

PAPER DETAILS

TITLE: Türkiye'de Konut Fiyat Endeksinin Makine Öğrenme Yöntemi ile Tahmini

AUTHORS: Serkan Nas, Ayse Ergin Ünal

PAGES: 283-298

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/3344449>



Ekonomik ve Sosyal Araştırmalar Dergisi

The International Journal of Economic and Social Research

2024, 20(2)

Türkiye’de Konut Fiyat Endeksinin Makine Öğrenme Yöntemi ile Kestirimi

Estimation of Housing Price Index in Türkiye with Machine Learning Method

Serkan NAS¹ , Ayşe ERGİN ÜNAL² 

Geliş Tarihi (Received): 19.08.2023

Kabul Tarihi (Accepted): 30.07.2024

Yayın Tarihi (Published): 30.12.2024

Özet: Tüketim ve yatırım amaçlı oluşan konut talebi pek çok farklı değişkene bağlı olup konut fiyatı bunlardan en önemlisidir. Bu bağlamda konut arz ve talebinde sağlanacak dengenin önemli belirleyicisi olan fiyatın kestirilmesi önem arz etmektedir. Literatürde konut fiyat kestirimine yönelik az sayıda çalışma olup yine bunlardan çok azında makine öğrenme tekniği kullanıldığı görülmektedir. Makine öğrenmesi çalışmalarında başarı tahmini seçilen algoritmaya ve öznelik kombinasyonuna bağlı olmaktadır. Bu bağlamda çalışmanın amacı konut fiyatının kestirimini en doğru sağlayan yöntem ve konut fiyatını en çok etkileyen makroekonomik belirleyicilerin tespit edilmesidir. Çalışmada Türkiye için konut fiyatının belirleyicilerini test etmek üzere 01:2013 ile 05:2023 dönemlerine ait TÜFE, BİST100, Sanayi Üretim Endeksi, Dolar Kuru, Tüketici Güven Endeksi değerleri öznelik olarak kullanılmaktadır. Yine çalışmada üç farklı makine öğrenme algoritması yanında en yaygın kullanılan doğrusal modellerden biri olan Otoregresif Entegre Hareketli Ortalama (ARIMA) modeli kullanılmıştır. Türkiye Konut Fiyat Endeksi serisi için bu modellerin öngörü performansları karşılaştırılmış olup MOYH kriterine göre en iyi tahmin oranları sırasıyla Karar Ağacı %80,69, K-en yakın komşu %79,21 ve Çok katmanlı algılayıcılar ise %78,44 şeklindedir. Karar ağacı algoritmasında, USD/TRY özneliğinin etkisi %72,3 ile en çok etkileyen öznelik olmuş, sırasıyla en çok etkileyen diğer öznelikler ise %14,6 ile Sanayi Üretim Endeksi (SUE) %5,61 ile tahvil faizleri (THVLF) özneliği olmuştur. Buna karşın geleneksel yöntemlerden ARIMA, MOYH kriterine göre kestirim başarısı açısından %46,11 oranla başarılı olmuştur.

Anahtar Kelimeler: Konut Fiyat Endeksi, Makine Öğrenme, Tahminleme, Makroekonomik Göstergeler, Karar Ağaçları, Çok Katmanlı Algılayıcılar, ARIMA.

&

Abstract: The demand for housing for consumption and investment purposes depends on many different variables, and the housing price is the most important of them. In this context, it is important to estimate the price, which is an important determinant of the balance to be achieved in the supply and demand of housing. There are few studies on housing price forecasting in the literature, and again, it is observed that machine learning technique is used in very few of them. The prediction of success in machine learning studies depends on the selected algorithm and attribute combination. In this context, the aim of the study is to determine the most accurate method for estimating the housing price and the macroeconomic determinants that affect the housing price the most. In the study, CPI, BIST100, Industrial Production Index, Dollar Exchange Rate, Consumer Confidence Index values for the periods between 01:2013 and 05:2023 constitute the attribute set to test the determinants of housing price for Türkiye. Again, the Autoregressive Integrated Moving Average (ARIMA) model, one of the most widely used linear models, was used in the study along with three different machine learning algorithms recently. The predictive performances of these models have been compared for the Turkish Housing Price Index series, and the best prediction rates according to the MAPE criterion are Decision Tree 80.69%, K-nearest neighbor 79.21% and Multilayer perceptron 78.44%, respectively. In the decision tree algorithm, the impact of the USD/TRY attribute was the most influential feature with 72.3%, while the most influential features, respectively, were the Industrial Production Index (SUE) with 14.6% and the Bond Interest Rate (THVLF) attribute with 5.61%. On the contrary, ARIMA, one of the traditional methods, was successful with a rate of 46.11% in terms of prediction success according to the MAPE criteria.

