

**TÜRKİYE'DE YABANCILARA YAPILAN KONUT SATIŞININ  
TAHMİNİNDE MAKİNE ÖĞRENMESİ YÖNTEMLERİ  
PERFORMANSLARININ İNCELENMESİ**

**Pamukkale Üniversitesi  
Sosyal Bilimler Enstitüsü  
Doktora Tezi  
İşletme Ana Bilim Dalı  
Genel İşletme Doktora Programı**

---

**Cansu TOSUN GAVCAR**

**Danışman: Prof. Dr. Arzu ORGAN**

**Ağustos 2024  
DENİZLİ**

Bu tezin tasarımı, hazırlanması, yürütülmesi, arařtırmalarının yapılması ve bulgularının analizlerinde bilimsel etiĐe ve akademik kurallara özenle riayet edildiĐini; bu alıřmanın doĐrudan birincil ürünü olmayan bulguların, verilerin ve materyallerin bilimsel etiĐe uygun olarak kaynak gösterildiĐini ve alıntı yapılan alıřmalara atıfta bulunulduĐunu beyan ederim.

İmza

Cansu TOSUN GAVCAR

## ÖNSÖZ

Bu tezin hazırlanma sürecinde bilgi ve tecrübeleriyle bana yol gösteren saygıdeğer danışman hocam Prof. Dr. Arzu ORGAN başta olmak üzere, saygıdeğer tez izleme komite üyeleri Doç. Dr. Hüseyin KOÇAK ve Doç. Dr. Veysel Fuat HATİPOĞLU hocalarıma ve saygıdeğer tez savunma jüri üyeleri Prof. Dr. İrfan ERTUĞRUL ve Doç. Dr. Algın OKURSOY hocalarıma teşekkürlerimi sunarım.

Doktora eğitim hayatımda, varlığı benim için sonsuz kıymetli olan canım kızım Lina GAVCAR'a ve her türlü zorluğu birlikte aştığımız sevgili eşim Uzman Dr. Erdal Görkem GAVCAR'a bana olan desteği ve güveni için teşekkür ederim.

Bugünlere gelmemde emekleri çok büyük olan, bana her konuda destek ve her daim yanımda olan değerli annem Sevinç TOSUN'a, değerli babam Halil Önder TOSUN'a ve değerli kardeşim Ege TOSUN'a teşekkür ederim.

Destekleri ile yanımda olan değerli kayınvalidem Emine GAVCAR'a ve değerli kayınpederim Prof. Dr. Erdoğan GAVCAR'a teşekkür ederim.

Desteği ile yanımda olan değerli dostum Buket Sultan AKKAŞ ASLAN'a teşekkür ederim.

## ÖZET

### TÜRKİYE'DE YABANCILARA YAPILAN KONUT SATIŞININ TAHMİNİNDE MAKİNE ÖĞRENMESİ YÖNTEMLERİ PERFORMANSLARININ İNCELENMESİ

TOSUN GAVCAR, Cansu  
Doktora Tezi  
İşletme ABD  
Genel İşletme Doktora Programı  
Tez Yöneticisi: Prof. Dr. Arzu ORGAN

Ağustos 2024 IX+124 Sayfa

Günümüzde tahminleme teknikleri oldukça önem kazanmaktadır. Özellikle son yıllarda tahminlemede makine öğrenmesi yöntemlerinin kullanımı her geçen gün artmaktadır. Bu durumda, farklı yöntemlerden yararlanarak en uygun yöntemi belirlemek önem arz etmektedir.

Son yıllarda ülkemize göç eden yabancıların sayısı oldukça artmıştır. Dolayısıyla yerleşme istekleri konut satışına olan talebi de doğal olarak arttırmaktadır. Bu noktada konut sektöründe arz ve talep dengede tutulmalıdır. Bu sebepten, yabancıların konut talebini doğru bir şekilde tahmin etmek gerekmektedir.

Bu tezde, yabancılara yapılan konut satışının tahmininde dört makine öğrenmesi yöntemlerinin performansları karşılaştırılarak en uygun tahmin yöntemine ulaşılması amaçlanmıştır. Bu yöntemler; Çoklu Doğrusal Regresyon, Çok Katmanlı Yapay Sinir Ağı, Karar Ağacı Regresyon, Rastgele Orman Regresyonudur. Bu çalışmada, iki farklı veri seti kullanılarak yöntemlerin performansları karşılaştırılmıştır. Birinci veri setinde, 2013-2023 yılları arasındaki toplam 127 ayın mevcut olduğu 16 faktör bulunmakta, ikinci veri setinde ise, 2015-2023 yılları arasındaki toplam 102 ayın mevcut olduğu 20 faktör bulunmaktadır. Bu iki veri setinde, 4 farklı makine öğrenmesi yöntemi uygulanmıştır. Söz konusu yöntemlerinin performansları karşılaştırılmıştır.

Yöntemlerin karşılaştırılması sonucunda, Çoklu Doğrusal Regresyon yönteminin diğer yöntemlere göre daha iyi bir tahmin gerçekleştirmesi sağladığı; ikinci yöntem olarak Rastgele Orman Regresyonu modelinin olduğu saptanmıştır.

**Anahtar Kelimeler:** Yabancılara Konut Satışı, Çoklu Doğrusal Regresyon, Çok Katmanlı Yapay Sinir Ağı, Rastgele Orman Regresyonu, Karar Ağacı Regresyonu, Makine Öğrenmesi

## ABSTRACT

### AN INVESTIGATION OF THE PERFORMANCE OF MACHINE LEARNING METHODS IN THE PREDICTION OF HOME SALES TO FOREIGNERS IN TURKEY

TOSUN GAVCAR, Cansu

Doctoral Thesis

Business Administration Department

Ph.D. in Business Administration Programme

Adviser of Thesis: Prof. Dr. Arzu ORGAN

August 2024 IX+124 Pages

Nowadays, forecasting techniques are gaining importance. Especially in recent years, the use of machine learning methods in forecasting has been increasing day by day. In this case, it is important to determine the most appropriate method by utilizing different methods.

In recent years, the number of foreigners migrating to our country has increased considerably. Therefore, the desire to settle naturally increases the demand for housing sales. At this point, supply and demand in the housing sector must be kept in balance. For this reason, it is necessary to accurately forecast foreign demand for housing.

In this thesis, it is aimed to reach the most appropriate prediction method by comparing the performances of four machine learning methods in the prediction of housing sales to foreigners. These methods are Multiple Linear Regression, Multilayer Neural Network, Decision Tree Regression, Random Forest Regression. In this study, the performances of the methods are compared using two different data sets. In the first dataset, there are 16 factors with a total of 127 months between 2013-2023, and in the second dataset, there are 20 factors with a total of 102 months between 2015-2023. In these two datasets, 4 different machine learning methods were applied. The performances of these methods are compared.

As a result of the comparison of the methods, it was found that the Multiple Linear Regression method provided a better prediction than the other methods, with the Random Forest Regression model as the second method.

**Keywords:** Housing Sales to Foreigners, Multiple Linear Regression, Multilayer Artificial Neural Network, Random Forest Regression, Decision Tree Regression, Machine Learning

## İÇİNDEKİLER

ÖN SÖZ .....	i
ÖZET.....	ii
ABSTRACT.....	iii
İÇİNDEKİLER .....	iv
ŞEKİLLER DİZİNİ .....	vii
TABLolar DİZİNİ .....	viii
KISALTMALAR DİZİNİ .....	ix
GİRİŞ .....	1

## BİRİNCİ BÖLÜM TAHMİN ve TAHMİNLEME YÖNTEMLERİ

1.1. Tahmin ve Tahminleme Yöntemleri.....	4
1.2. Tahmin İlkeleri.....	5
1.3. Tahmin Yönteminin Seçimi.....	7
1.4. Tahminleme Yöntemleri.....	8
1.4.1. Nitel Yöntemler.....	8
1.4.1.1. Delphi tekniği.....	9
1.4.1.2. Yönetici görüşleri.....	10
1.4.1.3. Uzman grup görüşü.....	10
1.4.1.4. Satış ekibinin tahminleri .....	10
1.4.1.5. Senaryo analizi.....	11
1.4.2. Nicel Yöntemler.....	11
1.4.2.1. Klasik İstatistiksel Yöntemler .....	11
1.4.2.1.1. Doğrusal regresyon .....	11
1.4.2.1.2. Doğrusal olmayan regresyon .....	13
1.4.2.1.3. Zaman serisi analizleri .....	14
1.4.2.2. Yapay Zekâ ve Gelişmiş Modeller .....	15
1.4.2.2.1. Makine öğrenmesi .....	16
1.4.2.2.2. Derin öğrenme .....	18
1.4.2.2.3. Genetik algoritmalar .....	19
1.4.2.1.4. Bulanık mantık ve bulanık küme .....	20
1.4.2.1.5. Uzman sistemler .....	21
1.5. Tahmin İle İlgili Literatür Taraması .....	22

## İKİNCİ BÖLÜM

### YAPAY ZEKÂ VE MAKİNE ÖĞRENMESİ YÖNTEMLERİ

2.1. Çalışmada Kullanılan Makine Öğrenmesi Yöntemleri .....	23
2.1.1. Yapay Sinir Ağları .....	23
2.1.1.1. Yapay sinir ağlarının temel kavramları.....	24
2.1.1.2. Yapay sinir ağlarının ana yapıları.....	28
2.1.1.2.1. Tek katmanlı ileri beslemeli ağlar.....	29
2.1.1.2.2. Çok katmanlı ileri beslemeli ağlar.....	30
2.1.1.2.3. Tekrarlayan veya geri beslemeli ağlar.....	31
2.1.2. Çoklu Doğrusal Regresyon .....	31
2.1.3. Karar Ağacı Regresyon .....	33
2.1.4. Rastgele Orman Regresyon .....	35
2.2. Model Performans Değerlendirme Ölçütleri .....	38
2.2.1. K Katlamalı Çapraz Doğrulama.....	38
2.2.2. Hata Kareler Ortalaması.....	39
2.2.3. Hata Kareler Ortalamasının Karekökü.....	39
2.2.4. Belirleme Katsayısı.....	40
2.2.5. Hatanın Mutlak Ortalaması.....	41
2.2.6. Ortalama Mutlak Yüzde Hata.....	41

## ÜÇÜNCÜ BÖLÜM

### YABANCILARA KONUT SATIŞ TAHMİNİNDE MAKİNE ÖĞRENMESİ YÖNTEMLERİNİN KARŞILAŞTIRILMASI

3.1. Çalışmanın Amacı ve Yöntemi .....	46
3.2. Yabancılara Konut Satış Tahmininde Makine Öğrenmesi Yöntemlerinin Performanslarının Değerlendirilmesi .....	48
3.2.1. İllere Göre Yabancı Konut Satış Sayıları Dahil Edilerek Yapılan Yabancı Konut Satış Tahmininde Makine Öğrenmesi Yöntemlerinin Performanslarının Değerlendirilmesi .....	48
3.2.1.1. Çoklu doğrusal regresyon yöntemine göre performansların belirlenmesi .....	48
3.2.1.2. Karar ağacı regresyon yöntemine göre performansların belirlenmesi .....	54
3.2.1.3. Rastgele orman regresyon yöntemine göre performansların belirlenmesi .....	54
3.2.1.4. Çok katmanlı yapay sinir ağı yöntemine göre performansların belirlenmesi.....	55
3.2.2. İllere ve Ülke Uyrıklarına Göre Yabancı Konut Satış Sayıları Dahil Edilerek Yapılan Yabancı Konut Satış Tahmininde Makine Öğrenmesi Yöntemlerinin Performanslarının Değerlendirilmesi .....	56
3.2.2.1. Çoklu doğrusal regresyon yöntemine göre performansların belirlenmesi .....	56
3.2.2.2. Karar ağacı regresyon yöntemine göre performansların belirlenmesi .....	63

3.2.2.3. Rastgele orman regresyon yöntemine göre performansların belirlenmesi .....	64
3.2.2.4. Çok katmanlı yapay sinir ağı yöntemine göre performansların belirlenmesi .....	64
3.3. Makine Öğrenmesi Yöntemlerinin Analizlerinin Değerlendirilmesi .....	65
SONUÇ .....	69
KAYNAKLAR .....	74
EKLER .....	93
ÖZ GEÇMİŞ .....	124



## ŞEKİLLER DİZİNİ

Şekil 1. Makine Öğreniminin Genel Sınıflandırması.....	17
Şekil 2. İnsan Nöronu (1), Yapay Nöron (2), Biyolojik Sinaps (3), YSA Sinaps (4).....	25
Şekil 3. Bir Nöronun Doğrusal Olmayan Modeli.....	27
Şekil 4. Bir Nöronun Başka Bir Doğrusal Olmayan Modeli.....	28
Şekil 5. Tek Katmanlı İleri Beslemeli Ağ.....	29
Şekil 6. Tek Bir Gizli Katmanı Olan Çok Katmanlı İleri Beslemeli Ağ (3-3-2 Ağ)	30
Şekil 7. Karar Ağacı Yapısı .....	34
Şekil 8. Rastgele Orman Algoritması .....	36
Şekil 9. Konut Satış İstatistikleri .....	43
Şekil 10. Yabancılara Yapılan Konut Satış İstatistikleri .....	44
Şekil 11. Birinci Veri Setindeki Değişkenlerin Histogram Grafikleri .....	50
Şekil 12. Birinci Veri Setinde Yabancı Konut Satışı ile Arasında Güçlü Korelasyon Olan Bağımsız Değişkenlerin Saçılım Grafikleri .....	52
Şekil 13. İkinci Veri Setinde Yabancı Konut Satışı ile Arasında Güçlü Korelasyon Olan Bağımsız Değişkenlerin Saçılım Grafikleri .....	61

**TABLolar DİZİNİ**

Tablo 1. Veri Hakkında Bilgiler .....	49
Tablo 2. Yabancı Konut Satışının Diğer Değişkenlerle Korelasyonu .....	51
Tablo 3. Çoklu Doğrusal Regresyon Yönteminin Performans Değerleri .....	53
Tablo 4. Karar Ağacı Regresyon Yönteminin Performans Değerleri .....	54
Tablo 5. Rastgele Orman Regresyon Yönteminin Performans Değerleri .....	55
Tablo 6. Çok Katmanlı Yapay Sinir Ağı Yönteminin Performans Değerleri .....	55
Tablo 7. Veri Hakkında Bilgi .....	56
Tablo 8. Yabancı Konut Satışının Diğer Değişkenlerle Korelasyonu.....	58
Tablo 9. Çoklu Doğrusal Regresyon Yönteminin Performans Değerleri .....	62
Tablo 10. Karar Ağacı Regresyon Yönteminin Performans Değerleri .....	63
Tablo 11. Rastgele Orman Regresyon Yönteminin Performans Değerleri .....	64
Tablo 12. Çok Katmanlı Yapay Sinir Ağı Yönteminin Performans Değerleri .....	65
Tablo 13. Veri Setinde İller Mevcutken Yapılan Analizlerin Sonuçları .....	66
Tablo 14. Veri Setinde İller ve Uyruklar Mevcutken Yapılan Analizlerin Sonuçları .....	67

**KISALTMALAR DİZİNİ**

ARIMA	Auto Regressive Integrated Moving Average
ARMA	Auto Regressive Moving Average
ÇR	Çoklu Regresyon
DR	Doğrusal Regresyon
DVR	Destek Vektör Regresyon
KA	Kovaryans Analizi
KFE	Konut Fiyat Endeksi
KAR	Karar Ağacı Regresyon
HO	Hareketli Ortalamalar
HP	Hedef Programlama
RA	Regresyon Analizi
ROR	Rastgele Orman Regresyon
ÜD	Üstel Düzeltme
YSA	Yapay Sinir Ağları
YZ	Yapay Zekâ

## GİRİŞ

Konut, hane halkının en temel ihtiyalarından biri olan gvenlik ihtiyaını karřılayan bir yapı olup, aynı zamanda hane halkı iin barınma, sosyal, kltrel, yatırım malları ve tketim malları olarak karřımıza ıkmaktadır. lkelerin konut alım ve satımına iliřkin uyguladıkları politikalar, toplumların ekonomik dzeyi, refah seviyesi, teknolojik geliřmeler, kiřilerin seyahatleri konut alım ve satımını etkileyen nemli faktrlerdir (Piřkin, 2022: 572).

Konut talebi, artan kreselleřme ve yasal engellerin ortadan kaldırılmasıyla birlikte, bir lkedeki yerleřiklerle sınırlı olmaktan ıkmıřtır (Yanar ve Demir, 2022: 296). Kreselleřme, gayrimenkul sektrnde tařınmazların uluslararası alanda hareketini saėlamıřtır. lkemizde 2013 yılından itibaren Avrupa Birliėi'ne uyum yasaları kapsamında yapılan dzenlemeler, bu srecin hızlanmasına katkıda bulunmuřtur (Kadı, 2014: 41). Trkiye, jeopolitik konumu dolayısıyla konut sektrnde yabancılar iin olduka cazip bir lke haline gelmiřtir. zellikle komřu lkeler, Trkiye'yi gvenli bir lke olarak deėerlendirmektedir. Bu sebeple, son yıllarda lkemizde bir g artıřı yařanmaktadır. Bu durum, yabancıların konut talebinin artmasına sebep olmuřtur. Ayrıca lkemizin sahip olduėu doėal gzellikler, drt mevsimin yařanması, denizleri vb. zellikleri olduka nemli etkenlerdir (Karadaė ve Alıcı, 2024: 141). Konut sektrndeki bu canlılıėın devamlılıėının olabilmesi iin konut arz ve talebinin dengede tutulması nem arz etmektedir. Konut arz ve talebinin dengede tutulabilmesi ise konut satıř tahminlerinin doėru bir řekilde yapılması gereklidir (Seli, 2021: 22).

Talep tahmininde nitel ve nicel olmak zere klasik tahmin yntemlerinin yanı sıra, son yıllarda, talep tahminini daha iyi gerekleřtirmek amacıyla, makine ėrenmesi yntemleri istatistiksel yntemlere alternatif olarak ortaya ıkmıřtır. Karmařık problemlere özm retme, genellemelerdeki bařarısı, doėruluk ve yanlılık aısından daha iyi tahminde bulunma gibi stnlkleri sebebiyle makine ėrenmesi yntemleri, geleneksel tahmin yntemlerine gre daha ok kullanılmaktadır (Spiliotis vd., 2022: 3037).

Makine ėrenmesi, verilerin makineler tarafından daha verimli olarak nasıl kullanılacağı noktasında makinelere ėretmek iin kullanılmaktadır. Bazı durumlarda

verilerin incelenmesi sonrasında, elde edilen bilgiler yorumlanamamaktadır. Bu tip durumlar için, makine öğrenimi uygulanmaktadır. Günümüzde veri kümelerinin çeşitliliği fazladır. Bu durum da makine öğrenimine olan talebi arttırmaktadır. Birçok sektör, bu sebeplerden ötürü makine öğrenimini uygulamaktadır. Makine öğrenmesinin temel amacı sahip olunan mevcut verilerden öğrenmektir. Makine Öğrenimi, veri problemlerini çözmek için farklı algoritmalara dayanmaktadır (Mahesh, 2020: 381).

Çalışmada, ülkemizde yabancılara konut satışının tahmininde makine öğrenmesi yöntemleri ele alınmıştır. Söz konusu yöntemler performans ölçütlerine göre karşılaştırılmıştır. Yabancılara yapılan konut satış tahmini ile ilgili literatürdeki çalışmalar incelendiği zaman, bu alanda makine öğrenmesi yöntemlerinin karşılaştırılması konusunda kısıtlı çalışma olmasından dolayı bu konu tercih edilmiştir. Yabancılara Konut Satışı tahmininde özellikle farklı makine öğrenmesi yöntemleri kullanılmıştır. Söz konusu yöntemler arasında karşılaştırma yapılarak en iyi tahmin yapan makine öğrenmesi yönteminin belirlenmesi amaçlanmıştır.

Çalışma üç ana bölümden oluşmaktadır. Birinci bölümde, tahmin kavramı tanımlanarak, tahminleme yöntemleri, tahmin ilkeleri ve tahmin yönteminin seçimi konuları hakkında açıklayıcı bilgiler verilmiştir. Tahmin yöntemleri, nitel ve nicel yöntemler olmak üzere ikiye ayrılmıştır. Söz konusu yöntemler açıklanmıştır. Tahmin ile ilgili literatür taraması yapılarak, mevcut çalışmalara yer verilmiştir.

İkinci bölümde, yapay zekâ kavramı açıklanmıştır. Başlıca yapay zekâ tekniklerinden bahsedilmiştir. Yapay zekâ tekniklerinden olan makine öğrenmesi hakkında detaylı olarak bilgi verilmiştir. Çalışmada kullanılan makine öğrenmesi yöntemleri ele alınmıştır. Yapay Sinir Ağları, insan beynini taklit eden bir tahmin modeli olarak tanımlanmıştır. Çoklu Doğrusal Regresyon, bağımlı değişken ile birden fazla bağımsız değişken arasındaki ilişkiyi tahmin etmek amacıyla oluşturulan model olarak tanımlanmıştır. Karar ağacı regresyon, bir karar ağacına dayalı tahmin modeli olarak tanımlanmıştır. Rastgele Orman Regresyonu bir dizi karar ağacına dayalı bir regresyon tahmin modeli olarak tanımlanmıştır. Model performansının değerlendirilmesinde kullanılan ölçütler sınıflandırılmıştır. Söz konusu ölçütler hakkında bilgi verilmiştir.

Üçüncü bölümde ise, ülkemizde yabancılara konut satışının tahmininde makine öğrenmesi yöntemleri karşılaştırılıp, en uygun tahmin yönteminin belirlenmesine

yönelik yöntem, analiz, bulgular ve sonuçlar sunulmuştur. Analiz sonucunda söz konusu yöntemlerin performans değerlendirmesi yapılmıştır. Performans ölçütleri karşılaştırılmıştır. Sonuç olarak, yabancılara yapılan konut satış tahmin modeli için en uygun makine öğrenmesi yöntemi saptanmıştır.

## BİRİNCİ BÖLÜM

### TAHMİN ve TAHMİNLEME YÖNTEMLERİ

#### 1.1. Tahmin ve Tahminleme Yöntemleri

Modem bir toplumda, hisse senedi fiyatlarından otomobil satışlarına, ülkedeki toplam enerji tüketiminden mikrobilgisayar iş alanında devam edecek şirket sayısına kadar çok sayıda tahmin mevcuttur. *International Journal of Forecasting*' e (Uluslararası Tahmin Dergisi) göre tahmin, özel ve kamu kuruluşlarında tam donanımlı bir işleve dönüşmüş şekilde yer almaktadır. Tahminler, farklı disiplinlerden gelen çeşitli yaklaşımlarla üretilmektedir. Çeşitli yönetsel ve teknik faaliyetler için farklı şekillerde kullanılmaktadır (Chen ve Kung, 1984: 255). Söz konusu *International Journal of Forecasting*, 1982'de *International Institute of Forecasters* (Uluslararası Tahminciler Enstitüsü) tarafından *Journal of Forecasting* (Tahmin Dergisi) kurulduktan sonra, 1985'te kurulmuştur. Kuruluşlarının temel amacı, birden çok akademik disiplini ilgilendiren bir bakış açısı kazandırmak olmuştur. Tüm tahmin yöntemleri ilgi çekmektedir (Fildes, 2006: 415).

İşletmelerin başarılı olması ve faaliyetlerine devam edebilmesi için kısa, orta ve uzun vadede planlamalar yapmak zorundadır. İyi bir tahmin işletmenin başarısını doğrudan etkilemektedir. Bu nedenle yapılacak olan tahminlerin bilimsel yöntemlere dayandırılmaları gerekmektedir. Tahmin, şimdiki zamanda gelecekte ne olacağını önceden haber veren bilgi ve sanattır. Tahmin yaparken, geçmiş veriler ve bilgiler olmalıdır. Geçmiş veriler ve bilgiler, geçmişte o sırada çeşitli durumlarda ortaya çıkan davranışlardır (Wardani vd., 2019: 1). Pek çok durumda tahmin yapmak gerekmektedir. Örnek olarak, önümüzdeki beş yıl içinde başka bir elektrik üretim tesisi inşa edip etmemeye karar vermek, gelecekteki talep tahminlerini gerektirmektedir. Gelecek hafta bir çağrı merkezindeki personeli planlamak, çağrı hacmi tahminlerini gerektirmektedir. Bir envanteri stoklamak, stok gereksinimlerinin tahminlerini gerektirmektedir. Tahminler, sermaye yatırımları durumunda birkaç yıl önceden veya telekomünikasyon yönlendirmesi için sadece birkaç dakika öncesinden gerekli olabilmektedir. Koşullar veya zaman dilimleri ne olursa olsun, tahmin, etkili ve verimli planlamada önemli bir yardımcıdır (Hyndman, 2009: 1).

Talep kavramı; belli bir yerde, belli bir zaman diliminde, belli bir miktar ve fiyattan satın alınması arzulanan mal ve hizmet miktarıdır. Talep etmek; kavramsal

olarak istemek, arzulamak olarak belirtilse de iktisadi anlamda satın alma gücü ile birliktelik göstererek oluşması gerekmektedir (Korucuk vd., 2015: 16). Talebin tahmin edilmesi ise, belirlenmiş bir zaman sürecinde, müşterilerin işletmeden talepte bulunabileceği ürün miktarı ile bu ürünün imalatı için gerekli olan hammadde ve gerekli malzeme miktarının talep oluşmadan önce saptanmasıdır. Taleplerin tahmin edilebilmesi amacıyla farklı yöntemler ortaya koyulmuştur. Bu yöntemler direk ve indirekt yöntemler olarak sınıflandırılmaktadır. Direk yöntemlere örnek olarak anket benzeri yöntemler örnek verilirken, indirekt yöntemlere örnek olarak regresyon analizi, korelasyon yöntemi, zaman seriler analizi ve en küçük kareler yöntemi verilebilir (Deran vd., 2014: 24).

Geleceği daha iyi bilmek, binlerce yıldır birçok insanı etkilemektedir. Tahmin yöntemleri büyük ölçüde değişiklik göstermektedir. Tahmin yöntemleri, verilerin ulaşılabilirliğine, mevcut modellerin kalitesine ve diğerlerinin yanı sıra yapılan varsayım türlerine bağlı olacaktır. Genel olarak, tahmin etmek kolay bir iş değildir. Bu yüzden, bu konuyu keşfetmek birçok araştırmacı için oldukça caziptir. Yapay Sinir Ağı, tahmin teorisinde giderek artan bir öneme sahiptir. YSA örneklerden (geçmiş veriler) öğrenebilmektedir. Tarihsel gözlemlerde gizli bir model tanıyabilir ve bunları gelecekteki değerleri tahmin etmek için kullanabilir. Buna ek olarak, eksik bilgi veya gürültülü verilerle başa çıkabilmektedir. Özellikle bir sorunun çözümüne yol açan kuralları veya adımları tanımlamanın mümkün olmadığı durumlarda çok etkili olabilmektedir (Shamsuddin vd., 2008: 1-2).

## **1.2. Tahmin İlkeleri**

Tahmin yöntemleri seçilirken birçok değişken faktörün değerlendirilip incelenmesi gerekmektedir. Bu faktörler arasında; kullanılan yöntemin kolay olması, maliyet noktasındaki tahminlerin hazırlanma süresi, gerekli verilerin toplanması, elde edilen verilerin özellikleri, tahmin edilmesi planlanan dönemin zaman aralığı, elde edilen tahminlere göre uygulanacak kararların kısa veya uzun vadeli oluşu, süreçle ilgili karar verme yetkisine sahip kişilerin uygun olarak değerlendirebileceği hata payı, kullanılması planlanan tahmin yöntemini hayata geçirecek ve yöntemden elde edilen sonuçların yol göstericiliğinde karar verme yetkisine sahip birimlerin özellikleri sayılabilir. Başta ekonometrik modeller olmak üzere tahmin modellerinde uygun değişkenlerin seçilebilmesi de büyük önem arz etmektedir. Tahmin süreçlerini olumsuz



etkileyebilen ve bu sebeple istenmeyen bazı durumlar mevcuttur. Tahmin modellerinin geniş ve karmaşık olması bu durumlara örnek olarak verilebilir (Akgül, 2013: 93).

Tahmin etme sürecinde bilgi sahibi olunan ve gelecek ile ilgili olan veriler değerlendirmeye alınmalıdır. Reklam veya düzenlenen bir kampanya sonucunda, talepte hızlı yükseliş, sonrasında hızlı düşüş ve son olarak normal düzeylere gelme şeklinde sonuçlar oluşabilmektedir. İşletmelerin gelecekte yapmayı planladığı promosyon dağıtımının sonrasında talep düzeyinin artacağına bilinmesi gerekmektedir. Promosyon kampanya sürecinin tamamlanmasının ardından ürüne yönelik talepte azalmalar olacağı unutulmamalıdır. Piyasa ortamına çıkan yeni ürünler veya rekabet halinde olunan firmaların benzer ürünlerini daha uygun fiyatlı satışa sunması gibi durumları içeren rekabet kavramı, politika ve endüstrinin ekonomik yapısı göz önünde bulundurulması gereken faktörler olarak akılda tutulmalıdır. Bu kavramlara talep tahmini sürecinde önem verilerek dikkat edilmelidir (Aydın, 2017: 4).

Tahmin ilkeleri, tahmin çıktılarının etkili şekilde değerlendirilmesi ve kullanılması için bilinmesi gereken kavramlardır. Bu ilkeler ve sahip oldukları özellikleri aşağıda belirtilmektedir (Bulut, 2006: 11-13; Meydan, 2007: 16-17; Demirbaş, 2011: 7-8):

- Mükemmel bir tahminde bulunabilmek genel anlamda mümkün görülmemektedir. Çoğunlukla var olan gerçek sonuçlar, tahmin edilen değerlerden farklılık arz etmektedir. Bu farklılığa sebep olabilecek 2 faktör belirtilmektedir. Bunlardan birincisi, tahmin edilmesi planlanan değişkene etki edebilecek bütün faktörlerin dikkate alınmamış olması gerçeği, ikincisi ise ön görülemeyen, oluşması beklenmeyen tesadüfî süreçlerin etkisidir.
- Tahminlerde belirli bir hata payı olmaktadır. Bu sebeple, tahmin yapılırken alt ve üst sınırları olan bir tahmin aralığının belirlenmesi önem arz etmektedir.
- Tahminler yapılırken veri setinin geniş olması daha duyarlı sonuçlar oluşturmaktadır.
- Tahminlerde zaman aralığının kısa olması duyarlılık düzeyini arttıran bir durumdur.
- Tahmin yapılırken, gelişmelerin ve değişimlerin göz önünde bulundurulması gerekmektedir.

### 1.3. Tahmin Yönteminin Seçimi

Yönetim kararları gelecek ile ilgili konuları kapsamaktadır. Yönetim uygulamalarında karar verme süreçlerinde gelecek ile ilgili öngöründe bulunabilme gayreti işletmeler için önem arz eden bir husustur. Olayların gerçekleşme olasılığı, her zaman doğru tahmin oluşturmaya bile karar vericilere yol göstererek onlara avantajlar kazandırabilmektedir. Güvenilir tahmin modeli birden çok değişkenden meydana gelen bir fonksiyon biçiminde düşünülebilmektedir. Bu değişkenlerden biri de tahmin kavramıdır. Hata açısından değerlendirildiğinde, uzun dönemli olan tahminler kısa dönemli olan tahminlere göre daha fazla hata içerebilmektedir. Tahmin modelinin güvenilirliğini etkileyen bir başka değişken ise, geçmiş bilgilere dair gözlem sayısını içeren örnek hacmidir (Karahan, 2011: 29).

Tahmin yöntemini seçmenin altı yolu tanımlanmıştır: Kolay olan yöntem tercih edilebilmektedir. Kolaylığından ötürü ucuz ama riskli olabilmektedir. Popülaritesi yüksek olan yöntem seçilebilmektedir. Ancak popülerlik ve başarı ilişkili olmayabileceğinden ve bazı yöntemleri göz ardı ettiğinden dolayı değerli olma ihtimali düşüktür. Yapılandırılmış yargı, yani yöntemleri önceden belirlenmiş kriterlere göre değerlendirmek umut verici bir bakış açısı olarak görülebilmektedir. İstatistiksel kriterler, "neyin işe yaraması gerektiği", yaygın olarak kullanılmaktadır. Değerli aynı zamanda da dar bir şekilde uygulanırsa risklidir. Göreceli sicil kayıtları, "bu durumda ne işe yarar", değerlendirme çalışmalarının yürütülmesine bağlı olduğu için pahalıdır. Önceki araştırmalardan elde edilen kılavuzlar, "bu tür bir durumda ne işe yarar", yayınlanmış araştırmalara dayanmaktadır. Seçim için düşük maliyetli, etkili bir yaklaşım sunmaktadır (Armstrong, 2001: 365).

Talep tahmin yöntemi seçilirken; duyarlılık, zaman tasarrufu ve maliyet kavramları önem arz etmektedir. Bunun yanı sıra (Kobu, 2010: 131-132):

- Karar verici kişiler için anlaşılabilirlik
- Zaman
- Kararın kısa, orta veya uzun dönem olması
- Yöntem ile verilerin uyumu
- Değişkenlik

- Karar vericinin bölümü

tahmin yönteminin seçimi hususunda değerlendirilmesi gereken etkenlerdir.

#### **1.4. Tahminleme Yöntemleri**

Talep tahminleri, kısa, orta ya da uzun vadeli olacak şekilde gerçekleştirilebilmektedir. 1 saatten 1 haftaya kadar olan zamanı kapsayan tahminler kısa vadeli, 1 haftadan 1 yıla kadar olan zamanı kapsayan tahminler orta vadeli, 1 yıldan uzun süreye sahip tahminler için ise uzun vadeli tahminler yapılmaktadır (Tutu, 2017: 53).

Tahmin yöntemleri, en uygun biçimde kullanılacakları durumlara göre değerlendirilmelidir. Değerlendirme işleminin temelinde, yöntemlerin uygun alternatiflere karşı test edilmesi ihtiyacı yatmaktadır. Değerlendirme dört adımdan oluşmaktadır: varsayımların test edilmesi, verilerin ve yöntemlerin test edilmesi, çıktıların çoğaltılması ve çıktıların değerlendirilmesidir (Armstrong, 2001: 443).

##### **1.4.1. Nitel Yöntemler**

Bu yöntem çeşitleri; öznel yöntemler olarak da bilinmektedir. Geçmiş dönemler ile ilgili yeterli düzeyde bilgiye ulaşamadığı durumlarda, bilimsel olarak değerlendirilen yöntemlerin yerine bireylerin fikir ve deneyimlerine başvurularak gerçekleştirilen tahmin yöntemleridir. Bu yöntemlerin dayanağının, bilimsel veriler olmaması sebebiyle; düşük tahmin performansı gerçekleşmektedir. Bir başka açıdan değerlendirildiğinde, işletmenin kullandığı teknolojinin artık kullanılmadığı bir dönem ile ilgili tahmin gündeme geldiğinde geçmiş dönemde elde edilen veriler kullanılamayacaktır. Bu gibi durumlarda teknolojinin değişimi ve gelişimi süreci hakkında bilgi birikimi olan ve ayrıca yeterli deneyime de sahip olan kişilerin görüşleri önem kazanmaktadır. Bu kişilerin bilgisine başvurulmaktadır. Ayrıca nitel yöntemlerin önemli bir yönü, makro çevrenin hızlı bir biçimde değiştiği ya da çevresel etkilerde karışıklıkların gözlemlendiği durumlarda kullanılabilmesidir. Bununla birlikte, çoğunlukla yüksek bir maliyete sahip olmamaları ve istatistiksel açıdan üst düzey bilgi birikimi ve yeteneğe gerek duyulmadan gerçekleştirilebilmeleri de önemli yönleri olarak görülmektedir. Ancak, fikirlerine başvuru alan bireylerin bilgi ve birikimlerinin yeterli düzeyde olmaması ve gelecek ile ilgili beklentiler içermeleri nedenleriyle

tahminlerin etkilenebilme ihtimali olması bu yöntemlerin olumsuz yönleri olarak görülmektedir (Demirbaş, 2011: 10).

Nitel tahmin yöntemleri, aşağıdaki koşullardan biri veya her ikisi birden sağlanmadığında kullanılmaktadır:

1. geçmişle ilgili sayısal bilgiler mevcuttur;
2. geçmişteki modellerin bazı yönlerinin gelecekte de devam edeceğini varsaymak mantıklıdır.

Ayrıca, resmi istatistiksel modele dahil edilemeyen bilgileri dikkate alarak nicel tahminleri ayarlamak için kullanılmaktadır (Hyndman, 2009: 1).

#### **1.4.1.1. Delphi tekniği**

Delphi tekniği, 1950'lerde RAND Corporation'da, geleneksel grup toplantılarının olumsuz yönlerinden kaçınırken farklı uzmanların bilgilerini yakalamaya yardımcı olmak için geliştirilmiştir. Bu olumsuzluklar arasında grup baskısı, yüksek idari masraflar ve yapı eksikliği yer almaktadır. Delphi ile tahmin yapmak için yönetici, bilgi ve görüşlerinde çeşitlilik gösteren beş ile yirmi uzmana tahminlerini ve bunların nedenlerini sormalıdır. Yönetici daha sonra uzmanlara tahminlere ilişkin anonim özet istatistikler ve uzmanların tahminlerine ilişkin gerekçelerini sunmaktadır. Süreç, turlar arasında tahminlerde çok az değişiklik olana kadar tekrarlanmaktadır. İki ya da üç tur genellikle yeterlidir. Delphi tahmini, uzmanların son tur tahminlerinin ortancası veya modudur (Armstrong ve Kesten, 2005: 3).

Delphi yöntemi, fikir-oylama yöntemleri kullanılarak tartışılacak konuda bir anlaşma sağlanması amacı taşımaktadır. Özellikle çok çeşitli düşünceleri temel alan uzun dönemli tahminler için geliştirilmiştir. Delphi yöntemleri üç başlık altında değerlendirilmektedir. Bunlardan birincisi, "Decision Delphi" tekniği olarak isimlendirilen ve tam katılımcılık yaklaşımını içeren yöntemdir. Bu yöntemin amacı, kararlar almak ve alınan bu kararlar ile sosyal gelişmeleri etkilemektir. Delphi yöntemlerinin 2.başlığı olan "Klasik Delphi" tekniğinde kurallar açık olarak ortaya koyulmaktadır. Sahip olduğu bu koşul nedeniyle Klasik Delphi tekniği sosyal sistemler için uygulanabilir olmaktan uzak olmaktadır. Delphi yöntemlerinin 3.başlığı olan "Policy Delphi" tekniğinde görüşler ön planda tutulmaktadır. İstatistiksel veriler ve gerçekler önem arz etmez. Panele katılan kişiler, fikirlerini Delphi yöntemlerini kullanarak belirtmektedir (Akgül, 2013: 99).

#### **1.4.1.2. Yönetici görüşleri**

Yönetici görüşü, bir veya daha fazla yöneticinin fikirlerinin, deneyimlerinin ve teknik bilgilerinin tek bir tahmini elde etmek için özetlendiği bir yöntemdir. Ani gelişen uluslararası olaylar gibi olağan dışı durumlar dikkate alınarak, o an yapılan satış tahminini düzeltmek amacıyla yararlanılabilir (Krajewski vd., 2020: 467). Bu yöntemin olumlu yönleri hızlı ve kolay tahmin yapılabilmesinin yanında; istatistiksel süreçlere gereksinim duyulmamasıdır. Tahmin sonucu bir kişiye değil, bir gruba ait olacağından dolayı; sahip olunan sorumluluk da grupta yer alan kişilere dağıtılacaktır. Dolayısıyla, tahminin belirlenmesinde kişisel sorumluluk azalacaktır. Bu durum da yöntemin en önemli olumsuz yanındır (Aydın, 2017: 9).

#### **1.4.1.3. Uzman grup görüşleri**

Çalıştıkları alanda uzman olan kişilerin deneyimleri ve benzer olay yönetimindeki içgüdüsel olumlu tarafları dikkate alınarak, uzman kişilerden oluşan grubun görüşleri olarak değerlendirilebilir. İşletmede karar verme yetkisi olan yönetici kadrosundaki kişilerin, uzmanların, deneyimli bireylerin fikirleri ile bireysel değerlendirmeleri bir araya getirilerek işletmelerin satış ile ilgili tahminleri elde edilmektedir (Aikeshan, 2014: 10).

Uzman grup görüşleri yönteminin en olumsuz yönlerinden birisi toplam tahmini temsil etmemesidir. Yöntemin üstünlükleri (Çağlar, 2007: 20):

- Kısa zamanda hazırlanabilir olması
- Kantitatif uygulamaya ihtiyaç duyulmaması
- Farklı ortamlarda uygulanabilir olması
- Teknik desteğe gerek olmaması.
- Geçmişle ilgili bilgilerin kullanılabilmesi.

#### **1.4.1.4. Satış ekibinin tahminleri**

Şirketin satış ekibini oluşturan üyelerin düzenli olarak yaptıkları öngörülerden bir araya getirilen tahminlerdir. Satış grubunda yer alan çalışanlar, müşterilerin tercih edebileceği mal ve hizmetleri satın alabilecekleri miktarı büyük ihtimalle bilebilecek bir ekiptir. Farklı satış grubunda olan kişilerin tahminleri bölgesel veya ulusal satış

tahminlerine ulaşmak için bir araya getirilebilir. Satışçıların bireysel önyargıları tahmini bozabilir. Bu durumda tahminlerde düzeltmelerin yapılması gerekebilir (Krajewski vd., 2020: 466).

Tüketiciler ile yüz yüze görüşme imkanının olmadığı, satışı gerçekleştirecek çalışanların iş birliği yapmaya istekli oldukları, bu kişilerin peşin yargısının olmadığı, tahminde bulunmanın satıcı ve satış personelinin yana faydalar oluşturduğu koşullarda gerçekleştirilebilmektedir (Bulut, 2006: 15).

#### **1.4.1.5. Senaryo analizi**

Senaryo yönteminde işletme, gelecekte talep edilen çıktılara ulaşılması sürecinde karşılaşılabilecekleri olası durumları, farklı nitel ve nicel tahmin yöntemleri kullanarak kurgulamaktadır. Bu durumlara uyumlu davranışlar belirlemeye çalışmaktadır. Senaryo geliştirmek, yaratıcılık gerektiren bir etkinliktir. Temel amaç, sonuca ulaşmaya çalışma sürecinde birden fazla olası durum geliştirerek; bu durumlara uyum sağlayabilen davranışları saptayabilmektir (Ülgen ve Mirze, 2013: 112).

#### **1.4.2. Nicel Yöntemler**

Geçmişte elde edilmiş veriler yardımıyla gelecek zaman dilimindeki istenilen tahminin matematiksel biçimde hesaplanmasıdır. Geçmiş dönemlere ait yeterli miktarda bilginin olması ve bu bilgilerin matematiksel biçimde ölçülebilir olması durumunda kullanılmaktadır. Nicel tahmin yöntemlerinde basit işlemler mevcut olmasına rağmen; karmaşık işlemler de yer almaktadır. Uygulama süreçlerinde bazı yöntemlerin, başka diğer yöntemlere kıyasla daha uygun çıktı vermesi bu yöntemler hakkında bir genelleme yapmaya yeterli değildir. Farklı tahmin yöntemlerinin çeşitli tahmin yapılarıyla kullanılması ve değerlendirilmesi gerekmektedir (Demirbaş, 2011: 13).

##### **1.4.2.1. Klasik İstatistiksel Yöntemler**

###### **1.4.2.1.1. Doğrusal regresyon**

Regresyon, iki veya daha fazla değişken arasındaki doğrusal ilişkinin modellenmesi için kullanılan bir yöntemdir. Bağımlı değişken sürekli olduğunda, genellikle doğrusal bir regresyon modeli kullanılmaktadır. Doğrusal modellerde, hata terimlerinin normal dağılıma sahip olduğu varsayılmaktadır (Gacar ve Kocakoç, 2020: 253).

Değişkenler arasındaki ilişkilerin değerlendirilmesi amacıyla kullanılan istatistiksel yöntemdir. Genellikle bir değişkenin diğer bir değişken üzerindeki nedensel etkisini (örneğin fiyattaki artışın talep üzerinde oluşan etkisi ya da para arzında meydana gelen değişikliklerin enflasyon oranı üzerindeki etkisi gibi) tespit edilmeye çalışılmaktadır. Araştırmacılar, değerlendirmek istedikleri değişkenler ile ilgili verileri topladıktan sonra nedensel değişkenlerin etkiledikleri değişken üzerindeki nicel etkisini tahmin edebilmek amacıyla regresyon yöntemini kullanmaktadırlar. Araştırmacılar, tahminde bulunulan ilişkilerin "istatistiksel olarak anlamlılığını", yani gerçekte olan ilişkinin tahmin edilen ilişkiye yakın olduğunu gösteren güven düzeyini incelemektedir (Sykes, 1993: 1).

Regresyon analizi, bir veya birden fazla nicel bağımsız değişkenin tek bir nicel bağımlı değişkene ait değerleri açıklamak ya da tahmin etmek amacıyla kullanılan istatistiksel bir yöntemdir. Regresyonun iki ana türü bulunmaktadır: Basit regresyon, tek bir bağımsız değişkenin olduğu; ÇR ise iki ya da daha fazla bağımsız değişkenin yer aldığı regresyon türüdür. Regresyon analizinin temel amacı bir regresyon eşitliğine ulaşabilmektir. Eşitlik kavramı, verilerdeki gözlem çıktılarına en iyi uyumu gösteren regresyon doğrusunu tanımlamaktadır (Christensen vd., 2015: 463). Regresyon analiz yöntemleri olarak; Polinom Regresyon, DVR, KAR ve ROR da mevcuttur (Uğuz, 2023: 73).

Regresyon analizi üç adımda gerçekleşmektedir (Gogtay vd., 2017: 49):

1. Korelasyonun (verilerin gücü ve yönlülüğü) analiz edilmesi
2. Regresyon veya en küçük kareler doğrusunun uyumu
3. Modelin geçerliliğinin ve kullanılabilirliğinin değerlendirilmesi.

Trend doğrusunun objektif olarak oluşturulabilmesi için en küçük kareler tekniği kullanılmaktadır. Söz konusu tekniğin mantığı, veriler ile bu verilerin arasından geçecek trend denklemine göre ulaşılabilecek olan teorik değerler arasındaki farkların kareleri toplamının en küçük olmasıdır (Gavcar, 2019: 138).

Yeterli düzeyde açıklayıcı gücü olan güvenilir bir regresyon katsayısıyla güvenilir tahminler elde edilebilmektedir. Regresyon analizinde, zaman içinde değişen geçmiş veriler kullanılarak bir eşitlik (formül) geliştirilebilir. Bu eşitlik, gelecekteki değerleri tahmin etmek için kullanılır. Tahminde kullanılan bağımsız değişkenlerin

değerleri, önemli ölçüde aşırı ise, tahmin hatasının da fazla olması beklenir. Geçmiş zaman verilerinin sürekli ve düzenli biçimde meydana geldiği durumlarda, tahminin tutarlılığının da o düzeyde yüksek olması beklenecektir (Karahan, 2011: 44).

#### 1.4.2.1.2. Doğrusal olmayan regresyon

İki değişken arasında ilişki bulunmadığı zaman doğru denklemi tahminlerde kullanılmaz. Bu durumda iki değişken arasında ilişki olup olmadığını bulmak ve buna bağlı denklemi oluşturmak için doğrusal olmayan regresyon kullanılabilir. Doğrusal olmayan regresyonda en çok kullanılan denklem ikinci derece (parabol) fonksiyonudur (Gavcar, 2009: 176).

