



**T.C.**  
**KONYA TEKNİK ÜNİVERSİTESİ**  
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**MAKİNE ÖĞRENME TEKNİKLERİ İLE**  
**TÜRKİYE'NİN DOĞALGAZ ENERJİ**  
**TÜKETİMİNİN TAHMİNLENMESİ**

**Osman Emin ERDEM**

**YÜKSEK LİSANS**

**Endüstri Mühendisliği Anabilim Dalı**

**Ağustos-2019**  
**KONYA**  
**Her Hakkı Saklıdır**

## TEZ KABUL VE ONAYI

Osman Emin ERDEM tarafından hazırlanan “Makine Öğrenme Teknikleri İle Türkiye’nin Doğalgaz Enerji Tüketiminin Tahminlenmesi” adlı tez çalışması 09/09/2019 tarihinde aşağıdaki jüri tarafından oy birliği / ~~oy çokluğu~~ ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Endüstri Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

#### Başkan

Doç. Dr. İsmail KARAOĞLAN

#### Danışman

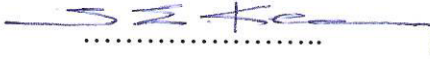
Doç. Dr. Saadettin Erhan KESEN

#### Üye

Dr. Öğr. Üyesi Kemal ALAYKIRAN

### İmza

  
.....

  
.....

  
.....

Yukarıdaki sonucu onaylarım.

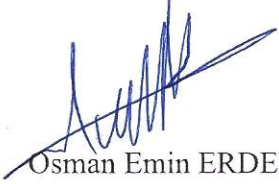
Prof. Dr. Hakan KARABÖRK  
Enstitü Müdürü

## 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 material and results that are not original to this work.



Osman Emin ERDEM

Tarih: 09.09.2019

## ÖZET

### YÜKSEK LİSANS

## MAKİNE ÖĞRENME TEKNİKLERİ İLE TÜRKİYE’NİN DOĞALGAZ ENERJİ TÜKETİMİNİN TAHMİNLENMESİ

**Osman Emin ERDEM**

**Konya Teknik Üniversitesi  
Lisansüstü Eğitim Enstitüsü**

**Endüstri Mühendisliği Anabilim Dalı**

**Danışman: Doç. Dr. Saadettin Erhan KESEN**

**2019, 52 Sayfa**

**Jüri**

**Doç. Dr. İsmail KARAOĞLAN  
Doç. Dr. Saadettin Erhan KESEN  
Dr. Öğr. Üyesi Kemal ALAYKIRAN**

Teknolojinin ilerlemesi ve dünya nüfusunun giderek artması enerjiye olan ihtiyacın her geçen gün artması anlamına gelmektedir. Dünyadaki kullanılabilir enerji kaynaklarının en önemlilerinden biri doğalgazdır. Türkiye’nin doğal ve yeraltı kaynaklarının sınırlı olması nedeniyle enerjide dışa bağımlılığın yüksektir. Bu sebeple satın alınan doğalgazın etkin ve verimli kullanılabilmesi ve önümüzdeki yıllara yönelik güvenilir enerji politikaları geliştirebilmek ancak ülkemizin önümüzdeki yıllardaki doğalgaz tüketiminin doğru tahmin edilmesi ile mümkündür. Bu çalışmada 2010-2018 yılları arasındaki 8 yıllık aylık bazda Türkiye’nin doğalgaz tüketim verilerini kullanarak makine öğrenmesi teknikleri ile tahminleme yapılmıştır. Yapay sinir ağları, rastgele orman ağacı, regresyon, zaman serileri, çok mevsimli zaman serileri tekniklerinin doğalgaz tüketiminin tahmin edilmesinde birbirleri ile olan performansları karşılaştırılmıştır. Deneysel sonuçlar yapay sinir ağlarının 5 metot arasında en düşük ortalama hata kareleri değerine sahip olduğunu ve regresyon tekniğinin yapay sinir ağlarının ardından ikinci en iyi teknik olduğunu göstermiştir. Beş teknik arasında en kötü performansı zaman serileri göstermiştir.

**Anahtar Kelimeler:** Enerji tüketimi, doğalgaz, tahmin, makine öğrenme, R dili

**ABSTRACT**

**MS THESIS**

**ESTIMATION OF TURKEY'S NATURAL GAS CONSUMPTION WITH  
MACHINE LEARNING TECHNIQUES**

**Osman Emin ERDEM**

**Konya Technical University  
Institute of Graduate Studies  
Department of Industrial Engineering**

**Advisor: Assoc. Prof. Dr. Saadettin Erhan KESEN**

**2019, 52 Pages**

**Jury**

**Assoc. Prof. Dr. İsmail KARAOĞLAN  
Assoc. Prof. Dr. Saadettin Erhan KESEN  
Asst.Prof.Dr. Kemal ALAYKIRAN**

Technological advancements coupled with growing world population require the increasing need of energy. Natural gas is one of the most important usable energy resources. Turkey is with high external dependency on energy as it has its own limited natural and underground energy resources. Thus, in order to effectively and productively use of natural gas purchased from foreign countries and to make reliable and robust energy policies for the years ahead, it is crucial to make a reasonable and plausible prediction for natural gas consumption of Turkey. In this paper, we estimate the natural gas consumption using machine learning techniques on the basis of real monthly data representing natural gas consumption of Turkey between the years 2010 and 2018. The performances of machine learning techniques involving Artificial Neural Networks, Random Forest Tree, Regression, Time Series and Multiple Seasonality Time Series are compared in predicting the natural gas consumption of Turkey. Experimental results show that among the five techniques, artificial neural networks produce the best estimation, having the lowest mean square errors, followed by regression method. Time series shows the worst performance among all the techniques.

**Keywords:** Energy consumption, natural gas, estimation, machine learning, R Language

## ÖNSÖZ

Ülkemizin kalkınma planlarının gerçekleştirilebilmesi için özellikle üretim alanında kapasitesinin artırılması gerekmektedir. Üretim kapasitesinin artması enerji talebini de artmasına neden olacaktır ve enerji talebi doğru şekilde karşılanmazsa üretim maliyetleri de artacaktır. Üretimde mamullerin birim maliyetlerinin azaltılmasının yolu doğru bir enerji politikası geliştirmekten geçmektedir. Enerji politikalarının iyi yönetilmesi için gelişen ülkelerin ileriye dönük enerji tüketimlerinin ne olacağının iyi belirlenmesi gerekmektedir. Bu doğrultuda enerjinin doğru planlanması için tahmin modellerinin kullanılmasının doğru bir yaklaşım olduğu bu çalışmada izah edilmeye çalışılmıştır.

Bu çalışmam boyunca bana destek olan başta danışmanım Doç. Dr. Saadettin Erhan Kesen olmak üzere yüksek lisans eğitimimde emeği geçen tüm Konya Teknik Üniversitesi Lisans Üstü Eğitim Enstitüsü Endüstri Mühendisliği Ana Bilim Dalı'nda görevli öğretim görevlilerine ayrı ayrı teşekkürlerimi ve saygılarımı sunarım.

Tüm hayatım boyunca her konuda maddi ve manevi desteklerini benden esirgemeyen aileme teşekkürlerimi ve saygılarımı sunarım.

Osman Emin ERDEM  
KONYA-2019

# İÇİNDEKİLER

<b>ÖZET .....</b>	<b>iv</b>
<b>ABSTRACT.....</b>	<b>v</b>
<b>ÖNSÖZ .....</b>	<b>vi</b>
<b>İÇİNDEKİLER.....</b>	<b>vii</b>
<b>SİMGELER VE KISALTMALAR.....</b>	<b>viii</b>
<b>1. GİRİŞ.....</b>	<b>1</b>
1.1 Enerji Kaynakları.....	1
1.1.1 Hidrolik enerji kaynağı.....	2
1.1.2 Rüzgar enerjisi kaynağı.....	3
1.1.3 Jeotermal enerji kaynağı.....	4
1.1.4 Güneş enerjisi kaynağı.....	4
1.1.5 Biyogaz enerji kaynağı.....	5
1.1.6 Kömür enerji kaynağı.....	6
1.1.7 Petrol enerji kaynağı.....	7
1.1.8 Doğalgaz enerji kaynağı.....	8
<b>2. KAYNAK ARAŞTIRMASI.....</b>	<b>14</b>
<b>3. MATERYAL VE YÖNTEM.....</b>	<b>17</b>
3.1 Tahmin Kavramı.....	17
3.2 Makine Öğrenme Teknikleri.....	20
3.2.1 Yapay sinir ağları.....	21
3.2.2 Regresyon.....	26
3.2.3 Rastgele orman metodu.....	28
3.2.4 Zaman serileri.....	29
3.2.5 Çok mevsimsel zaman serileri.....	34
<b>4. DENEYSEL ÇALIŞMA.....</b>	<b>35</b>
<b>5. SONUÇLAR VE ÖNERİLER.....</b>	<b>41</b>
5.1 Sonuçlar.....	41
5.2 Öneriler.....	43
<b>KAYNAKLAR.....</b>	<b>44</b>
<b>EKLER.....</b>	<b>47</b>
<b>ÖZGEÇMİŞ.....</b>	<b>52</b>

## SİMGELER VE KISALTMALAR

### Simgeler

GWh : Gigawatt

Km: Kilometre

Km/h: Kilometre/Saat

Kwh: Kilowatt Saat

m: Metre

m<sup>3</sup>: Metreküp

m/sn: Metre / Saniye

Mwh: Megawattsaat

Mwt :Megawatts

Twh :Tetawattsaat

### Kısaltmalar

BOTAŞ: Boru Hatları İle Petrol Taşıma Anonim Şirketi

BTE: Bakü-Tiflis-Erzurum

İNOGATE: Interstate Oil and Gas Transport to Europe

M.T.A : Maden Tetkik ve Arama

MTEP: Milyon Ton Eşdeğer Petrol

MSE: Mean Square Error

NCAR: National Centre for Atmospheric Research

RİTM: Rüzgar Gücü İzleme ve Tahmin Merkezi

SCPX: Güney Kafkasya Boru Hattı Genişleme Projesi

SOCAR: State Oil Company of Azerbaijan Republic

TANAP: Trans-Anadolu Doğal Gaz Boru Hattı

TBATS : Trigonometric Box-Cox transform ARMA errors Trend and Seasonal

TÜİK: Türkiye İstatistik Kurumu

YSA: Yapay Sinir Ağları



## 1. GİRİŞ

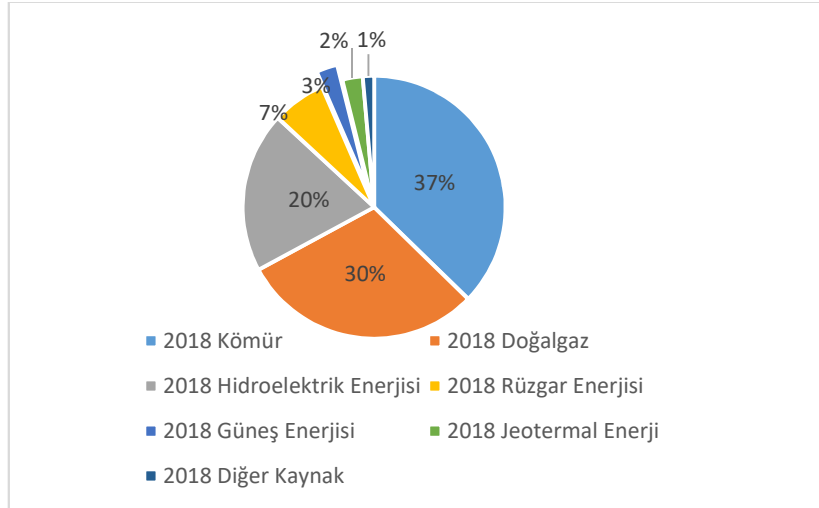
### 1.1 Enerji Kaynakları

Günümüzde dünya ülkeleri için gelişen sanayi ve artan nüfus etkisiyle enerjiye olan gereksinim her geçen gün artmaya devam etmektedir. Bu bağlamda hem bulunduğu coğrafyada enerji kaynaklarının sınırlı olması, hem de gelişen sanayisi ve artan nüfusunun taleplerini karşılayabilmesi için Türkiye’de enerji kritik rol oynamaktadır. Türkiye’nin, gelişen dünya ülkeleri ile ekonomik anlamda rekabet edebilmesinin en önemli koşulları enerji yönetimi ve enerji planının iyi yapılmış olmasıdır. Enerji yönetiminin ve planlanmasının iyi yapılabilmesi için enerjinin ve enerji kaynaklarının ne olduğunun bilinmesi gerekmektedir.

Enerji, fiziksel manada hareket ettirici güç demektir. Üretim ve hizmet faaliyetlerinin gerçekleşebilmesi için güç kullanmak gerekmektedir. Eskiden günümüze insan en önemli güç kaynağı iken günümüzde insanın ürettiği güç tek başına yeterli gelmemektedir. Yeterli gelmeyen bu gücün üretilmesi için yüksek miktarda enerji tüketilmesi gerekmektedir. İhtiyaç duyulan bu enerji doğal kaynaklardan elde edilebilmektedir. Enerji kaynaklarının en önemlileri; Güneş, petrol, kömür, odun, rüzgar, akarsu gibi kaynaklardan belli yöntem ve teknikleri kullanarak ekonomik getiri amacıyla enerji üretilmesinde kullanılır.(Doğanay, 1998: sf 85)

Enerji kaynakları farklı şekillerde sınıflandırılabilir. Enerji kaynakları, birincil tip enerji kaynakları ve ikincil tip enerji kaynağı olarak ikiye ayrılır. Birincil tip enerji kaynağı; yenilenemeyen enerji kaynağı ve yenilenebilir enerji kaynağı olmak üzere iki kısma ayrılır. Petrol, doğal gaz, kömür gibi kaynaklar yenilenemeyen enerji kaynakları olurken hidrolik enerjisi, rüzgâr enerjisi ve güneş enerjisi yenilenebilir enerji kaynağı olarak belirtilmektedir. Birincil tip enerji kaynağından faydalanarak üretilen enerji kaynakları ise ikincil tip enerji kaynağıdır. En önemli ikincil enerji kaynağı elektriktir. (Eren, 2017)

Enerji ve Tabii Kaynaklar Bakanlığı resmi sitesinde alınan verilere göre, Türkiye’de elektrik enerjisi tüketimi 2018 yılında, 2017 yılına göre %2,2 artarak 303,3 milyar kWh, elektrik üretimi ise 2017 yılına göre %2,2 oranında artarak 303,9 milyar kWh olarak gerçekleşmiştir. 2018 yılı elektrik üretiminde kullanılan enerji kaynakları dağılımı Şekil 1.1’de verilmiştir.(Anonim, 2019c)



**Şekil 1.1** 2018 yılı elektrik üretiminde kullanılan enerji kaynakları

Türkiye'nin uygulanmakta olan kalkınma planları neticesinde, küresel ekonomide önemli bir güç olması hedeflenmektedir. Hedefler doğrultusunda kalkınma hamlelerini gerçekleştirebilmek için Türkiye'nin dünya pazarında hakim olduğu sanayi kollarında üretim kapasitesini artırması, yeni sanayi kolları bulması ve bunun yanı sıra artan nüfusun taleplerini karşılayabilmesi gerekmektedir. Üretim kapasitesinin ve nüfusun artması sonucunda enerji talebinde artış meydana gelmektedir. Bu ve benzeri nedenlerden dolayı enerji kaynaklarının iyi yönetilmesi bu hedeflerin gerçekleşmesinde kilit önem taşımaktadır.

Enerji kaynağı kullanımında genel olarak Türkiye'de yenilenemeyen enerji kaynakları; kömür, petrol, doğal gaz olarak sınıflandırılırken yenilenebilir enerji kaynakları hidrolik enerji, rüzgâr enerjisi, güneş enerjisi ve biyokütle enerjisi olarak sınıflandırılır.

### 1.1.1 Hidrolik enerji kaynağı

Yenilenebilir enerji kaynaklarından hidrolik enerji potansiyeli Türkiye'de hem çok sayıda akarsu bulunması hem de ortalama yükseltisi fazla olan akarsuların önemli kısmının derin vadilerden akması nedeniyle hidrolik enerji potansiyeli oldukça yüksektir.

Türkiye Avrupa kıtasında Norveç'ten sonra ikinci olarak hidrolik enerji potansiyele sahip olmasına rağmen bu potansiyeli kullanamamıştır.(Anonim, 2019d) Hidrolik enerji potansiyelinin kullanılmaması bazı ekonomik ve beşeri faktörlere bağlıdır. Ülke yatırımları ve yüksek harcamaları yürütecek mühendislik ve teknoloji imkanına sahip değilse var olan hidrolik potansiyeli kullanmakta güç hale gelecektir. Bir başka kısıtlayıcı faktör ise pazarlama koşulları olup pazarlama her satılan mal için önemli olduğu gibi hidroelektrik enerji içinde önemlidir. Elektrik, bir yandan elektrik üretim

tesislerinde üretilirken bir yandan da yarıçapı 2.500 km'yi aşmayan bir bölgede tüketilmesi gereklidir. Bu nedenden dolayı hidroelektrik enerji depolama ve istenildiği zaman talep edilecek kadar satılması olanaklı değildir.(Doğanay, 1998: sf 15-18)

Zorlukları olmasına rağmen hidrolik enerji kaynağı en güvenilir enerji kaynaklarından. İlk yatırım maliyeti yüksek işletme maliyeti düşük olan bu enerji kaynağından yararlanılırken içme suyu, hayvanların sulanması, arazilerin sulanması, erozyonların önlenmesi gibi ekonomik ve beşeri faydalardan da yararlanılmaktadır.

### **1.1.2 Rüzgar enerjisi kaynağı**

Rüzgar gücü güneşten kaynaklı oluşan bir enerji türüdür. Güneş yeryüzünü eşit derecede ısıtamadığından dolayı alçak ve yüksek basınç merkezlerinin etkileşiminden rüzgar meydana gelir. Rüzgar alçak basınç merkezlerinden yüksek basınç merkezlerine doğru hareket eder.

İmal edilecek olan rüzgar türbininin ekonomik olup olmamasını, rüzgar hızı (şiddeti) ve rüzgar yönü doğrudan etkileyen etmenlerdir. Yapılan çalışmalarla rüzgar hızı 5-6 m/sn, diğer deyişle 27 km/h' dan 35 km/h kadar olan rüzgarlardan elektrik enerji üretimi yapılabilmektedir. Rüzgar yönünün belirlenmesinde, en önemli etmenlerden biride bölgenin bulunduğu sıcaklık değerleridir.(Doğanay, 1998: sf 19) Rüzgar yönü belirlenmesinin de ikinci önemli konu, hakim rüzgarın yıl boyunca hangi yönlerden estiğinin sayısıdır. Rüzgarın frekansı yani sürekliliği ve rüzgar hızı yeterli ise o bölgede kurulacak rüzgar türbini ekonomik olacaktır.