Keywords: Housing Price Index, Machine Learning, Predicting, Macroeconomic Indicators, Decision Tree, Multilayer Perceptron, ARIMA.

Atıf/Cite as: Nas, S. ve Ergin Ünal, A. (2024). Türkiye’de Konut Fiyat Endeksinin Makine Öğrenme Yöntemi ile Kestirimi. *Ekonomik ve Sosyal Araştırmalar Dergisi*, 20(2), 283-298.

İntihal-Plagiarizm/Etik-Ethic: Bu makale, en az iki hakem tarafından incelenmiş ve intihal içermediği, araştırma ve yayın etiğine uyulduğu teyit edilmiştir. / This article has been reviewed by at least two referees and it has been confirmed that it is plagiarism-free and complies with research and publication ethics. <https://dergipark.org.tr/pub/ijaws>

Copyright © Published by Bolu Abant İzzet Baysal University, Since 2005 – Bolu

¹Dr.Öğr.Üyesi, Tarsus Üniversitesi, Yönetim Bilişim Sistemleri Bölümü, Tarsus/MERSİN, serkannas@tarsus.edu.tr, ORCID: <https://orcid.org/0000-0002-0040-3091>

²Doç.Dr., Tarsus Üniversitesi, Finans ve Bankacılık Bölümü, Tarsus/MERSİN, ayseerginunal@tarsus.edu.tr, ORCID: <https://orcid.org/0000-0001-6551-8933>

1. GİRİŞ

İnşaat sektörünün önemli bileşenlerinden biri olan konut sektörüne olan artan talebin, çeşitli sebepleri bulunmakla beraber tüketim ve yatırım kararları bunlardan ikisidir. Barınma ihtiyacını karşılayan tüketim amacı yanında yer alan yatırım amaçlı konut talebi, konutların göreceli fiyatları ile doğrudan ilişkili (Mankiw, 2010: 562-563) olup alternatif finansal varlık olarak da görülmektedir. Söz konusu bu özellik diğer bir deyişle konutların, konut ihtiyacının yanında dayanıklı bir tüketim malı ve yatırım aracı olması, konut piyasasını diğer pazarlardan ayıran önemli bir özellik olarak görülmektedir (Lacoviello, 2000). Makroekonomik açıdan değerlendirildiğinde konut piyasasında meydana gelen canlanmanın inşaat sektöründen hareketle gerek istihdam yaratma gerekse alt sektörlerle olan pozitif etkisi sonucunda ekonomik büyümeye katkı sağlayacağı düşünülmekle beraber konut piyasasındaki talep ve arz değişikliklerinin doğru tahmin edilmesi önemlidir. Konut fiyatlarındaki hareketleri tahmin edebilmenin kritik önemini gösteren diğer bir sebep de ABD konut piyasasında meydana gelen Mortgage Krizi tecrübesidir. Küresel ekonomik daralma ile sonuçlanan söz konusu kriz ile reel kesimin önemli aktörlerinden inşaat sektöründe, durgunluk ve gerileme yaşanmış olup konut üretimi yanında konut satışında da azalmalar meydana gelmiştir. Bu bağlamda konut piyasasında meydana gelen fiyat dalgalanmalarının tahmini, konut arz ve talep eden açısından önem arz etmekle beraber uygun bir kestirim modeli geliştirmenin oldukça zor olduğu düşünülmektedir. Keza Bork ve Moller (2015)' e göre bir kestirim modeli bazı bölgeler için geçerli iken bazı bölgelerde geçersiz olabilmektedir. Bunun yanında konut fiyat belirleyicilerinin dinamik yapısı model oluşturmayı zorlaştıran sebeplerdendir. Bu bağlamda oluşturulacak modelde girdi değişkeni olarak kullanılacak parametrelerin kombinasyonunun doğru seçilmesinin, yapılan kestirim başarısını artıracığı düşünülmektedir. Konut fiyatlarını etkileyen değişkenler üzerine görüş birliği bulunmamakla beraber ülke makroekonomik performansı ve konutlara ait fiziksel özellikler temel iki ayırım olarak görülmektedir. Örneğin Shi vd. (2001) nüfus artışı, işsizlik, göç, inşaat faaliyetleri ve banka kredileri gibi faktörleri, konut fiyatlarının önemli belirleyicileri olduğunu düşünürlerken Burhan (2023) konuta ait net m², bina yaşı gibi fiziksel özellikleri dikkate almaktadır. Yine Demary (2009) konut fiyatları ile fiyatlar, çıktı ve faiz oranları gibi makro göstergeler arasındaki bağlantıyı ampirik olarak analiz ettiği çalışmasında, olası faiz şoklarının konut fiyatlarındaki değişimin %12 ila 24'ünü tespit ettiğini ve reel konut fiyatlarını düşürdüğünü tespit etmişlerdir. Konut fiyatı belirleyicilerine yönelik söz konusu farklı çalışma ve değişkenler literatür bölümünde detaylandırılmaktadır.

