



T.C.
NECMETTİN ERBAKAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİR ELEKTRİK DAĞITIM ŞİRKETİNDE 10
YILLIK TALEP TAHMİNİ

Büşra YAPICI

YÜKSEK LİSANS

Endüstri Mühendisliği Anabilim Dalı

Temmuz-2018

KONYA

Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Büşra YAPICI tarafından hazırlanan “Bir Elektrik Dağıtım Şirketinde 10 Yıllık Talep Tahmini” adlı tez çalışması 19/07/2018 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Mehmet AKTAN

.....
.....

Danışman

Prof. Dr. Mehmet AKTAN

.....
.....

Üye

Doç. Dr. Saadettin Erhan KESEN

.....
.....

Üye

Dr. Öğr. Üyesi Kemal ALAYKIRAN

.....
.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mehmet KARALI
FBE Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all materials and results that are not original to this work.

Büşra YAPICI

ÖZET

YÜKSEK LİSANS TEZİ

BİR ELEKTRİK DAĞITIM ŞİRKETİNDE 10 YILLIK TALEP TAHMİNİ

Büşra YAPICI

Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü
Endüstri Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Mehmet AKTAN

2017, Sayfa

Jüri

Prof. Dr. Mehmet AKTAN
Doç. Dr. Saadettin Erhan KESEN
Dr. Öğr. Üyesi Kemal ALAYKIRAN

Bu çalışmanın amacı; elektrik enerjisi, iletim ve dağıtım şebekeleri ile üretildiği bölgeden diğer bölgelere taşınabilen ancak depolanamayan bir enerji kaynağı olması nedeni ile elektrik enerjisi talebinin tahmin edilmesi operasyonel ve mali planlama çalışmalarında da kullanılacağından doğru ve gerçeğe yakın tahminler yapılması için kullanılacak metod seçiminin analizidir. Elektrik dağıtım şirketleri tarafından yapılan tahminler ülkemizin 10 yıllık tahmin projeksiyonunu ortaya koyacağı için; yapılan tahminlerin doğruluk oranları, bu tahminler baz alınarak gerçekleştirilen planlama ve yatırım çalışmalarının daha sağlıklı olmasını sağlamaktadır. Bu çalışmada ise Konya’da faaliyet gösteren bir elektrik dağıtım şirketinin önümüzdeki 10 yıl içerisindeki elektrik tüketim tahminleri farklı yöntemlerle yapılmış olup kıyaslanarak şirketin sonraki süreçler için hangi yöntemi kullanması gerektiğine bilimsel bir şekilde karar verilmiştir.

Anahtar Kelimeler: Enerji dağıtımı, Talep tahmini, Yapay sinir ağları, Regresyon, Zaman Serileri

ABSTRACT

MASTER'S THESIS

ESTIMATING 10 YEAR DEMAND FOR AN ELECTRICITY DISTRIBUTION COMPANY

Büşra YAPICI

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
NECMETTIN ERBAKAN UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN INDUSTRIAL ENGINEERING**

Advisor: Prof. Mehmet AKTAN

2018, Sayfa

Jury

Prof. Mehmet AKTAN

Assoc. Prof. Saadettin Erhan KESEN

Asst. Prof. Kemal ALAYKIRAN

The purpose of this study is choosing the method to be used to make accurate and near-realistic estimates for electricity demand. Electric energy is an energy source that can be transported by transmission and distribution networks, but cannot be stored in the region where electricity is produced. The estimates made by the electricity distribution companies show the 10 year forecast of the country. Accuracy rates of the estimations will make the planning and investment studies based on these estimates healthier. In this study, the electricity consumption forecasts of an electricity distribution company operating in Konya in the next 10 years were obtained by different methods and the method that should be used by the company for the next forecasting processes was determined.

Keywords: Artificial neural network, Demand forecasting, Power distribution, Regression, Time Series

ÖNSÖZ

Günümüzde enerji dağıtım şirketleri EPDK mevzuatları gereği enerji talebi tahminlerini gerçeğe yakın yapabilmek zorundadırlar. Bu yüzden şirketlerin kar kaybına uğramamaları için bu tahmini gerçeğe en yakın olacak şekilde ancak bilimsel bir yöntemle ulaşabileceklerinin farkında olup en doğru yöntemin kendi bünyelerinde bulunamamasından dolayı bu çalışma ihtiyacı doğmuştur.

Bu çalışma sürecinde öncelikle danışmanlık yaparak sorduğum soruları cevaplayan, benden bilgi ve desteğini esirgemeyen Sayın Prof. Dr. Mehmet AKTAN'a ve bu süreçte hep yanımda olan aileme (Aytek YAPICI, Nurhayat YAPICI, Dilara YAPICI, Cemal Berk YAPICI, Esra YAŞAR ve Cankat YAVUZ) sonsuz teşekkürlerimi sunarım.

Büşra YAPICI
KONYA-2018

İÇİNDEKİLER

ÖZET	iv
ABSTRACT	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR.....	ix
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	3
3. MATERYAL VE YÖNTEM	9
3.1. Talep Tahmini	9
3.2. Talep Tahmininde Kullanılan Yöntemler	9
3.2.1. Kalitatif Yöntemler	10
3.2.2. Kantitatif Yöntemler	10
3.2.2.1. İlişkisel Yöntemler	10
3.2.2.2. Zaman Serileri Yöntemleri.....	12
3.2.2.2.1. Mekanik Tahmin Yöntemi	13
3.2.2.2.2. Hareketli Ortalamalar Yöntemi	13
3.2.2.2.3. Üstel Düzeltme Yöntemi	14
3.2.2.2.4. Box-Jenkins Tahmin Yöntemi (ARIMA).....	16
3.2.2.2.4.1. Durağan ARIMA Modelleri	17
3.2.2.2.4.2. Durağan Olmayan ARIMA Modelleri	17
3.2.3. Yapay Zeka Tabanlı Yöntemler	18
3.2.3.1. Yapay Sinir Ağları (YSA).....	18
3.2.3.1.1. Yapay Sinir Ağları Modelleri.....	22
3.2.3.1.2. YSA' da Öğrenme Algoritmaları	23
3.2.3.1.3. YSA' da Öğrenme Kuralları	25
4. ARAŞTIRMA BULGULARI VE TARTIŞMA	26
4.1. Tahmin Analizi İçin ARIMA Modellerin İncelenmesi	26
4.1.1. Toplam Abone Sayısı.....	26
4.1.2. Dağıtım Sistemine Giren Elektrik Enerjisi Talebi	32
4.2. Tahmin Analizi İçin Yapay Sinir Ağları Modellerin İncelenmesi	43

4.2.1. Öğrenme Katsayısının Belirlenmesi.....	43
4.2.2. Momentum Katsayısının Belirlenmesi.....	44
4.2.3. Çevrim Sayısının Belirlenmesi	44
4.2.4. Nöron Sayısının Belirlenmesi	44
4.2.5. Ağın Eğitilmesi	44
5. SONUÇLAR VE ÖNERİLER	48
KAYNAKLAR	53
EKLER.....	57
EK-1 Otokorelasyon Analizi Komutu – Abone Sayısı	57
EK-2 Backtest Analizi – ARIMA(0,1,0).....	57
EK-3 Hata Terimleri Histogram Komutu – ARIMA(0,1,0).....	57
EK-4 ARCH Test - ARIMA(0,1,0).....	57
EK-5 Gün tipi ağırlıklarını bulmaya yönelik ARIMA modeli	58
EK-6 Otokorelasyon Analizi Komutu – Dağıtım Giren Enerji Talebi.....	58
EK-7 ARCH Test - Dağıtım Giren Enerji Talebi.....	58
ÖZGEÇMİŞ.....	59

SİMGELER VE KISALTMALAR

AR: Özbağımsal Tasarım
ARIMA: Özbağımsal Tümlşik Hareketli Ortalama
ARMA: Özbağımsal Hareketli Ortalama
EPDK: Enerji Piyasaları Düzenleme Kurumu
YSA: Yapay Sinir Ağları



1. GİRİŞ

Elektrik enerjisi, iletim ve dağıtım şebekeleri ile üretildiği bölgeden diğer bölgelere taşınabilen ancak depolanamayan bir enerji kaynağıdır. Bu sebeple elektrik enerjisi talebinin tahmin edilmesi operasyonel ve mali planlama açısından çok önemlidir. Yapılan tahminlerin doğruluk oranları ise, bu tahminler baz alınarak gerçekleştirilen planlama çalışmalarının daha sağlıklı olmasını sağlamaktadır.

Şirketler için talep tahminleri kritik öneme sahiptir. Çünkü şirketler talep tahminleri doğrultusunda yatırım planlarını hazırlamaktadırlar. Hangi ürünlerin, hangi bölgelere, hangi tarih aralıklarında ne kadar satış yapılabileceği verisine talep tahmini ile ulaşabildikleri için bu konuda ciddi çaba sarf etmektedirler.

Bu sebeple Elektrik Dağıtım şirketleri, Elektrik Enerjisi Talep Tahminleri Hakkında Yönetmelik (Yönetmelik) ”MADDE 5 – (1) Dağıtım şirketleri dağıtım bölgelerine ilişkin, görevli tedarik şirketler ise enerji tedarik etmeyi planladığı son kaynak, perakende satış ve serbest tüketicilerin tüketimine ilişkin talep tahminlerini bilimsel yöntemlerle, bölgelerine özgü şartları dikkate alarak, resmi ekonomik hedefleri göz önünde bulundurarak ve gerek duyulması halinde ilgili kamu ya da özel sektör kurum ve kuruluşlarının görüşlerini de alarak yapar veya yaptırır.

(2) Talep tahminlerinin OSB’ler, dağıtım ve görevli tedarik şirketleri tarafından diğer gerçek veya tüzel kişilere yaptırılması, ilgili OSB ve şirketlerin sorumluluğunu ortadan kaldırmaz.

(3) OSB, dağıtım bölgesine ilişkin talep tahminlerini resmi ekonomik hedefleri göz önünde bulundurarak hazırlamak ve bağlantı durumuna göre dağıtım şirketi veya TEİAŞ’a bildirmekle yükümlüdür.

Talep tahmini dönemi ve senaryoları

MADDE 6 – (1) Talep tahminleri, dağıtım şirketleri için gelecek on, görevli tedarik şirketleri için gelecek beş yıllık dönem için her yıl takip eden yıl birinci yıl olmak üzere yıllık bazda hazırlanır ve tahmin sonuçları düşük, baz ve yüksek senaryo şeklinde Kuruma sunulur. TEİAŞ tarafından üretim kapasite projeksiyonu ve iletim sistemi gelişim raporu ile dağıtım şirketi tarafından yatırım planı hazırlanmasında baz senaryo esas alınır.

Talep tahminine esas veri seti

MADDE 7 – (1) Talep tahminine esas veri seti; ekonomik, sosyal, demografik, iklimsel, çevresel değişkenler ve açıklanan değişkenin gerçekleştirmeleri kullanılarak oluşturulur.

(2) Talep tahminine esas veri setinde, ilgili kurum ve kuruluşlar tarafından yayımlanmış resmi veriler ile OSB veya ilgili şirketin kullanıcı/tüketici verileri kullanılır.

(3) Talep tahmin modelinin gerektirdiği veri setinde kullanılan verilerin talep tahmin sonucunu nasıl etkilediği, istatistiksel ve mantıksal yaklaşımlarla değerlendirilir” hükümleri uyarınca, 10 yıllık bir dönem için, abone sayısı, tüketim ve puant taleplerine ilişkin düşük, baz ve yüksek tahmin senaryoları oluşturmakla yükümlü hale getirilmiştir.

Bu tez; Konya, Karaman, Aksaray, Nevşehir, Niğde ve Kırşehir illerini kapsayan özel bir elektrik dağıtım şirketi talep tahmininin yapılmasına yöneliktir. Bu çalışmada amaçlanan, dağıtım şirketi yatırım planlarına esas teşkil edecek dağıtım bölgesine ait 10 yıllık (2017-2026) talep tahminlerinin Enerji Piyasası Düzenleme Kurumu’na sunulmasıdır. Çalışma kapsamında, ilgili Yönetmelik’te belirtildiği gibi bilimsel ve teknik geçerliliği olan yöntemler kullanılmış ve bölgesel özellikler dikkate alınmıştır. Çalışma süresince girdi olarak kullanılan ve tahmin edilen tüketim değerleri dağıtım sistemine giren enerji ve bölgedeki abone sayısı değerleridir.

10 yıllık tahminleri yapılması gereken ‘Abone Sayısı, Dağıtım Sistemine Giren Enerji ve Puant Talep’ değişkenleri için ARIMA modelleri oluşturulmuş, MATLAB programı üzerinden yapay sinir ağları ve regresyon analizi kullanılarak tahmin gerçekleştirilmiş ve sonuçlar kıyaslanmıştır. Bu çalışma kapsamında tahmin modellerinin ortaya çıkarılmasında Türkiye Elektrik İletim A.Ş. ve dağıtım şirketinden elde edilen veriler kullanılmış ve istatistiksel sonuçlar elde edilmiştir. Ayrıca yıllar içerisindeki eşdeğer iş günü sayıları tahmin modellerinde girdi olarak kullanılmıştır.

Raporun son bölümünde ise sonuçlar değerlendirilmiştir. Talep tahmin çalışmasında yaşanan problemler, dikkat edilmesi gerekenler ve çözüm önerileri, ileride yapılacak benzer çalışmalara yol göstermesi açısından belirtilmiştir.

2. KAYNAK ARAŞTIRMASI

Talep tahmini çalışması konusunda geçmişte modelleri, teknikleri, kullanılan girdileri gibi pek çok faktörün farklı olduğu çalışmalar mevcuttur. Bu tez kapsamında yalnızca elektrik enerjisinde talep tahmini çalışmaları yapıldığı için literatür konusunda da yalnızca bu konunun araştırması yapılmış bulunmaktadır.

Makas ve Karaatlı (2016) yılında yaptıkları çalışmalarında hidroelektrik enerjisinin üretim tahminini yapmak için yapay sinir ağları kullanmış olup ileri beslemeli geri yayılım sinir ağı yöntemi ile 12 aylık elektrik üretimini tahmin etmiştir. Girdiler 2007-2014 yılları arasındaki aylık ortalama yağış, aylık ortalama nispi nem ve aylık ortalama debi verileri, çıktı ise 2015 yılı hidroelektrik üretimidir.

Hamzaçebi ve Kutay (2004) yılında Türkiye'nin elektrik enerjisi tüketimini tahmin etmek için yapay sinir ağı, Box-Jenkins ve regresyon tekniğini kullanmışlardır. Sonuçlar kıyaslandığında en iyi sonucu veren tekniğin yapay sinir ağları olduğu görülmüş ve diğer tekniklerin yapay sinir ağları kullanıldığında desteklemek için çalıştırılabileceği vurgulanmıştır.

Altınay (2010) yılında Türkiye'nin aylık elektrik tüketimini 1995-2008 veri setiyle 2009 için ARIMA yöntemi kullanarak tahmin etmiştir.

Demirel ve ark. (2010) çalışmalarında 2006-2010 yılları arasındaki Gayri Safi Milli Hasıla, üretilen enerji, tüketilen enerji, nüfus, kurulu güç verileri girdi olarak kullanmış ve ANFIS ve ARMA modellerinden faydalanılmıştır. Sonuç olarak ise, ANFIS modelinin tahmin sonucu gerçeğe daha yakın olarak bulunmuştur.

Tripathy (1997) çalışmasında Hindistan için kişi başı tüketim harcamaları, ortalama elektrik tüketimi, tarımsal sulama sistemleri sayısı, kentteki hane sayısı, üretim maden ve taşocağı sektörleri katma değerlerinin 196-1990 yılları arasındaki veri girdileri ile yıllık elektrik tüketimini tahmin etmek için EKK yöntemini kullanmışlardır.

Rothe ve ark. (2009) çalışmalarında Hindistan için çoklu doğrusal regresyon modelini kullanarak sıcaklık, rüzgâr miktarı, gölge süresi, saatlik elektrik tüketimi girdi verileri ile saatlik elektrik tüketimini tahmin etmiştir.

Amarawickram ve ark. (2008) çalışmalarında 1970-2003 yılları arasındaki yıllık enerji tüketimi, nüfus, elektrik fiyatı, gayri safi yurtiçi hasıla verilerini girdi olarak kullanmışlar ve statik EG, dinamik EG, Johansen, STMS, FMOLS, PSS yöntemlerini kullanarak yıllık elektrik tüketimini tahmin etmişlerdir.

Çunkaş ve Altun (2010) çalışmalarında 1981-2002 yıllarındaki GNP, GDP, nüfus, endüstriyel üretim, petrol fiyatları, elektrik fiyatı, hane halkı sayısı, sanayi üretimi indeksi, kişi başına elektrik fiyatı verilerini kullanarak 2008-2014 yılları elektrik talebini tahmin etmişlerdir.

Hatunoğlu ve Karakaya (2011) çalışmalarında 1970-2008 yılları arasındaki nüfus, ithalat, ihracat, enerji yoğunluğu ve GDP verilerini kullanarak 2009-2030 yılları enerji talebini yapay sinir ağları ile tahmin etmişlerdir.