Doğrusal olmayan regresyon modelleri de aynı doğrusal modeller gibi basit formda gösterilebilir:

$$Y_i = f(X_i, \gamma) + \varepsilon_i \quad (1)$$

Doğrusal olmayan regresyon modellerinde, regresyon parametre sayısı modeldeki açıklayıcı değişken sayısı ile doğrudan ilişkili değildir. Eşitlik 1'de  $\gamma$ , bilinmeyen parametrelerin vektörü;  $\varepsilon$ , korelasyonsuz hata terimidir.  $F(X_i, \gamma)$  ise doğrusal olmayan regresyon modeli için beklenti fonksiyonu olarak adlandırılmaktadır. Doğrusal olmayan regresyon modellerinin parametre tahminleri için önerilen birçok yöntem vardır. En çok bilinenler ise; en küçük kareler, en çok olabilirlik (maximum likelihood) ve gauss newton yöntemleridir (Keskintürk ve Şahin, 2009: 168-169).

Doğrusal olmayan regresyon modelleri istatistik, kimya, fizik, psikoloji, sağlık bilimleri ve biyoloji gibi çeşitli alanlarda yaygın olarak kullanılmaktadır. Doğrusal olmayan regresyon modellerinden istatistiksel çıkarımlar elde edilebilmektedir. Doğrusal olmayan regresyon modellerinin başlıca avantajları arasında yorumlanabilirlik, basitlik ve tahmin yer almaktadır. Genel olarak, doğrusal olmayan modeller çeşitli ortalama fonksiyonları barındırabilmektedir. Bu nedenle doğrusal olmayan modeller az sayıda parametreye sahip uygulamalar için uygundur ve parametrelerin anlamlı faktörlerle ilişkilendirilebilmesi nedeniyle kolayca yorumlanabilmektedir (Huang ve He, 2024: 1).



### 1.4.2.1.3. Zaman serisi analizleri

Zaman serisi yöntemleri hareketli ortalamalar, üstel düzeltme, AR, ARMA, ARIMA olarak sınıflandırılabilir.

Hareketli ortalamalar yönteminde, tahmin değeri sabit sayıda önceki gözlemlerin ortalaması olarak hesaplanmaktadır. Ortalamaya dahil edilecek gözlem sayısı genellikle tahmincinin "duyarlılığı" ile "istikrarı" arasında bir uzlaşma sağlamak için keyfi olarak belirlenmektedir. Alternatif olarak, dahil edilen gözlem sayısı, haftalık verilerdeki aylık döngü gibi bir tür periyodik davranışı ortadan kaldırmak için seçilebilmektedir. Bu durumda, hareketli ortalama aslında bir sonraki haftanın seviyesine ilişkin bir tahminden ziyade bir sonraki ayın ortalama seviyesine ilişkin bir tahmindir (Caldwell, 2006: 5).

Üstel düzeltme ile tahmin değeri, önceki gözlemlerin ağırlıklı bir ortalamasıdır. Üstel düzeltmede, ağırlıkların azalma oranını belirleyen bir veya daha fazla parametre (sabit) vardır. Düzgünleştirme sabitleri olarak adlandırılan bu parametreler ya keyfi olarak ya da en küçük kareler yöntemi gibi bazı resmi tahmin prosedürleriyle belirlenmektedir (Caldwell, 2006: 5).

Bir AR modeli doğrusal bir regresyon modeline benzemektedir. Ancak bir regresyon modelinde bağımlı değişken ve bağımsız değişkenler farklıdır. Oysa bir AR modelinde bağımsız değişkenler sadece bağımlı değişkenin zaman gecikmeli değerleridir. Bu nedenle otoregresiftir. Bir AR modeli farklı sayıda otoregresif terim içerebilmektedir. Bir AR modeli yalnızca bir otoregresif terim içeriyorsa, bu bir AR (1) modelidir; AR (2), AR (3) vb. de olabilir. Bir AR modeli doğrusal veya doğrusal olmayan olabilmektedir (Wang, 2008: 19).

Bazı zaman serilerinde, sadece hareketli ortalamalarla veya oto regresyonla modelleme yapılamaz. Bununla birlikte, karma model olarak isimlendirilen ve kısaltması ARMA (p, q) olan bir model bulunmaktadır. Söz konusu modelde (p) regresyon sırasını, (q) HO sırasını gösterirken (p, q) ise sıralamayı göstermektedir (Omarbl, 2017: 23).

George Box ve Gwilym Jenkins zaman serisi modellemesi için istatistiksel bir yaklaşım geliştirmiştir. Bu yaklaşım temelinde geliştirilen zaman serisi modelleri Box-Jenkins modelleri olarak adlandırılmaktadır. Aynı zamanda ARIMA modelleri olarak da

bilinmektedir. Bir zaman serisi, zaman akışı içerisinde gözlemlenebilen veri kümesi olarak açıklanabilir. ARIMA modelleri tek değişkenlidir. Tek bir zaman serisi değişkenine dayanırlar. ARIMA, Otoregresif Entegre Hareketli Ortalama anlamına gelmektedir. "I" (Integrated) harfi, modelleme zaman serisinin durağan bir zaman serisine dönüştürüldüğünü göstermektedir. ARIMA üç farklı model türünü temsil etmektedir: Bir AR (otoregresif) modeli veya bir MA (hareketli ortalama) modeli ya da hem AR hem de MA terimlerini içeren bir ARMA olabilir (Wang, 2008: 19).

#### 1.4.2.2. Yapay Zekâ ve Gelişmiş Modeller

Yapay zekâ (YZ) terimi; zamana ve uygulamalara bağlı olarak bir dizi olası tanımı olan bulanık bir kavramdır. Akademik disiplin olarak 1956 yılında Dartmouth konferansında kurulduğu kabul edilmektedir (Moor, 2006: 87). Winston (1992: 5) tarafından yapay zekâ; akıl yürütmeyi, durumları algılayabilmeyi ve harekete geçmeyi olanaklı kılan hesaplamaların incelenmesi olarak tanımlanmıştır. Bu tanım açısından bakıldığında, yapay zekâ hesaplamaya daha fazla vurgu yapması nedeniyle psikolojinin çoğundan; algı, akıl yürütme ve eyleme vurgu yapması nedeniyle bilgisayar bilimlerinin çoğundan ayrılmaktadır.

YZ hakkında "yapay" olması gereken şey, hiç şüphesiz, özellikle biyolojik veya evrimsel doğal etkinin bir sonucu olmaktan çok, insan icadı ve yaratıcılığının bir ürünü olarak ortaya çıkmasındaki kökenleri ve yaratılış şekli ile ilgilidir. Diğer bir deyişle, yapay zekâyâ sahip olan şeyler, yapay olmayanların normalde sahip olduğu özel özelliklere sahip yapay nesnelere sahip olarak doğal zekâyâ sahip olanlardan farklıdır. Yani bunlar oluşturuldukları, tasarlandıkları veya üretildikleri için belirli bir süreç sonucunda akıl gibi belirli bir özelliğe sahip olmaktadır (Fetzer, 1990: 3). Oldukça genel bir tanım olarak; insanların ve diğer hayvanların sergilediği doğal zekanın aksine, makinelerin gösterdiği zeka olarak tanımlanabilir. Bununla birlikte daha spesifik bir tanım yapılmak istenirse; sistem tarafından belirli hedef ve görevleri gerçekleştirmek amacıyla, dış ortamlardan elde edilen verilerin doğru olarak yorumlanması, bu verileri kullanarak öğrenmenin oluşması ve bu öğrenmenin esnek bir adaptasyon yeteneği ile kullanılmasıdır (Kaplan ve Haenlein, 2019: 15).

YZ kavramı, başlangıçta makineler tarafından sergilenen insan zekasının basit teorik hali olarak algılanmaktaydı (Bini, 2018: 2359). Günümüzde hızlı teknolojik ilerlemeler ve büyük veri kümelerinde artışların yaşanması sonucunda yapay zekâ,

benzeri görülmemiş bir ölçekte salt teoriden somut uygulamaya geçiş yapmıştır (Topol, 2019: 44). Otonom sürüş arabaları, akış geçmişinden etkilenen video izleme önerileri, çevrimiçi satın alma önerileri, reklamlar ve sahtekarlık tespiti gibi toplumun birçok yönüne yapay zekâ temel olarak yerleşmiştir ve genellikle kişisel elektronik cihazlarımızın arka planında görünmez şekilde işlev görmektedir (Helm vd., 2020: 69).

#### 1.4.2.2.1. Makine öğrenmesi

Öğrenme çok yönlü bir olgudur. Öğrenme süreçleri, yeni bir bilgiye sahip olunmasını, öğrenme veya uygulama aracılığıyla bilişsel ve motor becerilerin geliştirilmesini, sahip olunan yeni bilginin genel temsiller şeklinde düzenlenmesini, gözlem yapma ve deney yoluyla yeni gerçeklerin ve teorilerin oluşturulmasını içermektedir (Carbonell vd., 1983: 69). Makine öğrenimi, öğrenme sistemlerinin resmi olarak incelenmesine adanmış bir araştırma alanıdır. Bu alan, çok çeşitli disiplinlerden (istatistik, bilgisayar bilimi, mühendislik, bilişsel bilim, optimizasyon teorisi vb. gibi) fikirler edinen ve bu fikirler üzerine yeni yaklaşımlar inşa eden oldukça disiplinler arası bir alandır (Ghahramani, 2003: 72).

Yapay zekâ araştırmalarının çok önemli buluşlarından biri, biçimsel olarak zor problemlerin geleneksel şemayı genişleterek çözülebileceği fikridir:

program = algoritma + veri

Daha ayrıntılı,

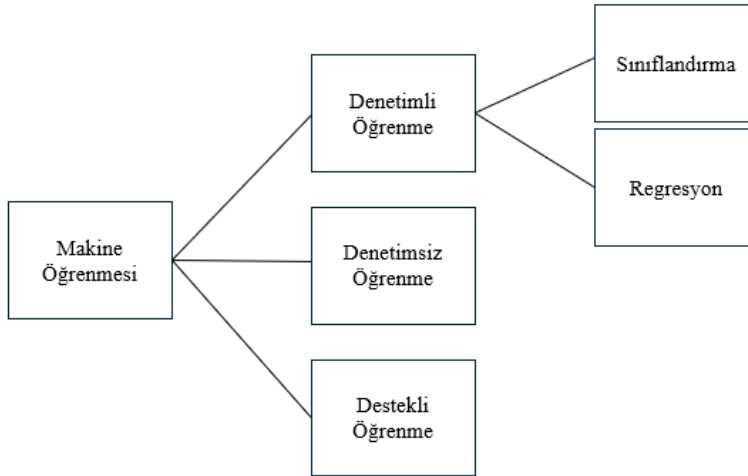
program = algoritma + veri + alan bilgisi

olarak değerlendirilmektedir. Uygun veri yapılarında kodlanmış alan bilgisini uygulamak, bu tür problemleri çözmek için temeldir. Yapay zekâ üzerine çalışmış olan herkes uzman sistemlerde üretim kurallarının, çerçevelerin, anlamsal ağların ve belirsizlik yayılımının gücünü bilmektedir. Makine öğrenmesi sistemleri de bu fikirden yararlanmaktadır (Kubat vd., 1998: 1-2).

Makine öğrenmesi, YZ'nin bir alt dalıdır. Bu alanın temel amacı, verilerden bilgi edinmek için hesaplama yöntemlerini kullanmaktır (Hsieh, 2009: 9). Makine öğrenmesi; istatistik, bilgi teknolojisi, psikoloji, olasılık, yapay zekâ, nörobiyoloji ve diğer birçok disiplini de içeren geniş bir alanı temsil etmektedir. Makine öğrenimi ile problemler, seçilen bir veri kümesinin iyi bir temsili olan bir model oluşturularak basitçe

çözülebilir. Makine öğrenimi, bilgisayarlara insan beynini taklit etmeyi öğretmekten ileri bir alan haline gelmiş ve istatistik alanını, öğrenme süreçlerinin temel istatistiksel hesaplama teorilerini üreten geniş bir disipline getirmiştir (Nasteski, 2017: 1).

Makine öğrenimi çeşitleri genel olarak 3 ana sınıfa ayrılmaktadır. Şekil 1, makine öğreniminin genel sınıflandırmasını özetlemektedir. Makine öğrenimi genel olarak 3 farklı şekilde sınıflandırılmaktadır. Bunlar; Denetimli Öğrenme, Denetimsiz Öğrenme ve Destekli Öğrenmedir. Sınıflandırma ve regresyon grupları olarak Denetimli Öğrenmenin iki alt gruba bulunmaktadır. Denetimli öğrenme genellikle göreve dayalı bir model olup, uygulamaya bağlıdır. Denetimsiz öğrenme ise veriye dayalıdır (Sevgen ve Aliefendioğlu, 2020: 303).



**Şekil 1.** Makine Öğreniminin Genel Sınıflandırması

Kaynak: Sevgen ve Aliefendioğlu, 2020: 303

Denetimli öğrenme, bir girdiyi bir çıktıya eşleme şeklindeki bir işlevi öğrenmeye yönelik oluşturulmuş makine öğrenimi görevidir. Bu görevde, bir dizi eğitim örneğinden oluşan etiketlenmiş eğitim verilerinden bir fonksiyon çıkartılmaktadır. Bu algoritmalar, dışarıdan yardıma gereksinim duymaktadır. Girdi verileri, eğitim ve test verisi olarak ikiye ayrılmaktadır. Eğitim veri kümesinde, tahmininin yapılması ya da sınıflandırılma gerçekleştirilmesi gereken çıktı değişkeni bulunmaktadır. Bütün algoritmalar eğitim veri setinden bir çeşit örüntü öğrenmektedir. Öğrendikleri bu örüntüleri tahmin veya sınıflandırma için test veri setine uygulamaktadır (Mahesh, 2020: 381).

Denetimsiz öğrenme, sistemlerin belirli girdi modellerini, genel girdi modelleri koleksiyonunun istatistiksel yapısını yansıtacak şekilde temsil etmeyi nasıl öğrenebileceğini incelemektedir. Denetimli öğrenmenin aksine, her bir girdiyle ilişkili açık hedef çıktılar veya çevresel değerlendirmeler yoktur; bunun yerine denetimsiz öğrenici, girdinin hangi yönlerinin çıktıda bulunması gerektiğine olan önyargılarını ortaya koymaktadır (Dayan vd., 1999: 857). Denetimsiz öğrenme, öğrenme uğruna bir öğrenme paradigması oluşturmak için tasarlanmış bir algoritma türüdür. Denetimsiz öğrenmenin motivasyonu, denetimsiz öğrenme algoritmalarından geçen verilerin zengin bir içsel yapıya sahip olmasına rağmen, temel gerçeğin ve eğitim için kullanılan metriğin tipik olarak seyrek olmasıdır. Bu, algoritma tarafından öğrenilenlerin çoğunun, pratik bir göreve belirli bir anlayış uygulamak yerine girdi veri yapısından gelmesi gerektiği anlamına gelmektedir (Tyagi vd., 2022: 33).

Destekli öğrenme, modelin çevresi ile sahip olduğu etkileşimlere dayanarak performansını artıran bir sistem geliştirmektedir. Performans artışı bir ödül-ceza sistemine dayanmaktadır.

Destekli öğrenme yöntemlerinden popüler olanlar Q-learning, State-Action-Reward-State-Action, Deep Q Network; Denetimsiz öğrenme yöntemlerinden popüler olanlar k-Ortalamalar Algoritması, Hiyerarşik Küme Analizi, Temel Bileşen Analizi, Kernel PCA; Denetimli öğrenme yöntemlerinden popüler olanlar Doğrusal Regresyon, Polinom Regresyon, DVR, KAR, Çoklu Doğrusal Regresyon, Rastgele Orman Regresyon ve Yapay Sinir Ağlarıdır (Uğuz, 2023: 72).

#### **1.4.2.2.2. Derin öğrenme**

Hinton yapmış olduğu çalışmalar ile yapay sinir ağlarına yeni bir bakış açısı getirmiş ve bu yeni yaklaşım derin öğrenme olarak isimlendirilmiştir (Hinton vd., 2006: 1546). Derin öğrenme yöntemi, yapay sinir ağlarının üzerine kurgulanmış makine öğrenmesi sınıflandırmalarından birisidir (Deng ve Yu, 2014: 199-200). Verilerin temsillerini öğrenmek için birden fazla işleme katmanının bir araya geldiği çoklu soyutlama yapısıyla çalışmaktadır (LeCun vd., 2015: 437-438). Derin öğrenmenin mimarisinde; konvansiyonel sinir ağları, tekrarlayan sinir ağları, uzun/kısa vadeli hafıza ağları, sınırlı Boltzmann makineleri, derin inanç ağları, derin oto kodlayıcılar yer almaktadır (Şeker vd., 2017: 50-53).

İnsan beyninin çalışma prensiplerinden esinlenerek oluşturulan derin öğrenme yöntemi son yıllarda artarak devam eden popüleriteye sahip olmuştur (Toğaçar vd., 2019: 223). Derin öğrenmenin birçok kullanım avantajları mevcuttur. Birincisi, veri setlerinden otomatik olarak özellik öğrenimidir (LeCun vd., 2015: 436). İkinci olarak, büyük veri setleri ile eğitildiğinde yüksek performans sergileyebilmesidir (Krizhevsky vd., 2012: 8). Yöntemin bir diğer avantajı, genelleştirme yeteneği sayesinde daha önce görülmemiş veri örneklerini doğru bir şekilde işleyebilmesidir (Vaswani vd., 2017: 6008). Büyük veri setleri ve güçlü hesaplama kaynakları ile ölçeklenebilir olması, derin öğrenmenin kullanım avantajlarından birisidir (Szegedy vd., 2015: 1).

Derin öğrenmenin kullanım alanları incelendiği zaman; doğal dil işleme, görüntü/video işleme, biyomedikal/sinyal görüntü işleme (özellikle tıp alanında hastalıkların öngörülmesi/tahmin edilmesi), araç otonom sistemleri, multimedya yönetimi, akıllı trafik planlaması gibi alanlarda kullanılabildiği görülmektedir (Şeker vd., 2017: 53-56). Fazla alanda kullanımının tercih ediliyor olması, problemlerin çözümünde ortaya koyduğu yüksek doğruluk oranlarından ileri gelmektedir. Görüntü tanıma, ses tanıma gibi alanlarda insan performansının bile üzerine çıkabildiği görülmüştür (İnik ve Ülker, 2017: 87).

#### **1.4.2.2.3. Genetik algoritmalar**

Genetik Algoritmalar (GA), tarihte ileri sürülen ilk popülasyon tabanlı stokastik algoritmalarından biridir (Mirjalili, 2019: 43). GA, genetik rekombinasyon kavramının evrim teorisi ve bir popülasyonun en uygun üyelerinin hayatta kalması ile birleştirilmesinden türetilmektedir. Rastgele bir aday parametre kümesinden başlayarak, öğrenme süreci optimum parametrelere giderek daha iyi yaklaşımlar geliştirmektedir. GA, öncelikle bir arama ve optimizasyon tekniğidir (Haupt vd., 2008: 11)

GA, canlı organizmaların düşmanca bir dünyada yaşamın sert gerçeklerine evrim ve kalıtım vasıtasıyla uyum sağlama biçiminden ilham almaktadır. Algoritma, üreme için yalnızca uygun bireyleri seçerek popülasyonların evrim sürecini taklit eder. Bu nedenle, bir genetik algoritma doğal seleksiyon ve en uygun olanın hayatta kalması kavramlarına dayanan optimum bir arama tekniğidir. Zaman içinde gelişen, bireyler olarak adlandırılan bir problemin olası çözümlerinin sabit boyutlu bir popülasyonu ile çalışır. Bir genetik algoritma seçim, çaprazlama ve mutasyon olmak üzere üç temel genetik operatör kullanır. Nesil olarak adlandırılan üreme sürecindeki her adım

sırasında, mevcut nesildeki bireyler, bireyin problemi ne kadar iyi çözdüğünün bir ölçüsü olan bir uygunluk fonksiyonu değeri ile değerlendirilir. Uygunluk ne kadar yüksek olursa çaprazlamaya katılma ve döl üretme şansı o kadar yüksek olur. Az sayıda yeni doğan yavru, mutasyon operatörünün etkisine girer. Birçok nesilden sonra, uygunluk fonksiyonu açısından yalnızca en iyi genetiğe sahip olan bireyler hayatta kalır. Bu “en uygun olanın hayatta kalma testi” sürecinden ortaya çıkan bireyler, uygunluk fonksiyonu ve kısıtlamalar tarafından belirtilen probleme en uygun çözümü temsil eden süreçlerdir. GA, uygunluk fonksiyonunun mevcut olduğu problemlerde optimum çözümü bulmak için uygundur (Kalogirou, 2004: 397-398).

GA, doğal evrimde gözlemlenen bazı süreçleri taklit ederek geliştirilmiş uyarlamalı arama ve optimizasyon teknikleridir. Tipik bir genetik algoritma aşağıdaki adımlardan oluşmaktadır (Jadav ve Panchal, 2012: 47-49):

1. Başlangıç popülasyonu oluşturma.
2. Popülasyonda her bireyin (kromozomun) değerlendirilmesi.
  - 2.1. Çaprazlama ve mutasyon uygulayarak yeni kromozomlar oluşturma.
  - 2.2. Uygunluk fonksiyonunu kullanarak yeni üyeleri değerlendirmek ve onları popülasyona ekleme.
3. Sonlandırma koşulu sağlanana kadar ya da en uygun çözüme ulaşıncaya kadar 2. adımın tekrarlanması.
4. Çözüm olarak en iyi bireyi getirme.

#### **1.4.2.1.4. Bulanık mantık ve bulanık küme**

Zadeh (1965: 338) tarafından bulanık kümeler teorisi ortaya konulmuştur. Bulanık küme, sürekli üyelik dereceleri olan bir nesne grubudur. Bulanık kümede, her nesneye 0 ile 1 arasında değişen bir üyelik derecesi oluşturulmaktadır. Bu sayede bulanık küme, belirsizlik ve karmaşıklık içeren kavramları modellemede daha esnek ve gerçekçi bir yaklaşım sunmaktadır. Kapsama, birleşim, kesişim, tümleyen, bağıntı, dışbükeylik vb. gibi kavramlar bu tür gruplara genişletilmektedir. Söz konusu kavramların bulanık kümeler özelinde farklı özellikleri saptanmaktadır.

Veri ve bilgiye sahip istatistiksel olmayan belirsizliklerin kullanılmasında yararlanılmaktadır. Çok sayıda probleme ait kendine özgü kesinsizlikle çalışmada matematiksel olarak belirsizlik ve muğlaklığı temsil etmek ve formel yapıya

kavuşturulmuş araçlar elde etmek için özel olarak tasarlanmıştır. Sonsuz-değerli mantık fikri, L.Zadeh'in çalışması "Bulanık Kümeler"le başlamıştır. Bulanık küme teorisinin, matematiğini tanımlamıştır. Akabinde bulanık mantığın genişletilmiştir. Bu teori [0,1] gerçek sayılar aralığından işlem gerçekleştiren üyelik fonksiyonu (veya Doğru ve Yanlış değerleri) kavramını geliştirmiştir. Bulanık Mantık, temeli bilgi olan sistemlere uygulanabilir yaklaşık çıkarsama imkanına sahiptir. Bulanık küme teorisi, düşünme ve uslamlama gibi insanın bilişsel durumlarıyla birleşmiş belirsizlikleri kapsayan matematiksel güç imkanı sağlamaktadır. Bulanık mantığın temel özelliklerinden bazıları şunlardır (Kubat, 2019: 623):

- Bulanık mantıkta tam uslamlama yaklaşık çıkarsamanın sınırlı bir durumu olarak görülebilir.
- Her şey bir önem derecesine sahiptir.
- Bilgi değişkenlerin toplamı üzerinde esnek veya bulanık kısıt toplamı olarak düşünülebilir.
- Çıkarsama esnek kısıtların yayılması olarak değerlendirilebilir.
- Mantıksal sistemler bulanıklaştırılabilmektedir. Bulanık sistemlerin iki önemli özelliği özel-belirli uygulamalar için daha iyi performans vermesidir.
- Bulanık sistemler belirsiz veya yaklaşık çıkarsama için ve özellikle de matematiksel olarak modeli kurulamayan sistemler için çok uygun ortam sağlamaktadır.

#### **1.4.2.1.5. Uzman sistemler**

Uzman sistemler, bir sorun uzmanlar tarafından nasıl çözülyorsa sorunlara o şekilde bilgi ile yaklaşan ve çözüm ortaya koyan sistemlerdir (Öztemel, 2003: 13). Uzman sistem, belirli bir alanda uzmanlık düzeyinde bilgi, birikim ve deneyime sahip bir bireyin yargılamasını ve davranışını simüle eden bir bilgisayar programıdır. Uzman sistemler, birikmiş deneyimin bilgi tabanını ve her bir özel duruma uygulanan bir dizi kuralı içermektedir. Uzman sistemler, insan uzmanlığını kullanan yapay zekâ uygulamalarıdır. Uzman sistemler, kural biçiminde veri tabanında saklanan uzmanlık yardımıyla karmaşık sorunları çözmek için kullanılmaktadır. Uzman bir sistem tasarlamak için, uzman bireylerin nasıl karar verdiğini inceleyen ve kuralları bir bilgisayarın anlayabileceği terimlere çeviren bir bilgi mühendisine ihtiyaç vardır.



Uzman sistemler ayrıca bilgi tabanlı sistemler, bilgi tabanlı uzman sistemler ve kural tabanlı sistemler olarak da bilinmektedir. Uzman sistemler, "uygulamalı yapay zekâ" olarak kabul edilmektedir (Gupta ve Nagpal, 2020: 23).

Uzman sistemler, insanlar tarafından if-then ifadeleri şeklinde programlanan kural koleksiyonlarıdır. Uzman sistemler, insan zekasının kurallar aracılığı ile resmileştirilebileceğini ve dolayısıyla yukarıdan aşağıya bir yaklaşım ile (aynı zamanda sembolik veya bilgi temelli yaklaşım olarak da adlandırılır) yeniden yapılandırılabilirliğini varsaymaktadır. Bu tür sistemler örtük olan ve basit kurallara kolayca aktarılamayan karmaşık insan zekası biçimlerine bağlı görevler sırasında düşük performans gösterme eğilimindedir. Ancak bu durum uzman sistemlerin kullanışlı olmadığı anlamına gelmemektedir. 1990'ların sonlarında Garry Kasparov'u yenen IBM'in ünlü Deep Blue satranç oynama algoritması yapay zekâ değil, bir uzman sistemdi. Deep Blue gibi uzman sistemler, yapay zekâyı halk arasında daha belirgin hale getirmenin temel itici güçleri olmuştur (Kaplan ve Haenlein, 2019: 18).

### **1.5. Tahmin İle İlgili Literatür Taraması**

Talep tahmini yöntemleri kullanılarak birçok araştırma yapılmıştır. Bunlardan bazıları Ek-1'de yer almaktadır.

Çalışmada kullanılan yöntemler ikinci bölümde ayrıntılı olarak incelenecektir.

## İKİNCİ BÖLÜM

### MAKİNE ÖĞRENMESİ YÖNTEMLERİ VE PERFORMANS ÖLÇÜTLERİ

#### 2.1. Çalışmada Kullanılan Makine Öğrenmesi Yöntemleri

##### 2.1.1. Yapay Sinir Ağları

Yapay Sinir Ağları (YSA) temelde devasa paralel hesaplamalı insan beyninin işlevini taklit eden modellerdir. Bir YSA, çok sayıda basit işlemcinin ağırlıklı bağlantılarla birbirine bağlanmasını içermektedir. Analojiyle, işlem düğümleri “nöronlar” olarak isimlendirilmektedir. Her düğüm çıkışı, yalnızca düğümde yerel olarak mevcut olan ya dahili olarak depolanan ya da ağırlıklı bağlantılar yoluyla sağlanan bilgilere bağlıdır. Her birim diğer çok sayıda düğümden girdi almaktadır. Sonrasında çıktısını başka bir düğüme ulaştırmaktadır. Girdiler doğrusal olmayan basit bir fonksiyon ile sayısal tek bir çıktı üretmektedir (Dongare vd., 2012: 190).

Bir YSA'nın gücü, eğitim verilerinden ne kadar iyi genelleme yaptığına bağlıdır. Yineleme sayısı ile birlikte eğitim veri setinin boyutu ve özellikleri, bir sinir ağının genelleme yeteneklerini etkileyen diğer faktörlerdir (Kavzoglu, 1999: 676).

YSA, nöronların yapısını ve insan beyninin öğrenme yöntemlerini araştırmaktadır. 1800'lü yıllarda yaşayan psikoloji ve nöroloji ile ilgilenen araştırmacıların insan beynini anlamaya çalışmaları YSA'nın kökenlerini oluşturmaktadır. YSA, beyin nöral ağına benzer bir şekilde çalışma prensibi oluşturmuştur. Beynin bazı görevlerini gerçekleştirmek için çaba sarf eden bir sistemdir. YSA'larda en önemli odak noktası öğrenme işlevidir. YSA'nın kullanım alanlarında; görüntü ve ses tanıma, tahmin etme ve kestirimde bulunma, kontrol ve sistem tanımlama, arızaların analizi, tıp, haberleşme, trafik, üretim, haberleşme yönetimi yer almaktadır (Kubat, 2019: 623-624).


YSA, geliştirildikleri ilk yıllardan beri karmaşık problemlerin çözümünde başarıyla kullanılmaktadır. Bu ağlar, farklı bakış açıları sunarak, kısa sürede çözüme ulaşılmasını sağlar. YSA'nın tek başına veya diğer uygulamalarla entegre olarak kullanılabilmesi, bu ağları her alanda çok yönlü bir araç haline getirmiştir. YSA yönteminin yalnız uygulandığında elde edilen sonuçları ve diğer yöntemlerin uygulama sonuçlarının karşılaştırılması sonucunda, birçok alanda YSA yönteminin daha üstün performans gösterdiğini ortaya koymaktadır. Tıp, mühendislik, sağlık, savunma, ticaret

ve güvenlik gibi çeşitli alanlarda halen başarıyla uygulanan YSA, her geçen gün gelişmeye devam etmektedir. Daha iyi sonuçlar elde etmek için YSA'ya yeni yaklaşımlar getirilmekte ve bu sayede YSA'nın uygulama yelpazesi de genişlemektedir. YSA yönteminin kullanıldığı yerler hususunda herhangi bir sınırlama bulunmamaktadır. Çok çeşitli uygulama alanına açık olan YSA, bu alanlar için yeni bilgi üretme imkanına sahiptir. Problemin çözümünde matematiksel model veya algoritma bulunmayan durumlarda da YSA kullanımı oldukça yaygındır. Deneme-yanılma yoluyla kendi kendine öğrenen YSA, yeni bilgi işleme yöntemleri sayesinde bilgi üretir ve uygulanma imkanının olduğu her alanda yeni çözümler sunar. YSA yöntemi, çoğunlukla tahmin, sınıflandırma, veri filtreleme, veri ilişkilendirme, vektör sayısallaştırma, desen uygunluğu, kontrol, arama çalışmaları, tanıma-eşleştirme, optimizasyon ve yorumlama fonksiyonlarını yerine getirmek amacıyla kullanılmaktadır (Sönmez Çakır, 2019: 12-13).

#### **2.1.1.1. Yapay sinir ağlarının temel kavramları**

Yapay sinir ağları temel kavramları beyin nöronu, yapay nöron ve aktivasyon fonksiyonu olarak karşımıza çıkmaktadır.

En basit haliyle, yapay sinir ağı, insan beyninin bir taklididir. Doğal bir beyin, yeni şeyler öğrenme, yeni ve değişen çevreye uyum sağlama yeteneğine sahiptir. Beyin, eksik ve belirsiz, bulanık bilgileri analiz etme ve ondan kendi yargısını çıkarma konusunda en şaşırtıcı yeteneğe sahiptir. Beyin, nöron olarak adlandırılan hücrelerden oluşmaktadır. Söz konusu nöronların birbirine bağlanması ile sinir ağı veya beyin oluşmaktadır. İnsan beyninde yaklaşık 1011 nöron ve birbirine bağlanmış yaklaşık 10000 bağlantı mevcuttur. YSA, yapay nöronların beyin ağına benzer bir biçimde bağlandığı, doğal sinir ağının bir taklidi olarak düşünülmektedir (Kukreja vd., 2016: 27).



**Şekil 2.** İnsan Nöronu (1), Yapay Nöron (2), Biyolojik Sinaps (3), YSA Sinaps (4)

**Kaynak:** Maltarollo vd., 2013: 205; Öztürk ve Şahin, 2018: 28

Şekil 2, bir insan nöronu ile bir YSA nöronu arasındaki karşılaştırmayı göstermektedir (Maltarollo vd., 2013: 205). Biyolojik terminolojideki dendrit kavramı; YSA terminolojisinde toplama fonksiyonu ( $f(x)$ ) olarak adlandırılmaktadır. Biyolojik terminolojideki sinaps kavramı; YSA terminolojisinde bağlantı ya da ağırlıklar olarak adlandırılmaktadır. Biyolojik terminolojideki aksonlar kavramı; YSA terminolojisinde yapay nöron çıkışı olarak adlandırılmaktadır.

Bir yapay sinir ağı, nöron olarak isimlendirilen işlem birimlerinden oluşmaktadır. Yapay bir nöron, doğal nöronun yapısını ve davranışını kopyalamaya çalışmaktadır. Bir nöron, girdilerden (dendritler) ve bir çıktıdan (akson yoluyla sinaps) oluşmaktadır. Nöronun, aktivasyonu belirleyen bir işlevi vardır.  $x_1 \dots x_n$  nöronun girdileridir. Girdilerle birlikte nörona bir yanlılık (bias) da eklenmektedir. Genellikle bias değeri 1 olarak başlatılmaktadır.  $W_0 \dots W_n$  ağırlıklardır. Ağırlık, sinyale bağlantıdır. Bir nöron, bir sinir ağının çalışması için temel olan bir bilgi işleme birimidir. Şekil 3 blok şeması, YSA oluşturmanın temelinde yer alan bir nöron modelini göstermektedir. Nöronal modelin üç ana ögesi şu şekilde tanımlanmaktadır (Haykin, 1999 :32):

1. Her biri kendi ağırlığı ya da kuvveti ile karakterize edilen bir dizi sinaps veya bağlantı birbirine bağlanmaktadır. Özellikle,  $k$  nöronuna bağlı  $j$  sinapsının girdisindeki bir  $x_j$  sinyali,  $w_{kj}$  sinaptik ağırlığı ile çarpılmaktadır.  $w_{kj}$  sinaptik ağırlığının alt indislerinin yazılma şeklini not etmek önem

taşımaktadır. İlk alt simge, söz konusu nörona atıfta bulunmaktadır. İkinci alt simge, ağırlığın atıfta bulunduğu sinapsın girdi ucunu belirtmektedir. Beyindeki bir sinapstan farklı olarak, yapay bir nöronun sinaptik ağırlığı, pozitif olduğu kadar negatif değerleri de içeren bir aralıkta olabilmektedir.

2. Nöronun ilgili sinapsları tarafından ağırlıklandırılan girdi sinyallerini toplamak amacıyla bir toplayıcı oluşturulmaktadır.
3. Bir nöronun çıktısının genliğini sınırlamak amacıyla bir aktivasyon fonksiyonu belirlenmektedir. Aktivasyon fonksiyonu, çıktı sinyalinin olması gereken genlik aralığını bazı sonlu değerlerle sınırladığı için bir bastırma fonksiyonu olarak da adlandırılmaktadır. Genellikle, bir nöronun çıktısının normalleştirilmiş genlik aralığı, kapalı birim aralığı  $[0,1]$  veya alternatif olarak  $[-1,1]$  olarak yazılmaktadır.

Şekil 4'ün nöronal modeli  $b_k$  ile gösterilen harici olarak uygulanan bir yanlılık içermektedir. Yanlılık  $b_k$ , sırasıyla olumlu veya olumsuz olmasına bağlı olarak aktivasyon fonksiyonunun net girdisini artırma veya düşürme etkisine sahiptir. Matematiksel terimlerle, aşağıdaki eşitlik çiftini yazarak bir  $k$  nöronunu tanımlayabiliriz (Haykin, 1999: 33):

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (2)$$

$$y_k = \phi(u_k + b_k) \quad (3)$$

$x_1, x_2, \dots, x_m$ : Girdi sinyalleri.

$w_{k1}, w_{k2}, \dots, w_{km}$ :  $k$  nöronunun sinaptik ağırlıkları.

$u_k$ : Girdi sinyalleri nedeniyle lineer birleştirici çıktı.

$b_k$ : Bias (yanlılık).

$\phi(\cdot)$ : Aktivasyon fonksiyonu.

$y_k$ : Nöronun çıktı sinyali.

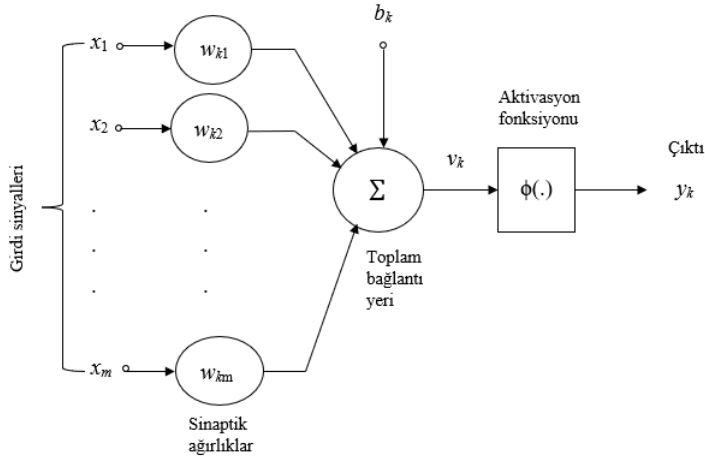
Yanlılık  $b_k$ 'nın kullanımı, Şekil 3'teki modelde doğrusal birleştiricinin  $u_k$  çıktısına bir afin dönüşüm uygulama etkisine sahiptir.

$$v_k = u_k + b_k \quad (4)$$

Eşit bir biçimde, (2)'den (4)'e kadar olan eşitliklerin kombinasyonunun formülü aşağıdaki gibidir:

$$v_k = \sum_{j=0}^m w_{kj} x_j \quad (5)$$

$$y_k = \phi(v_k) \quad (6)$$



**Şekil 3.** Bir Nöronun Doğrusal Olmayan Modeli

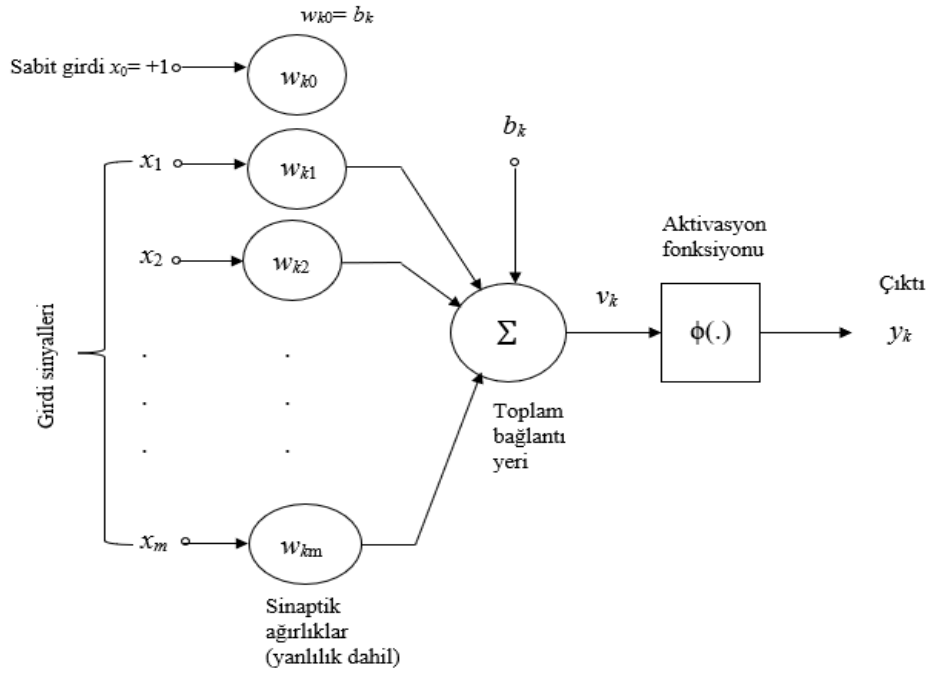
**Kaynak:** Haykin, 1999: 33

Eşitlik (5)'e yeni bir sinaps eklendiğinde girdi değişkeni (Haykin, 1999: 34),

$$x_0 = +1 \quad (7)$$

ve ağırlığı,

$$w_{k0} = b_k \quad (8)$$



**Şekil 4.** Bir Nöronun Başka Bir Doğrusal Olmayan Modeli

**Kaynak:** Haykin, 1999: 35

Söz konusu yeni bir sinaps eklendiğinde, nöron  $k$  modeli Şekil 4 'teki gibi yeniden formüle edilebilmektedir. Şekil 3 ve Şekil 4 modelleri görünüş olarak farklı olmasına rağmen, matematiksel olarak eşdeğerdirler (Haykin, 1999: 34).

Aktivasyon fonksiyonu  $z_i = f(x, w_i)$  bir nöronun  $w_i$  ağırlıklarını  $x$  girişine bağlar ve nöronun aktivasyonunu veya durumunu belirlemektedir (Debes, 2005: 2). Aktivasyon Fonksiyonları temel olarak yapay bir nöronun çıkışı ve diğer yapay nörona sinyal gönderen transfer fonksiyonudur. Adım, Parçalı Doğrusal, Sigmoid, Gaussian ve Doğrusal (Purelin) olmak üzere beş Aktivasyon Fonksiyonu formu vardır (Beale vd., 1992: 158-159; Jain vd., 1996: 34).

### 2.1.1.2. Yapay sinir ağlarının ana yapıları

Bir yapay sinir ağı, üç katmana ayrılmaktadır (Da Silva vd., 2017: 21-22):

**Girdi Katmanı:** Dış ortamdan bilgi (veri), sinyal, özellik ya da ölçüm almaktadır. Söz konusu girdiler, aktivasyon fonksiyonu tarafından üretilen sınır değerler içerisinde normalleştirilmektedir. Söz konusu normalleştirme, ağı gerçekleştirdiği matematiksel işlemler için daha iyi sayısal keskinlik sağlama konusunda önem arz etmektedir.


*Gizli katmanlar:* Analizi gerçekleştirilen süreç ya da sistemle ilişkili olan kalıpları çıkarmaktan sorumlu nöronlardan meydana gelmektedir. Söz konusu katmanlar, çok sayıda dahili işlemleri bir ağdan gerçekleştirmektedir.

*Çıktı Katmanı:* Önceki katmanlardaki nöronların yaptıkları işlemlerden kaynaklanan, nihai ağ çıktılarının üretildiği katmandır.

### 2.1.1.2.1. Tek katmanlı ileri beslemeli ağlar

İleri beslemeli ağlar katmanlar halinde düzenlenmiş birkaç nörondan oluşmaktadır. Bir katmandaki her nöron, bir önceki katmandaki tüm nöronlarla bağlantılıdır. Söz konusu bağlantıların hepsinin eşit olmamasıyla birlikte; her bağlantı farklı bir ağırlıkta olabilmektedir. Kaynak düğümlerinin bir girdi katmanından ve kaynak düğümlerinin doğrudan nöronların çıktı katmanına yansıtıldığı bir çıktı nöron katmanından oluşur. Tek katmanlı ifadesi, sinir ağının yalnızca bir katmanı olduğu anlamına gelir (Zhang, 2018: 1-2).

Tek Katmanlı İleri Beslemeli YSA, yalnızca bir girdi ve çıktı katmanı olan tek bir sinir katmanından oluşmaktadır. Girdiler ve çıktılarından oluşan basit katmanlı bir ileri beslemeli ağ, Şekil 5'te yer almaktadır.



**Şekil 5.** Tek Katmanlı İleri Beslemeli Ağ

**Kaynak:** Da Silva vd., 2017: 22


Bilgi, her daim girdi katmanından çıktı katmanına tek bir yönde ilerlemektedir. Şekil 5'te görüldüğü üzere, bu tip ağlarda, ağ çıktılarının sayısı her daim nöron sayısı ile örtüşecektir. Söz konusu ağlar çoğunlukla model sınıflandırma ve doğrusal filtreleme problemlerinde uygulanmaktadır. Eğitim süreçlerinde sırasıyla Hebb kuralına ve Delta kuralına dayanan Perceptron ve ADALINE öğrenme algoritmaları kullanılmaktadır (Da Silva vd., 2017: 22).



### 2.1.1.2.2. Çok katmanlı ileri beslemeli ağlar

Çok katmanlı bir ileri beslemeli ağ, kaynak düğümlerin bir girdi katmanından, bir veya daha fazla gizli katmandan ve bir çıktı nöron katmanından oluşmaktadır. Şekil 6'da tek bir gizli katmanı olan ileri beslemeli ağ örneği gösterilmektedir (Zhang, 2018: 2)

Girdi katmanında hesaplama için nöronlar bulunmamaktadır. Yalnızca, birinci ara katmandaki nöronları beslemek için girdiler bulunmaktadır. Birinci ara katmanı, ikinci ve diğer ara katmanlar takip etmektedir. En son katman, çıktı katmanıdır. Girdi ile çıktı arasındaki katmanlar ara katmanlar olarak ifade edilmektedir. Aynı katman içinde düğümler arasında bir bağlantı kurulmamaktadır. Çok sayıda ara katmanın olması, eğitilmiş ağın karmaşıklığını artırmaktadır. Bir ya da iki ara katmanlı ağlarda doğruluk, sağlamlık ve genelleştirme çoğu durumda sağlanmaktadır (Kılıç vd., 2012: 695). Doğrusal olmayan problemlerin çözümünde tek katmanlı modeller başarısız olunca; Çok Katmanlı Algılayıcılar geliştirilmiştir. Girdi, bir veya daha fazla gizli ve bir çıktı katmanlarından meydana gelmektedir. ÇKA'da katmanlar arası ileri ve geri yayılım olarak adlandırılan geçişler mevcuttur. İleri yayılım evresinde, ağın çıktısı ve hata değeri hesaplanmaktadır. Geri yayılım evresinde ise hesaplanan hata değerinin minimize edilmesi için katmanlar arası bağlantı ağırlık değerleri güncellenmektedir. ÇKA modeli doğrusal algılayıcıdaki en küçük kareler algoritmasının geliştirilmesi olan geri yayılım öğrenme algoritmasını kullanmaktadır (Arı ve Berberler, 2017: 59).



**Şekil 6.** Tek Bir Gizli Katmanı Olan Çok Katmanlı İleri Beslemeli Ağ (3-3-2 Ağ)

**Kaynak:** Zhang, 2018: 3

Şekil 6'da tek bir gizli katmanı olan çok katmanlı ileri beslemeli ağ örneği yer almaktadır.

Çok katmanlı ileri beslemeli ağların, eğitim süreçlerinde kullanılan öğrenme algoritmaları sırasıyla genelleştirilmiş delta kuralına ve rekabet/delta kuralına dayanan Çok Katmanlı Algılayıcı ve Radyal Temel İşlevidir (Da Silva vd., 2017: 23). Çok Katmanlı YSA'nda çok sayıda katman mevcuttur. Çok Katmanlı Yapay Sinir Ağlarında sinirler ayrı paralel katmanlarda yer almaktadır. Ağda ayrı katmanlara bağlantı olduğu için, girdi ve çıktı arasındaki doğrusal olmayan eşleme daha karmaşık olabilmektedir.

