Böylelikle 2018 yılındaki değişken değerlerinden nüfus değişkeninin Holt metodu sonucu tahmin değeri 81834423 olarak bulunmuştur. Sonuç olarak gerçek değer ile tahmin edilen değer arasındaki fark 169459'dur.

YIL	NÜFUS	St	Bt	TAHMİN	Et	MSE
1980	43905790	43905790	0	43905790	0	0
1981	44936836	44888513,02	650340,4893	43905790	1.031.046	1,06306E+12
1982	45997940	45976423,57	939912,9537	45538853,51	459.086	2,1076E+11
1983	47072603	47065279,12	1038479,278	46916336,53	156.266	24419210633
1984	48138191	48136577,22	1060197,919	48103758,39	34.433	1185604334
1985	49178079	49178955,25	1048405,183	49196775,13	-18.696	349545444,5
1986	50186914	50188809,64	1022893,273	50227360,43	-40.446	1635913849
1987	51168270	51170305,61	995497,6168	51211702,91	-43.433	1886417968
1988	52125597	52127481,38	970137,2184	52165803,23	-40.206	1616540688
1989	53065801	53067292,22	950068,0131	53097618,6	-31.818	1012359702
1990	53994605	53995671,49	935714,9654	54017360,24	-22.755	517800844,4
1991	54911233	54912177,55	923003,0123	54931386,46	-20.153	406161787
1992	55815175	55816112,62	910384,344	55835180,56	-20.006	400222541,1
1993	56713073	56713702,15	901917,0722	56726496,96	-13.424	180202783
1994	57613441	57613543,09	900543,1392	57615619,23	-2.178	4744665,872
1995	58522320	58521934,1	905736,6565	58514086,23	8.234	67795000,25
1996	59442502	59441806,89	915091,5815	59427670,76	14.831	219965775,4
1997	60372413	60371685,87	924877,4938	60356898,47	15.515	240700578,4
1998	61308204	61307658,43	932219,9202	61296563,36	11.641	135504495,6

1999	62243779	62243596,18	934680,2878	62239878,35	3.901	15215088,62
2000	63174483	63174660,79	932287,5248	63178276,47	-3.793	14390432,28
2001	64100297	64100608,73	928092,1536	64106948,32	-6.651	44240017,6
2002	65022300	65022600	924054,7431	65028700,89	-6.401	40971353,88
2003	65938265	65938658,21	918762,8481	65946654,74	-8.390	70387725,79
2004	66845635	66846187,39	911328,6982	66857421,06	-11.786	138911155,7
2005	67743052	67743729,9	902205,3605	67757516,09	-14.464	209209788
2006	68626337	68627255,53	889843,6003	68645935,26	-19.598	384091874,9
2007	70586256	70536146,85	1564222,825	69517099,13	1.069.157	1,1431E+12
2008	71517100	71544436,63	1196320,827	72100369,67	-583.270	3,40204E+11
2009	72561312	72569722,23	1083134,171	72740757,46	-179.445	32200673531
2010	73722988	73719701,08	1127370,234	73652856,41	70.132	4918440478
2011	74724269	74730024,49	1049911,696	74847071,31	-122.802	15080407817
2012	75627384	75634533,8	953688,1886	75779936,18	-152.552	23272168887
2013	76667864	76664131,35	1003923,021	76588221,99	79.642	6342849506
2014	77695904	77694598,75	1021489,4	77668054,37	27.850	775602124
2015	78741053	78739882,95	1037236,181	78716088,15	24.965	623243966,3
2016	79814871	79813101,65	1061048,474	79777119,13	37.752	1425203675
2017	80810525	80813506,98	1020916,42	80874150,12	-63.625	4048156209
2018	82003882			81834423,4		TOPLAM= 2,881E+12

Tablo 5-2 Holt Yöntemi ile 2018 Yılı Nüfus Değişkeninin Tahmini

α	0,953132084
β	0,661773943
MSE	77864838743
n	38
GERÇEK DEĞER	82003882
TAHMİN DEĞERİ	81834423,4
FARK	169458,6027

Tablo 5-3 Holt Yöntemi ile 2018 Yılı Nüfus Değişkeninin Tahmininde Kullanılan Alfa ve Beta Değerleri

Bütün değişkenler nüfus örneğinde olduğu gibi işlemlerden geçerek 2018 yılına ait değişken değerleri tahmin edilmiştir. Aşağıdaki tabloda 2018 yılına ait değişkenlerin gerçek ve tahmin değerleri gösterilmiştir.

	GERÇEK DEĞER	TAHMİN DEĞERİ
NÜFUS	82.003.882	81.834.423
ÜRETİM	304.801.884	302.166.491
TRAFO SAYISI	1.826	1.817
GSYİH	3.700.989	3.497.429
YATIRIM	285.608	296.489

Tablo 5-4 Holt Yöntemi ile 2018 Yılı Değişkenlerin Tahmin Değerleri

Yapay sinir ağını eğitmeden önce verilerimizi incelememiz gerekmektedir. Yapay sinir ağına öğretmediğiniz bir bilgi ile verimli çıktılar elde etmeniz mümkün değildir. Örneğin; Ağı eğitmek için 1900-2000 seneleri arasında gerçekleşen çıktı verilerini girdiniz ve bu seneler arasında gerçekleşen maksimum çıktı değeri 300 olsun. Bu durumda yapay sinir ağının tahmin edebileceği maksimum değer 300 olacaktır. 2001 senesinde çıktı değeri 400 ise bunu tahmin etmesi oldukça zordur. Çünkü ağı eğitim esnasında maksimum değer olarak 300 değeri gösterilmiştir. Eğer çıktı değerleri sürekli artış trendi gösteren bir grafik çiziyorsa bunun için çözüm olarak seneler arasındaki büyüme miktarı hesaplanarak işleme devam edilebilir.

Bu çalışmada elektrik tüketim verileri sürekli artış trendi göstermektedir. Bu aşamada verilerin bir önceki döneme göre büyümesi hesaplanarak oluşturulan sinir ağının doğru şekilde öğrenmesi ve istenilen sonuçlar vermesi amaçlanmaktadır. Büyüme formülü olarak aşağıdaki formül kullanılmıştır.

$$\text{Büyüme miktarı} = \frac{(\text{Şimdiki Dönem Değeri} - \text{Bir Önceki Dönem Değeri})}{(\text{Bir önceki Dönem Değeri})}$$

Kullanılan formül sonucunda oluşan değerler Tablo.1 de görülmektedir.