Es ve ark. (2014) çalışmalarında 1970-2010 yılları arasındaki GDP, nüfus, ithalat, ihracat, bina alanı ve araç sayısı verilerini kullanarak yapay sinir ağları ile 2011-2025 yılları arasındaki net enerji talebini tahmin etmişlerdir.

Bayrak ve Esen (2014) çalışmalarında 1960-2011 yılları arasındaki GDP, nüfus, ithalat, ihracat ve enerji tüketimi verilerini kullanarak yapay sinir ağları ile 2012-2020 yılları arasındaki enerji tüketimini tahmin etmişlerdir.

Yetis ve Jamshidi (2014) çalışmalarında 1992-2011 yılları arasındaki GDP, sanayi üretim indeksi ve nüfus verilerini kullanarak yapay sinir ağları ile 2012-2023 yılları arasındaki elektrik tüketimini tahmin etmişlerdir.

Birim ve Tümtürk (2016) çalışmalarında 1992-2014 yılları arasındaki GDP, nüfus, ithalat, ihracat, istihdam ve doğalgaz verilerini kullanarak yapay sinir ağları ile 2015-2023 yılları arasındaki elektrik talebini tahmin etmişlerdir.

Asilkan ve Irmak (2009) çalışmalarında yapay sinir ağları ile ikinci el otomobil fiyatları tahmin edilmiştir. Girdi olarak web sitelerinden ulaşılan ilan verileri kullanılmıştır. Yapay sinir ağları ile ulaşılan sonuçlar zaman serileri analizleri ile karşılaştırılmış olup yapay sinir ağlarının başarılı bir tahmin yöntemi olduğu sonucuna varılmıştır.

Erkaymaz ve Yaşar (2011) çalışmalarında yapay sinir ağları ile hava sıcaklığını tahmin etmişlerdir.

Yakut ve ark. (2014) çalışmalarında Borsa İstanbul (BIST) endeksinin önceki günlere ait değeri, Amerikan dolar kuru, gecelik faiz oranı ve 2005-2012 yılları arasındaki borsa endeksi değerleri kullanılarak yapay sinir ağları ve destek vektör makineleri yöntemleri ile BIST endeksi tahmin edilmiştir.

Çuhadar ve Kayacan (2005) çalışmalarında 1990-2002 yılları arasındaki konaklama istatistikleri girdi olarak, dış turizm talebi ile oluşan doluluk oranları ise çıktı olarak yapay sinir ağlarında tahmin için kullanılmıştır.

Karaatlı ve ark. (2012) çalışmalarında Ocak 2007-Haziran 2011 aylık gayri safi yurtiçi hasıla, reel kesim güven endeksi, yatırım harcamaları, tüketim harcamaları, tüketici güven endeksi, dolar kuru ve zaman verileri kullanılmış olup satılan toplam otomobil sayısı yapay sinir ağları ile tahmin edilmiştir.

Budak ve Erpolat (2012) çalışmalarında banka müşterilerinin kredi ödeme sürekliliklerini yapay sinir ağları ve lojistik regresyon modeli yardımı ile tahmin etmişlerdir. Sonuç olarak ise yapay sinir ağları tahminlerinin daha doğru sonuçlar verdiği ulaşılmıştır.

Karaali ve Ülengi (2011) çalışmalarında bilişsel haritalar yöntemi kullanarak konu uzmanı olan 5 akademisyenin görüşü alınarak işsizliği etkileyen faktörler belirlenmiştir. Bu faktörler yapay sinir ağlarına girdi olarak verilmiştir. Bu veriye ek olarak 1988-2004 yılları arasındaki veriler kullanılarak işsizlik oranı tahmin edilmiştir.

Bircan ve Karagöz (2003) çalışmalarında döviz kuru tahmini için Ocak 1991-Aralık 2002 aylık verilerini kullanarak Box-Jenkins modeli ile çözüme ulaşımlardır.

Önder ve Akgül (2009) çalışmalarında 1986-2007 tarihleri arasında Türkiye'ye gelen yabancı turist verisini kullanarak yapay sinir ağları, zaman serisi analizi ve Box-Jenkins modelleri ile 2008-2010 yılları arasındaki turist sayısını tahmin etmiştir.

ZhoumcMahon ve ark. (2002) çalışmalarında Avustralya'da bir bölgeye ait günlük su tüketimi verilerini kullanarak zaman serileri analizi ile gelecek için su tüketimini tahmin etmişlerdir.

Jones (2008) çalışmasında ilkyardım bölümlerine olan talebi tahmin etmek için aylık ve haftalık talep verisini kullanmış ve yapay sinir ağları ile gelecek için tahminde bulunmuştur.

Oruç ve Eroğlu (2017) çalışmalarında Isparta ili için doğalgaz talebi tahmini yapmışlardır. Ocak 2010-Nisan 2016 aylık verileri kullanılarak gri tahminleme, Box-Jenkins ve üstel düzleştirme yöntemi ile Mayıs 2016-Aralık 2017 dönemleri arasındaki doğalgaz talebi tahmin edilmiştir.

Güler ve ark. (2017) çalışmalarında yağlı tohumlu bitkilerin ithalat miktarını tahmin etmek için ARIMA ve yapay sinir ağları modelleri ile 1990-2016 yılları arasındaki verileri girdi olarak kullanmışlardır. Sonuç olarak 2017-2023 yılları arasındaki yağlı tohumlu bitkilerin (soya, çığit, ayçiçeği, kolza) talebi tahmin edilmiştir.

Dilaver ve Hunt (2011) çalışmalarında yapısal zaman serisi yöntemleri ile 1960-2008 yılları arasındaki GSYİH, ortalama elektrik fiyatı, sanayi sektörü yıllık elektrik tüketimi verilerini girdi olarak kullanmışlardır. Tahmin sonucu olarak ise 2009-2020 yılları arasındaki sanayi sektörü yıllık elektrik tüketimi tahminine ulaşmışlardır.

Bianco ve ark. (2009) çalışmalarında 1970-2007 yılları arasındaki elektrik tüketimi, GSYİH ve nüfus verilerini kullanarak çoklu regresyon modeli ile 2008-2030 yılları arasındaki yıllık elektrik tüketimini tahmin etmişlerdir.

Yaşar ve Uçkun (2017) çalışmalarında 1965-2015 yılları arasındaki nüfus, ithalat, ihracat, GSYİH ve GSYİH büyüme oranını girdi olarak kullanarak YSA ile 2017-2020 yıllarındaki elektrik tüketimini tahmin etmişlerdir.

Çizelge 2.1. Literatür Taraması

Yazar	Yıl	Yöntem	Bağımsız Değişkenler	Bağımlı Değişkenler
Makas ve Karaatlı	2016	YSA	Yağış, nisbi nem, debi	Hidroelektrik enerjisi üretimi
Demirel ve ark.	2010	ANFIS, ARMA	Gayri Safi Milli Hasıla, üretilen enerji, tüketilen enerji, nüfus, kurulu güç	Enerji tüketimi
Tripathy	1997	EKK	Tüketim harcamaları, ortalama elektrik tüketimi, tarımsal sulama sistemleri sayısı, kentteki hane sayısı, üretim maden ve taşocağı sektörleri katma değerleri	Elektrik tüketimi
Rothe ve ark.	2009	Çoklu doğrusal regresyon	Sıcaklık, rüzgâr miktarı, gölge süresi, elektrik tüketimi	Elektrik tüketimi
Amarawickram ve ark.	2008	statik EG, dinamik EG, Johansen, STMS, FMOLS, PSS	Enerji tüketimi, nüfus, elektrik fiyatı, gayri safi yurtiçi hasıla	Elektrik tüketimi
Hatunoğlu ve Karakaya	2011	YSA	Nüfus, ithalat, ihracat, enerji yoğunluğu ve GDP	Enerji talebi
Bayrak ve Esen	2014	YSA	GDP, nüfus, ithalat, ihracat, enerji tüketimi	Enerji tüketimi
Yetis ve Jamshidi	2014	YSA	GDP, sanayi üretim indeksi ve nüfus	Elektrik tüketimi
Birim ve Tümtürk	2016	YSA	GDP, nüfus, ithalat, ihracat, istihdam ve doğalgaz	Elektrik talebi
Asilkan ve Irmak	2009	YSA, zaman serileri	İlan verileri	İkinci el otomobil fiyatları
Yakut ve ark.	2014	YSA, destek vektör makineleri yöntemi	Borsa İstanbul (BIST) endeksinin önceki günlere ait değeri, Amerikan dolar kuru, gecelik faiz oranı, borsa endeksi	BIST endeksi
Çuhadar ve Kayacan	2005	YSA	Konaklama istatistikleri	Dış turizm talebi ile oluşan doluluk oranları
Karaatlı ve ark.	2012	YSA	GDP, reel kesim güven endeksi, yatırım harcamaları, tüketim harcamaları, tüketici güven endeksi, dolar kuru	Satılan otomobil sayısı
Budak ve Erpolat	2012	YSA, lojistik regresyon modeli	Kredi tutarı, kredinin vadesi, Aylık gelir, Kredi tutarı/aylık gelir, kefalet, ipotek, meslek, yaş, medeni durum	Banka müşterilerinin kredi ödeme süreklilikleri
Karaali ve Ülengi	2011	YSA, bilişsel haritalar yöntemi	İşsizliği etkileyen faktörler	İşsizlik oranı
Bircan ve Karagöz	2003	Box-Jenkins	Döviz kuru geçmiş veriler	Döviz kuru tahmini
Önder ve Akgül	2009	YSA, zaman serisi analizi ve Box-Jenkins	Yabancı turist verisi	Turist sayısı

ZhoumcMahon ve ark.	2002	Zaman serisi analizi	Su tüketimi geçmiş verileri	Su tüketimi
Jones	2008	YSA	İlkyardım bölümlerine olan geçmiş veriler	İlk yardım bölümlerine olan talebi
Oruç ve Eroğlu	2017	Box-Jenkins ve üstel düzleştirme yöntemi	Doğalgaz talebi geçmiş verileri	Doğalgaz talebi
Güler ve ark.	2017	YSA, ARIMA	Yağlı tohumlu bitkilerin ithalat miktarı geçmiş verileri	Yağlı tohumlu bitkilerin ithalat miktarı
Dilaver ve Hunt	2011	Zaman serisi yöntemleri	GSYİH, Ortalama elektrik fiyatı, sanayi sektörü yıllık elektrik tüketimi	Elektrik tüketimi
Bianco ve ark.	2009	Çoklu regresyon modeli	Yıllık elektrik tüketimi, GSYİH, nüfus	Elektrik tüketimi
Yasar ve Uckun	2017	YSA	Nüfus, ithalat, ihracat, GSYİH ve GSYİH büyüme oranı	Elektrik tüketimi

3. MATERYAL VE YÖNTEM

Bu bölümde çalışmada kullanılan materyal ve yöntemler hakkında bilgiler verilmiştir.

3.1. Talep Tahmini

Talep, tüketicilerin bir ürün veya hizmeti belirli bir fiyat seviyesinden almaya hazır oldukları miktara denir. (Tekin, 1996) Talep tahmini ise geçmiş veriler ışığında gelecek süreçler için müşteri taleplerini belirli bir dönemde öngörmektir. Talep tahminleri hiçbir zaman 100% doğruluk ile yapılamaz, her tahmin yönteminin hata payı vardır.

Talep tahminleri, tahmin edilmek istenen döneme göre kısa, orta ve uzun vadeli olarak yapılabilmektedir. Kısa vadeli talep tahminleri bir saat ile bir hafta arasında değişebilir, orta vadeli talep tahminleri bir hafta ile bir yıl arasında değişebilir, uzun vadeli talep tahminleri ise bir yıl ve daha fazlası için kullanılır. Talep tahmini aşağıdaki ilkelere dayanır:

- Talep tahmini hiçbir zaman gerçek talebin yerini tutamaz.
- Talep tahmini yönteminin belirlenmesi, tahmin edilecek döneme, verilerin bulunma şekline bağlıdır.
- Talep tahmini yapılmadan önce performansın denenmesi gereklidir.
- Küçük ürün grupları için değil, büyük ürün grupları için yapılması daha uygundur.
- Tahminlerin doğruluğunun, tahmin yapılan süre ile ters orantılı olduğu düşünülmektedir. (Yazıcıoğlu, 2010)

Talep tahmini yapmadan önce şirketin hangi çevre ortamında bulunduğu, hangi ürünleri ürettiği, şirketin şimdiki durumu ve gelecekte ulaşmak istediği durum, rakiplerin durumu, fiyat ve talep ilişkisi, iktisadi değişimler, endüstriyel değişimler, teknolojik gelişim, sosyal değişimler, ulusal ve uluslararası eğilimler gibi talebi etkileyen etkenler ve ağırlıkları belirlenmelidir (Bolt 1994).

3.2. Talep Tahmininde Kullanılan Yöntemler

Talep tahminlerinde kullanılan yöntemler için literatürde farklı sınıflandırmalar bulunmaktadır. Ancak temelde kalitatif, kantitatif ve yapay zeka tabanlı yöntemler olmak üzere 3 sınıfa ayrılabilir. Bu tez kapsamında talep tahmini yöntemlerinde kantitatif ve

yapay zeka tabanlı yöntemler kullanıldığı için bu konular daha detaylı anlatılacaktır.

3.2.1. Kalitatif yöntemler

Kalitatif tahmin yöntemleri, “subjektif” veya “ölçüt karar tabanlı” yöntemler de denebilir, tahmin ve genelleme yapmak için öncelikle insan kapasitesini kullanır (Viglioni, 2007). Bilimsel yöntemler yerine hissi ve şahsi görüşlere dayanarak sezgisel yargılarla hareket eden tahmin yöntemleridir. Senaryo analizi, delphi yöntemi, uzman panelleri, anket yöntemi gibi teknikler kalitatif yöntemlere örnek verilebilir.

3.2.2. Kantitatif yöntemler

Nicel yöntemler, geçmiş dönem gözlem değerlerine dayalı analizler yapan tahmin modellerini kapsamaktadır. Kullanılan yöntemler; incelenen değişkende gözlenen gelişmelerin analiz edilmesi, veri serisinin dinamik özelliklerinin belirlenmesi ve bu özelliklerin matematiksel bir fonksiyon ile ifade edilerek geleceğe ilişkin öngörülerin türetilmesini içermektedir. Nicel tahmin yöntemleri genel olarak ilişkiye dayalı (nedensel) ve zaman serileri yöntemleri olmak üzere iki gruba ayrılmaktadır. (Başoğlu, 2003)

3.2.2.1. İlişkisel yöntemler

İlişkisel yöntemlerde bir değişkenin sonraki süreçler için ne olacağını tahmin etmekten daha çok iki ya da daha fazla değişkenin arasındaki ilişki açıklanmaya çalışılmaktadır. Bağımlı değişken ile ilişkisi bulunan değişkenin veya değişkenlerin saptanması ve bu ilişkiye uygun bir matematiksel ifadenin bulunması, ilişkisel yöntemlerin temel amacını oluşturmaktadır. İlişkiye dayalı tahmin yöntemlerinin temelini regresyon analizi oluşturmaktadır. (Fretchling, 2012)

Regresyon analizi:

Regresyon analizi bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi çözümlenmeye çalışan tekniklerdir. Bağımsız değişken yalnızca bir değişken ise tek değişkenli regresyon analizi, birden fazla ise çok değişkenli regresyon analizi olarak adlandırılır.

Regresyon analizi için basit doğrusal regresyon denklemi aşağıdaki gibi ifade

edilmiştir.

$$Y = \beta_0 + \beta_1 x + \epsilon \quad (3.1)$$

Bu denklem, $x = 0$ olduğunda regresyon doğrusunun dikey eksenini kestiği noktayı göstermektedir. Doğrusal fonksiyonun eğimi β_1 , bağımsız değişken x 'teki bir birimlik değişiminin bağımlı değişken Y 'de (Y cinsinden) ne kadarlık bir değişim meydana getirdiğini gösteren regresyon katsayısıdır. ϵ ise, rastsal hata terimidir. Artık veya kalıntı adı da verilmektedir. $\epsilon = Y - \hat{Y}$, tahmini bağımlı değişkenin değerini göstermektedir. Gerçek hayat uygulamalarında β_0 ve β_1 değerleri bilinmiyorsa, ana kütlede örnekler alınarak bunların tahmincileri olan b_0 ve b_1 kullanılarak (3.1) no'lu denklem,

$$y = b_0 + b_1 x + e \quad (3.2)$$

olarak yazılır.

Ana kütle ve örnek için çoklu doğrusal regresyon denklemleri ise sırasıyla

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + e \quad (3.3)$$

$$Y = b_0 + b_1 x_1 + b_2 x_2 + \dots + b_n x_n + e \quad (3.4)$$

Şeklinde ifade edilmektedir. (Kalaycı, 2003)

Regresyon analizi, yapılan tahmin çalışmalarında çok sık kullanılan yöntemlerden biridir ve bu yöntemle güvenilirliği yüksek katsayılara ulaşılarak başarılı tahminler yapılabilmektedir. (Feinberg ve Genethliou, 2005)

Korelasyon Analizi:

Korelasyon analizi değişkenler arasındaki ilişkinin derecesini ölçen istatistiksel bir yöntemdir. Herhangi bir değişkenin değişmesi durumunda diğer bir değişken de buna bağlı olarak artıyor veya azalıyor ise değişkenler arasında korelasyon vardır. Korelasyon katsayısına ulaşılarak değişkenler arasındaki ilişki belirlenmiş olur. İlişkinin derecesine göre doğruluk derecesi de değişmektedir.