### **2.1.1.2.3. Tekrarlayan veya geri beslemeli ağlar**

Tekrarlayan bir sinir ağı, en az bir geri besleme döngüsüne sahip olduğundan dolayı, ileri beslemeli bir sinir ağından ayrılmaktadır (Haykin, 1999: 45). Söz konusu ağlarda nöronların çıktıları diğer nöronlar için geri besleme girdileri olarak kullanılmaktadır. Geri bildirim sayesinde, dinamik bir biçimde bilgi işleme süreci sağlanmaktadır. Böylece zaman serisi tahmini, sistem tanımlama ve optimizasyon, süreç kontrolü vb. gibi zamanla değişen sistemlerde kullanılmaktadır. Temel geri besleme ağları arasında, eğitim süreçlerinde kullanılan öğrenme algoritmaları sırasıyla enerji fonksiyonu minimizasyonu ve genelleştirilmiş delta kuralına dayanan, farklı katmanlardan nöronlar arasındaki geri beslemeli Hopfield ve Perceptron bulunmaktadır (Da Silva vd., 2017: 24)

### **2.1.2. Çoklu Doğrusal Regresyon**

Çoklu doğrusal regresyon, çok sayıda bağımsız tahmin edici değişkeninin, bağımlı sonuç değişkenini tahmin etme sürecidir. Bağımlı ve bağımsız değişkenler sürekli, ikili ya da çoklu çeşitli şekillerde olabilmektedir. Bağımlı değişkenin ölçüm düzeyi tipik olarak çoklu regresyon tekniğini tanımlamak için kullanılmaktadır. Örneğin, lojistik regresyonda bağımlı değişken ikilidir; Çoklu Doğrusal Regresyonda ise bağımlı değişken sürekli (Vesey vd., 2011: 15).

Çoklu doğrusal regresyon, bağımlı değişken ile birden fazla bağımsız değişken arasındaki en iyi ilişkiyi tahmin etmek amacıyla uygulanabilen ve makine öğrenmesi kapsamında kullanılan bir regresyon modelidir. Çoklu doğrusal regresyon modeli, Eşitlik 9'daki fonksiyon ile ifade edilebilir. Eşitlikte  $n$  tane olmak üzere,  $x$  değerleri bağımsız değişkenleri ifade etmektedir.  $\epsilon$  ise hata terimidir. Hata teriminin sıfır ortalamalı ve normal dağılıma sahip olduğu varsayılmaktadır.  $Q_n$  ağırlık değerleridir (Uğuz, 2023: 125).

$$y = h_Q(x) = Q_0 + Q_1x_1 + Q_2x_2 + \dots + Q_nx_n + \varepsilon \quad (9)$$

Bir regresyon modeli, Y bir bağımlı değişken ve  $x_1, x_2, \dots, x_p$  açıklayıcı bağımsız değişkenlerden oluşmaktadır. Model,  $x_1, x_2, \dots, x_p$  değerleri verildiğinde Y değişkeninin beklenen değerini tahmin etmektedir. Eşitlik 10'da standart çoklu doğrusal regresyon, koşullu beklenti ile doğrusal bir form halinde yer almaktadır. Model, tahmini genellikle en küçük kareler yöntemiyle elde etmektedir (Şenel vd., 2014: 219).

$$E(Y|X_1, X_2, \dots, X_p) = \beta_0 + \beta_1X_1 + \beta_2X_2 + \dots + \beta_pX_p \quad (10)$$

Çoklu doğrusal regresyon; iki veya daha fazla bağımsız değişkenin bağımlı değişkendeki değişimi açıklamasında kullanılmaktadır. Doğrusal bir ilişki saptansa da; nedensel bir durumun mevcut olduğu hususunda kesin olarak emin olunamamaktadır (Kılıç, 2013: 91). Çoklu doğrusal regresyon, basit doğrusal regresyonun birden fazla açıklayıcı değişken içerecek şekilde genişletilmiş halidir. Her iki durumda da 'doğrusal' terimi kullanılmaya devam edilmektedir. Bağımlı değişkenin, açıklayıcı değişkenlerin doğrusal bir kombinasyonu ile doğrudan ilişkili olduğu varsayılmaktadır (Tranmer vd., 2020: 10). Araştırmacı ilgilenilen sonucun birden fazla açıklayıcı değişkenle ilişkili olabileceğinden veya bunlara bağlı olabileceğini düşünüyorsa, basit doğrusal regresyon kullanan yaklaşım uygun olmayabilir. Birden fazla açıklayıcı değişkenin aynı anda eşitlikte yer almasını sağlayan bir çoklu regresyon modeli kullanılabilir (Marill, 2004: 94).

Basit doğrusal regresyon modeli, verilere en iyi uyan düz çizgiyi bulmak için kullanılmaktadır. Öte yandan, örneğin iki bağımsız değişkenli çoklu doğrusal regresyon modeli, verilere en iyi uyan düzlemi bulmak için kullanılmaktadır. İki'den fazla bağımsız değişken içeren modeller yapı olarak daha karmaşıktır. Ancak yine de çoklu doğrusal regresyon teknikleri kullanılarak analiz edilebilmektedir. Çoklu doğrusal regresyon analizinde, regresyon katsayılarını tahmin etmek için en küçük kareler yöntemi kullanılmaktadır. Regresyon katsayıları, her bir bağımsız değişkenin bağımlı değişkeni tahmin etmeye yönelik ilişkisiz katkılarına göstermektedir. Basit doğrusal regresyondan farklı olarak, bağımsız değişkenlerin her biri arasındaki etkileşim veya korelasyon derecesi hakkında çıkarımlar yapılmalıdır (Brown, 2009: 1).

Basit doğrusal regresyon analizinde, bir bağımlı değişken ile bir bağımsız değişken arasındaki ilişkinin incelenmesi yapılırken, çoklu doğrusal regresyon analizinde bir bağımlı değişken ile birden fazla bağımsız değişken arasındaki ilişkinin incelenmesi

yapılabilmektedir. Bu analizi kullanan arařtırmacılar temelde iki faktör üzerinde bu analizi kullanmayı tercih etmektedir. Bunlar birincisi bu analiz ile bağımlı deęiřkeni etkilediđi öngörülen deęiřkenler aracılıđı ile bağımlı deęiřkenin deęerini tahmin edilebilmektedir. Arařtırmacıları bu analizi kullanmaya iten ikinci faktör ise, bu analiz ile bağımlı deęiřkeni etkilediđi düşünölen bağımsız deęiřkenlerden hangisinin/hangilerinin bağımlı deęiřken üzerinde daha etkili olduđunun ortaya koyulabilmesi ve deęiřkenler arasındaki iliřkinin tanımlanabilmesidir (Alpar, 2003: 408).

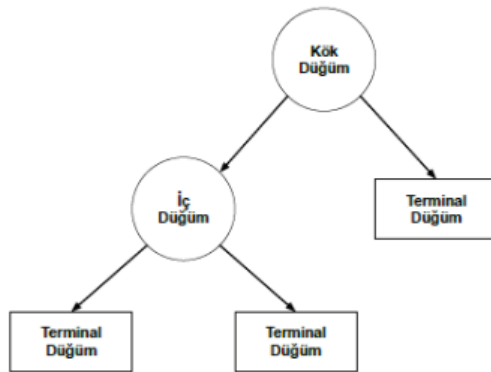
Çoklu doğrusal regresyon yönteminde, bazı varsayımlar üzerinden model oluşturulmaktadır. Bu varsayımlar doğrusallık, çoklu bağlantı, otokorelasyon, hataların normal dağılımı ve eş varyans olarak sıralanabilir. İlk varsayım, bağımlı deęiřken ile bağımsız deęiřkenler arasında doğrusal bir iliřki olması gerekliliđidir. İkinci varsayım, iki veya daha fazla bağımsız deęiřkenin birbiriyle korelasyon içinde olması çoklu bağlantı oluşmasına neden olmaktadır. Bu durumda, katsayıların standart hatası artmaktadır. Bu artış bazı bağımsız deęiřkenlerin istatistiksel olarak anlamlı olması gerekirken anlamsız olarak deęerlendirilmelerine neden olmaktadır. Üçüncü varsayım, çoklu doğrusal regresyon modelindeki hata terimlerinin birbiriyle iliřkili olması, otokorelasyon oluşmasına neden olabilmektedir. Bir diđer varsayım, hataların normal dağılıma uygun olması gerekliliđidir. Son varsayım, eş varyanstır. Hata teriminin bağımsız deęiřkenlerin tümünde aynı olma durumudur (Uđuz, 2023: 125-128).

### **2.1.3. Karar Ađacı Regresyon**

Karar ađacı, seřimleri ve sonuçlarını bir ađaç biçiminde gösteren bir grafikdir. Grafikteki, düđümler bir olayı veya seřimi, grafiđin kenarları karar kurallarını ya da kořulları temsil etmektedir. Her ađaç düđümlerden ve dallardan oluşmaktadır. Her düđüm sınıflandırılacak bir gruptaki nitelikleri, her dal ise düđümün alabileceđi bir deęeri göstermektedir (Mahesh, 2020: 382). Ađaç yapısı, kök düđümün en önemli bağımsız deęiřken olduđunu gösterirken, alt dallar bunun diđer bağımsız deęiřkenler olduđunu göstermektedir (Gacar ve Kocakoç, 2020: 254).

Karar Ađacı Regresyon analizi, tahmin modeli olarak kullanılan bir karar ađacına dayanmaktadır. Ađaç, kaynak kümenin bir öznitelik deęer testi temelinde alt kümelere ayrılmasıyla elde edilmektedir. İşlem, türetilen her bir alt küme üzerinde öz yinelemeli olarak tekrar edilmektedir. Bir düđümdeki alt grup hedef deęiřkenin tümü

aynı değerlere sahip olduğunda ya da bölme işlemi artık tahminlerin sonuçlarını iyileştirmediğinde bir sonuca ulaşılmaktadır. Karar Ağacı Regresyon, Karar Ağaçlarının gerçek değerli fonksiyonlara yaklaşmak için geliştirilmiş bir çeşiddir. Bir kez daha amaç, birkaç girdi değişkeni verildiğinde bir hedef değişkenin değerini tahmin edebilecek bir model geliştirmektir. Bu modelde, tüm girdi alanı öz yinelemeli olarak alt alanlara bölünürken, her birinde tahminler yapmak için çok değişkenli bir doğrusal regresyon modeli kullanılmaktadır. Ağaç, bir kök düğüm (tüm verileri içeren), bir dizi iç düğüm (bölünmeler) ve bir dizi terminal düğümden (yapraklar) oluşmaktadır. Regresyon Ağaçları oluşturma süreci, verileri bölümlere veya dallara ayıran yinelemeli bir süreçten oluşmaktadır. Başlangıçta, eğitim setindeki tüm veriler tek bir bölümde gruplandırılmaktadır. Algoritma daha sonra her alanda mümkün olan her ikili bölünmeyi kullanarak verileri ilk iki dala ayırmaya başlar. Daha sonra, yöntem her bir dalda ilerledikçe prosedür her bir bölümü daha küçük gruplara ayırmaya devam etmektedir. Her aşamada algoritma, iki ayrı bölümdeki ortalamadan karesel sapmaların toplamını en aza indiren bölünmeyi seçmektedir. İşlem, her bir düğüm kullanıcı tarafından belirlenen minimum düğüm boyutuna ulaşp bir terminal düğüm haline gelene kadar tekrarlanmaktadır. Bir düğümden ortalamadan karesel sapmaların toplamı sıfıra eğilim gösteriyorsa, minimum boyuta ulaşılmamış olsa bile terminal düğüm olarak kabul edilmektedir (Granata vd., 2017: 3-6). Şekil 7’de karar ağacı yapısı verilmiştir.



**Şekil 7.** Karar Ağacı Yapısı

**Kaynak:** Doğruel ve Fırat, 2021: 475.

Şekil 7’de görüldüğü üzere, karar ağaçları düğümler ve uçlardan meydana gelmektedir. Hiyerarşik ve yönlü bir yapıya sahiptir. Yaprak olmayan bir düğüm iç veya bölünmüş düğüm olarak isimlendirilmektedir. Yaprak düğüme ise terminal düğüm de denilmektedir (Doğruel ve Fırat, 2021: 475).

Karar ağacı, regresyon analizi gerçekleştirmek ya da bir sınıflandırıcı ortaya çıkarmak için kullanılan ağaç biçiminde bir veri yapısıdır. Quinlan tarafından ortaya atılan ID3 algoritması karar ağaçlarının temelini meydana getirmektedir. Bu algoritmadaki bilgi kazanımı hesabı standart sapma ile değiştirilerek yöntem regresyon analizi için uygulanabilmektedir. Eşitlik 11’de bir özellik için standart sapma formülü yer almaktadır. Eşitlik 12’de iki özellik için standart sapma formülü gösterilmektedir. Eşitlik 13’te standart sapma indirgemesi yer almaktadır. Eşitliklerde yer alan  $\mu$  değişkeni özeliğe ait ortalamayı,  $n$  özelliğe yer alan veri sayısını ve  $c$  değişkeni ilgili özelliğin alabileceği farklı değerleri göstermektedir. Ağaç kurulurken ilk adım sınıf etiketi için Eşitlik 11’de gösterildiği gibi standart sapma değeri hesaplanmaktadır. Ardından veri kümesinde mevcut olan her özellik için, sınıf etiketiyle birlikte Eşitlik 12’de gösterildiği gibi ikili standart sapma hesabı yapılmaktadır. Birinci adımda elde edilen standart sapma değerinden her bir özellik için ikinci adımda hesaplanan standart sapma değeri çıkartılarak her özellik için Eşitlik 13’te gösterildiği gibi standart sapma indirgemesi elde edilmektedir. En büyük standart sapma indirgemesine sahip özellik karar düğümü olarak seçilmektedir. Seçilen özelliğin bölümlene değerlerine göre alt dallara ait veri kümeleri elde edilmektedir. Tüm yapraklar elde edilene kadar, ilk işleme dönerek öz yinelemeli olarak devam etmektedir. (Gülağız ve Ekinçi, 2017: 204).

$$S = \sqrt{\frac{\sum(x-\mu)^2}{n}} \quad (11)$$

$$S(T, X) = \sum_{c \in X} P(c)S(c) \quad (12)$$

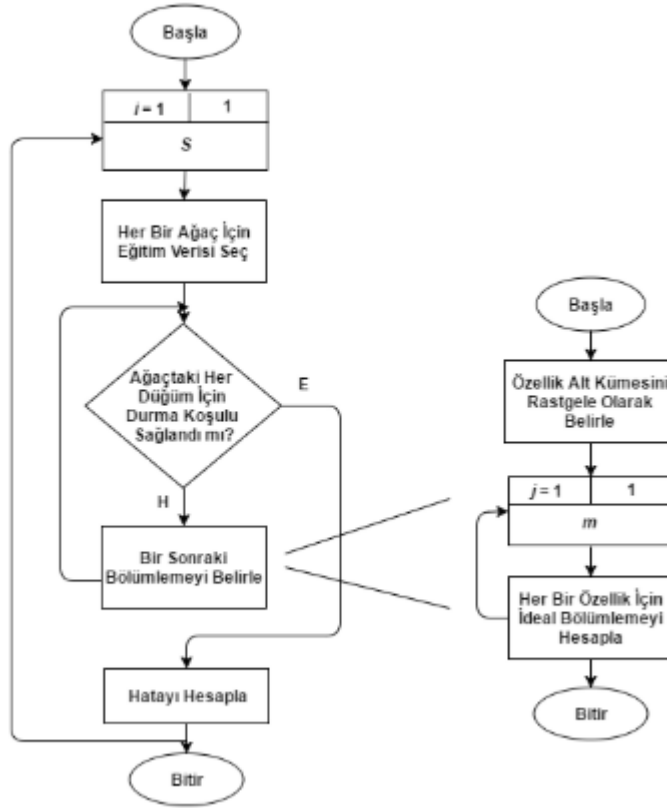
$$SDR(T, X) = S(T) - S(T, X) \quad (13)$$

Regresyon ağaçları, regresyon görevine uyarlanmış karar ağaçlarıdır. Regresyon ağaçları yapraklarda sınıf etiketleri yerine sayısal hedef nitelik değerlerini depolamaktadır. Uygun şekilde değiştirilmiş bölme seçimi ve durdurma kriterleri kullanılmaktadır. Regresyon ağacı modellerinin oluşturulması ve kullanılması regresyon ağacı büyütme, regresyon ağacı budama, regresyon ağacı tahmini olmak üzere üç ana algoritmik alt görev içermektedir (Parziale vd., 2016: 193).

#### 2.1.4. Rastgele Orman Regresyon

Rastgele ormanlar, her bir ağacın bağımsız olarak ve ormandaki tüm ağaçlar için aynı dağılımla örneklenen rastgele bir vektörün değerlerine bağlı olacağı şekilde ağaç tahmincilerinin bir kombinasyonudur (Breiman, 2001: 5). Rastgele orman

algoritmasının ana fikri, ormandaki ağaçlar arasında yüksek çeşitliliğe sahip (dolayısıyla varyansı azaltan) yüksek performanslı karar ağaçlarından (nispeten düşük yanlılık) oluşan bir topluluğu eğitmeyi amaçlamaktadır (Do, 2015: 34).



**Şekil 8. Rastgele Orman Algoritması**

**Kaynak:** Gülağız ve Ekinci, 2017: 205

Şekil 8’de Rastgele Orman algoritmasının akış diyagramı yer almaktadır. “ $m$ ”, ağacın her bir düğümünde karar almak için kullanılacak değişkenlerin sayısıdır (Gülağız ve Ekinci, 2017: 205). Rastgele Orman, birden fazla karar ağacının üretilmesi sonucu ortaya çıkmaktadır. Dolayısıyla “orman” olarak adlandırılmaktadır. Rastgele Orman algoritmasında kullanıcıya ağaç sayısı ( $N$ ) ve her bir düğümde kullanılacak değişken sayısı ( $m$ ) sorulmaktadır. Her ağaç, eğitim verilerinden rastgele seçilen değişkenlerle oluşturulmaktadır. Algoritmanın “rastgele” olarak adlandırılmasının nedeni budur.  $N$  ağacın en altında Rastgele Orman algoritması ile sonuçlar elde edilmektedir. Sonra veriye ait değişkenlerin ağırlıkları alınarak sonuç hesaplanmaktadır. ROR’da, sonuç her ağaçtan ortalama sonuçlar alınarak, elde edilecektir. Sonrasında, Rastgele Orman modeli verilerin geri kalanı için sonuçları elde etmek amacıyla kullanılmaktadır. Rastgele

Orman algoritmasının ilk adımı, denetimli öğrenmede olduğu gibi eğitim verilerinin oluşturulmasıdır. Modelin hesaplanması için Rastgele Orman eğitim verileri ve geri kalan test verilerinin sonuçları bu model kullanılarak elde edilmektedir. Öğrenme adından da anlaşılacağı gibi, makineye öğretmektedir. Bir başka deyişle, sistemin öğrenmesini sağlama sürecidir. Bu süreçte eğitim verisi, algoritmaya sunulan veriler ve algoritmanın modeli oluşturması için bu verilerin değişkenleridir. Test verileri, modelde eğitim verisi olarak kullanılmayan verilerdir. Test verileri kullanılarak algoritmadan elde edilen sonuçların kalitesi kontrol edilmektedir. Daha sonra, eğitim verilerinin dışında kalan test verileri Rastgele Orman algoritmasının modeline yerleştirilerek her ağaçtan elde edilen sonuçlar incelenmektedir (Sevgen ve Aliefendioğlu, 2020: 304).

Rastgele orman regresyonu, makine öğrenimi tabanlı bir regresyon yöntemidir. Temelinde torbalama ve rastgele alt uzay yöntemleri yatmaktadır. Torbalama kullanılarak bir dizi öğrenen ağaç oluşturulmaktadır. Bu ağaçlar daha sonra genel tahmini elde etmek için bir araya getirilmektedir. Öğrenen ağaçları eğitmek için orijinal eğitim verilerinden bir dizi bağımsız önyükleme örneği oluşturulmaktadır. Her bir önyükleme örneği ( $D_b$ ),  $N$  örnek içeren orijinal eğitim verisi  $D$ 'den  $n$  örnek çekilerek oluşturulmaktadır. Önyükleme örnekleri oluşturulurken örneklerin değiştirilmesine izin verilmektedir. Genel olarak  $D_b$ ,  $D$ 'nin  $2/3$ 'ü olabilir ve yinelenen örnekler içermez. Girdi vektörü  $x$  olan önyükleme örnekleri için  $K$  sayıda bağımsız regresyon ağacı oluşturulmaktadır. Regresyon ağaçları düşük yanlılık ve yüksek varyans ile karakterize edilmektedir. Regresyon görevlerinde, rastgele orman tahminini elde etmek için  $K$  regresyon ağacının ortalama tahmini  $h_k(x)$  hesaplanmaktadır. Torbalama, rastgele orman regresyon modelindeki varyansın azaltılmasından ve aşırı uyumun önlenmesinden sorumludur. Eşitlik 14'te Rastgele Orman Regresyon Tahmini formülü yer almaktadır (Jain vd., 2021: 5):

$$\text{Rastgele Orman Regresyon Tahmini} = \frac{1}{K} \sum_{k=1}^K h_k(x) \quad (14)$$

Rastgele orman, bir fark dışında torbalama yöntemine benzemektedir. Torbalamada her örnek için tüm değişkenler/sütunlar seçilirken, rastgele ormanda birkaç alt sütun seçilmektedir. Tüm değişkenlerin yerine birkaçının seçilmesinin sebebi, örneklenen her bağımsız ağaç sırasında, önemli değişkenlerin her zaman bölmenin en üst katmanında ilk sırada yer almasıdır. Bu durum, tüm ağaçların daha fazla ya da daha az benzer görünmesine neden olmaktadır. Rastgele orman yöntemi, korelasyonlu



bireysel modeller yerine; çeşitlendirilmiş ve bağımsız bireysel modellerde daha iyi çalışmaktadır. Rastgele orman düşük yanlılık ve varyans hatalarına sahiptir (Dangeti, 2017: 52).

## **2.2. Model Performans Değerlendirme Ölçütleri**

Tahmin edici modeller karşılaştırılırken, makine öğrenmesi yöntemlerinin performans değerlendirmelerinde temel performans ölçütleri kullanılmaktadır. Bu ölçütler yardımıyla, en uygun yöntemin belirlenmesi sağlanmaktadır (Gültepe, 2019: 12).

Çalışmada kullanılan modellerin doğrulaması için, mevcut makine öğrenmesi algoritmalarının model performansının değerlendirilmesini içeren k katlamalı çapraz doğrulama yöntemi kullanılmıştır. Ayrıca çalışmada kullanılan yöntemleri değerlendirmede kullanılan temel performans ölçütleri Hata Kareler Ortalamasının Karekökü, Belirleme Katsayısı, Hatanın Mutlak Ortalaması, Ortalama Mutlak Yüzde Hata, Hata Kareler Ortalamasıdır.

### **2.2.1. K Katlamalı Çapraz Doğrulama**

Çapraz doğrulama genellikle makine öğrenimi görevinin tahmin olduğu ve bir tahmin modelinin eğitimde ne kadar doğru performans göstereceğinin değerlendirilmek istendiği durumlarda kullanılmaktadır. Çapraz doğrulamanın amacı, modelin tahmin edilmesinde kullanılmayan yeni verilerin tahmin yeteneğini değerlendirmek, seçim yanlılığı veya aşırı uyum gibi sorunların önüne geçmektir. K katlamalı çapraz doğrulama, makine öğrenmesinde optimal modeli ölçmede en çok kullanılan tekniklerden biridir. K değerini artırarak veya azaltarak her zaman daha doğru bir sonuç elde etmenin beklenemeyeceğini yaptıkları çalışma sonucunda ortaya koymuşlardır. Bazı durumlarda, k değerindeki artış doğruluğu iyileştirirken, bazen de yalnızca hesaplama karmaşıklığını artıracığı vurgulanmıştır (Nti vd., 2021: 61-69). K katlamalı çapraz doğrulama algoritması, makine öğrenimi algoritmalarını değerlendirmek ve karşılaştırmak için aktif olarak kullanılmaktadır (Kovalerchuk, 2020: 517).

K katlamalı çapraz doğrulama prosedüründe, orijinal örnek aynı boyuta göre rastgele k alt örneğe ayrılmaktadır. Alt örnekler bir test üyesi ve eğitim üyeleri için sınıflandırılmaktadır. Doğrulama veri seti olarak test seti bilinmeyen bir veri setini, eğitim setleri ise bilinen veri setlerini temsil etmektedir. Ardından, model eğitim setleri

üzerinde analiz yapar ve test seti üzerinde analizi doğrular. Çapraz doğrulama işlemi, farklı setler için sonuçların ortalama değerinden model çıktısının tek bir tahminini elde etmek için  $k$  kez tekrarlanmaktadır (Jung vd., 2020: 7).  $K$  katlamalı çapraz doğrulama,  $K$  yinelemesini içermektedir. Her birinde bölümlerden biri test seti olarak kullanılmaktadır. Geri kalan veriler eğitim için kullanılmaktadır. Genel tahmin hatası yinelemelerin ortalama test hatasıdır (Ghojogh ve Crowley, 2019: 7).

Literatürde aşırı uyumdan kaçınmak, modelin daha önceden görmediği veri seti üzerinde nasıl performans gösterdiğini anlamak ve verilerdeki hataları minimum düzeye indirmek için doğruluk analizi olarak  $k$  katlamalı çapraz doğrulama tekniği kullanan bazı çalışmalar mevcuttur (Von Neumann, 2016; Srinivasan vd., 2019; Özmaden ve Erdal, 2020; Üstüner vd., 2020; Yavuz ve Çilengiroğlu, 2020; Kernbach ve Staartjes, 2022; Dikici ve Altuntaş, 2023; Yates vd., 2023).

### 2.2.2. Hata Kareler Ortalaması

Hata kareler ortalaması (MSE), model değerlendirmesinde tahmin edilen ile gerçek değer arasındaki yakınlığı ortaya koyan bir ölçüttür (Özden ve Öztürk, 2018: 258). MSE, formülünde  $X_i$ , tahmin edilen  $i$ ' inci değerdir.  $Y_i$  elemanı gerçek  $i$ ' inci değerdir. Gözlem sayısı  $m$ 'dir. Eşitlik 15'te formül yer almaktadır (Chicco vd., 2021: 4):

$$MSE = \frac{1}{m} \sum_{i=1}^m (X_i - Y_i)^2 \quad (15)$$

Hata Kareler Ortalamasının, 0'a yakın bir değer alması iyi olarak değerlendirilmektedir. Hata Kareler Ortalaması değeri sıfır olursa hata olmadığı anlamına gelmektedir (Al-Shayea, 2011: 152).

### 2.2.3. Hata Kareler Ortalamasının Karekökü

Hata Kareler Ortalamasının Karekökü (RMSE), hata kareler ortalamasının (MSE) kareköküdür. Hata Kareler Ortalamasının Karekökü hesaplanırken  $n$  gözlem  $y$  ( $y_i, i= 1,2,\dots,n$ ) ve  $n$  karşılık gelen  $\hat{y}$  model tahminlerinden oluşan bir örnek için, RMSE şöyledir (Hodson, 2022: 5481):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (16)$$

RMSE, modelin veriye uyumunun nasıl olduğunu gösteren bir ölçüttür. Düşük RMSE değeri, modelin iyi olduğu anlamına gelmektedir (Polat ve Günay, 2009: 441).

#### 2.2.4. Belirleme Katsayısı

Belirleme Katsayısı, model uyumunun bir ölçüsüdür. Model tarafından açıklanan varyans yüzdesidir (Tranmer vd., 2020: 59).

Belirleme katsayısı, bağımlı değişkendeki toplam değişkenliğin bağımsız değişken ya da değişkenlerdeki regresyon eşitliği tarafından açıklanan oranıdır.  $R^2$  için 1 değeri, uygun regresyon eşitliğinin örnek verilerdeki bağımlı değişken değerlerinin tüm değişkenliğini açıkladığını göstermektedir. Diğer uçta,  $R^2$  için 0 değeri, regresyon eşitliğinin değişkenliğin hiçbirini açıklamadığını göstermektedir. Bağımsız değişkenler hakkında herhangi bir bilgi olmaksızın, bağımlı değişken  $Y$ 'nin gelecekteki değeri için en iyi tahmin,  $n$  adet geçmiş gözlemin örnek ortalaması olan  $\bar{Y}$ 'dir. Belirli bir geçmiş değer  $Y_i$  için,  $\bar{Y}$ 'nin tahmin edici olarak kullanılmasındaki hata,  $Y_i - \bar{Y}$  sapmasıdır (başlangıç varyasyonu). Verilen  $n$  gözlem ( $Y_i, i = 1, \dots, n$ ) için toplam değişkenliğin bir ölçüsü,  $\bar{Y}$  etrafındaki sapmaların karelerinin toplamıdır. Eşitlik 17'de yer verilmektedir. Bağımsız değişkenlerin ilişkili değerleri bilindiğinde,  $Y$  için gelecekteki bir değer için en iyi tahmini, uygun regresyon eşitliğinden elde edilen  $\hat{Y}$  değeridir. Bu da  $Y_i - \hat{Y}_i$  tahmin hatasına (veya artık varyasyona) yol açmaktadır. Dolayısıyla,  $Y$ 'deki değişkenliğin ölçüsü, regresyon eşitliği kurulduktan sonra  $\hat{Y}_i$ 'ler etrafındaki sapmaların karelerinin toplamı ile verilmektedir. Eşitlik 18'de gösterilmektedir. Önceki iki niceliğin oranı, uygun regresyon eşitliği tarafından açıklanamayan toplam değişkenliğin oranıdır. Eşitlik 19'da gösterilmektedir. Belirleme katsayısı ( $R^2$ ), 1'den çıkarılan önceki miktardır. Böylece, regresyon eşitliği tarafından açıklanan toplam değişkenliğin oranıdır. Eşitlik 19'da gösterilmektedir.  $R^2$  değeri,  $S$  ( $Y$ 'nin orijinal değerlerinin örneklem standart sapması) ve  $S_E$  (regresyon eşitliğinin standart tahmin hatası) değerleri aşağıdaki gibi ilişkilidir. Eşitlik 21'de gösterilmektedir. Burada,  $k$  uygun regresyon eşitliğindeki terim sayısını (kesişim dahil) ifade etmektedir.  $S_E$  Eşitlik 22'de görülmektedir (Hahn, 1973: 609-612).

$$\sum_{i=1}^n (Y_i - \bar{Y})^2 \quad (17)$$

$$\sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (18)$$

$$\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (19)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2}$$

$$= \frac{\sum_{i=1}^n (Y_i - \bar{Y})^2 - \sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (20)$$

$$R^2 = 1 - \frac{S_E^2}{S^2} \left( \frac{n-k}{n-1} \right) \quad (21)$$

$$S_E = \left( \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n-k} \right)^{\frac{1}{2}} \quad (22)$$

### 2.2.5. Hatanın Mutlak Ortalaması

Gerçekleşen değer ile tahmin edilen değer farkının, negatif olmaması için mutlak değerinin alınması gerekmektedir. Çünkü bu işlem, gerçek değerler vektörü ile tahmin değerleri vektörünün her bir elemanı için yapılmaktadır. Söz konusu toplamların, eleman sayısına bölünmesi ile hatanın ortalamasının bulunması amaçlanmaktadır. Negatif değerlerin pozitif değerlerle toplanması sonucu hata bilgisinin kısmen veya tamamen kaybedilmesi sorunu bu şekilde çözülmektedir (Harman, 2022: 8). Hatanın Mutlak Ortalaması eşitliğinde  $X_i$ , tahmin edilen  $i$ ' inci değer,  $Y_i$  elemanı gerçek  $i$ ' inci değerdir. Gözlem sayısı  $m$ 'dir. Hatanın Mutlak Ortalaması için en iyi değer 0 iken, en kötü değer  $+\infty$ 'dur. Eşitlik 23'te formül yer almaktadır (Chicco vd., 2021: 4):

$$MAE = \frac{1}{m} \sum_{i=1}^m |X_i - Y_i| \quad (23)$$

### 2.2.6. Ortalama Mutlak Yüzde Hata

Ortalama Mutlak Yüzde Hata (MAPE) değeri, hataların yüzdelik değerinin ortalamasıdır (Tekin ve Patır, 2023: 65). MAPE formülü Eşitlik 24'te yer almaktadır (Sood ve Jain, 2017: 2).

$$MAPE = \frac{1}{n} \sum_{i=1}^n |(Y_t - F_t)/Y_t| \times 100 \quad (24)$$

$Y_t$  : Gözlemlenen değer

$F_t$  : Tahmin edilen değer.

$n$  : Tahmin olarak kullanılan zaman dilimi sayısı.

MAPE için en iyi değer 0 iken, en kötü değer  $+\infty$ 'dur (Chicco vd., 2021: 6).


MAPE incelemelerinin sonuçları, mükemmel (MAPE<10), iyi (MAPE=10-20), kabul edilebilir (MAPE=20-50) ve kabul edilemez (MAPE>50) olmak üzere dört tipte sınıflandırılabilir (Chang vd., 2007: 894).

## ÜÇÜNCÜ BÖLÜM

### YABANCILARA KONUT SATIŞ TAHMİNİNDE MAKİNE ÖĞRENMESİ YÖNTEMLERİNİN KARŞILAŞTIRILMASI

Son yıllarda genel olarak ülkemizde yabancılara konut satışı dikkat çekici bir gelişme göstermektedir. Bu noktada yabancıların konut satış talebini iyi bir şekilde belirlemek oldukça önemlidir. Talep ile arzı dengede tutabilmek ve geleceğin belirsizliğinden en az etkilenecek şekilde kararlar alabilmek adına doğru bir talep tahmin modeli geliştirmek önem arz etmektedir.

Türkiye'deki konut satışını içeren istatistikler incelendiği zaman, konut satışlarında 2023 yılında 2022 yılına göre %17,5 azalma gerçekleşmiştir. 2023 yılında gerçekleşen konut satış sayısı 1.225.926'dır. Bu istatistiklerde, en yüksek konut satışının gerçekleştiği ilin 198.739 satış ile İstanbul olduğu belirtilmiştir. İstanbul'u, 114.432 gerçekleşen konut satışı ile Ankara takip etmektedir. Üçüncü sırada, İzmir 65.465 konut satışıyla yer almaktadır. Şekil 9'da 2013-2023 yılları arasında ülkemizdeki konut satış değerleri gösterilmektedir (<https://www.tuik.gov.tr/>, 25.04.2024).




**Şekil 9.** Konut Satış İstatistikleri

TÜİK'in yayınladığı konut sektörüne ilişkin göstergelerin gelişimi, sektörün 2018 ve 2019 yıllarında ılımlı bir yavaşlamanın ardından genel olarak düzenli bir büyüme performansı sergilediği görülmektedir. 2020 ve sonrasındaki veriler ışığında, genel iktisadi gelişmelere benzer olarak sektördeki ekonomik aktivitenin yeniden artmaya başladığına işaret etmektedir. 2022 yılından itibaren konut satışlarındaki hızlı artışın, enflasyona karşı borçlanma maliyetlerinin tarihsel olarak düşük seviyelerde seyretmesinden ve son dönemde Türkiye'ye yönelik artan dış talepten kaynaklandığı değerlendirilmektedir. Güçlü büyüme potansiyelinin yanında genç bir nüfusa sahip olan ülkemize yurt dışından gelenlerin ilgisi artmaktadır. Ülkemizi 30 milyondan fazla turist

ziyaret ederken, bu gelişmenin yabancıların gayrimenkul talebini de olumlu etkilediği görülmektedir (Alkan, 2022: 1515). Özellikle 2013 yılından itibaren yabancılara yapılan konut satışlarındaki hızlı artışın ekonomik göstergelerin yanı sıra; Lozan Antlaşması'nda (1923) yer alan mütekabiliyet ilkesinin 2012 yılında 6302 sayılı Kanun ile kaldırılmasının bir sonucu olarak, gayrimenkul sahibi olma hakkına sahip vatandaşların sayısı artmıştır. Ek olarak, 14 Nisan 2018 tarihinde yürürlüğe giren 9601 sayılı Yönetmelik kapsamında yabancılar, belirli bir parasal değer üzerinde gayrimenkul satın almaları halinde Türk vatandaşlığı kazanma hakkına sahip olmuştur. Ayrıca, 2017 yılında Maliye Bakanlığı tarafından yayımlanan Tebliğ kapsamında Türkiye'de ilk gayrimenkulünü edinen yabancılar KDV'den muaf tutulmuştur. Tüm bu düzenlemelerle birlikte yabancıların ülkemizde konut edinme süreci kolaylaştırılmıştır (Karakurt, 2020: 394-395).

TÜİK'in yabancılara yapılan konut satışlarına dair yayınlamış olduğu istatistikler incelendiğinde, 2023 yılında 2022 yılına göre %48,1 azalma gerçekleşmiştir. 2023 yılında gerçekleşen yabancı konut satış sayısı 35.005 olmuştur. 2023 senesinde yabancı konut satış istatistiklerinde ilk sırada Antalya ili bulunmaktadır. Antalya ilinde 12.702 satış gerçekleşmiştir. Antalya'yı sırasıyla İstanbul 11.229, Mersin ise 3.016 satış sayısı ile takip etmektedir. Şekil 10'da 2013-2023 yılları arasında ülkemizde yabancılara yapılan konut satış değerleri gösterilmektedir (<https://www.tuik.gov.tr/>, 25.04.2024).



### Şekil 10. Yabancılara Yapılan Konut Satış İstatistikleri

Literatürde Yabancılara Yapılan Konut Satışı ile ilgili bazı çalışmalar mevcuttur.

Goh (1998) çalışmasında, Singapur'da konut inşaatı talebinin tahmininde Zaman Serileri, Regresyon ve Yapay Sinir Ağı yöntemlerini karşılaştırmıştır. Geliştirilen talep modellerinin doğruluğunun karşılaştırılması sonucunda, Yapay Sinir Ağı modelinin genel olarak en iyi performansı gösterdiği tespit edilmiştir.

Çiftçi ve Arı (2019), yabancılara konut satışı ile ilgili Antalya ilinin verilerini içeren bir çalışma yapmıştır. Çalışmada Eş bütünleşme ve VECM analizleri kullanılmıştır.

Özaktaş (2019) çalışmasında, reel efektif döviz kurunun ülkemizdeki yabancı konut satışlarını nasıl etkilediğini araştırmıştır. Bu araştırmada kullanılan analizlerden birincisi Engle-Granger Eş Bütünleşme Testi, ikincisi Hata Düzeltme Modeli ve son olarak Dinamik En Küçük Kareler yöntemidir. Bu yöntemlerle yapılan analiz sonucunda döviz kurunda meydana gelen artışın yabancı konut satışlarının üzerinde olumlu bir etkisi olduğu ortaya çıkmıştır.

Süleymanlı (2019), Türkiye’de yabancılara konut satışı ile döviz kuru arasındaki ilişkiyi tespit etmek için eş bütünleşme analizi uygulamıştır. Yabancılara yapılan konut satışı ve döviz kuru arasında tek yönlü olan nedensellik bulunmuştur.

Davids (2020) çalışmasında, Güney Afrika Cape Town'daki büyük ve ani döviz kuru değer kayıplarının emlak fiyatları üzerindeki etkisini incelenmiştir. Yerleşik olmayan yabancıların, büyük döviz kuru değer kayıplarını takiben daha fazla mülk satın aldıkları ortaya çıkmıştır.

Karakurt (2020) çalışmasında, yabancıların Türkiye’de gayrimenkul satın almalarını etkileyen iki ana faktör olan ekonomik göstergeler ve yasal düzenlemeleri ele almıştır. Yapılan analiz sonucunda, yasal düzenlemeler yabancıların Türkiye’de gayrimenkul sahibi olmasında önemli bir belirleyici faktör olduğu sonucuna ulaşılmıştır. Ancak, yasal düzenlemelerin tek faktör olmadığı vurgulanmıştır. Türkiye'nin stratejik ve jeopolitik rolünün yanı sıra sosyokültürel yapısı, doğal ve yapısal çevre değerleri ve iklimi de yabancıları gayrimenkul satın almak için teşvik edici olduğu değerlendirilmiştir. Bu faktörlerin, 2015 yılından bu yana Irak, Suudi Arabistan, Kuveyt, İran ve Azerbaycan'dan gelenler için özellikle cazip hale geldiğine dikkat çekilmiştir.

Gökler (2021), Ankara ve Trabzon’da dış talep ve yüksek katlı lüks konut projeleri çalışması yapmıştır. Çok katlı lüks konut projelerinin ortaya çıkışı ile yabancıların konut talebinin artması arasındaki ilişkiyi iki örnek şehre odaklanarak incelemiştir.



Selçi (2021), Yapay Sinir Ağları yöntemi ile Türkiye'nin konut satış değerlerinin tahmininin gerçekleştirdiği bir çalışma yapmıştır. YSA yöntemi ile gerçekleştirilen analizin sonucunda ulaşılan tahmin değerleri ile gerçek değerlerin oldukça yakın olduğu saptanmıştır.

Yanar ve Demir (2022), Türkiye'de döviz kurundaki değişimlerin yabancı konut talebine etkisini araştırmıştır. Zaman serisi analizi yapılmıştır. Çalışmanın sonucunda, döviz kurundaki değişimin yabancıların konut talebine etkisi olduğu saptanmıştır.

Akay vd. (2023) çalışmasında KFE ve Konut Satışı değişkenlerini kullanarak Basit Doğrusal Regresyon analizini gerçekleştirmiştir. KFE ve konut satışına ait veriler 2013-2022 senelerini kapsamaktadır. Söz konusu değişkenler arasında istatistiksel olarak anlamlı, pozitif yönde bir ilişki bulunmuştur.

### **3.1. Çalışmanın Amacı ve Yöntemi**

Çalışmada, Türkiye'de Yabancılara Konut Satışının Tahmininde Makine Öğrenmesi Yöntemleri karşılaştırılmıştır. Uygulama sonucunda en uygun tahmin yöntemine ulaşılması amaçlanmıştır.

Çalışmada, Python programında makine öğrenmesi yöntemlerinden Çoklu Doğrusal Regresyon, Rastgele Orman Regresyon, Karar Ağacı Regresyon, Çok Katmanlı Yapay Sinir Ağları yöntemleri kullanılmıştır.

Model doğrulaması için, mevcut makine öğrenmesi algoritmalarının model performansının değerlendirilmesini içeren k katlamalı çapraz doğrulama yöntemi kullanılmıştır. Literatürdeki mevcut k değerlerinden 3, 5, 10 ve 20 değerleri denenmiştir. Çalışmada kullanılan yöntemlerin tümünün çalıştırılabilmesi adına k değeri 3 olarak belirlenmiştir. Literatürde k değerinin 3 olarak kullanıldığı çalışmalar mevcuttur (Blockeel ve Struyf, 2002: 621; Etsel ve Braver, 2013: 140; Chen ve Lei, 2018: 241; Wang vd., 2023: 5019; Xie vd., 2023).

Söz konusu yöntemler iki farklı veri setinde uygulanmıştır. Birinci veri setinde, illere göre yabancılara yapılan konut satış sayıları dikkate alınmıştır. İkinci veri setinde, illere ve ülke uyruklarına göre yabancılara yapılan konut satış sayıları dikkate alınmıştır.

Birinci veri seti, 2013-2023 yılları arasında 12 aylık periyotlardan oluşmaktadır. Yalnız 2023 yılı verileri, ilk 6 ayı kapsamaktadır. Bu veri setinde bağımlı değişken "Yabancılara Konut Satışı"dır. Bağımsız değişkenler: "Tüm Konut Satışları", "Dolar",

“Euro”, “Sterlin”, “Altın”, “Gayrisafi Büyüme Hızı”, “Enflasyon”, “Borsa Endeksi”, “Konut Fiyat Endeksi”, “Yapı Ruhsatlı Bina Sayısı”, “Yapı Ruhsatlı Daire Sayısı”, “Yapı Ruhsatlı Yüz Ölçüm Metrekaresi”, “Yapı Kullanım İzni Verilen Bina Sayısı”, “Yapı Kullanım İzni Verilen Daire Sayısı”, “Yapı Kullanım İzinli Yüz Ölçüm Metrekaresi”, “Belirsizlik Endeksi”, “İllere Göre Yabancılara Yapılan Konut Satış Sayıları (İstanbul, Antalya, Bursa, Yalova, Sakarya, Diğer İller). Söz konusu iller, her yıl illere göre yabancılara yapılan konut satışındaki sıralamada ilk onda yer aldıkları için bağımsız değişken olarak belirlenmiştir. İlk onda bu iller dışında geriye kalan iller ise “Diğer İller” değişkenine eklenerek çalışmada yer verilmiştir.

İkinci veri seti, 2015-2023 yılları arasında 12 aylık periyotlardan oluşmaktadır. Yalnız 2023 yılı verileri, ilk 6 ayı kapsamaktadır. Bu veri setinde bağımlı değişken “Yabancılara Konut Satışı”dır. Bağımsız değişkenler: “Tüm Konut Satışları”, “Dolar”, “Euro”, “Sterlin”, “Altın”, “Gayrisafi Büyüme Hızı”, “Enflasyon”, “Borsa Endeksi”, “Konut Fiyat Endeksi”, “Yapı Ruhsatlı Bina Sayısı”, “Yapı Ruhsatlı Daire Sayısı”, “Yapı Ruhsatlı Yüz Ölçüm Metrekaresi”, “Yapı Kullanım İzni Verilen Bina Sayısı”, “Yapı Kullanım İzni Verilen Daire Sayısı”, “Yapı Kullanım İzinli Yüz Ölçüm Metrekaresi”, “Belirsizlik Endeksi”, “İllere Göre Yabancılara Yapılan Konut Satış Sayıları (İstanbul, Antalya, Bursa, Yalova, Sakarya, Diğer İller), “Ülke Uyruklarına Göre Yabancılara Yapılan Konut Satış Sayıları (Irak, Kuveyt, Rusya Federasyonu, İngiltere, Almanya, Azerbaycan, İran, Afganistan, Ukrayna, Kazakistan, Mısır, Ürdün, Diğer Uyruklar). Her yıl ülke uyruklarına göre yabancılara yapılan konut satışındaki sıralamada ilk yirmide yer alan ülkeler bağımsız değişken olarak belirlenmiştir. İlk yirmide bu iller dışında geriye kalan ülke uyrukları ise “Diğer Uyruklar” değişkenine eklenerek çalışmada yer verilmiştir. Çalışmada yer alan verilere, TÜİK ve Türkiye Cumhuriyet Merkez Bankası resmi web sitelerinden ulaşılmıştır (<https://www.tuik.gov.tr/>, <https://www.tcmb.gov.tr/>, 01.12.2023). Belirsizlik endeksi verilerine, World Uncertainty Index internet web sitesinden ulaşılmıştır (<https://worlduncertaintyindex.com/>, 01.12.2023).