Nüfus	Üretim	trafo adet	GSYİH	Yatırım	Tüketim
23,483	60,038	26,936	510,419	2.104,187	79,997
23,613	76,145	31,148	327,933	536,182	70,667
23,363	29,953	34,976	325,391	1.154,800	37,237
22,637	119,455	47,619	581,835	324,013	129,574
21,602	117,772	16,129	595,445	884,100	75,030
20,514	160,026	-66,378	455,449	1.051,766	84,186
19,554	117,348	30,912	462,871	-263,030	139,327
18,709	83,329	28,486	729,410	-289,773	82,408
18,037	83,132	36,443	759,133	1.863,277	85,558
17,503	105,678	45,007	729,074	570,925	85,807
16,976	46,979	53,836	603,106	58,715	52,604
16,462	117,782	65,134	735,183	435,448	95,404
16,087	96,007	7,194	812,626	660,064	97,292
15,876	61,162	28,571	951,912	-159,783	36,530

15,775	101,194	28,935	977,296	2.692,175	97,603
15,724	99,879	28,121	931,240	-112,552	100,347
15,644	88,909	52,516	952,049	521,131	104,216
15,500	74,801	45,738	811,110	1.660,649	71,072
15,260	48,796	31,809	482,343	-112,791	39,875
14,953	72,842	26,012	609,288	1.917,837	77,782
14,655	-17,586	23,474	432,072	94,703	-12,469
14,384	54,388	-32,110	555,800	128,055	60,552
14,087	86,407	16,114	296,097	20,167	85,657
13,761	71,972	15,858	196,653	667,505	83,888
13,425	74,705	-0,918	507,351	-297,838	75,291
13,039	88,565	38,603	168,676	215,428	98,322
28,559	86,547	38,053	111,799	-65,135	84,327
13,187	35,811	57,971	127,323	-39,168	43,912
14,601	-18,169	24,980	2,210	87,268	-31,204
16,010	84,157	35,377	217,690	32,166	96,604
13,582	86,111	30,372	202,121	935,434	81,656
12,086	44,036	50,111	125,635	1.130,673	47,414
13,758	2,744	56,140	152,924	-583,351	16,016
13,409	49,172	29,900	129,718	658,675	47,110
13,452	38,976	29,032	143,892	222,372	47,919
13,637	48,225	50,157	115,399	801,266	63,924
12,475	83,342	44,776	190,917	779,953	77,070
14,767	25,311	43,429	191,355	245,136	?

Tablo 5-5 Büyüme Oranları

Yapay sinir ağlarında, ağıın girdi ve çıktı değerlerine uygulanan bazı adımlar ağıın eğitimini daha verimli hale getirebilir. Ağdaki girdi işlem fonksiyonları, ağ kullanımının daha iyi bir forma gelmesinde yardımcı olur. Normalizasyon yöntemi ile ham girdi verileri, ağıın eğitime uygun olacak şekilde hazırlanır. Bu yöntemin uygulanmaması ağıın yavaş öğrenmesine neden olmaktadır. Birçok normalizasyon yöntemi kullanılmaktadır. Bunlardan bazıları; Z-Score yöntemi, Min-Max normalizasyonu, Medyan normalizasyonu, Sigmoid normalizasyonu ve D_Min_Max normalizasyonu (Jayalakshmi & Santhakumaran, 2011).

Bu çalışmada normalizasyon yöntemi olarak D_Min_Max normalizasyon yöntemi kullanılmıştır. Bu yöntem ile tüm veriler 0,1 ile 0,9 arasında normalize edilmiştir. D_Min_Max normalizasyon formülü aşağıda verilmiştir.

$$X' = 0,8 * \frac{(X_i - X_{\min})}{(X_{\max} - X_{\min})} + 0,1$$

Bu eşitlikte;

X' = Normalize edilmiş veriyi,

X_i = Girdi değerini,

$X_{\min}$ = Girdi setindeki en küçük değeri,

$X_{\max}$ = Girdi setindeki en büyük değeri,

ifade etmektedir. (Yavuz & Deveci, 2012)

Büyüme miktarları bulunan değerler D_Min_Max normalizasyon tekniğı ile normalize edilmiştir. Normalize edilmiş veriler Tablo.2 de görölmektedir.

Normalizasyon işleminden sonra elde edilen veri seti, oluşturulacak sinir ağıının eğitiminde kullanılmak üzere hazır hale getirilmiştir.

Nüfus	Üretim	Trafo Adet	GSYİH	Yatırım	Tüketim
					0,246385949
0,653485516	0,451107201	0,667637785	0,516955018	0,756392337	0,621670025
0,659803088	0,523418816	0,693256793	0,367236558	0,373429706	0,577901098
0,647664764	0,316043671	0,716546573	0,365150671	0,524518237	0,421074065
0,612399548	0,717857606	0,793454408	0,575548015	0,321610622	0,854246764
0,562137645	0,710301876	0,601897892	0,586713925	0,458403698	0,598367741
0,509289765	0,9	0,1	0,471856096	0,499353665	0,641319768
0,462674027	0,708399656	0,691823375	0,477945195	0,17823385	0,9
0,421655747	0,555674782	0,67706493	0,696624642	0,171702139	0,632977014
0,389015935	0,554789285	0,725470438	0,721010548	0,697553589	0,647757593
0,363063335	0,656006333	0,777565291	0,696348624	0,381915137	0,648925006
0,337490595	0,392479883	0,831271461	0,59299978	0,256815269	0,49316053
0,312509057	0,710346481	0,9	0,70136036	0,34882686	0,693947685
0,294303103	0,612589015	0,547546798	0,764897925	0,40368612	0,702805128
0,284049366	0,456154125	0,677586076	0,879173576	0,203450488	0,41775508
0,279174686	0,63587819	0,67979884	0,9	0,9	0,704263858
0,276656169	0,629973531	0,674849029	0,862213756	0,214985759	0,717136123
0,272784023	0,58072622	0,8232455	0,879286414	0,369753683	0,735283129
0,265811985	0,517385589	0,782012109	0,763654018	0,648064577	0,579798648
0,254151165	0,400640291	0,697281389	0,493920465	0,214927404	0,433450078
0,23921161	0,508591555	0,662014176	0,598071307	0,710878972	0,611276283
0,224754778	0,102617167	0,646579058	0,452675968	0,265604895	0,187890188
0,211588415	0,42574513	0,308455085	0,554187635	0,27375056	0,530449948
0,197173872	0,569490841	0,601804893	0,341116945	0,247400497	0,648221089
0,18134054	0,504684241	0,60025045	0,259529214	0,40550348	0,63992037