Rüzgar enerjisi kullanım alanları; küçük miktarda su ihtiyacını karşılamak için mekanik su pompası, tekli sistemlerle küçük yerlerin elektrik talebinin karşılanması şeklinde doğrudan doğruya şebeke bağlantılı yapılar olarak hayata geçirilmiştir.(Anonim, 1994: sf 49) Türkiye'de Ege ve Marmara bölgelerinde ve Güneydoğu bölgelerinde rüzgar enerji potansiyeli yüksektir. Bu bölgelerde ekonomik olarak rüzgar enerji santrali kurulup işletilebilir.(Doğanay, 1998: sf 553)

Türkiye'de ticari manada ilk rüzgâr santrali, 1998'de İzmir'in Çeşme ilçesine bağlı Alaçatı'da kurulmuştur. Rüzgâr santrallerinin, Türkiye'de yaygın olarak kullanılması sağlamak amacıyla ekonomik bölgelerin belirlenmesi amacıyla bilgisayar destekli rüzgar gözlem istasyonları yapılmıştır. Türkiye bu yatırımların ardından enerji üretiminde adından söz ettirmeye başlamıştır. (Anonim, 2019e)

### 1.1.3 Jeotermal enerji kaynağı

Yer kabuğunda meydana gelen sıcaklık iki temel nedenden dolayı oluşur. İlki magmanın hareket ederken ki oluşturduğu sıcaklık ikincisi ise yerin kendi sıcaklığıdır. Jeotermal enerji, magmanın ısıttığı sıcak su ve su buharını ifade etmektedir. Bu sıcaklık ortalama 1100-1200 °C'ı bulabilmektedir. Volkanizma hareketlerinde oluşan magmadan ayrılan çeşitli gazların yoğunlaşması ile sıcak su buhar karışımı meydana gelmektedir.(Doğanay, 1998: sf 410-415) Anlaşılacağı üzere jeotermal enerji, magmanın ısıttığı sıcak su ve su buharını ifade etmektedir. İlk zamanlardan günümüze sağlık için kullanılmakta iken günümüzde binaların ısıtılmasında, seracılıkta ve elektrik enerjisi elde etmekte kullanılmaktadır. Jeotermal kaynaklarımız %90 oranında ısıtma ve termal turizm için kullanılırken %10 oranında elektrik enerjisi üretiminde kullanılmaktadır.(Anonim, 2019a)

Türkiye'nin jeotermal potansiyeli oldukça yüksektir. 1962 yılından günümüze MTA Genel Müdürlüğü tarafından araştırmalar yapılmıştır. Bunun sonucunda; jeotermal potansiyel oluşturan alanların en çok oranda Batı Anadolu'da, ikincil en yüksek oranda İç Anadolu'da yer aldığı tespit edilmiştir. (Anonim, 1994: sf 48) Jeotermal enerji rezervleri hakkında tahminde bulunmak zordur; çünkü yer kabuğu mevsimsel etkilerden çok fazla etkilenmez. Bundan dolayı enerji rezervinin tam olarak ne kadar olacağını kestirmek mümkün olmamaktadır.(Doğanay, 1998: sf 413)

Jeotermal enerji uygulamalarında Kızıldere Santrali'nde ilk elektrik üretimi 1975 yılında başlatılmıştır. 2008 yılında, Jeotermal Kaynaklar ve Doğal Mineralli Sular Kanunu'nun yürürlüğe girdikten sonra ve özel sektörün araştırma ve geliştirme faaliyetlerinin de katkısıyla, toplam jeotermal ısı kapasitesi 35.500 MWt'e ulaşmıştır (Anonim, 2019a).

### 1.1.4 Güneş enerjisi kaynağı

Güneş, organik ve inorganik enerji kaynakları, jeoenerji kaynağı ve birçok enerji kaynağının köküdür. Güneşin yüzey sıcaklığı ortalama 6000 °C sıcaklığında olup uzaya oldukça fazla elektromanyetik dalga yaymaktadır. Güneşten gelen radyasyonun iki milyarda biri sayesinde yeryüzü ısınmaktadır. Gelen bu radyasyonun miktarını hesaplamak oldukça zordur; fakat bazı kaynaklar teorik olarak tahminde bulunabilmektedir. Gerçekte bu tahmin coğrafi nedenleri dikkate almadan ileri sürülmüş bir değer olup  $700 \times 10^{12}$  Mwh enerji sağladığı hesaplanmıştır. Bu değer 122 trilyon taş kömüre eşit olduğu da ileri sürülmektedir.

Hesapların doğruluğu her ne kadarda tartışılır olsa da dünya üzerinde bu enerjiden yararlanmak açısından en uygun yerler Ekvator'un 40° kuzeyi ve 40° derece güneyi arasında kalan alanlardır. Bundan dolayıdır ki arada kalan bu bölgeye güneş enerji kuşağı denilir.(Doğanay, 1998: sf 415-417)

Güneş enerjisinden yararlanma potansiyeli açısından Türkiye coğrafi konumunun avantajından dolayı oldukça iyi durumdadır. Türkiye'nin ortalama ısınma şiddeti 308 cal/cm<sup>2</sup> gün (3.6 kWh/m<sup>2</sup> gün) olarak hesaplanmıştır. Yıllık güneşlenme süresi de 2640 saat olduğu ileri sürülmektedir.(Anonim, 1994: sf 50) Güneş enerjisi potansiyeli en yüksek yerler, Güneydoğu Anadolu bölgesi, Akdeniz ve Ege'nin kıyı kesimidir. Güneşlenme süresi en az olan yer Karadeniz kıyılarıdır. Tükenmeyen enerji kaynaklarından biri olan güneş enerjisinden ısınma ve elektrik enerjisi üretmek amacı ile yararlanılmaktadır.

İşletmelerdeki güneş enerjisi santral sayısı 2018 yılında 5.868 adet olup bunların 4.981,2 MW'ı lisanssız, 81,8 MW da lisanslıdır. Toplamda güneş enerjisi üretim gücümüz 5.063 MW'a ulaşmış olup toplam elektrik üretimi içerisindeki payı da %2,5 yükselmiştir (Anonim, 2019g).

### **1.1.5 Biyogaz enerji kaynağı**

Biyokütle enerjisi, bitkisel ve hayvansal kökenli maddelerden yani organik maddelerden elde edilmektedir. Mısır koçanı, saman, pamuk atıkları, odun, evsel atıklar ve hayvansal atıklar oksijensiz ortamda fermantasyon işlemine tabi tutulduktan sonra açığa çıkan metan gazı (CH<sub>4</sub>) biyogaz olarak isimlendirilir. Biyokütle enerjisinin oldukça ekonomik olduğu uygulamalar sonucunda tespit edilmiş olup 1 ton biyomas maddesi fermente işlemine tabi tutulduktan sonra 1.2 varil petrol ile eşdeğer enerji verdiği ileri sürülmektedir. Bu kaynaklardan elde edilen gazın büyük bir kısmının metan gazından oluştuğu belirtilmektedir.(Doğanay, 1998: sf 434)

Klasik olarak biyokütle enerjisinden yararlanma; odun, bitkisel ve hayvansal atıkların doğrudan yakılması şeklindedir. En yeni teknoloji ile biyokütle enerjisinden yararlanma ise biyogaz ve biyodizel gibi ürünlerin elde edilmesi şeklindedir. Biyodizel elde etmek için kolza, ayçiçeği, soya, aspir gibi yağlı tohumlar ve hayvansal yağlar ile mısır, buğday ve şeker pancarı gibi atık ya da mamullerden yararlanılır. Biyogaz için hayvansal, bitkisel ve şehir atıklarından yararlanılmaktadır. Bu organik atıklar kullanılarak üretilen elektrik ilk kurulduğundan günümüze çok yüksek artış gerçekleştirilmiş olup 3.216 GWh elektrik üretimi gerçekleştirilmiştir.(Anonim, 2019h)

### 1.1.6 Kömür enerji kaynağı

Türkiye'nin yenilenemeyen enerji kaynakları bakımından rezervleri kısıtlı olsa da kullanım alanları fazladır. En fazla kullanılan yenilenemeyen enerji kaynaklarından biri de linyittir. Oluşumu taşkömüründen eski olmayıp Jeolojik Zaman'ın Tersiyer Dönemi içinde gerçekleşmiştir.(Doğanay, 1998: sf 18)

Linyit, termik santrallerde yakıt olarak kullanılan bir kömür çeşididir. Linyitin termik santrallerinde kullanılmasının nedeni ısıl değerinin düşük, barındırdığı kül ve nem miktarı fazla olmasıdır.(Anonim, 2019i) Sanayi sektörünün 1950 sonrasında gelişmesi ile paralel olarak linyite olan talepte 1950 yıllarından itibaren artış olmuştur. Özellikle 1950'li yıllardan sonra termik santrallerin sayılarının giderek artmasını linyite olan talebinde giderek artırmasını sağlamıştır. Linyitler termik santrallerin dışında meskenlerin ısıtılmasında kullanılmaktadır.(Doğanay, 1998: sf 18-19)

Linyit yerkabuğunda bol miktarda olması nedeniyle meskenlerde ve termik enerji santrallerinde kullanımı yaygın olan enerji hammaddesidir. (Anonim, 2019i) Türkiye linyit rezervi büyük olan bir ülkedir, bundan dolayı ülkedeki linyit talebi büyük ölçüde karşılanabilmektedir.

Jeologlarca yapılan araştırmada linyit rezervleri subbitümlüler dahil olmak üzere 517.77 milyar ton olarak belirlenmiş olup (Anonim, 1994: sf 3) 1960 -1995 yılları arasında yapılan rezerv belirleme çalışmaları neticesinde 114 sahada yaklaşık olarak 8.3 milyar ton rezerv bulunmuştur. Keşfedilen linyitin yapılan çalışmalar neticesinde 10 milyar tonu bulacağı da ön görülmektedir. Türkiye'de Tersiyer Devre ait arazilerin her bölgede yaygın oluşu nedeniyle linyit ülke genelinde çok miktarda bulunmaktadır. (Doğanay, 1998: sf 15) Linyit rezervleri daha çok, Yatağan (Muğla), Soma (Manisa), Tavşanlı, Tunçbilek, Seyitömer (Kütahya), Nallıhan (Ankara), Dodurga (Çorum), Çeltek (Amasya), Aşkale (Erzurum), Kangal (Sivas), Orhaneli (Bursa), Çan (Çanakkale) ve Afşin-Elbistan'da (Kahramanmaraş) bulunmaktadır. Linyitten elektrik enerjisi üretilen başlıca termik santraller; Yatağan, Soma, Tavşanlı, Tunçbilek, Çayırhan ve Afşin-Elbistan'dır. Türkiye'de mevcut durumda elektrik üretiminde en çok pay linyit kullanımındadır (Anonim, 2019i)

Taşkömürü yüksek kalorili kömürler sınıfındadır. Antrasit haricindeki kömür sınıfına taş kömürü adı verilir, karbon oranları yüksek olduğundan dolayı verdiği enerji de yüksektir. Demir çelik sanayisinde yüksek enerjiye ihtiyaç olduğu için bu sanayi kolunda taşkömürü oldukça fazla talep görmektedir. Dünya kömür rezervinin %80'i taş kömüründen oluşur. Jeolojik Zaman'ın Karbonifer Dönemi ve Permiyen Dönemi

boyunca oluşmuştur.(Doğanay, 1998: sf 503) Yapılan araştırmalar neticesinde dünyanın taşkömürü rezervleri antrasit ve bitümler dahil olmak üzere 521.41 milyar ton olarak hesaplanmıştır (Anonim, 1994) Türkiye'nin yataklarının toplam rezervi yaklaşık olarak 1.5 milyar ton olarak hesaplanmıştır. En fazla taşkömürü Kuzeybatı Anadolu Karbonifer Havzası ismi verilen, Ereğli Zonguldak-Amasra Havzasında olduğu belirlenmiştir.(Doğanay, 1998: sf 503-506) Türkiye'nin taş kömürü rezervi bakımından Batı Karadeniz önde gelmektedir. Taş kömürü yataklarının bulunduğu alan; Zonguldak ile Kastamonu'nun İnebolu ilçesi arasındaki bölgedir. Bu bölgeden elde edilen taş kömürünün belli bir bölümü Ereğli ve Karabük demir çelik fabrikalarında enerji kaynağı olarak kullanılmaktadır. Belli bölümü de Çatalağzı Termik Santralinde elektrik enerjisi üretiminde kullanılmaktadır. Türkiye'de taş kömürü talebi karşılanamadığı için taş kömürü ithalatı yapılmaktadır.

Türkiye linyit rezerv ve üretim değerleri açısından dünyada orta sırada, taşkömüründe ise alt sırada değerlendirilir. Dünyada toplam linyit/alt bitümlü kömür rezervi değerine bakılacak olursa yaklaşık %3,2 pay Türkiye'ye aittir. Linyit rezervinin %46'sı Afşin-Elbistan havzasında bulunmaktadır. Taş kömürü rezervi ise Zonguldak civarında olup toplam 1,30 milyar tondur.

Birincil enerji tüketimi Türkiye'de 2017 yılı sonu itibariyle toplamda 145,3 Milyon Ton Eşdeğer Petrol (MTEP) değerindedir, bu tüketim içinde kömürün payı %27'dir. 2018 yılı sonu değerler neticesinde kömüre dayalı santral kurulu gücü 18.997 MW olup toplam kurulu gücün %21,5'ine karşılık gelmektedir. İthal kömüre dayalı kurulu güç 8.794 MW iken, yerli kömüre dayalı kurulu güç 10.203 MW değerindedir. Kömürden 2018 yılında 113,3 TWh elektrik üretilmiştir olup kömürün elektrik üretimindeki payı %37,3 düzeyindedir.(Anonim, 2019i)

### **1.1.7 Petrol enerji kaynağı**

Dünyada birincil enerji talebi her geçen gün artmaktadır, 2030 yılına kadar bu talebin %40 oranında artması beklenmektedir. Birincil enerji talebini karşılaması beklenen bölge Türkiye'nin de bulunduğu bölge üzerinde olup yaklaşık olarak petrol ve doğalgaz rezervinin %70'lik bölümünü oluşturur. Türkiye'nin bu bölgede bulunması jeopolitik önemini artırmaktadır zira petrol ve doğalgaz rezervinin dörtte üçüne sahip ülkelerle komşudur. Türkiye; Hazar, Orta Asya, Orta Doğu ülkeleri ile Avrupa'daki pazara doğrudan koridor oluşturmaktadır. Bundan dolayı Türkiye birçok enerji projesine ortak olmuştur.

Dünya yıllık enerji gelir giderlerinde petrolün payı 1950 öncesinde %30'un altında iken 1980 yılında %50'yi bulmuş, 1990'da %55'e ulaşmıştır sadece yıllık gelir giderdeki payı göz önüne aldığımızda petrolün küresel ekonomide ne kadar önemli olduğu anlaşılmaktadır. Petrolün günlük hayatta ki kullanımlarını; yakıt olarak kullanılması, ısı kaynağı olarak kullanılması, sanayi hammaddesi olarak kullanılması olarak sınıflandırabiliriz. Deniz taşımacılığında demiryolu taşımacılığında kara taşımacılığında ve hava taşımacılığında yaygın olarak kullanılmaktadır. Isı kaynağı olarak meskenlerin ısıtılması, elektrik üretiminde kullanılmasında büyük önem kazanmıştır. Petrol sanayisinde birçok petrokimya endüstrisinin hammaddesi konumundadır. (Doğanay, 1998: sf 157)

Türkiye petrol kaynağının rezervi konusunda şanslı değildir. 1934 yılından günümüze arama çalışmaları devam ettiği halde ülke talebini karşılayacak rezervler bulunamamıştır.(Doğanay, 1998: sf 520) M.T.A (Maden Tetkik ve Arama) kurulmasıyla beraber arama çalışmaları bu kurum tarafından yapılmış olup ilk Türk petrolüne, 1940 yılında Raman 1 kuyusunda, 1050 m derinliklerinde rastlanmıştır. Daha sonraki yıllarda yapılan arama çalışmalarında 1951'de Yanarsu (Garzan) petrol bölgesi bulunmuştur.(Gürel, 1982) Daha sonraki dönemlerde Diyarbakır, Batman, Adıyaman petrol yatakları bulunmuştur. Türkiye'de yerli ve yabancı petrol arama şirketlerin arama çalışmalarında başarılı sonuçlar elde edilememiştir zira açılan 100 kuyudan 80'i boş çıkmıştır. Diğer kuyu açan ülkelerde boş kuyu çıkma yüzdesi A.B.D'de 20, İran-Irak'ta 5 olmuş, S.Arabistan ve Kuveyt'te her kuyudan petrol keşfedilmiştir.(Doğanay, 1998: sf 552) Türkiye petrol üretiminde geçmiş yıllara bakılarak önemli bir artış olmasına rağmen petrol ihtiyacını karşılayamamaktadır. 1946 yılında 550 ton olan üretim 1965 yılında 1.5 milyon ton 1970 yılından sonra 3.5 ile 4 milyon ton arasına ulaşmıştır. Buna rağmen Türkiye petrol üretimi, tüketimini karşılayamadığı gibi her geçen yıl üretim ve tüketim arasındaki fark artmaktadır.(Doğanay, 1998: sf 526) Bunun için Irak, Nijerya, İran, Kazakistan ve Suudi Arabistan'dan petrol ithal etmiştir. Türkiye'nin ham petrol ithalatı 2017 yılında 25,8 milyon tonu bulurken bunun yanında 16,8 milyon ton petrol ürünleri ithal etmiştir. Türkiye aynı dönemde 10,1 milyon ton petrol ürünü de ihraç etmiştir.(Anonim, 2019k)

### **1.1.8 Doğalgaz enerji kaynağı**

Yapısında birçok bileşik ve elementi belli oranlarda bulunduran doğalgazın oluşumunda birçok düşünce olsa da en çok kabul gören görüş bitkisel ve hayvansal atıkların yüksek sıcaklıklarda ve yüksek basınçta yer altında milyonlarca yıl bekleyip



kimyasal reaksiyonlar sonucu oluşan hafif, renksiz ve kokusuz bir gaz olduğudur. Bileşiminde hem metan, etan, propan gibi hidrokarbonları barındırırken hem de karbondioksit, oksijen, nitrojen, hidrojen sülfür gibi bileşik ve elementleri barındırır. (Zumerchik, 2001)

Doğalgaz tarihsel olarak çıkarımı incelendiğinde 1800'lü yıllarda petrolün yanında yan ürün olarak çıkartılıp kullanım maksadı olmadığı düşünülerek önem verilmemiştir. İlk tüketimi A.B.D 20. yüzyılın ortalarında gerçekleştirmiştir. 1960'lı yıllarda üretim alanlarında amaçsız kullanılmış olup yüksek oranda gaz rezervlerinin keşfedilmesinden sonra önemli enerji kaynağı olarak borularla sevkiyatı son kullanıcılara ulaşmıştır.(Topçu, 2013)

Dünya ülkelerinin gelişmesinde doğalgazın enerji piyasasındaki payı oldukça kritiktir. Dünya ülkeleri için kalkınmanın temel girdisini oluşturan doğalgaz enerjisinin sektöre girişi 1970'li yıllarda baş gösteren petrol krizinden sonra olmuştur. Uluslararası enerji sektörünün yeni enerji kaynağı arayışı doğalgaz üzerinde yoğunlaşmış olup bu arayışla beraber doğalgaza olan talep her geçen gün artış göstermiştir. (Bayrac, 2018)

Uluslararası piyasalarda doğalgazın öneminin artmasıyla birlikte dünya üzerindeki rezervin toplamda ne kadar olduğu ve nasıl dağıldığı ile ilgili çalışmalar yapılmıştır. Dünya doğalgaz rezervlerinin en yoğun olduğu bölgeleri oransal olarak ifade edebilmek için yapılan araştırmada 2009 yılı rakamlarına ulaşılmış olup 2009 yılına ait toplam rezerv miktarı 187.5 trilyon m<sup>3</sup>dür. Bu rezervin 76.2 trilyon m<sup>3</sup>ü en fazla miktarı Katar'da olmak üzere Ortadoğu ülkelerine aittir. Avrupa- Avrasya'da en fazla rezerv Rusya'da olmak üzere 63.89 trilyon m<sup>3</sup>dür. Geri kalan rezerv miktarının %25'ini ise diğer ülkeler oluşturmuştur.(Akpınar ve Başibüyük, 2011)

Rusya ve Katar gibi doğalgaz yatakları bakımından zengin olan ülkelere nazaran Türkiye doğalgaz yatakları bakımından oldukça sınırlı bir ülkedir. Fakat farklı bölgelerde yapılan sondaj çalışmalarının sayıları artırıldıkça Türkiye'nin doğalgaz kaynağı bakımından çokta yetersiz olmadığı aksine işletilecek rezervlerin var olduğu ortaya çıkmaktadır. Tüm sondaj işlemleri tamamlanmamış olsa da rezerv miktarı 10 -12 milyar m<sup>3</sup> arasında olduğu tahmin edilmektedir. Doğalgaz yatakların en önemlileri Trakya Bölgesinde Hamitabat (Kırklareli), Osmancık, Kumrular ve Deveçatağı yerlerinde mevcuttur. Kuzey Marmara Bölgesinde Tekirdağ Marmaraeğlisi ve Güneydoğu Anadolu Bölgesinde Siirt, Batman Mardin'de bulunmaktadır.