Konut fiyat kestirimi üzerine yapılan bu çalışmanın, oluşturulacak model sayesinde gerek kredi verecek kurum ve kuruluşlara gerekse konut talep eden tüketici ve yatırımcılara öngörülebilir konut fiyatları imkânı sağlayacağı düşünülmektedir. Diğer yandan konut fiyat endekslerine ek olarak, bir konut fiyat kestirim modelinin geliştirilmesinin, gelecekteki konut fiyatlarının tahmin edilmesine, gayrimenkul politikalarının oluşturulmasına ve konut yatırımcılarının risk getiri hesaplamasını kolaylaştırmasına büyük ölçüde yardımcı olabileceği düşünülmektedir.

Bu çalışmada bir konut fiyatı kestirim modeli geliştirmek için TÜFE, BİST100, Sanayi Üretim Endeksi, Dolar Kuru, Tüketici Güven Endeksi öznitelikleri ile beraber araştırma yöntemi olarak makine öğrenimi algoritmaları ve en yaygın kullanılan doğrusal modellerden biri olan Otoregresif Entegre Hareketli Ortalama (ARIMA) modeli kullanılmaktadır. Çalışmanın bundan sonraki kısmında, yapılan diğer çalışmalar incelenmekte olup analiz kısmına geçilmektedir. Makine öğrenme algoritmaları ve ARIMA modelinin yer aldığı söz konusu bölümde ilk aşama Türkiye'de konut fiyat endeksini kestiriminde diğer bir deyişle konut fiyat hareketlerini belirleyen faktörlerin belirlenmesidir. İkinci aşama farklı makine öğrenme algoritmaları ve ARIMA modelinin uygulanmasına ayrılmışken son aşamada kullanılan yöntem ve seçilen özniteliklerin sonucuna göre gelecek aylara yönelik konut fiyat endeksi kestirimleri yer almaktadır.

Makroekonomik belirsizliklere bağlı olarak göstergelerin hızla değiştiği enflasyonist durumlarda, konut fiyat hareketlerinin kestirilmesi yatırımcılar, ekonomik karara alıcılar ve hane halkı açısından oldukça

önemlidir. Keza çalışmada oluşturulan model üzerinde yapılan analizler sonucunda Türkiye konut piyasasında konut satış fiyatlarının başarılı bir şekilde tahmin edildiği görülmüştür. Bu kestirimler doğrultusunda çalışmanın, bankalara konut sektörünün destekleneceği çeşitli kredi paketleri ve uygun kredi hedeflerinin oluşturulmasında yardımcı olacağı düşünülmektedir.

2. Literatür

Konut fiyat endeksinin kestiriminde makine öğrenme algoritmalarının kullanıldığı çalışmalar ülke genelinde eskiye dayanmamakla beraber pek çok çalışmada örneklem büyüklüğü seçilen bir il ile sınırlı olmaktadır. Yine yapılan çalışmalardan bir kısmında ise konut fiyatlarını tahmin etmek üzere makroekonomik ve finansal değişkenlerin kullanıldığı görülmektedir. Tablo 1’de Türkiye’de konut fiyat kestirimine yönelik yapılan çalışmalar ve detayları yer almaktadır.