0,16503843	0,516955374	0,49819764	0,514437819	0,169732319	0,599592599
0,146270599	0,579178488	0,738608644	0,236575376	0,295090174	0,70763691
0,9	0,570122218	0,735263896	0,189911686	0,226566722	0,641983582
0,153485772	0,342342785	0,856426327	0,202647699	0,232908762	0,452385493
0,222132311	0,1	0,65573822	0,1	0,263788949	0,1
0,290543866	0,559388726	0,718987143	0,276788704	0,250331056	0,699574688
0,172636236	0,568164735	0,688539461	0,264015173	0,470941196	0,629450376
0,1	0,379269484	0,808610361	0,201262857	0,518625654	0,468816934
0,181198616	0,193889622	0,84529024	0,223652193	0,1	0,321518946
0,164251378	0,402325289	0,685669914	0,20461302	0,403346865	0,467388671
0,166329027	0,356551613	0,680389343	0,216241482	0,296786255	0,471183356
0,175339638	0,398073035	0,808891411	0,192865177	0,438172788	0,546267579
0,118870573	0,555733261	0,776160627	0,254822672	0,432967337	0,607938206
0,230216877	0,295202969	0,767963375	0,255182679	0,30234593	?

Tablo 5-6 Normalizasyon İşlemi Sonrası Veriler


5.3 Yapay Sinir Ağı Mimarisi

Veri setinin hazırlanmasından sonraki aşama yapay sinir ağının mimarisini oluşturma aşamasıdır. Bu aşamada ağın oluşturulması için MATLAB R2018a programından yararlanılmıştır.

Öncelikle girdi, çıktı ve test girdi verilerinin seçilmesi ve programa aktarılması gerekmektedir. Ağın kurulumu için “nntool” aracı kullanılmaktadır. Burada verilerin çalışabilmesi için satırlar halinde değil sütunlarda olması gerekmektedir. Dolayısıyla Excel programından aktarılan veriler transpoze edilmiştir.

Çalışmada, girdi veri seti “input”, girdi değerine karşılık gelen çıktı veri seti “target” ve 2018 yılına ait girdi veri seti “testinput” olarak belirlenmiştir.

“nntool” komutunu çalıştırdığımızda aşağıdaki pencere ile karşılaşılacaktır. Burada girdi ve test girdi verilerimizi “Input Data” kısmına, çıktı değerlerimizi ise “Target Data” kısmına aktarmamız gerekmektedir.



Şekil 5-2 "nntool" komut penceresi

“New” sekmesi ile yeni ağ oluşturabiliriz.

Talep tahmin çalışmalarında en çok kullanılan model çok katmanlı algılayıcı (Multi-layer perceptron)’dır. Modele “Hata yayma modeli” de denilmektedir. Delta öğrenme kuralı isminde bir öğrenme metodu kullanılır.


Bu çalışmada model olarak çok katmanlı algılayıcı modeli kullanılmıştır. Eğitim fonksiyonu olarak “Gradient descent with momentum and adaptive learning rate backpropagation” fonksiyonu kullanılmıştır. MATLAB programında “TRAINGDX” komutu ile çalışmaktadır. Bu fonksiyon gradyan iniş momentumuna ve uyarlanabilir bir öğrenme hızına göre ağırlık ve bias değerini güncelleyen bir ağ eğitim işlevidir (MathWorks , 2019) . Ağın performansını ölçmek için MSE (Mean Squared Error) yani

ortalama hata kareleri toplamı fonksiyonu kullanılmıştır. Birçok transfer fonksiyonu bulunmaktadır. Bunlardan bazıları aşağıda gösterilmiştir.

- Logsig (Log-Sigmoid Transfer Function)
- Tansig (Hyperbolic Tangent Sigmoid Transfer Function)
- Purelin (Linear Transfer Function)
- ...


Bu çalışmada transfer fonksiyonu olarak Logsig (Log-Sigmoid Transfer Function) fonksiyonu kullanılmıştır. Logsig transfer fonksiyonu talep tahmininde en fazla kullanılan fonksiyondur.

Nöron sayısının belirlenmesinde herhangi bir kural yoktur. Çalışmadan çalışmaya nöron sayılarında farklılıklar görülebilir. Nöron sayısı deneme yanılma yoluyla bulunabilir. Çalışmada 5 ile 19 arasındaki tek sayılar ile nöron sayıları belirlenerek deneme yapılmış ve modele en uygun nöron sayısının 13 olduğu görülmüştür. Katman sayısı ise 2 olarak belirlenmiştir.



Şekil 5-3 Yeni Ağ Oluşturma Penceresi (MATLAB)


“Create” sekmesi ile “electricityconsumption” isimli ağ oluşturulmuştur. Oluşturulan ağın şekli aşağıdaki gibidir. 5 girdi değişkeni, 13 nöron sayısı ve 1 çıktı değeri ağın mimarisinde görülmektedir.



Şekil 5-4 Oluşturulan YSA Mimarisi

5.4 Yapay Sinir Ağının Eğitilmesi ve Testi

Ağın eğitim felsefesi, ağın girdi verilerine karşılık beklenen çıktıyı üretmek için kullanılan ağırlık değerlerini bulmaktır. Çok katmanlı algılayıcı modelinin eğitiminde algoritmanın bir çok kez Şekil 5.1 'de W^* değeri hatanın en az olduğu ağırlık değerini ifade etmektedir.




Şekil 5-5 Hata-Ağırlık İlişkisi

Problem için hatanın en az olduğu nokta W^* değeridir. Her iterasyon işleminden sonra ΔW kadar değişim yapılarak ΔE kadar hatanın düşmesi beklenmektedir. Bu değeri bulmak oldukça kolay olmayabilir. Dolayısıyla kullanıcılar tarafından bir ϵ hata değeri belirlenir. Buna tolerans değeri de denilmektedir. Tolerans değeri altındaki herhangi bir noktada olay öğrenilmiş kabul edilir.

View		Train		Simulate		Adapt		Reinitialize Weights		View/Edit Weights	
Training Info											
Training Parameters											
showWindow	true	lr	0.01								
showCommandLine	false	lr_inc	1.05								
show	25	lr_dec	0.7								
epochs	1000	max_perf_inc	1.04								
time	Inf	mc	0.9								
goal	0										
min_grad	1e-05										
max_fail	1000										
Train Network											


Şekil 5-6 Oluşturulan Ağın Eğitim Parametreleri (MATLAB)

Oluşturulan yapay sinir ağı modelinin eğitiminde durma kriteri olarak “1000” iterasyon, “0” hata, “1e-05” gradient değeri ve “1000” doğrulama hata sayısı kullanılmıştır. Eğitim 1 saniye sürede tamamlanmıştır ve 899 iterasyon sonunda durmuştur. Dividerand fonksiyonu ile veriler randomize şekilde %70 eğitim, %15 doğrulama ve %15 test verisi olarak ayrılmıştır. Oluşturulan modelin eğitimi için öğrenim oranı 0,01 , momentum değeri olarak 0,9 alınmıştır. Şekil 5’de kullanılan MATLAB yapay sinir ağı ara yüzü görülmektedir.