Türkiye doğalgaz üretimi 1980 yılında başlanmış olup 23 milyon m<sup>3</sup> üretilmiştir. 1980-1996 yılları arasındaki en yüksek üretim 457 milyon m<sup>3</sup> ile 1986 yılında

yakalanmıştır. Bu zaman zarfı aralığında ise yıllık ortalama 200 milyon m<sup>3</sup> üretim gerçekleşmiştir.(Doğanay, 1998: sf 553) Türkiye'de 1980 yılında 21 milyon m<sup>3</sup> doğalgaz tüketimi gerçekleşirken bu tüketim değeri her yıl artış göstererek 2017 yılında 53,5 milyar m<sup>3</sup> olarak gerçekleşmiştir. (Anonim, 2019f)

Doğalgaz uluslararası piyasalardaki tercih nedenleri içinde doğalgazın enerji kullanım verimliliği ve alternatiflere göre düşük fiyatlı olması, işletme ve bakım maliyetlerinin az olması, depolama maliyetinin olmaması, çevre kirliliğine neden olmaması, taşıma sorununun olmaması vb. nedenlerden dolayı talebi büyüterek artmıştır. Doğalgaz sanayi, konut ve elektrik üretiminde kullanılmasından dolayı tercih nedeni sayılmaktadır. Doğalgazın sağladığı bu avantaj neticesinde doğalgaz dünya enerji kaynakları içinde payı giderek artmakta ve küresel ekonomide son derece kritik ticaret akımlarına konu olmaktadır.(Bayrac, 2018)

Küresel ekonomide doğalgazın giderek önem kazanması Türkiye'nin doğalgaz politikalarını doğru belirlemesi noktasında kritik öneme sahiptir. Türkiye'de doğalgaz arz talep dengesi dikkate alındığında, yıllık gaz talebini karşılama da herhangi bir sorun gözüküyor gibi görünse de kış aylarında yaşanan talep yoğunluğu nedeniyle ithalatı yapılan doğalgaz ülkelerinde yaşanan siyasi istikrarsızlıklar nedeniyle doğalgaz temininde problemler oluşturabilmektedir. Büyük kısmı ithal edilen doğalgazın 2005 yılında Rusya'nın Ukrayna'ya verdiği doğalgazı kesmesi neticesinde Türkiye ciddi anlamda doğalgaz problemi yaşamıştır. Bu yaşanan siyasi kriz neticesinde Türkiye yeni projelerin arayışına girmiştir.(Yarman, 1985)

Jeopolitik konumu itibariyle enerji koridorlarının geçiş noktası üzerinde olan Türkiye'nin içinde bulunduğu enerji koridorları hem Orta Asya-Hazar ve Ortadoğu ülkeleri için hem de Avrupa Birliği ülkeleri için geçiş noktasını oluşturmaktadır. Türkiye doğal gaz boru hatları ve projeleri Şekil 1.2'de verilmiştir.

- Türkiye - Yunanistan Doğal Gaz Enterkonneksiyonu
- Doğu Anadolu Doğal Gaz Ana İletim Hattı (İran - Türkiye)
- Rusya - Türkiye Doğal Gaz Boru Hattı (Batı Hattı)
- Mavi Akım Gaz Boru Hattı
- TürkAkım Gaz Boru Hattı Projesi
- Bakü - Tiflis-Erzurum Doğal Gaz Boru Hattı
- Trans - Anadolu Doğal Gaz Boru Hattı Projesi (Anonim, 2019j)



Şekil 1.2 Türkiye doğal gaz boru hatları ve projeleri (Anonim, 2019b)

Avrupa Birliği ülkeleri, Batı Avrupa’da 2005 yılında yaşanan doğalgaz probleminden sonra geçiş ülkesi olan Ukrayna’ya bağımlılığını azaltmak istemiştir. Bu yüzden Avrupa Birliği de Türkiye üzerinden yapılacak enerji geçişine sıcak bakmıştır.

İNOGATE (Interstate Oil and Gas Transport to Europe) programı kapsamında Güney Avrupa Gaz Projesi’nin ilk adımı olan Türkiye - Yunanistan Doğal Gaz Enterkonneksiyonu; Güney Akdeniz Ülkeleri, Rusya, Hazar Havzası, Ortadoğu Ülkelerinden temin edilecek doğalgazın Türkiye-Yunanistan üzerinden Avrupa piyasasına ulaşması için geliştirilmiştir. Bu hat 2007 yılında çalışmaya başlamış yılda 750 milyon m<sup>3</sup> doğalgaz sevkiyatı gerçekleştirilmektedir.(Engin, 2010)

Battı Hattı; 1984 yılında Türkiye ile Rusya arasında imzalanan doğalgaz sevkiyatı konusunda o zamanki hükümetler arasında imzalanan antlaşmadır. 1985 yılında BOTAŞ (Boru Hatları İle Petrol Taşıma Anonim Şirketi) tarafından doğalgaz tüketimi için en uygun potansiyel olan güzergâh belirlenmeye çalışılmıştır. Bu güzergâh, Türkiye’ye Bulgaristan sınırında Malkoçlar’dan girerek, Hamitabat, Ambarlı, İzmit, Bursa, Eskişehir güzergahını takip edip Ankara’ya ulaşan Rusya-Türkiye Doğal Gaz Boru Hattı 845 km uzunluğuna sahiptir. 1986 tarihinde BOTAŞ ile SoyuzGazExport arası 25 yıl süreli Doğal Gaz Alım-Satım Anlaşması taraflarca imzalanmıştır. 1987 yılında yerli gazın yanında ithal gazın Hamitabat’a ulaşması ile iki gazda Trakya Kombine Çevrim Santrali’nde elektrik enerjisi üretiminde kullanılmaya başlamıştır. Sonrasında İthal gaz 1988’de Ankara’ya ve İstanbul Ambarlı Santraline ulaşmıştır. Bu zaman zarfında

Bulgaristan sınırında bulunan Malkoçlar Ölçüm İstasyonunda yılda 8 Milyar m<sup>3</sup>den 14 Milyar m<sup>3</sup>e ulaşmıştır. (Anonim, 2019b)

Mavi Akım Projesi kapsamında 1997 yılında, yıllık 16 milyar m<sup>3</sup> doğalgaz verilmesi amacıyla BOTAŞ ve Gazexport arasında 25 yıllık Doğal Gaz Alım-Satım Anlaşması taraflarca imzalanmıştır. Bu sayede Rusya'dan gazın Karadeniz'den geçerek Türkiye'ye ulaşması sağlanmıştır. 2003 yılında işletmeye açılan bu proje kapsamındaki boru hatlarının 3 aşamada sevki yapılmıştır. Birinci aşaması İzobilnoye-Djubga arasında 372 km, ikinci aşamada Karadeniz'in 2100 m altından 390 km, Samsun' boru hattında bulunan limandan Ankara'ya 501 km sevk edilmiştir.(Özaydın, 2018) İzlenen güzergâh Samsun'dan Amasya, Çorum Kırıkkale oradan da Ankara'ya uzanarak merkez hatla dağıtımı sağlanmıştır.

Doğu Anadolu Doğal Gaz Ana İletim Hattı ile Türkiye ve İran arasında 1996 yılında İran'da 10 milyar m<sup>3</sup>/yıllık Doğal Gaz Alım-Satım Anlaşması taraflarca imzalanmıştır. Anlaşma kapsamında 1491 km uzunluğunda Doğubayazıt'tan başlayarak Erzurum, Sivas ve Kayseri'den geçerek Ankara'ya ulaşmakta bir yolu da Kayseri ve Konya'dan geçerek Seydişehir'e ulaşmaktadır.

Bakü-Tiflis-Erzurum (BTE) Doğal Gaz Boru Hattı, Şah Deniz bölgesinde üretilen doğal gazın 2001 yılında Türkiye ve Azerbaycan hükümetleri tarafınca imzalanmış olup uygulamaya geçilmiştir. Yılda 6 milyar m<sup>3</sup> doğalgazın Türkiye'ye arzına ilişkin BOTAŞ ve SOCAR (State Oil Company of Azerbaijan Republic ) arasında 15 yıl süreli Alım-Satım Anlaşması 2001 yılında imzalanmıştır. BTE boru hattı, 2004 yılında inşa edilip 2007 tarihinde ise gaz akışı sağlanmıştır. Hat 980 km uzunluğunda olup Bakü-Tiflis-Ceyhan Boru Hattı ile aynı enerji koridorundadır. BTE'nin kapasitesini artırma girişimine 2015 yılında başlanmış olup 2022 yılında tam kapasite ile çalışacağı öngörülmektedir.

Trans-Anadolu Doğal Gaz Boru Hattı (TANAP) , kapsamında 2001 yılında Türkiye artan doğalgaz talebini karşılayabilmek için 6 milyar m<sup>3</sup> gazın Türkiye'ye satışına yönelik Azerbaycan ile anlaşma imzalanmıştır. 2013 yılında alınan yatırım kararları neticesinde Şah Deniz Faz II geliştirme, TANAP ve Trans Adriyatik Doğal Gaz Boru Hattı, Güney Kafkasya Boru Hattı Genişleme Projesi (SCPX) yaklaşık maliyeti 45 milyar dolara mal olacak yatırımı ile üretimden son kullanıcıya ulaştırılmasına kadar ki süreçte etkin rol oynayacaktır. Gürcistan sınırından Yunanistan sınırına kadar uzanacak 1850 km uzunluğundaki hat ile yıllık 32 milyar m<sup>3</sup> kapasiteye sahip boru hattı yapılması öngörülmektedir. BOTAŞ %30, SOCAR %58 ve BP %12 payla projeye ortak

olmuşlardır. 2018 yılında proje kapsamında ilk gaz akışı haziran ayında sağlanmış olup 2020 yılı içerisinde Avrupa'ya gaz akışı verileceği öngörülmektedir.

2016 yılında 15,75 milyar m<sup>3</sup> kapasiteli ve Türkiye'nin komşu devlet sınırlarına kadar uzanan Türk Akım Gaz Boru Hattı Projesi Türkiye ve Rusya Hükümetleri tarafından imzalanmış olup resmi onay süreçleri de tamamlanmıştır. Bu proje Türkiye'nin ihtiyacını karşılamasının yanı sıra Türkiye toprakları üzerinden Avrupa'ya da doğalgaz satışı için aracı olacaktır. Proje kara ve deniz inşası olarak iki kısımda yapılacak olup deniz kısmında yer alan iki hattın inşası Rusya tarafından inşa edilecektir. Kara bölümünde yer alan hatlardan Türkiye'nin ihtiyacını karşılayacak olan hat ise BOTAŞ tarafından yapılacaktır. Diğer hat ile Avrupa'ya gaz verilecek olup bu hattın inşası iki ülkenin yetkilileri tarafından kurulan yarı yarıya ortaklı TürkAkım Gaz Taşıma Anonim Şirketi tarafından yapılacaktır. Batı Hattı ile alınan 14 milyar m<sup>3</sup> doğalgazın Türk Akımı Gaz Projesi ile var olan sözleşmeler de değişiklik olmaksızın Türkiye'ye teslim edilmesi anlaşmasına varılmıştır. Bu durum sayesinde farklı taraflardan kaynaklı siyasi krizlerden Türkiye'nin etkilenmesinin önüne geçilmesi sağlanmış olacaktır. Projenin hem Avrupa ihtiyacını karşılayacak hem Türkiye ihtiyacını karşılayacak inşa çalışmalarının 2019 yıl sonu itibariyle bitmesi planlanmaktadır.(Anonim, 2019b)

## 2. KAYNAK ARAŞTIRMASI

Literatürde tahminleme tekniklerinin kullanımına yönelik çok sayıda çalışma bulunduğundan taramanın kapsamı makine öğrenme tekniklerinin enerji tahmininde kullanımı olarak daraltılmıştır.

Es ve ark. (2014) tarafından yapılan çalışmada; Türkiye'deki enerji talebini 1970-2010 yılları arasındaki Gayri Safi Yurtiçi Hasıla, bina yüz ölçümü, taşıt sayısı, nüfus, ithalat ve ihracat değerlerini model girdisi olarak alıp 2011-2015 yılları arasında Türkiye net enerji talebinin tahmin edilmesi çalışması yapılmıştır. Çalışmada tahmin için çoklu regresyon tekniği ve yapay sinir ağları kullanılmış olup yapay sinir ağlarının tahmin performansının çoklu regresyona göre daha başarılı olduğu görülmüştür.

Karaca ve ark. (2016) tarafından yapılan çalışmada, makine öğrenme tekniklerinden olan basit regresyon ile yapılan tahminler ve çoklu regresyon kullanarak yapılan talep tahminlerinin sonuçları ortaya konulmuştur. Çalışmada, Elektrik tüketimine etki edeceği düşünülen faktörlerin de tüketime etkisi incelenmiştir.

Hamzaçebi ve ark. (2004) tarafından yapılan çalışmada, yapay sinir ağları kullanarak uzun dönemli elektrik enerjisi tüketimi araştırılmıştır. Bu yöntemle bulunduğu sonuçları regresyon teknikleri ve box-jenksin modelleri ile karşılaştırmıştır. Çalışmasının sonucunda yapay sinir ağlarının, elektrik enerjisi tüketiminde daha başarılı performans verdiği görülmüştür.

Şenol ve ark. (2017) tarafından yapılan çalışmada, yapay sinir ağları metodu kullanarak rüzgar türbinlerine ait çıkış güçlerini girdi verileri olarak kullanıp elektrik üretim miktarının tahmin edilmesi çalışması yapılmıştır. Farklı tip rüzgar türbinlerine ait çıkış güçlerini eğitim aşamasında kullanarak model eğitildikten sonra, rüzgar hız verileri test aşamasında çıkan sonuçların regresyon eğrileri ile oluşturulan modelin yaptığı tahminlerin tutarlı olduğu gösterilmiştir.

Makas ve ark. (2016) tarafından yapılan çalışmada, Türkiye'nin Isparta ilinin Aksu ilçesine ait Yenice deresinden beslenen bir hidroelektrik santralin 12 aylık elektrik üretimi tahmin edilmeye çalışılmıştır. Aylık ortalama nisbi nem, aylık ortalama debi ve aylık ortalama yağış verilerini girdi verileri olarak kullanıp ileri beslemeli geri yayılım sinir ağı modeli ile 12 aylık elektrik üretimi tahmin çalışması yapılmıştır. Kurulan modelin aylık elektrik tüketimini başarı ile temsil ettiği belirtilmiştir.

Aksoy ve ark . (2013) tarafından yapılan çalışmada, rüzgar santrallerinde üretilen enerji miktarı ve piyasaya verilecek elektrik enerji fiyatlarını tahmin etmek amacıyla yönelik, geliştirilen yaklaşımla verilerini kümeleyip yerel yüzdellik dilim

regresyonu uygulamasıyla aralık tahmini yapılmaya çalışılmıştır. Bir sonraki adımda ise elektrik enerjisi fiyatlarının tahmini için yöntem geliştirilmiştir. Çalışması yapılan model rüzgar gücü izleme ve tahmin merkezine (RİTM'e) kayıtlı santrallerde denemesi yapıp başarılı sonuçlar elde edildiği saptanmıştır.

Çoban ve ark. (2011) tarafından yapılan çalışmada, Konya'da gelecek dönemlerde enerjinin tedarik edilebilmesi açısından doğalgaz talebine ilişkin öngörülerde bulunmaya çalışılmıştır. Zaman serileri analizleri ile yapılan çalışmada hane halkı doğalgaz talebinin aylar itibari ile dalgalanma göstereceği ve mevsimsellik etkisi olduğu sonucuna varılmıştır. Sanayi sektörü için yapılan analizlerde ise tüketimin yıllar itibari ile bir artış trendine gireceği öngörülmüştür.

Dünder ve ark. (2011) tarafından yapılan çalışmada, Balıkesir-Balya ve İstanbul-Çatalca meteoroloji radar sahalarında bulunan otomatik gözlem istasyonlarından alınan saatlik veriler kullanılarak 48 saatlik rüzgar tahmini ve bu tahminlerin tutarlılığı incelenmiştir. NCAR (National Centre for Atmospheric Research) tarafından geliştirilen ve operasyonel olarak çalıştırılan MM5 orta ölçekli tahmin modeli kullanılmıştır. Tahmin ve gözlemlerin korelasyonun yüksek olduğu belirtilmiştir.

Yavuzdemir (2014) tarafından yapılan çalışmada, Türkiye'nin kısa dönem elektrik talebi tahmini için bulanık mantık modeli oluşturulmuştur. Model, zaman serileri ve regresyon analizi ile elde edilen sonuçların karşılaştırılması yapılmış olup modellerin ortalama mutlak bağıl hata oranları kıyaslanmıştır. Modellerin performans değerlendirmesi sonucunda zaman serileri ile yapılan tahminin, diğer iki modele göre üstün olduğu görülmüştür.

Eren (2017) tarafından TÜİK (Türkiye İstatistik Kurumu) verilerini kullanarak yapmış olduğu çalışmasında Türkiye'nin yıllık doğalgaz tüketimini ve nüfus verilerini kullanarak yaptığı analizde Gri model (1,1) modelini kullanılmış olup 2017 – 2030 dönemi için doğal gaz tüketiminin tahmini yapılmıştır.

Mohamed ve ark. (2019) tarafından yapılan çalışmada, Yeni Zelanda'nın elektrik tüketimi için altı tahmin modelinin performansı karşılaştırılmıştır. Modellerin içinde Harvey modeli evsel ve toplam elektrik tüketiminde tüm modeller içinde en iyi sonucu verirken, Harvey lojistik modeli evsel olmayan tüketimler için en iyi tahmin sonucunu vermiştir.

Bianco ve ark (2009) tarafından yapılan çalışmada, İtalya'da ekonomik ve nüfus etkenlerinin yıllık elektrik tüketimine etkisinin uzun dönem tahmin modeli ile

incelenmesi yapılmıştır. 1970'den 2007'e kadar olan verilerden faydalanarak regresyon modeli ile tahmin çalışması yapılmıştır.