Tablo 1. Türkiye’de Konut Fiyat Kestirimine Yönelik Yapılan Çalışmalar

Yazar/Yazarlar	Kullanılan Yöntem	Öznitelikler	Bulgular
Özkan vd. (2007)	Yapay sinir ağları ve regresyon yöntemleri	<ul style="list-style-type: none"> Konya Selçuklu için; konut büyüklüğü, bina yaşı, dairenin bulunduğu kat, cephe, Taban Alanı katsayısı, Kat Alanı Katsayısı ve bölge gibi fiziksel özellikler. 	Regresyon Metodu ile %83, yapay sinir ağları ile %84,5 doğruluk oranı bulunmuştur.
Ecer (2014)	Hedonik regresyon yöntemi ile yapay sinir ağları	<ul style="list-style-type: none"> İzmir Karşıyaka ’da bulunan 610 konutun sahip olduğu 83 özellik. 	Yapay sinir ağları modelinin hedonik modelden daha iyi tahmin yaptığı sonucuna ulaşılmıştır.
Yılmaz vd. (2018)	Yapay Sinir Ağları	<ul style="list-style-type: none"> Oda Sayısı Banyo sayısı Apartman dairesinin metrekare büyüklüğü..... gibi 13 farklı fiziksel nitelik 	Konut fiyatının tahmin edilmesinde Yapay sinir ağlarının etkili bir araç olduğu tespit edilmiştir.
Akay vd. (2019)	Otoregresif Hareketli Ortalama (ARIMA) modeli Rastgele Orman ve Hibrit Rastgele Orman	<ul style="list-style-type: none"> Konut fiyatları endeksi (KFE) 	Konut fiyat endeksinin öngörmede Hibrit modelin diğer yöntemlerden daha başarılı olduğu tespit edilmiştir.
Kayakuş vd. (2022)	RO, YSA ve DVM	<ul style="list-style-type: none"> Konut Fiyat Endeksi Konut Kredisi Yıllık Ortalama Faiz Oranı Dolar/TL Euro/TL 	Üç makine öğrenimi yönteminin de başarılı olduğu tespit edilmiştir.

		<ul style="list-style-type: none"> • BIST 100 Endeksi • Tüketici fiyat endeksi (TÜFE) (2003=100) • (TÜİK) (Aylık) • 2 Yıllık Devlet Tahvili Gösterge Faizi (%) • Altın (1 Troy Ons) • Bireysel Konut Kredileri (Bin TL) 	
Doğan vd. (2022)	Yapay Sinir Ağları	Ankara Keçiören için; <ul style="list-style-type: none"> • Bina Yaşı, • Bulunduğu Kat, • Cephesi, • Oda Sayısı gibi fiziksel özellikler. 	Yapay sinir ağlarının yönteminin başarılı sonuçlar verdiği görülmüştür.
Çetin (2022)	Yapay Sinir Ağları	<ul style="list-style-type: none"> • Tüketici Fiyat Endeksi, • Konut Kredisi Faiz Oranları, • Dolar Kuru, • Türkiye Konut Fiyat Endeksi • BIST 100 Endeksi 	5,6 Ortalama Mutlak Yüzde Hata ve %99,97 R ² oranı bulgulanmıştır.
Oral vd. (2021)	Bagged Trees Ensemble, Fine Tree, Exponential GPR, Wide Neural Network, Quadratic SVM olarak tespit edilmiştir.	(Madrid için) <ul style="list-style-type: none"> • Konutlara ait 22 farklı özellik 	En iyi performans değerine sahip yöntem Bagged Trees Ensemble olarak belirlenmiştir.
Emeç ve Tekin (2022)	Yapay Sinir Ağı, Doğrusal Regresyon, Destek Vektör Makinesi, Gauss Proses Regresyonu, Regresyon Ağacı	(Konya İçin) <ul style="list-style-type: none"> • Konut kredisi faiz oranları • Tüketici fiyat endeksi • Tüketici güven endeksi • İnşaat güven endeksi • Dolar kuru • Sanayi üretim endeksi 	Konut talebini tahmin etmede en iyi tahmin sonucunu YSA yöntemi ile sağlamaktadır.
Barut ve Bilgin (2023)	Yapay sinir ağları ve Polinomsal regresyon	<ul style="list-style-type: none"> • Konutlara ait 21 farklı özellik 	Yapay sinir ağları Polinomsal regresyon yöntemine göre daha doğru tahminler vermektedir.