R korelasyon katsayısını göstermektedir.

$$R = \frac{n \sum X_i Y_i - \sum X_i \sum Y_i}{\sqrt{[n \sum X^2 - (\sum X)^2] [n \sum Y^2 - (\sum Y)^2]}} \quad (3.5)$$

Korelasyon katsayısının aldığı değerler aşağıdaki gibi yorumlanır. (Yücesoy, 2011)

0.90-1.00 : Çok yüksek korelasyon

0.70-0.90: Yüksek korelasyon

0.40-0.70: Normal korelasyon

0.20-0.40: Düşük korelasyon

0.00-0.20: Çok düşük korelasyon

3.2.2.2. Zaman serileri yöntemleri

Zaman serileri geçmiş zaman verilerini inceleyerek gelecek için tahminler yapan yöntemlerdir. Geçmiş zaman verileri analiz edilir ve bu doğrultuda bir model kurularak gelecek verilere yön verilir.

Zaman serilerini etkileyen 5 tane ana faktör vardır.

- Ortalama: Zaman serisi verileri bir ortalama etrafında yoğunlaşmaktadır.
- Eğilim: Serinin aynı yönde değişip değişmediği incelenir, bunun için regresyon analizi kullanılabilir.
- Mevsimlik değişim: Verilerin mevsimlere veya belirli aylara göre değişiklik göstermesi durumudur.
- Konjonktürel değişim: Verilerde bir yıldan fazla meydana gelen değişiklikler durumudur.
- Rastgele olaylar: Düzensiz veya rastgele gerçekleşerek veri setinde anlaşılması kolay olmayan değişiklikler durumudur.

Ekonomi ve iş dünyasındaki belirsizlikler nedeniyle, ekonomik zaman serilerinin gelecekte göstereceği seyri tahmin etmek, planlama ve karar alma açısından önemlidir. Zaman serisi yöntemlerinde geleceğin tahmini yanında geçmiş dönemlerin incelenmiş olması; geçmişteki olumlu ve olumsuz gelişmelerin tespit edilmesine, nedenlerinin araştırılmasına ve yapılan yanlışların tekrarlanmaması için gerekli tedbirlerin alınmasına da imkan sağlamaktadır. Sayılan bu özellikleri nedeniyle bilhassa orta ve kısa dönem tahminlerine ihtiyaç duyulan her alanda yaygın olarak kullanılmaktadırlar. (Akgül,2003)

3.2.2.2.1. Mekanik tahmin yöntemi

Mekanik tahmin yöntemi en basit tahmin yöntemlerinden biridir. Bu yöntemde, zaman serisinin son dönemde aldığı değer, bir sonraki dönem için kullanılır. Formülü aşağıda verildiği gibidir.

$$y_{t+1}=y_t \quad (3.6)$$

Eğer zaman serilerinde trend gözlemleniyorsa tahmin trend yönünde yapılır. Serinin mevsimsellik göstermesi durumunda ise dönemler belirlenerek tahmin için önceki mevsim dönemi kullanılır. 3 aylık seri için formül aşağıdaki gibidir (Hanke, 1992).

$$y_t = y_{t-3} + \frac{(y_t - y_{t-1}) + \dots + (y_{t-3} - y_{t-4})}{4} \quad (3.7)$$

3.2.2.2.2. Hareketli ortalamalar yöntemi

Bir zaman serisinde oluşan tesadüfilik durumu, yapılan tahminin serideki verilerin ortalamasından uzaklaşmasına sebep olmaktadır. Bu uzaklaşmanın önlenmesi için geçmiş değerlerin ortalaması alınmaktadır. Alınan bu ortalama ise gelecek dönemler için bir tahmin olarak kullanılmaktadır. Hangi dönemlerin ortalamasının alınacağı konusuna ise tahminde bulunacak kişi gözlemlerine dayanarak karar vermektedir. Hareketli ortalamalar yöntemi; basit, ağırlıklı ve çift hareketli ortalamalar olmak üzere 3 ayrı sınıfta incelenebilir.

Basit hareketli ortalama yöntemi:

Basit hareketli ortalama yönteminde önceden belirlenmiş olan n dönemin ortalaması, bir sonraki sürecin tahmini olarak kullanılır. Bu yöntemde hata minimizasyonu için, kullanılan n dönem sayısı deneme yanılma yöntemi ile belirlenebilir (Armutlulu, 2000).

Ağırlıklı hareketli ortalama yöntemi:

Basit hareketli ortalama yönteminde ağırlıklar her dönem için eşit alındığı için dönem değerleri toplamı dönem sayısına bölünebilmektedir; ağırlıklı hareketli ortalama yönteminde ise her döneme farklı ağırlık verilmekte ve ağırlıklar ve dönem değerleri

çarpımı ağırlıklar toplamına bölünmektedir.

Çift hareketli ortalama yöntemi:

Çift hareketli ortalama yöntemi, polinom şeklindeki seriler için uygulanan bir yöntemdir. Bu yöntem bir seri için hareketli ortalamasının hesaplanmasının ardından birinci serinin hareketli ortalaması olarak ikinci bir serinin hesaplanması temeline dayanmaktadır (Hanke, 1992).

3.2.2.2.3. Üstel düzeltme yöntemi

Hareketli ortalamalar yöntemlerindeki sorun çıkarabilecek durumlardan dolayı üstel düzeltme yöntemlerinin kullanılması önerilmektedir (Armutlulu, 2000). Gerçekleşen her dönem verisi modele kolay bir şekilde dahil edilebildiği için kullanışlı ve uygulaması kolaydır.

Basit üstel düzeltme yöntemi:

Basit üstel düzeltme yöntemi, veri setinde bir trend veya mevsimsel dalgalanmaların olmadığı tahminlerde kullanılabilir. Formülü aşağıdaki gibidir.

$$y_t' = a * y_{t-1} + (1-a) * y_{t-1}' \quad (3.8)$$

Bu denklemde y_t' t döneminin tahmini değeri, y_{t-1} t-1 döneminde gerçekleşen değeri, a ise düzeltme sabitini vermektedir. Düzeltme sabiti 0 ile 1 arasında olmalıdır. Literatürdeki uygulamalarda düzeltme sabiti için 0,01 ile 0,3 arasındaki değerlerde tahmin sonuçlarının daha uygun olduğu görülmüştür (Orhunbilge, 2002).

Brown' un tek parametrelili doğrusal üstel düzeltme yöntemi:

Brown' un tek parametrelili doğrusal üstel düzeltme yöntemi zaman serisinde trend varsa kullanılır. Başlangıç denklemleri aşağıdaki gibidir (Armutlulu, 2000).

$$y_t^1 = a * y_t + (1-a) * y_{t-1}^1 \quad (3.9)$$

$$y_t^2 = a * y_t^1 + (1-a) * y_{t-1}^2 \quad (3.10)$$

y_t^1 = tekli üstel düzeltilmiş sonuçtur.

y_t^2 = ikili üstel düzeltilmiş sonuçtur.

y_{t-1}^1 ve y_{t-1}^2 değerleri y_t değeri ve gözlemlere göre önceki dönem değerlerinin ortalaması alınarak bulunmaktadır. Çift hareketli ortalama yönteminde kullanıldığı gibi a_t ve b_t istatistikleri aşağıdaki gibi hesaplanmaktadır.

$$a_t = y_{t+1}^1 - (y_t^1 - y_t^2) = 2y_t^1 - y_t^2 \quad (3.11)$$

(3.11) ve (3.12) istatistikleri kullanılarak m sonrasındaki dönemin tahmini aşağıdaki gibi hesaplanır. (Orhunbilge, 2002)

$$\begin{aligned} \hat{y}_{t+m} &= a_t + b_t * m \\ b_t &= a_t / (1-a) * (y_t^1 - y_t^2) \end{aligned} \quad (3.12)$$

Brown' un ikinci derece üstel düzeltme yöntemi:

“Doğrusaldan eğrisel düzeltmeye geçerken üçüncü bir düzeltme eklenmekte ve ilave bir parametre modele girmektedir“ (Orhunbilge, 1999). İkinci derece üstel düzeltme konusundaki denklemler (3.13)-(3.18) eşitliklerinde verilmiştir. (Orhunbilge, 1999)

$$y_t^1 = a * y_t + (1-a) * y_{t-1}^1 \quad (3.13)$$

$$y_t^2 = a * y_t^1 + (1-a) * y_{t-1}^2 \quad (3.14)$$

$$y_t^3 = a * y_t^2 + (1-a) * y_{t-1}^3 \quad (3.15)$$

$$a_t = 3y_t^1 - 3y_t^2 - y_t^3 \quad (3.16)$$

$$b_t = a/2(1-a) * [6-5a)y_t^1 - (10-8a)y_t^2 + (4-3a)y_t^3] \quad (3.17)$$

$$c_t = a^2 / (1-a)^2 * (y_t^1 - 2y_t^2 + y_t^3) \quad (3.18)$$

Tahmin denklemi ise aşağıdaki gibidir (Orhunbilge, 1999).

$$\hat{y}_{t+m} = a_t + b_t * m + 1/2c_t * m^2 \quad (3.19)$$

Mevsimsel üstel düzeltme-winters tahmin yöntemi:

Mevsimsel üstel düzeltme yöntemi ile ilgili ilk çalışma 1960 yılında Winters tarafından yapılmıştır. Bu yöntem doğrusal üstel düzeltme ile benzerlik göstermektedir. Ancak mevsimsel üstel düzeltme yöntemi ile veri setindeki mevsimsellik dağılımları da düzeltilmektedir. Bu yöntemde tahminler aşağıdaki formüllerde olduğu gibi yapılmaktadır (Orhunbilge, 2002).

$$y_t' = a * y_t + (1-a) * (y_{t-1}' + b_{t-1}) \quad (3.20)$$

$$b_t = \beta (y_t' - y_{t-1}') + (1-\beta) * b_{t-1} \quad (3.21)$$

$$y_{t+m} = y_t' + b_t * m \quad (3.22)$$

(3.20) numaralı denklemde önceki dönemin trendi eklenerek y_t ' değeri hesaplanır. (3.21) numaralı denklemde trend güncellenmektedir. Denklemlerdeki a ve β değerleri düzeltme sabitleridir ve 0 ile 1 arasında yer alır. En uygun düzeltme sabitlerine deneme yanılma yöntemi ile ulaşılabilir.

3.2.2.2.4. Box-Jenkins tahmin yöntemi (arırma)

1970 yılında George Box ve Gwilym Jenkins tarafından bulunmuştur. Box-Jenkins modellerinin başlıca özelliđi incelendiđinde deđişkenin mevcut verisinin, geđmiş verilerinin ađırlıklı toplamı ve rassal deđişikliklerinin bileşimine dayandıđı görülmektedir (Akgün, 2003). Box-Jenkins tahmin yönteminin kısa ve orta dönem tahminleri için gerçekliđinin yüksek olması, modellerinin çokluđu ve denenebilir olması sebebi ile yaygın kullanım alanı vardır. Bu modeller yalnızca durađan veya durađanlaştırılmış veri setlerinde uygulanabilmektedir. Bu yüzden durađanlık model için önem kazanmaktadır. Bir sürecin durađan olması (3.23)-(3.25) numaralı eşitliklere bađlıdır.

$$E(Y_t) = \mu \quad (3.23)$$

$$\text{Var}(Y_t) = E(Y_t - \mu)^2 = \sigma^2 \quad (3.24)$$

$$\gamma_k = E[(Y_t - \mu)(Y_{t+k} - \mu)] \quad (3.25)$$

Burada (3.23) numaralı denklem ortalamayı, (3.24) numaralı denklem varyansı, (3.25) numaralı denklem ise kovaryansı göstermektedir.

Bir zaman serisi veri setindeki durađanlıđı kontrol etmek için literatürde yöntemler mevcuttur. Bu yöntemlerden biri otokorelasyon fonksiyonuna dayanmaktadır. Örnek olması açısından yalnızca bu yöntem anlatılacaktır.

$$P_k = \gamma_k / \gamma_0 \quad (3.26)$$

Otokorelasyon katsayısı (3.26) numaralı formülle gösterilmiştir. Otokorelasyon katsayısı -1 ile 1 arasında deđerler almaktadır. Otokorelasyon, veri setinden hesaplanabilmektedir. Bunun için ise kovaryans ve varyansın hesaplanması gerekmektedir.

“ P_k 'nın istatistiki açıdan anlamlılıđı, standart hatasıyla belirlenir. Tesadüfi bir

değişkenin $k= 1, 2, 3, \dots$ gecikme değerleri için hesaplanan örnek otokorelasyon katsayılarının örnekleme dağılımının ortalaması sıfır, standart hatası yaklaşık olarak $1/(n^{1/2})$ dir. Fakat gecikme değeri $k \leq 1$ için örnek otokorelasyon katsayısının standart hatası (3.27) numaralı formüle göre hesaplanır.

$$s[\hat{\rho}_k] = \sqrt{\frac{1}{n} [1 + 2] \sum_{k=1}^k (\hat{\rho}_k)^2} \quad (3.27)$$

Eğer çeşitli gecikmeler için örnekleme dağılımından hesaplanan oto korelasyonlar $\pm Zc * 1/(n^{1/2})$ aralıkları içinde ise otokorelasyon değerlerinin sıfır olduğu ve serinin tesadüfi olduğuna karar verilir. Eğer bir seri için hesaplanan otokorelasyon katsayılarının değerleri birkaç gecikmeden sonra sıfıra yaklaşıyor, yani $\pm Zc * 1/(n^{1/2})$ limitleri arasında kalıyorsa bu seri durağandır, aksi takdirde serinin durağan olmadığına karar verilir” (Çuhadar, 2006).

3.2.2.2.4.1. Durağan ARIMA modelleri

Bir seri durağan olduğu zaman talep tahmini için bu modeller kullanılmaktadır. Durağan ARIMA modellerinden en çok kullanılanları; otoregresif AR(p), hareketli ortalama MA(q), otoregresif hareketli ortalama ARMA(p,q) dur.

Otoregresif Model AR(p): Bu modellerde sonuç, talep tahmini yapılacak dönemden p dönem kadar öncesinin ağırlıklı toplamı alınarak rassal değişkenin eklenmesi ile bulunur.

Hareketli Ortalama Modelleri MA(q): Bu modellerde tahmini yapılacak dönemden q dönem öncesine kadar alınan zaman serisinde geçmişe gittikçe azalan ağırlık verilir.

Otoregresif Hareketli Ortalama Modelleri ARMA(p,q): AR(p) ve MA(q) modellerini birlikte kullanmanın daha uygun olacağı modeller için kullanılır. ARMA(p,q) modelleri, en genel durağan stokastik süreç modelleri olup, geçmiş gözlemlerin ve geçmiş hata terimlerinin doğrusal bir fonksiyonudur. (Çuhadar, 2006).

3.2.2.2.4.2. Durağan olmayan ARIMA modelleri

Bir zaman serisinin ortalamasında veya varyansında zamana bağlı bir trend görünüyorsa veya veriler durağan değilse durağan zaman serileri için kullanılan AR(p), MA(q) ve

ARMA(p,q) modellerinin kullanılması doğru olmaz. Bu yüzden zaman serisinin durağanlaştırılması gerekmektedir. Bunun için durağan olana kadar serinin farkının alınması gerekir.

Otoregresif Entegre Hareketli Ortalama Modeli ARIMA(p,d,q): Durağan olmayan zaman serilerinin d dereceden farkı alınarak durağan hale getirildikten sonra AR(p) ve MA(q) modellerinin birleştirilmesiyle oluşan modellerdir. d fark alma derecesi belirlendikten sonra p ve q değerlerine karar verilerek model oluşturulur.

Durağan olmayan seri y_t ile ifade edilirse farkı alınarak durağan hale getirilmiş seri w_t ile gösterilmektedir. ARIMA(p,d,q) modelinin gösterimi (3.28) numaralı formülde gösterildiği gibidir.

$$w_t = \phi_1 w_{t-1} + \phi_2 w_{t-2} + \dots + \phi_p w_{t-p} + \epsilon_t - \theta_1 \epsilon_{t-1} - \theta_2 \epsilon_{t-2} - \dots - \theta_q \epsilon_{t-q} \quad (3.28)$$

3.2.3. Yapay zeka tabanlı yöntemler


Yapay zeka temelde insan beynindeki düşünce sistemini anlamaya ve bu doğrultuda bilgisayar fonksiyonlarını geliştirmeye çalışır. Son zamanlarda araştırmacıların yoğunlukla ilgilendiği bir alandır. Literatürde en fazla bulunan yöntemleri yapay sinir ağları, sezgisel algoritmalar ve bulanık mantık yöntemleridir. Bu tez kapsamında ele alınan zaman serisi yapay sinir ağları yöntemiyle de çözüldüğü için daha detaylı açıklanacaktır.