Al-Fattah (2005) tarafından yapılan çalışmada ABD doğalgaz üretim tahmini için zaman serileri modeli kullanılmış olup çıkan sonuçlar geçmiş dönem verilerine dayanarak analiz edilmiştir.

Demirel ve ark. (2011) tarafından yapılan çalışmada İstanbul doğalgaz tüketiminin tahmin edilmesi için çoklu regresyon, ARMAX modeli ve yapay sinir ağıları modellerini kullanarak karşılaştırma yapılmıştır. Çalışmanın sonucunda geri yayımlı yapay sinir ağı modeli, diğer modellere göre üstün gelmiştir.

Busse ve ark. (2012) tarafından yapılan çalışmada, NARX yapay sinir ağıları ile Almanya pazarındaki doğalgaz fiyatlarının günlük hareketlerini dinamik olarak tahmin etme yaklaşımında bulunulmuştur. Bu amaçla bazı ticaret adamları ile yapılan görüşmede hangi özelliklerin tahmin için önemli olduğu görüşülüp sonrasında duyarlı bir analiz yardımı ile hangi özelliğin yapılan tahmini ne derecede etkileyeceği anlaşılmasına çalışılmıştır.

Vıtullo ve ark. (2009) tarafından yapılan çalışmada günlük doğalgaz tüketim talebinin tahmini için çoklu regresyon metodu ve yapay sinir ağıları metodunu GasDay adı verilen bir bilgisayar programı kullanılarak hesaplatılmıştır. Kullanılan bilgisayar programı ilgili veri seti için tahmin sonuçlarında başarılı olduğu belirtilmiştir.

Çalışmamızda literatürden farklı olarak Türkiye'nin aylık bazda doğalgaz tüketimini 5 farklı makine öğrenmesi metodu ile R yazılım programı kullanarak tahmin edilmeye çalışılmıştır. Çıkan tahmin sonuçlarının gerçekleşen sonuçlar ile karşılaştırılması, ortalama kareler hatası ölçütü kullanarak yapılmış olup ölçüt sonuçları kıyaslanarak hangi modelin daha iyi tahminde bulunduğu gösterilmiştir.



### 3. MATERYAL VE YÖNTEM

Öğrenme, belli bir zaman sürecinde yeni bilgilerin bulunması yolu ile davranışların gözden geçirilerek iyileştirilmesi sürecidir (Simon, 1983). Öğrenme işinin bilgisayar tarafından gerçekleştirilmesi makine öğrenmesi olarak adlandırılır. Makine öğrenmesi, geniş kapsamda geçmişteki verilerden elde edilen tecrübeleri kullanarak öğrenme sürecini tamamladıktan sonra gelecekte olacak durumları öğrendiği bu tecrübelerden faydalanarak tahmin etmesi işidir. Makine öğrenme metotlarının iyi uygulanabilmesi için tahmin kavramının iyi anlaşılması gerekmektedir.

#### 3.1 Tahmin Kavramı

Geleceğin tahmini; gelecekte ne olacağını, geçmişe bakarak öngörmektir (Özmuçur, 1990). Talep tahmini, gelecekteki belli bir dönem aralığı için bir veya daha fazla ürünün talep düzeyinin belirlenmesidir. Talep tahmini belli kuralların kullanımı ile alışılmış tahminden öte, bir metottur. Talep tahminlerinin bilimsel bir uygulama olduğunu ve mümkün mertebe az insan hatası içerdiğini söyleyebiliriz.

Anlamlı bir talep tahmini yapmak için iki noktaya dikkat etmek gerekmektedir: Öncelikle talep tahminleri için kullanılacak birim, planlanacak ürün birimi bazında olmalıdır. Diğer nokta ise, tahminin içereceği zaman sürecidir. Talep tahmin süresi, etkin bir karar verebilmeye ve uygulama yapmaya yeterli olmalıdır (Tanyaş ve Baskak, 2015: sf 72).

Talep tahminlerini yapmak için kullanımda olan birçok değişik yöntem vardır. Yönteme dayalı tahminler, sezgiye dayalı tahminlerden çok daha gerçekçidir. Fakat hangi yöntem kullanılırsa kullanılsın, yapılan tüm talep tahminlerinin belli bir doğruluk derecesi söz konusudur ve hiçbir tahmin %100'lük bir doğruluk derecesine sahip olmaz. (Biegel, 1963: sf 21)

Tahmin yapılmasında çeşitli faktörler etkili olur. Bu faktörlerde istikrar varsa yapılan tahminlerin doğruluğu daha fazla olur. Tahmin yapılmak için ilgilenilen faktörlerde istikrar yok ise tahminlerin doğruluğundan emin olunamaz. İstikralsız faktörleri de güvenilir tahmin metotları kullanılarak tahmin yapılması gereklidir. Tahminlerin birden fazla metotla yapılması da tahminlerin doğruluğu ve güvenilirliği konusunda olumsuz durumlar ile karşılaşılma olasılığını düşürür (Bağırkan, 1993). Tahmin metodunun önemli olması ile beraber toplanan verinin doğruluğu da doğru tahmin yapabilmek için önemlidir. Toplanan verinin düzgün olmasına rağmen yanlış tahmin metodunun seçilmesi doğru tahmin yapılmasını zorlaştırır. Bu yüzden en az hatalı sonucu

veren metodun kullanılması önemlidir bunun içinde aynı veri grubuna birden fazla metot uygulayarak yöntemlerin birbirine olan üstünlüğü anlaşılır.

Talep tahminlerinin çeşitleri:

- Uzun periyotla talep tahmini; içerilen uzun periyottan dolayı bu tür tahminler zorunlu olarak düşük ayrıntı düzeyine, yüksek düzeyde belirsizliğe ve düşük doğruluk derecesine sahiptirler.
- Orta periyotla talep tahminleri; periyodu 6 ay ile 1 yıl arası kadardır. İçerdiği devir orta uzunlukta olduğu için bu tür tahminler ayrıntı düzeyi, belirsizlik düzeyi ve doğruluk derecesi yönlerinden uzun devirli talep tahminleri ile kısa devirli talep tahminleri arasında yer alır.
- Kısa periyotla talep tahminler için öngörülen tahmin zamanı hazırlık dönemi ile operasyon dönemi toplamı kadardır(Biegel, 1963: sf 22).

Talep tahminlerinin içerdiği zaman dilimi büyüdükçe sonucu etkileyen unsurların sayısı artar ve bunların arasındaki ilişkiler gittikçe karmaşık bir durum alır. Ülkenin ekonomik yapısı, toplumsal olaylar teknolojik buluşlar vb. etmenleri hesaba katmak gerekir. Bunlardaki küçük farklılıklar nedeni ile uygulamadaki olumsuz sonuçlar derhal ortaya çıkar.(Kobu, 2010: sf 111-112)

Talep tahminleri ile çalışırken belirlenmesi gereken önemli ilkeleri şöyle açıklayabiliriz (Toomey, 1996).

- Tahminler kısa periyotla yapılması daha gerçekçi sonuçlar verir; ne kadar zaman dilimini artırırsanız o kadar yanılırsınız gerçeğini göz önüne alırsak, dönem uzadıkça etki eden unsurlar çoğalacağından uzun devirli tahminlerin tutturulmasının zor olacağı söyleyebiliriz.
- Tahmin daima yanlıştır; tahmin hatası var olmasına karşılık, bu hata hakkında bir kanıya sahip olunması çok önemlidir. Matematiksel metotlarla olası hataların düzeyini hesaplamak olanaklıdır. Geçmiş ortalamalardan olan farklara dayanarak gerçek talebin artı veya eksi yönde belli bir oranda farkı olabileceği beklenebilmektedir.
- Tahmin yöntemi, kullanmadan önce test edilmelidir; Talep tahmininde kullanılan çeşitli modeller vardır ve aynı geçmiş veriler kullanılarak değişik metotlar ile incelenmesi önerilmektedir. Geçmiş veriler ile en iyi çalışan metot, gelecekte de iyi sonuçlar vereceği düşünülerek kullanılabilir.

- Tahmin, kesin talebin yerini tutamaz; tahminlerin bir hata payı vardır. İleriye yönelik elimizde kesinleşmiş veriler varsa bunlar ile ileriye yönelik yapılan tahminler karşılaştırılabilir.

Talep tahmini başlıca dört aşamada gerçekleştirilen işlemdir:

- Bilgi toplanması; çalışmanın değerini en çok etkileyen aşamadır. Öte yandan tahmincinin de amaçlarını göz önüne alarak toplayacağı verilerin cinsi ve ayrıntısı konusunda doğru kararı vermesi gerekir.
- Talep tahmin periyodu; kullanım maksadına göre zamanı belirlenmelidir.
- Talep yönteminin belirlenmesi ve hata hesabının yapılması; toplanan verilerin belirsizlik, duyarlılık, değişim biçimi gibi nitelikler ile uygulama amaçları, kullanılacak yöntemin seçimi göz önüne alınması gereken unsurlardır. Verilere uygun hassasiyette bir tahmin metodu kullanılması gerekir. Kullanılan metodun hassasiyetine dayalı olarak olası hata hesaplamalarının yapılması gerekir.
- Tahmin sonuçlarının doğruluğunun araştırılması; belli bilgiler referans alınarak yapılan tahminler ile gerçek değerler arasındaki farkların belli bir format biçiminde belirlenmesi ve nedenlerinin incelenmesinden ibarettir. (Kobu, 2010: sf 112-114)

Talep tahmini metotlarının teknikleri bireysel varsayımlara, düşüncelere dayanmadan, istatistiksel ve matematiksel modeller kurarak tahminler yapmaya yardımcı olan metotlardır. Bu yöntemler iki sınıfa ayrılabilir; zaman serileri analizleri, çok etmenli analizler.

Zaman serileri analizleri, geçmişteki talep değişim yapısının gelecekte de aynen devam edeceği varsayımına dayanarak, geleceği geçmişin bir devamı olarak tahmin eder.

Çok etmenli analizlerde talep tahmini, zaman serisi analizlerinde olduğu gibi sadece zamanı dikkate alarak düşünmemekte, çok sayıda unsurun, uygun istatistik ve matematiksel metotların etkisini göz önüne alarak tahmin yapılmaktadır(Tanyaş ve Baskak, 2015: sf 82). Çok etmenli analizlerde tüm olası unsurlar belirlenerek ilgili modeller kurulur. Tahminci sözü edilen tahmin metotlarından tümünü veya bir bölümünün doğruluğunu belirlemek için kullanılan farklı tahmin metotlarının sonuçlarını gerçekleştiren sonuçlar ile kıyaslanmasına bağlı olarak karar verir(Biegel, 1963: sf 23-24).

### 3.2 Makine Öğrenme Teknikleri

Doğumumuzdan bu yana vücudumuzun alıcı organları olan gözler, kulaklar, burun, diş ve sinir hücreleri sürekli olarak dışarıdan aldığı bilgileri beynimize sinyal olarak iletir; bizde bu verilerden faydalanarak karşılaştığımız olaylar karşısında deneyim kazanırız. Duyular arası etkileşimle kazandığımız bu yaşam deneyimlerinin kayıt edilmesinden sonra öğrendiğimiz bu bilgilerle olaylara nasıl yaklaşım geliştireceğimize karar veririz. Çalışma alanlarındaki özelliklerin algoritmaya öğretilmesi ile birlikte belli sonuçlar üretilmesi makine öğrenmesi olarak bilinir.(Lantz, 2015: sf 2-3)

Makine öğrenme teknikleri gözlemlerin sayısını artırdıkça daha çok başarılı sonuçlar ortaya koyar. Makine öğrenme teknikleri geniş kullanımı ve çok büyük potansiyeli olmasına rağmen, tekniğin sınırları olduğu bilinmektedir. Gerçek verilerin uygulanmasından önce hangi algoritmanın seçileceği konusunda dikkatli olunmalıdır.(Lantz, 2015: sf 5-7) Algoritmaların seçimini yapmadan önce eldeki verilerin hangi makine öğrenmesi tekniğine uygun olduğu anlaşılmalıdır. Doğru algoritmaların seçilmesi için ise öğrenme metotlarının neler olduğu bilinmesi gerekmektedir.

Makine öğrenmesi tekniğinde öğrenme metotları; deneme yolu ile öğrenme, analogi yolu ile öğrenme, görerek öğrenme, alışkanlıklarla öğrenme, açıklamalardan öğrenme ve keşfetme yolu ile öğrenme olarak sınıflandırılabilir. (Öztemel, 2003: sf 15-20)

Makine öğrenmesi metodunda farklı çağrışım yapmak ve oto çağrışım olmak üzere iki teknik yaygın olarak kullanılır. Farklı çağrışım yönteminde olayları gözlem yoluyla, örnekler yoluyla veya deneme yollarından herhangi biri ile dikkatli olarak incelemek gerekir. Sonrasında genel yönleri ortaya çıkarılarak problemin hedefine ulaşması sağlanır. Bir diğer yöntem oto çağrışım yöntemi olup bu yöntem verilerin sınıflandırılarak öğrenilmesidir. (Öztemel, 2003: sf 23)

Makine öğrenme stratejileri; gözetimli öğrenme, destekleyici öğrenme, gözetimsiz öğrenme ve karma öğrenme olarak 4'e ayrılır. Tahmin modeli neyi öğrenmek istediğini ve nasıl öğrenmeyi amaçladığını, gözetimli öğrenme olarak bilinen bir tahmin modelinin eğitilmesi sayesinde sağlar. Gözetimli öğrenme modelinin eğitim süreci; eğitim işleminde ne öğrenmeye ihtiyaç duyduğu ve nasıl öğrenmeyi amaçladığı açıkça modelde anlatılır (Lantz, 2015: sf 19-20). Gözetimli öğrenmede sistemin öğrenmesine yardımcı olan bir öğretmen vardır. Öğretmen sisteme öğrenilmesi istenilen örnek setinin hem girdileri hem çıktılarını verip o girdilerin karşısında oluşturulması istenen çıktıları sisteme öğretir . (Öztemel, 2003: sf 23)

Gözetimli öğrenmede kategorilere ayırarak sınıflandırma işlemi uygulanır. Sınıflandırmada sınıf olarak bilinen kategorik özellikler tahmin etmek için seviye diye adlandırılan yapılara bölünmelidir. Sınıflandırma makine öğrenmesinde geniş çapta kullanılır ve birçok sınıflandırma algoritması güçlü ve zayıf yönlü farklı tipli veriler için kullanılabilir. Gözetimli öğrenme için bazı örnekler şu şekildedir; laboratuvar verileri, test sonuçları, gelirler gibi sayısal tahmin için kullanılan verilerdir.

Gözetimsiz öğrenmenin, gözetimli öğrenmeden farkı verileri sebep-sonuç ya da giriş-çıkış şeklinde adlandırmadan, veri içerisinde var olan ilişkilerin ve yapıların öğrenilmesidir. Gözetimli öğrenmeye göre daha zordur.(Lantz, 2015: sf 19-20) Gözetimsiz öğrenmede sistemin öğrenmesini sağlayacak öğretmen olmayıp girdi değerleri sisteme gösterilip sistemin bu girdi değerlerinin özelliklerini kendi arasında değerlendirip sistemin öğrenmesi beklenir. Çıkan sonuç kullanıcı kişi tarafından neticeye bağlanır. Destekleyici öğrenmede öğretmen tarafından sisteme gösterilen girdi verilerine karşılık sistemin bir çıktı oluşturması beklenir. Gelen çıktıyı değerlendirerek doğru veya yanlış olarak cevap verir bu cevaba göre sistem öğrenme işlemini tamamlar.(Öztemel, 2003: sf 25) Karma stratejide bahsedilen 3 öğrenme stratejilerinden bir veya birkaçını kullanarak öğrenme süreci gerçekleştirilir.

### 3.2.1 Yapay sinir ağları

Sinir sisteminin çalışma mekanizması örnek alınarak benzer çalışma sisteminin matematiksel modelle uygulanması fikri yapay sinir ağlarının temelini oluşturur. Duyular vasıtasıyla çevrede yaşanan gelişmeleri algıladıktan sonra beyin algılanan bu gelişmelere bir cevap verdiği gibi yapay sinir ağları da geliştirilen modelle cevap verir. (Lantz, 2015: sf 219) Modelin asıl görevi giriş sinyalleri ile çıkış sinyalleri arasındaki ilişkiye bakarak verilen girdi setinden çıktı seti oluşturulması sağlamaktır.(Öztemel, 2003: sf 30) Beyin nöron olarak adlandırılan bağlantı hücrelerini kullanarak oluşturduğu paralel iletim ağı sayesinde algılanan gelişmelere cevap verir. Benzer şekilde yapay sinir ağıda öğrendiği problemleri çözmek için yapay sinir nöronları ya da boğumlarını kullanır.

İnsan beyni yaklaşık 85 milyar nörondan oluşur, bu sayede çok miktarda bilgiyi taşıma kapasitesi sağlanır. Diğer canlı türlerinin gelişmişlik düzeyi arttıkça nöron sayıları da buna bağlı olarak artmaktadır. Örneğin bir kedide yaklaşık 1 milyar nöron, bir farede yaklaşık 75 milyon nöron, kara böcekte yaklaşık 1 milyon nöron ve meyve sineğinde yaklaşık olarak 100 bin nöron vardır. Yapıların karmaşıklığı ve üstünlüğü göz önüne alındığında hiçbir zaman yaratılmış canlılar gibi yapay beyin oluşturmak mümkün olmasa da matematiksel modeller için bu yapılar örnek alınabilir.(Lantz, 2015: sf 221)

Matematiksel modelleri oluşturabilmek için Yapay sinir ağının (YSA) özelliklerini genel olarak belirtmek, çalışma mantığını anlamak konusunda önemlidir.

- YSA, makine öğrenme yöntemi olarak bildiğimiz bilgisayarları kullanarak öğrenmeyi sağlayabilmektedir. Bu sayede örnek veri setinden öğrendiklerini test veri setinde tahmin edebilmeyi sağlamaktadırlar.
- YSA'da ki bilgiler herhangi bir veri toplama yerinde saklanmayıp ağın üstünde bu bilgiler saklanır. YSA gerçekleşmiş olay olmadan öğrenme sürecini tamamlayamaz, yapay sinir ağının çalışması için gerçek olaya ait verilerin bulunması ve toplanması gerekmektedir.
- YSA, örnek verilerini sınıflandırıp onları belli kümeler halinde bir araya getirip yeni gelecek olan verinin hangi sınıfa gireceğini belirleyebilir.
- YSA, verilen şekil parçalarından şeklin tamamını bulması sağlanabilmektedir.
- Veri setinde eksik bilgi olması durumunda YSA çalışmasını sürdürebilmektedir. Çıkan sonuçların performansı incelendiğinde, performansın düşük çıkması eksik verinin önemli olduğu sonucunu doğurur ve bu bilgi çeşitli yaklaşımlarla veri kümesi incelenerek doldurulup yeniden sonuçlar ile kıyas edilerek örnek veri setinin performansı ölçülebilir.
- YSA, nümerik veriler ile çalışabilmektedir. Veriler nümerik değilse nümerik hale dönüştürülmesi gerekmektedir.
- YSA, eksik verilerle çalıştığı için belli bir hata toleransına sahip olması durumu vardır.
- YSA, zamanla eksik verilerden ve hücrelerden kaynaklı olarak zaman içinde eklenen verilerle kademeli olarak bozulma sürecine girebilir.
- YSA tek bir bağlantı değil tüm hücrelerin birbiri ile bağlantısı önemli olup bilgi tüm ağa yayılmış durumdadır bundan dolayı bilginin ağdan alınması zordur.(Öztemel, 2003: sf 33-34)


Tek bir sinir hücresi modeli oldukça basit bir biyolojik model için yapay sinir ağını anlatabilir. Yapay sinir ağları 5 temel etmeden oluşur.