Şekil 5-7 Oluşturulan Ağın Mimarisi, Algoritması ve Öğrenme Aşaması (MATLAB)


Yapay sinir ağı yöntemi ile Türkiye elektrik tüketim tahmini için uygulanan eğitime ait performans Şekil.5 de ki gibidir. YSA modelinin iterasyona bağlı hata değişim grafiği incelendiğinde en iyi eğitim performansı olan 0,0030843 hata değerine 101 iterasyon sonunda ulaşmıştır.



Şekil 5-8 Uygulanan Eğitime Ait Performans

Ağın eğitimi esnasında oluşan çıktılarına göre hedeflerin doğrusal regresyonunu çizen kısım “plotregression” kısmıdır. (MathWorks , 2019) Bu kısım “nntraintool” penceresinde Regression sekmesinde bulunur.

Yapılan çalışmada ağın eğitimi sonucu oluşan regresyon grafiği aşağıdaki gibidir.



Şekil 5-9 Ağın Eğitimi Sonucu Oluşan Regresyon Grafiği

5.5 Yapay Sinir Ağının Tahmini

Çalışmada bu aşamaya kadar veriler hazırlanmıştır. Hazırlanan veriler yardımı ile yapay sinir ağı oluşturulmuştur. Bu aşamada 2018 yılına ait Holt yöntemiyle tahmin ettiğimiz değişken değerlerini ağa sunduktan sonra 2018 yılına ait elektrik tüketim miktarının büyüme miktarının normalize olmuş değeri bulunacaktır. Bu değer ile ters işlem yaparak 2018 yılındaki elektrik tüketim tahmin miktarı elde edilebilmektedir.

2018 yılı deęiřkenlerinin veri seti “testinput” olarak belirlenmiřti. Oluřturulan sinir aęında iřleme sokmak iin “simulate” sekmesi altındaki “simulation data” kısmına veri seti girilmiřtir. ıkan sonu “simulation results” kısmında oluřturduęumuz “tahmin” kısmında oluřacaktır.

The image shows the 'Simulate' tab of a MATLAB Simulink model. The interface is divided into two main sections: 'Simulation Data' and 'Simulation Results'. In the 'Simulation Data' section, the 'Inputs' dropdown is set to 'testinput', 'Init Input Delay States' and 'Init Layer Delay States' are both set to '(zeros)', 'Supply Targets' is unchecked, and 'Targets' is set to '(zeros)'. In the 'Simulation Results' section, the 'Outputs' dropdown is set to 'tahmin', 'Final Input Delay States' is set to 'network1_inputStates', 'Final Layer Delay States' is set to 'network1_layerStates', and 'Errors' is set to 'network1_errors'. A 'Simulate Network' button is located at the bottom right of the interface.

řekil 5-10 2018 Yılına ait Tahminin Simlasyon Ařaması (MATLAB)

Bu iřlem sonucunda elde ettięimiz tahmin deęeri 0,35309’dur. Bu veri elektrik tketim tahmininin nce byme miktarına sonrasında normalizasyon iřlemine sokulmuř halidir. Elde edilen veri ters iřlem ile tketim tahmin verisine evrilebilmektedir. Ters iřlem sonucu elde edilen miktar **254.686.795 mWh**’dır.

6. SONUÇ

Günümüzde sürekli artan nüfus, sanayi ve teknolojik gelişmelere paralel olarak enerjiye duyulan ihtiyaçta artmaktadır. İnsanoğlu ısınma, aydınlatma, haberleşme gibi birçok alanda enerjiye ihtiyaç duymaktadır. En fazla kullanılan enerji türü ise elektrik enerjisidir. Yaşamımızın birçok alanında elektrik enerjisine ihtiyaç duyarız. Dolayısıyla elektrik enerjisinin kesilmesi durumunda hayat durma noktasına gelmektedir. Günümüzde dahi kısa bir elektrik kesilmesi durumunda bile refah seviyesinin düşmesine neden olmaktadır. Elektrik kesilmesi düşünüldenden daha büyük sorunlara da yol açabilir. Üretim, ekonomi gibi önemli unsurlar zarar görebilir. Bunun gibi sorunlarla karşılaşılması için ülkeler iyi bir plan dahilinde ilerlemelidir. İyi bir plan ise gelecekteki durumun en iyi şekilde tahmin edilmesi ile olacaktır. Gerçeğe oldukça yakın bir elektrik tüketim tahmini iyi bir planı da beraberinde getirecektir.

Türk Dil Kurumu'na göre tahmin; akla, sezgiye veya bazı verilere dayanarak olabilecek bir şeyi, bir olayı önceden kestirme demektir. Çeşitli yollarla elde edilen tahmin verileri planlama esnasında önemli ve değerli bir veri olarak kullanılmaktadır. Tahminler sadece sezgisel varsayımlara değil bilimsel ve objektif kriterlere de dayandırılması gerekmektedir.

Talep tahmini konusunda son zamanlarda makine öğrenmesinin gelişimi ile geleneksel tahmin yöntemlerinden ziyade yapay sinir ağları tahmin yöntemi kullanılmıştır. Yapay sinir ağları yöntemi sadece tahmin çalışmalarında değil sınıflandırma, veri kavramlaştırma, kontrol problemlerinin çözümü gibi birçok alanda da kullanılmaktadır. Ancak dünya literatürüne kıyasla Türkiye'de yapay sinir ağları üzerinde yapılan çalışmalar oldukça azdır. Yapay sinir ağları birçok alanda kullanıldığı görülmektedir. Dolayısıyla ülkemizde de birçok probleme bu yöntem ile çözümler bulunabileceği düşünülmektedir ve bununla ilgili daha fazla çalışmalar yapılmalıdır.

Bu çalışmada Türkiye'nin gelecek döneme ait elektrik tüketim tahmini en doğru şekilde yapılarak sonraki dönemin planı yapılırken elde edilecek tahmin değerinin bu planda kullanılabilir bir veri olması hedeflenmiştir. Tahmin yöntemi olarak yapay sinir ağları modeli seçilmiş ve ilgili bölümlerde yapay sinir ağları modeli detaylı bir şekilde incelenmiş ve açıklanmıştır. Oluşturulan ağı eğitimi için 1980-2017 yılları arasındaki veriler kullanılmış ve 2018 yılına ait Türkiye elektrik tüketim miktarı tahmin edilmeye çalışılmıştır.