3.2.3.1. Yapay sinir ağları (ysa)

“Yapay sinir ağları, biyolojik sinir sistemlerinin çalışma prensibini taklit eden matematiksel modellerdir. Yapılan tanımlardaki en önemli ortak nokta YSA’ların birbirlerine hiyerarşik olarak bağlanan ve bir değere sahip yapay hücrelerden oluşmasıdır” (Öztemel 2012, 41,48). YSA; öğrenme, hatırlama, keşfetme, yeni bilgiler oluşturma gibi özellikleri taşıyan olayları anlayarak çözüm üretmeye çalışan bilgi işleme sistemidir. YSA’nın çalışmasında etkili olan temel etmen yapay sinir ağları hücreleridir.

Yapay sinir ağları genelde tahmin, sınıflandırma, veri ilişkilendirme, veri yorumlama, veri filtreleme, resim işleme, el yazısı, optimizasyon, doğrusal olmayan sistem modelleme gibi alanlarda kullanılmaktadır. Kullanılması diğer sistemlere göre daha kolay ve kontrol edilebilir, aynı zamanda hata toleransı daha düşük ve yeni bir

veriyle karşılaştığında yorum yapabilme özelliğine sahip olduğu için pek çok alanda kullanılmaktadır.



Şekil 3.1 Yapay Sinir Ağı (Gürsoy, 2012)

Yukarıdaki şekilde görüldüğü gibi, yapay sinir hücrelerinin bileşenleri; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktıdır.

Girdiler:

Bir yapay sinir hücresine dış dünyadan gelen bilgilerdir. Bunlar ağıın öğrenmesi istenen örnekler tarafından belirlenir. Yapay sinir hücresine dış dünyadan olduğu gibi başka hücrelerden veya kendi kendisinden de bilgiler gelebilir. (Öztemel, 2003).

Ağırlıklar:


Girişlerdeki bilgilerin sinirler üzerindeki etkisini belirleyen katsayılardır. Tüm girişlerin ayrı katsayıları vardır.

Toplama fonksiyonu:

Hücreye gelen net girdiyi toplamak için kullanılan fonksiyondur. Genellikle ağırlıklı toplama fonksiyonu yaygın olarak kullanılır. Bu fonksiyonda hücreye her iletilen girdi kendi ağırlığı ile çarpılır ve bu değerlerin toplamı alınır. Sonraki aşama için bu toplam aktivasyon fonksiyonuna gönderilir ve oradan diğer sinir hücrelerine iletilir.

Aktivasyon fonksiyonu:

Aktivasyon fonksiyonu toplama fonksiyonundan gelen bilgilerden bir çıktı üretir. Aktivasyon fonksiyonun doğru seçilmesi çıktının doğruluğunda önemli bir etkidir. Uygun aktivasyon fonksiyonunun seçimi deneme yanılma yöntemi ile belirlenebilir. Literatürde kullanılmış olan farklı aktivasyon fonksiyonları mevcuttur ve yaygın olarak doğrusal olmayan çeşitleri kullanılır. YSA'nın doğrusal olmama özelliği aktivasyon fonksiyonundan gelir denilebilir. En çok kullanılan fonksiyonu sigmoiddir. Sürekli artış gösterir ve türevi alınabilir şekildedir. Çıktı değeri ise [0-1] arasındadır.



Şekil 3.2 Sigmoid fonksiyonu (Şen, 2004)

Çıktılar:

Aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Bu çıktı değeri başka bir hücreye ya da dış ortama gönderiliyor olabilir.

Yapay sinir ağlarının genel özellikleri aşağıdaki gibidir:

- 1- Paralel Çalışma: Bütün işlem bölümleri aynı anda çalıştıkları için sonucun çıkması çok hızlı olmaktadır.
- 2- Genelleme: Eğitilmiş bir ağa, girdi verisinin hepsi değil, yalnızca bir bölümü verildiğinde bile ağ, hafızadan bu girişe en yakın olanını seçerek tam bir giriş verisi alıyormuş gibi kabul eder ve buna uygun bir çıkış değeri üretir. Veri YSA'ya, eksik, bozuk veya daha önce hiç karşılaşmadığı şekilde girilse bile, ağ kabul edilebilir en uygun çıkışı üretecektir. Bu özellik ağın genelleştirme özelliğidir (Tebelkis, 1995).

- 3- Dağıtılmış Hafıza: YSA' da bilgi ağı yayılır ve bu bilgi ağıdaki bağlantıların tümündedir. Bir bütün olarak veriler tutulmaktadır, bu yüzden dağıtılmış hafızaya sahiptir.
- 4- Öğrenme: YSA, veri setiyle eğitildiği için süreci tecrübe eder ve sonraki gelen testlerde sonucu verebilir. Bu özelliği YSA'nın en önemli özelliklerinden biridir. Yapısında bu özellik olduğu için karmaşık problemleri çözebilirler.
- 5- Dereceli bozulma: YSA dağıtılmış hafızaya sahip olduğu için ağın tümünde bilgiler vardır ve bütün olarak bilgileri tutar. Bilgiler yalnızca herhangi bir bölgede kayıtlı olmadığı için herhangi bir hücre veya ağıdaki bozulma süreci etkilemez. Bu yüzden hata toleransı vardır ve dereceli bozulma yaşanır.
- 6- Kendi ilişkisini oluşturma: YSA verilen bilgiler ışığında kendi ilişkilerini oluşturabilirler. Bu özelliklerinden dolayı bir "akıllı karakutu" olarak tanımlanabilirler (Tenti, 1996).
- 7- Sınırsız sayıda değişken ve parametre: YSA, sınırsız sayıda değişken ve parametre kullanabilir. Bu yüzden bir problemin çözümünde yalnızca sonuç için kullanılması gereken verinin sisteme verilmesi gerekir.
- 8- Doğrusal olmayan yapı: Bu özelliği YSA'nın en önemli özelliklerinden biridir. YSA içerisindeki hücrelerin doğrusal olmaması nedeni ile karşılaşılan herhangi bir doğrusal olmayan probleme çözüm sağlayabilirler. Bu özellik ile diğer çözüm sağlayıcılara kıyasla büyük ölçüde tercih edilmektedirler.
- 9- Bilginin saklanması: YSA'da ağ bağlantılarının değerleri ölçülüp bu değerler bağlantılarda saklanmaktadır. (Hamzaçebi, 2004)
- 10- Adaptasyon: YSA tanımı veya parametreleri değişen probleme ya da sisteme uygun çözümler sağlamak için tekrar tekrar eğitilebilir. Bu özellik YSA'nın hedef tanıma, uyarlamalı örnek tanıma, sınıflandırma, işaret işleme, otomatik kontrol ve sistem kimliklendirme ve modelleme gibi alanlarda kullanımını yaygınlaştırmıştır (Bulgan, 2013).


3.2.3.1.1. Yapay sinir ağı modelleri

Yapay sinir ağı, içerisindeki ağların yönlerine göre ve katman sayısına göre sınıflandırılmaktadır. Ağların yapısına göre ileri beslemeli ve geri beslemeli ağlar olmak üzere ikiye ayrılır.

İleri beslemeli yapay sinir ağı:

İleri beslemeli ağlarda genellikle işlemler katmanlar halinde ilerler, hücreler katmanlara ayrılmıştır. Katmanlar arasında işlem elemanları aracılığı ile bağlantı kurulabilir ancak aynı katman içerisinde işlem elemanları birbirleri ile bağlantı kuramazlar. Bilgi ilk olarak girdi katmanına gelir ve buradan gizli katmana iletilir. Gizli katmanda ağırlıkları ile birlikte çıktı katmanına iletilir. Bilginin bir katmandan çıkışı ağırlıklar ile sonraki katmanın girişi olmaktadır. İleri beslemeli yapay sinir ağındaki bu bilgi akışı yalnızca tek yönlü olmaktadır, geri besleme yapılmaz. Bu modelde gecikme yoktur.

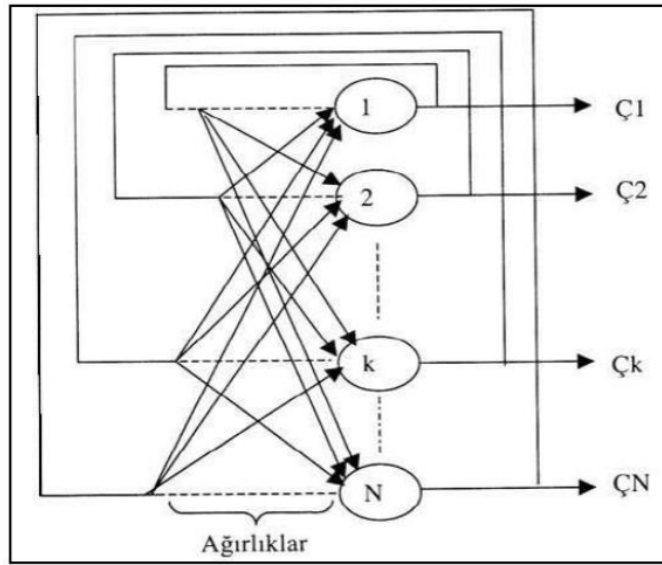
Gizli katmandaki nöronların doğrusal olmamasından dolayı ağı tamamı da doğrusal değildir. Ağda kullanılan katmanlardaki nöron sayılarının belirlenmesi için kullanılan bir yöntem yoktur, deneme yanılma ile uygun çözüm bulunabilir.



Şekil 3.3 İleri Beslemeli Yapay Sinir Ağı (Deveci,2012)

Geri beslemeli yapay sinir ağıları:

Geri beslemeli yapay sinir ağılarında, geri besleme yaygın olarak bir gecikme elemanı sayesinde yapılabilmektedir. Katmanlar arasındaki hücrelerde ve aynı zamanda katmanlar içindeki hücrelerde geri besleme olmaktadır. Hatalar çıkış noktasından giriş noktasına doğru düzeltilmeye çalışılır. Katman sayısı ileri beslemeli yapay sinir ağılarındaki ile aynıdır. Ancak bazı problem çeşitlerine göre gizli katman sayısı artırılabilir.




Şekil 3.4 Geri Beslemeli Yapay Sinir Ağları (Serttaş, 2011)

3.2.3.1.2. YSA' da öğrenme algoritmaları

Yapay sinir ağıları insan beyninden esinlendiği için tıpkı bir insan beyni gibi davranışlar sergilemektedir. İnsan beyni doğumıyla başlayan süreçte duyu organları aracılığı ile öğrenir ve tecrübe eder. Böylece karşılaştığı durumlarda bu öğrendiklerini ve tecrübelerini kullanarak tepki verebilir. Yapay sinir ağıları da aynı şekilde öğrenme algoritmalarına sahiptir. Öğrenme algoritmaları, çıktıyı etkileyen ağırlıkların belirlenmesini sağlamaktadır. Bu ağırlıklar örnekler aracılığı ile belirlenmektedir. Katmanlardaki ağırlıklar karşılaştığı her örnek problemde kendi ağırlıklarını değiştirmektedir. Yapay sinir ağılarında öğrenme kuralı temeli kolay bir model olan Hebbian öğrenme kuralına dayanmaktadır. Öğrenme kuralları; danışmanlı, danışmansız ve takviyeli öğrenme olmak üzere 3 gruba ayrılmaktadır.

Danışmanlı öğrenme:

Danışmanlı öğrenmede, ağa verilen örnek girdilerin yanı sıra beklenen çıktılar da verilmektedir. Burada amaç süreci haritalamaktır.




Şekil 3.5 Danışmanlı Öğrenme (Olgun,2009)

Ağa verilen girdi ve çıktı bilgileri ile ağ süreci öğrenir. Ağ girdileri kontrol ederek kendisi bir çıktı üretir ve bu çıktıyı beklenen çıktı ile karşılaştırır. Öğrenme ile güncel hatayı en aza indirmek için bağlantılarda bulunan ağırlıklar yeniden düzenlenir. Hata oranı kabul edilene kadar bu süreç tekrar edilir.

Danışmansız öğrenme:

Ağa hedef çıktı verilmiyorsa bu tarz öğrenmelere danışmansız öğrenme denir. Bu öğrenme algoritmasında ağa girilen girdiler aynı zamanda çıktı görevi de görmektedir.



Şekil 3.6 Danışmansız Öğrenme (Olgun,2009)

Takviyeli öğrenme:

Takviyeli öğrenme algoritması temelde danışmanlı öğrenme yöntemine benzer ancak danışmanlı öğrenmede hedef çıktının bulunması için bir öğretmen veya danışmana

ihtiyaç duyulurken takviyeli öğrenmede ağın sonuçlarının hangi oranda doğru olduğunun hesaplanması için bir derece belirlenir.

3.2.3.1.3. YSA'da öğrenme kuralları

YSA'ya düzenin öğretilmesi için çok sayıda geliştirilmiş algoritma literatürde bulunmaktadır. En yaygın olanları aşağıdaki gibidir:

Hebb Kuralı: 1949 yılında Hebb tarafından oluşturulmuş olan bu algoritma YSA içerisinde en çok kullanılan algoritmadır. Bu kurala göre birbirleriyle etkileşim halinde olan nöronlar matematiksel olarak aynı işaretli ise aralarındaki ağırlık güçlenmektedir, aksi durumda ise zayıflamaktadır (Hebb, 1949). Bu şekilde ağın öğrenmesi beklenir.

Hopfield Kuralı: Hebb kuralına mantık olarak benzerlik göstermektedir. Hebb kuralından farkı bağlantıların ne kadar güçlenmesi veya zayıflatılması gerektiği bilgisi öğrenme katsayısı ile sisteme verilir.

Delta Kuralı: Temelde Hebb kuralının geliştirilmiş hali olup YSA içerisinde en çok kullanılan kuraldır. Bu kuralın amacı ulaşılmak istenen sonuç ile elde edilen sonuç arasındaki farkı minimuma düşürmektir. Bu işlem YSA elemanlarının ağırlıklarının yeniden hesaplanması ile yapılır.

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

4.1. Tahmin Analizi için ARIMA Modellerinin İncelenmesi

Bu bölümde öncelikle toplam abone sayısı ve dağıtım sistemine giren enerji verileri için kurulan modellerin analizleri yapılmıştır. Daha sonra ortaya çıkacak parametrelerin istatistiki açıdan anlamlı olup olmadıklarını test etmek için t ve F testleri yapılmış ve daha sonra sırasıyla durağanlık, ardışık bağımlılık, eşdeğişkenlik ve çoklu doğrusallık testleri uygulanmıştır. Yapılacak olan testlerde güven aralığı olarak %95 (0,05 kritik değer seviyesi) seçilmiş ancak yeterli sonuç alınmadığı durumda EPDK'nın Talep Tahmin Yönetmeliği'nin 9. maddesinin 2. fıkrasında da belirtildiği üzere %90 güven aralığı (0,10 kritik değer seviyesi) kullanılmıştır. Bunun haricinde ilgili başlıklar altında test(ler)i geçemeyen veya kurulan ilişkileri açıklama gücü düşük modellere değinilmiş ve bunlara ilişkin detaylı tablolar yine bu başlıklar altında sunulmuştur. Bahsi geçen tüm analizler ve testler ise RStudio İstatistik Programı yardımıyla yapılmıştır.

4.1.1. Toplam abone sayısı

Bu bölümde abone sayısı tahminine yönelik aylık gözlemleri girdi olarak kullanan ARIMA modelleri üzerinde durulmuş ve mevsimsel karakteristik gösteren birçok zaman serisi üzerinde kullanıldığı gibi abone sayısı artış trendi de R yazılımı üzerinde geliştirilen bu model alternatifleriyle açıklanmaya çalışılmıştır.

ARIMA modelleri literatürde belirli bir periyotta kendini tekrar eden ve/veya uzun dönemde belirli bir artış veya azalış trendi olan zaman serilerini açıklamakta başarılıdır. Burada zaman serisinin karakteristiği 3 katsayı üzerinden açıklanır.

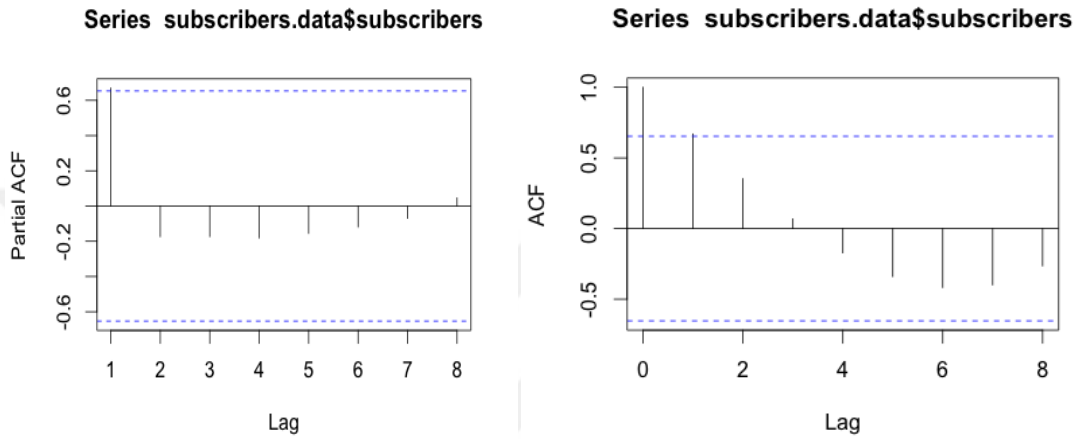
AR(p): p katsayısı zaman serisinin kaç gözlem önceki değerlerinin serinin akışını açıklayabileceğini belirlemek üzere kullanılır.