- Girdiler, hem YSA ağı içinden gelen bilgileri hem de dışarıdan gelen bilgileri içerir.
- Ağırlıklar, hücre için önemli olup olmadığı hakkında bilgi vermezler, girdinin hücre üzerine olan etkisi hakkında bilgi verirler. Bundan dolayı ağırlığın sıfır, negatif olması veya değerinin pozitif olması olayın önem derecesini ifade etmez.

Pozitif olması pozitif yönde bir etki oluşturduğunu, negatif olması negatif yönlü bir etki oluşturduğu anlamına gelmektedir. Sıfır olması da etkinin olmadığı anlamına gelmektedir.

- Toplam Fonksiyonu, ne olarak seçilmesi gerektiği genel olarak denenerek bulunur literatür de yapılan araştırmalarda çok çeşitli toplam fonksiyonu olduğunu göstermiştir. Ağ tasarımcıların ağırlık ve girdi çarpımının en büyüğünü kullanırken bazıları bunların en küçüğünü seçebilmektedir. Diğer bilinen toplam fonksiyonları; çoğunluk fonksiyonu ve birikim fonksiyonudur. Toplam fonksiyonlarının hangisinin en iyi olduğu bulunmuş değildir, gerçek olaylar üstüne denemeler yapılarak en iyisi bulunmaya çalışılır.
- Aktivasyon Fonksiyonu, YSA'nın toplam fonksiyonundan gelen net girdileri işleyerek hücrenin vereceği çıktıları oluşturur. Bir ağın içinde birden çok toplam fonksiyonu olduğu gibi birden çok aktivasyon fonksiyonu da olabilir.
- Çıktılar ise aktivasyon fonksiyonunda işlem gördükten sonra çıkan sonuç verileri olarak adlandırılabilir. Çıktılar bir başka hücreye gönderilebileceği gibi direk sonuç olarak da tek çıktı şeklinde gönderilebilir.(Öztemel, 2003: sf 51)

Aşağıda Şekil 3.1'de gösterilen giriş sinyalleri dendritler tarafından ( $x$  sayısal değişkeni) algılanır sonrasında toplam fonksiyonu tarafından toplanır( $\Sigma$ ) ve aktivasyon fonksiyonunda( $f$ ) işlem gördükten sonra çıkış sinyali ( $y$  sayısal değişkeni) olarak çıktı verir. Giriş sinyallerinden çıkış sinyallerine olan tüm işlemler arasında ilişki işlevsel çalışma ağı ile tanımlanmaktadır. Biyolojik nöron etki derecesine göre her bir dendrit sinyaline ağırlık değerini atar.



Şekil 3.1 Basit sinir hücresi (Lantz, 2015: sf 222)

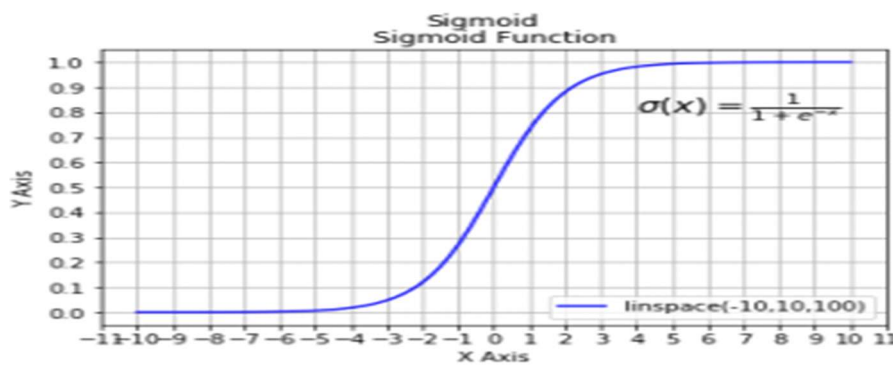
Genel olarak yapay sinir ađında n giriřli dendrit yapısı ařađıdaki formül ile cevap döndürür. Ađırlık deđerleri (w), her bir n giriř deđerine (x<sub>i</sub> olarak gösterilen deđer) atanır. Atanan bu ađırlık deđerleri etki durumuna göre giriř sinyallerine büyük ya da küçük katkı sađlayan deđerlerinin toplamı olarak sonuç verir. Bu toplam aktivasyon fonksiyonu f(x) ve sonuç fonksiyonu y(x) ile kullanılır.(Lantz, 2015: sf 223) Makine öğrenme tekniklerinde yaygın olarak kullanılan aktivasyon fonksiyonu modelimizde kullanılacaktır.

$$y(x) = f\left(\sum_{i=1}^n (w_i \cdot x_i)\right) \quad (3.1)$$

Aktivasyon fonksiyonu yapay sinir ađlarına gelen bilgiyi ađa ileten mekanizmadır. Yapay sinir ađı biyolojik yapısı sonrası modellendiđi gibi, aktivasyon fonksiyonu da tasarımdan sonra modellenir.

Biyolojik sinir hücrelerinin aktivasyon fonksiyonu eřik sınırlarını ařıp gelen sinyallerin tümünü seçerek iřleme alır. Buna yapay sinir ađlarında eřik deđer aktivasyon fonksiyonu denir. YSA'da en yaygın olarak sigmoid aktivasyon fonksiyonu kullanılır, fakat bazı alternatif kullanımlarda mevcuttur. Bunlar; Linear, Saturated Linear, Hyperbolic Tangent, Gaussian aktivasyon fonksiyonu olarak kullanım seçeneklerindedir.(Lantz, 2015: sf 224-225) Günümüzde Őekil 3.2'de gösterilen çok katmanlı algılayıcı sigmoid fonksiyonu modelimizde kullanılacaktır.(Öztemel, 2003: sf 51)

$$f(y(x)) = \frac{1}{1+e^{-y(x)}} \quad (3.2)$$



Őekil 3.2: Sigmoid fonksiyonu (Makinist, 2019)

Ađ topolojisinde yapay sinir ađının öğrenme kabiliyeti, topolojinin kökü, nöron bađlarının yapısı ve bileřenlerine bađlı olarak deđiřkenlik gösterir. Çok sayıda yapay mimari form oluşturulabilir. Yapay mimari formları oluştururken incelenmek istenen



problemin karmaşıklığı dikkate alınır. Ağ topolojisi belirlenirken üç anahtar karaktere dikkat edilir.

- Katmanların sayısı
- Ağda geri bildirim izin verilip verilmediği
- Ağ katmalarını içeren düğüm sayısı.(Lantz, 2015: sf 226)

Katmanlar girdi katmanı, ara katman ve çıktı katmanı olarak üçe ayrılır. Girdi katmanı dışardan gelen verileri alarak işlenmesi için ara katmana gönderilir. Bir veya birden fazla ara katman varsa tüm ara katmanlarda bilgi işlenerek çıktı katmanına gönderilir. Ara katmandan gelen veriler işlenerek çıktı olarak sunulur.(Öztemel, 2003: sf 53)

İşlem görmemiş sinyaller düğümlerden aktivasyon fonksiyonuna ulaşır buradan işlem görerek dönüştürülürler. Girdi ve çıktı düğümleri katman olarak bilinen grup içinde düzenlenir ve girdi düğümlerine ulaşan veriler ağdaki ağırlık değerleri ile işleme girerek çıktı oluşturur. Tek katmanlı ağ yapıları basit özellikli sınıflandırmalarda özellikle doğrudan ayrılabilen sınıflandırma problemleri için kullanılabilirken daha karmaşık problemlerde ağlar daha çok görevi öğrenebilmek için daha fazla katmana gereksinim duyar. Bundan dolayı katmanlar eklenerek daha karmaşık ağ yapıları oluşturulur. Çok katmanlı ağlarda bir veya daha fazla katman ekleyerek gelen sinyalleri çıkış düğümüne ulaşmadan önce giriş düğümlerinde işlem yapılır. Yapay sinir ağında birden fazla gizli katman olması derin yapay ağ olarak veya derin öğrenme olarak isimlendirilir.(Lantz, 2015: sf 227-228)

Tek katmanlı ve çok katmanlı yapay sinir ağ modellerinin çalışma mantığını anlamak kurulacak yapay sinir ağı modelleri için önemlidir. Yapay sinir ağları yalnızca giriş ve çıkış katmanından oluşuyorsa tek katmanlı algılayıcı olarak adlandırılır. Bu yapıda çıktı değerinin sıfır olmasını önleyen eşik değer( $\phi$ ) vardır. Ağırlıklı girdi değerleri ve eşik değerleri toplamı çıktı değerlerini oluşturur. Çıktı fonksiyonu tek katmanlı yapılarda doğrusal fonksiyondur ve bu yüzden ağı iki sınıfı ayıran doğru bulunmaya çalışılır. Ağın çıktısı 1 ise birinci sınıfta -1 ise ikinci sınıfta yer almaktadır. Tek katmanlı algılayıcı iki modelden oluşur; perseptron modeli ve ADALINE/MADALİNE modelidir. Perseptron modeli birden fazla girdi ile bir çıktı üretme sürecidir. ADALINE en küçük kareler yöntemini kullanarak bu hatayı en aza indirecek ağırlıkları bulmaya çalışır ve Perseptron algoritmasına çok benzemektedir. MADALİNE ağları birden çok ADALİNE ünitesinin bir araya gelmesiyle oluşur.(Öztemel, 2003: sf 59-74)

Çok katmanlı ağ yapıları ise doğrusal olmayan problemlerle ilgilenir ve öğretmenli öğrenme mantığına göre çalışır. Girdiler ve o girdilere karşı üretilmesi gereken çıktılar gösterilerek öğretilir. Öğrenme kuralı delta öğrenme kuralının genişletilmiş halidir. Delta öğrenme kuralı iki kısımda incelenir;

- İleri doğru hesaplama ile ağın çıktısı hesaplanır.
- Geriye doğru hesaplamada ağırlıklar güncellenir.

İleriye doğru hesaplamada gelen girdiler değişikliğe uğratılmadan ara katmana gönderilir. Bahsedilen aktivasyon fonksiyonları kullanılarak çıktı değerleri hesaplanır, çıktı değerlerinin tümü bulununca hesaplama işlemi tamamlanır.(Öztemel, 2003: sf 77-78)

Geriye bildirim ağlarda ise kabul edilebilir bir hata miktarı elde edilinceye kadar ağ çıktısı ile gerçek çıktı arasındaki farklar minimize edilmeye çalışılır, bu nedenden dolayı da girdi ağırlıkları devamlı olarak güncellenir. Ağırlıkların güncellenmesinin manası ağın öğrenmesi anlamına gelmektedir.(Lantz, 2015: sf 227-228) Çok katmanlı ağlarda öğrenme süreci uzundur bunun için herhangi bir bilimsel yaklaşım geliştirilmemiştir. Deneme yanılma yöntemiyle belirsiz sayıda iterasyon yaparak en iyi değer yakalanmaya çalışılır. Belli bir iterasyondan sonra hata değerinde daha fazla azalma gerçekleşmez bu durum ağın öğrenmesi manasına gelir.(Öztemel, 2003: sf 82)

### 3.2.2 Regresyon

Matematiksel ilişkiler günlük yaşantımızda birçok etkinin anlaşılmasına yardımcı olur. Örneğin vücut ağırlığı birinin aldığı kalori miktarı ile bağlantılıyken, kazanç ise eğitim ve mesleki tecrübe ile ilişkilidir. Bu gibi ilişkiler rakamsal olarak ifade edildiği için açıklamaları sayısal olarak yapmak kolaylaşır. Bu yaklaşım ile sayısal olarak bazı çıkarımlarda bulunulabilir. Örnek olarak kalori ve kilo özelliklerine sahip problem için günlük fazladan 250 kalori tüketen kişinin, ayda yaklaşık 1 kilo alabileceği sonucuna ulaşılabilir. Başka bir problemin ilişkisel sonucu yılda bir iş tecrübesi yılda ek olarak 1.000 para birimi kazandırabilir. Bu denklemler her durumda mükemmel olmayabilir fakat genelde kabul edilebilir doğruluğu vardır. (Lantz, 2015: sf 172-174)

Regresyon bağımlı bir veya daha fazla bağımsız değişken arasındaki ilişki ile ilgilenir. Bağımsız değişkenlerin bağımlı değişkeni nasıl etkilediği bir katsayı ile belirlenmektedir. Bu katsayıya değişkenin regresyon katsayısı denir. Regresyon katsayısı bağıllığın derecesini gösterir. Bağımlı ve bağımsız değişkenler arasında sebep sonuç ilişkisi bulunması bu metodun kullanılabilirliğine imkan sağlar.

Regresyon çözümlemesinde;  $X_{it}, t = 1,2,3,\dots,n$  ve  $i = 1,2,3,\dots,p$  bilinen bağımsız değişkenleri  $t = 1,2,3,\dots,n$  bağımlı değişkenleri gösterir.

$$y_t = \beta_0 + \beta_1 X_{1,t} + \beta_2 X_{2,t} + \dots + \beta_p X_{p,t} + e_t \quad (3.3)$$

İfadesi için amaç  $y$  değerine en yakın sonuçlar üretecek  $\beta_0$  ve  $\beta_t$  katsayı değerlerini üretmektir. Veri setimizde var olan bağımsız  $X_t$  değerleri ve bağımlı gerçek  $y_t$  değerleri kullanarak  $\beta_0$  ve  $\beta_1$  katsayı değerlerini, verilerin sapma değerlerini en küçükleyecek en küçük kareler yöntemi ile belirlenir (Akdi, 2003).

Problemle ilgili serpilme diyagramları incelendiğinde  $X_{it}$  ve  $y_t$  arasında doğrusal bir eğilim gözüküyor olsa da noktaların olduğu yerden çok sayıda doğru geçirilebilir bu doğruların en uygunu  $y_t$  gözlem değerine en yakın tahmini  $y'$  değerini veren doğrusal fonksiyon olacaktır.

$$e = y_t - y' = y_t - \beta_0 + \beta_1 X_{1,t} + \beta_2 X_{2,t} \quad (3.4)$$

Denklemini minimum yapan doğrusal fonksiyon seçilmelidir. Tüm değişkenler için bu geçerlidir;

$$f(x) = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y - y')^2 \quad (3.5)$$

Bu yöntem “ En Küçük Kareler Yöntemi” adı verilir. Elde edilecek regresyon denklemi ise en küçük kareler yöntemiyle elde edilen basit doğrusal regresyon denklemi olacaktır.

$$\text{minimum} = \sum_{n=1}^n e_i^2 \quad (3.6)$$

$$\frac{de}{d\beta_1} = 2 \sum (-1)(y_t - \beta_0 - \beta_1 X_{1,t}) = -\sum y + n\beta_0 + \beta_1 \sum x \quad (3.7)$$

$$\frac{de}{d\beta_2} = 2 \sum (-X)(y_t - \beta_0 - \beta_1 X_{1,t}) = -\sum xy + \beta_0 \sum x + \beta_1 \sum x^2 = 0 \quad (3.8)$$

Denklemini normal hale getirilecek olursa;

$$\sum y = n\beta_0 + \beta_1 \sum x \quad (3.9)$$

$$\sum xy = \beta_0 \sum x + \beta_1 \sum x^2 \quad (3.10)$$

Bu denklemlerden;  $\beta_0$  ve  $\beta_1$  çekilerek bu parametre değerleri hesaplanır. Aritmetik ortalamadan farklar toplamı sıfırdır,

$$\sum (y - \bar{y}) = 0 \quad (3.11)$$

$$\sum (x - \bar{x}) = 0 \quad (3.12)$$

Olduğundan  $\beta_1$  ilgili denklemden elde edilir .

$$\beta_1 = \frac{\sum (y - \bar{y})(x - \bar{x})}{\sum (x - \bar{x})^2} \quad (3.13)$$

$$\bar{y} = \beta_0 + \beta_1 \bar{x} \quad (3.14)$$

$\beta_0$  değerini elde edebilmek için fonksiyonun ortak noktaları denklemde  $x$  ve  $y$ 'nin yerine konulması gerekir. Elde edilen  $\beta_0$  ve  $\beta_1$  değerleri ile regresyon denklemi yazılmış olur. Böylece elde edilen regresyon denkleminin katsayılarından, bağımsız değişkendeki bir birimlik değişiminin bağımlı değişkende ne kadar bir değişme oluşturduğu belirlenebilir.(Orhunbilge, 1996) Regresyon denkleminde yararlanılarak ileriye yönelik tahmin değerleri hesaplanabilir.

### 3.2.3 Rastgele orman metodu

Rastgele orman metodu birden çok karar ağacı topluluğu üzerinde odaklanarak çalışır. Bu metod Leo Breiman ve Adele Cutler tarafından desteklenmiş olup karar ağacı modellerinde rastgele özellik seçiminin çeşitliliği artırılarak paketlenmesi prensibine dayandırılmıştır (Cutler ve ark., 2011).

Rastgele orman metodu; her bir ağacın rastgele değişkenlerinin toplanmasına dayanan karar ağacı topluluğudur.  $P$  boyutlu rastgele vektör için  $X = (X_1, \dots, X_p)^T$  gerçek değer ya da öngörü değerini  $Y$  gerçek değeri ise cevabı temsil ederken  $P_{XY}(X, Y)$  bizim varsaydığımız bağlantı noktasını ifade eder. Bizim amacımız,  $Y$  değerini öngörmek için  $f(X)$  tahmin fonksiyonunu bulmaktır. Tahmin fonksiyonu  $L(Y, f(X))$  bir hata fonksiyonu tarafından belirlenir ve hata değerlerinin beklenen değerini azaltmak için tanımlanır.

$E_{XY}(L(Y, f(X)))$   $X$  ve  $Y$  değerlerinin dağılımına ilişkin beklenen değer indisidir.

$L(Y, f(X))$   $f(x)$ 'in  $Y$ 'e ne kadar yakın olduğunu ölçüp  $Y$ 'den  $f(x)$ 'e ne kadar uzak olduğuna ceza puanı verir. Klasik olarak  $L$  regresyon için hata fonksiyonun kareler toplamıdır.

$$L(Y, f(x)) = (Y - f(x))^2 \quad (3.15)$$

Denklemi kullanarak hesaplanır, sınıflandırma için 0 ve 1 değerini alır. Temel öğrenme olarak adlandırılan  $h_1(x), \dots, h_j(x)$  toplamının terimi  $f(x)$  ve bu temel öğrenmelerin toplamı tahmin fonksiyonunu verir bu regresyonda ortalamadır (Sandy, 1990).

$$f(x) = \frac{1}{j} \sum_{j=1}^j h_j(x) \quad (3.16)$$

Rastgele orman metodunu kullanırken problemde dikkat etmemiz gereken en önemli unsur sınıflandırma tahmini mi yapılacak yoksa sayısal tahmin mi yapılacaktır. Kaynaklarda ve literatürde yapılan araştırmalar sonucunda, sınıflandırma probleminde her ağaçta kaç değişken kullanılacağı sayısını (mtry) belirlerken veri setinde

ilgilenilen deęişken sayısının karekökü kadar seçilir, problem sayısal tahmin problemi ise verideki ilgilenilen deęişken sayısının 3'e bölümü kadar seçilir.