Bu konuda yapılan birçok çalışmada yapay sinir ağıları metodu kullanılırken geçmiş dönemlere ait girdi değişkenlerine karşılık gelen çıktı değeri ağı gösterilip eğitilmiş ve yapay sinir ağlarının geçmiş dönemlerine ait tahmin değerleri elde edilmiştir. Performans ölçüm teknikleri ile yapay sinir ağlarının geçmiş dönemde gerçekleşen tahmin değerleri ile gerçek değerlerin ne ölçüde tutarlı olduğuna bakılmıştır.

Fakat bu çalışmada sürekli artış gösteren grafiğe sahip bir veri setinin nasıl tahmin edilebileceği ve gelecek dönemde nasıl bir değerle devam edeceği tahmin edilmeye çalışılmıştır. Çalışmada öncelikle tahmin edilmek istenen dönemin yani 2018 yılının değişkenlerinin tahmini Holt metodu ile tahmin edilmiştir. Fakat veri seti sürekli büyüyen bir grafiğe sahip olduğundan 2018 yılına ait değişkenlerin değerleri ağı eğitiminde kullanılan verilerden büyüktür. Dolayısıyla ağı eğitimde öğrendiği en büyük çıktı değeri veya değişken değeri (x) ise, oluşturulan ağıdan değişken değeri veya çıktı değerinin (x)'den daha büyük bir değer ataması beklenemez. Bundan dolayı verilerin büyüme oranları hesaplanarak ağı daha hızlı öğrenmesi ve daha doğru çıktılar sunması sağlanmıştır. Normalizasyon formülü olarak çoğu çalışmada Min-Max normalizasyonu kullanılmasına rağmen bu çalışmada D_Min_Max normalizasyonu kullanılmıştır. Böylelikle verilerin 0,1-0,9 aralığında toplanması sağlanmıştır. Oluşturulan veriler ile ağı eğitilmiştir. Eğitim boyunca hiç gösterilmeyen değişkenler ağı gösterilerek gelecek dönemin tahmini yapılmaya çalışılmıştır. Tahmin edilen değer 0,999308677 doğrulukta gerçek değere yakın olduğu görülmüştür. Çıktı değerlerine bakıldığında elektrik tüketim tahmini için yapay sinir ağları metodunun oldukça tutarlı sonuçlar verdiği ve kullanılabilir olduğu görülmüştür.

7. KAYNAKÇA

- Adıyaman, F. (2007). *Talep tahmininde yapay sinir ağlarının kullanılması yüksek lisans tezi*. İstanbul.
- Akan, Y., & Tak, S. (2003). Türkiye Elektrik Enerjisi Ekonometrik Talep Analizi. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 21-49.
- Akyüz, H. E. (2018). Vektör Otoregresyon (VAR) Modeli ile İklimsel Değişkenlerin İstatistiksel Analizi. *Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi*, 183-192.
- Armutlulu, İ. H. (2008). *İşletmelerde Uygulamalı İstatistik*. İstanbul: Alfa Yayınları.
- Ataseven, B. (2013). Yapay Sinir Ağları ile Öngörü Modellemesi. *Öneri Dergisi*.
- Barnett, V., & Lewis, T. (1980). *Outliers in Statistical Data*. J. Wiley & Sons.
- Başoğlu, B., & Bulut, M. (2016). Kısa dönem elektrik talep tahmini için yapay sinir ağları ve uzman sistemler tabanlı hibrit sistem geliştirilmesi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 575-583.
- Bergmeir, C., Hyndman, R., & Benitez, J. (2016). Bagging exponential smoothing methods using STL decomposition and Box-Cox transformation. *International Journal of Forecasting*, 303-312.
- Bülbül, Ş. (1994). Zaman Serilerinde Üstel Düzeltme Modelleri ve Bir Uygulama. *Öneri Dergisi*, 44-51.
- Ceylan, M. (2016). *Elektrik Enerji Santralleri ve Elektrik Enerjisi İletimi ve Dağıtımı*. Ankara: Seçkin Yayıncılık.
- Crosswhite, C. (2003). Method for determining optimal time series forecasting parameters.
- Demirel, Ö., Kakilli, A., & Tektaş, M. (2010). ANFIS ve ARMA Modelleri ile Elektrik Enerjisi Yük Tahmini. *Gazi Üniversitesi Mühendisler ve Mimarlar Fakültesi Dergisi*, 601-610.
- Ekonomou, L. (2010). Greek long term energy consumption prediction using artificial neural networks. *Energy*, 512-517.
- Elmas, Ç. (2016). *Yapay Zeka Uygulamaları*. Ankara: Seçkin .
- Enerji ve Tabii Kaynaklar Bakanlığı*. (2019, Eylül 13). Enerji ve Tabii Kaynaklar Bakanlığı Web sitesi: <https://sp.enerji.gov.tr/sp-2015-2019.html> adresinden alındı

- Engle, R., & Ng, V. (1993). Measuring and Testing the Impact of News on Volatility. *THE JOURNAL OF FINANCE*, 1749-1778.
- Haliloğlu, E. Y., & Tutu, B. E. (2018). Türkiye için Kısa Vadeli Elektrik Enerjisi Talep Tahmini. *Journal of Yaşar University*, 243-255.
- Haykin, S. (2009). *Neural Networks and Learning Machines*. New Jersey: Pearson.
- Honaker, J., & King, G. (2010). What to Do about Missing Values in Time-Series Cross-Section Data. *American Journal of Political Science*, 561-581.
- Hsiaotien, P. (2007). Forecasting electricity market using artificial neural networks. *Energy conversation and management*, 907-912.
- Hyndman, R., & Athanasopoulos, G. (2014). *Forecasting Principles and Practice*. Otexts.
- İsmiç, B. (2015). Gelişmekte Olan Ülkelerde Elektrik Tüketimi, Ekonomik Büyüme ve Nüfus İlişkisi. *Çankırı Karatekin Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 259-274.
- Jayalakshmi, T., & Santhakumaran, A. (2011). Statistical Normalization and Back Propagation for Classification. *International Journal of Computer Theory and Engineering*, 89-93.
- Jiang, W., Wu, X., Gong, Y., Yu, W., & Zhong, X. (2020). HolteWinters smoothing enhanced by fruitfly optimization algorithm to forecast monthly electricity consumption. *Energy*, 1-8.
- Kalekar, P. (2004). Time series Forecasting using Holt-Winters Exponential Smoothing. Kanwal Rekhi School of Information Technology.
- Kapusuzoğlu, A., & Karan, M. B. (2010). Gelişmekte Olan Ülkelerde Elektrik Tüketimi ile Gayri Safi Yurtiçi Hasıla (GSYİH) Arasındaki Es-Bütünleşme ve Nedensellik İlişkisinin Analizi: Türkiye Üzerine Ampirik Bir Çalışma. *İşletme ve Ekonomi Araştırmaları Dergisi*, 57-68.
- Karagöl, E. T., & Tür, M. R. (2017). *Türkiye'de Elektrik Enerjisi*. İstanbul: SETA Yayınları.
- Kılıç, S. (2013). Doğrusal Regresyon Analizi. *Journal of Mood Disorders*, 90-92.
- Kim, P. (2017). *MATLAB Deep Learning*. Seoul: Apress.
- Kuzu, S. (2018). Borsa İstanbul Endeksi (BİST 100) Getiri Volatilesinin ARCH ve GARCH Modeli ile Tahmin Edilmesi. *Muhasebe ve Vergi Uygulamaları Dergisi*, 608-624.