### **3.2. Yabancılara Konut Satış Tahmininde Makine Öğrenmesi Yöntemlerinin Performanslarının Değerlendirilmesi**

İlk olarak veriler analize uygun hale getirilmiştir. Veriler, Microsoft Excel Çalışma Sayfasında, “Dosya” sekmesinde “CSV UTF-8 (Virgülle ayrılmış)(\*.csv)” şeklinde farklı kaydedilmiştir. Ardından Google Drive hesabında Python’u yazmak ve çalıştırmak için Google Colaboratory Jupyter notebook çalıştırılmıştır. Google Colaboratory Jupyter notebook, Python 3 Google Compute Engine altyapısına bağlanarak çalışmaktadır.

#### **3.2.1. İllere Göre Yabancı Konut Satış Sayıları Dahil Edilerek Yapılan Yabancı Konut Satış Tahmininde Makine Öğrenmesi Yöntemlerinin Performanslarının Değerlendirilmesi**

İllere göre yabancı konut satış sayılarının dahil olduğu birinci veri setinde, Çoklu Doğrusal Regresyon, Karar Ağacı Regresyon, Rastgele Orman Regresyon, Çok Katmanlı Yapay Sinir Ağı yöntemleri uygulanarak, performans değerleri belirlenmiştir.

##### **3.2.1.1. Çoklu doğrusal regresyon yöntemine göre performansların belirlenmesi**

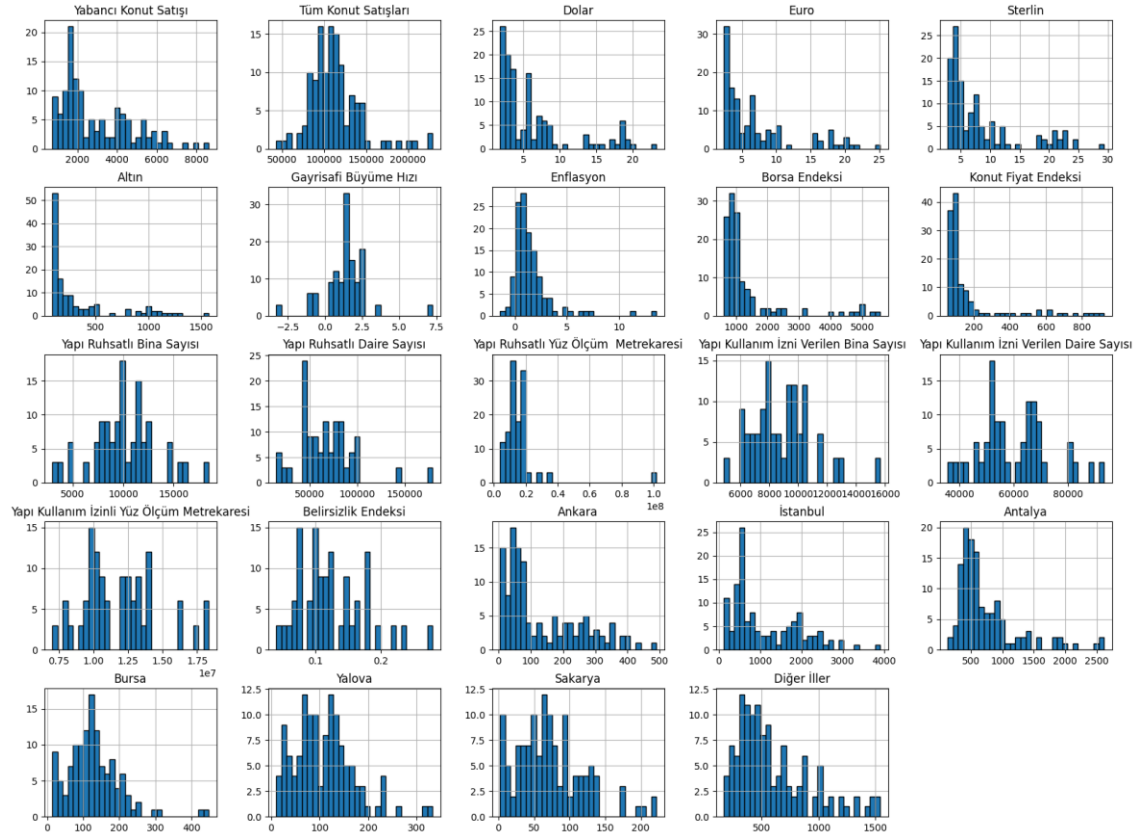
Çoklu Doğrusal Regresyon modelini kurmak, analizi gerçekleştirmek ve modelin performans ölçütlerini belirlemek için Ek-2’de yer alan gerekli kütüphaneleri Python’da çağırıp içe aktarım gerçekleştirilmiştir. Ardından programa veriler eklenerek, veri çerçevesi oluşturulmuştur. Birinci veri çerçevesi Ek-3’te yer almaktadır.

Veri hakkında bilgi, Tablo 1’de yer almaktadır. “Tam veri” eksik veri olmadığını göstermektedir. Sütundaki değerler, tam sayı ya da ondalıklı değerlerdir.

**Tablo 1. Veri Hakkında Bilgiler**

Değişken	Veri (Boşluk Veri-Tam Veri)	Veri Tipi
Yabancı Konut Satışı	126 Tam Veri	Tam Sayı Değeri
Tüm Konut Satışları	126 Tam Veri	Tam Sayı Değeri
Dolar	126 Tam Veri	Ondalıklı Sayı Değeri
Euro	126 Tam Veri	Ondalıklı Sayı Değeri
Sterlin	126 Tam Veri	Ondalıklı Sayı Değeri
Altın	126 Tam Veri	Ondalıklı Sayı Değeri
Gayrisafi Büyüme Hızı	126 Tam Veri	Ondalıklı Sayı Değeri
Enflasyon	126 Tam Veri	Ondalıklı Sayı Değeri
Borsa Endeksi	126 Tam Veri	Ondalıklı Sayı Değeri
Konut Fiyat Endeksi	126 Tam Veri	Ondalıklı Sayı Değeri
Yapı Ruhsatı Verilen Bina Sayısı	126 Tam Veri	Ondalıklı Sayı Değeri
Yapı Ruhsatı Verilen Daire Sayısı	126 Tam Veri	Ondalıklı Sayı Değeri
Yapı Ruhsatlı Yüz Ölçüm Metrekaresi	126 Tam Veri	Ondalıklı Sayı Değeri
Yapı Kullanım İzni Verilen Bina Sayısı	126 Tam Veri	Ondalıklı Sayı Değeri
Yapı Kullanım İzni Verilen Daire Sayısı	126 Tam Veri	Ondalıklı Sayı Değeri
Yapı Kullanım İzinli Yüz Ölçüm Metrekaresi	126 Tam Veri	Ondalıklı Sayı Değeri
Belirsizlik Endeksi	126 Tam Veri	Ondalıklı Sayı Değeri
Ankara	126 Tam Veri	Tam Sayı Değeri
İstanbul	126 Tam Veri	Tam Sayı Değeri
Antalya	126 Tam Veri	Tam Sayı Değeri
Bursa	126 Tam Veri	Tam Sayı Değeri
Yalova	126 Tam Veri	Tam Sayı Değeri
Sakarya	126 Tam Veri	Tam Sayı Değeri
Diğer İller	126 Tam Veri	Tam Sayı Değeri

Şekil 11’de verilerin istatistiksel dağılımlarını görmek amacıyla, birinci veri setinde yer alan değişkenlerin histogram grafikleri verilmiştir.



**Şekil 11.** Birinci Veri Setindeki Değişkenlerin Histogram Grafikleri

Şekil 11’de histogram (veri yoğunluk dağılımı) grafiklerinde, değişkenlerin değerleri yatay eksende, bu değerlerin frekansı ise dikey eksende gösterilmektedir. Bu grafiklere göre Tüm Konut Satışları, Yapı Ruhsatlı Bina Sayısı, Yapı Ruhsatlı Daire Sayısı, Yapı Kullanım İzni Verilen Daire Sayısı ve Yapı Kullanım İzinli Yüz Ölçüm Metrekaresi değişkenlerinin değerleri normale yakın bir dağılım göstermektedir. Yabancı konut satışı, dolar, euro, sterlin, altın, gayrisafi büyüme hızı, enflasyon, borsa endeksi, konut fiyat endeksi, yapı ruhsatlı yüz ölçüm metrekaresi, yapı kullanım izni verilen bina sayısı, belirsizlik endeksi, Ankara, İstanbul, Antalya, Bursa, Yalova, Sakarya, diğer iller değişkenleri normal bir dağılım göstermemektedir. Veri madenciliği ve yapay zekâ çalışmalarında normal dağılım koşulu aranmadığı için diğer değişkenlerin normal dağılım göstermemesi bir problem oluşturmamaktadır (Sattari vd., 2020: 4).

Yabancı konut satışının diğer değişkenlerle olan korelasyonu Tablo 2’de yer almaktadır.

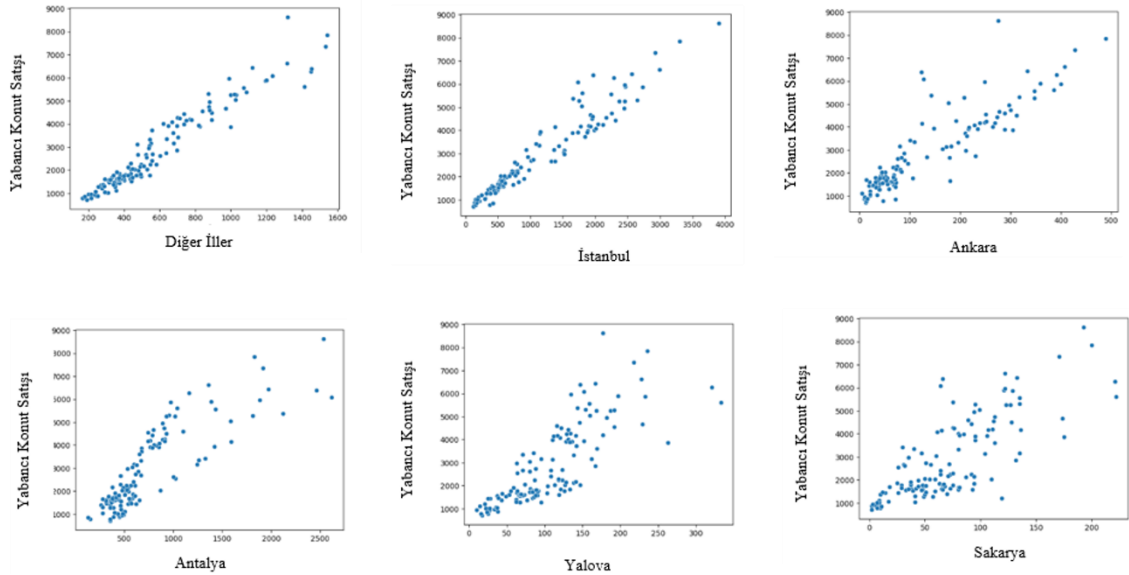
**Tablo 2.** Yabancı Konut Satışının Diğer Değişkenlerle Korelasyonu

Değişkenler	Korelasyon Değerleri
Yapı Ruhsatı Verilen Daire Sayısı	-0.340415
Belirsizlik Endeksi	-0.299724
Yapı Kullanım İzni Verilen Bina Sayısı	-0.167409
Yapı Ruhsatı Verilen Bina Sayısı	-0.097737
Yapı Kullanım İzni Verilen Daire Sayısı	-0.073017
Yapı Kullanım İzinli Yüz Ölçüm Metrekaresi	-0.031611
Gayrisafi Büyüme Hızı	0.210099
Yapı Ruhsatlı Yapıların Yüz Ölçüm Metrekaresi	0.212649
Borsa Endeksi	0.445501
Konut Fiyat Endeksi	0.451754
Tüm Konut Satışları	0.505702
Enflasyon	0.534738
Altın	0.614036
Dolar	0.661330
Euro	0.672196
Sterlin	0.673100
Bursa	0.688428
Sakarya	0.770682
Yalova	0.806601
Antalya	0.852908
Ankara	0.889245
İstanbul	0.962323
Diğer İller	0.963023

Korelasyon katsayısı, iki nicel değişken arasındaki doğrusal ilişkinin gücünü ve yönünü belirten katsayıdır. Uç noktalar, -1.00 ve +1.00, “mükemmel” korelasyonu temsil etmektedir. Sıfır ise hiç korelasyon olmadığı anlamına gelmektedir. Dolayısıyla sıfırdan herhangi bir yöne doğru hareket ettikçe, korelasyon daha güçlü hale gelirken; sıfıra yaklaştıkça da korelasyon zayıflamaktadır. Negatif işaretli korelasyon katsayıları ile pozitif işaretli katsayıların arasındaki fark, değişkenler arasındaki ilişkinin yönü ile

ilgilidir. Eğer işaret negatif ise, negatif korelasyon vardır. Bu durum, iki değişkenin değerlerinin zıt yönde hareket etme eğiliminde olduğunu göstermektedir. İşaret pozitif ise, pozitif korelasyon vardır. Bu durum, iki değişkenin aynı yönde hareket etme eğiliminde olduğunu göstermektedir (Christensen vd., 2015: 453-456). Tablo 2’de görüldüğü üzere, bağımlı değişken “Yabancı Konut Satışı” ile arasında güçlü pozitif yönlü korelasyon olan bağımsız değişkenler şunlardır: Diğer iller, İstanbul, Ankara, Antalya, Yalova, Sakarya. Bağımlı değişken “Yabancı Konut Satışı” ile arasında zayıf pozitif yönlü korelasyon olan bağımsız değişkenler şunlardır: Gayrisafi büyüme hızı, yapı ruhsatlı yapıların yüz ölçüm metrekaresi. Bağımlı değişken “Yabancı Konut Satışı” ile arasında zayıf negatif yönlü korelasyon olan bağımsız değişkenler şunlardır: Yapı ruhsatı verilen daire sayısı, belirsizlik endeksi, yapı kullanım izni verilen bina sayısı, yapı ruhsatı verilen bina sayısı, yapı kullanım izni verilen daire sayısı, yapı kullanım izinli yüz ölçüm metrekaresi.

Birinci veri setinde, bağımlı değişken “Yabancı Konut Satışı” ile arasında güçlü pozitif yönlü korelasyon olan bağımsız değişkenlerin ilişkilerinin yönünü görsel olarak belirlemek için çizilen saçılım grafikleri Şekil 12’de gösterilmektedir.



**Şekil 12.** Birinci Veri Setinde Yabancı Konut Satışı ile Arasında Güçlü Korelasyon Olan Bağımsız Değişkenlerin Saçılım Grafikleri

Şekil 12’de yer alan saçılım grafikleri incelendiği zaman, bağımlı değişken yabancı konut satışı ile diğer iller, İstanbul, Ankara, Antalya, Yalova, Sakarya bağımsız değişkenleri arasında doğrusal bir ilişki olduğu saptanmıştır. Yatay ekseninde bağımsız

değişkeninin değerleri; dikey ekseninde ise bağımlı değişken yabancı konut satışı değişkeninin değerleri yer almaktadır. Her bir grafik ayrı ayrı incelendiği zaman, söz konusu bağımsız değişkenlerin değerleri arttıkça, Yabancı Konut Satışının da arttığı görülmektedir. Şekil 12’de grafiklerde, saçılım hayali bir doğru etrafında kümelenmiş olarak görülmektedir. Bu durum, bağımlı değişken yabancı konut satışı ile sırasıyla diğer iller, İstanbul, Ankara, Antalya, Yalova, Sakarya bağımsız değişkenleri arasında güçlü bir ilişki olduğunu ortaya koymuştur.

Belirleme katsayısı ( $R^2$ ) değerini düşüren değişkenler belirlenip, veri setinden çıkarılmıştır. Çalışmada “Gayrisafi Büyüme Hızı”, “Yapı Ruhsatı Verilen Bina Sayısı”, “Yapı Ruhsatı Verilen Daire Sayısı”, “Yapı Ruhsatlı Yüz Ölçüm Metrekaresi”, “Yapı Kullanım İzni Verilen Bina Sayısı”, “Yapı Kullanım İzni Verilen Daire Sayısı”, “Yapı Kullanım İzinli Yüz Ölçüm Metrekaresi”, “Belirsizlik Endeksi” bağımsız değişkenlerden çıkarılmıştır. Söz konusu değişkenler veri setinden çıkarıldıktan sonra, birinci veri setinin bağımsız değişkenlerinin mevcut olduğu veri seti Ek 4’te yer almaktadır.

Değişkenler belirlendikten sonra, ilk olarak k katlamalı çapraz doğrulama ile veri seti eğitim ve test kümelerine ayrılmıştır. K değeri 3 olarak alınmıştır. Çoklu Doğrusal Regresyon modeli kurulduktan sonra modelin performans değerlerini hesaplanmıştır.

**Tablo 3.** Çoklu Doğrusal Regresyon Yönteminin Performans Değerleri

RMSE (Root Mean Square Error-Hata Kareler Ortalamasının Karekökü)	177.41
Belirleme Katsayısı ( $R^2$ )	0.9877
MAE (Mean Absolute Error-Hatanın Mutlak Ortalaması)	71.79
MAPE (Mean Absolute Percentage Error-Ortalama Mutlak Yüzde Hata)	0.0196
MSE (Mean Squared Error-Hata Kareler Ortalaması)	31473.04

Tablo 3’te çoklu doğrusal regresyon yöntemi uygulanması sonucunda, yabancılara konut satışı tahmin modelinin performans değerleri verilmektedir. Hata



kareler ortalamasının karekökü 177.41, hatanın mutlak ortalaması 71.79, hata kareler ortalaması 31473.04, ortalama mutlak yüzde hata 0.0196 olarak saptanmıştır. Belirleme katsayısı 0.9877 olarak saptanmıştır.

### 3.2.1.2. Karar ağacı regresyon yöntemine göre performansların belirlenmesi

Karar Ağacı Regresyon modelini kurmak, analizi gerçekleştirmek ve modelin performans ölçütlerini belirlemek için Ek-5'te yer alan gerekli kütüphaneleri Python'da çağırıp içe aktarım gerçekleştirilmiştir. Sonrasında k katlamalı çapraz doğrulama ile veri seti eğitim ve test kümelerine ayrılmıştır. K değeri 3 olarak alınmıştır. Karar Ağacı Regresyon modelini kurduktan sonra modelin performans değerleri hesaplanmıştır.

**Tablo 4.** Karar Ağacı Regresyon Yönteminin Performans Değerleri

RMSE (Root Mean Square Error-Hata Kareler Ortalamasının Karekökü)	490.29
Belirleme Katsayısı ( $R^2$ )	0.5129
MAE (Mean Absolute Error-Hatanın Mutlak Ortalaması)	299.22
MAPE (Mean Absolute Percentage Error-Ortalama Mutlak Yüzde Hata)	0.1450
MSE (Mean Squared Error-Hata Kareler Ortalaması)	238759.56

Tablo 4'te karar ağacı regresyon yöntemi uygulanması sonucunda, yabancılara konut satışı tahmin modelinin performans değerleri verilmektedir. Hata kareler ortalamasının karekökü 490.29, hatanın mutlak ortalaması 299.22, hata kareler ortalaması 238759.56, ortalama mutlak yüzde hata 0.1450 olarak saptanmıştır. Belirleme katsayısı 0.5129 olarak saptanmıştır.

### 3.2.1.3. Rastgele orman regresyon yöntemine göre performansların belirlenmesi

Rastgele Orman Regresyon modelini kurmak, analizi gerçekleştirmek ve modelin performans ölçütlerini belirlemek için Ek-6'da yer alan gerekli kütüphaneleri Python'da çağırıp içe aktarım gerçekleştirilmiştir. Sonrasında k katlamalı çapraz doğrulama ile veri seti eğitim ve test kümelerine ayrılmıştır. K değeri 3 olarak

alınmıştır. Rastgele Orman Regresyon modelini kurduktan sonra modelin performans değerleri hesaplanmıştır.

**Tablo 5.** Rastgele Orman Regresyon Yönteminin Performans Değerleri

RMSE (Root Mean Square Error-Hata Kareler Ortalamasının Karekökü)	581.32
Belirleme Katsayısı ( $R^2$ )	0.6978
MAE (Mean Absolute Error-Hatanın Mutlak Ortalaması)	406.85
MAPE (Mean Absolute Percentage Error-Ortalama Mutlak Yüzde Hata)	0.1454
MSE (Mean Squared Error-Hata Kareler Ortalaması)	509966.2401

Tablo 5’te rastgele orman regresyon yöntemi uygulanması sonucunda, yabancılara konut satışı tahmin modelinin performans değerleri verilmektedir. Hata kareler ortalamasının karekökü 581.32, hatanın mutlak ortalaması 406.85, hata kareler ortalaması 509966.2401, ortalama mutlak yüzde hata 0.1454 olarak saptanmıştır. Belirleme katsayısı 0.6978 olarak saptanmıştır.

#### 3.2.1.4. Çok katmanlı yapay sinir ağı yöntemine göre performansların belirlenmesi

Çok Katmanlı Yapay Sinir Ağı modelini kurmak, analizi gerçekleştirmek ve modelin performans ölçütlerini belirlemek için Ek-7’de yer alan gerekli kütüphaneleri Python’da çağırıp içe aktarım gerçekleştirilmiştir. Sonrasında k katlamalı çapraz doğrulama ile veri seti eğitim ve test kümelerine ayrılmıştır. K değeri 3 olarak alınmıştır. Çok Katmanlı Yapay Sinir Ağı modelini kurduktan sonra modelin performans değerleri hesaplanmıştır.

**Tablo 6.** Çok Katmanlı Yapay Sinir Ağı Yönteminin Performans Değerleri

RMSE (Root Mean Square Error-Hata Kareler Ortalamasının Karekökü)	588.54
Belirleme Katsayısı ( $R^2$ )	0.2957
MAE (Mean Absolute Error-Hatanın Mutlak Ortalaması)	464.83

MAPE (Mean Absolute Percentage Error-Ortalama Mutlak Yüzde Hata)	31.83
MSE (Mean Squared Error-Hata Kareler Ortalaması)	2242823.11

Tablo 6’da çok katmanlı yapay sinir ağı yöntemi uygulanması sonucunda, yabancılara konut satışı tahmin modelinin performans değerleri verilmektedir. Hata kareler ortalamasının karekökü 588.54, hatanın mutlak ortalaması 464.83, hata kareler ortalaması 2242823.11, ortalama mutlak yüzde hata 31.83 olarak saptanmıştır. Belirleme katsayısı 0.2957 olarak saptanmıştır.

### **3.2.2. İllere ve Ülke Uyruklarına Göre Yabancı Konut Satış Sayıları Dahil Edilerek Yapılan Yabancı Konut Satış Tahmininde Makine Öğrenmesi Yöntemlerinin Performanslarının Değerlendirilmesi**

İllere ve ülke uyruklarına göre yabancı konut satış sayılarının dahil olduğu ikinci veri setinde Çoklu Doğrusal Regresyon, Karar Ağacı Regresyon, Rastgele Orman Regresyon, Çok Katmanlı Yapay Sinir Ağı yöntemleri uygulanarak, performans değerleri belirlenmiştir.

#### **3.2.2.1. Çoklu doğrusal regresyon yöntemine göre performansların belirlenmesi**

Çoklu Doğrusal Regresyon modelini kurmak, analizi gerçekleştirmek ve modelin performans ölçütlerini belirlemek için Ek-2’de yer alan gerekli kütüphaneleri Python’da çağırıp içe aktarım gerçekleştirilmiştir. Ardından programa veriler eklenerek, veri çerçevesi oluşturulmuştur. İkinci veri çerçevesi Ek-8 ve Ek-9’da yer almaktadır.

Veri hakkında bilgi, Tablo 7’de verilmiştir. “Tam veri” eksik veri olmadığını göstermektedir. Sütundaki değerler, tam sayı ya da ondalıklı değerlerdir.

**Tablo 7.** Veri Hakkında Bilgi

Değişken	Veri (Boşluk Veri-Tam Veri)	Veri Tipi
Yabancı Konut Satışı	102 Tam Veri	Tam Sayı Değeri
Tüm Konut Satışları	102 Tam Veri	Tam Sayı Değeri
Dolar	102 Tam Veri	Ondalıklı Sayı Değeri
Euro	102 Tam Veri	Ondalıklı Sayı Değeri

Sterlin	102 Tam Veri	Ondalıklı Sayı Deęeri
Altın	102 Tam Veri	Ondalıklı Sayı Deęeri
Gayrisafi Büyüme Hızı	102 Tam Veri	Ondalıklı Sayı Deęeri
Enflasyon	102 Tam Veri	Ondalıklı Sayı Deęeri
Borsa Endeksi	102 Tam Veri	Ondalıklı Sayı Deęeri
Konut Fiyat Endeksi	102 Tam Veri	Ondalıklı Sayı Deęeri
Yapı Ruhsatı Verilen Bina Sayısı	102 Tam Veri	Ondalıklı Sayı Deęeri
Yapı Ruhsatı Verilen Daire Sayısı	102 Tam Veri	Ondalıklı Sayı Deęeri
Yapı Ruhsatlı Yüz Ölçüm Metrekaresi	102 Tam Veri	Ondalıklı Sayı Deęeri
Yapı Kullanım İzni Verilen Bina Sayısı	102 Tam Veri	Ondalıklı Sayı Deęeri
Yapı Kullanım İzni Verilen Daire Sayısı	102 Tam Veri	Ondalıklı Sayı Deęeri
Yapı Kullanım İzinli Yüz Ölçüm Metrekaresi	102 Tam Veri	Ondalıklı Sayı Deęeri
Belirsizlik Endeksi	102 Tam Veri	Ondalıklı Sayı Deęeri
Ankara	102 Tam Veri	Tam Sayı Deęeri
İstanbul	102 Tam Veri	Tam Sayı Deęeri
Antalya	102 Tam Veri	Tam Sayı Deęeri
Bursa	102 Tam Veri	Tam Sayı Deęeri
Yalova	102 Tam Veri	Tam Sayı Deęeri
Sakarya	102 Tam Veri	Tam Sayı Deęeri
Dięer İller	102 Tam Veri	Tam Sayı Deęeri
Irak	102 Tam Veri	Tam Sayı Deęeri
Kuveyt	102 Tam Veri	Tam Sayı Deęeri
Rusya Federasyonu	102 Tam Veri	Tam Sayı Deęeri
İngiltere	102 Tam Veri	Tam Sayı Deęeri
Almanya	102 Tam Veri	Tam Sayı Deęeri
Azerbaycan	102 Tam Veri	Tam Sayı Deęeri
İran	102 Tam Veri	Tam Sayı Deęeri
Afganistan	102 Tam Veri	Tam Sayı Deęeri
Ukrayna	102 Tam Veri	Tam Sayı Deęeri
Kazakistan	102 Tam Veri	Tam Sayı Deęeri
Mısır	102 Tam Veri	Tam Sayı Deęeri
Ürdün	102 Tam Veri	Tam Sayı Deęeri
Dięer Uyrıklar	102 Tam Veri	Tam Sayı Deęeri

Verilerin dağılımlarını görmek amacıyla, ikinci veri setinde yer alan değişkenlerin histogram grafikleri oluşturulmuştur. İkinci veri setinde yer alan değişkenlerin histogram grafikleri, Ek-10'da yer almaktadır.

Ek-10'da yer alan histogram grafiklerinde, değişkenlerin değerleri yatay ekseninde, bu değerlerin frekansı ise dikey ekseninde gösterilmektedir. Bu grafiklere göre tüm konut satışları, yapı ruhsatlı bina sayısı, yapı kullanım izni verilen bina sayısı, yapı kullanım izni verilen daire sayısı ve yapı kullanım izinli yüz ölçüm metrekaresi, belirsizlik endeksi, Afganistan değişkenlerinin değerleri normale yakın bir dağılım göstermektedir. Yabancı konut satışı, dolar, euro, sterlin, altın, gayrisafi büyüme hızı, enflasyon, borsa endeksi, konut fiyat endeksi, yapı ruhsatlı yüz ölçüm metrekaresi, yapı kullanım izni verilen bina sayısı, Ankara, İstanbul, Antalya, Bursa, Yalova, Sakarya, diğer iller, Irak, Kuveyt, Rusya Federasyonu, İngiltere, Almanya, Azerbaycan, İran, Ukrayna, Kazakistan, Mısır, Ürdün, Diğer Uyruklar değişkenleri normal bir dağılım göstermemektedir.

Yabancı konut satışının, diğer değişkenlerle olan korelasyonu Tablo 8'de yer almaktadır.

**Tablo 8.** Yabancı Konut Satışının Diğer Değişkenlerle Korelasyonu

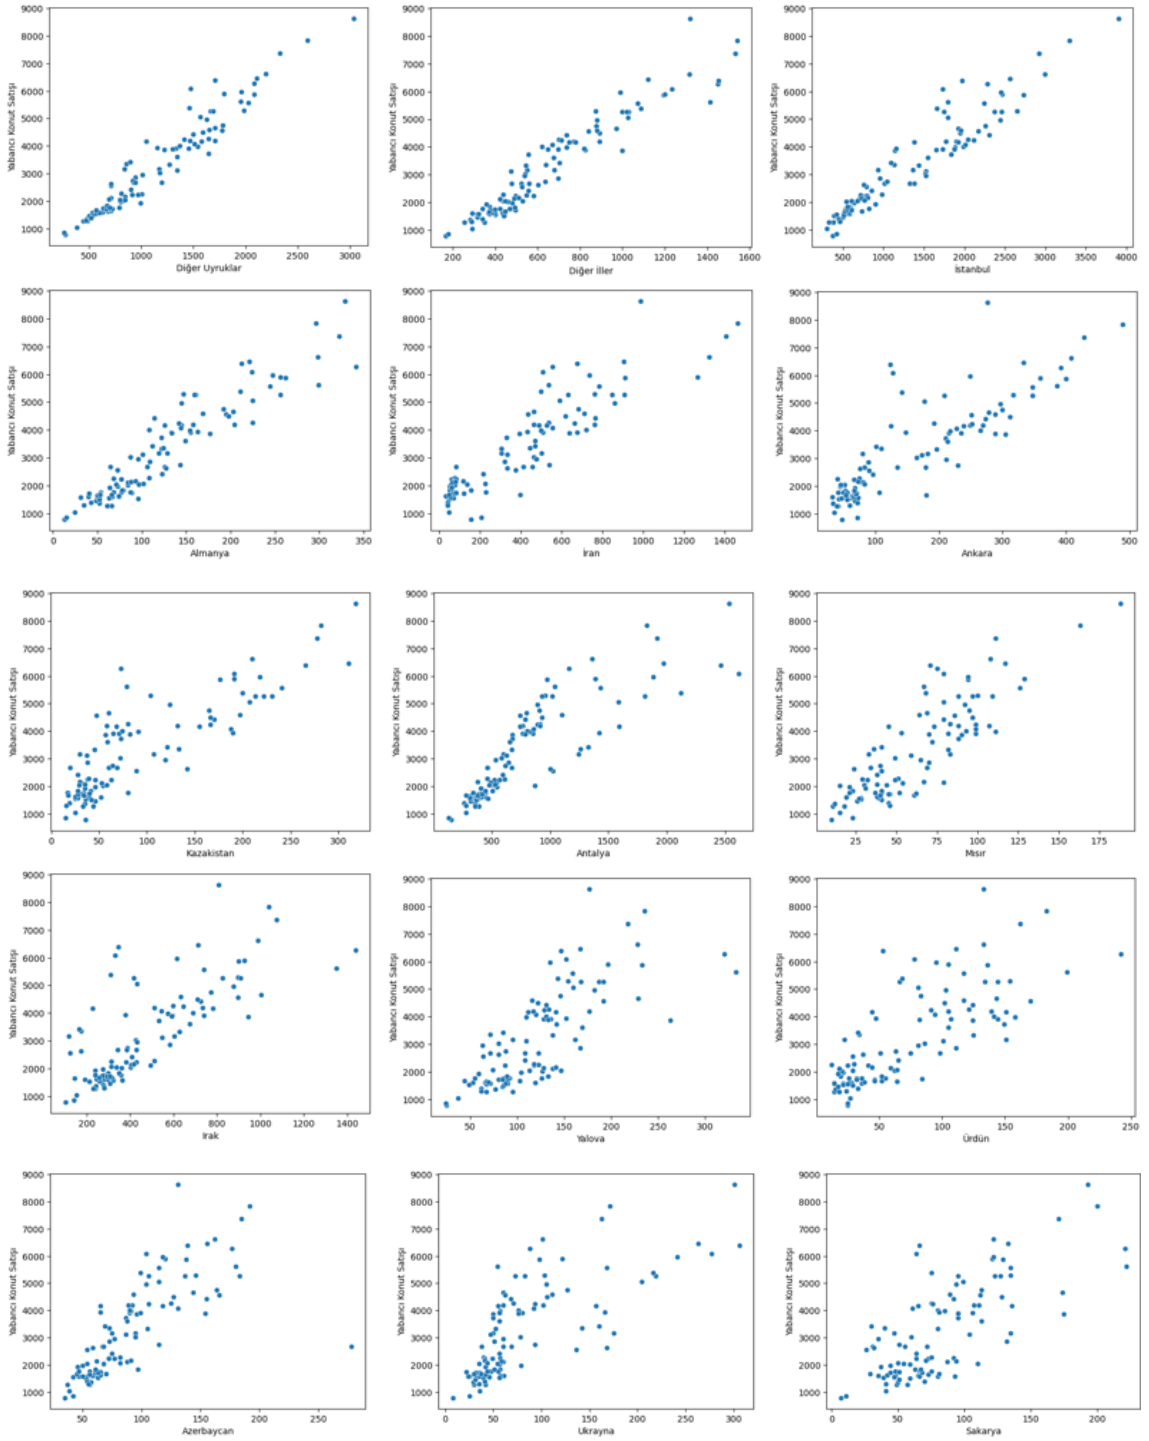
Değişkenler	Korelasyon Değerleri
Belirsizlik Endeksi	-0.472094
Yapı Ruhsatı Verilen Daire Sayısı	-0.318428
Yapı Ruhsatı Verilen Bina Sayısı	-0.050522
Yapı Kullanım İzni Verilen Daire Sayısı	-0.034096
Yapı Kullanım İzni Verilen Bina Sayısı	-0.023142
Yapı Kullanım İzinli Yüz Ölçüm Metrekaresi	-0.016118
Gayrisafi Büyüme Hızı	0.191646
Yapı Ruhsatlı Yüz Ölçüm Metrekaresi	0.238565
Konut Fiyat Endeksi	0.380510
Borsa Endeksi	0.380527
Kuweyt	0.414104
Tüm Konut Satışları	0.457893
Enflasyon	0.513062
Altın	0.555805
Dolar	0.591128

Bursa	0.599348
Euro	0.606496
Sterlin	0.607333
İngiltere	0.639215
Rusya Federasyonu	0.648449
Afganistan	0.703337
Sakarya	0.734449
Ukrayna	0.738972
Azerbaycan	0.757492
Ürdün	0.757970
Yalova	0.759384
Irak	0.764337
Mısır	0.854908
Antalya	0.859325
Kazakistan	0.859597
Ankara	0.862550
İran	0.904977
Almanya	0.938414
İstanbul	0.952903
Diğer İller	0.956771
Diğer Uyruklar	0.964620

Korelasyon katsayısı, iki nicel değişken arasındaki doğrusal ilişkinin gücünü ve yönünü belirten katsayıdır. Uç noktalar, -1.00 ve +1.00, “mükemmel” korelasyonu temsil etmektedir. Sıfır ise hiç korelasyon olmadığı anlamına gelmektedir. Dolayısıyla sıfırdan herhangi bir yöne doğru hareket ettikçe, korelasyon daha güçlü hale gelirken; sıfıra yaklaştıkça da korelasyon zayıflamaktadır. Negatif işaretli korelasyon katsayıları ile pozitif işaretli katsayıların arasındaki fark, değişkenler arasındaki ilişkinin yönü ile ilgilidir. Eğer işaret negatif ise, negatif korelasyon vardır. Bu durum, iki değişkenin değerlerinin zıt yönde hareket etme eğiliminde olduğunu göstermektedir. İşaret pozitif ise, pozitif korelasyon vardır. Bu durum, iki değişkenin aynı yönde hareket etme eğiliminde olduğunu göstermektedir (Christensen vd., 2015: 453-456). Tablo 8’de görüldüğü üzere, bağımlı değişken “Yabancı Konut Satışı” ile arasında güçlü pozitif yönlü korelasyon olan bağımsız değişkenler şunlardır: Diğer Uyruklar, Diğer İller, İstanbul, Almanya, İran, Ankara, Kazakistan, Antalya, Mısır, Irak, Yalova, Ürdün, Azerbaycan, Ukrayna, Sakarya, Afganistan. Bağımlı değişken “Yabancı Konut Satışı”

ile arasında zayıf pozitif yönlü korelasyon olan bağımsız değişkenler şunlardır: Gayrisafi büyüme hızı, yapı ruhsatlı yüz ölçüm metrekaresi, konut fiyat endeksi, borsa endeksi. Bağımlı değişken “Yabancı Konut Satışı” ile arasında zayıf negatif yönlü korelasyon olan bağımsız değişkenler şunlardır: Yapı kullanım izinli yüz ölçüm metrekaresi, yapı kullanım izni verilen bina sayısı, yapı kullanım izni verilen daire sayısı, yapı ruhsatı verilen bina sayısı, yapı ruhsatı verilen daire sayısı.

İkinci veri setinde, bağımlı değişken “Yabancı Konut Satışı” ile arasında güçlü pozitif yönlü korelasyon olan bağımsız değişkenlerin ilişkilerinin yönünü görsel olarak belirlemek için çizilen saçılım grafikleri Şekil 13’te gösterilmektedir.



**Şekil 13.** İkinci Veri Setinde Yabancı Konut Satışı ile Arasında Güçlü Korelasyon Olan Bağımsız Değişkenlerin Saçılım Grafikleri



Şekil 13'te yer alan saçılım grafikleri incelendiği zaman, bağımlı değişken yabancı konut satışı ile diğer uyruklar, diğer iller, İstanbul, Almanya, İran, Ankara, Kazakistan, Antalya, Mısır, Irak, Yalova, Ürdün, Azerbaycan, Ukrayna, Sakarya bağımsız değişkenleri arasında doğrusal bir ilişki olduğu saptanmıştır. Yatay ekseninde bağımsız değişkeninin değerleri; dikey ekseninde ise bağımlı değişken yabancı konut satışı değişkeninin değerleri yer almaktadır. Her bir grafik ayrı ayrı incelendiği zaman, söz konusu bağımsız değişkenlerin değerleri arttıkça, Yabancı Konut Satışının da arttığı görülmektedir. Şekil 13'te grafiklerde, saçılım hayali bir doğru etrafında kümelenmiş olarak görülmektedir. Bu durum, bağımlı değişken yabancı konut satışı ile sırasıyla diğer uyruklar, diğer iller, İstanbul, Almanya, İran, Ankara, Kazakistan, Antalya, Mısır, Irak, Yalova, Ürdün, Azerbaycan, Ukrayna, Sakarya bağımsız değişkenleri arasında güçlü bir ilişki olduğunu ortaya koymuştur.

Belirleme katsayısı ( $R^2$ ) değerini düşüren değişkenler belirlenip, veri setinden çıkarılmıştır. Buna göre, “Gayrisafi Büyüme Hızı”, “Konut Fiyat Endeksi”, “Borsa Endeksi”, “Yapı Ruhsatı Verilen Bina Sayısı”, “Yapı Ruhsatı Verilen Daire Sayısı”, “Yapı Ruhsatlı Yüz Ölçüm Metrekaresi”, “Yapı Kullanım İzni Verilen Bina Sayısı”, “Yapı Kullanım İzni Verilen Daire Sayısı”, “Yapı Kullanım İzinli Yüz Ölçüm Metrekaresi”, “Belirsizlik Endeksi” bağımsız değişkenlerden çıkarılmıştır. Söz konusu değişkenler veri setinden çıkarıldıktan sonra, ikinci veri setinin bağımsız değişkenlerinin mevcut olduğu veri seti Ek 11’de yer almaktadır.

Değişkenler belirlendikten sonra, ilk olarak k katlamalı çapraz doğrulama ile veri seti eğitim ve test kümelerine ayrılmıştır. K değeri 3 olarak alınmıştır. Çoklu Doğrusal Regresyon modeli kurulduktan sonra modelin performans değerlerini hesaplanmıştır.

**Tablo 9.** Çoklu Doğrusal Regresyon Yönteminin Performans Değerleri

RMSE (Root Mean Square Error-Hata Kareler Ortalamasının Karekökü)	20.84
Belirleme Katsayısı ( $R^2$ )	0.9999
MAE (Mean Absolute Error-Hatanın Mutlak Ortalaması)	12.55
MAPE (Mean Absolute Percentage Error-Ortalama Mutlak Yüzde Hata)	0.0041

MSE (Mean Squared Error-Hata Kareler Ortalaması)	434.27
--	--------

Tablo 9’da çoklu doğrusal regresyon yöntemi uygulanması sonucunda, yabancılara konut satışı tahmin modelinin performans değerleri verilmektedir. Hata kareler ortalamasının karekökü 20.84, hatanın mutlak ortalaması 12.55, hata kareler ortalaması 434.27, ortalama mutlak yüzde hata 0.0041 olarak saptanmıştır. Belirleme katsayısı 0.9999 olarak saptanmıştır.

### 3.2.2.2. Karar ağacı regresyon yöntemine göre performansların belirlenmesi

Karar Ağacı Regresyon modelini kurmak, analizi gerçekleştirmek ve modelin performans ölçütlerini belirlemek için Ek-5’te yer alan gerekli kütüphaneleri Python’da çağırıp içe aktarım gerçekleştirilmiştir. Sonrasında k katlamalı çapraz doğrulama ile veri seti eğitim ve test kümelerine ayrılmıştır. K değeri 3 olarak alınmıştır. Karar Ağacı Regresyon modelini kurduktan sonra modelin performans değerleri hesaplanmıştır.

**Tablo 10.** Karar Ağacı Regresyon Yönteminin Performans Değerleri

RMSE (Root Mean Square Error-Hata Kareler Ortalamasının Karekökü)	624.99
Belirleme Katsayısı ( $R^2$ )	0.2332
MAE (Mean Absolute Error-Hatanın Mutlak Ortalaması)	394.34
MAPE (Mean Absolute Percentage Error-Ortalama Mutlak Yüzde Hata)	0.1186
MSE (Mean Squared Error-Hata Kareler Ortalaması)	381197.40

Tablo 10’da karar ağacı regresyon yöntemi uygulanması sonucunda, yabancılara konut satışı tahmin modelinin performans değerleri verilmektedir. Hata kareler ortalamasının karekökü 624.99, hatanın mutlak ortalaması 394.34, hata kareler ortalaması 381197.40, ortalama mutlak yüzde hata 0.1186 olarak saptanmıştır. Belirleme katsayısı 0.2332 olarak saptanmıştır.

### 3.2.2.3. Rastgele orman regresyon yöntemine göre performansların belirlenmesi

Rastgele Orman Regresyon modelini kurmak, analizi gerçekleştirmek ve modelin performans ölçütlerini belirlemek için Ek-6'da yer alan gerekli kütüphaneleri Python'da çağırıp içe aktarım gerçekleştirilmiştir. Sonrasında k katlamalı çapraz doğrulama ile veri seti eğitim ve test kümelerine ayrılmıştır. K değeri 3 olarak alınmıştır. Rastgele Orman Regresyon modelini kurduktan sonra modelin performans değerleri hesaplanmıştır.

**Tablo 11.** Rastgele Orman Regresyon Yönteminin Performans Değerleri

RMSE (Root Mean Square Error-Hata Kareler Ortalamasının Karekökü)	636.57
Belirleme Katsayısı ( $R^2$ )	0.5817
MAE (Mean Absolute Error-Hatanın Mutlak Ortalaması)	484.59
MAPE (Mean Absolute Percentage Error-Ortalama Mutlak Yüzde Hata)	0.1427
MSE (Mean Squared Error-Hata Kareler Ortalaması)	655709.0572

Tablo 11'de rastgele orman regresyon yöntemi uygulanması sonucunda, yabancılara konut satışı tahmin modelinin performans değerleri verilmektedir. Hata kareler ortalamasının karekökü 636.57, hatanın mutlak ortalaması 484.59, hata kareler ortalaması 655709.0572, ortalama mutlak yüzde hata 0.1427 olarak saptanmıştır. Belirleme katsayısı 0.5817 olarak saptanmıştır.

### 3.2.2.4. Çok katmanlı yapay sinir ağı yöntemine göre performansların belirlenmesi

Çok Katmanlı Yapay Sinir Ağı modelini kurmak, analizi gerçekleştirmek ve modelin performans ölçütlerini belirlemek için Ek-7'de yer alan gerekli kütüphaneleri Python'da çağırıp içe aktarım gerçekleştirilmiştir. Sonrasında k katlamalı çapraz doğrulama ile veri seti eğitim ve test kümelerine ayrılmıştır. K değeri 3 olarak

alınmıştır. Çok Katmanlı Yapay Sinir Ağı modelini kurduktan sonra modelin performans değerleri hesaplanmıştır.

**Tablo 12.** Çok Katmanlı Yapay Sinir Ağı Yönteminin Performans Değerleri

RMSE (Root Mean Square Error-Hata Kareler Ortalamasının Karekökü)	1209.95
Belirleme Katsayısı ( $R^2$ )	0.0459
MAE (Mean Absolute Error-Hatanın Mutlak Ortalaması)	1318.20
MAPE (Mean Absolute Percentage Error-Ortalama Mutlak Yüzde Hata)	25.1490
MSE (Mean Squared Error-Hata Kareler Ortalaması)	1777608.12

Tablo 12’de çok katmanlı yapay sinir ağı yöntemi uygulanması sonucunda, yabancılara konut satışı tahmin modelinin performans değerleri verilmektedir. Hata kareler ortalamasının karekökü 1209.95, hatanın mutlak ortalaması 1318.20, hata kareler ortalaması 1777608.12, ortalama mutlak yüzde hata 25.1490 olarak saptanmıştır. Belirleme katsayısı 0.0459 olarak saptanmıştır.

### 3.3. Makine Öğrenmesi Yöntemlerinin Analizlerinin Değerlendirilmesi

Çalışma iki veri seti üzerinden yapılmıştır. Birinci veri setinde, illere göre yabancılara yapılan konut satış sayıları dikkate alınmıştır. İkinci veri setinde, illere ve ülke uyruklarına göre yabancılara yapılan konut satış sayıları dikkate alınmıştır.

İlk olarak, illere göre yabancı konut satış sayılarının dahil olduğu birinci veri seti kullanılmıştır. Birinci veri setinde uygulanan Çoklu Doğrusal Regresyon, Karar Ağacı Regresyon, Rastgele Orman Regresyon, Çok Katmanlı Yapay Sinir Ağı yöntemlerinin model performans değerleri Tablo 13’te yer almaktadır.