Difference(d): d katsayısı durağan olmayan zaman serilerinde yönelim trendini de hesaba katmak üzere kullanılır. "0" değeri kullanılacaksa serinin durağan olması gerekir ve bu durumda seride zamana bağlı bir yönelimin olmayacağı varsayılır.

MA(q): Kaç gözlem öncesine kadar modelin açıklayamadığı kısımların(hata terimleri) zaman serisinde açıklayıcı öneme sahip olduğunu belirtmek için kullanılmaktadır.

Bir sonraki aşamada “p” ve “d” katsayılarını belirleyebilmek için otokorelasyon ve durağanlık analizi yapılmıştır. “q” katsayısı ise tüketimin aylık karakteristiklerine göre uygun değerlerin alternatifleri denenerek kararlaştırılacaktır.

Veri seti üzerinde oluşan otokorelasyon grafikleri incelenerek uygun AR(p) katsayısına yönelik bir analiz yapılmıştır.



Şekil 4.1 Otokorelasyon ve Kısmi Otokorelasyon Fonksiyonları – Toplam Abone Sayısı

Yukarıda görüldüğü üzere kullanılması gerekirse AR(1) ve AR(2) makul değişkenler olarak kullanılabilir. Buna karşın gözlem sayısının az olması nedeniyle yeterli anlamlılık korunduğu sürece modele değişken eklemek doğru bir tercih olmayacaktır.

Durağanlık

İkinci olarak “d” katsayısını belirlemek üzere aylık tüketim serisine “Augmented Dickey-Fuller Test” olarak bilinen durağanlık kontrolü yapılmıştır. R konsoluna hazır şablon kullanılarak verilen komutun çıktıları aşağıdaki gibidir.

```
Augmented Dickey-Fuller Test
data: subscribers.data$subscribers
Dickey-Fuller = -1.0259, Lag order = 2, p-value = 0.9168
alternative hypothesis: stationary
```

Şekil 4.2 Durağanlık Testi – Toplam Abone Sayısı

ADF Test sonucunda p-değerinin %5'in oldukça üzerinde olmasına da dayanarak kurulacak modelde “difference” alınması gerektiği saptanmıştır. Sezonallığın da bulunmadığı bir seriden bahsettiğimiz varsayılırsa R konsolunda kullanabileceğimiz “auto.arima” fonksiyonu optimum AIC parametresine sahip p,d,q kombinasyonunu sunacaktır. Bunu kullanırken koşulacak tek ön şart 1. dereceden ya da 2. dereceden fark alınarak denenen alternatiflerin değerlendirilmesidir.

AUTO ARIMA(0,1,0)

Difference derecesinin 1'e eşitlendiği durumda (0,1,0) kombinasyonları en uygun model olarak sunulmuştur. Aşağıda bu modele ait özet dökümü paylaşılmıştır.

```
ARIMA(0, 1, 0) with drift
Coefficients:
      drift
      51032.7500
s.e.      778.9117

sigma^2 estimated as 4853549: log likelihood=-72.93
AIC=149.86 AICc=152.26 BIC=150.02
```

Şekil 4.3 ARIMA(0,1,0) Modeli Çıktıları – Toplam Abone Sayısı

<drift> terimi fark regresyonlarında her gözlemden tahmin edilen değerin ne miktarda değişeceğinin öngörüsüdür. Mevcut durumda model her sene abone sayısının 51.033'lük bir artış göstereceğine işaret etmektedir. T-istatistiği de 2.16'nın oldukça üzerinde bir değer vererek yeterli anlamlılığın sağlandığına işaret etmektedir.

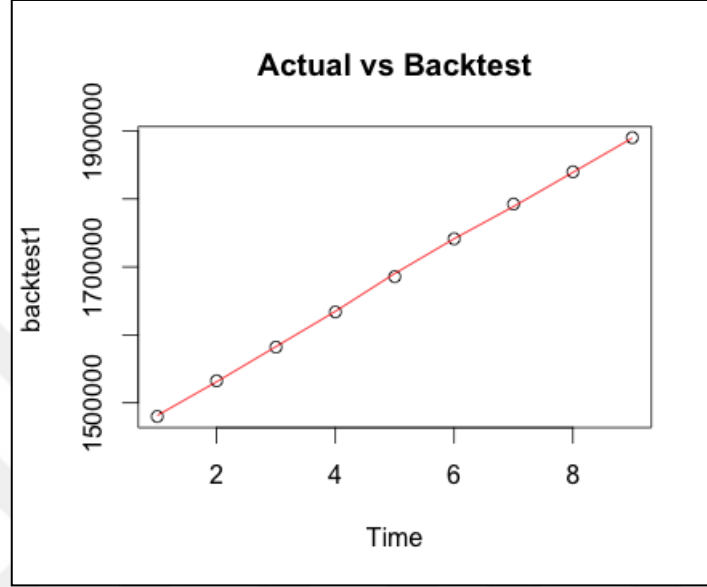
Bu şartlar sağlandığına göre modelin ortalama mutlak hata yüzdesinin incelenmesi ikinci aşamada kontrol edilebilir.

Görüldüğü üzere değişken sayısını minimumda tutmak üzere tasarlanmış olan bu model AR ve MA terimlerini modele katmamış ve sadece 1. derecede “difference” olarak zaman serilerinde sabit bir değişim miktarına karşılık gelen “drift” ile abone sayısı artışını açıklamaya çalışmıştır. İkinci aşamada ise bu modele “backtest” analizi yapılmıştır.

Modelin katsayısının yeterli anlamlılık seviyesinde olduğuna dayanarak bu katsayılarla geriye doğru çalıştırılmış ve elde edilen değerlerle gerçekleşen aylık abone sayısı değerleri karşılaştırılarak bir OYMH incelemesi yapılmıştır. Aşağıda bu aşamaya yönelik komutlar ve grafikler verilmiştir.

```
#DERIVING BACKTEST
backtest1<- fitted.values(AUTOarima)
plot(backtest1, type='p', main='Actual vs Backtest')
lines(subscribers.data$subscribers, col='red')
```

Şekil 4.4 Backtest Analizi – ARIMA(0,1,0)



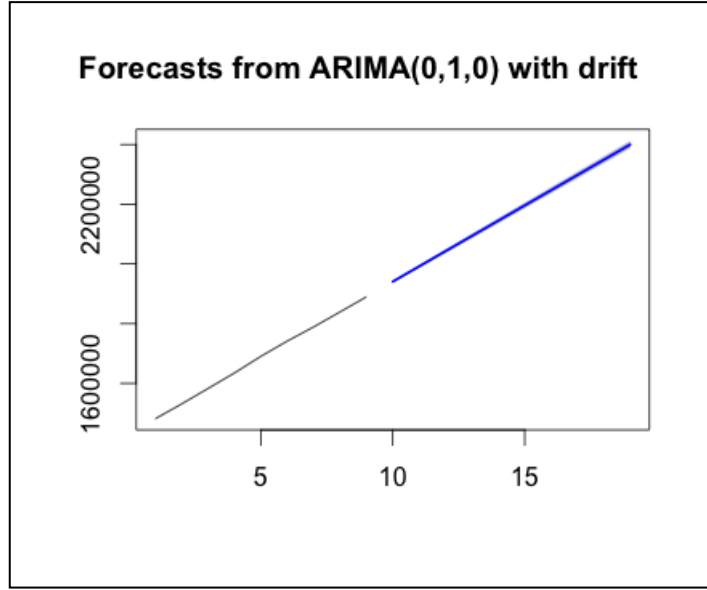
Şekil 4.5 Modelin geriye yönelik çalıştırılması – ARIMA(0,1,0)

Şekil 4.5'te gerçekleşen değerler nokta ile, tahminler de doğru üzerinde gösterilmiştir. Oldukça iyi bir eşleşme göze çarparken MAPE(OYMH) de aynı noktaya işaret etmektedir.

accuracy(AUTOarima)						
	ME	RMSE	MAE	MPE	MAPE	MASE
Training set	158.9336	2131.104	1566.045	0.0123024	0.0934085	0.03068705
Training set	ACF1					
	0.1128845					

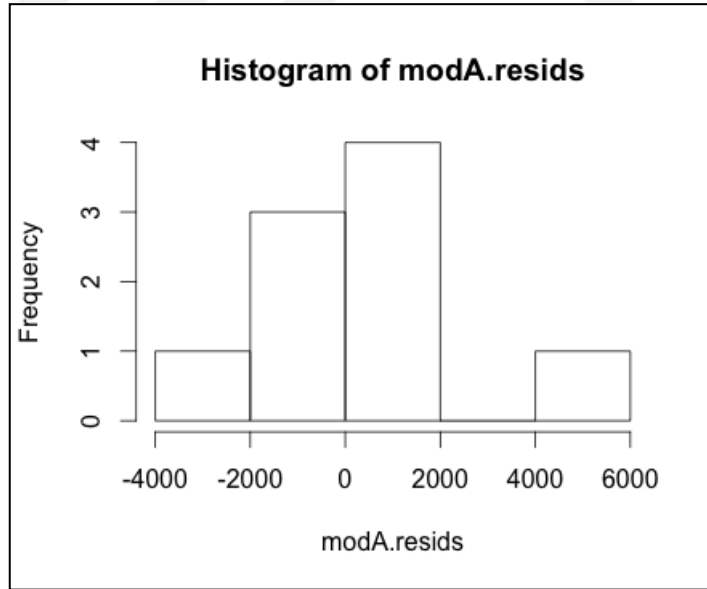
Şekil 4.6 Modelin geriye yönelik çalıştırılması – ARIMA(0,1,0)

Hata oranları incelendikten sonra öngörülecek projeksiyonun mantıklı olup olmayacağını incelemek üzere 2025'e kadar veri setinin bitişini takip eden 120 ayın tahmini komutla grafiğe dökülmüştür.



Şekil 4.7 Projeksiyon ve gerçekleşen değerlerin karşılaştırması – ARIMA(0,1,0)

Grafik incelendiğinde, abone sayısının yükseleceği varsayımına uygun bir yükseliş gözlemlenmektedir. Sonraki aşamada modelin anlamlılığına yönelik kontrollerin ilki olarak hata terimlerinin dağılımı incelenmiştir. Burada beklenen, bu terimlerin histogramda normal dağılıma yakın bir grafik oluşturmasıdır. Aşağıda bu kontrole yönelik oluşan histogram verilmiştir.



Şekil 4.8 Hata Terimlerinin Dağılımı (Histogram) – ARIMA(0,1,0)

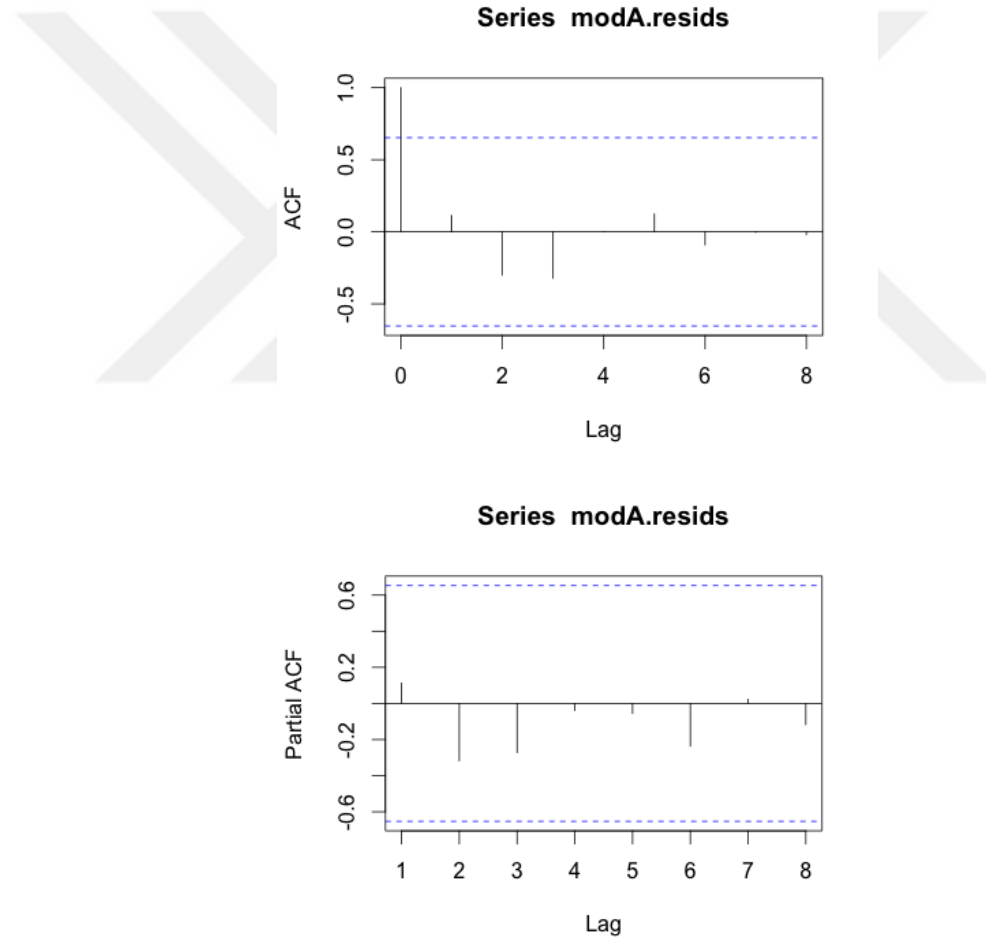
Grafikte de görüleceği üzere hata terimleri normale yakın bir dağılım göstermiştir. Bu aşamadan sonra kalan ilgili istatistiksel testlerle hata terimleri arası korelasyon bulunmaması ve eşdeğişkenliğin sağlanması gibi diğer şartların da sağlanıp sağlanmadığı

kontrol edilerek modelin kullanılabilirliđi sonuca bađlanmıřtır.

Ardıřık bađımlılık

Hata terimleri arasında otokorelasyon olmadıđının gsterilmesi iin farklı yntemler mevcuttur.

Birinci ařamada ařađıda da yer alan otokorelasyon ve kısmi otokorelasyon fonksiyonları –ACF ve PACF - izilmiř, bylece ardıřık bađımlılık deđerlerinin kritik deđerler olan $\pm 1,96/n^{1/2}$ sınırlarının ierisinde kaldıđı gsterilmiřtir. Bu grafikler, hata terimleri arasında ardıřık bađımlılık olmadıđına grsel kanıt olarak sunulmaktadır.



řekil 4.91 Otokorelasyon ve Kısmi Otokorelasyon Fonksiyonları – ARIMA(0,1,0)

İkinci olarak ise hata terimleri arasında ařađıdaki regresyon zerinden bir korelasyon kontrol yapılmıřtır.

$$e_t = \beta_0 + \beta_1 \times e_{t-1} + \varepsilon_t \quad (4.1)$$

Modelin açıklayıcılığı oldukça düşük kalmış, F ve t istatistikleri ve onlarla ilişkili p değerleri 0,05'in üzerinde kalarak, bir önceki periyoda ait hata teriminin mevcut hata terimini tahmin etme konusunda bir açıklayıcılığının olamayacağını ortaya koymuşlardır.

Tüm bu sonuçlar ışığında hata terimlerinin ardışık bağımlılık içermediği ifade edilebilir.

Eşdeğişkenlik

Son olarak eşdeğişkenlik şartının sağlanıp sağlanmadığına yönelik literatürde “ARCH Test” olarak geçen kontrol uygulanarak ARIMA(0,1,0) modelinin hata varyansının zamanla artmadığını teyit etmeye yönelik bir analiz ile çalışma sürdürülmüştür.

ARCH Test - Toplam Abone Sayısı tahmini sonucunda ortaya çıkan p değerinin 0,05'ten yüksek olması sebebiyle eşdeğişkenlik olduğunu varsayan sıfır hipotezi reddedilmemektedir. Bu yüzden, modelimizde homoskedastisite (eşdeğişkenlik) varsayımının sağlanmış olduğu sonucuna varılmaktadır.

Sonuç olarak Auto ARIMA(0,1,0) modeli ile abone sayısı tahmini yapılması uygun bulunmuştur.

4.1.2. Dağıtım sistemine giren elektrik enerjisi talebi

Dağıtım sistemine giren enerji tahmini için aylık gözlemleri girdi olarak kullanan ARIMA modelleri üzerinde durulmuş ve sezonsal karakteristik gösteren birçok zaman serisi üzerinde kullanıldığı gibi “Dağıtım Sistemine Giren Enerji” trendi de R yazılımı üzerinde geliştirilen bu model alternatifleriyle açıklanmaya çalışılmıştır.

Modellerde aylık elektrik tüketimine alternatif olarak takvim etkisinden arındırılmış tüketim de tahmin edilmeye çalışılmış ve bu şekilde eldeki model alternatifleri güçlendirilmiştir.

Takvimsel etkiden aylık tüketimi arındırma noktasında kullanılan input doğal olarak EPDK'nın 10 gün tipi olacaktır.