Burhan (2023)	k-En Yakın Komşu, Karar Ağaçları ve Rastgele Orman	(Kütahya ili için) <ul style="list-style-type: none"> • Net m², • Bina yaşı, • Bulunduğu kat, Site içinde olup olmama durumu	En başarılı tahmin yönteminin RO ve bunu takiben k-NN olduğu görülmüştür.
----------------------	--	--	---

Konut fiyatları tahminlemesinin makine öğrenme algoritmaları kullanılarak yapıldığı yurtdışı çalışmalarından Abraham (2016), Yeni Zelanda için konut arz ve talebini etkileyen çeşitli makroekonomik değişkenler kullanarak konut fiyat değişimini ölçmüştür. Çalışma bulguları yapay sinir ağlarının başarılı sonuçlar verdiğini göstermektedir. Benzer şekilde Abidoye ve Chan (2017) Nijerya için analiz yapmışlardır. Çalışmalarında konutlara ilişkin 370 veri ve 11 bağımsız değişkenden oluşan nitelikler göz önüne alınarak yapay zeka kullanılmış ve başarılı sonuçlar elde edilmiştir. Yine Park ve Bae (2015) çalışmalarında Virginia, Fairfax County'deki konut fiyatlarını tahmin etmek için RİPPER, Naive Bayesian ve AdaBoost gibi makine öğrenimi algoritmalarına dayalı bir konut fiyatı tahmin modeli geliştirmişlerdir. Girdi değişkenleri olarak konutların ısınma şekli, garaj durumları gibi fiziksel özellikler yanında yakında bulunan devlet okulları ve ipotekli konut oranları kullanılmıştır. Analiz sonuçları RİPPER algoritmasının, konut fiyat tahmininin performansında diğer modellerden daha iyi sonuçlar vermektedir.

Thamarai ve Malarvizhi (2020) West Godavari için konut tahminlemesi yaptıkları çalışmalarında, karar ağacı, çoklu doğrusal regresyon gibi farklı makine öğrenme algoritmaları kullandıkları çalışmalarında öznitelik olarak konutlara dair fiziksel özellikleri dikkate almışlardır. Analiz sonuçları konut fiyat tahminlemesinde Çoklu doğrusal regresyonların performansının, karar ağacı regresyonundan daha iyi olduğunu göstermektedir. Abigail Bola Adetunji vd. (2022) Boston’a yönelik konut fiyat tahminlemesini makine öğrenme algoritmalarından Rastgele Orman makine öğrenimi tekniğini kullanarak araştırdıkları çalışmalarında modelin, ± 5 'lik bir hata payı ile kabul edilebilir bir tahmin değerine sahip olduğunu ortaya çıkarmışlardır


3. Yöntem ve Bulgular

3.1. Makine Öğrenme Algoritmaları ile Analiz

Günümüzde verilerden yola çıkarak bir yöntem belirlemek, kural oluşturmak, teşhiste, tespitte bulunmak veya kestirim yapmak çok yaygın bir uygulamadır. Kestirim amaçlı çalışmalarda, geçmiş ve farklı bağımsız veriler analiz edilerek yapay zeka, veri madenciliği ve makine öğrenimi kullanılmaktadır. Makine öğrenimi yöntemleri ve yeterli uygun veri ile, her alanda gelecekle ilgili öngörü çalışması yapmak mümkündür. Yapay zekanın bir alt dalı olan makine öğrenimi ile bilgisayarların öğrenimi gerçekleşmektedir. Makine öğrenim yöntemleri denetimli, denetimsiz ve pekiştirmeli öğrenme şeklinde üç bölüme ayrılmaktadır. Denetimli öğrenme en etkili kestirim yöntemlerinden biri olmakla beraber etiketli veri kullanır. Bu veri tipinde bir dizi bağımsız değişken, öznitelik olarak adlandırılır. Bu özniteliklerden hedef değişkenin kestirimi yapılmaya çalışılır. Bu değişkene bağımlı değişken denir. Bu çalışmada denetimli makine algoritmaları kullanılmış olup kullanılan makine öğrenim algoritmaları sırasıyla; karar ağaçları, çok katmanlı algılayıcılar ve K-en yakın komşu algoritmalarıdır.

Karar ağaçları hem sınıflandırmada hem de regresyonda kullanılan, her iki konuda da başarılı sonuçlar veren doğrusal olmayan algoritmadır. Karar Ağaçları aynı zamanda hangi özniteliğin etkili olduğu hakkında bilgi vermektedir. Bir dizi basit sorgulamayı mantıksal olarak birleştiren sıralı modellerdir. Her sorgu, sayısal bir özniteliği bir eşik değerle veya nominal bir öznitelik ile karşılaştırır. Bu tür sembolik