**Tablo 13.** Veri Setinde İller Mevcutken Yapılan Analizlerin Sonuçları

	Çoklu Doğrusal Regresyon	Çok Katmanlı Yapay Sinir Ağı	Karar Ağacı Regresyon	Rastgele Orman Regresyon
R <sup>2</sup>	0.9877	0.2957	0.5129	0.6978
RMSE (Hata Kareler Ortalamasının Karekökü)	177.41	588.54	490.29	581.32
MAE (Hatanın Mutlak Ortalaması)	71.79	464.83	299.22	406.85
MSE (Hata Kareler Ortalaması)	31473.04	2242823.11	238759.56	509966.24
MAPE (Ortalama Mutlak Yüzde Hata)	0.0196	31.8262	0.1450	0.1454

Tablo 13'te değerler incelendiği zaman, Çoklu Doğrusal Regresyon modelinin belirleme katsayısının (R<sup>2</sup>) (0.9877), 1 değerine daha yakın olduğu görülmektedir. Çoklu Doğrusal Regresyon modelinin belirleme katsayısının Yabancılar Konut Satışındaki değişkenliği açıklama oranı, diğer yöntemlere göre daha yüksektir. Ayrıca, belirleme katsayısının çok yüksek olduğu görülmüştür. Bu duruma çoklu bağlantı problemi yol açmış olabilir. Modelimizi çalıştırmak ve sonuçlarını değerlendirebilmek adına, çoklu bağlantı problemini gidermek için yapılabilecek Ridge ve Robust regresyonları çalıştırılmamıştır. Çoklu Doğrusal Regresyon modelinin belirleme katsayısını sırasıyla Rastgele Orman Regresyon (0.6978), Karar Ağacı Regresyon (0.5129), Çok Katmanlı Yapay Sinir Ağı (0.2957) yöntemlerinin belirleme katsayıları takip etmektedir. Hata Kareler Ortalamasının Karekökünün, Hatanın Mutlak Ortalamasının, Hata Kareler Ortalamasının 0 olması hata olmadığı anlamına geldiği için, bu değerlerin 0'a yakın bir değer olması beklenmektedir. Bu değerler incelendiği zaman 0'a en yakın hata değerlerini Çoklu Doğrusal Regresyon yöntemi göstermektedir.

Onu sırasıyla Karar Ağacı Regresyon, Rastgele Orman Regresyon, Çok Katmanlı Yapay Sinir Ağı yöntemlerinin hata değerleri takip etmektedir. Yöntemlerin Ortalama Mutlak Yüzde Hata değerleri incelendiği zaman Çoklu Doğrusal Regresyon

modeli için hesaplanan MAPE değeri mükemmel olarak yorumlanmaktadır. Rastgele Orman Regresyon ve Karar Ağacı Regresyon modelleri için hesaplanan MAPE değerleri iyi olarak değerlendirilebilir. Çok Katmanlı Yapay Sinir Ağı modeli için hesaplanan MAPE değeri kabul edilebilir olarak yorumlanmaktadır.

İkinci veri seti olarak, illere ve ülke uyruklarına göre yabancı konut satış sayılarının dahil olduğu veri seti kullanılmıştır. İkinci veri setinde uygulanan Çoklu Doğrusal Regresyon, Karar Ağacı Regresyon, Rastgele Orman Regresyon, Çok Katmanlı Yapay Sinir Ağı yöntemlerinin model performans değerleri Tablo 14'te yer almaktadır.

**Tablo 14.** Veri Setinde İller ve Uyruklar Mevcutken Yapılan Analizlerin Sonuçları

	Çoklu Doğrusal Regresyon	Çok Katmanlı Yapay Sinir Ağı	Karar Ağacı Regresyon	Rastgele Orman Regresyon
R <sup>2</sup>	0.9999	0.0459	0.2332	0.5817
RMSE (Hata Kareler Ortalamasının Karekökü)	20.84	1209.95	624.99	636.57
MAE (Hatanın Mutlak Ortalaması)	12.55	1318.20	394.34	484.59
MSE (Hata Kareler Ortalaması)	434.27	1777608.12	381197.40	655709.06
MAPE (Ortalama Mutlak Yüzde Hata)	0.0041	25.1490	0.1186	0.1427

Tablo 14'te değerler incelendiği zaman, Çoklu Doğrusal Regresyon modelinin belirleme katsayısının ( $R^2$ ) 0.9999, 1 değerine daha yakın olduğu görülmektedir. Çoklu Doğrusal Regresyon modelinin belirleme katsayısının Yabancılara Konut Satışındaki değişkenliği açıklama oranı, diğer yöntemlere göre daha yüksektir. Ayrıca, belirleme katsayısının çok yüksek olduğu görülmüştür. Bu duruma çoklu bağlantı problemi yol açmış olabilir. Modelimizi çalıştırmak ve sonuçlarını değerlendirebilmek adına, çoklu bağlantı problemini gidermek için yapılabilecek Ridge ve Robust regresyonları çalıştırılmamıştır. Çoklu Doğrusal Regresyon modelinin belirleme katsayısını sırasıyla Rastgele Orman Regresyon (0.5817), Karar Ağacı Regresyon (0.2332), Çok Katmanlı Yapay Sinir Ağı (0.0459) yöntemlerinin belirleme katsayıları takip etmektedir. Hata Kareler Ortalamasının Karekökünün, Hatanın Mutlak Ortalamasının, Hata Kareler

Ortalamasının 0 olması hata olmadığı anlamına geldiği için, bu değerlerin 0'a yakın bir değer olması beklenmektedir. Bu değerler incelendiği zaman 0'a en yakın hata değerlerini Çoklu Doğrusal Regresyon yöntemi göstermektedir. Onu sırasıyla Karar Ağacı Regresyon, Rastgele Orman Regresyon, Çok Katmanlı Yapay Sinir Ağı yöntemlerinin hata değerleri takip etmektedir. Yöntemlerin Ortalama Mutlak Yüzde Hata değerleri incelendiği zaman Çoklu Doğrusal Regresyon modeli için hesaplanan MAPE değeri mükemmel olarak yorumlanmaktadır. Karar Ağacı Regresyon ve Rastgele Orman Regresyon modeli için hesaplanan MAPE değerleri iyi olarak değerlendirilebilir. Çok Katmanlı Yapay Sinir Ağı modeli için hesaplanan MAPE değeri kabul edilebilir olarak yorumlanmaktadır.

Çalışmada kullanılan makine öğrenmesi yöntemlerinin model performansları değerlendirildiğinde, her iki veri setinde de Çoklu Doğrusal Regresyon modelinin belirleme katsayısı diğer yöntemlere göre daha yüksektir. Bir başka deyişle, Çoklu Doğrusal Regresyon modelinin belirleme katsayısının, yabancılara konut satışındaki değişkenliği açıklama gücü diğer yöntemlere göre daha yüksektir. Ayrıca hata kareler ortalamasının karekökü, hatanın mutlak ortalaması, hata kareler ortalaması ve ortalama mutlak yüzde hata değerleri diğer yöntemlere göre daha düşüktür. Dolayısıyla, her iki veri setinde de yabancı konut satışı tahmininde, Çoklu Doğrusal Regresyon yönteminin daha iyi performans gösterdiği saptanmıştır. Çalışmada kullanılan performans ölçütlerine göre, ikinci iyi performans gösteren yöntem rastgele orman regresyon yöntemidir.

## SONUÇ

Ülkemizde konut sektöründe son yıllarda hızlı bir artış yaşanmaktadır. Konut satışının içerisinde yer alan yabancılara konut satışında da oldukça önemli bir artış görülmektedir. Bu hususta asıl önemli olan konut arz ve talep dengesini koruyabilmektir. Bunun için de konut talebini iyi bir şekilde tahmin etmek önemli bir hale gelmektedir. Dolayısıyla, yabancılara yapılan konut satışının tahmin modelini oluşturmak da oldukça önem arz etmektedir.

Yabancı Konut Satışını en iyi tahminde bulunmak ülkemiz için oldukça önemli bir konudur. Döviz katkısı, diğer ülkelerde olduğu gibi ülkemizin ulusal ekonomisinde de önemli bir rol üstlenmektedir (Alamsyah ve Friscintia, 2019: 1). Yapılan bir çalışmada, yabancı konut satışındaki artışın turist talebinde pozitif bir etkisi olacağı şeklinde bir sonuca yaklaşılmıştır (Çiftçi ve Arı, 2019: 487). Diğer bir çalışmada, yabancı konut yatırımlarından turizm gelirleri ve turist sayısına doğru tek yönlü nedensellik bulunmuştur. Yabancı konut yatırımları ile turizm arasında ilişki olduğu sonucuna ulaşılmıştır (Şit ve Karadağ, 2018: 115). Elbette yabancılara yapılan konut satışının da turizm talebinin artmasının da ülkemiz için önemi büyüktür.

Yabancılara konut satışı tahmin modelini oluşturmak için talep tahmin yöntemleri gözden geçirilmiştir. Ancak literatürde yabancılara konut satışı tahmini konusunda yapılan çalışmalar oldukça kısıtlıdır. Talep tahmin yöntemleri ile ilgili literatür incelendiğinde istatistiksel yöntemlerin yanı sıra son yıllarda özellikle makine öğrenmesi yöntemlerinin daha sık kullanıldığı saptanmıştır. Bu sebeple, çalışmada makine öğrenmesi yöntemleri olan Çoklu Doğrusal Regresyon, Çok Katmanlı Yapay Sinir Ağı, Karar Ağacı Regresyon, Rastgele Orman Regresyon kullanılmıştır. Yabancı Konut Satışı tahmin modellerinin analizi sonucunda; söz konusu yöntemlerin tahmin performansları karşılaştırılarak, en uygun tahmini yapan makine öğrenmesi yöntemine ulaşılması amaçlanmıştır.

Çalışmada, Türkiye’de Yabancılara Konut Satışı tahmininde makine öğrenmesi yöntemleri uygulanıp, performans değerleri göz önünde bulundurularak söz konusu yöntemler arasında karşılaştırma yapılmıştır. Model doğrulaması için, k katlamalı çapraz doğrulama yöntemi kullanılmıştır. Ayrıca, yöntemlerin model performanslarının değerlendirilmesinde belirleme katsayısı, hata kareler ortalamasının karekökü, hatanın mutlak ortalaması, hata kareler ortalaması ve ortalama mutlak yüzde hata kullanılmıştır.



İki farklı veri seti kullanılarak, Python programında makine öğrenmesi yöntemlerinden Çoklu Doğrusal Regresyon, Rastgele Orman Regresyon, Karar Ağacı Regresyon, Çok Katmanlı Yapay Sinir Ağı modeli kurulmuştur. Yöntemlerin karşılaştırılmasında dikkate alınan performans değerlendirilmesi için Belirleme Katsayısı, Hata Kareler Ortalamasının Karekökü, Hatanın Mutlak Ortalaması, Hata Kareler Ortalaması ve Ortalama Mutlak Yüzde Hata değerleri hesaplanmıştır. Uygulama sonucunda en uygun tahmin yöntemine ulaşılması hedeflenmiştir.

Çalışmada Yabancı Konut Satışı tahmin modellerinde kullanılan değişkenler belirlenirken literatür taraması sonucunda döviz kuru değişkeni verilerde yer almıştır. Literatürdeki çalışmalar göz önüne alındığında, döviz kurundaki artışın yabancı konut talebi üzerinde olumlu bir etkisi olduğu görülmüştür (Yanar ve Demir, 2022: 295; Özaktaş, 2019: 131; Süleymanlı, 2019: 118; Davids, 2020: 1). Bu sebeple euro ,dolar, sterlin bağımsız değişkenler olarak çalışmada kullanılmıştır. Bir başka bağımsız değişken olarak çalışmada kullanılan “Konut Fiyat Endeksi” ile ilgili literatürdeki çalışmalar incelendiği zaman, konut satışı ve turizm talebi ile konut fiyat endeksi arasında olumlu bir ilişki olduğu görülmektedir (Akay vd. 2023; Alamsyah ve Friscintia, 2019). Yılmaz ve Yücememiş (2022) çalışmasında, konut talebinin üzerinde etkili değişkenlerin sırasıyla döviz kuru ve enflasyon olduğu sonucuna ulaşmıştır. Bu sebeple, enflasyon çalışmamızda bağımsız değişken olarak yer almıştır. Bunların dışında yabancıya konut satışına etki edebileceğini düşündüğümüz başka faktörlerde çalışmaya bağımsız değişken olarak dahil edilmiştir.

Çalışma iki veri setinden oluşmaktadır. Birinci veri setinde, illere göre yabancılara yapılan konut satış sayıları dikkate alınmıştır. İkinci veri setinde, illere ve ülke uyruklarına göre yabancılara yapılan konut satış sayıları dikkate alınmıştır.

Birinci veri seti, 2013-2023 yılları arasında 12 aylık periyotlardan oluşmaktadır. Yalnız 2023 yılı verileri, ilk 6 ayı kapsamaktadır. Bu veri setinde bağımlı değişken “Yabancılara Konut Satışı”dır. Bağımsız değişkenler: “Tüm Konut Satışları”, “Dolar”, “Euro”, “Sterlin”, “Altın”, “Gayrisafi Büyüme Hızı”, “Enflasyon”, “Borsa Endeksi”, “Konut Fiyat Endeksi”, “Yapı Ruhsatlı Bina Sayısı”, “Yapı Ruhsatlı Daire Sayısı”, “Yapı Ruhsatlı Yüz Ölçüm Metrekaresi”, “Yapı Kullanım İzni Verilen Bina Sayısı”, “Yapı Kullanım İzni Verilen Daire Sayısı”, “Yapı Kullanım İzinli Yüz Ölçüm Metrekaresi”, “Belirsizlik Endeksi”, “İllere Göre Yabancılara Yapılan Konut Satış

Sayıları (İstanbul, Antalya, Bursa, Yalova, Sakarya, Diğer İller). Bağımlı değişken “Yabancı Konut Satışı” ile arasında güçlü korelasyon olan bağımsız değişkenler diğer iller, İstanbul, Ankara, Antalya, Yalova, Sakarya’dır. “Gayrisafi Büyüme Hızı”, “Yapı Ruhsatı Verilen Bina Sayısı”, “Yapı Ruhsatı Verilen Daire Sayısı”, “Yapı Ruhsatlı Yüz Ölçüm Metrekaresi”, “Yapı Kullanım İzni Verilen Bina Sayısı”, “Yapı Kullanım İzni Verilen Daire Sayısı”, “Yapı Kullanım İzinli Yüz Ölçüm Metrekaresi”, “Belirsizlik Endeksi” bağımsız değişkenlerden çıkarılmıştır. Bu değişkenler bağımsız değişkenlerden çıkarıldığında, yöntemlerin performans değerlerinin daha iyi sonuçlar verdiğine ulaşılmıştır.

İkinci veri seti, 2015-2023 yılları arasında 12 aylık periyotlardan oluşmaktadır. Yalnız 2023 yılı verileri, ilk 6 ayı kapsamaktadır. Bu veri setinde bağımlı değişken “Yabancılara Konut Satışı”dır. Bağımsız değişkenler: “Tüm Konut Satışları”, “Dolar”, “Euro”, “Sterlin”, “Altın”, “Gayrisafi Büyüme Hızı”, “Enflasyon”, “Borsa Endeksi”, “Konut Fiyat Endeksi”, “Yapı Ruhsatlı Bina Sayısı”, “Yapı Ruhsatlı Daire Sayısı”, “Yapı Ruhsatlı Yüz Ölçüm Metrekaresi”, “Yapı Kullanım İzni Verilen Bina Sayısı”, “Yapı Kullanım İzni Verilen Daire Sayısı”, “Yapı Kullanım İzinli Yüz Ölçüm Metrekaresi”, “Belirsizlik Endeksi”, “İllere Göre Yabancılara Yapılan Konut Satış Sayıları (İstanbul, Antalya, Bursa, Yalova, Sakarya, Diğer İller), “Ülke Uyruklarına Göre Yabancılara Yapılan Konut Satış Sayıları (Irak, Kuveyt, Rusya Federasyonu, İngiltere, Almanya, Azerbaycan, İran, Afganistan, Ukrayna, Kazakistan, Mısır, Ürdün, Diğer Uyruklar). Bağımlı değişken “Yabancı Konut Satışı” ile arasında güçlü korelasyon olan bağımsız değişkenler Diğer Uyruklar, Diğer İller, İstanbul, Almanya, İran, Ankara, Kazakistan, Antalya, Mısır, Irak, Yalova, Ürdün, Azerbaycan, Ukrayna, Sakarya, Afganistan’dır. “Gayrisafi Büyüme Hızı”, “Konut Fiyat Endeksi”, “Borsa Endeksi”, “Yapı Ruhsatı Verilen Bina Sayısı”, “Yapı Ruhsatı Verilen Daire Sayısı”, “Yapı Ruhsatlı Yüz Ölçüm Metrekaresi”, “Yapı Kullanım İzni Verilen Bina Sayısı”, “Yapı Kullanım İzni Verilen Daire Sayısı”, “Yapı Kullanım İzinli Yüz Ölçüm Metrekaresi”, “Belirsizlik Endeksi” bağımsız değişkenlerden çıkarılmıştır. Bu değişkenler çıkarıldığında, yöntemlerin performans değerlerinin daha iyi sonuçlar verdiğine ulaşılmıştır.

Değişkenler belirlendikten sonra,  $k=3$  katlamalı çapraz doğrulama ile veri seti eğitim ve test kümelerine ayrılmıştır. Daha sonra yöntemlerin kodları yazılarak modeller kurulmuştur. Söz konusu yöntemlerin performans değerleri hesaplanmıştır.

İllere göre yabancılara yapılan konut satış sayılarının da mevcut olduğu birinci veri setinde uygulanan yöntemlerin performans değerleri karşılaştırıldığında, en uygun tahmin yönteminin Çoklu Doğrusal Regresyon olduğu sonucuna ulaşılmıştır.

İllere göre yabancılara yapılan konut satış sayıları ve ülke uyruklarına göre yabancılara yapılan konut satış sayılarının da mevcut olduğu ikinci veri setinde, yöntemlerin performans değerleri karşılaştırıldığında, en uygun tahmin yönteminin Çoklu Doğrusal Regresyon olduğu sonucuna ulaşılmıştır.

Literatür incelendiği zaman, daha çok konut fiyatlarının tahmininde makine öğrenmesi yöntemlerinin karşılaştırıldığı görülmektedir. Rossini (1997) çalışmasında konut satış fiyatlarının analizinde çoklu regresyon ve yapay sinir ağları yöntemlerini karşılaştırmıştır. Çoklu regresyon analizinin daha yüksek doğruluk oranı gösterdiği tespit edilmiştir. Gülağız ve Ekinici (2017) çalışmasında konut fiyatlarının tahmini amacıyla doğrusal regresyon, karar ağacı regresyon ve rastgele orman regresyon yöntemlerini karşılaştırmıştır. Doğrusal regresyon yöntemi diğer yöntemlere göre daha doğru bir konut fiyat tahmini gerçekleştirmiştir. Aydemir vd. (2020) çalışmasında konut fiyat tahmini için on dört farklı algoritma kullanmıştır. En başarılı konut fiyat tahminine Rastgele Orman Algoritması uygulayarak ulaşmıştır. Burhan (2023) çalışmasında Naive Bayes, k-En Yakın Komşu, Karar Ağaçları ve Rastgele Orman analizleri gerçekleştirmiştir. Konut fiyat tahmininde en başarılı yöntemin Rastgele Orman olduğu sonucuna ulaşmıştır.

Bir başka alan olan sağlık harcaması tahmini ile ilgili yapılan bir çalışmada regresyon yöntemlerinin performans sonuçları karşılaştırılmıştır. Rastgele Ağaç Regresyonun diğer yöntemlere göre daha iyi tahmin sonuçlarına sahip olduğu sonucuna ulaşılmıştır (Çınaroğlu, 2017: 179).

Çalışmada, Yabancı Konut Satışı alanında dört makine öğrenmesi yönteminin karşılaştırılması sonucunda, Çoklu Doğrusal Regresyon yönteminin diğer yöntemlere göre daha doğru bir tahmin gerçekleştirdiği saptanmıştır. Diğer önemli bir bulgu da Yabancı Konut Satışı tahmininde Rastgele Orman Regresyonun Çoklu Doğrusal Regresyondan sonra en iyi belirleme katsayısı değerine sahip ikinci yöntem olduğu sonucuna ulaşılmıştır. Literatürdeki çalışmalarla karşılaştırma yapıldığı zaman, söz konusu çalışmalarla benzer doğrultuda sonuçlara ulaşılmıştır.

Çalışmanın bazı kısıtları mevcuttur. Ulaşılabilen sınırlı veri sayısından dolayı çalışmada veri bulunması konusunda zorluk yaşanmıştır. Gözlemlerin sınırlı olması, veri yeterliliği açısından makine öğrenmesi yöntemlerinin çalışması hususunda kısıt oluşturmuştur.

Gelecek çalışmalarda, çalışmada önerilen yöntemin performansını arttırabileceği düşünülen sosyal ya da kültürel bağımsız değişkenler çalışmaya dahil edilerek, yabancı konut satışı tahminin daha farklı gerçekleştirilmesine imkan sağlanabilir. Öte yandan çalışmada kullanılan makine öğrenmesi yöntemlerinin yanı sıra literatürde yer alan diğer makine öğrenmesi yöntemleri uygulanarak daha farklı sonuçlara ulaşılabilir.

## KAYNAKLAR

- Abbaspour Ghadım Bonab, A. (2022). “A Comparative Study of Demand Forecasting Based on Machine Learning Methods with Time Series Approach, Journal of Applied Research on Industrial Engineering, Cilt. 9, Sayı. 3, s. 331-353.
- Adıyaman, F. (2007). “Talep Tahmininde Yapay Sinir Ağlarının Kullanılması”, Tez (Yüksek Lisans Tezi), İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- Aikeshan, A. (2014). “Bulanık Doğrusal Regresyon Yöntemi İle Talep Tahmini: Medikal Asistans Firmasında Bir Uygulama”, Tez (Yüksek Lisans Tezi), İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- Akay, M. K.; Kaya, Z. S.; Günkut, M. Ş. (2023). “Veri Madenciliği: Konut Fiyat Endeksi ve Konut Satış Sayılarının Basit Doğrusal Regresyon Analizi”, Ekonomi Bilimleri Dergisi, Cilt. 15, No. 1, s. 25-44.
- Akgül, S. (2013). “Yapay Sinir Ağları İle Türkiye Elektrik Enerjisi Talep Tahmini ve Diğer Yöntemlerle Karşılaştırmalı Analizi”, Tez (Doktora Tezi), Atatürk Üniversitesi, Sosyal Bilimler Enstitüsü.
- Alamsyah, A.; Friscintia, P. B. A. (2019). “Artificial Neural Network for Indonesian Tourism Demand Forecasting”, 7th International Conference on Information and Communication Technology (ICoICT), IEEE, s. 1-7.
- Alcan, Ö.; Alcan, Y.; Demir, M.; Öztürk, Z. (2017). “Sinop İli Turizm Talebinin Yapay Sinir Ağları Yöntemiyle Tahmini” UMTEB- International Congress on Vocational and Technical Sciences Batumi-Georgia, April, s. 952-963.
- Alkan, U. (2022). “Main Determinants of House Prices: Effects of Construction Cost and House Sales to Foreigners”, Business & Management Studies: An International Journal, Cilt. 10, Sayı. 4, s. 1512-1528.
- Alon, I.; Qi, M.; Sadowski, R. J. (2001). “Forecasting Aggregate Retail Sales: A Comparison of Artificial Neural Networks and Traditional Methods”, Journal of Retailing and Consumer Services, Cilt. 8, Sayı. 3, s. 147-156.
- Alpar, R. (2003). Uygulamalı Çok Değişkenli İstatistiksel Yöntemlere Giriş 1, Nobel Yayın Dağıtım, Ankara.

- Al-Shayea, Q. K. (2011). "Artificial Neural Networks in Medical Diagnosis", *International Journal of Computer Science Issues*, Cilt. 8, Sayı. 2, s. 150-154.
- Arı, A.; Berberler, M. E. (2017). "Yapay Sinir Ağları ile Tahmin ve Sınıflandırma Problemlerinin Çözümü İçin Arayüz Tasarımı", *Acta Infologica*, Cilt. 1, Sayı. 2, s. 55-73.
- Armstrong, J. S. (2001). "Evaluating Forecasting Methods", *Principles of Forecasting: A Handbook for Researchers and Practitioners*, s. 443-472.
- Armstrong, J. S. (2001). *Selecting Forecasting Methods*, Springer US.
- Armstrong, J. S.; Kesten C. G. (2005). "Demand Forecasting: Evidence-Based Methods", No. 24/05, Monash University, Department of Econometrics and Business Statistics, s. 1-23.
- Aydemir, E.; Aktürk, C.; Yalçınkaya, M. A. (2020). "Yapay Zekâ ile Konut Fiyatlarının Tahmin Edilmesi", *Turkish Studies*, Cilt. 15, Sayı. 2, s. 183-194.
- Aydın, M. Ç. (2017). "Giyim Endüstrisinde Talep Tahmin Yöntemlerinin Uygulanması: Örnek Bir Uygulama", Tez (Doktora Tezi) Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü.
- Baker, J. R.; Fitzpatrick, K. E. (1986). "Determination of An Optimal Forecast Model for Ambulance Demand Using Goal Programming", *Journal of Operational Research Society*, Cilt. 37, Sayı. 11, s. 1047-1059.
- Ballı, M. T. (2014). "Yapay Sinir Ağları ile Talep Tahmini ve Gıda Sektöründe Uygulanması", Tez (Yüksek Lisans) - Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- Beale, M. H.; Hagan, M. T.; Demuth, H. B. (1992). "Neural Network Toolbox User's Guide", The MathWorks Inc, 103.
- Blockeel, H.; Struyf, J. (2002). "Efficient Algorithms for Decision Tree Cross-Validation", *Journal of Machine Learning Research*, 3.Dec, s. 621-650.
- Bhattacharya, M. N. (1974). "Forecasting the Demand for Telephones in Australia", *Applied Statistics*, Cilt. 23, Sayı. 1, s. 1-10.

- Bini, S. A. (2018). "Artificial Intelligence, Machine Learning, Deep Learning, And Cognitive Computing: What Do These Terms Mean And How Will They Impact Health Care?" *The Journal Of Arthroplasty*, Cilt. 33, Sayı. 8, s. 2358-2361.
- Breiman, L. (2001). "Random Forests", *Machine Learning*, Cilt. 45, s. 5-32.
- Brown, S. H. (2009). "Multiple Linear Regression Analysis: A Matrix Approach with MATLAB", *Alabama Journal of Mathematics*, Cilt. 34, s. 1-3.
- Bulut, Ş. (2006). "Orta Ölçekli Bir İşletmede Talep Tahmin Yöntemlerinin Uygulanması", *Kırıkkale Üniversitesi, Tez (Yüksek Lisans Tezi) Fen Bilimleri Enstitüsü*.
- Burger, C. J. S. C.; Dohnal, M.; Kathrada, M. ve Law, R. (2001). "A Practitioners Guide to Time-Series Methods for Tourism Demand Forecasting- A Case Study of Durban, South Africa", *Tourism Management*, Cilt. 22, Sayı. 4, s. 403-409.
- Burhan, H. A. (2023). "Konut Fiyatları Tahmininde Makine Öğrenmesi Sınıflandırma Algoritmalarının Kullanılması: Kütahya Kent Merkezi Örneği", *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, Sayı. 76, s. 221-237.
- Caldwell, J. G. (2006). "The Box-Jenkins Forecasting Technique", *Reformatted September*.
- Çağlar, T. (2007). "Talep Tahmininde Kullanılan Yöntemler ve Fens Teli Üretimi Yapan Bir İşletmede Uygulanması", *Tez (Yüksek Lisans Tezi) Kırıkkale Üniversitesi, Fen Bilimleri Enstitüsü*.
- Çınaroğlu, S. (2017). "Sağlık Harcamasının Tahmininde Makine Öğrenmesi Regresyon Yöntemlerinin Karşılaştırılması", *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, Cilt. 22, Sayı. 2, s. 179-200.
- Çiftçi, A.; Arı, Y. (2019). "Antalya İlinde Yabancılara Satılan Konut Sayısı Üzerine Bir Eş bütünleşme ve VECM Analizi", *Uluslararası Sosyal, Beşeri ve İdari Bilimler Sempozyumu, Alanya*, s. 479-488.
- Carbonell, J. G.; Michalski, R. S.; Mitchell, T. M. (1983). "Machine Learning: A Historical and Methodological Analysis", *AI Magazine*, Cilt. 4, Sayı. 3, s. 69-79.

- Carlson, R. L.; Umble, M. M. (1980). "Statistical Demand Functions for Automobiles and Their Use for Forecasting in an Energy Crisis", *The Journal of Business*, Cilt. 53, Sayı. 2, s. 193-204.
- Chang, Y. F.; Lin, C. J.; Chyan, J. M.; Chen, I. M.; Chang, J. E. (2007). "Multiple Regression Models for the Lower Heating Value of Municipal Solid Waste in Taiwan", *Journal of Environmental Management*, Cilt. 85, Sayı. 4, s. 891-899.
- Chen, K.; Kung, S. H. (1984). "Synthesis of Qualitative and Quantitative Approaches to Long-Range Forecasting", *Technological Forecasting and Social Change*, Cilt. 26, Sayı. 3, s. 255-266.
- Chen, K.; Lei, J. (2018). "Network Cross-Validation for Determining the Number of Communities in Network Data", *Journal of the American Statistical Association*, Cilt. 113, Sayı. 521, s. 241-251.
- Chicco, D.; Warrens, M. J.; Jurman, G. (2021). "The Coefficient of Determination R-Squared is More Informative Than SMAPE, MAE, MAPE, MSE and RMSE in Regression Analysis Evaluation", *Peerj computer science*, 7: e623, s. 1-18.
- Cho, V. (2003). "A Comparison of Three Different Approaches to Tourist Arrival Forecasting", *Tourism Management*, Cilt. 24, Sayı. 3, s. 323-330.
- Choudhury, D. K. (2018). "Market Demand Forecast Method Selection and Application: A Case Study in Hero MotoCorp Ltd.", *IUP Journal of Operations Management*, Cilt. 17, Sayı. 2, s. 7-22.
- Christensen, L. B.; Johnson, R. B; Turner, L. A. (2015). *Research Methods Design and Analysis- Araştırma Yöntemleri Desen ve Analiz 2015*, (Çeviri Editörü: Ahmet Aypay), Anı Yayıncılık, 2. Baskı, Ankara.
- Chu, C. W.; Zhang, G. P. (2003). "A Comparative Study of Linear and Nonlinear Models for Aggregate Retail Sales Forecasting", *International Journal of Production Economics*, Cilt. 86, Sayı. 3, s. 217-231.
- Claveria, O.; Monte, E.; Torra, S. (2015). "Tourism Demand Forecasting with Neural Network Models: Different Ways Of Treating Information", *International Journal of Tourism Research*, Cilt. 17, Sayı. 5, s. 492-500.



- Çuhadar, M.; Kayacan, C. (2005). “Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye'deki Konaklama İşletmeleri Üzerine Bir Deneme”, *Anatolia: Turizm Araştırmaları Dergisi*, Cilt. 16, Sayı. 1, s. 24-30.
- Çuhadar, M. (2013). “Türkiye’ye Yönelik Dış Turizm Talebinin MLP, RBF ve TDNN Yapay Sinir Ağı Mimarileri ile Modellenmesi ve Tahmini: Karşılaştırmalı Bir Analiz”, *Journal of Yasar University*, Cilt. 8, No. 31, s. 5274-5295.
- Çuhadar, M.; Güngör, İ.; Göksu, A. (2009). “Turizm Talebinin Yapay Sinir Ağları ile Tahmini ve Zaman Serisi Yöntemleri ile Karşılaştırmalı Analizi: Antalya İline Yönelik Bir Uygulama”, *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, Cilt. 14, Sayı. 1, s. 99-114.
- Da Silva, I. N.; Spatti, D. H.; Flauzino, R. A.; Liboni, L. H. B.; Dos Reis Alves, S. F. (2017). “Artificial Neural Network Architectures and Training Processes”, In *Artificial neural networks*, Springer, Cham.
- Dangeti, P. (2017). “Statistics For Machine Learning”, Packt Publishing Ltd., Birmingham, UK.
- Davidson, A. (2020). “The Cape of Good Homes: Exchange Rate Depreciations, Foreign Demand and House Prices”, *Foreign Demand and House Prices*, s. 1-64.
- Dayan, P.; Sahani, M.; Deback, G. (1999). “Unsupervised Learning”, *The MIT Encyclopedia of the Cognitive Sciences*, s. 857-859.
- Debes, K.; Koenig, A.; Gross, H. M. (2005). “Transfer Functions in Artificial Neural Networks A Simulation-Based Tutorial”, s. 1-11.
- Deng, L.; Yu, D. (2014). “Deep Learning: Methods and Applications”, *Foundations and Trends® in Signal Processing*, Cilt. 7, No. 3–4, s. 197-387.
- Demirbaş, F. P. (2011). “Kombi Üretiminde Talep Tahmin Yöntemlerinin Uygulanması, Tez (Yüksek Lisans Tezi), Kocaeli Üniversitesi Fen Bilimleri Enstitüsü.
- Deran, A.; Arslan, S.; Köksal, A. G. (2014). “İşletmelerde Lojistik Maliyetlerin Hesaplanması Maden İşletmesinde Uygulama Örneği”, *Eğitim Yayınevi*, Konya.

- Dikici, S.; Altuntaş, V. (2023). “Yapay Sinir Ağları Kullanılarak Protein Katlanması Tanıma”, *Bilişim Teknolojileri Dergisi*, 2023, Cilt. 16, Sayı. 2, s. 95-105.
- Do, T. N. (2015). “Using Local Rules in Random Forests of Decision Trees”, In: *Future Data and Security Engineering: Second International Conference, FDSE 2015, Ho Chi Minh City, Vietnam, November 23-25, Proceedings 2*. Springer International Publishing, s. 32-45.
- Doğan, O. (2016). “Uyarlamalı Sinirsel Bulanık Çıkarım Sisteminin (ANFIS) Talep Tahmini İçin Kullanımı ve Bir Uygulama”, *Dokuz Eylül Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi* Cilt. 31, Sayı. 1, s. 257-288.
- Doğruel, M.; Fırat, S. Ü. (2021). “Veri Madenciliği Karar Ağaçları Kullanarak Ülkelerin İnovasyon Değerlerinin Tahmini ve Doğrusal Regresyon Modeli ile Karşılaştırmalı Bir Uygulama”, *Istanbul Business Research*, Cilt. 50, Sayı. 2, s. 465-493.
- Dongare, A. D.; Kharde, R. R.; Kachare, A. D. (2012). “Introduction to Artificial Neural Network”, *International Journal of Engineering and Innovative Technology (IJEIT)*, Cilt. 2, Sayı. 1, s. 189-194.
- Dou, Z.; Sun, Y.; Zhang, Y.; Wang, T.; Wu, C.; Fan, S. (2021). “Regional Manufacturing Industry Demand Forecasting: A Deep Learning Approach”, *Applied Sciences*, Cilt. 11, Sayı. 13, s. 1-15.
- Du, J.; Guo, W.; Wang, R. (2007). “Tourism Room Occupancy Rate Prediction Based On Neural Network”, In: *International Symposium on Neural Networks*. Springer, Berlin, Heidelberg, s. 80-84.
- Efendigil, T.; Eminler, Ö. M. (2017), “Havacılık Sektöründe Talep Tahminin Önemi: Yolcu Talebi Üzerine Bir Tahmin Modeli”, *Journal of Yaşar University*, Cilt. 12, Tarım ve Gıda Değer Zincirlerinde Yöneylem Araştırmaları ve Endüstri Mühendisliği Özel Sayısı, s. 14-30.
- Etzal, J. A.; Braver, T. S. (2013). “MVPA Permutation Schemes: Permutation Testing in the Land of Cross-Validation”, In: *2013 International Workshop on Pattern Recognition in Neuroimaging, IEEE*, s. 140-143.

- Fernandes, P. O.; Teixeira, J. P.; Ferreira, J. M.; Azevedo, S. G. (2012). "Forecasting Tourism Demand with Artificial Neural Networks", *Tourism & Management Studies*, s. 1017-1019.
- Fetzer, J. H. (1990). "What is Artificial Intelligence? In: *Artificial Intelligence: Its Scope and Limits*". Springer, Dordrecht, s. 3-27.
- Fildes, R. (2006). "The Forecasting Journals and Their Contribution to Forecasting Research: Citation Analysis and Expert Opinion", *International Journal of forecasting*, Cilt. 22, No. 3, s. 415-432.
- Gacar, B. K.; Kocakoç, İ. D. (2020). "Regresyon Analizleri mi Karar Ağaçları mı?", *Celal Bayar University Journal of Social Sciences/Celal Bayar Üniversitesi Sosyal Bilimler Dergisi*, Cilt. 18, Sayı. 4, s. 251-260.
- Gavcar, E.; Şen, S.; Aytakin, A. (1999). "Türkiye'de Kullanılan Kağıt-Karton Türlerinin Talep Tahminlerinin Belirlenmesi", *Tr. Journal of Agriculture and Forestry, TÜBİTAK*.
- Gavcar, E. (2009). *İstatistik Yöntemleri I*, Gazi Kitapevi, 5 Baskı, Ankara.
- Gavcar, E. (2019). *İstatistik Yöntemleri I*, Gazi Kitapevi, 10 Baskı, Ankara.
- Ghahramani, Z. (2003). "Unsupervised Learning. In: *Summer School on Machine Learning*", Berlin, Heidelberg: Springer Berlin Heidelberg, s. 72-112.
- Ghalekhondabi, I.; Ardjmand, E.; Weckman, G. R.; Young, W. A. (2017). "An Overview of Energy Demand Forecasting Methods Published in 2005–2015", *Energy Systems*, Cilt. 8, s. 411-447.
- Ghojogh, B.; Crowley, M. (2019). "The Theory Behind Overfitting, Cross Validation, Regularization, Bagging, and Boosting: Tutorial", *arXiv preprint arXiv,1905.12787*, s. 1-23.
- Gogtay, N. J.; Deshpande, S. P.; Thatte, U. M. (2017). "Principles of Regression Analysis, *J. Assoc. Physicians India*, Cilt. 65, Sayı. 48, s. 48-52.
- Goh, B. H. (1998). "Forecasting Residential Construction Demand in Singapore: A Comparative Study of the Accuracy of Time Series, Regression and Artificial

- Neural Network Techniques”, Engineering, Construction and Architectural Management, Cilt. 5, Sayı. 3, s. 261-275.
- Gökler, L. A. (2021). “Foreign Demand and High-rise Luxury Housing Projects in Two Turkish Cities: Ankara and Trabzon”, Land Use Policy, 103, 105318, s. 1-8.
- Granata, F.; Papirio, S.; Esposito, G.; Gargano, R.; Marinis, G.(2017). “Machine Learning Algorithms for the Forecasting of Wastewater Quality Indicators”, Water, Cilt. 9, Sayı. 2, s. 1-12.
- Gupta, I; Nagpal, G. (2020). Artificial Intelligence and Expert Systems, Stylus
- Gülağız, F. K; Ekinci, E. (2017). “Farklı Regresyon Analizi Yöntemleri Kullanılarak Ev Fiyatlarının Tahmini”, In: Conference: International Symposium on Industry, s. 203-207.
- Gültepe, Y. (2019). “Makine Öğrenmesi Algoritmaları ile Hava Kirliliği Tahmini Üzerine Karşılaştırmalı Bir Değerlendirme”, Avrupa Bilim ve Teknoloji Dergisi, Sayı. 16, s. 8-15.
- Güngör, İ.; Çuhadar, M. (2005). “Antalya İline Yönelik Alman Turist Talebinin Yapay Sinir Ağları Yöntemiyle Tahmini”, Gazi Üniversitesi Ticaret ve Turizm Eğitim Fakültesi Dergisi, Sayı. 1, s. 84-98.
- Hahn, G. J. (1973). “The Coefficient of Determination Exposed”, Chemtech, Cilt. 3, No. 10, s. 609-612.
- Haliloğlu, E. Y.; Tutu, B. E. (2018). “Türkiye İçin Kısa Vadeli Elektrik Enerjisi Talep Tahmini”, Journal of Yasar University, Cilt. 13, Sayı. 51, s. 243-255.
- Harman, G. (2022). “Altın/Dolar Paritesinin Farklı Yapay Sinir Ağları Öğrenme Algoritmaları Kullanarak Bir Sonraki Kur Tahmini”, Veri Bilimi, Cilt. 5, No. 1, s. 1-12.
- Haupt, SE.; Pasini, A.; Marzban, C. (ed.) (2008). “Artificial Intelligence Methods in The Environmental Sciences”, Springer Science & Business Media.
- Haykin, S. (1999). Neural Networks-A Comprehensive Foundation, Prentice Hall, 2. Edition, New Jersey.

- Helm, J. M.; Swiergosz, A. M.; Haeberle, H. S.; Karnuta, J. M.; Schaffer, J. L.; Krebs, V. E.; Spitzer, A. I.; Ramkumar, P. N. (2020). "Machine Learning And Artificial Intelligence: Definitions, Applications, And Future Directions", *Current Reviews In Musculoskeletal Medicine*, Cilt. 13, Sayı. 1, s. 69-76.
- Hinton, G. E.; Osindero, S.; Teh, Y.-W. (2006). "A Fast Learning Algorithm for Deep Belief Nets", *Neural computation*, Cilt. 18, Sayı. 7, s. 1527-1554.
- Hodson, T. O. (2022). "Root Mean Square Error (RMSE) or Mean Absolute Error (MAE): When to Use Them or Not", *Geoscientific Model Development Discussions*, Cilt. 15, Sayı. 14, s. 5481-5487.
- Hsieh, W. W. (2009). *Machine Learning Methods in The Environmental Sciences: Neural Networks and Kernels*, Cambridge University Press.
- Huang, H.-H.; He, Q. (2024). "Nonlinear Regression Analysis", Preprint submitted to *International Encyclopedia of Education 4th Edition*, arXiv Preprint arXiv: 2402.05342, s. 1-12.
- Huber, Jakob; Stuckenschmidt, Heiner (2020). "Daily Retail Demand Forecasting Using Machine Learning with Emphasis on Calendric Special Days", *International Journal of Forecasting*, Cilt. 36, Sayı. 4, s. 1420-1438.
- Huss, W. R. (1985). "Comparative Analysis of Company Forecasts and Advanced Time Series Techniques Using Annual Electric Utility Energy Sales Data", *International Journal of Forecasting*, Cilt. 1, Sayı. 3, s. 217-239.
- Hyndman, R. J. (2009). "Forecasting: An Overview", *Academia*, s. 1-5.
- İncekara, Ç. Ö. (2020). "Türkiye'nin Elektrik Üretiminde Doğalgaz Talep Tahminleri", *Journal of Turkish Operations Management*, Cilt. 4, Sayı. 2, s. 494-508.
- İnik, Ö.; Ülker, E. (2017). "Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri", *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, Cilt. 6, Sayı. 3, s. 85-104.
- Jadav, K.; Panchal, M. (2012). "Optimizing Weights Of Artificial Neural Networks Using Genetic Algorithms. *Int J Adv Res Comput Sci Electron Eng*, Cilt. 1, Sayı. 10, s. 47-51.

- Jain, A. K.; Mao, J.; Mohiuddin, K. M. (1996). "Artificial Neural Networks: A Tutorial", *Computer, Cilt. 29, Sayı. 3, s. 31-44.*
- Jung, K.; Bae, D. H.; Um, M. J.; Kim, S.; Jeon, S.; Park, D. (2020). "Evaluation of Nitrate Load Estimations Using Neural Networks and Canonical Correlation Analysis with K-fold Cross-Validation", *Sustainability, Cilt. 12, Sayı. 1, s. 1-17.*
- Kadı, F. (2014). "Türkiye'de Yabancılara Gayrimenkul Satışı: Sektörel ve Bölgesel Bir İnceleme", *Akademik Araştırmalar Dergisi, Cilt. 16, Sayı. 62, s. 41-60.*
- Kalogirou, S. A. (2004). "Optimization Of Solar Systems Using Artificial Neural-Networks And Genetic Algorithms", *Applied Energy, Cilt. 77, Sayı. 4, s. 383-405.*
- Kamenetzky, R. D.; Shuman, L. J.; Wolfe, H. (1982). "Estimating Need and Demand for Prehospital Care", *Operations Research, Cilt. 30, Sayı. 6, s. 1148-1167.*
- Kaplan, A.; Haenlein, M. (2019). "Siri, Siri, In My Hand: Who's The Fairest In The Land? On The Interpretations, Illustrations, And Implications Of Artificial Intelligence". *Business Horizons, Cilt. 62, Sayı. 1, s. 15-25.*
- Karaatlı, M.; Helvacıoğlu, Ö. C.; Ömürbek, N.; Tokgöz, G. (2012). "Yapay Sinir Ağları Yöntemi ile Otomobil Satış Tahmini", *Uluslararası Yönetim İktisat ve İşletme Dergisi, Cilt 8, Sayı 17, s. 87-100.*
- Karadağ, H.; Alıcı, V. A. (2024). "Türkiye Ekonomisinde Konut Fiyat Endeksi İle Yabancılara Yapılan Konut Satışı Arasındaki İlişki", *Uluslararası Ticarete Güncel Sorunlar, Bölüm 9, s. 141-152.*
- Karahan, M. (2011). "İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu ile Ürün Talep Tahmini Uygulaması", *Tez (Doktora Tezi), Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü.*
- Karahan, M. (2015). "Turizm Talebinin Yapay Sinir Ağları Yöntemiyle Tahmin Edilmesi", *Suleyman Demirel University Journal of Faculty of Economics & Administrative Sciences, Cilt. 20, Sayı. 2, s. 195-209.*
- Karakurt, E. (2020). "Evaluation of Real Estate Sales to Foreign Nationals in Turkey", *Contemporary Studies in Sciences, 386.*

- Kavzoglu, T. (1999). "Determining Optimum Structure for Artificial Neural Networks", In: Proceedings of the 25th Annual Technical Conference and Exhibition of the Remote Sensing Society, Remote Sensing Society Nottingham UK Cardiff, UK, s. 675-682.
- Kernbach, J. M.; Staartjes, V. E. (2022). "Foundations of Machine Learning-based Clinical Prediction Modeling: Part II—Generalization and Overfitting", Machine Learning in Clinical Neuroscience: Foundations and Applications, s. 15-21.
- Keskintürk, T.; Şahin, S. (2009). "Doğrusal Olmayan Regresyon Analizinde Gerçek Değer Kodlamalı Genetik Algoritma". İstanbul Ticaret Üniversitesi Sosyal Bilimler Dergisi, Sayı. 15, s.167-178.
- Kılıç, S. (2013). "Doğrusal Regresyon Analizi", Journal of Mood Disorders, Cilt. 3, Sayı. 2, s. 90-92.
- Kılıç, E.; Özbalcı, U.; Özçalık, H. R. (2012). "Lineer Olmayan Dinamik Sistemlerin Yapay Sinir Ağları ile Modellenmesinde MLP ve RBF Yapılarının Karşılaştırılması", ELECO2012 Elektrik-Elektronik ve Bilgisayar Mühendisliği Sempozyumu , (29.11. 2012-01.12. 2012), Bursa, s. 694-698.
- Kirby, M. (1966). "A Comparison of Short and Medium Range Statistical Forecasting Methods", Management Science, Cilt. 13, Sayı. 4, B-202-B-210.
- Krajewski, L. J.; Ritzman, L. P.; Malhotra, M. K. (2020). Operations Management Processes and Supply Chains-Üretim Yönetimi Süreçler ve Tedarik Zincirleri (Çev. Semra Birgün), 9. Basımdan Çeviri, Gözden Geçirilmiş Yeni Basım, Nobel, Ankara.
- Krizhevsky, A.; Sutskever, I.; Hinton, G. E (2012). "Imagenet Classification with Deep Convolutional Neural Networks", Advances in Neural Information Processing Systems, Cilt. 25, s. 1-9.
- Kobu, B. (2010). Üretim Yönetimi, Beta Basım, 15. Baskı, İstanbul.
- Korucuk, S.; Tatlı, Y.; Erdal, H.; Mert, F.; Dişli, E., (2015). Temel Lojistik Bilgisi, (1.Baskı), Gündüz Ofset, Trabzon.
- Kovalerchuk, B. (2020). "Enhancement of Cross Validation Using Hybrid Visual and Analytical Means with Shannon Function", Beyond Traditional Probabilistic

Data Processing Techniques: Interval, Fuzzy etc. Methods and Their Applications, s. 517-543.