- Lancaster, G., & Massingham, L. (2011). *Essentials of Marketing Management*. Oxon: Routledge .
- Maia, A., & Carvalho, F. (2011). Holt's exponential smoothing and neural network models for forecasting interval-valued time series. *International Journal of Forecasting*, 740-759.
- Marsland, S. (2009). *Machine Learning : an algorithmic perspective* (s. 83). içinde CRC Press Taylor&Francis Group.
- MathWorks* . (2019, Eylül 27). The MathWorks, Inc web sitesi: <https://www.mathworks.com/help/deeplearning/ref/traingdx.html> adresinden alındı
- Öztemel, E. (2016). *Yapay Sinir Ağları*. İstanbul: Papatya Yayıncılık.
- RWE&Turcas Güney Elektrik Üretim A.Ş.* (2019, Eylül 13). RWE&Turcas Güney Elektrik Üretim A.Ş. Web Sitesi: <https://www.rwe-turcas.com/tr-TR/enerji-santralleri/denizli-enerji-santrali> adresinden alındı
- Satman, A. (2017, Aralık). *Türkiye'nin Enerji Vizyonu*. Jeotermal Enerji Semineri: http://www1.mmo.org.tr/resimler/dosya_ekler/8188c7e9965c217_ek.pdf adresinden alındı
- Soysal, M., & Ömürgönülşen, M. (2010). Türk Turizm Sektöründe Talep Tahmini Üzerine Bir Uygulama. *Anatolia: Turizm Araştırmaları Dergisi*, 128-136.
- Spurgeon, R., & Flood, M. (2014). *Enerji ve Güç*. Ankara: Tübitak Yayınları.
- Şeker, S. E. (2015). Zaman Serisi Analizi (Time Series Analysis). *YBS Ansiklopedisi, Cilt 2, Sayı 4*. içinde
- Şengönül, A., & Koşaroğlu, Ş. M. (2018). Elektrik Tüketimi ve Ekonomik Büyüme Arasındaki İlişki: Brics Ülkeleri İçin Bir Uygulama. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 431- 447.
- Şenol, Ü., & Musayev, Z. (2017). Rüzgar enerjisinden elektrik üretiminin yapay sinir ağları ile tahmini . *Bilge Uluslararası Fen ve Teknoloji Araştırmaları Dergisi*, 23-31.
- Tarı, R. (2014). *Ekonometri*. İstanbul: Umuttepe Yayınları.
- Taşkiner, B. (2018). *Ankara ili Doğalgaz Tüketiminin Yapay Sinir Ağları ile Öngörüsü Yüksek Lisans Tezi*. İstanbul.

- Tso, G., & Yau, K. (2007). Predicting electricity energy consumption: A comparison of regression analysis, decision tree and neural networks. *Energy*, 1761-1768.
- Türk Dil Kurumu*. (2019, Eylül 13). Türk Dil Kurumu Web Sitesi: <https://sozluk.gov.tr/> adresinden alındı
- Türkiye Elektrik İletim A.Ş.* . (2020, Nisan 1). Türkiye Elektrik İletim A.Ş. Resmi Web Sitesi: <https://www.teias.gov.tr/tr-TR/kurulus-ve-tarihce> adresinden alındı
- Wasserman, L. (2003). *All of Statistics - A Concise Course in Statistical Inference*. New York: Springer.
- Yağımlı, M., & Ergin, H. (2017). Türkiye’de İş Kazalarının Üstel Düzeltme Metodu ile Tahmin Edilmesi. *Marmara Fen Bilimleri Dergisi*, 118-123.
- Yanar, R., & Kerimoğlu, G. (2011). Türkiye’de Enerji Tüketimi, Ekonomik Büyüme Ve Cari Açık İlişkisi. *Ekonomi Bilimleri Dergisi*, 191-201.
- Yapraklı, S., & Yurttaoçmaz, Z. (2012). Elektrik Tüketimi ile Ekonomik Büyüme Arasındaki Nedensellik : Türkiye Üzerine Ekonometrik Bir Analiz. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 195 - 215.
- Yavuz, S., & Deveci, M. (2012). İstatistiksel Normalizasyon Tekniklerinin Yapay Sinir Ağın Performansına Etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 167-187.
- Yılmaz, A. (2017). *Yapay Zeka*. İstanbul: KODLAB.