sınıflandırıcılar kara kutu denilen modellere karşı avantaj sağlar. Burada karar ağaçlarının takip ettiği mantıksal kuralları anlamak ve izah etmek, yapay sinir ağlarındaki düğümlerdeki sayısal ağırlıkları anlamaktan çok daha kolaydır. Karar vericiler bu tip modelleri kullanırken kendilerini daha rahat hissetme eğilimindedirler (Kotsiantis, 2011: 261). Karar ağaçları eğitim kümesi örneklerinden ve her eğitim kümesindeki örnek, girdi vektörü ile doğru sınıflandırılmasıyla oluşur. Ağaç yapısının çalışması, aşırı uyum hatasından kaçınarak eğitim setine uymayı amaçlamaktadır. Elde edilen ağaç, daha önce kullanılmamış test kümesinde test edilir ve tahmin edilen her sınıf gerçek verilerle karşılaştırılır. Test kümesi için bulunan hata oranı, algoritmanın başarı oranıdır. Bir karar ağacı, her giriş vektörünü bir dizi teste göre sınıflandırır. Bir karar ağacının diyagramı, bir akış şemasıdır. Baş aşağı bir ağacın şekli Şekil 1’de verilmiştir. Üst düğümeden başlar ve sorgu sonucuna bağlı olarak sağa veya sola doğru dallanır. Bu işlem, bir terminal düğüme ulaşana kadar ağaçtan aşağı doğru ilerler. Bu giriş terminal sınıfının düğüme göre sınıflandırılır (Rovnyak,1994: 1417-1418).



Şekil 1. Basit Bir Karar Ağacı Görseli


Kaynak: Rovnyak, S., Kretsinger, S., Thorp, J. & Brown, D. (1994).

K-En Yakın Komşular (KNN) “tembel öğrenme” algoritması olarak da bilinen “örnek tabanlı bir öğrenme” veya genelleştirmeyen bir öğrenmedir. Genel bir iç model oluşturmaya odaklanmak yerine Öklid mesafe fonksiyonu gibi benzerlik ölçülerine göre yeni veri noktalarını sınıflandırır. Sınıflandırma, her bir noktanın en yakın komşularının basit çoğunluk oyuyla hesaplanır. Gürültülü eğitim verilerine karşı oldukça sağlamdır ve doğruluk veri kalitesine bağlıdır. KNN ile ilgili en büyük sorun, dikkate alınacak en uygun komşu sayısını seçmektir. KNN hem sınıflandırma hem de regresyon için kullanılabilir (Sarker, 2021: 160).


KNN algoritması genellikle sınıflandırmada kullanılan ve regresyon ile kestirimde başarılı sonuçlar veren algoritmadır. Sınıflandırmada kullanılan yöntem regresyonda da kullanılmaktadır. Sadece regresyon ve kestirim için K en yakın komşuların ortalaması ile özel değer belirlenir. Komşu değerleri, katkılarına göre ağırlıklandırılmasında fayda bulunmaktadır. Böylece, uzaktaki bir değerden, yakındaki bir değer daha fazla ortalamaya katkıda bulunabilir. KNN, gerçek değere yakın olan K adet komşunun çıktılarını baz alarak kestirimde bulunur. Bu nedenle KNN ile tahmin yapabilmek için sorgu noktası ile diğer değerler arasındaki mesafeyi ölçmek için bir ölçüt gerekmektedir. Bu ölçütlerin en yaygın olanı Öklid mesafesidir. K değeri belirlendikten sonra, KNN örneklerinden tahminler yapılır. Regresyon için tahmin değeri en yakın K değerinin ortalamasıdır.