Kubat, C. (2019). Matlab Yapay Zekâ ve Mühendislik Uygulamaları, 4. Baskı, Abaküs Yayınları.

Kubat, M.; Bratko, I.; Michalski, R.S. (1998). "A Review of Machine Learning Methods", Machine learning and data mining: methods and applications, s. 1-72.

Kukreja, H.; Bharath, N.; Siddesh, C. S.; Kuldeep, S. (2016). "An Introduction to Artificial Neural Network". Int J Adv Res Innov Ideas Educ, Cilt.1, Sayı. 5, s. 27-30.

Law, R. (1998). "Room Occupancy Rate Forecasting: A Neural Network Approach", International Journal of Contemporary Hospitality Management, Cilt. 10, Sayı. 6, s. 234-239.

Law, R.; Au, N. (1999). "A Neural Network Model to Forecast Japanese Demand for Travel to Hong Kong", Tourism Management, Cilt. 20, Sayı. 1, s. 89-97.

Law, R. (2000). "Back-propagation Learning in Improving the Accuracy of Neural Network-based Tourism Demand Forecasting", Tourism Management, Cilt. 21, Sayı. 4, s. 331-340.

LeCun, Y.; Bengio, Y.; Hinton, G. (2015). "Deep Learning", Nature, Cilt. 521, Sayı. 7553, s. 436-444.

Lin, C. J.; Chen, H. F.; Lee, T. S. (2011). "Forecasting Tourism Demand Using Time Series, Artificial Neural Networks And Multivariate Adaptive Regression Splines: Evidence From Taiwan", International Journal of Business Administration, Cilt. 2, Sayı. 2, s. 14-24.

Maltarollo, V. G.; Honório, K. M.; Da Silva, A. B. F. (2013). "Applications of Artificial Neural Networks in Chemical Problems", Artificial Neural Networks-Architectures and Applications, s. 203-223.

Mahesh, B. (2020). "Machine Learning Algorithms-A Review", International Journal of Science and Research (IJSR).[Internet], Cilt. 9, Sayı. 1, s. 381-386.



- Marchant, L. J.; Hockley, D. J. (1971). "A Comparison of Two Forecasting Techniques", *Journal of the Royal Statistical Society: Series D (The Statistician)*, Cilt. 20, Sayı. 3, s. 35-44.
- Marill, K. A. (2004). "Advanced Statistics: Linear Regression, Part II: Multiple Linear Regression". *Academic emergency medicine*, Cilt. 11, Sayı. 1, s. 94-102.
- Meydan, Y. A. (2007). "Talep Tahmin Yöntemleri ve Orta Ölçekli Bir İşletmede Uygulanması", *Tez (Yüksek Lisans Tezi)*, İstanbul Ticaret Üniversitesi.
- Mirjalili, S. (2019). "Genetic Algorithm", In: *Evolutionary algorithms and neural networks*. Springer, Cham, s. 43-55.
- Moor, J. (2006). "The Dartmouth College Artificial Intelligence Conference: The Next Fifty Years". *Ai Magazine*, Cilt. 27, Sayı. 4, s. 87-91.
- Narayanan, G.; Jain, P.; Choudhury, A.; Dutta, P.; Kalita, K.; Barsocchi, P. (2021). "Random Forest Regression-Based Machine Learning Model for Accurate Estimation of Fluid Flow in Curved Pipes", *Processes*, Cilt. 9, 2095, s. 1-15.
- Nasteski, V. (2017). "An Overview of the Supervised Machine Learning Methods". *Horizons. b*, Cilt. 4, Sayı. 56, s. 1-11.
- Nti, I. K.; Nyarko-Boateng, O.; Aning, J. (2021). "Performance of Machine Learning Algorithms with Different K Values in K-fold Cross-Validation", *International Journal of Information Technology and Computer Science*, Cilt. 13, Sayı. 6, s. 61-71.
- Omarbl, H. A. (2017). "The 2018 Forecasting of Opec Oil Price by Using Time Series Model", *Thesis (Instute of Natural and Applied Sciences) Van Yüzüncü Yıl University Instute of Natural and Applied Sciences*.
- Organ, A.; Tosun Gavcar, C. (2021). "Forecasting Hotel Occupancy Rates With Artificial Neural Networks in the COVID-19 Process", In: *Handbook of Research on the Impacts and Implications of COVID-19 on the Tourism Industry*. IGI Global, s. 583-602.
- Özaktaş, F. D. (2019). "Yabancılara Konut Satışı ve Reel Efektif Döviz Kuru: Türkiye Örneği Ampirik Çalışma", *Ekonomik ve Sosyal Araştırmalar Dergisi*, Cilt. 15, Sayı. 1, s. 131-147.

- Özdemir, A.; Özdemir, A., (2006). “Talep Tahminlemede Kullanılan Yöntemlerin Karşılaştırılması: Seramik Ürün Grubu Firma Uygulaması”, Ege Academic Review, Cilt. 6, Sayı. 2, s. 105-114.
- Özden, S.; Öztürk, A. (2018). “Yapay Sinir Ağları ve Zaman Serileri Yöntemi ile Bir Endüstri Alanının (İvedik OSB) Elektrik Enerjisi İhtiyaç Tahmini”, Bilişim Teknolojileri Dergisi, Cilt. 11, Sayı. 3, s. 255-261.
- Özmaden, M. Ş.; Erdal, M. (2020). “Performance Analysis of Methods Used in The Cost Estimation of Residential Buildings”, Konya Mühendislik Bilimleri Dergisi, Cilt. 8, Sayı. 4, s. 970-985.
- Öztemel, E. (2003). Yapay Sinir Ağları, PapatyaYayıncılık, İstanbul.
- Öztürk, K.; Şahin, M. E. (2018). “Yapay Sinir Ağları ve Yapay Zekâ’ya Genel Bir Bakış”, Takvim-i Vekayi, Cilt. 6, Sayı. 2, s. 25-36.
- Özüdoğru, A. G.; Görener, A. (2015). “Sağlık Sektöründe Talep Tahmini Üzerine Bir Uygulama”, İstanbul Ticaret Üniversitesi Sosyal Bilimleri Dergisi, Sayı:27, s. 37-53.
- Parziale, L.; Benke, O.; Favero, W.; Kumar, R.; Lafalce, S.; Madera, C.; Muszytowski, S. (2016). “Enabling Real-time Analytics on IBM z Systems Platform”, International Technical Support Organization, Baskı 1, Redbooks, s. 1-202.
- Pattie, D. C.; Snyder, J. (1996). “Using a Neural Network to Forecast Visitor Behavior”, Annals of Tourism Research, Cilt. 23, Sayı. 1, s. 151-164.
- Pişkin, M. D.; Bas, E. (2022). “Forecasting Monthly Housing Sales to Foreigners with Type 1 Fuzzy Regression Functions Approach Based on Ridge Regression”. Karadeniz Fen Bilimleri Dergisi, Cilt. 12, Sayı. 2, s. 571-583.
- Polat, E.; Günay, S. (2009). “Kismi En Küçük Kareler ve Bir Uygulama”, İçinde VI: İstatistik Günleri Sempozyumu Bildiriler Kitabı, s. 437-444.
- Rossini, P. (1997). “Artificial Neural Networks Versus Multiple Regression in the Valuation of Residential Property”, Australian Land Economics Review, Cilt. 3, Sayı. 1, s. 1-12.

- Sani, B.; Kingsman, B. G. (1997). "Selecting the Best Periodic Inventory Control and Demand Forecasting Methods for Low Demand Items", *The Journal of Operational Research Society*, Cilt. 48, Sayı. 7, s. 700-713.
- Sattari, M. T.; Apaydın, H.; Shamshirband, S. (2020). "Performance Evaluation of Deep Learning-Based Gated Recurrent Units (GRUs) and Tree-Based Models for Estimating ETo by Using Limited Meteorological Variables", *Mathematics*, 8.6: 972, s. 1-18.
- Schultz, C. R. (1987). "Forecasting and Inventory Control for Sporadic Demand Under Periodic Review", *The Journal of the Operational Research Society*, Cilt. 38, Sayı. 5, s. 453-458.
- Selçi, B. Y. (2021). "Türkiye'nin Konut Satışı Değerlerinin Yapay Sinir Ağları ile Öngörülmesi", *Ekoist: Journal of Econometrics and Statistics*, (35), s. 19-32.
- Sevgen, S. C.; Aliefendioğlu, Y. (2020). "Mass Appraisal With a Machine Learning Algorithm: Random Forest Regression", *Bilişim Teknolojileri Dergisi*, Cilt. 13, Sayı. 3, s. 301-311.
- Shamsuddin, S. M.; Sallehuddin, R.; Yusof, N. M. (2008). "Artificial Neural Network Time Series Modeling For Revenue Forecasting", *Chiang Mai J. Sci.*, Cilt. 35, Sayı. 3, s. 411-426.
- Sood, S.; Jain, K. (2017). "Comparative Analysis of Techniques for Forecasting Tourists' Arrival", *Journal of Tourism Hospitality*, Cilt. 6, Sayı. 3, s. 1-4.
- Sönmez Çakır, F. (2019). "Yapay Sinir Ağları Matlab Kodları ve Matlab Toolbox Çözümleri", 2. Baskı, Nobel Yayıncılık.
- Spiliotis, E.; Makridakis, S.; Semenoglou, A. A.; Assimakopoulos, V. (2022). "Comparison of Statistical and Machine Learning Methods for Daily SKU Demand Forecasting". *Operational Research*, Cilt. 22, Sayı. 3, s. 3037-3061.
- Srinivasan, K.; Cherukuri, A. K.; Vincent, D. R.; Garg, A.; Chen, B. Y. (2019). "An Efficient Implementation of Artificial Neural Networks with K-Fold Cross-Validation for Process Optimization", *Journal of Internet Technology*, Cilt. 20, No. 4, s. 1213-1225.

- Süleymanlı, C. (2019). “Türkiye’de Yabancıların Konut Edinimi ile Döviz Kuru Arasındaki İlişki: Eş bütünleşme Analizi (2013-2019)”, Bingöl Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, Cilt. 3, Sayı. 2, s. 117-136.
- Sykes, A. O. (1993). “An Introduction to Regression Analysis”, Coase-Sandor Institute for Law & Economics Working Paper, Sayı. 20.
- Szegedy, C.; Liu, W.; Jia, Y.; Sermanet, P.; Reed, S.; Angueloy, D.; Erhan, D.; Vanhoucke, V.; Rabinovich, A. (2015). “Going Deeper with Convolutions”, In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, s. 1-9.
- Şeker, A.; Diri, B.; Balık, H. H. (2017). “Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme”, Gazi Mühendislik Bilimleri Dergisi, Cilt. 3, No. 3, s. 47-64.
- Şenel, T.; Cengiz, M.; Savaş, N.; Terzi, Y. (2014). “Çoklu Doğrusal Regresyonda Model Seçiminde Genelleştirilmiş Toplamsal Modellerin Kullanımı”, Erzincan University Journal of Science and Technology, Cilt. 2, Sayı. 2, s. 217-227.
- Şıt, M.; Karadağ, H. (2018). “Türkiye’de Yabancı Konut Yatırımı ve Turizm Arasındaki İlişki: Nedensellik Analizi”, Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, Sayı. 51, s. 115-126.
- Tekin, T. G.; Patır, S. (2023). “Amerikan Doları Kurunun Yapay Sinir Ağları Yöntemiyle Tahminlenmesi: 2009–2021 Dönemi”, R&S-Research Studies Anatolia Journal, Cilt. 6, Sayı. 1, s. 56-77.
- Toğaçar, M.; Ergen, B.; Sertkaya, M. E. (2019). “Zatürre Hastalığının Derin Öğrenme Modeli ile Tespiti”, Firat University Journal of Engineering Science, Cilt. 31, Sayı. 1, s. 223-230.
- Toker, A. C.; Korkmaz, O. (2010). “Türkiye Kısa Süreli Elektrik Talebinin Saatlik Olarak Tahmin Edilmesi”, In: Proc. 2010 17. Uluslararası Enerji ve Çevre Konferansı, s. 32-35.
- Topol, E. J. (2019). “High-Performance Medicine: The Convergence Of Human And Artificial Intelligence”, Nature Medicine, Cilt. 25, Sayı. 1, s. 44-56.

- Tranmer, M.; Murphy, J.; Elliot, M.; Pampaka, M. (2020). "Multiple Linear Regression (2nd Edition)", Cathie Marsh Institute Working Paper 2020-01, s. 1-59.
- Tutu, B. E. (2017). "Türkiye İçin Kısa Vadeli Elektrik Enerjisi Talep Tahmini", Tez (Yüksek Lisans Tezi) Tobb Ekonomi ve Teknoloji Üniversitesi, Sosyal Bilimler Enstitüsü.
- Tyagi, K.; Rane, C., Sriram, R.; Manry, M. (2022). "Unsupervised Learning. In Artificial Intelligence and Machine Learning for Edge Computing", Academic Press, s. 33-52.
- Uğuz, S. (2023). "Makine Öğrenmesi Teorik Yönleri ve Python Uygulamaları ile Bir Yapay Zekâ Ekolü, Güncellenmiş ve Gözden geçirilmiş 3. Basım, Nobel, Haziran.
- Ulucan, E.; Kızılırmak, İ. (2018). "Konaklama İşletmelerinde Talep Tahmin Yöntemleri: Yapay Sinir Ağları ile İlgili Bir Araştırma", Seyahat ve Otel İşletmeciliği Dergisi, Cilt. 15, Sayı. 1, s. 89-101.
- Uysal, M.; El Roubi, M. S. (1999). "Artificial Neural Networks versus Multiple Regression in Tourism Demand Analysis", Journal of Travel Research, Cilt. 38, No. 2, s. 111-118.
- Ülgen, H.; Mirze, S. (2013). İşletmelerde Stratejik Yönetim, Beta Yayınevi, İstanbul.
- Üstüner, M.; Abdikan, S.; Bilgin, G.; Şanlı, F. B. (2020). "Hafif Gradyan Artırma Makineleri ile Tarımsal Ürünlerin Sınıflandırılması". Turkish Journal of Remote Sensing and GIS, Cilt. 1, Sayı. 2, s. 97-105.
- Wang, G. C. S. (2008). "A Guide to Box-Jenkins Modeling", The Journal of Business Forecasting, Cilt. 27, Sayı. 1, s. 19.
- Wang, Y. F.; Li, G. H.; Hanson, J. R.; Tario Jr, J. D.; Monaghan, S. A.; Ko, B. S.; Wallace, P. K.; Fu, K.; Qian, Y (2023). "Machine Learning-Facilitated Cross-Panel Automatic Classification at Both Sample and Cell Level in Acute Myeloid Leukemia", Blood, Cilt. 142, s. 5019-5020.
- Wardani, N.; Ramadiani; Kridalaksana, A. H.; Jundillah, M. L.; Azainil (2019). "Forecasting the Hotel Room Reservation Rate in East Kalimantan Using

- Double Exponential Smoothing”, Fourth International Conference on Informatics and Computing (ICIC), IEEE, s. 1-7.
- Willemain, T. R.; Smart, C. N.; Schwarz, H. F. (2004). “A New Approach to Forecasting Intermittent Demand for Service Parts Inventories”, *International Journal of Forecasting*, Cilt. 20, Sayı. 3, s. 375-387.
- Winer, R. S. (1979). “An Analysis of the Time-Varying Effects of Advertising: The Case of Lydia Pinkham”, *Journal of Business*, Cilt. 52, Sayı. 4, s. 563-576.
- Winston, P. H. (1992). *Artificial Intelligence*, Addison-Wesley Longman Publishing Co., Inc., 3. Baskı.
- Xie, T.; Fan, G.; Tang, L.; Xing, P.; Shi, Y. (2023). “P2. 05-06 An Artificial Neural Network System to Predict the Immune-related Adverse Events Based on the RNA Data of ORIENT-3 Study”, *Journal of Thoracic Oncology*, Cilt. 18, Sayı. 11.
- Yanar, R.; Demir, C. Ş. (2022). “Döviz Kurundaki Değişimlerin Yabancı Konut Talebine Etkileri: Türkiye Örneği”, *İşletme Ekonomi ve Yönetim Araştırmaları Dergisi*, Cilt. 5, Sayı. 2, s. 56-71.
- Yates, L. A.; Aandahl, Z.; Richards, S. A.; Brook, B. W. (2023). “Cross Validation for Model Selection: A Review with Examples From Ecology”, *Ecological Monographs*, Cilt. 93, Sayı. 1, e1557, s. 1-24.
- Yavuz, A.; Çilengiroğlu, Ö. V. (2020). “Lojistik Regresyon ve CART Yöntemlerinin Tahmin Edici Performanslarının Yaşam Memnuniyeti Verileri İçin Karşılaştırılması”, *Avrupa Bilim ve Teknoloji Dergisi*, Sayı. 18, s. 719-727.
- Yılmaz, K. S.; Yücememiş, B. T. (2022). “Türkiye Cumhuriyet Merkez Bankası (TCMB) Faiz Politikalarının Konut Talebine Etkisi: Ekonometrik Bir Analiz”, *Eurasian Academy of Sciences Social Sciences Journal*, Cilt. 43, s. 13-38.
- Yue, L.; Wangwei, J.; Jianguo, Z.; Junjun, G.; Jiazhou, Z. (2016). “Product Life Cycle Based Demand Forecasting by Using Artificial Bee Colony Algorithm Optimized Two-Stage Polynomial Fitting”, *Journal of Intelligent & Fuzzy Systems*, Cilt. 31, Sayı. 2, s. 825-836.

- Vaswani, A.; Shazeer, N.; Parmar, N.; Uszkoreit, J.; Jones, L.; Gomez, A. N.; Kaiser, L.; Polosukhin, I. (2017). "Attention is All You Need", Proceedings of the 31th International Conference on Neural Information Processing Systems, Edited by: Ulrike von Luxburg, Isabelle Guyon, Samy Bengio, Hanna Wallach, Rob Fergus, Curran Associates Inc, NY, USA; s. 6000-6010
- Vesey, W. B.; Vesey, J. T.; Stroter, A. D.; Middleton, K. V. (2011). "Multiple Linear Regression: A Return to Basics in Educational Research", Multiple Linear Regression Viewpoints, Cilt. 37, Sayı. 2, s. 14-22.
- Von Neumann, J. (2016). "Model Selection and Overfitting", Nat. Methods, Cilt. 13, Sayı. 9, s. 703-704.
- Zadeh, L. A. (1965). "Fuzzy Sets", Information and Control, Cilt. 8, Sayı. 3, s. 338-353.
- Zhang, Z. (2018). Artificial Neural Network. In: Multivariate Time Series Analysis in Climate and Environmental Research, Springer, Cham, s. 1-35.
- Zhou, S. L.; McMahon, T. A.; Walton, A.; Lewis, J. (2002). "Forecasting Operational Demand for an Urban Water Supply Zone", Journal of Hydrology, Cilt. 259, Sayı. 1-4, s. 189-202.
- Zotteri, G.; Kalchschmidt, M.; Canato, F. (2005). "The Impact of Aggregation Level on Forecasting Performance", International Journal of Production Economics, Cilt. 93- 94, s. 479-491.

<https://www.tcmb.gov.tr/> (01.12.2023)

<https://www.tuik.gov.tr/> (01.12.2023), (25.04.2024)

<https://worlduncertaintyindex.com/>(01.12.2023)

## **EKLER**



### Ek-1. Tahmin İle İlgili Yapılan Literatür Taraması

Çalışmanın yılı	Çalışmanın yazar/yazarları	Çalışmanın Adı	Çalışmanın Konusu	Çalışmada kullanılan yöntem/yöntemler	Çalışmadan elde edilen sonuç/sonuçlar
1966	Kirby	A Comparison of Short and Medium Range Statistical Forecasting Methods	Beş farklı ülkeden yirmi üç farklı dikiş makinesi ürün grubu için talep tahmini	ÜD, HO ve zaman serileri analizinde en küçük kareler yöntemleri	Çalışmanın sonucunda, üstel düzgünleştirme ve hareketli ortalama yöntemleri, orta aralıklı tahminler (gelecek altı aylık talep) için genel performans açısından yaklaşık olarak eşit bulunduğu; Kısa aralık için (gelecek ayın talebi) ise, üstel düzgünleştirme genel olarak biraz daha iyi sonuçlar verdiği belirtilmiştir.
1971	Marchant ve Hockley	A Comparison of Two Forecasting Techniques	İngiltere pazarında binek otomobil talebinin tahmini	ÜD ve HO	Çalışmanın sonucunda, her iki yaklaşımında biraz hayal kırıklığı yaratan tahminler oluşturduğu, daha matematiksel olan yaklaşımın daha kısa bir süre sonrasında tahmin etmesine rağmen herhangi bir avantaj gösteremediği belirtilmiştir.
1974	Bhattacharya	Forecasting the Demand for Telephones in Australia	Telefon ile ilgili talebinin belirlenmesi	DR ve HO	Çalışmada kurulan modelin toplam taleplerin kısa vadeli tahmini için objektif bir araç olarak alınabileceği belirtilmiştir.
1979	Winer	An Analysis of the Time-Varying Effects of Advertising: The Case of Lydia Pinkham	Satış hacmi ve reklam harcamaları arasındaki ilişkinin tespiti	RA ve KA	Çalışmanın sonucunda, mevcut reklam harcamalarının etkinliğinin zamanla arttığı ancak devreden etkilerin azaldığının görüldüğü, ayrıca araştırmacının parametrelerinin güncel değerlerini belirleyebilme yeteneği sağlandığında, tahmin yeteneklerinin de arttığı belirtilmiştir.
1980	Carlson ve Umble	Statistical Demand Functions for Automobiles and Their Use for Forecasting in an Energy Crisis	Amerika'da çeşitli otomobil türünün beş senelik talep tahmini	ÇR analizi	Çalışmanın sonucunda, harcanabilir gelirin 1974 öncesi seviyelere eşit oranlarda artmaması durumunda, enerji ve fiyat seviyeleri hakkındaki olumlu varsayımlar altında bile otomobil talebinin 12,5 milyon civarında durgunlaşabileceği öne sürülmüş ve bunun otomobil üreticilerinin 1983'e kadar öngördüğü satış seviyelerinin çok altında olduğu belirtilmiştir.
1982	Kamenetzky vd.	Estimating Need and	Ambulans hizmetlerine olan	ÇR analizi	Çalışmanın sonucunda, istatistiksel testlerin, talep

		Demand for Prehospital Care	talep tahmini		tahmini amacıyla, sosyodemografik faktörler dikkate alındığında, hizmet sağlayıcılarının özelliklerinin önemli olmadığı belirtilmiştir.
1985	Huss	Comparative Analysis of Company Forecasts and Advanced Time Series Techniques Using Annual Electric Utility Energy Sales Data	ABD’de elektrik dağıtımını gerçekleştiren kırk dokuz şirketin 2, 4, 6 ve 7 yıllık satışlarının tahmin edilmesi	DR, zaman serileri analizi, ÜD ve çoklu regresyon	Çalışmanın sonucunda, test edilen zaman serisi tekniklerinden, kombinasyon tekniği ve tek değişkenli uyarlamalı tahmin prosedürü tüm zaman süreçlerinde en iyi performansı gösterdiği belirtilmiştir. Holt’un üstel düzeltmesi kısa vadede makul derecede iyi performans gösterirken doğrusal ekstrapolasyon daha uzun vadeler için oldukça iyi performans göstermektedir. Çok değişkenli tekniğin sonuçlarının ise kısa vadede hayal kırıklığı yarattığı ancak daha uzun zaman süreçleri için bazı iyileşmeler gösterdiği belirtilmiştir.
1986	Baker ve Fitzpatrick	Determination of An Optimal Forecast Model for Ambulance Demand Using Goal Programming	Güney Carolina’da acil ve rutin sağlık hizmetlerine olan günlük talebin tahmin edilmesi	ÜD yöntemi, HP modeli, ÇR analizi	Çalışmanın sonucunda, iki tek amaçlı tahmin modeliyle karşılaştırıldığında, çok amaçlı yaklaşımın daha doğru tahminler ürettiği ve bu nedenle planlamacı için daha uygun maliyetli olduğu belirtilmiştir.
1987	Schultz	Forecasting and Inventory Control for Sporadic Demand Under Periodic Review	Düzenli seyretmeyen ürün talebinin tahminlenmesi	ÜD yöntemi	
1996	Pattie ve Snyder	Using a Neural Network to Forecast Visitor Behavior	Turizm talep tahmini	Yapay Sinir Ağları yöntemi	Çalışma, 12 ay sonrasını tahmin ederken Census II ayrıştırmasının ve sinir ağı tekniğinin en doğru modeller olduğunu göstermektedir. Sonuçlar, sinir ağı modelinin turizm bilimindeki klasik tahmin tekniklerine geçerli bir alternatif olduğunu göstermektedir.
1997	Sani ve Kingsman	Selecting the Best Periodic Inventory Control and Demand Forecasting Methods for Low Demand Items	Yedek parça talebi	Basit ÜD ve HO	Araştırma, genel olarak, her inceleme döneminde güncellenen basit 52 haftalık hareketli ortalama tahmin yönteminin en iyisi olduğunu göstermektedir. Bunu Croston yöntemi yakından takip etmektedir.
1998	Law	Room Occupancy Rate Forecasting: A Neural Network Approach	Hong Kong otel endüstrisi için oda doluluk oranı tahmini	Yapay Sinir Ağları yöntemi	Çalışmanın sonucu, sinir ağlarının oda doluluk oranlarını tahmin etmek için kullanılmasının, yaygın olarak kullanılan iki tahmin yaklaşımı olan çoklu regresyon ve saf ekstrapolasyondan daha iyi

					performans gösterdiğini göstermektedir.
1999	Gavcar vd.	Türkiye’de Kullanılan Kağıt-Karton Türlerinin Talep Tahminlerinin Belirlenmesi	Ülkemizde kullanımı olan farklı kağıt-karton türlerinin talep tahmini	ÇR analizi	Çalışmanın sonucunda, talep tahmini yapılan kağıt türlerinden yazıtacı, gazete, temizlik, kraft torba, oluklu mukavva, kartonlar ve sigara kağıtlarının 1981-1994 yılları arasındaki tüketim eğrisinin 1995 ile 2000 yılları arasında da doğrusal olarak bir gelişme göstereceği, bunun yanında sargılık kağıtlar tüketiminde bir azalma söz konusu olabileceği saptanmıştır.
1999	Law ve Au	A Neural Network Model to Forecast Japanese Demand for Travel to Hong Kong	Japon turistler tarafından Hong Kong’a yapılan seyahat talebinin tahmini	İleri beslemeli sinir ağı, çoklu regresyon, hareketli ortalama, üstel düzeltme	Çalışmanın sonucunda, Japon varışlarını tahmin etmek için sinir ağı modelinin kullanılmasının diğer yöntemlere göre daha iyi performans gösterdiği ortaya konmuştur.
1999	Uysal ve El Roubi	Artificial Neural Networks versus Multiple Regression in Tourism Demand Analysis	ABD’de Kanadalı turistlerin harcamalarının tahmini	YSA ve çoklu regresyon yöntemi	Çalışmanın sonucu, turizm talep çalışmalarında YSA kullanımının tahmin yanlılığı ve doğruluk açısından daha iyi tahminlere yol açabileceğini ortaya koymuştur.
2000	Law	Back-propagation Learning in Improving the Accuracy of Neural Network-based Tourism Demand Forecasting	Turizm talep tahmini	Geri yayımlı YSA	Bir geri yayılım sinir ağının kullanılmasının tahmin doğruluğu bakımından regresyon modellerinden, zaman serisi modellerinden ve ileri beslemeli sinir ağlarından daha iyi performans gösterdiği gösterilmiştir.
2001	Alon vd.	Forecasting Aggregate Retail Sales: A Comparison of Artificial Neural Networks and Traditional Methods	Amerika bütünlük perakende satışlarının tahmini	ÇR ve YSA	Sonuçlar, ortalama olarak YSA'ların daha geleneksel istatistiksel yöntemlere göre daha başarılı olduğunu ve bunu Box-Jenkins modelinin izlediğini göstermektedir.
2001	Burger vd.	A Practitioners Guide to Time-Series Methods for Tourism Demand Forecasting- A Case Study of Durban, South Africa	ABD'den Güney Afrika'nın Durban şehrine giden turistlerin seyahat talebinin tahmini	HO, ÜD, ARIMA, genetik regresyon ve sinir ağları	En iyi sonucu sinir ağının verdiği ortaya koyulmuştur.
2002	Zhou	Forecasting Operational Demand for an Urban Water Supply Zone	Su talep tahmini	Zaman serileri analizi	Oluşturulan saatlik tahmin modeli, 162 l/p/d'lik bir standart hata ile en yüksek saatlik su tüketimindeki varyansın %66'sını açıklamıştır.

2003	Cho	A Comparison of Three Different Approaches to Tourist Arrival Forecasting	Altı ülkeden (ABD, İngiltere, Singapur, Japonya, Tayvan ve Kore) Hong Kong'a giden ziyaretçilerin tahmini	YSA, ÜD ve ARIMA	Çalışmanın sonucunda, sinir ağlarının, özellikle belirgin bir kalıbı olmayan seriler olmak üzere, ziyaretçi gelişlerini tahmin etmek için en iyi yöntem gibi görüldüğü saptanmıştır.
2003	Chu ve Zhang	A Comparative Study of Linear and Nonlinear Models for Aggregate Retail Sales Forecasting	ABD'de perakende satış tahmini	Doğrusal ve doğrusal olmayan yöntemler	Çalışmanın sonucunda, genel olarak en iyi modelin, mevsimsellikten arındırılmış zaman serisi verileri üzerine inşa edilen sinir ağı olduğu belirtilmiştir.
2004	Willemain vd.	A New Approach to Forecasting Intermittent Demand for Service Parts Inventories	Tedarik zincirinde yer alan servis parçalarına olan talebin tahmini	Bootstrapping, ÜD, croston yöntemi	Çalışmanın sonucunda, dokuz büyük endüstriyel veri kümesi kullanarak, yapılan analizde, bootstrapping yönteminin sabit bir teslim süresi boyunca talep dağılımının ÜD ve croston yöntemine göre daha doğru tahminler ürettiği belirtilmiştir.
2005	Çuhadar ve Kayacan	Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye'deki Konaklama İşletmeleri Üzerine Bir Deneme	Ülkemizdeki bakanlık belgesine sahip konaklama firmalarına yabancı turizm talebi ile oluşan doluluk oranı	YSA	Çalışma sonucunda, yapay sinir ağları kullanılarak konaklama işletmelerinde doluluk oranlarının tahmin edilebileceği, dolayısıyla turizm sektöründeki uygulamacılar ve karar verme konumunda olan yöneticilerin, geleceğe yönelik planlama çalışmalarında geleneksel tahmin yöntemlerine alternatif olarak yapay sinir ağlarını kullanabilecekleri ortaya koyulmuştur.
2005	Güngör ve Çuhadar	Antalya İline Yönelik Alman Turist Talebinin Yapay Sinir Ağları Yöntemiyle Tahmini	Antalya şehrine Alman turist talebinin tahmini	YSA, ÇR ve çoklu logaritmik regresyon	Çalışmadan elde edilen sonuçlar, yapay sinir ağı modelinin, regresyon modellerine göre daha düşük sapma değerlerine ve daha yüksek açıklayıcılık oranına sahip olduğunu göstermektedir.
2005	Zotteri vd.	The Impact of Aggregation Level on Forecasting Performance	Avrupa'da bir market zincirinin beş tane ürününün bütünleşik talebinin tahmini	Logaritmik regresyon yöntemi	Çalışmanın sonuçları, benimsenen toplulaştırma seviyesinin bir fonksiyonu olarak performansın önemli ölçüde değiştiğini göstermektedir.
2006	Özdemir ve Özdemir	Talep Tahminlemede Kullanılan Yöntemlerin Karşılaştırılması: Seramik Ürün Grubu Firma Uygulaması	Seramik ürün içeren grubun talep tahmini	Zaman serileri analizi, çoklu regresyon analizi	Çalışmanın sonucunda, zaman serisi analizi ile bulunan modelin 2006 tahminlerinde anlamlı sonuçlar vermediği, çoklu regresyon analizinin kullanmasının daha doğru olduğu saptanmıştır.
2007	Adıyaman	Talep Tahmininde Yapay Sinir Ağlarının	Altın ürünlerine olan talep tahmini	YSA, regresyon analizi, eğri yuvarlama yöntemi	Çalışmanın sonucunda, yapay sinir ağı yönteminin etkin bir talep tahmini yöntemi olduğu gösterilmiştir.

		Kullanılması			
2007	Du vd.	Tourism Room Occupancy Rate Prediction Based on Neural Network	Pekin'deki turizm oda doluluk oranı tahmini	Sinir ağı	Sinir ağı tarafından yapılan oda doluluk oranının tahmininin, sıklıkla kullanılan regresyon ve saf ekstrapolasyon yöntemlerine göre daha üstün olduğunu göstermiştir.
2009	Çuhadar, Güngör ve Göksu	Turizm Talebinin Yapay Sinir Ağları ile Tahmini ve Zaman Serisi Yöntemleri ile Karşılaştırmalı Analizi: Antalya İline Yönelik Bir Uygulama	Antalya'da dış turizm talebi için bulunan tahmin doğruluklarının karşılaştırılması	YSA modelleri ve zaman serisi yöntemlerinden ÜD ve Box-Jenkins	Çalışmada, yapılan çok sayıda deneme sonucunda orijinal seri değerleri kullanılarak oluşturulan 12 gecikmeli yapay sinir ağı modelinin en yüksek doğruluğu sağladığı saptanmıştır.
2010	Toker ve Korkmaz	Türkiye Kısa Süreli Elektrik Talebinin Saatlik Olarak Tahmin Edilmesi	Elektrik talebinin saatlik olarak tahmin edilmesi	YSA, FFT, ARIMA	Çalışmada, 7 günlük saatlik düzeyde yapılacak meteorolojik tahminlerin çok güvenilir olmayacağı düşünülerek bu tahminler için meteorolojik veri olarak yalnızca 7 günlük maksimum ve minimum sıcaklık değerleri kullanılmıştır. Bu sadeleştirmeye rağmen %4'lük MAPE hatası oranı YSA'nın bu amaçla kullanılabilceğine işaret etmektedir.
2011	Lin vd.	Forecasting Tourism Demand Using Time Series, Artificial Neural Networks and Multivariate Adaptive Regression Splines: Evidence from Taiwan	Tayvan ziyaretçilerinin tahmin modelinin oluşturulması	YSA, ARIMA, ve çok değişkenli uyarlanabilir regresyon uzanımları	Çalışmanın sonucunda, ARIMA'nın RMSE, MAD ve MAPE açısından YSA ve Mars yaklaşımlarından daha iyi performans gösterdiği ve turizm talebini tahmin etmek için etkili alternatifler sağladığı gösterilmiştir.
2012	Fernandes vd.	Forecasting Tourism Demand with Artificial Neural Networks	Turizm talep tahmini	YSA	Çalışmanın sonucu, yapay sinir ağı modellerinin en yüksek tahmin doğruluğuna ulaştığını göstermiştir.
2012	Karaatlı vd.	Yapay Sinir Ağları Yöntemi ile Otomobil Satış Tahmini	Otomobil satış tahmini	YSA	Çalışmada MAPE değeri %16,82 çıktığından yapılan tahmin "doğru tahminler" sınıfına girmektedir. Yapılan tahminler gerçek değerlerle karşılaştırıldığında genelde tahmin edilen ve gerçekleşen değerlerin birbirlerine yakın olduğu görülmüştür. Ancak Ekim ve Kasım aylarında tahmin ile gerçekleşen değerler arasında farkın fazla olduğu görülmüştür. Bunun nedeni de kış aylarına girilmesi ve müşterilerin firmaların aralık ayında yapacakları kampanyaları beklemeleri şeklinde açıklanmıştır.

2013	Çuhadar	Türkiye'ye Yönelik Dış Turizm Talebinin MLP, RBF ve TDNN Yapay Sinir Ağı Mimarileri ile Modellenmesi ve Tahmini: Karşılaştırmalı Bir Analiz	Türkiye'ye yönelik olan dış turizm talep tahmini	Çok katmanlı ileri beslemeli, radyal tabanlı fonksiyon ve zaman gecikmeli YSA yöntemleri	Çalışmada yapılan çok sayıda deneme sonucunda on iki gecikmeli veri değerleri kullanılarak geliştirilen [4-5-1] mimarisine sahip MLP modelinin en yüksek doğruluğu sağladığı görülmüştür. Bu model yardımıyla 2013 yılı için Türkiye'ye yönelik aylık dış turizm talebi tahminleri üretilmiştir.
2014	Ballı	Yapay Sinir Ağları ile Talep Tahmini ve Gıda Sektöründe Uygulanması	Gıda alanı talep tahmini	YSA	Çalışmada istatistiksel talep tahmin tekniklerinden yapay sinir ağı modeli kullanılarak, hızlı tüketim sektörü olan taze gıda sektöründe, şarküteri grubu ürünlerine ait talep tahmini uygulaması yapılmıştır. Uygulama sonrası yapılan hata testleri sonucuna göre, modelin yaptığı tahminlerin güvenilir ve tutarlı olduğu gözlenmiştir. Yapay sinir ağı yöntemi dışında başka yöntemlerle de talep tahmini yapılmış ve yapay sinir ağlarının mevcut yöntemlerden üstün olduğu gösterilmiştir.
2014	Aikeshan	Bulanık Doğrusal Regresyon Yöntemi ile Talep Tahmini: Medikal Asistans Firmasında Bir Uygulama	Dosya talep tahmin modeli geliştirilmesi	Bulanık DR	Çalışmada, bulanık yöntemle geliştirilen doğrusal modelin, gerçeği yansıtmak, az veriyle tahminleme imkânı sağlamak gibi birçok avantaja sahip olduğu, geleneksel doğrusal programlama yaklaşımının ise, çevre ve faktörler arasında bulanık etkileşimi göz ardı ederek somut bir sonuç vermekle yetindiği belirtilmiştir.
2015	Claveria vd.	Tourism Demand Forecasting with Neural Network Models: Different Ways of Treating Information	Turist talep tahmini	Çok katmanlı bir algılayıcı, radyal temel işlevi ve bir Elman ağı olmak üzere üç farklı YSA yöntemi	Çalışmanın sonucunda, çok katmanlı algılayıcı ve radyal temel fonksiyon modellerinin Elman ağlarından daha iyi performans gösterdiği belirtilmiştir.
2015	Karahan	Turizm Talebinin Yapay Sinir Ağları Yöntemiyle Tahmin Edilmesi	Denizli iline olan turizm talep tahmini	YSA	Çalışmadan elde edilen sonuçlar; YSA modeli kullanılarak turizm işletmelerine olan talebin doğru tahmin edilebileceğini, dolayısıyla turizm sektöründeki uygulamacılar ve karar verme konumunda olan yöneticilerin, geleceğe yönelik planlama çalışmalarında geleneksel tahmin yöntemlerine alternatif olarak YSA modelini kullanabileceklerini ortaya koymuştur.

2015	Özüdoğru vd.	Sağlık Sektöründe Talep Tahmini Üzerine Bir Uygulama	Sağlık alanında medikal malzemelerin talep tahmini	Hareketli ortalama yöntemleri, Üstel düzeltme yöntemi, Holt'un doğrusal yöntemi, Holt-Winters yöntemleri, Doğrusal regresyon	Çalışma sonucunda, talep tahmini yapılan enjektör isimli ürün için elde edilen hata değerlerine bakıldığında en düşük değerlerin, üç hata ölçütünden ikisinde 5 Aylık Hareketli Ortalama yöntemiyle, ölçütlerden birinde de Toplamsal Holt-Winters yöntemi ile sağlandığı görülmüştür.
2016	Doğan	Uyarlamalı Sinirsel Bulanık Çıkarım Sisteminin (ANFIS) Talep Tahmini İçin Kullanımı ve Bir Uygulama	Türkiye'de 15 farklı şubede faaliyet gösteren bir firmanın bir şubesine ait haftalık talep miktarı	Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi	Çalışmanın sonucunda, gerçek çıktılar ile model çıktıları arasında $\alpha = 0,05$ düzeyinde anlamlı bir ilişki vardır ( $p < 0,05$ ). R değeri 0,819 olarak bulunmuştur. Bu değer, veriler arası ilişkinin yüksek düzeyde ve pozitif yönlü olduğunu göstermektedir.
2016	Yue vd.	Product Life Cycle Based Demand Forecasting by Using Artificial Bee Colony Algorithm Optimized Two-Stage Polynomial Fitting	Ürün yaşam döngüsü teorisine dayanan entegre bir talep tahmini	Yapay Arı Kolonisi-PF, Hareketli Ortalama, Destek Vektör Makinesi ve Radyal Tabanlı Fonksiyon Sinir Ağı	Çalışmanın sonucunda, önerilen geliştirilmiş Yapay Arı Kolonisi-PF yönteminin diğer yöntemlere göre daha yüksek tahmin doğruluğu ve daha düşük güvenlik envanteri seviyesi sağladığı saptanmıştır.
2017	Ghalekhondabi vd.	An Overview of Energy Demand Forecasting Methods Published in 2005–2015	2005-2015 yıllarında yayımlanan enerji talebi tahmin yöntemlerinin incelenmesi	Literatür araştırması (Zaman Serisi Modelleri, Sinir Ağları, Bulanık Mantık)	Çalışmanın sonucunda, en çok atıfta bulunulan çalışmaların, enerji tüketimini tahmin etmek için sinir ağlarının uygulandığı araştırmalar olduğu saptanmıştır.
2017	Alcan vd.	Sinop İli Turizm Talebinin Yapay Sinir Ağlar Yöntemiyle Tahmini	Sinop iline olan turizm talebinin tahmini	YSA	Çalışmanın sonucunda, Karadeniz bölgesinde bulunan Sinop ili için turizm sektörünün geleceğine yönelik planlama çalışmalarında klasik tahmin yöntemlerine alternatif olarak YSA'nın kolaylıkla uygulanabilirliği ortaya konulmuştur.
2017	Efendigil	Havacılık Sektöründe Talep Tahminin Önemi: Yolcu Talebi Üzerine Bir Tahmin Modeli	Havacılık alanında yolcu talep tahmini	Adaptif sinirsel bulanık çıkarım sistemi ve YSA	Adaptif sinirsel bulanık çıkarım sistemi (ANFIS) ve yapay sinir ağlarının kullanıldığı bu çalışmada, havacılık sektöründe yolcu talep tahmini konusunda en başarılı ve güvenilir sonuçları "yapay sinir ağları" tekniğinin verdiği bulunmuştur.
2018	Choudhury	Market Demand Forecast Method Selection and Application: A Case Study in Hero MotoCorp Ltd.	Motosiklet talebini tahmin etmek için en uygun tahmin yönteminin seçilmesi	ÜD, Basit hareketli ortalama, regresyon	Çalışmanın sonucunda, motosiklet talebi tahmininde en uygun yöntemin üstel düzeltme yöntemi olduğu ortaya çıkmıştır.

2018	Haliloğlu vd.	Türkiye İçin Kısa Vadeli Elektrik Enerjisi Talep Tahmini	Elektrik enerjisi tüketiminin, günlük olarak talep edilen miktarının tahmin modeli	Çoklu en küçük kareler yöntemi	Çalışmada kurulan model sonucunda, gerçekleşen elektrik tüketimi ile tahmin edilen arasındaki aylık ortalama sapma oranlarının %1,3 ile %1,6 arasında değiştiği saptanmıştır.
2018	Ulucan ve Kızıllırmak	Konaklama İşletmelerinde Talep Tahmin Yöntemleri: Yapay Sinir Ağları ile İlgili Bir Araştırma	İstanbul'da konaklama işletmesi bir otele olan talebi tahmini	YSA	Çalışmanın sonucunda, yapay sinir ağı modeli ile elde edilen verilerin gerçek değerlere en yakın sonuçları verdiği görülmüştür.
2019	Alamsyah ve Friscintia	Artificial Neural Network for Indonesian Tourism Demand Forecasting	Endonezya'ya aylık gelen turist sayısının tahmini	YSA	Çalışmanın sonucunda, YSA'nın Endonezya'daki aylık turist varışlarını doğru bir şekilde tahmin edebildiği belirtilmiştir. Model doğruluğu %99,84 ve ortalama hata 0,00339'dur. Bu çalışma aynı zamanda YSA'nın MRA, SVM ve ARIMA gibi çeşitli modellerden daha iyi performans gösterdiğini ortaya koymuştur.
2020	İncekara	Türkiye'nin Elektrik Üretiminde Doğalgaz Talep Tahminleri	Türkiye'nin elektrik üretiminde doğalgaz talep tahmini	Bulanık AHP + bulanık TOPSIS modeli	Matematiksel modelin analizi sonucunda; ülkemizde 2019 ile 2030 yılları arasında elektrik üretiminde yüksek talep senaryosunda toplam doğal gaz kullanımı % 58 oranında artarak 77,8 bcm (milyar m3)' e ulaşacağı, elektrik üretiminde kullanılan doğal gaz miktarı % 40 oranında artarak 38,2 bcm' e ulaşacağı, düşük talep senaryosunda ülkemizde yenilenebilir enerji kaynaklarına yapılan yatırımların artması sonucu elektrik üretiminde kullanılan doğal gaz miktarı % 36 oranında azalarak 13,9 bcm' e seviyesine düşeceği hesaplanmıştır.
2020	Huber ve Stuckenschmidt	Daily Retail Demand Forecasting Using Machine Learning With Emphasis on Calendric Special Days	Günlük perakende talep tahmini	YSA ve gradyan destekli karar ağaçları	Çalışmanın sonucunda YSA ve gradyan destekli karar ağaçları yöntemlerinin doğru tahminler sağladığı saptanmıştır. Aynı zamanda perakende sektöründe sıklıkla karşılaşılan büyük ölçekli talep tahmini senaryosundaki uygulamalar için de daha uygun olduğunu tespit edilmiştir.
2021	Organ ve Tosun Gavcar	Forecasting Hotel Occupancy Rates with Artificial Neural Networks in the COVID-19 Process	COVID-19 sürecinde otel doluluk oranlarının tahmini	YSA	Çalışmada, test simülasyonu sonucunda en düşük hataya sahip ağın tahmini ve gerçek doluluk oranlarının birbirine yakın olduğu tespit edilmiştir. Tasarlanan bu modele göre 2019 ve 2020 yılları için aylık doluluk oranı tahmin edilmiştir. Sonuç olarak otel doluluk oranı ile gerçekleşen oranlar



					karşılaştırılarak COVID-19'un etkisi ortaya konmuştur.
2021	Dou vd.	Bölgesel İmalat Sanayi Talep Tahmini: Derin Öğrenme Yaklaşımı	İmalat sanayi talebi tahmini	Derin öğrenme, geriye doğru yayılım, gri model, destek vektör makinesi, rastgele orman, Otomatik regresif model	Çalışmanın sonucunda, derin öğrenmenin performansının diğer yöntemlere göre daha iyi olduğu saptanmıştır.
2022	Abbaspour Ghadim Bonab	A Comparative Study of Demand Forecasting Based on Machine Learning Methods with Time Series Approach	Lüks çanta talebine ilişkin talep tahmini	Adaptif nöro-bulanık çıkarım sistemi, çok katmanlı algılayıcı sinir ağı, radyal tabanlı fonksiyon sinir ağı, ayrık dalgacık dönüşümü-nöral ağlar ve grup veri işleme modeli	Çalışmanın sonucunda, radyal tabanlı fonksiyon sinir ağının diğer yöntemlere göre en iyi performansa sahip olduğu saptanmıştır.