8. EKLER

Tablo 8-1 Holt Yöntemi ile 2018 Yılı Üretim Değişkeninin Tahmini

Yıl	Üretim	It	Tt	Tahmin	Et	MSE
1980	23.275.400	23275400	0	23.275.400	0	0
1981	24.672.800	23974100	225038,5032	23275400	1.397.400	1.952.726.760.000
1982	26.551.500	25375319,25	603864,8307	24199138,5	2.352.361	5.533.604.611.794
1983	27.346.800	26662992,04	824106,8796	25979184,08	1.367.616	1.870.373.298.294
1984	30.613.500	29050299,46	1327585,21	27487098,92	3.126.401	9.774.383.708.555
1985	34.218.900	32298392,34	1946145,637	30377884,67	3.841.015	14.753.398.761.389
1986	39.694.800	36969668,99	2823860,542	34244537,97	5.450.262	29.705.356.171.853
1987	44.352.900	42073214,76	3558105,502	39793529,53	4.559.370	20.787.859.098.482
1988	48.048.800	46840060,13	3947418,526	45631320,27	2.417.480	5.844.208.265.462
1989	52.043.200	51415339,33	4149640,976	50787478,66	1.255.721	1.576.836.085.534
1990	57.543.000	56553990,15	4468182,976	55564980,31	1.978.020	3.912.561.911.728
1991	60.246.300	60634236,56	4343235,697	61022173,13	-775.873	601.979.112.284
1992	67.342.200	66159836,13	4724053,495	64977472,26	2.364.728	5.591.937.275.925
1993	73.807.500	72345694,81	5194874,235	70883889,63	2.923.610	8.547.497.619.316
1994	78.321.700	77931134,52	5320668,239	77540569,05	781.131	610.165.563.761
1995	86.247.400	84749601,38	5803081,805	83251802,76	2.995.597	8.973.602.808.213
1996	94.861.700	92707191,59	6497009,595	90552683,19	4.309.017	18.567.625.896.588
1997	103.295.800	101250000,6	7155924,203	99204201,19	4.091.599	16.741.180.831.485
1998	111.022.400	109714162,4	7577283,63	108405924,8	2.616.475	6.845.942.487.884
1999	116.439.900	116865673	7440149,922	117291446	-851.546	725.130.637.903
2000	124.921.604	124613713,5	7539315,836	124305822,9	615.781	379.186.319.265
2001	122.724.700	127438864,7	6020969,54	132153029,3	-9.428.329	88.893.393.463.571

2002	129.399.500	131429667,1	5367089,814	133459834,2	-4.060.334	16.486.313.752.364
2003	140.580.500	138688628,5	5976427,07	136796756,9	3.783.743	14.316.711.767.790
2004	150.698.300	147681677,8	6948025,972	144665055,5	6.033.244	36.400.038.890.962
2005	161.956.200	158292951,9	8127891,26	154629703,7	7.326.496	53.677.547.522.499
2006	176.299.800	171360321,6	9718807,009	166420843,1	9.878.957	97.593.788.892.404
2007	191.558.100	186318614,3	11406349,62	181079128,6	10.478.971	109.808.842.180.906
2008	198.418.000	198071482	11517956,75	197724963,9	693.036	480.299.027.547
2009	194.812.900	202201169,4	9138330,193	209589438,7	- 14.776.539	218.346.096.074.250
2010	211.207.700	211273599,8	9117105,081	211339499,5	-131.800	17.371.120.146
2011	229.395.100	224892902,4	10567180,65	220390704,9	9.004.395	81.079.131.958.175
2012	239.496.800	237478441,5	11217257,03	235460083,1	4.036.717	16.295.083.489.998
2013	240.154.000	244424849,3	9841694,516	248695698,6	-8.541.699	72.960.614.523.930
2014	251.962.800	253114671,9	9470697,624	254266543,8	-2.303.744	5.307.235.510.924
2015	261.783.300	262184334,8	9341531,655	262585369,5	-802.070	643.315.524.219
2016	274.407.700	272966783,2	9805624,624	271525866,4	2.881.834	8.304.964.795.655
2017	297.277.500	290024953,9	12141537,2	282772407,8	14.505.092	210.397.698.762.899
2018		151083245,6	-36519615,56	302166491,1		1.194.304.004.483.950

Tablo 8-2 Holt Yöntemi ile 2018 Yılı Üretim Değişkeninin Tahmininde Kullanılan Alfa ve Beta Değerleri

α	0,5
β	0,322081728
MSE	32278486607675
n	38
GERÇEK DEĞER	304.801.884
TAHMİN DEĞERİ	302.166.491
FARK	2.635.393

Tablo 8-3 Holt Yöntemi ile 2018 Yılı Trafo Miktarı Değişkeninin Tahmini

Yıl	Trafo Miktarı	It	Tt	Tahmin	MSE
1980	594	594	0	594	0
1981	610	610	5,751436902	594	256
1982	629	629	10,51382907	615,7514369	176
1983	651	651	14,64270328	639,5138291	132
1984	682	682	20,52257578	665,6427033	268
1985	693	693	17,09954492	702,5225758	91
1986	647	647	-5,582520776	710,0995449	3.982
1987	667	667	3,613495101	641,4174792	654
1988	686	686	9,144402105	670,6134951	237
1989	711	711	14,84393153	695,1444021	251
1990	743	743	21,01093436	725,8439315	294
1991	783	783	27,83683516	764,0109344	361
1992	834	834	36,16317773	810,8368352	537
1993	840	840	25,32057689	870,1631777	910
1994	864	864	24,84587597	865,3205769	2
1995	889	889	24,90127814	888,845876	0
1996	914	914	24,93676517	913,9012781	0
1997	962	962	33,22718641	938,9367652	532
1998	1.006	1006	37,09963376	995,2271864	116
1999	1.038	1038	35,2664949	1043,099634	26
2000	1.065	1065	32,29498091	1073,266495	68
2001	1.090	1090	29,67269201	1097,294981	53
2002	1.055	1055	6,4251353	1119,672692	4.183
2003	1.072	1072	10,22642699	1061,425135	112

2004	1.089	1089	12,6612881	1082,226427		46
2005	1.088	1088	7,750535819	1101,661288		187
2006	1.130	1130	20,06201283	1095,750536		1.173
2007	1.173	1173	28,30741195	1150,062013		526
2008	1.241	1241	42,57550042	1201,307412		1.576
2009	1.272	1272	38,41451541	1283,5755		134
2010	1.317	1317	40,78176535	1310,414515		43
2011	1.357	1357	40,50074822	1357,781765		1
2012	1.425	1425	50,38576144	1397,500748		756
2013	1.505	1505	61,03103797	1475,385761		877
2014	1.550	1550	55,26844401	1566,031038		257
2015	1.595	1595	51,57729977	1605,268444		105
2016	1.675	1675	61,79426021	1646,5773		808
2017	1.750	1750	66,5412589	1736,79426		174
2018				1816,541259		19.902

Tablo 8-4 Holt Yöntemi ile 2018 Yılı Trafo Miktarı Değişkeninin Tahmininde Kullanılan Alfa ve Beta Değerleri