Çizelge 4.1 Gün Tipleri ve Kodlamaları

EPDK GÜN TIPLERİ	
Pazar	1
Pazartesi	2
Salı	3
Çarşamba	4
Perşembe	5
Cuma	6
Cumartesi	7
Dini Bayram	8
Resmi Tatil	9
Arife	10

Bunlar ışığında çalışmanın ilk aşamasında gün tiplerine özel tüketim ağırlıklarını hesaplamak amacıyla dağıtım şebekesinin günlük ortalama Kesinleşmiş Dağıtılan Enerji değerleri kullanılarak basit bir regresyon modeli denenmiştir. Bu modeldeki mantıkta tüketimin tüm varyasyonların uzun dönemli büyüme trendine ve gün tiplerine bağlı olduğu varsayılmıştır. Aşağıda bağımsız değişken olarak kullanılan 10 “dummy variable” ve trend değişkeni ile kurulan çoklu regresyon denklemi ve bu denkleme ait model sonuçları dökümü verilmiştir.

$$TÜKETİM_t = \beta_1 \times D_1 + \beta_2 \times D_2 + \dots + \beta_{10} \times D_{10} + \beta_{11} \times t \quad (4.2)$$

Series: load. ts								
ARIMA(0, 0, 1) with non-zero mean								
Coefficients:								
	ma1	intercept	D1	D2	D3	D5	D6	D
7	D8							
	0.9462	812.2245	-150.3434	-25.9697	-1.9838	3.6694	-4.5198	-29.276
2	-198.4514							
s. e.	0.0057	13.2027	11.9313	12.7959	9.2343	8.9475	12.5173	11.922
8	22.2531							
	D9	D10	trend					
	-61.0640	-70.6840	0.1629					
s. e.	9.2958	17.5718	0.0101					
sigma^2 estimated as 14936: log likelihood=-11740.92								
AIC=23507.84 AICc=23508.03 BIC=23579.89								
Training set error measures:								

Şekil 4.10 Gün tipi ağırlıklarını bulmaya yönelik ARIMA modeli

Sonuçlar arasında kullanılacak olan gün tiplerine ait basit değişkenlerin katsayıları $(\beta_1, \beta_2, \beta_3 \dots \beta_{10})$ olacaktır. Regresyonda maksimum tüketimin gelmesi

beklenen Çarşamba'nın sabit olarak kullanılması dolayısıyla tüm gün tipine özel tüketimler "SABİT+KATSAYI" toplamı ile hesaplanmış, Perşembe günü ise sabitin kendi değerine karşılık gelmiştir. İkinci adımda ise aşağıdaki formülle bu katsayılar normalleştirilerek 0 ile 1 arasında bir değerle (Gün Tipi Ağırlıkları – GTA) eşleştirilmiştir.

$$Normalize\ Katsayı_i = \frac{(Katsayı_i - \min_i Katsayı)}{(\max_i Katsayı - \min_i Katsayı)} \quad (4.3)$$

Çizelge 4.2 Dağıtım Bölgesi Gün Tipi Ağırlıkları

Dağıtım Şirketi Değerleri (MWh)			
GÜN TİPİ	GÜN TİPİ KODU	Ortalama Tüketim	Normalize Edilmiş Değer
Pazar	1	661,88	0,24
Pazartesi	2	786,25	0,85
Salı	3	810,24	0,97
Çarşamba	4	812,22	0,98
Perşembe	5	815,89	1,00
Cuma	6	807,70	0,96
Cumartesi	7	782,95	0,84
Bayram Tatili	8	613,77	0,00
Resmi Tatil	9	751,16	0,68
Arife	10	741,54	0,63

Veri setindeki tüm aylar ilk günleri ve son günleri arasındaki ağırlıklandırılmış gün toplamına bölünerek istenilen takvim etkisinden arındırılmış değerler elde edilmiştir. Buna göre t1 başlangıçlı, t2 bitişli bir ay için hesaplanan değer olan ve tahminlerde kullanılacak değişken aşağıdaki formülden gelmektedir.

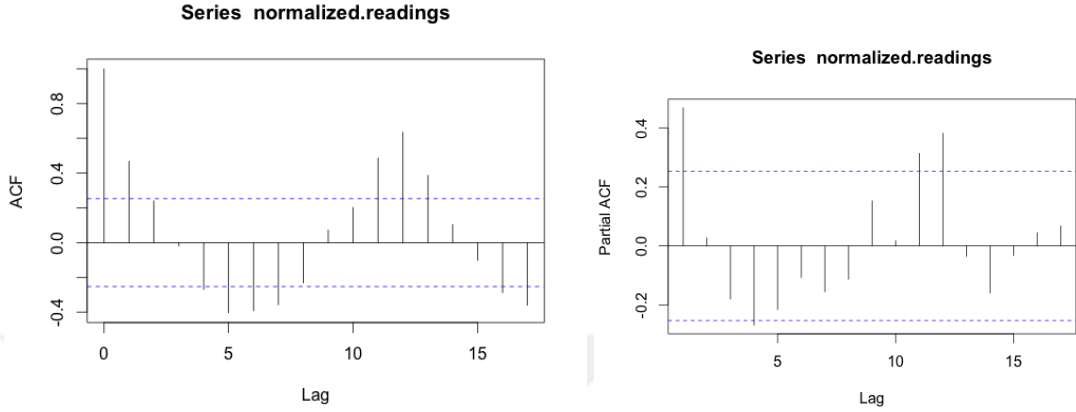
$$NORMALİZE\ TÜKETİM_t = \frac{AY\ TOPLAMI_t}{\sum_{t1}^{t2} GÜN\ TİPİ\ AĞIRLIĞI} \quad (4.4)$$

Sonraki bölümde ilk olarak belirlenen değişken üzerine kurulan modeller özetlenmiş, daha sonra aylık tüketimin ham değerleri olan "monthly_data\$load" değerleri model kurmak üzere denenmiştir.

AR(x) Katsayısı


Veri seti üzerinde yukarıdaki komutlar çalıştırıldığında oluşan otokorelasyon

grafikleri incelenerek uygun AR(p) katsayısına yönelik bir analiz yapılmıştır. Veri seti üzerinde yukarıdaki komutlar çalıştırıldığında oluşan otokorelasyon grafikleri incelenerek uygun AR(p) katsayısına yönelik bir analiz yapılmıştır. Buradaki sonuçlar tüketimin hangi “lag” ile daha korele gittiğine yönelik bir ipucu sunacaktır.



Şekil 4.11 Otokorelasyon ve Kısmi Otokorelasyon Fonksiyonları – Takvimsel Etkiden Arındırılmış Tüketim

Grafiklerde de görüldüğü üzere AR(1) takvimsel etkiden arındırılmış değerler için önemli açıklayıcılığa sahip bir değişken olarak göze çarpmaktadır.



Şekil 4.12 Otokorelasyon ve Kısmi Otokorelasyon Fonksiyonları – Ham Tüketim

Yine aylık ham tüketim değerleri de aynı AR derecesine işaret etmektedir. Bu sonuçlara göre hem AR hem MA olarak 1 katsayısı kullanılması tüketim modelleri için makul görünmektedir.

Durağanlık

İkinci olarak serilerin durağanlığını belirlemek üzere aylık tüketim serilerine

“Augmented Dickey-Fuller Test” olarak bilinen durağanlık kontrolü yapılmıştır. Bu sayede model kurulurken fark almanın gerekip gerekmediği saptanacaktır. R konsoluna hazır formül kullanılarak verilen komutun çıktıları aşağıdaki gibidir.

```
Augmented Dickey-Fuller Test
data: normalized readings
Dickey-Fuller = -4.9273, Lag order = 3, p-value = 0.01
alternative hypothesis: stationary
```

Şekil 4.13 Durağanlık Testi – Dağıtım Giren Enerji Talebi (değişken:normalized readings)

0,05’in altında p-değeri veren ADF Test’i serilerin durağan olduğuna işaret etmektedir. Bu durumda “difference” almadan (d=0) kurulan modellerin de kabul edilebilir olacağı anlaşılmıştır.

ARIMA (1,1,1) – NORMALİZE TÜKETİM

İlk olarak 1. dereceden AR ve MA katsayıları kullanılarak tüketimin değişimi üzerine bir model(d=1) kurulmuştur. Aşağıda bu modele ait özet çıktının detayları verilmiştir.

```
Series: normalized readings
ARIMA(1, 1, 1) (1, 1, 0) [12]

Coefficients:
      ar1      ma1      sar1
-0.4017 -0.9235 -0.5144
s.e.    0.1357  0.0822  0.1366

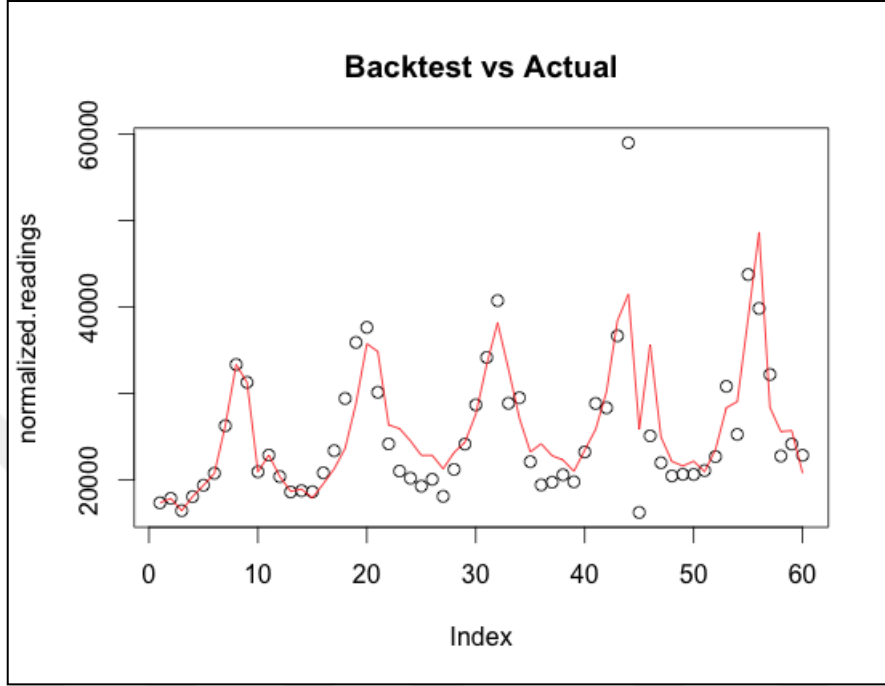
sigma^2 estimated as 20392142: log likelihood=-465.6
AIC=939.19 AICc=940.14 BIC=946.59

Training set error measures:
      ME      RMSE      MAE      MPE      MAPE      MASE
ACF1
T
```

Şekil 4.14 ARIMA(1,1,1) Modeli Çıktıları – Dağıtım Giren Enerji Talebi

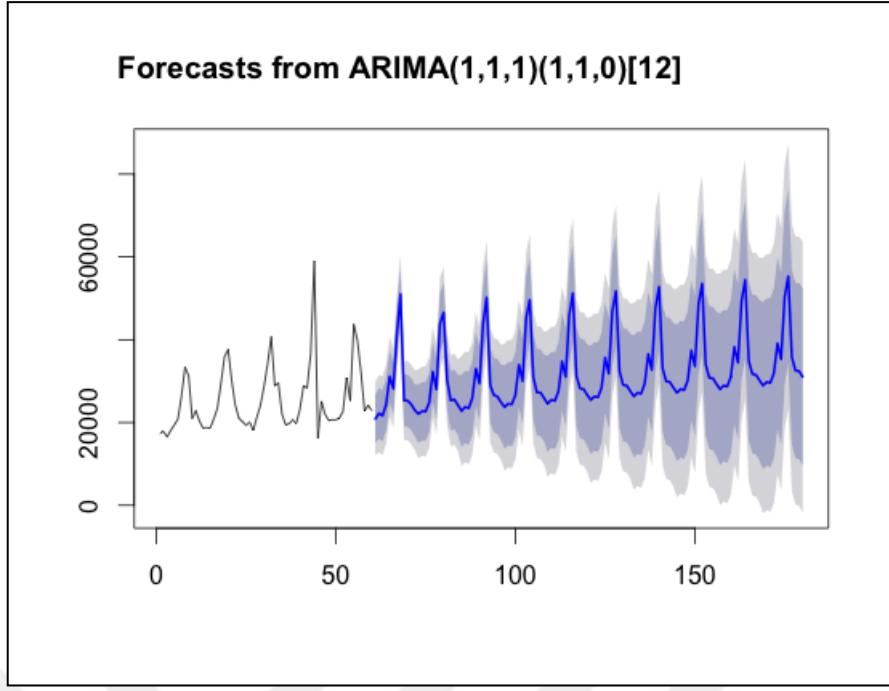
Sonuçlar incelendiğinde tüm katsayıların yeterli anlamlılık seviyesinde olduğu görülmüş ve model geriye doğru çalıştırılarak OYMH analizi gerçekleştirilmiştir.

Yukarıda görüldüğü üzere modelin hata oranları aylık gözlemler için %9,6 gibi yüksek bir seviyeye işaret etmektedir. Aşağıdaki grafikten buna dair bir çıkarım yapmak gerekirse, noktaların karşılık geldiği gerçekleşen tüketimler ile tahmin(kırmızı doğru) özellikle 2014 yazında arasında farkın açılmasını gösterebiliriz.



Şekil 4.15 Modelin geriye yönelik çalıştırılması – ARIMA(1,1,1)

Hata oranları incelendikten sonra öngörülecek projeksiyonun mantıklı olup olmayacağını incelemek üzere 2025'e kadar veri setinin bitişini takip eden 120 ayın tahmini "Dağıtım Sistemine Giren Enerji" değerleri ilgili komutla grafiğe dökülmüştür.



Şekil 4.16 Projeksiyon ve gerçekleşen değerlerin karşılaştırması – ARIMA(1,1,1)

Grafiğe göre tahmini değerler hem mevcut sezonsallığı hem de artış trendini aynı oranda geleceğe yansıtıyor görünmektedir.

Tüm bu detaylar incelendikten sonra daha düşük bir sapma oranına erişebilmek amacıyla takvim etkisinden arındırılmış tüketim yerine aylık ham tüketim üzerinden kurulacak bir modelin sonuçlarının incelenmesine karar verilmiştir.

ARIMA (1,1,1)

Önceki modele paralel olarak 1. dereceden AR ve MA katsayıları kullanılarak tüketimin değişimi üzerine bir model($d=1$) kurulmuştur. Aşağıda bu modele ait özet çıktının detayları verilmiştir.

Series: monthly_data\$load
ARIMA(1, 1, 1) (1, 1, 0) [12]

Coefficients:

	ar1	ma1	sar1
	-0.3432	-0.9442	-0.5298
s. e.	0.1397	0.0936	0.1310

sigma^2 estimated as 1.215e+10: log likelihood=-616.03
AIC=1240.07 AICc=1241.02 BIC=1247.47

Training set error measures:

	ME	RMSE	MAE	MPE	MAPE	MASE
ACF1						

Şekil 4.17 ARIMA(1,1,1) Modeli Çıktıları – Dağıtım Giren Enerji Talebi

Sonuçlar incelendiğinde tüm katsayıların yeterli anlamlılık seviyesinde olduğu görülmüş ve model geriye doğru çalıştırılarak OYMH analizi gerçekleştirilmiştir.

Training set error measures:

	ME	RMSE	MAE	MPE	MAPE	MASE
ACF1						
Training set	-14992.99	97554.24	57493.41	-4.220642	8.664954	0.5312455
3140	-0.0794					


Şekil 4.18 Modelin isabet oranları – ARIMA(1,1,1)

Aylık ham tüketim üzerinden kurulan model takvim etkisinden arındırılmış versiyonun altında bir hata oranı vermiştir. Buna karşın aylık %8,66'lık bu oranın yıllık toplamda daha düşük olacağını da teyit etmek amacıyla model geriye doğru çalıştırıldığında elde edilen sonuçlarla yıllık toplamlar oluşturulup gerçek tüketimlerle karşılaştırılmıştır.

Çizelge 4.3 OYMH Tablosu – Dağıtım Şebekesi Sisteme Giren Enerji Tahmini

YIL	TAHMİN (MWh)	GERÇEKLEŞME(MWh)	FARK	OYMH
2011	6.558.152	6.559.340	-1.188	0,02%
2012	7.406.374	7.413.925	-7.551	0,10%
2013	7.966.338	7.525.957	440.381	5,85%
2014	8.214.509	7.933.829	280.680	3,54%
2015	8.271.362	8.084.105	605.322	7,49%
Ortalama	-	-	-	3,40%


Hata oranları incelendikten sonra öngörülecek projeksiyonun mantıklı olup olmayacağını incelemek üzere 2025'e kadar veri setinin bitişini takip eden 120 ayın tahmini "Dağıtım Sistemine Giren Enerji" değerleri ilgili komutla grafiğe dökülmüştür.



Şekil 4.19 Projeksiyon ve gerçekleşen değerlerin karşılaştırması – ARIMA(1,1,1)

Grafiğe göre tahmini değerler hem mevcut sezonsallığı hem de artış trendini aynı oranda geleceğe yansıtıyor görünmektedir.

Bunu da teyit ettikten sonra modelin istatistiksel doğruluğunun ölçülmesi amacıyla çeşitli testler uygulanmıştır. Burada beklenen, bu terimlerin histogramda normal dağılıma yakın bir grafik oluşturmasıdır. Aşağıda bu kontrole yönelik oluşan histogram verilmiştir.