**Ek-2. Çoklu Doğrusal Regresyon Yönteminde Kullanılan Kütüphane Kodları**

<code>import pandas as pd</code>
<code>import numpy as np</code>
<code>import matplotlib.pyplot as plt</code>
<code>import seaborn as sns</code>
<code>from sklearn.preprocessing import StandardScaler</code>
<code>from sklearn.model_selection import KFold, train_test_split, cross_val_predict, cross_val_score</code>
<code>from sklearn.linear_model import LinearRegression</code>
<code>from sklearn.metrics import root_mean_square_error, mean_absolute_error, mean_squared_error, R2_score, mean_absolute_percentage_error</code>

## Ek-3. Birinci Veri Çerçevesi

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26
2013	1	888	87444	1,76	2,34	2,83	96,55	0,47	1,65	760,15	56,90	8136,00	54336,00	11118037,67	8234,67	51222,67	9848959,67	0,10	9	138	448	23	26	2	242
2013	2	716	88519	1,77	2,37	2,76	96,12	0,47	0,30	793,34	57,60	8136,00	54336,00	11118037,67	8234,67	51222,67	9848959,67	0,10	13	120	357	16	17	2	191
2013	3	962	97956	1,81	2,34	2,74	95,79	0,47	0,66	858,99	58,40	8136,00	54336,00	11118037,67	8234,67	51222,67	9848959,67	0,10	10	198	495	19	34	6	200
2013	4	947	95381	1,80	2,34	2,76	95,13	1,00	0,42	860,46	59,20	11306,67	82060,00	16375083,00	9208,00	54931,33	10076178,33	0,10	10	209	445	31	27	9	216
2013	5	938	103261	1,82	2,37	2,80	94,39	1,00	0,15	859,90	60,00	11306,67	82060,00	16375083,00	9208,00	54931,33	10076178,33	0,10	10	188	476	16	10	3	235
2013	6	783	96424	1,89	2,50	2,95	93,35	1,00	0,76	762,95	60,60	11306,67	82060,00	16375083,00	9208,00	54931,33	10076178,33	0,10	14	155	358	14	16	10	216
2013	7	1114	106636	1,93	2,52	2,94	92,28	1,47	0,31	733,77	61,20	9737,00	66867,33	14178352,33	10303,00	64183,00	12131818,67	0,08	5	192	505	33	14	9	356
2013	8	890	84480	1,95	2,60	3,05	91,52	1,47	-0,10	663,94	61,50	9737,00	66867,33	14178352,33	10303,00	64183,00	12131818,67	0,08	16	170	387	22	38	6	251
2013	9	1025	102280	2,02	2,69	3,21	90,36	1,47	0,77	744,87	62,00	9737,00	66867,33	14178352,33	10303,00	64183,00	12131818,67	0,08	21	156	482	28	22	9	307
2013	10	1021	76344	1,99	2,71	3,21	88,95	1,47	1,80	776,20	62,50	11405,00	76613,33	16931062,33	12565,33	71776,00	14108063,33	0,06	21	181	433	44	27	7	308
2013	11	1456	102681	2,02	2,73	3,27	87,64	1,47	0,01	757,48	63,30	11405,00	76613,33	16931062,33	12565,33	71776,00	14108063,33	0,06	19	345	622	73	28	14	355
2013	12	1441	115784	2,06	2,82	3,39	86,41	1,47	0,46	678,02	63,60	11405,00	76613,33	16931062,33	12565,33	71776,00	14108063,33	0,06	27	395	540	56	25	26	372
2014	1	1207	87639	2,22	2,02	3,67	85,93	1,47	1,98	618,58	64,10	15365,33	99449,67	22410051,00	15680,33	87660,67	18339394,33	0,09	21	243	464	62	21	119	277
2014	2	1071	82597	2,21	3,02	3,67	85,85	1,47	0,43	625,53	64,80	15365,33	99449,67	22410051,00	15680,33	87660,67	18339394,33	0,09	21	301	400	57	36	17	239
2014	3	1362	87617	2,22	3,07	3,69	86,03	1,47	1,13	697,36	65,70	15365,33	99449,67	22410051,00	15680,33	87660,67	18339394,33	0,09	38	478	459	65	43	10	269
2014	4	1554	83610	2,13	2,94	3,57	86,23	1,43	1,34	738,72	66,80	11513,67	96142,67	19335616,33	8068,00	53601,67	9833757,00	0,12	33	489	563	89	37	33	310
2014	5	1610	90377	2,09	2,87	3,53	86,46	1,43	0,40	792,90	67,50	11513,67	96142,67	19335616,33	8068,00	53601,67	9833757,00	0,12	20	406	652	64	73	38	357
2014	6	1703	92936	2,12	2,88	3,59	87,02	1,43	0,31	784,89	68,20	11513,67	96142,67	19335616,33	8068,00	53601,67	9833757,00	0,12	14	600	586	88	63	18	334
2014	7	1473	85101	2,12	2,88	3,64	87,79	0,70	0,45	821,57	69,30	10134,67	79749,00	16945203,00	8472,33	51420,67	9855057,00	0,16	28	416	569	66	39	12	343
2014	8	1774	105624	2,16	2,88	3,62	88,17	0,70	0,09	803,13	70,20	10134,67	79749,00	16945203,00	8472,33	51420,67	9855057,00	0,16	38	511	591	96	64	29	545
2014	9	1857	115786	2,20	2,85	3,62	88,19	0,70	0,14	749,38	70,90	10134,67	79749,00	16945203,00	8472,33	51420,67	9855057,00	0,16	42	546	590	87	81	25	486
2014	10	1806	95645	2,26	2,86	3,64	88,53	0,57	1,90	805,80	71,50	9500,00	68576,67	14860406,00	9282,67	66515,67	12928176,33	0,12	32	556	612	78	84	37	407
2014	11	1687	103783	2,23	2,79	3,54	88,64	0,57	0,18	861,69	72,40	9500,00	68576,67	14860406,00	9282,67	66515,67	12928176,33	0,12	37	500	549	86	103	80	332
2014	12	1855	134666	2,29	2,82	3,60	89,23	0,57	-0,44	857,21	73,10	9500,00	68576,67	14860406,00	9282,67	66515,67	12928176,33	0,12	45	534	507	116	121	94	438
2015	1	1289	86167	2,33	2,72	3,55	89,58	0,87	1,10	889,46	74,20	8579,67	62360,67	13353773,33	7907,00	53660,33	10368578,33	0,18	41	377	392	81	95	49	254
2015	2	1369	95021	2,46	2,79	3,78	90,00	0,87	0,71	841,48	75,40	8579,67	62360,67	13353773,33	7907,00	53660,33	10368578,33	0,18	33	466	356	106	77	50	281
2015	3	1610	116030	2,58	2,80	3,89	90,30	0,87	1,19	808,46	76,60	8579,67	62360,67	13353773,33	7907,00	53660,33	10368578,33	0,18	32	548	451	103	119	65	292
2015	4	1847	119317	2,65	2,85	3,97	91,39	0,77	1,63	839,47	77,70	11341,67	82027,67	17319823,00	9612,67	64902,00	12509078,00	0,23	52	584	507	133	133	63	375
2015	5	1982	107888	2,65	2,96	4,11	92,64	0,77	0,56	829,81	78,90	11341,67	82027,67	17319823,00	9612,67	64902,00	12509078,00	0,23	44	636	546	128	104	44	480
2015	6	2256	110657	2,70	3,03	4,22	93,81	0,77	-0,51	822,50	79,90	11341,67	82027,67	17319823,00	9612,67	64902,00	12509078,00	0,23	40	718	610	125	123	92	548
2015	7	2027	96589	2,69	2,97	4,22	94,54	1,27	0,09	799,10	80,60	10135,33	70414,33	14728271,67	8643,00	55631,67	10902450,00	0,28	44	541	868	112	127	59	458
2015	8	2044	112463	2,85	3,17	4,46	95,67	1,27	0,40	752,10	81,10	10135,33	70414,33	14728271,67	8643,00	55631,67	10902450,00	0,28	51	602	518	177	147	110	439
2015	9	1768	92483	3,00	3,37	4,64	97,41	1,27	0,89	742,05	81,70	10135,33	70414,33	14728271,67	8643,00	55631,67	10902450,00	0,28	41	561	440	112	126	66	422
2015	10	2236	104098	2,93	3,30	4,50	99,12	1,33	1,55	794,09	82,70	11857,00	84274,00	17822973,67	10572,00	70122,00	13921777,00	0,22	66	780	567	136	118	73	496
2015	11	2119	106008	2,87	3,09	4,38	100,39	1,33	0,67	752,33	83,70	11857,00	84274,00	17822973,67	10572,00	70122,00	13921777,00	0,22	80	703	539	149	138	87	423
2015	12	2283	142599	2,92	3,17	4,39	101,38	1,33	0,21	717,27	84,50	11857,00	84274,00	17822973,67	10572,00	70122,00	13921777,00	0,22	75	977	460	139	118	75	439
2016	1	1462	84556	3,01	3,27	4,35	102,44	1,90	1,82	734,81	85,70	11341,00	87206,00	18352666,67	8226,33	54900,33	10739659,00	0,18	68	498	315	129	84	51	317
2016	2	1585	101703	2,94	3,26	4,22	103,84	1,90	-0,02	758,14	86,60	11341,00	87206,00	18352666,67	8226,33	54900,33	10739659,00	0,18	61	555	328	141	90	93	317
2016	3	1595	117205	2,89	3,21	4,12	105,26	1,90	-0,04	832,68	87,50	11341,00	87206,00	18352666,67	8226,33	54900,33	10739659,00	0,18	56	583	360	115	66	48	367
2016	4	1581	106348	2,83	3,21	4,07	106,18	1,60	0,78	853,28	88,60	11806,00	84109,67	17520014,00	9556,33	62828,67	12635669,67	0,15	55	540	360	116	71	66	373
2016	5	1612	114800	2,93	3,31	4,28	107,74	1,60	0,58	778,03	89,70	11806,00	84109,67	17520014,00	9556,33	62828,67	12635669,67	0,15	54	511	407	118	53	35	434
2016	6	1543	106187	2,92	3,28	4,16	109,24	1,60	0,47	768,17	90,50	11806,00	84109,67	17520014,00	9556,33	62828,67	12635669,67	0,15	42	507	381	80	49	39	445
2016	7	1044	81343	2,96	3,27	3,92	111,59	1,03	1,16	754,06	91,30	8870,33	65775,00	13418577,67	7853,33	52189,33	10611891,00	0,15	35	300	281	60	37	41	290
2016	8	1512	114751	2,96	3,32	3,90	113,61	1,03	-0,29	759,68	92,30	8870,33	65775,00	13418577,67	7853,33	52189,33	10611891,00	0,15	55	390	370	111	86	59	441
2016	9	1276	108918	2,96	3,32	3,90	115,10	1,03	0,18	764,88	92,80	8870,33	65775,00	13418577,67	7853,33	52189,33	10611891,00	0,15	39	323	359	82	67	57	349
2016	10	1566	130274	3,07	3,39	3,81	116,51	0,60	1,44	785,36	93,50	12682,33	98459,33	19699254,33	11491,67	81473,00	16448040,33	0,20	46	423	467	115	67	47	401
2016	11	1773	132655	3,27	3,53	4,08	119,18	0,60	0,52	739,95	94,00														

2017	2	1306	101468	3,67	3,91	4,59	127,46	1,17	0,81	874,78	96,70	9886,33	79560,00	15638027,67	9071,67	65561,00	13283253,33	0,15	59	458	279	119	62	41	288
2017	3	1578	128923	3,67	3,92	4,54	129,94	1,17	1,02	889,47	97,90	9886,33	79560,00	15638027,67	9071,67	65561,00	13283253,33	0,15	73	579	313	124	88	80	321
2017	4	1624	114446	3,65	3,91	4,62	132,99	1,67	1,31	946,55	98,70	16000,00	143524,33	28669594,33	9441,67	65064,33	12602822,00	0,16	65	571	385	109	69	42	383
2017	5	1775	116558	3,56	3,93	4,62	134,91	1,67	0,45	975,42	99,80	16000,00	143524,33	28669594,33	9441,67	65064,33	12602822,00	0,16	55	530	442	120	92	67	469
2017	6	1926	97579	3,52	3,95	4,52	136,81	1,67	-0,27	1004,40	100,30	16000,00	143524,33	28669594,33	9441,67	65064,33	12602822,00	0,16	68	903	408	93	59	37	358
2017	7	1726	115869	3,56	4,09	4,64	138,12	1,70	0,15	1075,31	100,50	18460,00	179160,33	36325125,33	9262,67	61372,33	12219937,33	0,14	68	528	386	102	80	68	494
2017	8	1684	120198	3,51	4,14	4,57	139,57	1,70	0,52	1100,10	100,80	18460,00	179160,33	36325125,33	9262,67	61372,33	12219937,33	0,14	53	524	376	100	103	81	447
2017	9	2236	140298	3,47	4,14	4,65	141,29	1,70	0,65	1029,08	101,40	18460,00	179160,33	36325125,33	9262,67	61372,33	12219937,33	0,14	67	797	520	119	87	64	582
2017	10	2677	122882	3,66	4,31	4,86	143,47	3,70	2,08	1101,43	102,20	12682,33	98459,33	19699254,33	11491,67	81473,00	16448040,33	0,11	83	1321	465	121	108	55	524
2017	11	2152	122732	3,88	4,55	5,16	145,83	3,70	1,49	1039,84	102,80	12682,33	98459,33	19699254,33	11491,67	81473,00	16448040,33	0,11	81	728	491	142	128	94	488
2017	12	2164	132972	3,85	4,55	5,17	148,16	3,70	0,69	1153,33	103,40	12682,33	98459,33	19699254,33	11491,67	81473,00	16448040,33	0,11	73	802	378	188	141	71	511
2018	1	1742	97019	3,77	4,59	5,23	149,62	2,43	1,02	1195,29	104,10	8011,33	47377,00	10724939,67	9637,67	69173,67	13618826,67	0,08	71	545	427	161	90	51	397
2018	2	1729	95953	3,78	4,67	5,31	151,03	2,43	0,73	1189,51	104,80	8011,33	47377,00	10724939,67	9637,67	69173,67	13618826,67	0,08	70	604	415	134	84	44	378
2018	3	1827	110905	3,88	4,79	5,45	152,76	2,43	0,99	1149,30	105,70	8011,33	47377,00	10724939,67	9637,67	69173,67	13618826,67	0,08	67	556	446	109	89	67	493
2018	4	2043	103087	4,05	4,98	5,74	154,82	2,47	1,87	1042,83	107,10	10990,00	73419,67	15176259,33	9686,00	67483,67	13112408,33	0,18	45	676	475	150	113	54	530
2018	5	2415	119655	4,41	5,22	5,99	158,47	2,47	1,62	1006,52	108,60	10990,00	73419,67	15176259,33	9686,00	67483,67	13112408,33	0,18	96	854	595	141	108	64	557
2018	6	2060	119413	4,63	5,41	6,17	162,42	2,47	2,61	965,20	109,10	10990,00	73419,67	15176259,33	9686,00	67483,67	13112408,33	0,18	83	764	525	117	74	50	447
2018	7	2858	123878	4,75	5,55	6,30	166,54	1,73	0,55	969,52	109,30	7319,67	46598,00	10484669,33	10214,00	68071,00	13303063,00	0,10	89	956	641	176	167	132	697
2018	8	3866	105154	5,73	6,61	7,51	173,89	1,73	2,30	927,23	108,70	7319,67	46598,00	10484669,33	10214,00	68071,00	13303063,00	0,10	305	1141	675	307	263	175	1000
2018	9	5615	127327	6,37	7,42	8,30	181,79	1,73	6,30	999,57	107,80	7319,67	46598,00	10484669,33	10214,00	68071,00	13303063,00	0,10	386	1799	1038	424	333	222	1413
2018	10	6276	146536	5,86	6,74	7,63	188,41	0,53	2,67	902,01	108,50	8515,33	55660,33	13426974,67	12834,67	93351,67	18168120,33	0,07	392	2283	1160	448	321	221	1451
2018	11	4672	89626	5,37	6,11	6,94	192,78	0,53	-1,44	954,16	109,20	8515,33	55660,33	13426974,67	12834,67	93351,67	18168120,33	0,07	278	1922	797	301	229	174	971
2018	12	4560	136845	5,31	6,04	6,76	197,62	0,53	-0,40	912,70	108,00	8515,33	55660,33	13426974,67	12834,67	93351,67	18168120,33	0,07	251	2170	744	252	192	112	839
2019	1	3168	72937	5,37	6,13	6,94	202,89	1,00	1,06	1040,74	107,60	4545,00	25608,67	6499820,67	10508,00	83277,33	17495742,00	0,11	182	1361	601	177	162	135	550
2019	2	3321	78450	5,26	5,98	6,87	208,08	1,00	0,16	1045,30	108,60	4545,00	25608,67	6499820,67	10508,00	83277,33	17495742,00	0,11	196	1440	672	192	138	80	543
2019	3	3129	105046	5,44	6,16	7,22	213,54	1,00	1,03	937,84	109,00	4545,00	25608,67	6499820,67	10508,00	83277,33	17495742,00	0,11	173	1520	626	121	110	104	475
2019	4	3720	96071	5,74	6,45	7,52	218,93	0,87	1,69	954,16	109,30	2984,67	14945,67	3779265,33	6485,33	48612,33	9644050,33	0,13	210	1839	676	201	142	95	557
2019	5	3925	91937	6,05	6,77	7,79	224,23	0,87	0,95	905,90	110,20	2984,67	14945,67	3779265,33	6485,33	48612,33	9644050,33	0,13	216	1734	850	187	136	106	696
2019	6	2689	61355	5,81	6,56	7,38	229,98	0,87	0,03	964,85	111,00	2984,67	14945,67	3779265,33	6485,33	48612,33	9644050,33	0,13	134	1009	668	122	123	72	561
2019	7	4192	102236	5,67	6,37	7,09	235,63	0,50	1,36	1020,82	112,40	3631,00	18470,33	4665469,33	6463,33	49325,33	9970128,67	0,07	249	1903	764	217	177	111	771
2019	8	3604	110538	5,62	6,26	6,88	238,46	0,50	0,86	967,18	114,40	3631,00	18470,33	4665469,33	6463,33	49325,33	9970128,67	0,07	213	1549	656	228	169	113	676
2019	9	4177	146903	5,71	6,29	7,07	241,37	0,50	0,99	1050,33	115,20	3631,00	18470,33	4665469,33	6463,33	49325,33	9970128,67	0,07	239	1924	744	213	141	136	780
2019	10	4272	142810	5,78	6,39	7,32	245,45	0,30	2,00	984,69	116,00	7411,67	47548,67	9505966,00	7836,67	65057,00	12920968,67	0,10	192	2043	912	215	134	75	701
2019	11	3988	138372	5,73	6,34	7,41	250,57	0,30	0,38	1069,04	117,10	7411,67	47548,67	9505966,00	7836,67	65057,00	12920968,67	0,10	218	1885	825	128	110	85	737
2019	12	5298	202074	5,84	6,48	7,69	255,84	0,30	0,74	1144,25	118,80	7411,67	47548,67	9505966,00	7836,67	65057,00	12920968,67	0,10	317	2650	957	212	154	135	873
2020	1	3907	113615	5,92	6,58	7,76	261,89	2,00	1,35	1191,40	120,90	4722,33	26933,00	5874789,49	6201,00	52008,00	10607384,17	0,12	235	1875	762	163	128	95	649
2020	2	4005	118753	6,04	6,59	7,88	269,42	2,00	0,35	1059,94	123,70	4722,33	26933,00	5874789,49	6201,00	52008,00	10607384,17	0,12	265	1987	805	115	131	80	622
2020	3	3036	108670	6,31	6,99	7,86	277,65	2,00	0,57	896,44	125,40	4722,33	26933,00	5874789,49	6201,00	52008,00	10607384,17	0,12	165	1513	584	93	80	60	541
2020	4	790	42783	6,82	7,42	8,52	288,78	1,50	0,85	1011,10	127,50	6545,00	45948,67	9167515,45	4830,67	38324,33	7858806,49	0,07	47	374	150	21	25	7	166
2020	5	860	50936	6,95	7,56	8,57	300,11	1,50	1,36	1055,20	135,90	6545,00	45948,67	9167515,45	4830,67	38324,33	7858806,49	0,07	72	423	130	23	24	11	177
2020	6	1664	190012	6,81	7,66	8,56	310,39	1,50	1,13	1165,25	139,50	6545,00	45948,67	9167515,45	4830,67	38324,33	7858806,49	0,07	180	730	277	34	44	29	370
2020	7	2741	229357	6,85	7,82	8,68	323,26	3,30	0,58	1126,90	141,40	8442,33	47024,00	9292069,76	7037,67	51209,33	10341771,35	0,07	230	1046	615	75	88	51	636
2020	8	3893	170408	7,25	8,58	9,59	340,26	3,30	0,86	1078,61	144,40	8442,33	47024,00	9292069,76	7037,67	51209,33	10341771,35	0,07	288	1648	784	119	133	95	826
2020	9	5269	136744	7,51	8,86	9,80	356,14	3,30	0,97	1145,24	146,70	8442,33	47024,00	9292069,76	7037,67	51209,33	10341771,35	0,07	347	2370	1018	239	168	127	1000
2020	10	5258	119574	7,87	9,27	10,27	373,53	2,23	2,13	1112,37	149,90	12370,67	65226,67	13246431,70	7885,67	58490,33	11935071,76	0,04	347	2458	928	186	187	123	1029
2020	11	4962	112483	8,00	9,46	10,57	390,58	2,23	2,30	1283,58	152,20	12370,67	65226,67	13246431,70	7885,67	58490,33	11935071,76	0,04	297	2443	893	174	182	94	879
2020	12	4427	105981	7,72	9,38	10,39	462,72	2,23	1,25	1476,72	154,90	12370,67	652												

2021	8	5866	141400	8,48	9,98	11,73	489,92	7,23	1,12	1472,07	192,70	10150,33	49805,00	11115416,94	7318,00	46241,00	9431467,18	0,10	400	2729	976	206	233	129	1193
2021	9	6630	147143	8,51	10,03	11,77	470,59	7,23	1,25	1406,39	198,90	10150,33	49805,00	11115416,94	7318,00	46241,00	9431467,18	0,10	408	2995	1358	204	228	122	1315
2021	10	5893	137401	9,14	10,60	12,57	521,44	2,47	2,39	1522,04	210,20	14566,33	79859,00	17096677,10	10246,00	69417,00	14055245,70	0,11	359	2464	1385	167	197	121	1200
2021	11	7363	178814	10,52	12,01	14,42	634,13	2,47	3,51	1809,65	229,20	14566,33	79859,00	17096677,10	10246,00	69417,00	14055245,70	0,11	428	2922	1917	175	218	171	1532
2021	12	7841	226503	13,53	15,29	18,09	817,61	2,47	13,58	1857,65	247,40	14566,33	79859,00	17096677,10	10246,00	69417,00	14055245,70	0,11	489	3300	1827	248	236	200	1541
2022	1	4186	88306	13,52	15,31	18,40	795,39	2,50	11,10	2003,20	279,90	8718,00	42874,00	9057516,00	7495,00	51828,00	10149752,00	0,12	269	1771	914	117	117	107	891
2022	2	4591	97587	13,62	15,44	18,53	824,04	2,50	4,81	1946,19	318,00	8718,00	42874,00	9057516,00	7495,00	51828,00	10149752,00	0,12	288	1958	1099	161	116	89	880
2022	3	5567	134170	14,57	16,05	19,30	926,51	2,50	5,46	2233,30	347,70	8718,00	42874,00	9057516,00	7495,00	51828,00	10149752,00	0,12	347	2245	1434	174	159	135	1073
2022	4	6447	133058	14,68	15,93	19,09	921,01	2,57	7,25	2430,55	383,00	9640,00	47490,00	101839614,00	7658,00	49842,00	9824407,00	0,10	333	2564	1970	158	167	133	1122
2022	5	5962	122768	15,62	16,53	19,62	944,07	2,57	2,98	2547,09	431,10	9640,00	47490,00	101839614,00	7658,00	49842,00	9824407,00	0,10	249	2451	1885	132	135	122	988
2022	6	8630	150509	16,96	17,96	21,00	1018,48	2,57	4,95	2405,36	470,00	9640,00	47490,00	101839614,00	7658,00	49842,00	9824407,00	0,10	276	3906	2534	226	177	193	1318
2022	7	3939	93902	17,39	17,77	21,06	998,91	1,30	2,37	2592,38	507,80	9426,00	47968,00	10593600,00	7586,00	45807,00	9155818,00	0,09	148	1154	1421	165	152	81	818
2022	8	5273	123491	17,99	18,25	21,69	1040,39	1,30	1,46	3171,21	548,20	9426,00	47968,00	10593600,00	7586,00	45807,00	9155818,00	0,09	208	1750	1814	193	192	95	1021
2022	9	5049	113402	18,28	18,13	20,81	1010,29	1,30	3,08	3179,99	575,00	9426,00	47968,00	10593600,00	7586,00	45807,00	9155818,00	0,09	177	1795	1585	206	160	99	1027
2022	10	5377	102660	18,56	18,25	21,01	1010,47	1,87	3,54	3978,96	605,80	14755,00	92260,00	18520664,00	10279,00	66570,00	13839597,00	0,12	142	1658	2123	148	143	75	1088
2022	11	6083	117806	18,59	18,92	21,90	1047,70	1,87	2,88	4331,66	628,60	14755,00	92260,00	18520664,00	10279,00	66570,00	13839597,00	0,12	127	1733	2616	157	152	64	1234
2022	12	6386	207963	18,64	19,70	22,77	1091,54	1,87	1,18	5046,19	662,50	14755,00	92260,00	18520664,00	10279,00	66570,00	13839597,00	0,12	123	1968	2465	165	147	66	1452
2023	1	4161	97708	18,79	20,25	23,00	1165,67	1,33	6,65	5568,43	708,50	7947,00	43587,00	8939410,00	6729,00	42046,00	8417249,00	0,15	124	1380	1592	140	112	65	748
2023	2	3350	80031	18,86	20,21	22,85	1108,61	1,33	3,15	4998,82	768,10	7947,00	43587,00	8939410,00	6729,00	42046,00	8417249,00	0,15	109	1133	1261	97	71	40	639
2023	3	3415	105476	19,01	20,36	23,12	1214,35	1,33	2,29	5258,74	809,60	7947,00	43587,00	8939410,00	6729,00	42046,00	8417249,00	0,15	101	1090	1324	83	85	30	702
2023	4	2557	85652	19,34	21,21	24,13	1242,82	1,27	2,39	4806,40	847,40	10237,00	62913,00	12857630,00	5970,00	35627,00	7020848,00	0,18	90	792	1024	34	64	26	527
2023	5	3167	113276	19,77	21,49	24,73	1312,42	1,27	0,04	4628,36	878,00	10237,00	62913,00	12857630,00	5970,00	35627,00	7020848,00	0,18	80	934	1245	89	95	47	677
2023	6	2625	83636	23,23	25,14	29,37	1575,04	1,27	3,92	4928,63	921,00	10237,00	62913,00	12857630,00	5970,00	35627,00	7020848,00	0,18	76	760	1004	72	80	32	601

(1. Yıl, 2. Ay, 3. YKS, 4. TKS, 5. Dolar, 6. Euro, 7. Sterlin, 8. Altın, 9. GSBH, 10. Enflasyon, 11. BE, 12. KFE, 13. YRBS, 14. YRDS, 15. YRVYÖ, 16. YKİVBS, 17. YKİVDS, 18. YKVYÖ, 19. BE, 20. Ankara, 21. İstanbul, 22. Antalya, 23. Bursa, 24. Yalova, 25. Sakarya, 26. Di)

**Ek-4. Birinci Veri Seti (Bağımsız Değişkenler)**

Yıl	Ay	Toplam Konut Satışları	Dolar	Euro	Sterlin	Altın	Enflasyon	Borsa Endeksi	Konut Fiyat Endeksi	Ankara	İstanbul	Antalya	Bursa	Yalova	Sakarya	Diğer İller
2013	1	87444	1,76	2,34	2,83	96,55	1,65	760,15	56,90	9	138	448	23	26	2	242
2013	2	88519	1,77	2,37	2,76	96,12	0,30	793,34	57,60	13	120	357	16	17	2	191
2013	3	97956	1,81	2,34	2,74	95,79	0,66	858,99	58,40	10	198	495	19	34	6	200
2013	4	95381	1,80	2,34	2,76	95,13	0,42	860,46	59,20	10	209	445	31	27	9	216
2013	5	103261	1,82	2,37	2,80	94,39	0,15	859,90	60,00	10	188	476	16	10	3	235
2013	6	96424	1,89	2,50	2,95	93,35	0,76	762,95	60,60	14	155	358	14	16	10	216
2013	7	106636	1,93	2,52	2,94	92,28	0,31	733,77	61,20	5	192	505	33	14	9	356
2013	8	84480	1,95	2,60	3,05	91,52	-0,10	663,94	61,50	16	170	387	22	38	6	251
2013	9	102280	2,02	2,69	3,21	90,36	0,77	744,87	62,00	21	156	482	28	22	9	307
2013	10	76344	1,99	2,71	3,21	88,95	1,80	776,20	62,50	21	181	433	44	27	7	308
2013	11	102681	2,02	2,73	3,27	87,64	0,01	757,48	63,30	19	345	622	73	28	14	355
2013	12	115784	2,06	2,82	3,39	86,41	0,46	678,02	63,60	27	395	540	56	25	26	372
2014	1	87639	2,22	3,02	3,67	85,93	1,98	618,58	64,10	21	243	464	62	21	119	277
2014	2	82597	2,21	3,02	3,67	85,85	0,43	625,53	64,80	21	301	400	57	36	17	239
2014	3	87617	2,22	3,07	3,69	86,03	1,13	697,36	65,70	38	478	459	65	43	10	269
2014	4	83610	2,13	2,94	3,57	86,23	1,34	738,72	66,80	33	489	563	89	37	33	310
2014	5	90377	2,09	2,87	3,53	86,46	0,40	792,90	67,50	20	406	652	64	73	38	357
2014	6	92936	2,12	2,88	3,59	87,02	0,31	784,89	68,20	14	600	586	88	63	18	334
2014	7	85101	2,12	2,88	3,64	87,79	0,45	821,57	69,30	28	416	569	66	39	12	343
2014	8	105624	2,16	2,88	3,62	88,17	0,09	803,13	70,20	38	511	591	96	64	29	545
2014	9	115786	2,20	2,85	3,62	88,19	0,14	749,38	70,90	42	546	590	87	81	25	486
2014	10	95645	2,26	2,86	3,64	88,53	1,90	805,80	71,50	32	556	612	78	84	37	407
2014	11	103783	2,23	2,79	3,54	88,64	0,18	861,69	72,40	37	500	549	86	103	80	332
2014	12	134666	2,29	2,82	3,60	89,23	-0,44	857,21	73,10	45	534	507	116	121	94	438
2015	1	86167	2,33	2,72	3,55	89,58	1,10	889,46	74,20	41	377	392	81	95	49	254
2015	2	95021	2,46	2,79	3,78	90,00	0,71	841,48	75,40	33	466	356	106	77	50	281
2015	3	116030	2,58	2,80	3,89	90,30	1,19	808,46	76,60	32	548	451	103	119	65	292
2015	4	119317	2,65	2,85	3,97	91,39	1,63	839,47	77,70	52	584	507	133	133	63	375
2015	5	107888	2,65	2,96	4,11	92,64	0,56	829,81	78,90	44	636	546	128	104	44	480
2015	6	110657	2,70	3,03	4,22	93,81	-0,51	822,50	79,90	40	718	610	125	123	92	548
2015	7	96589	2,69	2,97	4,22	94,54	0,09	799,10	80,60	44	541	868	112	127	59	458

2015	8	112463	2,85	3,17	4,46	95,67	0,40	752,10	81,10	51	602	518	177	147	110	439
2015	9	92483	3,00	3,37	4,64	97,41	0,89	742,05	81,70	41	561	440	112	126	66	422
2015	10	104098	2,93	3,30	4,50	99,12	1,55	794,09	82,70	66	780	567	136	118	73	496
2015	11	106008	2,87	3,09	4,38	100,39	0,67	752,33	83,70	80	703	539	149	138	87	423
2015	12	142599	2,92	3,17	4,39	101,38	0,21	717,27	84,50	75	977	460	139	118	75	439
2016	1	84556	3,01	3,27	4,35	102,44	1,82	734,81	85,70	68	498	315	129	84	51	317
2016	2	101703	2,94	3,26	4,22	103,84	-0,02	758,14	86,60	61	555	328	141	90	93	317
2016	3	117205	2,89	3,21	4,12	105,26	-0,04	832,68	87,50	56	583	360	115	66	48	367
2016	4	106348	2,83	3,21	4,07	106,18	0,78	853,28	88,60	55	540	360	116	71	66	373
2016	5	114800	2,93	3,31	4,28	107,74	0,58	778,03	89,70	54	511	407	118	53	35	434
2016	6	106187	2,92	3,28	4,16	109,24	0,47	768,17	90,50	42	507	381	80	49	39	445
2016	7	81343	2,96	3,27	3,92	111,59	1,16	754,06	91,30	35	300	281	60	37	41	290
2016	8	114751	2,96	3,32	3,90	113,61	-0,29	759,68	92,30	55	390	370	111	86	59	441
2016	9	108918	2,96	3,32	3,90	115,10	0,18	764,88	92,80	39	323	359	82	67	57	349
2016	10	130274	3,07	3,39	3,81	116,51	1,44	785,36	93,50	46	423	467	115	67	47	401
2016	11	132655	3,27	3,53	4,08	119,18	0,52	739,95	94,00	49	596	409	111	85	48	475
2016	12	142713	3,49	3,68	4,38	121,66	1,64	781,39	94,80	63	585	315	140	67	73	397
2017	1	95389	3,73	3,97	4,63	124,83	2,46	862,96	95,50	72	441	264	137	62	70	340
2017	2	101468	3,67	3,91	4,59	127,46	0,81	874,78	96,70	59	458	279	119	62	41	288
2017	3	128923	3,67	3,92	4,54	129,94	1,02	889,47	97,90	73	579	313	124	88	80	321
2017	4	114446	3,65	3,91	4,62	132,99	1,31	946,55	98,70	65	571	385	109	69	42	383
2017	5	116558	3,56	3,93	4,62	134,91	0,45	975,42	99,80	55	530	442	120	92	67	469
2017	6	97579	3,52	3,95	4,52	136,81	-0,27	1004,40	100,30	68	903	408	93	59	37	358
2017	7	115869	3,56	4,09	4,64	138,12	0,15	1075,31	100,50	68	528	386	102	80	68	494
2017	8	120198	3,51	4,14	4,57	139,57	0,52	1100,10	100,80	53	524	376	100	103	81	447
2017	9	140298	3,47	4,14	4,65	141,29	0,65	1029,08	101,40	67	797	520	119	87	64	582
2017	10	122882	3,66	4,31	4,86	143,47	2,08	1101,43	102,20	83	1321	465	121	108	55	524
2017	11	122732	3,88	4,55	5,16	145,83	1,49	1039,84	102,80	81	728	491	142	128	94	488
2017	12	132972	3,85	4,55	5,17	148,16	0,69	1153,33	103,40	73	802	378	188	141	71	511
2018	1	97019	3,77	4,59	5,23	149,62	1,02	1195,29	104,10	71	545	427	161	90	51	397
2018	2	95953	3,78	4,67	5,31	151,03	0,73	1189,51	104,80	70	604	415	134	84	44	378
2018	3	110905	3,88	4,79	5,45	152,76	0,99	1149,30	105,70	67	556	446	109	89	67	493
2018	4	103087	4,05	4,98	5,74	154,82	1,87	1042,83	107,10	45	676	475	150	113	54	530
2018	5	119655	4,41	5,22	5,99	158,47	1,62	1006,52	108,60	96	854	595	141	108	64	557
2018	6	119413	4,63	5,41	6,17	162,42	2,61	965,20	109,10	83	764	525	117	74	50	447
2018	7	123878	4,75	5,55	6,30	166,54	0,55	969,52	109,30	89	956	641	176	167	132	697

2018	8	105154	5,73	6,61	7,51	173,89	2,30	927,23	108,70	305	1141	675	307	263	175	1000
2018	9	127327	6,37	7,42	8,30	181,79	6,30	999,57	107,80	386	1799	1038	424	333	222	1413
2018	10	146536	5,86	6,74	7,63	188,41	2,67	902,01	108,50	392	2283	1160	448	321	221	1451
2018	11	89626	5,37	6,11	6,94	192,78	-1,44	954,16	109,20	278	1922	797	301	229	174	971
2018	12	136845	5,31	6,04	6,76	197,62	-0,40	912,70	108,00	251	2170	744	252	192	112	839
2019	1	72937	5,37	6,13	6,94	202,89	1,06	1040,74	107,60	182	1361	601	177	162	135	550
2019	2	78450	5,26	5,98	6,87	208,08	0,16	1045,30	108,60	196	1440	672	192	138	80	543
2019	3	105046	5,44	6,16	7,22	213,54	1,03	937,84	109,00	173	1520	626	121	110	104	475
2019	4	96071	5,74	6,45	7,52	218,93	1,69	954,16	109,30	210	1839	676	201	142	95	557
2019	5	91937	6,05	6,77	7,79	224,23	0,95	905,90	110,20	216	1734	850	187	136	106	696
2019	6	61355	5,81	6,56	7,38	229,98	0,03	964,85	111,00	134	1009	668	122	123	72	561
2019	7	102236	5,67	6,37	7,09	235,63	1,36	1020,82	112,40	249	1903	764	217	177	111	771
2019	8	110538	5,62	6,26	6,88	238,46	0,86	967,18	114,40	213	1549	656	228	169	113	676
2019	9	146903	5,71	6,29	7,07	241,37	0,99	1050,33	115,20	239	1924	744	213	141	136	780
2019	10	142810	5,78	6,39	7,32	245,45	2,00	984,69	116,00	192	2043	912	215	134	75	701
2019	11	138372	5,73	6,34	7,41	250,57	0,38	1069,04	117,10	218	1885	825	128	110	85	737
2019	12	202074	5,84	6,48	7,69	255,84	0,74	1144,25	118,80	317	2650	957	212	154	135	873
2020	1	113615	5,92	6,58	7,76	261,89	1,35	1191,40	120,90	235	1875	762	163	128	95	649
2020	2	118753	6,04	6,59	7,88	269,42	0,35	1059,94	123,70	265	1987	805	115	131	80	622
2020	3	108670	6,31	6,99	7,86	277,65	0,57	896,44	125,40	165	1513	584	93	80	60	541
2020	4	42783	6,82	7,42	8,52	288,78	0,85	1011,10	127,50	47	374	150	21	25	7	166
2020	5	50936	6,95	7,56	8,57	300,11	1,36	1055,20	135,90	72	423	130	23	24	11	177
2020	6	190012	6,81	7,66	8,56	310,39	1,13	1165,25	139,50	180	730	277	34	44	29	370
2020	7	229357	6,85	7,82	8,68	323,26	0,58	1126,90	141,40	230	1046	615	75	88	51	636
2020	8	170408	7,25	8,58	9,59	340,26	0,86	1078,61	144,40	288	1648	784	119	133	95	826
2020	9	136744	7,51	8,86	9,80	356,14	0,97	1145,24	146,70	347	2370	1018	239	168	127	1000
2020	10	119574	7,87	9,27	10,27	373,53	2,13	1112,37	149,90	347	2458	928	186	187	123	1029
2020	11	112483	8,00	9,46	10,57	390,58	2,30	1283,58	152,20	297	2443	893	174	182	94	879
2020	12	105981	7,72	9,38	10,39	462,72	1,25	1476,72	154,90	273	2308	789	98	131	92	736
2021	1	70587	7,39	9,01	10,11	449,12	1,68	1473,45	157,70	179	1380	462	75	71	31	477
2021	2	81222	7,07	8,56	9,84	413,65	0,91	1471,39	161,70	211	1525	533	60	63	35	537
2021	3	111241	7,63	9,09	10,67	423,38	1,08	1391,73	165,50	252	2119	889	70	129	76	713
2021	4	95863	8,16	9,73	11,32	464,33	1,68	1397,82	168,80	228	2009	859	131	120	61	669
2021	5	59166	8,34	10,13	11,81	501,26	0,89	1420,49	175,40	106	818	341	41	55	75	340
2021	6	134731	8,60	10,37	12,12	512,01	1,94	1356,34	180,30	300	2257	906	148	146	113	878
2021	7	107785	8,61	10,19	11,95	500,55	1,80	1392,91	185,40	312	1951	931	158	122	128	893



2021	8	141400	8,48	9,98	11,73	489,92	1,12	1472,07	192,70	400	2729	976	206	233	129	1193
2021	9	147143	8,51	10,03	11,77	470,59	1,25	1406,39	198,90	408	2995	1358	204	228	122	1315
2021	10	137401	9,14	10,60	12,57	521,44	2,39	1522,04	210,20	359	2464	1385	167	197	121	1200
2021	11	178814	10,52	12,01	14,42	634,13	3,51	1809,65	229,20	428	2922	1917	175	218	171	1532
2021	12	226503	13,53	15,29	18,09	817,61	13,58	1857,65	247,40	489	3300	1827	248	236	200	1541
2022	1	88306	13,52	15,31	18,40	795,39	11,10	2003,20	279,90	269	1771	914	117	117	107	891
2022	2	97587	13,62	15,44	18,53	824,04	4,81	1946,19	318,00	288	1958	1099	161	116	89	880
2022	3	134170	14,57	16,05	19,30	926,51	5,46	2233,30	347,70	347	2245	1434	174	159	135	1073
2022	4	133058	14,68	15,93	19,09	921,01	7,25	2430,55	383,00	333	2564	1970	158	167	133	1122
2022	5	122768	15,62	16,53	19,62	944,07	2,98	2547,09	431,10	249	2451	1885	132	135	122	988
2022	6	150509	16,96	17,96	21,00	1018,48	4,95	2405,36	470,00	276	3906	2534	226	177	193	1318
2022	7	93902	17,39	17,77	21,06	998,91	2,37	2592,38	507,80	148	1154	1421	165	152	81	818
2022	8	123491	17,99	18,25	21,69	1040,39	1,46	3171,21	548,20	208	1750	1814	193	192	95	1021
2022	9	113402	18,28	18,13	20,81	1010,29	3,08	3179,99	575,00	177	1795	1585	206	160	99	1027
2022	10	102660	18,56	18,25	21,01	1010,47	3,54	3978,96	605,80	142	1658	2123	148	143	75	1088
2022	11	117806	18,59	18,92	21,90	1047,70	2,88	4331,66	628,60	127	1733	2616	157	152	64	1234
2022	12	207963	18,64	19,70	22,77	1091,54	1,18	5046,19	662,50	123	1968	2465	165	147	66	1452
2023	1	97708	18,79	20,25	23,00	1165,67	6,65	5568,43	708,50	124	1380	1592	140	112	65	748
2023	2	80031	18,86	20,21	22,85	1108,61	3,15	4998,82	768,10	109	1133	1261	97	71	40	639
2023	3	105476	19,01	20,36	23,12	1214,35	2,29	5258,74	809,60	101	1090	1324	83	85	30	702
2023	4	85652	19,34	21,21	24,13	1242,82	2,39	4806,40	847,40	90	792	1024	34	64	26	527
2023	5	113276	19,77	21,49	24,73	1312,42	0,04	4628,36	878,00	80	934	1245	89	95	47	677
2023	6	83636	23,23	25,14	29,37	1575,04	3,92	4928,63	921,00	76	760	1004	72	80	32	601

**Ek-5. Karar Ağacı Regresyon Yönteminde Kullanılan Kütüphane Kodları**

<code>import pandas as pd</code>
<code>import numpy as np</code>
<code>import matplotlib.pyplot as plt</code>
<code>import seaborn as sns</code>
<code>from sklearn.preprocessing import StandardScaler</code>
<code>from sklearn.model_selection import KFold, train_test_split, cross_val_predict, cross_val_score</code>
<code>from sklearn.tree import DecisionTreeRegressor</code>
<code>from sklearn.metrics import root_mean_square_error, mean_absolute_error, mean_squared_error, R2_score, mean_absolute_percentage_error</code>

**Ek-6.** Rastgele Orman Regresyon Yönteminde Kullanılan Kütüphane Kodları

<code>import pandas as pd</code>
<code>import numpy as np</code>
<code>import matplotlib.pyplot as plt</code>
<code>import seaborn as sns</code>
<code>from sklearn.preprocessing import StandardScaler</code>
<code>from sklearn.model_selection import KFold, train_test_split, cross_val_predict, cross_val_score</code>
<code>from sklearn.ensemble import RandomForestRegressor</code>
<code>from sklearn.metrics import root_mean_square_error, mean_absolute_error, mean_squared_error, R2_score, mean_absolute_percentage_error</code>

**Ek-7. Çok Katmanlı Yapay Sinir Ağı Yönteminde Kullanılan Kütüphane Kodları**

<code>import pandas as pd</code>
<code>import numpy as np</code>
<code>import matplotlib.pyplot as plt</code>
<code>import seaborn as sns</code>
<code>from sklearn.preprocessing import StandardScaler</code>
<code>from sklearn.model_selection import KFold, train_test_split, cross_val_predict, cross_val_score</code>
<code>from sklearn.neural_network import MLPRegressor</code>
<code>from sklearn.metrics import root_mean_square_error, mean_absolute_error, mean_squared_error, R2_score, mean_absolute_percentage_error</code>