### 3.2.4 Zaman serileri

Geçmişe ilişkin verilerin dönem içindeki farklılıklarını gösteren dizinin deęerleri, bir zaman serisini oluşturur. Zaman serisi analizi, bu deęerlerin farklılaşma nedenini inceleyip işlemi ve davranışı temsil eden bir model hazırlar. Bu model yardımıyla geleceęe dönük talep tahmini yapılabilir. Söz konusu matematiksel modelin kurulabilmesi için bir zaman serisi davranışını oluşturan şu 4 etmenin bilinmesi gerekir.

- Eğilim (Trend); veriler sürekli bir şekilde artma azalma eğilimi gösterir. Sürekli olarak temsil edilen bir doğru bulunması zaman serisi modelini kurmak için gerekli ilk adımı oluşturur.
- Mevsimsel Deęişim; verilerin mevsimsel dönemlerde artış veya azalış göstermesi olup kullanılan mevsim kavramının zaman sürecinde benzer davranışları göstermesidir. Zaman sürecinde ilgilenilen dizi deęişkeninin deęişik aylarda daha çok talep görürken bazı aylarda daha az talep görebilmesi mevsim deęişim olduğunu gösterir.
- Periyodun Deęişimi; verilerin mevsimsel farklılaşması dışında daha uzun süreçteki deęişimleridir. Uzun süreçlere yayılan talep dalgalanmalarını gösteren dönem deęişimi olarak da düşünülebilir.
- Rastgele Olaylar; düzensiz ve anlaşılması kolay olmayan olaylardır.(Toomey, 1996)

Zaman serileri gözlemlerin ortalamasındaki sapmalara göre 2 kısımda incelenir bunlar; durağan olmayan zaman serileri ve durağan zaman serileridir. Serinin durağan zaman serisi olduğuna karar verebilmemiz için ilgilenilen zaman serisinin ortalaması başka bir deyişle trendinin ve varyansının simetrik deęişim göstermemesi gerekmektedir. Aynı zamanda periyodik dalgalanmaların olmaması gerekmektedir. Yapılacak istatistiksel çalışmalarda zaman serisinin durağan olması beklenir, durağan deęilse yapılacak tekniklerle durağanlaştırılması gerekmektedir. Zaman serisi için yapılacak çalışmada trendinin stokastik mi yoksa deterministik mi olduğu önemlidir. Zaman serisinin trendi deterministik ise bunu teknikler kullanarak durağanlaştırmak gerekir fakat trend stokastik ise istatistiksel sonuç alınması mümkün olmamaktadır (Akdi, 2003).

T bir indis kümesi olarak tanımlı zaman serisi;  $\{X_t: t \in T\}$ ,  $T = \{1,2,3 \dots\} = N$  Rastgele deęişkenin tanımlanması için olasılık uzayını tanımlamak gerekir.  $\Omega$  boş

olmayan bir küme iken bunun alt kümelerini oluşturduğu sınıf  $F$  iken  $F$ 'nin her bir elemanına ise olay denir.  $(\Omega, F)$  ölçülebilir uzay olması için şu özellikleri sağlamalıdır.

- $\Omega \in F$
- $\forall A \in F$  için  $A^c \in F$  ( $A^c$ ,  $A$  nın tümleyenini göstermektedir.)
- $A_n \in F, n = 1, 2, 3, \dots$  ise  $\bigcup_{n=1}^{\infty} A_n \in F$

$(\Omega, F)$  bir olasılık uzayı olmak üzere  $F$  tanımlanan fonksiyon;  $P: F \longrightarrow [0, 1], A \longrightarrow P(A)$ ,  $P$  küme fonksiyonuna bir olasılık ölçüsü olarak  $P(A)$  ise  $A$  olayının olasılığıdır.  $(\Omega, F, P)$  üçlüsü bir olasılık uzayı denir.

- $\forall A \in F$  için  $P(A) \geq 0$
- $P(\Omega) = 1$
- $A_n$  ile  $F$  ayrık elemanların bir dizisi ise,

$$P\left(\bigcup_{n=1}^{\infty} A_n\right) = \sum_{n=1}^{\infty} P(A_n) \quad (3.17)$$

$(\Omega, F, P)$  bir olasılık uzayı olarak alırsak  $\Omega$  örnek uzayından reel sayılarına giden  $X: \Omega \longrightarrow \mathbb{R}$   $w \longrightarrow X(w)$  Fonksiyonu eğer  $\forall A \in \mathbb{R}$  için  $\{w \in \Omega : X(w) \leq a\} \in F$  koşulunu sağlıyorsa,  $X$ 'e bir ratsgele değişken denir.  $(\Omega, F, P)$  bir olasılık uzayı,  $T$  indis kümesi olmak üzere  $\Omega \times T$  uzayında reel sayıya giden fonksiyon olmak üzere;

- $X(., .) : \Omega \times T \longrightarrow \mathbb{R}$
- $(w, t) \longrightarrow X(w, t)$

Şeklinde tanımlanan fonksiyondur.  $X_t(w)$  yerine bazen de genellikle  $X_t$  gösterimi kullanılır ve bu fonksiyonuna zaman serisinin yörüngesi adı verilir. Bu yörünge ise zaman serileri grafikleridir.

Dağılım fonksiyonu;  $(\Omega, F, P)$  herhangi bir olasılık uzayında  $x$  ve  $\Omega$  üzerinde tanımlı rastgele değişken olsun.  $X$  rastgele değişkenin dağılım fonksiyonu,

$$F_x : \mathbb{R} \longrightarrow [0, 1] : x \longrightarrow F_x(x) = P(w : X(w) \leq x) = P(X \leq x) \quad (3.18)$$

$n$  boyutlu rastgele vektörün dağılım fonksiyonu ;

$$F(X_1, X_2, \dots, X_n) = P(X_1 \leq x_1, X_2 \leq x_2, \dots, X_n \leq x_n) \quad (3.19)$$

olarak tanımlayabiliriz.

Durağan zaman serisi aşağıda belirtilen koşulu sağlıyorsa durağandır denilir.

- $\{X_t : t \in T\}, E(X_t) = \mu$  (beklenen değer zamanla değişmez),
- $Cov(X_t, X_s)$  kovaryans  $|t - s|$  fonksiyonudur.

$Cov(X_t, X_{t+h})$  kovaryansı  $h$  nin bir fonksiyonu olması gerekir. Bu fonksiyon  $\{X_t : t \in T\}$  zaman serisinin otokovaryans fonksiyonu olarak belirtilir ve  $E(h)$  ile

gösterilir.  $\mathcal{E}(h) = Cov(X_t, X_{t+h})$  olarak gösterilir. Bu fonksiyon sezgisel olarak model türü ve derecesini belirleme ve serinin durağan olup olmaması hakkında bilgi verir (Akdi, 2003).

Zaman serileri uygulamalarında otokovaryans şu şekilde tanımlanmaktadır(Akdi, 2003);

- $\mathcal{E}(h)$  fonksiyonu simetriktir
- $|\mathcal{E}(h)| \leq \mathcal{E}(0)$  ,  $\forall(h)$
- $\mathcal{E}(h)$  fonksiyonu negatif olmayan

Bir AR (Autoregressive) modelinde, bağımlı değişken geçmişte aldığı sayısal değerlerin bir fonksiyonudur. Birçok zaman serisi verisi de bu süreci içermektedir. AR zaman serisinin geçmişten bugüne olan değerlerinden ve beyaz gürültüden etkilenir. Birinci dereceden otoregresif zaman serisi  $e_t \sim WN(0, \sigma^2)$  beyaz gürültü serisi ve  $\mu$  ise serinin beklenen değeri olarak kabul edilir.

$$(X_t - \mu) = \sum_{i=1}^p k_i (X_{t-i} - \mu) + e_t \quad (3.20)$$

Otoregresif zaman serisinin derecesi  $p$  ile gösterilir.  $i = 1, 2, 3, \dots, p$  ve  $\sigma^2$  modelin parametrelerini gösterir;

$$X_t = \mu(1 - k) + k X_{t-1} + e_t \quad (3.21)$$

serinin otokovaryans fonksiyonu,

$$\mathcal{E}x(h) = \frac{\sigma^2}{1 - \sigma^2} kh \quad (3.22)$$

seri üstel olduğu anlaşılmaktadır o yüzden 1 yaklaştıkça azalmada eskiye nispeten yavaşlar (Akdi, 2003),

$k=1$  alırsak seri (AR(1));

$$X_t = X_{t-1} + e_t \quad (3.23)$$

bu durum aşağıdaki gibi bir denklemlerle ifade edilebilir, (Sandy, 1990)

$$x_t = a + a_1 * x_{(t-1)} + a_2 * x_{(t-2)} + a_3 * x_{(t-3)} + \dots + \varepsilon \quad (3.24)$$

ifadede,  $a$  sabit terimi temsil ederken  $a_1, \dots$  gibi katsayılar gecikmeli sayısal değerlerin şimdiki sayısal değerle olan ilişkisini temsil eder. Buna ek olarak  $\varepsilon$  hata terimi de rassal şokları tanımlamakta olup genel bir ifade ile AR(p) şeklinde gösterilir.

Eğer serinin gecikmeli hata terimi, şimdiki hata terimini de etkiliyorsa hareketli ortalama sürecinin tanımlanması gerekir. Bir hareketli ortalama sürecinde değişkenin tahmin değeri hata terimlerinin tahmin değeri ile ilgilidir. Bir hareketli ortalama süreci genel şekil olarak MA(q) şeklinde ifade edilir. Ortalaması sıfır olan zaman serisinde  $\{ e_t : t \in T \}$  otokovaryans fonksiyonu;

$$\mathcal{E}(h) = \begin{cases} \sigma^2, & h = 0 \\ 0, & \text{diğer} \end{cases} \quad (3.25)$$

bu durumda  $\{e_t : t \in T\}$  White Noise serisi olarak adlandırılır,  $e_t \sim WN(0, \sigma^2)$  gösterimi ile gösterilir.(Akdi, 2003)  $X_t$  zaman serisi şu şekilde tanımlanır;

$$x_t = e_t - a_1 e_{t-1} - \dots, t = 1, 2, \dots, n \quad (3.26)$$

şeklinde ifade edilebilir (Sandy, 1990).

$$\text{Var}(X_t) = \sigma^2(1 + a_1^2) \quad (3.27)$$

$$\mathcal{E}x(h) = \text{Cov}(e_t + a_1 e_{t-1}, e_{t+h} + a_1 e_{t+h-1}) = \sigma^2(1 + a_1^2) \quad (3.28)$$

Otokovaryans fonksiyonu;

$$\mathcal{E}x(h) = \begin{cases} \sigma^2(1 + a_1^2), & h = 0 \\ a_1 \sigma^2, & h = -1, +1 \\ 0, & |h| \geq 2 \end{cases} \quad (3.29)$$

Otokorelasyon fonksiyonu;

$\alpha(h) = \mathcal{E}(h) / \mathcal{E}(0)$  olduğu durumda

$$\alpha(h) = \begin{cases} 1, & h = 0 \\ a_1 / (1 + a_1^2), & h = -1, +1 \\ 0, & |h| \geq 2 \end{cases} \quad (3.30)$$

serilerin otokorelasyon ve otokovaryans fonksiyonları  $|h| \geq 2$  için 0 olacaktır. Bu durumda  $e_t \sim WN(0, \sigma^2)$  zaman serisine birinci dereceden hareketli ortalama serisi denir ve  $X_t \sim MA(1)$  olarak gösterilir. İkinci dereceden hareketli ortalama  $e_t \sim WN(0, \sigma^2)$  olduğu kabul edilerek,

$$x_t = e_t + a_1 e_{t-1} + a_2 e_{t-2} \quad (3.31)$$

$X_t \sim MA(2)$

Otokovaryans fonksiyonu

$$\mathcal{E}x(h) = \begin{cases} \sigma^2(1 + a_1^2 + a_2^2), & h = 0 \\ \sigma^2(a_1 + a_1 a_2), & h = -1, +1 \\ \sigma^2 a_2, & h = -2, +2 \\ 0, & |h| \geq 3 \end{cases} \quad (3.32)$$

Otokorelasyon fonksiyonu

$$\alpha(h) = \begin{cases} 1, & h = 0 \\ \frac{a_1 + a_1 a_2}{1 + a_1^2 + a_2^2}, & h = -1, +1 \\ \frac{a_2}{1 + a_1^2 + a_2^2}, & h = -2, +2 \\ 0, & |h| \geq 3 \end{cases} \quad (3.33)$$

sonuç olarak bu fonksiyonlar 3.dereceden 4.dereceden olmak üzere devam eder;

$$x_t - \mu = e_t + \sum_{j=1}^q a_j e_{t-j} \quad (3.34)$$

genel ifade ile gösterimi olmak üzere  $X_t \sim MA(q)$  olarak gösterilir.



Otokovaryans fonksiyonu,

$$Ex(h) = \begin{cases} \sigma^2 \sum_{j=0}^{q-h} a_j a_{j+k}, & 0 \leq h \leq q \\ 0, & dd \end{cases} \quad (3.35)$$

Otokorelasyon fonksiyonu,

$$\alpha(h) = \begin{cases} ((\sum_{j=0}^{q-h} a_j a_{j+k}) / (\sum_{j=0}^{q-h} a_j^2)), & h = 0 \\ 0, & dd \end{cases} \quad (3.36)$$

Otoregresif zaman serilerinde otokorelasyon fonksiyonu model derecesi belirlemede kullanılamaz sadece otokorelasyonun azalma hızına bakarak durağanlığı hakkında sezgisel olarak bazı şeyler söylenebilir. AR zaman serisine bakılarak  $X_t$ 'ler, geçmiş değişkenlere göre bir linear regresyon modeline benzetilebilir.

Çoğu zaman serisi hem AR hem de MA sürecini içermektedir. MA zaman serileri durağan zaman seri biçimindedir. AR serilerinde durağanlık denklemin köklerine bağlıdır. Otokorelasyonları MA serilerinde belli bir zaman sonra kısmi korelasyonları azalmakta, otokorelasyonu ise 0 olmaktadır. AR serilerinde durum MA serilerine göre zıt çalışmaktadır. Kısmi korelasyon 0 olurken otokorelasyon azalmaktadır. Zaman serisinin model derecesi belirlenirken otokorelasyon ve kısmi korelasyon bakarak belirlenir fakat bazı durumlarda otokorelasyon ve kısmi korelasyon değerleri 0 olmayı başaramaz. Bu durum ne AR modeline ne MA modeline uyar bu zaman serileri ARMA zaman serisi olarak adlandırılır (Akdi, 2003).

I(integrated) ise seri tarafından içerilen trendi ifade etmektedir. ARIMA olarak ifade edilen kavramı açıklayacak olursak, ARIMA(p,d,q) bize, zaman serisinin p dereceden kendisinin gecikmesi ile kaynaklı durumu ifade ederken AR(p) sürecini içerdiğini anlatır. Diğer gösterimdeki q hata terimlerinin geçmiş değerleri ile ilişkisini ifade ederken rassal süreci yansıtmaması açısından hata terimlerinin düzleştirilme metotlarından olan MA(q) sürecini ifade etmektedir. Bu gösterimlere ek olarak eğer zaman serilerinde genelde olduğu gibi bir durağan olmama durumunun olması veya durağan bir zaman serisi ile karşılaşmasında d ile gösterilir ve zaman serisi hangi düzeyde durağan(integrated) ise açıkça belirtilir (Sandy, 1990). Bu durumda, söz konusu ortalaması denklem, kısmi korelasyon sıfırdan farklı olmak üzere;

$$(\phi_p \neq 0), \theta_q \neq 0,$$

$$(x_t - \mu) = \sum_{j=1}^p \phi_j (x_{t-j} - \mu) + e_t + \sum_{i=1}^q \theta_i e_{t-i} \quad (3.37)$$

ARIMA(p,d,q) sürecini ifade eder.(Akdi, 2003)

### 3.2.5 Çok mevsimsel zaman serileri

Zaman serileri veri tahmininde genellikle tek mevsimsel etkiye bakar fakat bazı durumlarda iki veya daha fazla mevsimin etkisi söz konusu olabilir. Bunun için TBATS modeli kullanılabilir; model Trigonometric , Box-Cox transform, ARMA errors, Trend, and Seasonal components kelimelerinin baş harflerinin birleşimi ile isimlendirilir.

Trigonometric olması modelin tam sayı olmayan değerler ile çalışmasını sağlamaktadır. Box-Cox transform modelinin normal olmayan bağımlı değişkenlerini normal bağımlı değişkene dönüştürmeyi sağlayan dönüştürücüdür. ARMA errors zaman serilerinde bahsettiğimiz derece parametrelerini ifade etmektedir. Trend zaman serisinde ki artışın ya da azalışın olduğu dönemleri belirlemede kullanılır.

TBATS modeli durağan olmayan dönemlerdeki artışları tanımlamak için kullanılan bir modeldir. Modelinin parametreleri; Trigonometric  $\omega$ , Box-Cox parametresini  $\varphi$ , ARMA parametrelerini  $p, q$  , mevsimsellikte tam sayı olmayan frekansları tanımlarken de  $m_t, k_t$  parametreleri kullanılır.

$$TBATS(\omega, \varphi, \{m_2, k_2\}, \dots, \{m_t, k_t\}) \quad [55] \quad (3.38)$$

#### 4. DENEYSSEL ÇALIŞMA


Türkiye'nin artan teknolojisi ve artan nüfusun taleplerini karşılamak için, enerji politikalarının iyi yönetilmesi gerekmektedir. Enerji kaynakları kullanımında doğalgaza olan talep her geçen gün artmaktadır. Bu nedenden dolayı doğalgazın yurtiçi tüketim tahmininin doğru yapılması kritik öneme sahiptir.

Tahmin çalışması için makine öğrenme tekniklerinden faydalanarak 5 farklı model için Jodi.Data.Org sitesinden elde ettiğimiz gerçek doğalgaz verisi ile tahmin çalışması yapılmıştır. Gerçek veriler ile tahmin verileri karşılaştırılıp tahmin performansına göre en iyi model seçilmesi amaçlanmıştır.

Regresyon metodunu kullanarak yaptığımız çalışmada Gross Inland Deliveries Observed bağımlı değişkeni ile Import ( $x_1$ ) ve Electricity.and.Heat.Generation ( $x_2$ ) bağımsız değişkenlerini kullanarak regresyon modeli oluşturulmuş olup regresyon denklemi belirtilmiştir.

$$y = 1,33 x_1 - 0,118x_2 - 1159,53 \quad (4.1)$$

Değişkenlere ilişkin serpilme diyagramı Şekil 4.1'de verilmiştir.



Şekil 4.1 Değişkenlere ilişkin serpilme diyagramı

Regresyon modelimizin Multiple R-squared değeri 0.9201 olarak hesaplanmıştır buradan anlaşılacağı üzere modele verdiğimiz bağımsız değişkenler tahmin etmek istediğimiz değeri yaklaşık yüzde %92 oranında açıklayabilmektedir.