Şekil 4.20 Hata Terimlerinin Dağılımı (Histogram) – ARIMA(1,1,1)

Grafikte de görüleceği üzere hata terimleri normale yakın bir dağılım göstermiştir. Bu aşamadan sonra kalan ilgili istatistiksel testlerle hata terimleri arası korelasyon bulunmaması ve eşdeğişkenliğin sağlanması gibi diğer şartların da sağlanıp sağlanmadığı kontrol edilerek modelin kullanılabilirliği sonuca bağlanmıştır.

Ardışık bağımlılık

Daha önce de belirtilmiş olduğu üzere, hata terimleri arasında otokorelasyon olmadığının gösterilmesi için farklı yöntemler mevcuttur.

Birinci aşamada aşağıda da yer alan otokorelasyon ve kısmi otokorelasyon fonksiyonları –ACF ve PACF - çizilmiş, böylece ardışık bağımlılık değerlerinin bir iki değer dışında kritik değerler olan $\pm 1,96/n^{1/2}$ sınırlarının içerisinde kaldığı gösterilmiştir. Bu grafikler, hata terimleri arasında ardışık bağımlılık olmadığına görsel kanıt olarak sunulmaktadır.



Şekil 4.21 Otokorelasyon ve Kısmi Otokorelasyon Fonksiyonları – ARIMA(1,1,1)

Kısmi otokorelasyon grafiğinde görüldüğü gibi hata terimleri arası korelasyon hem rassal bir yöne sahip hem de istenilen aralıklarda seyreden katsayılar vermiştir. İkinci olarak ise hata terimleri arasında aşağıdaki regresyon üzerinden bir korelasyon kontrolü yapılmıştır.

$$e_t = \beta_0 + \beta_1 \times e_{t-1} + \varepsilon_t \quad (4.20)$$

```
#Durbin-Watson Test#
Call:
lm(formula = mod111.resids[-1] ~ mod111.resids[-n1])

Residuals:
    Min       1Q   Median       3Q      Max
-211044 -60677  14669  24770  513062

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept) -1.655e+04  1.301e+04  -1.272   0.209
mod111.resids[-n1] -8.017e-02  1.326e-01  -0.605   0.548

Residual standard error: 98560 on 57 degrees of freedom
Multiple R-squared:  0.006374, Adjusted R-squared:  -0.01106
F-statistic: 0.3656 on 1 and 57 DF,  p-value: 0.5478
```

Yukarıdaki regresyon çıktılarından da görüldüğü üzere modelin açıklayıcılığı oldukça düşük kalmış, F ve t istatistikleri ve onlarla ilişkili p değerleri 0,05'in üzerinde kalarak, bir önceki periyoda ait hata teriminin mevcut hata terimini tahmin etme konusunda bir açıklayıcılığının olamayacağını ortaya koymuşlardır.

Tüm bu sonuçlar ışığında hata terimlerinin ardışık bağımlılık içermediği ifade edilebilir.

Eşdeğişkenlik

Son olarak eşdeğişkenlik şartının sağlanıp sağlanmadığına yönelik literatürde “ARCH Test” olarak geçen kontrol uygulanarak ARIMA(1,1,1) modelinin hata varyansının zamanla artmadığını teyit etmeye yönelik bir analiz ile çalışma sürdürülmüştür.

Test sonucunda ortaya çıkan p değerinin 0,05'ten yüksek olması sebebiyle eşdeğişkenlik olduğunu varsayan sıfır hipotezi reddedilmemektedir. Bu yüzden, modelimizde homoskedastisite (eşdeğişkenlik) varsayımının sağlanmış olduğu sonucuna varılmaktadır.

Tüm testleri geçen en düşük OYMH'ya sahip modelin ham tüketimle kurulan ARIMA(1,1,1) olması sebebiyle sisteme giren enerji tahmininde bu alternatifle devam edilmesine karar verilmiştir.

4.2. Tahmin Analizi İçin Yapay Sinir Ağları Modellerin İncelenmesi

Bu bölümde çalışılan problemin YSA için uygulama aşamaları anlatılmış ve modeli etkileyen etmenler üzerinde durulmuştur.

Uygulamanın bu aşamasında YSA ile talep tahmini sonucuna ulaşmak için MATLAB (R2014A Sürümü) kullanılmıştır.

Talep tahmini uygulamalarında literatürde en çok kullanılan yöntem geri yayılım algoritmasıdır. Bu yüzden bu çalışmada çok katmanlı ileri beslemeli geri yayılım algoritması kullanılmıştır. 2009-2016 yılları arasındaki talep edilen enerji verileri abone gruplarına göre girdi olarak kullanılmıştır. Veriler üzerinde normalizasyon tekniği kullanılmış olup tüm girdiler [0.1-0.9] arasında düzenlenmiş ve programa aktarılmıştır.

4.2.1. Öğrenme katsayısının belirlenmesi

Öğrenme katsayısının belirlenmesi YSA ağının öğrenmesi için çok önemli bir karardır. Öğrenme katsayısı ağırlıkların değişim oranlarını belirler ve büyük değerler seçildiğinde çözümler arasında ağırlık dolaşma zamanı, küçük değerler seçildiğinde ise öğrenme zamanı artar. Çalışmalarda genellikle 0.2-0.4 arasındaki değerler kullanılmaktadır (Öztemel, 2003). Bu çalışma için çevrim sayısı 1000 olarak sabit tutulup

yapılan denemeler sonucunda en uygun öğrenme katsayısının 0.9 olduğu görülmüştür.

4.2.2. Momentum katsayısının belirlenmesi

Momentum katsayısı öğrenme performansını etkilediğinden dolayı problemimizin çözümü için önem arz etmektedir. Momentum katsayısı çözüme takılan ağı bir sıçrama ile daha iyi sonuçlar bulmasını sağlar. Bu değerin küçük olması yerel çözümlerden kurtulmayı zorlaştırırken çok büyük olması tek bir çözüme ulaşmakta sorun çıkartabilir. Literatürdeki çalışmalara göre bu değerin 0.6-0.8 arasında seçilmesin daha uygun olmaktadır. (Öztemel, 2003). Bu çalışmada ise gerekli denemeler yapılmış ve en uygun momentum katsayısının 0.6 olduğuna karar verilmiştir.

4.2.3. Çevrim sayısının belirlenmesi


Ağ için yeterli olan iterasyon sayısından sonra ağ öğrenmeyi bırakır. Ağ öğrenmeyi bıraktıktan sonraki denemelerde daha iyi bir sonuç bulamaz. 250-5000 arasındaki yapılan denemelerde ağ için yeterli çevrim sayısının 1000 olduğu görülmüştür.

4.2.4. Nöron sayısının belirlenmesi

YSA içerisinde nöron sayısı da çözümü etkileyeceği için doğru bir şekilde belirlenmesi gerekmektedir. Literatürde genel gözlemlendiği üzere nöron sayısının az olması ağın genelleme düzeyini artırmaktadır, fazla olması ise verilerin ezberlenmesine yol açmaktadır. Bu yüzden bu çalışmada 1-20 arasındaki nöron sayıları denenmiş olup en iyi sonuca nöron sayısı 10 iken ulaşılmıştır.

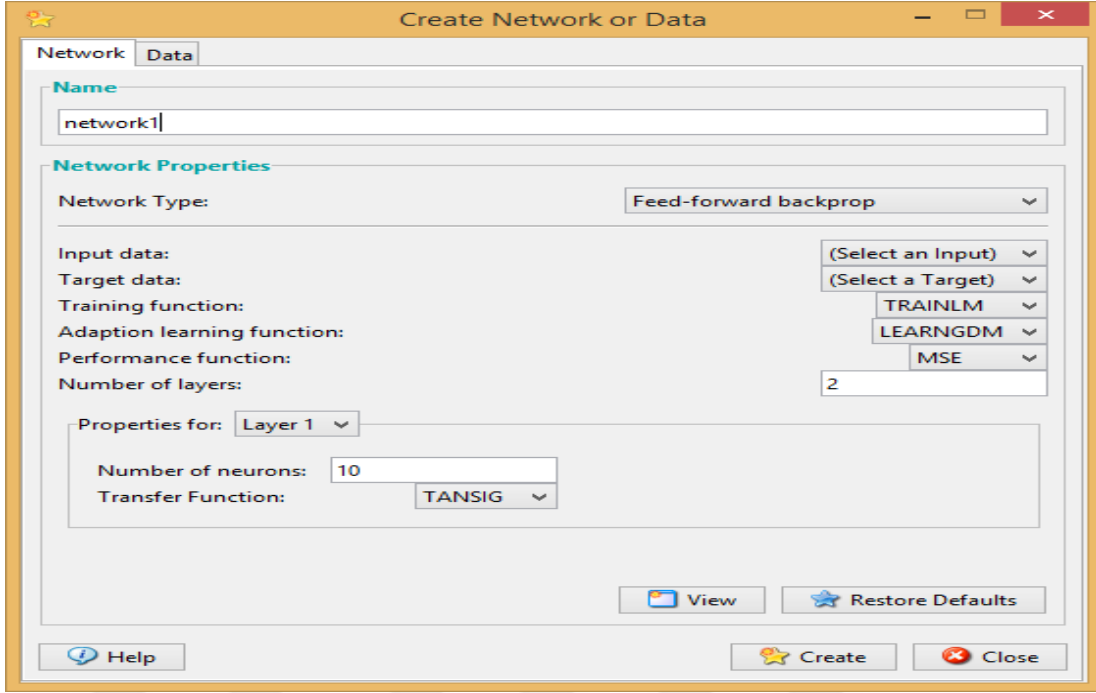
4.2.5. Ağı eğitilmesi

YSA'nın eğitilmesi için MATLAB R2014A programının Neural Network uygulaması kullanılmıştır. Yeni bir ağ oluşturma pencereleri aşağıdaki şekilde gösterilmiştir.




Şekil 4.23 MATLAB Veri Giriş Ekranı

Programda öncelikle data kısmına normalize edilmiş ve testte kullanılacak olan eğitim girdi ve çıktıları girilir. Aşağıdaki şekilde de gösterildiği gibi pencerede “Network” sekmesinde yeni oluşturulan ağın özellikleri seçilir. Bu sekmede öncelikle “Network Type” kısmında çalışmada kullanılacak ağ tipi seçilerek sisteme girilmesi gerekmektedir. Bu tez kapsamında ileri beslemeli geri yayılım ağı kullanıldığı için “Feed Forward Backprop” seçilmiştir.



Şekil 4.24 MATLAB Ağ Oluşturma Ekranı

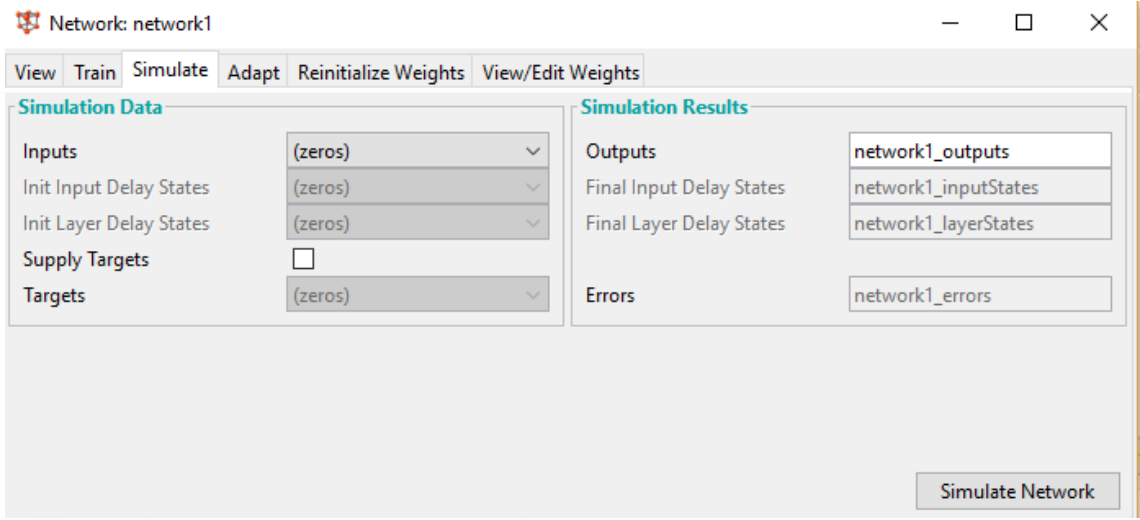
Gereken veriler girildikten sonra “Create” butonuna basılarak ağ yaratılmış olur. Verilerin yaratılmasından sonra ağı eğitmemiz için “Network” girişinden aşağıdaki şekildeki gibi gerekli parametreler girildikten sonra “Train Network” butonuna basılır ve böylece ağı eğitimi gerçekleşir.



Şekil 4.25 MATLAB Ağ Eğitim Ekranı

Ağın eğitilmesinden sonra programın test edilmesi için “Simulate” sekmesinden giriş yapılı ve programa test için girilmiş olan normalize edilen veriler inputs olarak

seçilir ve “Simulate Network” butonuna basılarak ağ test edilmiş olur.



Şekil 4.26 MATLAB Simulate Seçim Ekranı

Testin sonucu gerçek verilerle kıyaslanarak ağın performansı değerlendirilir. Performansın düşük olması durumunda ilgili parametreler üzerinde değişiklik yapılarak test işlemine devam edilmelidir.

5. SONUÇLAR VE ÖNERİLER

Çalışmanın son bölümü olan bu bölümde bir elektrik dağıtım şirketinde uygulaması yapılmış olan talep tahmini çalışmasının bilimsel yöntemlerle karşılaştırma sonuçları verilerek sonraki olası çalışmalar için önerilerde bulunulmuştur.

5.1 Sonuçlar

Bu çalışmada bir elektrik dağıtım şirketinin sahip olduğu gerçek veriler üzerinden, gelecek için elektrik talebi tahmininin yapılması amacı ile problem oluşturulmuş ve talep tahmininde kullanılan ARIMA yöntemi ve yapay sinir ağları yöntemi ile sonuca ulaşılmış ve kıyaslanmıştır.

Aşağıdaki tablolardan da anlaşıldığı üzere, YSA ile genel bir çerçeve sonuç üzerinde ilerlenmiş, ARIMA ile ise daha tutarlı sonuçlara ulaşılmıştır. Abone büyüme oranlarında ise YSA bazı yıllar artış, bazı yıllar azalış gösterirken, ARIMA sürekli artış göstermektedir. Bu genel yapının sektör uzmanları tarafından yorumlanması üzerine ARIMA'nın daha gerçekçi tahmin sonuçları verdiği değerlendirilmiştir. YSA'nın ise bu şekilde çıktılar üretmesinin nedeni, veri sayısının az olması olarak yorumlanmıştır.

ARIMA yöntemi ile ulaşılan sonuçlar aşağıdaki gibidir.

Çizelge 5.1 ARIMA Değişkenleri

Bağımlı Değişken:	Abone Sayısı
Model Türü	ARIMA
ARIMA Katsayıları	$p=0, q=1, d=0$

Bağımlı Değişken:	Dağıtım Sistemine Giren Enerji
Model Türü	ARIMA
ARIMA Katsayıları	$p=1, q=1, d=1$

Çizelge 5.2 ARIMA Yöntemi Abone Sayısı ve Büyüme Sonuçları

YILLAR		
	ABONE SAYISI	BÜYÜME
2016	1.940.731	2,70%
2017	1.991.764	2,63%
2018	2.042.796	2,56%
2019	2.093.829	2,50%
2020	2.144.862	2,44%
2021	2.195.895	2,38%
2022	2.246.927	2,32%
2023	2.297.960	2,27%
2024	2.348.993	2,22%
2025	2.400.026	2,17%
2026	2.451.058	2,13%

Çizelge 5.3 ARIMA Yöntemi Elektrik Tüketim Tahmin Sonuçları

Brüt Elektrik Tüketimi Tahmini						
Yıllar	Mesken	Sanayi	Ticarethane	Tarımsal Sulama	Aydınlatma	TOPLAM
2016	2.037.171	2.061.548	2.422.426	1.620.163	307.481	8.448.790
2017	2.100.781	2.125.920	2.498.066	1.670.753	317.082	8.712.603
2018	2.177.279	2.203.333	2.589.031	1.731.592	328.629	9.029.863
2019	2.246.948	2.273.836	2.671.876	1.787.000	339.144	9.318.804
2020	2.320.236	2.348.000	2.759.023	1.845.285	350.206	9.622.750
2021	2.391.606	2.420.225	2.843.890	1.902.046	360.978	9.918.745
2022	2.463.992	2.493.477	2.929.965	1.959.615	371.904	10.218.954
2023	2.535.840	2.566.185	3.015.401	2.016.756	382.748	10.516.930
2024	2.607.973	2.639.181	3.101.175	2.074.123	393.636	10.816.088
2025	2.679.955	2.712.024	3.186.770	2.131.371	404.500	11.114.620
2026	2.752.016	2.784.947	3.272.458	2.188.680	415.377	11.413.479

Yapay sinir ağı uygulamalarında MATLAB kullanılarak ulaşılan sonuçlar aşağıdaki gibidir.