## Ek-8. İkinci Veri Çerçevesi (İlk Kısım)

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
2015	1	1289	86167	2,33	2,72	3,55	89,58	0,87	1,10	889,46	74,20	8580	62361	13353773	7907	53660	10368578	0,18	41
2015	2	1369	95021	2,46	2,79	3,78	90,00	0,87	0,71	841,48	75,40	8580	62361	13353773	7907	53660	10368578	0,18	33
2015	3	1610	116030	2,58	2,80	3,89	90,30	0,87	1,19	808,46	76,60	8580	62361	13353773	7907	53660	10368578	0,18	32
2015	4	1847	119317	2,65	2,85	3,97	91,39	0,77	1,63	839,47	77,70	11342	82028	17319823	9613	64902	12509078	0,23	52
2015	5	1982	107888	2,65	2,96	4,11	92,64	0,77	0,56	829,81	78,90	11342	82028	17319823	9613	64902	12509078	0,23	44
2015	6	2256	110657	2,70	3,03	4,22	93,81	0,77	-0,51	822,50	79,90	11342	82028	17319823	9613	64902	12509078	0,23	40
2015	7	2027	96589	2,69	2,97	4,22	94,54	1,27	0,09	799,10	80,60	10135	70414	14728272	8643	55632	10902450	0,28	44
2015	8	2044	112463	2,85	3,17	4,46	95,67	1,27	0,40	752,10	81,10	10135	70414	14728272	8643	55632	10902450	0,28	51
2015	9	1768	92483	3,00	3,37	4,64	97,41	1,27	0,89	742,05	81,70	10135	70414	14728272	8643	55632	10902450	0,28	41
2015	10	2236	104098	2,93	3,30	4,50	99,12	1,33	1,55	794,09	82,70	11857	84274	17822974	10572	70122	13921777	0,22	66
2015	11	2119	106008	2,87	3,09	4,38	100,39	1,33	0,67	752,33	83,70	11857	84274	17822974	10572	70122	13921777	0,22	80
2015	12	2283	142599	2,92	3,17	4,39	101,38	1,33	0,21	717,27	84,50	11857	84274	17822974	10572	70122	13921777	0,22	75
2016	1	1462	84556	3,01	3,27	4,35	102,44	1,90	1,82	734,81	85,70	11341	87206	18352667	8226	54900	10739659	0,18	68
2016	2	1585	101703	2,94	3,26	4,22	103,84	1,90	-0,02	758,14	86,60	11341	87206	18352667	8226	54900	10739659	0,18	61
2016	3	1595	117205	2,89	3,21	4,12	105,26	1,90	-0,04	832,68	87,50	11341	87206	18352667	8226	54900	10739659	0,18	56
2016	4	1581	106348	2,83	3,21	4,07	106,18	1,60	0,78	853,28	88,60	11806	84110	17520014	9556	62829	12635670	0,15	55
2016	5	1612	114800	2,93	3,31	4,28	107,74	1,60	0,58	778,03	89,70	11806	84110	17520014	9556	62829	12635670	0,15	54
2016	6	1543	106187	2,92	3,28	4,16	109,24	1,60	0,47	768,17	90,50	11806	84110	17520014	9556	62829	12635670	0,15	42
2016	7	1044	81343	2,96	3,27	3,92	111,59	1,03	1,16	754,06	91,30	8870	65775	13418578	7853	52189	10611891	0,15	35
2016	8	1512	114751	2,96	3,32	3,90	113,61	1,03	-0,29	759,68	92,30	8870	65775	13418578	7853	52189	10611891	0,15	55
2016	9	1276	108918	2,96	3,32	3,90	115,10	1,03	0,18	764,88	92,80	8870	65775	13418578	7853	52189	10611891	0,15	39
2016	10	1566	130274	3,07	3,39	3,81	116,51	0,60	1,44	785,36	93,50	12682	98459	19699254	11492	81473	16448040	0,20	46
2016	11	1773	132655	3,27	3,53	4,08	119,18	-0,60	0,52	739,95	94,00	12682	98459	19699254	11492	81473	16448040	0,20	49
2016	12	1640	142713	3,49	3,68	4,38	121,66	-0,60	1,64	781,39	94,80	12682	98459	19699254	11492	81473	16448040	0,20	63
2017	1	1386	95389	3,73	3,97	4,63	124,83	1,17	2,46	862,96	95,50	9886	79560	15638028	9072	65561	13283253	0,15	72
2017	2	1306	101468	3,67	3,91	4,59	127,46	1,17	0,81	874,78	96,70	9886	79560	15638028	9072	65561	13283253	0,15	59
2017	3	1578	128923	3,67	3,92	4,54	129,94	1,17	1,02	889,47	97,90	9886	79560	15638028	9072	65561	13283253	0,15	73
2017	4	1624	114446	3,65	3,91	4,62	132,99	1,67	1,31	946,55	98,70	16000	143524	28669594	9442	65064	12602822	0,16	65
2017	5	1775	116558	3,56	3,93	4,62	134,91	1,67	0,45	975,42	99,80	16000	143524	28669594	9442	65064	12602822	0,16	55
2017	6	1926	97579	3,52	3,95	4,52	136,81	1,67	-0,27	1004,40	100,30	16000	143524	28669594	9442	65064	12602822	0,16	68
2017	7	1726	115869	3,56	4,09	4,64	138,12	1,70	0,15	1075,31	100,50	18460	179160	36325125	9263	61372	12219937	0,14	68
2017	8	1684	120198	3,51	4,14	4,57	139,57	1,70	0,52	1100,10	100,80	18460	179160	36325125	9263	61372	12219937	0,14	53
2017	9	2236	140298	3,47	4,14	4,65	141,29	1,70	0,65	1029,08	101,40	18460	179160	36325125	9263	61372	12219937	0,14	67

2017	10	2677	122882	3,66	4,31	4,86	143,47	3,70	2,08	1101,43	102,20	12682	98459	19699254	11492	81473	16448040	0,11	83
2017	11	2152	122732	3,88	4,55	5,16	145,83	3,70	1,49	1039,84	102,80	12682	98459	19699254	11492	81473	16448040	0,11	81
2017	12	2164	132972	3,85	4,55	5,17	148,16	3,70	0,69	1153,33	103,40	12682	98459	19699254	11492	81473	16448040	0,11	73
2018	1	1742	97019	3,77	4,59	5,23	149,62	2,43	1,02	1195,29	104,10	8011	47377	10724940	9638	69174	13618827	0,08	71
2018	2	1729	95953	3,78	4,67	5,31	151,03	2,43	0,73	1189,51	104,80	8011	47377	10724940	9638	69174	13618827	0,08	70
2018	3	1827	110905	3,88	4,79	5,45	152,76	2,43	0,99	1149,30	105,70	8011	47377	10724940	9638	69174	13618827	0,08	67
2018	4	2043	103087	4,05	4,98	5,74	154,82	2,47	1,87	1042,83	107,10	10990	73420	15176259	9686	67484	13112408	0,18	45
2018	5	2415	119655	4,41	5,22	5,99	158,47	2,47	1,62	1006,52	108,60	10990	73420	15176259	9686	67484	13112408	0,18	96
2018	6	2060	119413	4,63	5,41	6,17	162,42	2,47	2,61	965,20	109,10	10990	73420	15176259	9686	67484	13112408	0,18	83
2018	7	2858	123878	4,75	5,55	6,30	166,54	1,73	0,55	969,52	109,30	7320	46598	10484669	10214	68071	13303063	0,10	89
2018	8	3866	105154	5,73	6,61	7,51	173,89	1,73	2,30	927,23	108,70	7320	46598	10484669	10214	68071	13303063	0,10	305
2018	9	5615	127327	6,37	7,42	8,30	181,79	1,73	6,30	999,57	107,80	7320	46598	10484669	10214	68071	13303063	0,10	386
2018	10	6276	146536	5,86	6,74	7,63	188,41	0,53	2,67	902,01	108,50	8515	55660	13426975	12835	93352	18168120	0,07	392
2018	11	4672	89626	5,37	6,11	6,94	192,78	0,53	-1,44	954,16	109,20	8515	55660	13426975	12835	93352	18168120	0,07	278
2018	12	4560	136845	5,31	6,04	6,76	197,62	0,53	-0,40	912,70	108,00	8515	55660	13426975	12835	93352	18168120	0,07	251
2019	1	3168	72937	5,37	6,13	6,94	202,89	-1,00	1,06	1040,74	107,60	4545	25609	6499821	10508	83277	17495742	0,11	182
2019	2	3321	78450	5,26	5,98	6,87	208,08	-1,00	0,16	1045,30	108,60	4545	25609	6499821	10508	83277	17495742	0,11	196
2019	3	3129	105046	5,44	6,16	7,22	213,54	-1,00	1,03	937,84	109,00	4545	25609	6499821	10508	83277	17495742	0,11	173
2019	4	3720	96071	5,74	6,45	7,52	218,93	-0,87	1,69	954,16	109,30	2985	14946	3779265	6485	48612	9644050	0,13	210
2019	5	3925	91937	6,05	6,77	7,79	224,23	-0,87	0,95	905,90	110,20	2985	14946	3779265	6485	48612	9644050	0,13	216
2019	6	2689	61355	5,81	6,56	7,38	229,98	-0,87	0,03	964,85	111,00	2985	14946	3779265	6485	48612	9644050	0,13	134
2019	7	4192	102236	5,67	6,37	7,09	235,63	-0,50	1,36	1020,82	112,40	3631	18470	4665469	6463	49325	9970129	0,07	249
2019	8	3604	110538	5,62	6,26	6,88	238,46	-0,50	0,86	967,18	114,40	3631	18470	4665469	6463	49325	9970129	0,07	213
2019	9	4177	146903	5,71	6,29	7,07	241,37	-0,50	0,99	1050,33	115,20	3631	18470	4665469	6463	49325	9970129	0,07	239
2019	10	4272	142810	5,78	6,39	7,32	245,45	0,30	2,00	984,69	116,00	7412	47549	9505966	7837	65057	12920969	0,10	192
2019	11	3988	138372	5,73	6,34	7,41	250,57	0,30	0,38	1069,04	117,10	7412	47549	9505966	7837	65057	12920969	0,10	218
2019	12	5298	202074	5,84	6,48	7,69	255,84	0,30	0,74	1144,25	118,80	7412	47549	9505966	7837	65057	12920969	0,10	317
2020	1	3907	113615	5,92	6,58	7,76	261,89	2,00	1,35	1191,40	120,90	4722	26933	5874789	6201	52008	10607384	0,12	235
2020	2	4005	118753	6,04	6,59	7,88	269,42	2,00	0,35	1059,94	123,70	4722	26933	5874789	6201	52008	10607384	0,12	265
2020	3	3036	108670	6,31	6,99	7,86	277,65	2,00	0,57	896,44	125,40	4722	26933	5874789	6201	52008	10607384	0,12	165
2020	4	790	42783	6,82	7,42	8,52	288,78	1,50	0,85	1011,10	127,50	6545	45949	9167515	4831	38324	7858806	0,07	47
2020	5	860	50936	6,95	7,56	8,57	300,11	1,50	1,36	1055,20	135,90	6545	45949	9167515	4831	38324	7858806	0,07	72
2020	6	1664	190012	6,81	7,66	8,56	310,39	1,50	1,13	1165,25	139,50	6545	45949	9167515	4831	38324	7858806	0,07	180
2020	7	2741	229357	6,85	7,82	8,68	323,26	-3,30	0,58	1126,90	141,40	8442	47024	9292070	7038	51209	10341771	0,07	230
2020	8	3893	170408	7,25	8,58	9,59	340,26	-3,30	0,86	1078,61	144,40	8442	47024	9292070	7038	51209	10341771	0,07	288
2020	9	5269	136744	7,51	8,86	9,80	356,14	-3,30	0,97	1145,24	146,70	8442	47024	9292070	7038	51209	10341771	0,07	347

2020	10	5258	119574	7,87	9,27	10,27	373,53	2,23	2,13	1112,37	149,90	12371	65227	13246432	7886	58490	11935072	0,04	347
2020	11	4962	112483	8,00	9,46	10,57	390,58	2,23	2,30	1283,58	152,20	12371	65227	13246432	7886	58490	11935072	0,04	297
2020	12	4427	105981	7,72	9,38	10,39	462,72	2,23	1,25	1476,72	154,90	12371	65227	13246432	7886	58490	11935072	0,04	273
2021	1	2675	70587	7,39	9,01	10,11	449,12	1,97	1,68	1473,45	157,70	11197	58247	11464009	6993	53043	11014205	0,05	179
2021	2	2964	81222	7,07	8,56	9,84	413,65	1,97	0,91	1471,39	161,70	11197	58247	11464009	6993	53043	11014205	0,05	211
2021	3	4248	111241	7,63	9,09	10,67	423,38	1,97	1,08	1391,73	165,50	11197	58247	11464009	6993	53043	11014205	0,05	252
2021	4	4077	95863	8,16	9,73	11,32	464,33	2,33	1,68	1397,82	168,80	10179	52509	10606493	6170	40326	8098122	0,07	228
2021	5	1776	59166	8,34	10,13	11,81	501,26	2,33	0,89	1420,49	175,40	10179	52509	10606493	6170	40326	8098122	0,07	106
2021	6	4748	134731	8,60	10,37	12,12	512,01	2,33	1,94	1356,34	180,30	10179	52509	10606493	6170	40326	8098122	0,07	300
2021	7	4495	107785	8,61	10,19	11,95	500,55	7,23	1,80	1392,91	185,40	10150	49805	11115417	7318	46241	9431467	0,10	312
2021	8	5866	141400	8,48	9,98	11,73	489,92	7,23	1,12	1472,07	192,70	10150	49805	11115417	7318	46241	9431467	0,10	400
2021	9	6630	147143	8,51	10,03	11,77	470,59	7,23	1,25	1406,39	198,90	10150	49805	11115417	7318	46241	9431467	0,10	408
2021	10	5893	137401	9,14	10,60	12,57	521,44	2,47	2,39	1522,04	210,20	14566	79859	17096677	10246	69417	14055246	0,11	359
2021	11	7363	178814	10,52	12,01	14,42	634,13	2,47	3,51	1809,65	229,20	14566	79859	17096677	10246	69417	14055246	0,11	428
2021	12	7841	226503	13,53	15,29	18,09	817,61	2,47	13,58	1857,65	247,40	14566	79859	17096677	10246	69417	14055246	0,11	489
2022	1	4186	88306	13,52	15,31	18,40	795,39	2,50	11,10	2003,20	279,90	8718	42874	9057516	7495	51828	10149752	0,12	269
2022	2	4591	97587	13,62	15,44	18,53	824,04	2,50	4,81	1946,19	318,00	8718	42874	9057516	7495	51828	10149752	0,12	288
2022	3	5567	134170	14,57	16,05	19,30	926,51	2,50	5,46	2233,30	347,70	8718	42874	9057516	7495	51828	10149752	0,12	347
2022	4	6447	133058	14,68	15,93	19,09	921,01	2,57	7,25	2430,55	383,00	9640	47490	101839614	7658	49842	9824407	0,10	333
2022	5	5962	122768	15,62	16,53	19,62	944,07	2,57	2,98	2547,09	431,10	9640	47490	101839614	7658	49842	9824407	0,10	249
2022	6	8630	150509	16,96	17,96	21,00	1018,48	2,57	4,95	2405,36	470,00	9640	47490	101839614	7658	49842	9824407	0,10	276
2022	7	3939	93902	17,39	17,77	21,06	998,91	1,30	2,37	2592,38	507,80	9426	47968	10593600	7586	45807	9155818	0,09	148
2022	8	5273	123491	17,99	18,25	21,69	1040,39	1,30	1,46	3171,21	548,20	9426	47968	10593600	7586	45807	9155818	0,09	208
2022	9	5049	113402	18,28	18,13	20,81	1010,29	1,30	3,08	3179,99	575,00	9426	47968	10593600	7586	45807	9155818	0,09	177
2022	10	5377	102660	18,56	18,25	21,01	1010,47	1,87	3,54	3978,96	605,80	14755	92260	18520664	10279	66570	13839597	0,12	142
2022	11	6083	117806	18,59	18,92	21,90	1047,70	1,87	2,88	4331,66	628,60	14755	92260	18520664	10279	66570	13839597	0,12	127
2022	12	6386	207963	18,64	19,70	22,77	1091,54	1,87	1,18	5046,19	662,50	14755	92260	18520664	10279	66570	13839597	0,12	123
2023	1	4161	97708	18,79	20,25	23,00	1165,67	1,33	6,65	5568,43	708,50	7947	43587	8939410	6729	42046	8417249	0,15	124
2023	2	3350	80031	18,86	20,21	22,85	1108,61	1,33	3,15	4998,82	768,10	7947	43587	8939410	6729	42046	8417249	0,15	109
2023	3	3415	105476	19,01	20,36	23,12	1214,35	1,33	2,29	5258,74	809,60	7947	43587	8939410	6729	42046	8417249	0,15	101
2023	4	2557	85652	19,34	21,21	24,13	1242,82	1,27	2,39	4806,40	847,40	10237	62913	12857630	5970	35627	7020848	0,18	90
2023	5	3167	113276	19,77	21,49	24,73	1312,42	1,27	0,04	4628,36	878,00	10237	62913	12857630	5970	35627	7020848	0,18	80
2023	6	2625	83636	23,23	25,14	29,37	1575,04	1,27	3,92	4928,63	921,00	10237	62913	12857630	5970	35627	7020848	0,18	76

(1. Yıl, 2. Ay, 3. Yabancı Konut Satışı, 4. Toplam Konut Satışları, 5. Dolar, 6. Euro, 7. Sterlin, 8. Altın, 9. Gayrisafi Büyüme Hızı, 10. Enflasyon, 11. Borsa Endeksi, 12.

Konut Fiyat Endeksi, 13. Yapı Ruhsatlı Bina Sayısı, 14. Yapı Ruhsatlı Daire Sayısı, 15. Yapı Ruhsatı Verilen Yüz Ölçümü Metrekaresi, 16. Yapı Kullanım İzni Verilen Bina Sayısı, 17. Yapı Kullanım İzni Verilen Daire Sayısı, 18. Yapı Kullanım İzni Verilen Yüz Ölçümü Metrekaresi, 19. Belirsizlik Endeksi, 20. Ankara)

**Ek-9. İkinci Veri Çerçevesi (İkinci Kısım)**

1	2	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39
2015	1	377	392	81	95	49	254	240	124	157	54	66	56	44	20	30	44	11	14	444
2015	2	466	356	106	77	50	281	243	144	143	86	52	57	43	33	29	35	12	15	484
2015	3	548	451	103	119	65	292	297	168	138	48	40	58	60	33	61	52	19	14	632
2015	4	584	507	133	133	63	375	298	187	196	91	79	97	53	50	57	41	23	19	665
2015	5	636	546	128	104	44	480	276	216	222	103	73	50	52	37	79	46	21	21	801
2015	6	718	610	125	123	92	548	315	214	238	104	68	72	85	36	57	38	29	12	1005
2015	7	541	868	112	127	59	458	362	147	195	101	84	68	77	40	56	54	15	20	830
2015	8	602	518	177	147	110	439	401	226	155	86	71	54	58	58	35	58	30	29	797
2015	9	561	440	112	126	66	422	359	160	115	109	68	56	67	56	55	34	21	26	659
2015	10	780	567	136	118	73	496	430	142	191	133	76	77	62	75	49	46	32	25	911
2015	11	703	539	149	138	87	423	495	193	136	74	84	88	64	98	60	53	54	18	713
2015	12	977	460	139	118	75	439	512	209	150	65	108	82	79	120	40	39	51	30	809
2016	1	498	315	129	84	51	317	308	134	106	49	49	54	45	104	31	46	26	17	505
2016	2	555	328	141	90	93	317	365	159	88	45	50	54	52	141	25	40	28	21	535
2016	3	583	360	115	66	48	367	244	136	96	62	74	60	53	148	39	28	39	28	597
2016	4	540	360	116	71	66	373	276	172	96	65	50	47	66	115	24	27	28	14	620
2016	5	511	407	118	53	35	434	193	182	121	85	67	58	53	125	57	25	19	26	634
2016	6	507	381	80	49	39	445	214	110	114	102	96	63	55	107	56	36	28	21	556
2016	7	300	281	60	37	41	290	153	111	64	71	25	39	49	53	36	25	15	27	383
2016	8	390	370	111	86	59	441	267	155	117	58	52	53	50	75	40	42	41	29	543
2016	9	323	359	82	67	57	349	230	85	99	84	61	37	42	64	42	33	18	18	486
2016	10	423	467	115	67	47	401	257	135	132	94	63	42	72	88	46	25	27	25	572
2016	11	596	409	111	85	48	475	285	212	107	63	77	47	82	91	46	18	41	55	669
2016	12	585	315	140	67	73	397	144	153	84	49	50	56	45	94	42	35	38	64	710
2017	1	441	264	137	62	70	340	279	115	60	40	43	54	42	107	41	19	45	33	520
2017	2	458	279	119	62	41	288	282	114	77	37	35	55	42	81	35	16	46	24	474
2017	3	579	313	124	88	80	321	323	139	115	39	31	50	54	112	35	28	39	36	599
2017	4	571	385	109	69	42	383	245	169	99	55	74	65	33	81	31	25	38	38	681
2017	5	530	442	120	92	67	469	277	125	134	65	54	63	68	70	48	17	52	32	790
2017	6	903	408	93	59	37	358	239	136	115	87	64	46	62	73	42	35	31	17	994
2017	7	528	386	102	80	68	494	293	142	118	76	41	61	74	71	36	32	46	32	726
2017	8	524	376	100	103	81	447	317	135	95	78	66	45	49	81	37	18	61	52	665
2017	9	797	520	119	87	64	582	383	160	129	103	77	72	84	75	41	63	49	41	972

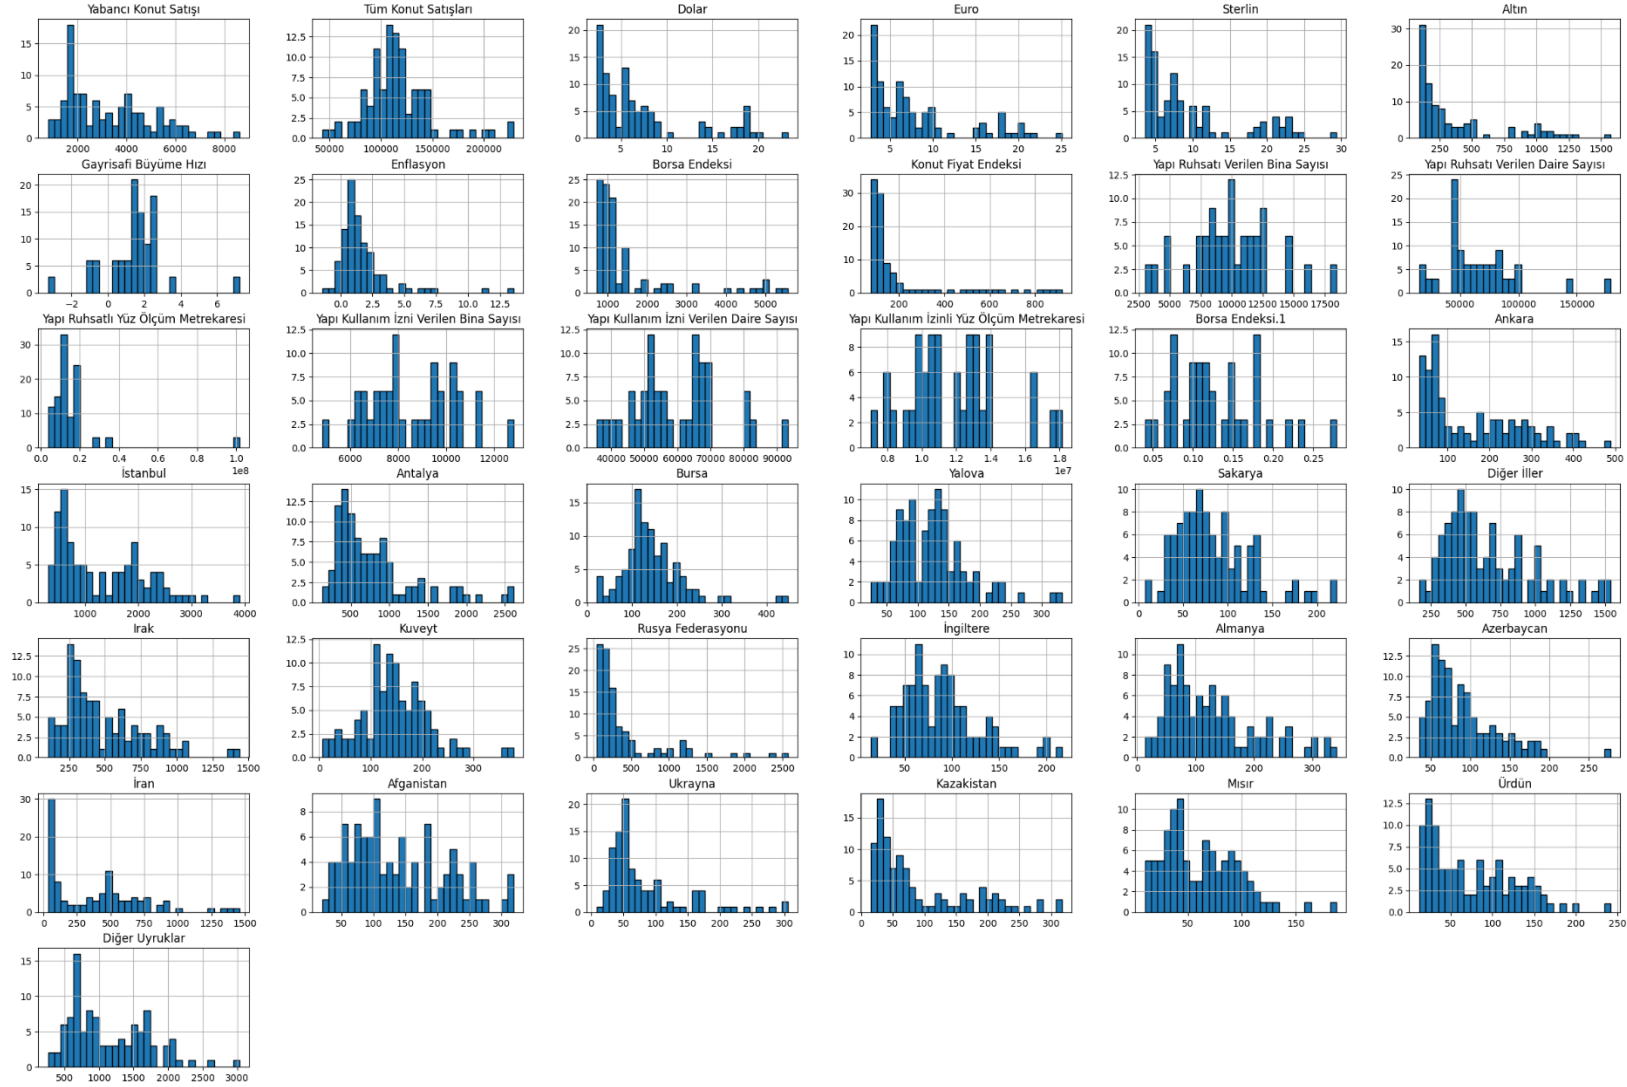


2017	10	1321	465	121	108	55	524	344	154	125	94	106	278	85	120	60	20	34	75	1199
2017	11	728	491	142	128	94	488	405	151	135	68	88	62	81	105	58	31	79	59	849
2017	12	802	378	188	141	71	511	418	151	129	52	93	91	118	102	41	30	67	44	845
2018	1	545	427	161	90	51	397	272	108	121	55	89	65	83	124	22	40	62	84	635
2018	2	604	415	134	84	44	378	308	99	128	48	53	63	122	118	32	28	45	46	668
2018	3	556	446	109	89	67	493	348	79	120	52	78	61	156	108	51	28	41	52	675
2018	4	676	475	150	113	54	530	337	116	112	57	97	68	138	99	54	29	44	62	846
2018	5	854	595	141	108	64	557	407	114	165	112	123	75	217	131	56	28	38	65	902
2018	6	764	525	117	74	50	447	315	90	169	88	102	82	228	139	44	35	38	64	691
2018	7	956	641	176	167	132	697	584	171	173	94	109	73	321	143	51	38	70	111	947
2018	8	1141	675	307	263	175	1000	944	271	192	97	177	96	394	183	50	57	90	124	1219
2018	9	1799	1038	424	333	222	1413	1351	360	263	193	299	180	538	227	54	79	67	199	1952
2018	10	2283	1160	448	321	221	1451	1439	378	336	217	341	177	557	319	88	73	75	242	2085
2018	11	1922	797	301	229	174	971	1003	218	261	128	203	144	463	261	60	60	69	143	1705
2018	12	2170	744	252	192	112	839	897	195	257	96	195	166	435	232	62	47	86	170	1776
2019	1	1361	601	177	162	135	550	605	130	195	76	119	95	305	191	50	30	83	151	1170
2019	2	1440	672	192	138	80	543	628	150	236	70	122	105	307	166	52	45	82	125	1269
2019	3	1520	626	121	110	104	475	548	123	156	74	101	87	334	150	47	37	59	101	1343
2019	4	1839	676	201	142	95	557	533	202	202	94	122	87	332	189	50	73	88	149	1647
2019	5	1734	850	187	136	106	696	594	152	285	149	155	90	509	183	80	71	99	144	1456
2019	6	1009	668	122	123	72	561	429	113	190	113	126	67	415	108	38	60	34	98	926
2019	7	1903	764	217	177	111	771	734	219	215	124	158	92	464	163	60	58	107	139	1708
2019	8	1549	656	228	169	113	676	675	159	212	109	149	88	469	146	56	59	72	105	1342
2019	9	1924	744	213	141	136	780	781	191	248	139	145	118	489	182	55	68	73	151	1577
2019	10	2043	912	215	134	75	701	597	182	292	166	225	125	536	185	71	80	83	121	1648
2019	11	1885	825	128	110	85	737	575	109	300	133	154	91	500	216	57	91	111	158	1542
2019	12	2650	957	212	154	135	873	897	173	362	106	147	146	763	312	103	104	100	154	1984
2020	1	1875	762	163	128	95	649	739	121	254	72	133	99	678	204	56	65	82	107	1335
2020	2	1987	805	115	131	80	622	691	79	282	66	108	90	721	256	76	74	93	141	1371
2020	3	1513	584	93	80	60	541	426	65	227	65	87	95	465	184	78	72	49	86	1176
2020	4	374	150	21	25	7	166	103	6	61	14	13	35	157	54	8	36	10	25	274
2020	5	423	130	23	24	11	177	143	7	40	16	15	42	209	48	25	15	23	25	262
2020	6	730	277	34	44	29	370	257	19	63	37	53	70	398	60	30	34	40	46	572
2020	7	1046	615	75	88	51	636	388	36	154	69	143	115	540	149	93	64	40	63	918
2020	8	1648	784	119	133	95	826	592	137	366	140	134	154	640	156	76	82	70	82	1303
2020	9	2370	1018	239	168	127	1000	826	241	448	197	161	183	908	166	73	222	97	134	1667

2020	10	2458	928	186	187	123	1029	909	210	400	202	159	137	849	225	83	213	109	144	1691
2020	11	2443	893	174	182	94	879	876	202	434	147	145	104	860	203	105	124	92	103	1627
2020	12	2308	789	98	131	92	736	724	108	349	101	114	155	764	224	68	170	79	124	1499
2021	1	1380	462	75	71	31	477	385	58	260	47	65	68	459	168	69	69	69	51	944
2021	2	1525	533	60	63	35	537	432	41	259	44	96	77	477	230	60	119	65	81	1014
2021	3	2119	889	70	129	76	713	644	49	419	98	142	106	663	302	93	166	99	91	1413
2021	4	2009	859	131	120	61	669	546	78	402	82	144	131	557	229	92	188	99	94	1510
2021	5	818	341	41	55	75	340	239	43	119	36	87	47	231	98	44	80	37	36	699
2021	6	2257	906	148	146	113	878	773	151	300	63	192	164	683	250	127	165	95	83	1780
2021	7	1951	931	158	122	128	893	712	189	365	63	198	127	619	229	106	166	97	102	1591
2021	8	2729	976	206	233	129	1193	900	264	451	110	262	138	911	313	98	176	94	136	2079
2021	9	2995	1358	204	228	122	1315	990	281	540	100	298	162	1323	270	101	210	108	133	2190
2021	10	2464	1385	167	197	121	1200	926	189	543	139	256	120	1265	188	122	191	129	105	1790
2021	11	2922	1917	175	218	171	1532	1075	185	836	157	322	185	1406	231	163	278	111	162	2330
2021	12	3300	1827	248	236	200	1541	1039	263	885	150	296	192	1462	254	171	282	163	183	2590
2022	1	1771	914	117	117	107	891	513	82	479	82	204	89	761	131	102	132	88	105	1466
2022	2	1958	1099	161	116	89	880	633	144	509	100	169	93	711	141	111	197	64	117	1650
2022	3	2245	1434	174	159	135	1073	741	156	547	140	244	115	784	214	168	241	126	117	2025
2022	4	2564	1970	158	167	133	1122	714	104	1152	116	221	156	905	247	263	311	117	111	2107
2022	5	2451	1885	132	135	122	988	617	130	1275	91	247	118	736	210	241	218	94	95	1961
2022	6	3906	2534	226	177	193	1318	807	190	1887	144	329	131	987	258	301	318	188	133	3034
2022	7	1154	1421	165	152	81	818	380	125	1028	90	163	65	431	83	166	190	53	47	1153
2022	8	1750	1814	193	192	95	1021	417	195	1238	92	256	106	633	108	219	231	88	66	1691
2022	9	1795	1585	206	160	99	1027	433	192	1196	120	225	115	592	95	204	207	79	81	1565
2022	10	1658	2123	148	143	75	1088	310	118	2023	98	211	99	498	62	216	200	68	68	1464
2022	11	1733	2616	157	152	64	1234	331	116	2575	92	224	104	510	80	277	191	79	78	1476
2022	12	1968	2465	165	147	66	1452	345	119	2403	71	212	139	675	103	306	266	71	53	1706
2023	1	1380	1592	140	112	65	748	229	113	1557	57	126	65	526	76	157	155	45	44	1048
2023	2	1133	1261	97	71	40	639	173	73	1183	43	124	73	446	69	142	133	36	34	857
2023	3	1090	1324	83	85	30	702	165	81	1175	65	112	69	472	51	160	121	41	33	896
2023	4	792	1024	34	64	26	527	124	24	817	46	73	54	377	50	136	89	41	29	711
2023	5	934	1245	89	95	47	677	118	82	991	56	129	75	503	49	175	107	33	22	843
2023	6	760	1004	72	80	32	601	175	46	733	55	127	59	333	42	168	142	24	37	710

(1. Yıl, 2. Ay, 20. Ankara, 21. İstanbul, 22. Antalya, 23. Bursa, 24. Yalova, 25. Sakarya, 26. Diğer İller, 27. Irak, 28. Kuveyt, 29. Rusya Federasyonu, 30. İngiltere, 31. Almanya, 32. Azerbaycan, 33. İran, 34. Afganistan, 35. Ukrayna, 36. Kazakistan, 37. Mısır, 38. Ürdün, 39. Diğer Uyrıklar)

## Ek-10. İkinci Veri Setindeki Değişkenlerin Histogram Grafikleri



**Ek-11. İkinci Veri Seti (Bağımsız Değişkenler)**

Yıl	Ay	Toplam Konut Satışları	Dolar	Euro	Sterlin	Altın	Enf	Irak	Kuveyt	Rusya	Ing	Almanya	Azerbaycan	Iran	Afg	Ukrayna	Kazakistan	Mısır	Ürdün	Diğer Uyruklar
2015	1	86167	2,33	2,72	3,55	89,58	1,10	240	124	157	54	66	56	44	20	30	44	11	14	444
2015	2	95021	2,46	2,79	3,78	90,00	0,71	243	144	143	86	52	57	43	33	29	35	12	15	484
2015	3	116030	2,58	2,80	3,89	90,30	1,19	297	168	138	48	40	58	60	33	61	52	19	14	632
2015	4	119317	2,65	2,85	3,97	91,39	1,63	298	187	196	91	79	97	53	50	57	41	23	19	665
2015	5	107888	2,65	2,96	4,11	92,64	0,56	276	216	222	103	73	50	52	37	79	46	21	21	801
2015	6	110657	2,70	3,03	4,22	93,81	-0,51	315	214	238	104	68	72	85	36	57	38	29	12	1005
2015	7	96589	2,69	2,97	4,22	94,54	0,09	362	147	195	101	84	68	77	40	56	54	15	20	830
2015	8	112463	2,85	3,17	4,46	95,67	0,40	401	226	155	86	71	54	58	58	35	58	30	29	797
2015	9	92483	3,00	3,37	4,64	97,41	0,89	359	160	115	109	68	56	67	56	55	34	21	26	659
2015	10	104098	2,93	3,30	4,50	99,12	1,55	430	142	191	133	76	77	62	75	49	46	32	25	911
2015	11	106008	2,87	3,09	4,38	100,39	0,67	495	193	136	74	84	88	64	98	60	53	54	18	713
2015	12	142599	2,92	3,17	4,39	101,38	0,21	512	209	150	65	108	82	79	120	40	39	51	30	809
2016	1	84556	3,01	3,27	4,35	102,44	1,82	308	134	106	49	49	54	45	104	31	46	26	17	505
2016	2	101703	2,94	3,26	4,22	103,84	-0,02	365	159	88	45	50	54	52	141	25	40	28	21	535
2016	3	117205	2,89	3,21	4,12	105,26	-0,04	244	136	96	62	74	60	53	148	39	28	39	28	597
2016	4	106348	2,83	3,21	4,07	106,18	0,78	276	172	96	65	50	47	66	115	24	27	28	14	620
2016	5	114800	2,93	3,31	4,28	107,74	0,58	193	182	121	85	67	58	53	125	57	25	19	26	634
2016	6	106187	2,92	3,28	4,16	109,24	0,47	214	110	114	102	96	63	55	107	56	36	28	21	556
2016	7	81343	2,96	3,27	3,92	111,59	1,16	153	111	64	71	25	39	49	53	36	25	15	27	383
2016	8	114751	2,96	3,32	3,90	113,61	-0,29	267	155	117	58	52	53	50	75	40	42	41	29	543
2016	9	108918	2,96	3,32	3,90	115,10	0,18	230	85	99	84	61	37	42	64	42	33	18	18	486
2016	10	130274	3,07	3,39	3,81	116,51	1,44	257	135	132	94	63	42	72	88	46	25	27	25	572
2016	11	132655	3,27	3,53	4,08	119,18	0,52	285	212	107	63	77	47	82	91	46	18	41	55	669
2016	12	142713	3,49	3,68	4,38	121,66	1,64	144	153	84	49	50	56	45	94	42	35	38	64	710
2017	1	95389	3,73	3,97	4,63	124,83	2,46	279	115	60	40	43	54	42	107	41	19	45	33	520
2017	2	101468	3,67	3,91	4,59	127,46	0,81	282	114	77	37	35	55	42	81	35	16	46	24	474
2017	3	128923	3,67	3,92	4,54	129,94	1,02	323	139	115	39	31	50	54	112	35	28	39	36	599
2017	4	114446	3,65	3,91	4,62	132,99	1,31	245	169	99	55	74	65	33	81	31	25	38	38	681
2017	5	116558	3,56	3,93	4,62	134,91	0,45	277	125	134	65	54	63	68	70	48	17	52	32	790
2017	6	97579	3,52	3,95	4,52	136,81	-0,27	239	136	115	87	64	46	62	73	42	35	31	17	994
2017	7	115869	3,56	4,09	4,64	138,12	0,15	293	142	118	76	41	61	74	71	36	32	46	32	726

2017	8	120198	3,51	4,14	4,57	139,57	0,52	317	135	95	78	66	45	49	81	37	18	61	52	665
2017	9	140298	3,47	4,14	4,65	141,29	0,65	383	160	129	103	77	72	84	75	41	63	49	41	972
2017	10	122882	3,66	4,31	4,86	143,47	2,08	344	154	125	94	106	278	85	120	60	20	34	75	1199
2017	11	122732	3,88	4,55	5,16	145,83	1,49	405	151	135	68	88	62	81	105	58	31	79	59	849
2017	12	132972	3,85	4,55	5,17	148,16	0,69	418	151	129	52	93	91	118	102	41	30	67	44	845
2018	1	97019	3,77	4,59	5,23	149,62	1,02	272	108	121	55	89	65	83	124	22	40	62	84	635
2018	2	95953	3,78	4,67	5,31	151,03	0,73	308	99	128	48	53	63	122	118	32	28	45	46	668
2018	3	110905	3,88	4,79	5,45	152,76	0,99	348	79	120	52	78	61	156	108	51	28	41	52	675
2018	4	103087	4,05	4,98	5,74	154,82	1,87	337	116	112	57	97	68	138	99	54	29	44	62	846
2018	5	119655	4,41	5,22	5,99	158,47	1,62	407	114	165	112	123	75	217	131	56	28	38	65	902
2018	6	119413	4,63	5,41	6,17	162,42	2,61	315	90	169	88	102	82	228	139	44	35	38	64	691
2018	7	123878	4,75	5,55	6,30	166,54	0,55	584	171	173	94	109	73	321	143	51	38	70	111	947
2018	8	105154	5,73	6,61	7,51	173,89	2,30	944	271	192	97	177	96	394	183	50	57	90	124	1219
2018	9	127327	6,37	7,42	8,30	181,79	6,30	1351	360	263	193	299	180	538	227	54	79	67	199	1952
2018	10	146536	5,86	6,74	7,63	188,41	2,67	1439	378	336	217	341	177	557	319	88	73	75	242	2085
2018	11	89626	5,37	6,11	6,94	192,78	-1,44	1003	218	261	128	203	144	463	261	60	60	69	143	1705
2018	12	136845	5,31	6,04	6,76	197,62	-0,40	897	195	257	96	195	166	435	232	62	47	86	170	1776
2019	1	72937	5,37	6,13	6,94	202,89	1,06	605	130	195	76	119	95	305	191	50	30	83	151	1170
2019	2	78450	5,26	5,98	6,87	208,08	0,16	628	150	236	70	122	105	307	166	52	45	82	125	1269
2019	3	105046	5,44	6,16	7,22	213,54	1,03	548	123	156	74	101	87	334	150	47	37	59	101	1343
2019	4	96071	5,74	6,45	7,52	218,93	1,69	533	202	202	94	122	87	332	189	50	73	88	149	1647
2019	5	91937	6,05	6,77	7,79	224,23	0,95	594	152	285	149	155	90	509	183	80	71	99	144	1456
2019	6	61355	5,81	6,56	7,38	229,98	0,03	429	113	190	113	126	67	415	108	38	60	34	98	926
2019	7	102236	5,67	6,37	7,09	235,63	1,36	734	219	215	124	158	92	464	163	60	58	107	139	1708
2019	8	110538	5,62	6,26	6,88	238,46	0,86	675	159	212	109	149	88	469	146	56	59	72	105	1342
2019	9	146903	5,71	6,29	7,07	241,37	0,99	781	191	248	139	145	118	489	182	55	68	73	151	1577
2019	10	142810	5,78	6,39	7,32	245,45	2,00	597	182	292	166	225	125	536	185	71	80	83	121	1648
2019	11	138372	5,73	6,34	7,41	250,57	0,38	575	109	300	133	154	91	500	216	57	91	111	158	1542
2019	12	202074	5,84	6,48	7,69	255,84	0,74	897	173	362	106	147	146	763	312	103	104	100	154	1984
2020	1	113615	5,92	6,58	7,76	261,89	1,35	739	121	254	72	133	99	678	204	56	65	82	107	1335
2020	2	118753	6,04	6,59	7,88	269,42	0,35	691	79	282	66	108	90	721	256	76	74	93	141	1371
2020	3	108670	6,31	6,99	7,86	277,65	0,57	426	65	227	65	87	95	465	184	78	72	49	86	1176
2020	4	42783	6,82	7,42	8,52	288,78	0,85	103	6	61	14	13	35	157	54	8	36	10	25	274
2020	5	50936	6,95	7,56	8,57	300,11	1,36	143	7	40	16	15	42	209	48	25	15	23	25	262
2020	6	190012	6,81	7,66	8,56	310,39	1,13	257	19	63	37	53	70	398	60	30	34	40	46	572
2020	7	229357	6,85	7,82	8,68	323,26	0,58	388	36	154	69	143	115	540	149	93	64	40	63	918

2020	8	170408	7,25	8,58	9,59	340,26	0,86	592	137	366	140	134	154	640	156	76	82	70	82	1303
2020	9	136744	7,51	8,86	9,80	356,14	0,97	826	241	448	197	161	183	908	166	73	222	97	134	1667
2020	10	119574	7,87	9,27	10,27	373,53	2,13	909	210	400	202	159	137	849	225	83	213	109	144	1691
2020	11	112483	8,00	9,46	10,57	390,58	2,30	876	202	434	147	145	104	860	203	105	124	92	103	1627
2020	12	105981	7,72	9,38	10,39	462,72	1,25	724	108	349	101	114	155	764	224	68	170	79	124	1499
2021	1	70587	7,39	9,01	10,11	449,12	1,68	385	58	260	47	65	68	459	168	69	69	69	51	944
2021	2	81222	7,07	8,56	9,84	413,65	0,91	432	41	259	44	96	77	477	230	60	119	65	81	1014
2021	3	111241	7,63	9,09	10,67	423,38	1,08	644	49	419	98	142	106	663	302	93	166	99	91	1413
2021	4	95863	8,16	9,73	11,32	464,33	1,68	546	78	402	82	144	131	557	229	92	188	99	94	1510
2021	5	59166	8,34	10,13	11,81	501,26	0,89	239	43	119	36	87	47	231	98	44	80	37	36	699
2021	6	134731	8,60	10,37	12,12	512,01	1,94	773	151	300	63	192	164	683	250	127	165	95	83	1780
2021	7	107785	8,61	10,19	11,95	500,55	1,80	712	189	365	63	198	127	619	229	106	166	97	102	1591
2021	8	141400	8,48	9,98	11,73	489,92	1,12	900	264	451	110	262	138	911	313	98	176	94	136	2079
2021	9	147143	8,51	10,03	11,77	470,59	1,25	990	281	540	100	298	162	1323	270	101	210	108	133	2190
2021	10	137401	9,14	10,60	12,57	521,44	2,39	926	189	543	139	256	120	1265	188	122	191	129	105	1790
2021	11	178814	10,52	12,01	14,42	634,13	3,51	1075	185	836	157	322	185	1406	231	163	278	111	162	2330
2021	12	226503	13,53	15,29	18,09	817,61	13,58	1039	263	885	150	296	192	1462	254	171	282	163	183	2590
2022	1	88306	13,52	15,31	18,40	795,39	11,10	513	82	479	82	204	89	761	131	102	132	88	105	1466
2022	2	97587	13,62	15,44	18,53	824,04	4,81	633	144	509	100	169	93	711	141	111	197	64	117	1650
2022	3	134170	14,57	16,05	19,30	926,51	5,46	741	156	547	140	244	115	784	214	168	241	126	117	2025
2022	4	133058	14,68	15,93	19,09	921,01	7,25	714	104	1152	116	221	156	905	247	263	311	117	111	2107
2022	5	122768	15,62	16,53	19,62	944,07	2,98	617	130	1275	91	247	118	736	210	241	218	94	95	1961
2022	6	150509	16,96	17,96	21,00	1018,48	4,95	807	190	1887	144	329	131	987	258	301	318	188	133	3034
2022	7	93902	17,39	17,77	21,06	998,91	2,37	380	125	1028	90	163	65	431	83	166	190	53	47	1153
2022	8	123491	17,99	18,25	21,69	1040,39	1,46	417	195	1238	92	256	106	633	108	219	231	88	66	1691
2022	9	113402	18,28	18,13	20,81	1010,29	3,08	433	192	1196	120	225	115	592	95	204	207	79	81	1565
2022	10	102660	18,56	18,25	21,01	1010,47	3,54	310	118	2023	98	211	99	498	62	216	200	68	68	1464
2022	11	117806	18,59	18,92	21,90	1047,70	2,88	331	116	2575	92	224	104	510	80	277	191	79	78	1476
2022	12	207963	18,64	19,70	22,77	1091,54	1,18	345	119	2403	71	212	139	675	103	306	266	71	53	1706
2023	1	97708	18,79	20,25	23,00	1165,67	6,65	229	113	1557	57	126	65	526	76	157	155	45	44	1048
2023	2	80031	18,86	20,21	22,85	1108,61	3,15	173	73	1183	43	124	73	446	69	142	133	36	34	857
2023	3	105476	19,01	20,36	23,12	1214,35	2,29	165	81	1175	65	112	69	472	51	160	121	41	33	896
2023	4	85652	19,34	21,21	24,13	1242,82	2,39	124	24	817	46	73	54	377	50	136	89	41	29	711
2023	5	113276	19,77	21,49	24,73	1312,42	0,04	118	82	991	56	129	75	503	49	175	107	33	22	843
2023	6	83636	23,23	25,14	29,37	1575,04	3,92	175	46	733	55	127	59	333	42	168	142	24	37	710