$$d(p, q) = \sqrt{(p - q)^2} \quad (1)$$

Yapay sinir ağlarının en basit hali perceptron algoritmasıdır. 1957 yılında, Frank Rosenbalt tarafından Cornell Havacılık laboratuvarında icat edilmiştir. Esas olarak amacı görüntü tanımadır. Basit bir sinir ağı mimarisi olan Perceptron çalışma prensibi de oldukça basittir. Her girdiye bir ağırlık verir ve sonucu bulmak için bu değerler toplanır. Bu işlem aktivasyon fonksiyonu ile yapılır. Çalışmalarına, tek katlı ağı ile kalıpların sınıflandırılmasının yapılamayacağı, sadece doğrusal olarak ayrılacağı belirlenmiştir. Daha sonra bir veya iki gizli katmanlı ağı çok daha hızlı işlem gücüne sahip olduğu belirlenmiştir (Sigh, 2019: 35). Çok katmanlı algılayıcıların çok daha iyi sonuçlar vermesi ile çok katmanlı algılayıcılar en çok bilinen ve yaygın olarak kullanılan sinir ağı tipi olmuştur. Bu modelde çoğu durumda sinyaller tek yönde, girişten çıkışa doğru ilerler. Nöronlarda döngü olmaz, nöronun çıktısı kendisini etkilemez, ancak bir başka nörona girdi olabilir. Bu mimariye ileri beslemeli sinir ağı denir. Şekil 2’de ileri beslemeli çok katmanlı sinir ağı gösterilmektedir. Ağa doğrudan bağlı olmayan katmanlara gizli katmanlar denir. Ağdaki ilk katman olan girdi katmanı ile tartışmalı bir durum vardır, çünkü girdi katmanı hiçbir işlem yapmadan bir üst noktaya iletmektedir. Katmanlar sayılırken sadece bağımsız nöronları içeren katmanlar sayılır. Aynı zamanda geriye de bilgiyi ileten nöronlar bulunmaktadır. Bu ağlar çok karmaşık ve çok güçlü olmakla beraber dinamik ve koşullara göre değişebilen ağlardır. Katman sayısının çoğaltılması, karar bölgelerini karmaşıklaştırmaktadır. Konulan her katmandaki nöron çıktısı, bir sonraki katmandaki nöron tarafından algılanır. Bu sebepten dolayı, nöronlar tarafından üretilen yarı düzlemlerin kesişmesinden kaynaklanan dış bükey karar bölgelerini tahmin edebilir. Tek katmanlı algılayıcılar da aktivasyon fonksiyonu hesaplamalarda güç katmamaktadır. Çünkü aktivasyon fonksiyonu doğrusal ise doğrusal fonksiyonun fonksiyonu yine doğrusaldır. Çok katmanlı algılayıcıların gücü, doğrusal olmayan aktivasyon fonksiyonlarından kaynaklanmaktadır. Polimimal fonksiyonlar hariç, doğrusal olmayan her fonksiyon kullanılabilir. Genelde en çok kullanılan fonksiyon Şekil 3’te gösterilen sigmoid aktivasyon fonksiyonudur (Popescu, 2009: 579-580).



Şekil 2. İleri Beslemeli Çok Katmanlı Sinir Ağı



Şekil 3. Sigmoid Tek Kutuplu Aktivasyon Fonksiyonu

Kaynak: Popescu, M.C., Balas VE, Perescu-Popescu, L. & Mastorakis, N. (2009).

Makine öğrenmesinin en önemli amacı kestirim başarısıdır. Bunun içinde yeterli ve ilgili verilerin bulunması gerekmektedir. Bu veriler hatalı, eksik veya yanlış veriler olabilirler. Öncelikle verilerin hazırlanması sonraki aşamada ise verilerin farklı ölçeklerde olmasından dolayı makine öğrenimi algoritmalarının performansının düşmemesi için verilerin standartlaştırılması gerekmektedir. Bu çalışmada veriler 0 ile 1 arasında değerlere çevrilerek algoritmada kullanılmıştır. Veriler standart hale getirildikten sonra eğitim kümesi ve test kümesi olarak ikiye ayrılır. Eğitim verileri tahmin algoritması oluşturmak için kullanılır, test verileri ile de oluşturulan algoritmanın başarısı ölçülür. Bu çalışmada da yaygın olarak kullanılan yaklaşım ile verilerin %20’si test ve %80’i eğitim için bölünmüştür. Test kümesi ile yapılan algoritma çalışmalarında başarıyı ölçen hata kriterleri vardır ve amaç; bu hatayı en aza indirmektir. Bunlardan bazıları Ortalama Mutlak Hata, Ortalama Kare Hata, Kök Ortalama Kare Hata başarı kriterleridir. Bu çalışmada tüm makine öğrenme algoritmaları Mutlak Ortalama Hata Yüzde Oranı (MOYH), Ortalama Mutlak Hata ve Ortalama Kareler Hatası olarak bilinen başarı ölçüt koşullarına göre

çalıştırılmıştır. Tahminleme çalışmalarında genellikle Mutlak Ortalama Hata Yüzde Oranı (MOYH) başarı ölçüt kriteri olarak kullanılmaktadır. Bu değer hesaplanırken makine öğrenme algoritmalarının oluşturduğu çıktı değerle gerçek değer arasındaki fark hesaplanır. Bu farkın mutlak değeri alınıp gerçekte bölünerek bağıl değer bulunur. Yüz ile çarpılarak hatanın yüzde değerine ulaşılır. Gerçek değerlerin sıfır olmadığı durumlarda kullanılması gerekmektedir. Denklem 2’de formül ile gösterilmiştir.