Çizelge 5.4 YSA Abone Sayısı ve Büyüme Sonuçları

YILLAR		
	ABONE SAYISI	BÜYÜME
2016	1.766.973	6,95%
2017	1.762.649	-0,24%
2018	1.861.204	5,59%
2019	1.863.545	0,13%
2020	1.770.058	-5,02%
2021	1.663.392	-6,03%
2022	1.692.524	1,75%
2023	1.847.155	9,14%
2024	1.885.192	2,06%
2025	1.835.862	-2,62%
2026	1.843.714	0,43%


Çizelge 5.5 YSA Elektrik Tüketim Tahmin Sonuçları

Brüt Elektrik Tüketimi Tahmini						
Yıllar	Mesken	Sanayi	Ticarethane	Tarımsal Sulama	Aydınlatma	TOPLAM
2016	1.796.721	2.191.985	1.918.389	1.653.875	234.527	7.795.497
2017	1.760.443	1.768.473	1.605.415	1.624.347	271.596	7.030.274
2018	1.882.849	1.747.269	2.185.289	1.115.889	233.324	7.164.620
2019	1.703.921	1.765.721	2.191.714	1.642.608	272.523	7.576.487
2020	1.816.496	1.941.871	1.543.584	1.653.695	260.565	7.216.211
2021	1.636.402	2.158.641	2.184.410	1.105.035	227.519	7.312.007
2022	1.840.800	2.228.825	1.538.403	1.083.072	227.519	6.918.619
2023	1.883.254	1.990.707	1.583.896	1.523.600	277.254	7.258.711
2024	1.822.354	1.971.537	2.191.714	1.290.140	252.672	7.528.417
2025	1.884.274	1.870.237	1.544.035	1.361.793	275.930	6.936.269
2026	1.574.982	1.791.699	1.850.893	1.233.574	252.373	6.703.521


Regresyon analizi ile alınan sonuçlar aşağıdaki gibidir;

Doğrusal regresyon kullanılmadan önce geçmiş verilerin doğrusal olup olmadığı incelenmiş ve grafikler aşağıda verilmiştir. Böylece regresyon sonucunun yorumlanması amaçlanmıştır.

Toplam Dağıtılan Enerji



Toplam Abone Sayısı



Çizelge 5.6 Regresyon Abone Sayısı ve Büyüme Sonuçları

YILLAR	ABONE SAYISI	BÜYÜME
2016	1.940.930	2,71%
2017	1.991.470	2,60%
2018	2.042.009	2,54%
2019	2.092.548	2,47%
2020	2.143.088	2,42%
2021	2.193.627	2,36%
2022	2.244.166	2,30%
2023	2.294.705	2,25%
2024	2.345.245	2,20%
2025	2.395.784	2,15%
2026	2.446.323	2,11%

Çizelge 5.7 Regresyon Elektrik Tüketim Tahmin Sonuçları

Brüt Elektrik Tüketimi Tahmini

Yıllar	Mesken	Sanayi	Ticarethane	Tarımsal Sulama	Aydınlatma	TOPLAM
2016	1.949.397	1.981.626	2.398.753	1.704.642	284.977	8.319.395
2017	1.998.085	1.990.842	2.538.271	1.789.027	292.592	8.608.816
2018	2.046.773	2.000.057	2.677.789	1.873.412	300.206	8.898.237
2019	2.095.461	2.009.273	2.817.307	1.957.797	307.820	9.187.659
2020	2.144.150	2.018.489	2.956.826	2.042.182	315.434	9.477.080
2021	2.192.838	2.027.704	3.096.344	2.126.567	323.048	9.766.501
2022	2.241.526	2.036.920	3.235.862	2.210.952	330.662	10.055.922
2023	2.290.214	2.046.136	3.375.381	2.295.337	338.276	10.345.344
2024	2.338.902	2.055.351	3.514.899	2.379.722	345.891	10.634.765
2025	2.387.591	2.064.567	3.654.417	2.464.107	353.505	10.924.186
2026	2.436.279	2.073.783	3.793.936	2.548.492	361.119	11.213.607

5.2. Öneriler

Bu çalışmadan sonraki çalışmalar için, farklı YSA modelleri daha çok veri ile kurulup çalıştırılabilir. Buna ek olarak YSA ve farklı teknikler ile birlikte melez algoritmalar oluşturulabilir. Literatürdeki çalışmalarda, özellikle doğrusal olmayan veri setleri için YSA ilişkilerin modellenmesinde daha iyi sonuçlar verdiği için, doğrusal olmayan verilerin ilişkilerinin modellenmesinde YSA kullanılabilir.

KAYNAKLAR

- Akgül, I., 2003, Zaman Serilerinin Analizi ve ARIMA Modelleri, Der Yayınları, İstanbul,
- Amarawickrama, H. A., Hunt, L. C. 2008, Electricity demand for Sri Lanka: a time series analysis. *Energy*, 33(5), 724-739.
- Armutlulu, H., İşletmelerde Uygulamalı İstatistik, Alfa Basım Yayın Dağıtım Ltd. Sti.,
- Asılkan, Ö., Irmak, S., 2009, İkinci El Otomobillerin Gelecekteki Fiyatlarının Yapay Sinir Ağları ile Tahmin Edilmesi. *Suleyman Demirel University Journal of Faculty of Economics & Administrative Sciences*, 14(2).
- Başoğlu, U., Parasız, İ., 2003, *İktisadi verilerin analizi ve temel öngörü yöntemleri*. Ekin Kitapevi.
- Bayrak, M., Esen, Ö., 2014, Forecasting Turkey's Energy Demand Using Artificial Neural Networks: Future Projection Based on an Energy Deficit. *Journal of Applied Economic Sciences*, 2(28): 191-204.
- Bianco, Vincenzo, Oronzio Manca, Sergio Nardini, 2009, "Electricity Consumption Forecasting in Italy Using Regression Models ." *Enegrgy* 34: 1413-1421.
- Bircan, H., Karagöz, Y., 2003, Box-Jenkins Modelleri ile Aylık Döviz Kuru Tahmini Üzerine Bir Uygulama. *Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (6), pp.49-62.
- Birim, Ş., Tümtürk, A., 2016, Modeling and Forecasting Turkey's Electricity Consumption by Using Artificial Neural Network. *American Scientific Research Journal for Engineering, Technology, and Sciences*, 25(1): 192-208.
- Budak, H., Erpolat, S., 2012, Kredi Riski Tahmininde Yapay Sinir Ağları ve Lojistik Regresyon Analizi Karşılaştırılması. *AJIT-e: Online Academic Journal of Information Technology*, 3(9), 23-30.
- BOLT, G., 1994, *Market and Sales Forecasting: A Total Approach*. Kogan Page, Londra. p. 56.
- Bulgan, A., 2013, Pnömatik Devrelerde Optimum Tasarım ve Yapay Sinir Ağları ile Titreşim Analizi, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Makine Mühendisliği Bölümü, Yüksek Lisans Tezi,
- Çuhadar, M., Kayacan, C., 2005, Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye'deki Konaklama İşletmeleri Üzerine Bir Deneme. *Anatolia Turizm Araştırmaları Dergisi*, 16(1), 121-126.

- Çuhadar, M., 2006, Turizm Sektöründe Talep Tahmini İçin Yapay Sinir Ağları Kullanımı ve Diğer Yöntemlerle Karşılaştırmalı Analizi (Antalya İlinin Dış Turizm Talebinde Uygulama).
- Demirel, Ö., Kakilli, A., Tektaş, M., 2010, Anfis ve Arma Modelleri ile Elektrik Enerjisi Yük Tahmini. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 25(3).
- Deveci, M., 2012, Yapay Sinir Ağları ve Bekleme Süresinin Tahmininde Kullanılması, Gazi Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Ana Bilim Dalı, Üretim Yönetimi Bilim Dalı, Yüksek Lisans Tezi.
- Erdogdu, E., 2007, Electricity demand analysis using cointegration and ARIMA modelling: A case study of Turkey. *Energy policy*, 35(2), 1129-1146.
- Feinberg, Eugene A., Dora Genethliou, 2005, "Load Forecasting." Applied Mathematics Restructured Electric Power Systems içinde, yazar Eugene A. Feinberg ve Dora Genethliou, 269-285. Springer US.
- Frechtling, D., 2012, *Forecasting tourism demand*. Routledge.
- Güler, D., Saner, G., Naseri, Z., Yağlı Tohumlu Bitkiler İthalat Miktarlarının Arama ve Yapay Sinir Ağları Yöntemleriyle Tahmini.
- Gürsoy, A., 2012, Yapay Sinir Ağları Yaklaşımıyla Lastik Kalıbı Maliyetinin Tahmin Edilmesi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi.
- Hamzaçebi, C. Kutay, F., 2004, Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini, Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 19(3):227-233.
- Hanke, J. E., Reitsch, A.G., 1992, Business Forecasting, Fourth Edition, Allyn and Bacon, Boston.
- Hebb, D., O., 1949, The organization of behavior: A neuropsychological approach. John Wiley & Sons.
- Hotunluoğlu, H., Karakaya, E., 2011, Forecasting Turkey's Energy Demand Using Artificial Neural Networks: Three Scenario Applications. *Ege Academic Review*, 11: 87-94.
- Jones, Spencer S., 2008, Measuring, Modeling, and Forecasting Demand in The Emergency Department, Doktora Tezi, The University of Utah, USA.
- Kalaycı, S., 2003, SPSS Uygulamalı Çok Değişkenli İstatistik Teknikleri, Asil Yayın Dağıtım A.Ş., Ankara .
- Karaatlı, M., Helvacıoğlu, Ö. C., Ömürbek, N., Tokgöz, G., 2012, Yapay Sinir Ağları Yöntemi İle Otomobil Satış Tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(17), 87-100.

- Karaali, F. Ç., Ülengin, F., 2011, Yapay Sinir Ağları ve bilişsel haritalar kullanılarak işsizlik oranı öngörü çalışması. *İtüdergisi/d*, 7(3).
- Kargı, V., 2015, Yapay Sinir Ağ Modelleri ve Bir Tekstil Firmasında Uygulama, 1.Cilt, Ekin Yayınevi, 1-163.
- Makas, Y., Karaatlı, M., 2016, Yapay Sinir Ağlarıyla Hidroelektrik Enerji Üretiminin Çok Dönemli Tahmini. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 21(3).
- Olgun, S., 2009, Tedarik Zinciri Yönetiminde Talep Tahmini Yöntemler ve Yapay Zeka Tabanlı Bir Talep Tahmini Modelinin Uygulanması, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi.
- Orhunbilge, N., 2002, Uygulamalı Regresyon ve Korelasyon Analizi, İstanbul Üniversitesi İşletme Fakültesi Yayını, No: 281, İstanbul.
- Orhunbilge, N., 1999, Zaman Serileri Analizi Tahmin ve Fiyat Endeksleri, İstanbul Üniversitesi İşletme Fakültesi Yayınları, No: 277, İstanbul.
- Oruç, K. O., Eroğlu 2017, Isparta İli İçin Doğal Gaz Talep Tahmini
- Önder, E., Hasgül, Ö., 2009, Yabancı Ziyaretçi Sayısının Tahmininde Box Jenkins Modeli, Winters Yöntemi ve Yapay Sinir Ağlarıyla Zaman Serisi Analizi. İstanbul Üniversitesi İşletme İktisadi Enstitüsü Dergisi, sy.62, syf.42-63.
- Öztemel, Ercan., 2012, Yapay Sinir Ağları. İstanbul: Üniversite Yayınları
- Rothe, M., Wadhwani, D. A., Wadhwani, D., 2009, Short term load forecasting using multi parameter regression.
- Serttaş, Z., 2011, Türkiye' de Perakende Sektöründe Talebi Etkileyen Etmenler ve Yapay Sinir Ağlarıyla Talep Tahmini Uygulaması, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği, Yüksek Lisans Tezi.
- Şen Z., 2004, Yapay Sinir Ağları İlkeleri, Su Vakfı İstanbul, 975645513
- Tekin, M., 1996, Üretim Yönetimi. Arı Ofset Matbaacılık, Konya. s. 72.
- Tenti, P., 1996, Forecasting Foreign Exchange Rates Using Recurrent Neural Networks. *Applied Artificial Intelligence*, vol.10, pp. 567-581.
- Tebelkıs J., 1995, Speech Recognition using Neural Networks, School of Computer Science Carnegie Mellon University, Pennsylvania, Thesis (PhD)
- Tripathy, S. C., 1997, Demand forecasting in a power system. *Energy conversion and management*, 38(14), 1475-1481.
- Viglionni, G., Cury, M. V. Q., da Silva, P. A. L., 2007, Methodology for Railway Demand Forecasting Using Data Mining. In *Proceedings of the SAS Global Forum, Brazil*.

- Yakut, E., Elmas, B., Yavuz, S., 2014, Yapay Sinir Ağları ve Destek Vektör Makinaları Yöntemleriyle Borsa Endeksi Tahmini, Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 19(1): 139-157.
- Yasar, E., Uckun, A., 2017, "Turkey's Forecasting of Energy Demand with Artificial Neural-Network", International Renewable Energy Conference (IRENEC 2017), 21-29, İstanbul, turkey
- Yazıcıoğlu, N., 2010, Yapay Zeka İle Talep Tahmini, Uludağ Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi.
- Yetiş, Y., Jamshidi, M., 2014, Forecasting of Turkey's Electricity Consumption Using Artificial Neural Network. World Automation Congress. San Antonio, Texas. IEEE Conference Publications.
- Yücesoy, M., 2011, Temizlik Sektöründe Yapay Sinir Ağları ile Talep Tahmini, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi.
- ZhoumcMahon, S.L, Walton, T.A Lewis, A, 2002, Forecasting operational demand for an urban water supply zone. Journal of Hydrology, 259(1): 189-202.

EKLER

EK-1 Otokorelasyon Analizi Komutu – Abone Sayısı

```
### AUTOCORRELATION CHECK ###  
acf(raw.data$abone)  
pacf(raw.data$abone)
```

EK-2 Backtest Analizi – ARIMA(0,1,0)

```
#DERIVING BACKTEST  
backtest1<- fitted.values(AUTOari ma)  
plot(backtest1, type='p', main='Actual vs Backtest')  
lines(subscribers.data$subscribers, col='red')
```

EK-3 Hata Terimleri Histogram Komutu – ARIMA(0,1,0)

```
# TESTING PROCEDURE - AUTO ARIMA  
modA.resi ds<- residuals(AUTOari ma)  
hist(modA.resi ds)
```

EK-4 ARCH Test - ARIMA(0,1,0)

```
Call:  
lm(formula = y[, 1] ~ y[, 2] + 1)  
  
Residuals:  
    Min       1Q   Median       3Q      Max  
-6339814 -5544751 -2540004  2669467 14915291  
  
Coefficients:  
            Estimate Std. Error t value Pr(>|t|)  
(Intercept)  6.803e+06  3.441e+06  1.977  0.0954 .  
y[, 2]      -3.839e-01  3.839e-01 -1.000  0.3560  
---  
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1  
  
Residual standard error: 8020000 on 6 degrees of freedom  
(2 observations deleted due to missingness)  
Multiple R-squared:  0.1428, Adjusted R-squared:  -4.199e-05  
F-statistic: 0.9997 on 1 and 6 DF, p-value: 0.356
```

EK-5 Gün tipi ağırlıklarını bulmaya yönelik ARIMA modeli

Series: load.ts

ARIMA(0, 0, 1) with non-zero mean

Coefficients:

	ma1	intercept	D1	D2	D3	D5	D6	D7	D8
	0.9462	812.2245	-150.3434	-25.9697	-1.9838	3.6694	-4.5198	-29.2762	-198.4514
s. e.	0.0057	13.2027	11.9313	12.7959	9.2343	8.9475	12.5173	11.9228	22.2531
	D9	D10	trend						
	-61.0640	-70.6840	0.1629						
s. e.	9.2958	17.5718	0.0101						

sigma^2 estimated as 14936: log likelihood=-11740.92

AIC=23507.84 AICc=23508.03 BIC=23579.89

Training set error measures:

	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1
Training set	0.04190242	122.213	100.1058	-2.693701	10.44493	1.727428	0.8576761

EK-6 Otokorelasyon Analizi Komutu – Dağıtım Giren Enerji Talebi

```
### AUTOCORRELATION CHECK ###
acf(normalized readings)
pacf(normalized readings)
```

EK-7 ARCH Test - Dağıtım Giren Enerji Talebi

```
# ARCH TEST for Heteroskedasticity #
Call:
lm(formula = y[, 1] ~ y[, 2] + 1)

Residuals:
    Min       1Q   Median       3Q      Max
-1.229e+10 -7.907e+09 -7.507e+09 -2.692e+09  2.451e+11

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  7.907e+09  4.550e+09   1.738   0.0877 .
y[, 2]       1.839e-01  1.301e-01   1.413   0.1630
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 3.36e+10 on 57 degrees of freedom
(2 observations deleted due to missingness)
Multiple R-squared:  0.03385, Adjusted R-squared:  0.0169
F-statistic: 1.997 on 1 and 57 DF, p-value: 0.163
```

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Büşra YAPICI
Uyruğu : T.C.
Doğum Yeri ve Tarihi : Konya 29/03/1989
Telefon : 5057935527
Faks :
e-mail : busrayapici89@gmail.com

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise :	Karatay Anadolu Lisesi	2007
Üniversite :	Selçuk Üniversitesi	2012

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2014	Meram Elektrik Perakende Satış A.Ş.	Uzman

YABANCI DİLLER

İngilizce