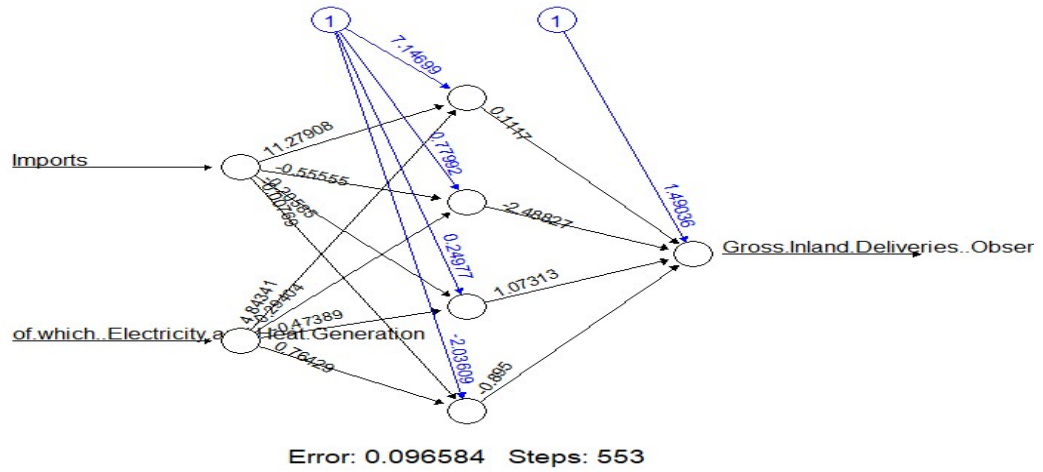
Tahmin hatalarını ölçmek için, tüm gözlenen değerler ile tüm tahmin değerlerin farkının karelerinin ortalaması olan ortalamalar kareler hatası (MSE) yöntemi kullanılacaktır.

$$MSE = \frac{\sum_{n=1}^{\infty} (\text{Tahminleri Hatası})^2}{n} \quad (4.2)$$

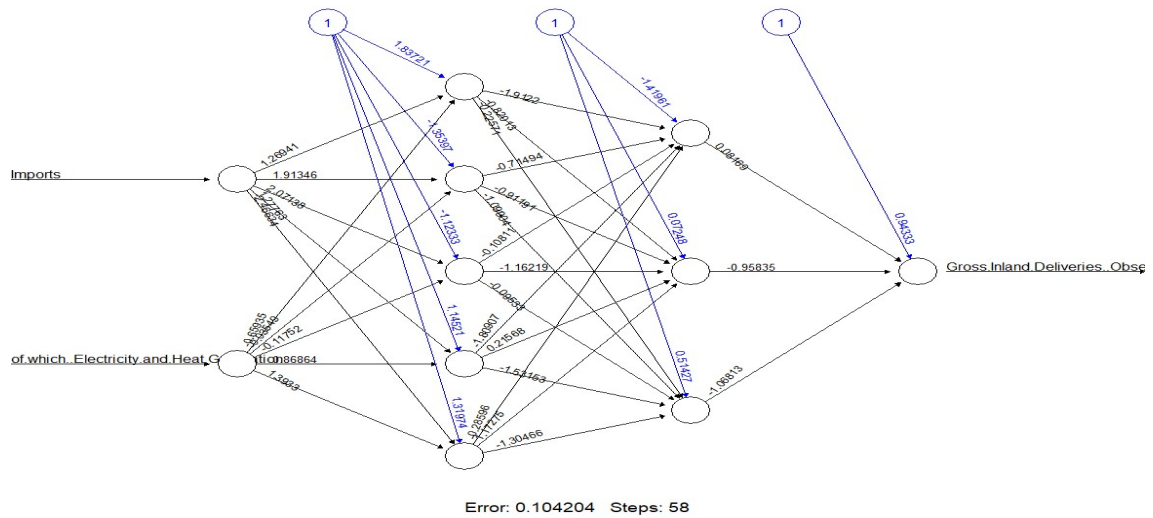
Regresyon modeli ile ileriye dönük 36 ayın tahmini yapılmıştır. Çıkan tahmin sonuçları ile gerçek değerler karşılaştırılmış olup tahmin değerleri EK-1'de detaylandırılmıştır. Modelin tahmin sonucunda ortalama kareler hatası 102.969 olarak hesaplanmıştır.

Yapay sinir ağı ile geliştirilen modelimizde Import ve Electricity.and.Heat. Generation değişkenlerini giriş verisi olarak kullanıp Gross Inland Deliveries Observed çıktı verisi olarak tahmin edilmiştir. Verilerimizin %80 kısmını modelin eğitim için kullanırken verilerimizin %20'lik kısmı modelin testi için kullanılmıştır. Bu doğrultuda 2010-2015 yılları arasındaki verilerimizi kullanarak modelimizi eğitip ileriye dönük 36 ayın verisi tahmin edilmiştir.

Modelin hangi katmanlarda en iyi sonuç vereceği katman sayıları ve düğüm sayıları değiştirilerek model geliştirilebilir. Geliştirilen modellerin hata sonucu en az olan en uygun model olarak karar verilir. Yapılan birden çok model denemelerinde hata oranı en düşük çıkan modeller içerisinde Şekil 4.2'de 4 düğümlü modelin hata oranı, Şekil 4.3'te ilk katmanında 5 düğümlü ikinci katmanında 3 düğümlü modelin hata oranından daha düşük olduğu görülmüştür. Bu nedenden dolayı yapay sinir ağları içinde en uygun modelimiz tek katmanlı 4 düğümlü model olmuştur.



Şekil 4.2 4 düğümlü tek katmanlı yapay sinir ağı modeli



**Şekil 4.3** İlk katmanında 5 düğüm ikinci katmanında 3 düğüm olan yapay sinir ağı modeli

Yapay Sinir ağı modeli ile ileriye dönük yaptığımız 36 ayın tahmin değerleri ile gerçek değerler karşılaştırılması yapılmış olup EK-2’de modelin tahmin değerleri detaylandırılmıştır. Modelin ortalama kareler hatası 93.381 hesaplanırken modelin Multiple R-squared değeri 0,93 olarak hesaplanmıştır. Modelin sonuç matrisi de aşağıda verilmiştir.

error	0,09658
reached.threshold	0.00978
steps	553
Intercept.to.1layhid1	0,90259
Imports.to.1layhid1	1,06825
of.which..Electricity.and.Heat.Generation.to.1layhid1	0,46014
Intercept.to.1layhid2	0,67747
Imports.to.1layhid2	-1,22090
of.which..Electricity.and.Heat.Generation.to.1layhid2	-0,35093
Intercept.to.1layhid3	-1,36197
Imports.to.1layhid3	-1,18892
of.which..Electricity.and.Heat.Generation.to.1layhid3	-0,34281
Intercept.to.1layhid4	0,36960
Imports.to.1layhid4	-2,08644
of.which..Electricity.and.Heat.Generation.to.1layhid4	0,806526
Intercept.to.Gross.Inland.Deliveries..Observed.	-0,066475
1layhid1.to.Gross.Inland.Deliveries..Observed.	0,949092
1layhid2.to.Gross.Inland.Deliveries..Observed.	-0,207895
1layhid3.to.Gross.Inland.Deliveries..Observed.	0,867289
1layhid4.to.Gross.Inland.Deliveries..Observed.	-0,513505

Rastgele orman metodu ile yapılan tahmin çalışmasında literatürde yapılan araştırmadan elde edilen bilgiye göre; problemimiz sayısal tahmin problemi olduğu için her ağaçta kaç değişken kullanılması gerektiği ile ilgili, ilgilenilen problem için önemli


olan deęişken sayısının 3'e bölümü ile elde edileceęi belirtilmektedir. Kaç tane ağaç seçileceęi konusunda ise tahminci verinin büyüklüğüne göre karar verileceęi belirtilmektedir. Verilerimizin %80'lik kısmı modelin eğitim için kullanılırken %20'lik kısmı modelin testi için kullanılmıştır. Bu doğrultuda 2010-2015 yılları arasındaki verilerimizi kullanarak modelimizi eğitip ileriye dönük 36 ayın verisi tahmin edilmiştir. Modelde bahsedilen n-tree deęeri kaç tane ağaç oluşturulacağını belirtirken m-try deęeri de her ağaçta kaç deęişken kullanılacağı belirtir. Rastgele orman modeli için bahsedilen modellerin sonuçları EK-3'de detaylandırılmış olup ortalama kareler hatası şu şekildedir;

- Rastgele orman modeli ile yaptığımız birinci modelde ( mtry=1, ntree=100 olduğunda) yapılan tahminin ortalama kareler hatası 377.099 olarak bulunmuştur.
- Rastgele orman modeli ile yaptığımız ikinci modelde ( mtry=1, ntree=1000 olduğunda) yapılan tahminin ortalama kareler hatası 341.566 olarak bulunmuştur.
- Rastgele orman modeli ile yaptığımız üçüncü modelde ( mtry=1, ntree=10000 olduğunda) yapılan tahminin ortalama kareler hatası 340.344 olarak bulunmuştur.

Yapılan dięer model çalışmalarında n-tree deęerinin yani ağaç sayısının artırılması, ortalama kareler hatasında önemli derecede iyileşme olmadığı gözlemlendiği için dięer modellere yer verilmemiştir. MSE deęeri en düşük olan rastgele orman modelimizin Multiple R-squared deęeri 0,89 olarak hesaplanmıştır. Modele ilişkin sonuç deęerleri aşağıdaki gibidir.

- Number of trees: 10000
- No. of variables tried at each split: 1
- Mean of squared residuals: 100787.3
- % Var explained: 86.43

Zaman serileri ile yapılan model çalışması tüm veri setine uygulanmıştır. Verimiz aylık bazda olduğu için frekans deęeri 12 ay seçilmiş olup veri setinin başlangıç zamanı 2010 yılı olarak alınmıştır. Şekil 4.4'de ARIMA modeli ile yapılan ileriye dönük 36 ayın tahmini %80 ve %90 güven aralıklarında gösterilmiştir.



**Şekil 4.4** Zaman serileri ile yapılan modelin güven aralıkları ile tahmini

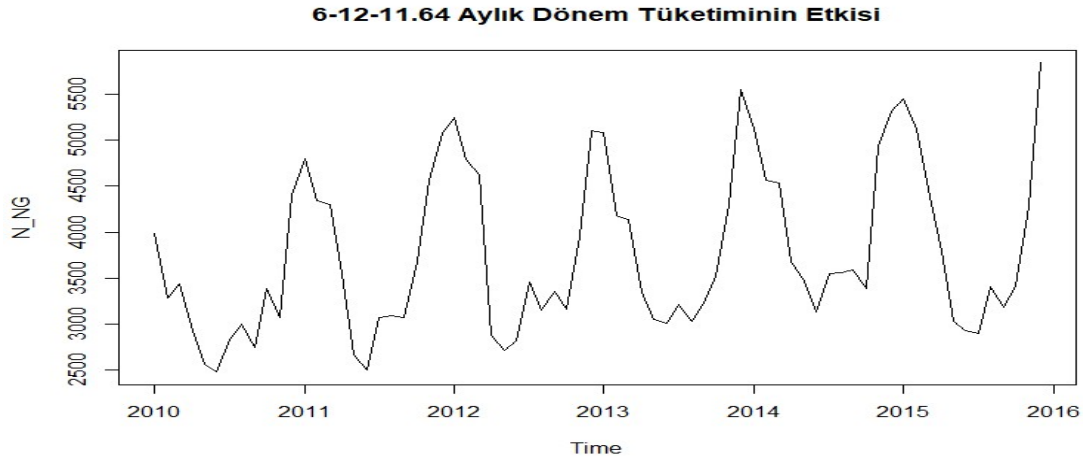
ARIMA (2,0,1) modelinin denklem katsayıları ;

AR1: 1,59, AR2: -0,82, MA1: -0,65, Ortalama: 3799,4 olarak hesaplanmıştır.


Kurulan ARIMA modeli ile yaptığımız tahminler ile gerçek değerlerin karşılaştırılmasının detayları EK-4’de verilmiştir. Modelin ortalama kareler hatası 1050187 olarak hesaplanırken Multiple R-squared değeri 0,34 olarak hesaplanmıştır.

Çoklu mevsimsel etki modelimizde birden fazla mevsimsel etkinin modele etkisi olduğu düşüncesiyle oluşturulmuştur. Türkiye sosyal ve kültürel anlamda hicri takvime göre hareket eden bir ülkedir. Bu bağlamda dini bayram zamanı doğalgaz tüketimini azaltıcı etkisi olması beklenir. Sosyal ve kültürel anlamdaki bu etkinin doğalgaz tüketimine etkisi de bu modelle incelenmek istenmiştir.

Çok mevsimsel etki modeli için TBATS yöntemi kullanılacaktır. Mevsimsel etki parametrelerimizi; doğalgaz tüketiminin yıllık bazda dağılım grafiği (Şekil 4.5) incelenip sezgisel olarak karar vermek gerekirse mevsimsel etki periyotlarından biri 6 ay olarak belirlenebilir. Hicri takvimin etkisi dikkate alındığında ise hicri gün sayısı olan 354.37 gün yaklaşık olarak 11.64 ay olarak alınabilir. Gregorian takvimin etkisini de dikkat aldığımızda 365.25 gün olan gün sayısı 12 ay olarak alınıp TBATS modelini bu parametrelere göre geliştirdiğimizde ileriye dönük 36 ayın tahmini %80 ve %90 güven aralıklarında Şekil 4.6’da olduğu gibidir.



**Şekil 4. 5** Yıllık bazda doğalgaz tüketimi



**Şekil 4.6.** Çok mevsimsel etki modelinin güven aralıkları ile tahmini

Kurulan çok mevsimsel etki modeli ile yaptığımız tahmin çalışmasında gerçek değerler ve tahmin değerleri EK-5’de detaylı olarak verilmiş olup modelin ortalama kareler hatası 294.752 olarak hesaplanırken Multiple R-squared değeri 0,82 olarak hesaplanmıştır.

TBATS (0, {0;0}, 0,95, {<6;1>, <11,64;4>, <12;1>}) modelimizin denklemin katsayıları aşağıdaki şekilde hesaplanmıştır.

- $\lambda$ : 0
- $\alpha$ : 0,0605
- $\beta$ : -0,00403
- Damping Parametre : 0,9548
- Gamma-1 Değerleri : 0,0006 ; -0,00018 ; 0,00065
- Gamma-1 Değerleri : -0,00076 ; 0,00035; -0,0009



## 5. SONUÇLAR VE ÖNERİLER

### 5.1 Sonuçlar

Doğalgaz, çevre dostu ve diğer enerji kaynaklarına göre nispeten ucuz olması gibi önemli faktörlerden dolayı dünya piyasasındaki talebi giderek artan birincil enerji kaynaklarındandır. Türkiye'nin enerji ihtiyacı, hızla büyüyen ekonomisi ve popülasyonu ile birlikte sürekli artmaktadır. Artan enerji ihtiyacına rağmen Türkiye, sahip olduğu oldukça sınırlı doğalgaz rezervi ile kendi ihtiyacını karşılayamamakta ve yüksek dış bağımlılığa mahkûm kalmaktadır.

Avrupa'nın enerji ihtiyacının göz ardı edilemeyecek bir kısmı doğalgaz kaynakları tarafından karşılanması gerektiği ve dünyadaki doğalgaz rezervinin büyük bir kısmı Orta Doğu ve Hazar Bölgesi'nde bulunması gibi kritik sebeplerden dolayı Türkiye'nin jeopolitik konumunun önemi giderek artmaktadır. Türkiye enerji koridorlarında önemli bir aktör olmakla birlikte birçok doğalgaz projesine ortak olmaktadır. Bu duruma rağmen, Türkiye'nin doğalgaz tüketimi için oldukça fazla paralar ödenmiştir. Doğalgazda yüksek dış bağımlılığa sahip bir ülke olan Türkiye'nin ekonomisindeki büyümeyi sürdürmek istemesi, gelecek yıllardaki doğalgaz tüketiminin tahmin edilmesinin önemini arz etmektedir. Bu sebeple dışarıdan satın alınan doğalgazın etkin ve verimli kullanılabilmesi için önümüzdeki yıllarda tüketilecek doğalgazın iyi tahmin edilmesi ülke ekonomisi açısından önemlidir.


Makine öğrenmesi, tahminlemedeki başarısını kanıtlamış ve kullanımı gittikçe artan teknikler bütünüdür. Bu çalışmada, Türkiye'nin doğal gaz tüketimini hesaplamak amacıyla Yapay Sinir Ağları, Regresyon, Rastgele Orman Metodu, Zaman Serileri ve Çoklu Mevsimler algoritmalarını içeren, denetimli makine öğrenme algoritmaları kullanılmıştır. Bu tahminleme işlemi için 2010 ve 2018 yılları arasındaki gerçek doğalgaz tüketim verileri kullanılmıştır. 2010 - 2015 yılları arasındaki veriler öğretim verisi olarak kullanılırken, 2016 - 2018 yılları arasındaki veriler, algoritmaların geçerliliğini test etmek amacıyla kullanılmıştır. Algoritmaların geçerliliğinin belirlenmesinde, literatürde yaygın olarak kullanılan toplam "Mean Square Error (MSE)" değeri dikkate alınmıştır. Deneysel sonuçlar, Yapay Sinir Ağları metodunun en iyi performansı sergilediğini göstermektedir (MSE = 93381). Regresyon (MSE = 102969) metodu en başarılı ikinci metod olurken, Çok Mevsimsel Zaman Serileri (TBATS) (MSE = 294752) metodu üçüncü sırada yer almıştır. Rastgele Orman (MSE = 340344) ve Zaman Serileri (ARIMA) (MSE = 10.508.187) metodları en kötü performansa sahip makine öğrenmesi metodları olarak

belirlenmişlerdir. Modellerimizin MSE değerleri ve  $R^2$  değerleri Çizelge 5.1’de verilmiştir.

Model	Multiple R-squared	MSE Değeri
YSA	0,93	93381
Regresyon	0,92	102969
TBATS	0,82	294752
Rastgele Orman	0,89	340344
ARIMA	0,34	1050187

Çizelge 5.1. Modellerin  $R^2$  ve MSE Değerleri

Gerçekleşen değerler ile çalışmamızda kullanılan 5 modelin tahmin değerlerinin karşılaştırılması için Şekil 5.1’de grafik verilmiştir. Grafikten anlaşılacağı üzere modellerin tahmin değerleri gerçekleşen değere yakınlığı tahmin performans değeri (MSE) ile örtüştüğü görülmektedir.



Şekil 5.1. Gerçekleşen veriler ile modellerin tahmin ettiği verilerin karşılaştırılması

Çok Mevsimsel Zaman Serilerinin Zaman Serilerine göre daha başarılı olmasının nedeni seriyi etkileyen birden fazla mevsimsel dönemin modelde gösterilebilmiş olmasıdır. Yapay sinir ağının ise diğer modellerden üstün olmasının nedeni hata miktarının katmanlardaki nöronlara geri dönerek katmanların ağırlık değerlerini devamlı

olarak güncellenmiş böylelikle modelin iyileştirmesini sağlamıştır. Modellerin tahmin değerlerin hesaplanması için kullanılan R yazılım dili modellerin çıktılarını bir saniyenin altında bir sürede verdiği için modellerin cevap döndürme sürelerinden söz edilmemiştir.