α	1
β	0,359464806
MSE	538
n	38
GERÇEK DEĞER	1.826
TAHMİN DEĞERİ	1.817
FARK	9

Tablo 8-5 Holt Yöntemi ile 2018 Yılı GSYİH Değişkeninin Tahmini

Yıl	GSYİH	It	Tt	Tahmin	MSE1
1980	5,23	5.231,00	5231	3	5
1981	7,90	2.079,13	-2118,963586	10.462	109.288.186
1982	10,49	0,52	-2083,579126	-40	2.533
1983	13,91	-401,56	-609,2662563	-2.083	4.397.260
1984	22,00	-182,63	116,8784481	-1.011	1.066.717
1985	35,10	15,11	187,7814823	-66	10.170
1986	51,08	81,16	81,04353912	203	23.048
1987	74,72	92,05	19,53940714	162	7.653
1988	129,23	125,73	31,93570948	112	311
1989	227,32	213,52	80,90916198	158	4.852
1990	393,06	373,52	150,2512701	294	9.727
1991	630,12	609,05	225,0202327	524	11.310
1992	1.093,37	1.041,99	407,3267988	834	67.237
1993	1.981,87	1.876,36	781,7441707	1.449	283.606
1994	3.868,43	3.628,63	1632,690182	2.658	1.464.896
1995	7.649,03	7.175,96	3311,415486	5.261	5.701.145
1996	14.772,11	13.923,19	6323,881924	10.487	18.358.926
1997	28.835,88	27.134,22	12362,41453	20.247	73.767.603
1998	52.224,95	49.703,14	21311,30851	39.497	162.009.905
1999	77.415,27	76.147,10	25811,53647	71.014	40.970.557
2000	124.583,46	120.100,90	41718,36743	101.959	511.882.373
2001	178.412,44	175.124,90	53384,52884	161.819	275.333.340
2002	277.574,06	267.853,09	87880,395	228.509	2.407.337.330
2003	359.762,93	358.964,59	90713,37266	355.733	16.236.378
2004	430.511,48	434.308,85	77237,9909	449.678	367.354.190

2005	648.931,71	621.712,23	173829,1739	511.547	18.874.602.420
2006	758.390,79	765.751,28	147709,6856	795.541	1.380.168.694
2007	843.178,42	857.103,20	98296,13619	913.461	4.939.635.952
2008	950.534,25	951.498,15	94875,63833	955.399	23.669.086
2009	952.634,80	971.206,90	28970,56441	1.046.374	8.786.998.355
2010	1.160.013,98	1.128.346,25	141346,8227	1.000.177	25.547.709.964
2011	1.394.477,17	1.369.754,23	229078,7761	1.269.693	15.571.069.421
2012	1.569.672,11	1.575.449,64	208576,6311	1.598.833	850.357.299
2013	1.809.713,09	1.804.623,87	226636,2631	1.784.026	659.812.647
2014	2.044.465,88	2.041.849,48	235920,8271	2.031.260	174.391.725
2015	2.338.647,49	2.326.586,16	278721,7535	2.277.770	3.706.032.128
2016	2.608.525,75	2.607.888,21	280984,1204	2.605.308	10.354.495
2017	3.106.536,75	3.063.411,83	434017,4475	2.888.872	47.377.799.135
2018		692.930,76	-2024920,221	3.497.429	131.898.190.579

Tablo 8-6 Holt Yöntemi ile 2018 Yılı GSYİH Değişkeninin Tahmininde Kullanılan Alfa ve Beta Değerleri

α	0,801874261
β	0,876783373
MSE	3.471.005.015
n	38
GERÇEK DEĞER	3.700.989
TAHMİN DEĞERİ	3.497.429
FARK	203.560

Tablo 8-7 Holt Yöntemi ile 2018 Yılı Yatırım Değişkeninin Tahmini

Yıl	Yatırım	It	Tt	Tahmin		MSE
1980	1,26	1,261212	0	1,261212		0
1981	3,92	3,680975252	1,432199273	1,261212		7
1982	6,01	5,934740268	1,918464143	5,113174525		1
1983	12,96	12,50905993	4,674152279	7,853204411		26
1984	17,16	17,1606276	4,660784998	17,1832122		0
1985	32,33	31,40154004	10,33103044	21,8214126		110
1986	66,33	64,16049744	23,60557731	41,73257048		605
1987	48,88	52,31259606	2,62152179	87,76607475		1.512
1988	34,72	36,50116617	-8,28849595	54,93411785		409
1989	99,41	93,12842459	30,13356711	28,21267022		5.069
1990	156,16	153,2602776	47,88882611	123,2619917		1.082
1991	165,33	168,4900932	28,55874867	201,1491037		1.283
1992	237,32	233,7718025	50,29417976	197,0488419		1.622
1993	393,97	384,2793959	109,6080726	284,0659822		12.080
1994	331,02	345,3873574	21,71445282	493,8874685		26.525
1995	1.222,20	1146,777297	483,1854932	367,1018102		731.184
1996	1.084,63	1132,731032	188,8860566	1629,96279		297.383
1997	1.649,87	1620,918675	366,0354178	1321,617089		107.750
1998	4.389,73	4177,804866	1662,746938	1986,954093		5.773.308
1999	3.894,60	4066,231323	612,5696111	5840,551804		3.786.721
2000	11.363,81	10774,20679	4220,292734	4678,800934		44.689.386
2001	12.440,00	12665,30233	2841,697318	14994,49952		6.525.468
2002	14.033,00	14163,00416	2046,218932	15506,99965		2.172.675
2003	14.316,00	14482,97892	1024,49681	16209,22309		3.584.294

2004	23.872,00	23134,26379	5538,607977	15507,47573		69.965.266
2005	16.762,00	17812,51777	-889,3725644	28672,87177		141.868.866
2006	20.373,00	20068,72892	972,422265	16923,14521		11.901.498
2007	19.046,00	19221,9688	-104,3077402	21041,15119		3.980.628
2008	18.300,00	18372,11626	-545,5776548	19117,66106		668.570
2009	19.897,00	19714,38898	571,795267	17826,5386		4.286.810
2010	20.537,00	20514,87849	707,1538572	20286,18424		62.909
2011	39.748,00	38114,0425	10705,12562	21222,03235		343.211.477
2012	84.690,00	81526,25622	30063,65906	48819,16811		1.286.716.580
2013	35.286,00	42015,87005	-11115,53356	111589,9153		5.822.287.487
2014	58.528,00	56091,28906	3794,381259	30900,33649		763.287.791
2015	71.543,00	70514,84419	10085,53189	59885,67032		135.893.335
2016	128.868,00	124610,8811	36134,28411	80600,37607		2.329.763.519
2017	229.379,00	223325,6175	73174,13837	160745,1652		4.710.603.273
2018	285.608,00			296499,7558		15.692.216.510

Tablo 8-8 Holt Yöntemi ile 2018 Yılı Yatırım Değişkeninin Tahmininde Kullanılan Alfa ve Beta Değerleri

α	0,911801773
β	0,591875785
MSE	424113959,7
n	38
GERÇEK DEĞER	285.608,00
TAHMİN DEĞERİ	296.500
FARK	-10.892