## 5.2 Öneriler

Ülkemizin kalkınma planlarının gerçekleştirilebilmesi için özellikle üretim alanında kapasitesinin artırılması gerekmektedir. Üretim kapasitesinin artması enerji talebini de artmasına neden olacaktır ve enerji talebi doğru şekilde karşılanmazsa üretim maliyetleri de ne yazık ki buna paralel olarak artacaktır. Üretimde mamullerin birim maliyetlerinin azaltılması dünya pazarında önemli rekabet gücünü oluşturmaktadır. Rekabet gücünü artırmak da doğru bir enerji politikası geliştirmekten geçmektedir. Bir başka açıdan önemli konu ise Türkiye'nin doğal ve yeraltı kaynaklarının sınırlı olması enerjide dışa bağımlılığın yüksek olmasına neden olmaktadır. Bu ve benzeri sebeplerden dolayı doğalgazın tüketiminin tahmin edilmesi önem arz etmektedir. Dışarıdan satın alınan doğalgazın etkin ve verimli kullanılabilmesi için önümüzdeki yıllarda tüketilecek doğalgazın iyi tahmin edilmesi ülke ekonomisi açısından önemlidir. Bu yüzden Enerji politikalarının iyi yönetilmesi için gelişen ülkelerin ileriye dönük enerji tüketimlerinin ne olacağının iyi belirlenmesi gerekmektedir. Bu doğrultuda enerjinin doğru planlanması için doğru tahmin modellerinin kullanılması iyi bir yaklaşım olarak karşımıza çıkmaktadır.

Literatürde birçok tahmin modeli mevcut olmasına rağmen her tahmin modeli çalışma için çözüm olmayabilir. Doğru tahmin modelinin seçiminden önce çalışması yapılacak verinin doğru analiz edilip bu doğrultuda tahmin modellerinin seçilmesi gerekmektedir. Tahmin modellerinin birden fazla seçilerek ilgili konu için uygulama yapılması daha faydalı olmaktadır zira tek bir modele bağlı tahmin yapıldığında seçilen modelin ne kadar başarılı olduğu konusunda bilgi vermemektedir. Yapılan çalışmada tahmin modellerinin performansının birbirinden farklı olması tahminde kullanılacak olan modele de güveni artırmıştır.

## KAYNAKLAR

- Akdi, Y., 2003, Zaman Serileri Analizi (Birim Kökler ve Kointegrasyon), *Ankara, Bıçaklar Kitabevi*, p. 31-35.
- Akpınar, E. ve Başbüyük, A., 2011, Jeoekonomik Önemi Giderek Artan Bir Enerji Kaynağı: Doğalgaz, *Turkish Studies-International Periodical For the Languages, Literature and History of Turkish or Turkic*, 6, 17.
- Aksoy, S. A., Eryiğit, E., Hashimova, N., İşbilir, N., Avşar, Z. M., Köksal, G. ve Terciyanlı, E., 2013, Rüzgar Gücü Üretimi İçin Tahmin Ve Teklif Sistemi Tasarımı, *Endüstri Mühendisliği Dergisi*, 24 (3-4), 4-15.
- Al-Fattah, S. M., 2005, Time Series Modeling for U.S. Natural Gas Forecasting. International Petroleum Technology Conference. Doha, Qatar.
- Anonim, 1994, 1993 Enerji Raporu, *Ankara*, 84.
- Anonim, 2019a, Jeotermal [online], Ankara, <https://www.enerji.gov.tr/tr-TR/Sayfalar/Jeotermal> [Ziyaret Tarihi: 30 Nisan 2019].
- Anonim, 2019b, Doğal Gaz Boru Hatları ve Projeleri [online], Ankara, <https://www.enerji.gov.tr/tr-TR/Sayfalar/Dogal-Gaz-Boru-Hatlari-ve-Projeleri>: [Ziyaret Tarihi: 20 Nisan 2019].
- Anonim, 2019c, Elektrik [online], Ankara, <https://www.enerji.gov.tr/tr-TR/Sayfalar/Elektrik> [Ziyaret Tarihi: 3 Mayıs 2019].
- Anonim, 2019d, Hidrolik [online], Ankara, <https://www.enerji.gov.tr/tr-TR/Sayfalar/Hidrolik>: [Ziyaret Tarihi: 30 Mayıs 2019].
- Anonim, 2019e, Rüzgar [online], Ankara, <https://www.enerji.gov.tr/tr-TR/Sayfalar/Ruzgar> [Ziyaret Tarihi: 30 Nisan 2019].
- Anonim, 2019f, Doğalgaz [online], Ankara, <https://www.enerji.gov.tr/tr-TR/Sayfalar/Dogal-Gaz> [Ziyaret Tarihi: 15 Mayıs 2019 ].
- Anonim, 2019g, Güneş [online], Ankara, [Ziyaret Tarihi 30 Mayıs 2019].
- Anonim, 2019h, Biyokütle [online], Ankara, <https://www.enerji.gov.tr/tr-TR/Sayfalar/Biyokutle>: [Ziyaret Tarihi: 30 Mayıs 2019].
- Anonim, 2019i, Kömür [online], Ankara, <https://www.enerji.gov.tr/tr-TR/Sayfalar/Komur> [Ziyaret Tarihi: 30 Mayıs 2019].
- Anonim, 2019j, Doğal Gaz Sektör Raporu [online], Ankara, [www.gazbir.org.tr/uploads/page/Haziran-2018-Sektor-Raporu.pdf](http://www.gazbir.org.tr/uploads/page/Haziran-2018-Sektor-Raporu.pdf): [Ziyaret Tarihi: 29 Mayıs 2019 ].
- Anonim, 2019k, Petrol [online], Ankara, <https://www.enerji.gov.tr/tr-TR/Sayfalar/Petrol>: [Ziyaret Tarihi: 15 Mayıs 2019 ].
- Bağırkan, Ş., 1993, İstatiksel Analiz, *İstanbul, Bilim Teknik Yayınevi*, p. 272.
- Bayrac, H. N., 2018, Uluslararası Doğalgaz Piyasasının Ekonomik Yapısı ve Uygulanan Politikalar, *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 13 (3), 23.
- Bianco, V., Manca, O. ve Nardini, S., 2009, Electricity Consumption Forecasting In Italy Using Linear Regression Models, *Energy*, 34 (2009), 8.
- Biegel, J. E., 1963, Production Control: A Quantitative Approach, *New Jersey, Prentice-Hall*, p.
- Busse, S., Helmholtz, P. ve Weinmann, M., 2012, Forecasting Day Ahead Spot Price Movements Of Natural Gas- An Analysis Of Potential Influence Factors On Basis Of A NARX Neural Network, *2012*, 12.
- Cutler, A., Cutler, D. R. ve Steven , J. R., 2011, Random Forest, Springer, p.
- Çoban, O. ve Özcan, C. C., 2011, Sektörel Açından Enerjinin Artan Önemi : Konya İli İçin Bir Doğalgaz Talep Tahmini Denemesi, *SÜ İİBF Sosyal ve Ekonomik Araştırmalar Dergisi*, 19.

- Demirel, Ö. F., Zaim, S., Çalışkan, A. ve Özuyar, P., 2011, Forecasting Natural Gas Consumption In İstanbul Using Neural Networks And Multivariate Time Series Methods, *Turk J Elec Eng & Comp Sci*, 20 (5), 28.
- Doğanay, H., 1998, Enerji Kaynakları, *Erzurum*, Şafak Yayınevi, p.
- Dündar, C., Oğuz, K., Dokuyucu, K. ve Bacanlı, H., 2011, Kısa Süreli Rüzgar Enerjisi Tahmini. VI. Yeni Ve Yenilebilir Enerji Kaynakları Sempozyumu. Kayseri, Turkey.
- Engin, N., 2010, *Marmara Coğrafya Dergisi*, 22, 233-244.
- Eren, T., 2017, Doğal Gaz Tüketim Planlanmasında Gri Tahmin Yöntemi Ve Türkiye Uygulaması, *T.C. İstanbul Ticaret Üniversitesi*, İstanbul, 94.
- Es, H. A. ve Hamzaçebî, C., 2014, Yapay Sinir Ağları İle Türkiye Net Enerji Talep Tahmini, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 29 (3), 9.
- Gürel, M., 1982, Enerji-Petrol ve Türkiye. 100. Yılda Petrol Faaliyeti, *Petrol İşleri Genel Müdürlüğü Dergisi*, 25.
- Hamzaçebî, C. ve Kutay, F., 2004, Yapay Sinir Ağları İle Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini, *J. Fac. Eng. Arch. Gazi Univ.*, 19 (3), 6.
- Karaca, C. ve Karacan, H., 2016, Çoklu Regresyon Metoduyla Elektrik Tüketim Talebini Etkileyen Faktörlerin İncelenmesi, *SUJEST*, 4 (3), 12.
- Kobu, B., 2010, Üretim Yönetimi, *İstanbul*, Beta, p.
- Lantz, B., 2015, Machine Learning with R, *Birmingham*, Packt Publishing, p.
- Makas, Y. ve Karaatlı, M., 2016, Yapay Sinir Ağlarıyla Hidroelektrik Enerji Üretiminin Çok Dönemli Tahmini, *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 21 (3), 15.
- Makinist, S., 2019, Derin Öğrenme (Yapay Sinir Ağları-3) [online], Ankara, <http://buyukveri.firat.edu.tr/2018/04/16/derin-ogrenme-yapay-sinir-aglari-3/>: [Ziyaret Tarihi: 29 Nisan 2019].
- Mohamed, Z. ve Patrick, B., 2019, Forecasting Electricity Consumption: A Comparison of Models for New Zealand, <http://www.itee.uq.edu.au/~aupec/aupec04/>.
- Orhunbilge, N., 1996, Uygulamalı Regresyon ve Korelasyon Analizi, *İstanbul*, Avcıol Basım Yayını, p. 17.
- Özaydın, Y., 2018, Türkiye'nin Enerji Güvenliği Görünümü Ve TANAP Projesi'nin Türkiye'nin Doğalgaz Arzı Açısından Önemi, *T.C. Polis Akademisi Güvenlik Bilimleri Enstitüsü*, Ankara, 97.
- Özmutur, S., 1990, Geleceği Tahmin Yöntemleri, *İstanbul*, İSO Araştırma Dairesi Yayını, İstanbul, p. 173.
- Öztemel, E., 2003, Yapay Sinir Ağları, *İstanbul*, Papatya Yayıncılık, p. 82.
- Sandy, R., 1990, Statistics for Business and Economics, *USA*, Mc-Graw Hill Higher Education, p.
- Simon, H. A., 1983, Machine Learning, *Carnegie-Mellon University, Pittsburgh*, Morgan Kaufmann p. 25-37.
- Şenol, Ü. ve Musayev, Z., 2017, Rüzgar Enerjisinden Elektrik Üretimine Yapay Sinir Ağları İle Tahmini, *Bilge International Journal of Science and Technology Research*, 1 (1), 8.
- Tanyaş, M. ve Baskak, M., 2015, Üretim Planlama Ve Kontrol, *İstanbul*, İrfan Yayıncılık, p.
- Toomey, J. W., 1996, MRP 2: Planning for Manufacturing Excellence, *Boston*, Kluwer Academic, p. 41.

- Topçu, G. Y., 2013, Türkiye Doğalgaz Tüketim Tahmini, *T.C. Ankara Üniversitesi* Ankara, 105.
- Vıtullo Steven R., Brown Ronald H., Corliss George F. ve Brian.M., M., 2009, Mathematical Models For Natural Gas Forecasting, *Canadian Applied Mathematics Quarterly*, 17 (4), 20.
- Yarman, T., 1985, Enerji Ve Türkiye, *Eskişehir*, T.C Anadolu Üniversitesi Mühendislik Mimarlık Fakültesi Yayınları, p. 22.
- Yavuzdemir, M., 2014, Türkiye'nin Kısa Dönem Yıllık Brüt Elektrik Enerjisi Talep Tahmini, *T.C Ankara Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı*, Ankara, 92.
- Zumerchik, J., 2001, Macmillan Encyclopedia of Energy, *USA*, Macmillan Reference p. 820.



**EKLER****EK-1** Regresyon Modelinin Tahmin Deęerleri.

	Gerçekleşen Deęerler	Regresyon Tahmin Deęerleri
2016-01	5796	5839
2016-02	4416	3949
2016-03	4170	3760
2016-04	3207	3408
2016-05	2880	2974
2016-06	2830	2894
2016-07	2875	2938
2016-08	3486	3471
2016-09	2433	2684
2016-10	3379	3259
2016-11	4881	4473
2016-12	6118	6110
2017-01	6375	6526
2017-02	5512	5636
2017-03	5003	5336
2017-04	4176	4321
2017-05	3143	3625
2017-06	3074	3457
2017-07	3938	4091
2017-08	3564	3941
2017-09	3458	3558
2017-10	3818	4107
2017-11	5908	5754
2017-12	5629	6565
2018-01	6499	6791
2018-02	5307	5838
2018-03	4584	4988
2018-04	3508	3590
2018-05	3248	2693
2018-06	2447	2574
2018-07	3662	3506
2018-08	2947	2648
2018-09	3271	2986
2018-10	3677	3608
2018-11	4208	4465
2018-12	6285	6712
Regresyon modelinin MSE -102969		

**EK-2 YSA Modelinin Tahmin Değerleri.**

	Gerçekleşen Değerler	YSA Tahmin Değerleri
2016-01	5796	5746
2016-02	4416	3846
2016-03	4170	3620
2016-04	3207	3264
2016-05	2880	2938
2016-06	2830	2906
2016-07	2875	2944
2016-08	3486	3339
2016-09	2433	2798
2016-10	3379	3151
2016-11	4881	4527
2016-12	6118	5827
2017-01	6375	5968
2017-02	5512	5654
2017-03	5003	5454
2017-04	4176	4327
2017-05	3143	3479
2017-06	3074	3321
2017-07	3938	4040
2017-08	3564	3858
2017-09	3458	3413
2017-10	3818	4056
2017-11	5908	5737
2017-12	5629	5993
2018-01	6499	6043
2018-02	5307	5756
2018-03	4584	5119
2018-04	3508	3433
2018-05	3248	2799
2018-06	2447	2753
2018-07	3662	3358
2018-08	2947	2846
2018-09	3271	3004
2018-10	3677	3458
2018-11	4208	4517
2018-12	6285	6001
YSA modelinin MSE -93381		



**EK-3** Rastgele Orman Modelinin Tahmin Değerleri.

	Gerçekleşen Değerler	Rastgele Orman n tree =100 Tahmin Değerleri	Rastgele Orman n tree =1000 Tahmin Değerleri	Rastgele Orman n tree =10000 Tahmin Değerleri
2016-01	5796	4851	4924	4928
2016-02	4416	3978	4048	4063
2016-03	4170	3796	3786	3792
2016-04	3207	3546	3545	3559
2016-05	2880	3192	3183	3176
2016-06	2830	3143	3150	3141
2016-07	2875	3064	3063	3058
2016-08	3486	3405	3430	3433
2016-09	2433	3171	3168	3163
2016-10	3379	3303	3304	3312
2016-11	4881	4418	4454	4462
2016-12	6118	4851	4924	4928
2017-01	6375	4851	4924	4928
2017-02	5512	4755	4840	4821
2017-03	5003	4697	4757	4755
2017-04	4176	4389	4424	4427
2017-05	3143	3524	3525	3529
2017-06	3074	3441	3485	3476
2017-07	3938	4080	4062	4105
2017-08	3564	3787	3816	3833
2017-09	3458	3535	3521	3523
2017-10	3818	4058	3976	4030
2017-11	5908	5143	5273	5256
2017-12	5629	5037	5137	5123
2018-01	6499	4977	4969	4992
2018-02	5307	4851	4924	4928
2018-03	4584	4747	4775	4792
2018-04	3508	3543	3535	3535
2018-05	3248	3171	3168	3163
2018-06	2447	3144	3133	3126
2018-07	3662	3574	3577	3582
2018-08	2947	3209	3191	3190
2018-09	3271	3239	3272	3278
2018-10	3677	3526	3522	3527
2018-11	4208	4418	4454	4462
2018-12	6285	4851	4924	4928
Rastgele Orman Modellerinin MSE değerleri		377.099	341.566	340.344

**EK-4 ARIMA Modelinin Tahmin Değerleri.**

	Gerçekleşen Değerler	ARIMA Tahmin Değerleri
2016-01	5796	5791
2016-02	4416	5284
2016-03	4170	4519
2016-04	3207	3721
2016-05	2880	3085
2016-06	2830	2729
2016-07	2875	2689
2016-08	3486	2916
2016-09	2433	3310
2016-10	3379	3748
2016-11	4881	4120
2016-12	6118	4350
2017-01	6375	4410
2017-02	5512	4315
2017-03	5003	4116
2017-04	4176	3878
2017-05	3143	3664
2017-06	3074	3520
2017-07	3938	3467
2017-08	3564	3501
2017-09	3458	3599
2017-10	3818	3727
2017-11	5908	3848
2017-12	5629	3937
2018-01	6499	3977
2018-02	5307	3968
2018-03	4584	3921
2018-04	3508	3854
2018-05	3248	3786
2018-06	2447	3733
2018-07	3662	3705
2018-08	2947	3704
2018-09	3271	3726
2018-10	3677	3761
2018-11	4208	3798
2018-12	6285	3829
ARIMA Modelinin MSE değeri		1050187

**EK-5 TBATS Modelinin Tahmin Değerleri.**

	Gerçekleşen Değerler	TBATS Tahmin Değeri
2016-01	5796	5445
2016-02	4416	5230
2016-03	4170	4106
2016-04	3207	3418
2016-05	2880	3286
2016-06	2830	3113
2016-07	2875	3120
2016-08	3486	3180
2016-09	2433	3252
2016-10	3379	3977
2016-11	4881	4900
2016-12	6118	5255
2017-01	6375	5617
2017-02	5512	5170
2017-03	5003	4025
2017-04	4176	3527
2017-05	3143	3297
2017-06	3074	3071
2017-07	3938	3114
2017-08	3564	3107
2017-09	3458	3324
2017-10	3818	4188
2017-11	5908	4872
2017-12	5629	5294
2018-01	6499	5741
2018-02	5307	5015
2018-03	4584	4021
2018-04	3508	3627
2018-05	3248	3253
2018-06	2447	3047
2018-07	3662	3076
2018-08	2947	3049
2018-09	3271	3471
2018-10	3677	4323
2018-11	4208	4800
2018-12	6285	5407
TBATS Modelinin MSE değeri		294752

## ÖZGEÇMİŞ

### KİŞİSEL BİLGİLER

**Adı Soyadı** : Osman Emin ERDEM  
**Uyruğu** : T.C.  
**Doğum Yeri ve Tarihi** : Konya / 23.05.1989  
**Telefon** : 0 554 744 67 12  
**Faks** : -  
**E-Posta** : [erdem.eminosman@gmail.com](mailto:erdem.eminosman@gmail.com)

### EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Selçuklu Cumhuriyet Anadolu Lisesi, Selçuklu / Konya	2006
Üniversite	: Eskişehir Osmangazi Üniversitesi, Odunpazarı / Eskişehir	2013
Yüksek Lisans	: Konya Teknik Üniversitesi, Selçuklu / Konya	-
Doktora	:	

### İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
12.2017-09.2018	YAYTEK TİC. LTD.	Üretim Planlama Mühendisi
10.2015-12.2017	BEDELOĞLU ALÜMİNYUM TİC. LTD.	Üretim Planlama Mühendisi
08.2013-02.2015	CAN EROĞLU BİLGİ SİSTEMLERİ	İş Analisti

### UZMANLIK ALANI

### YABANCI DİLLER

İngilizce