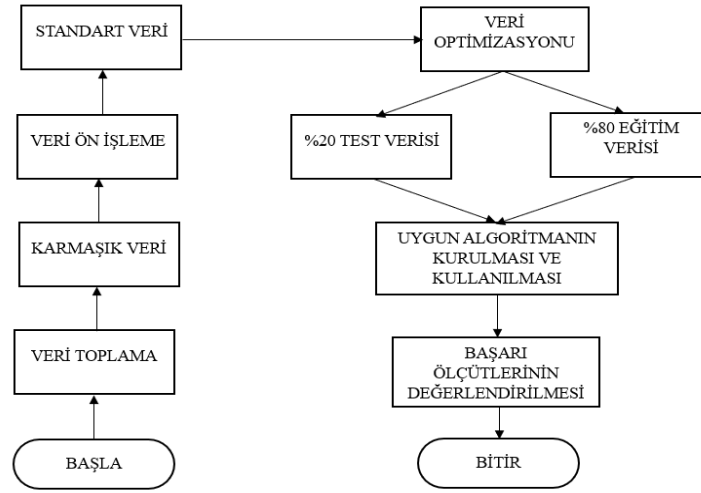
$$MOYH = \frac{100}{n} \sum_j \frac{e_j}{A_j} \quad (2)$$

Ortalama Mutlak Hata (MAE), gerçek değer ile tahmin değeri arasındaki fark hesaplanır. Bu farkın mutlak değeri alınır, gözlem sayısına bölünerek MAE değeri hesaplanır. Denklem 3’te formül ile gösterilmiştir.

$$MAPE = \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}_i| \quad (3)$$

Ortalama Kareler Hatası (MAE), gerçek değerler ile tahmin değerleri arasındaki fark hesaplanır. Bu farkın karesinin toplamı bulunur. Bu toplam değer gözlem sayısına bölünerek MSE değeri hesaplanır. Aykırı değerler var ise MSE yüksek çıkabilir. Denklem 4’te formül ile gösterilmiştir.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (4)$$



Şekil 4. Makine Öğrenme Algoritmalarının Gerçek Veriye Uygulanmasının Aşamaları

3.1.1. Makine Öğrenme Algoritmalarında Aşırı Öğrenme

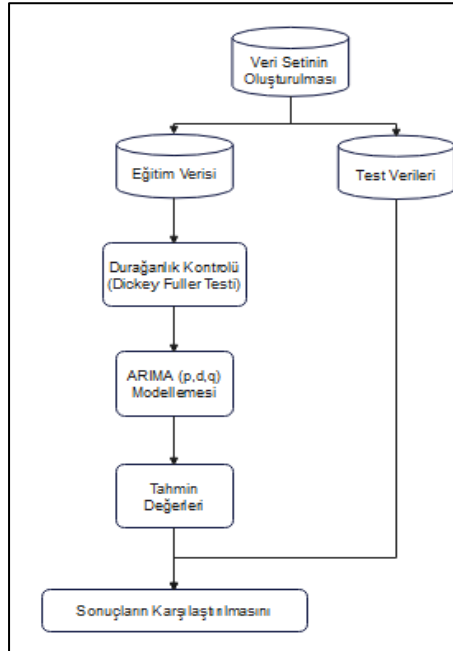
Makine öğrenmesinin başarısı, eğitim verileri kullanılarak öğrendiği bilgiler ile tüm veriler için genelleme yapabilme yeteneğine bağlıdır. Test verileri ile de bu öğrenen bilgileri kullanarak başarılı kestirim yapmaya çalışır. Eğitim veri kümesinde başarı göstermiş fakat deneme veri kümesinde performans az ise aşırı öğrenme olduğu söylenebilir (Usta, Tosun ve Tosun, 2021). Aşırı öğrenme problemini çözebilmek için iki yöntemden faydalanılmaktadır. Bunlardan ilki yüksek korelasyonlu olan özneliklerin tespit edilmesi ve yüksek korelasyonlu verilere bağlı olarak öznelik sayısının azaltılmasıdır. Bu çalışmada da korelasyon tablosu, Tablo 3’te verilmiştir ve iki değişken azaltılmıştır.

Aşırı öğrenmeyi engellemenin bir diğer yöntemi de k-katlı çapraz doğrulama yöntemidir. Çapraz doğrulamada, D veri kümesi iki kısma bölünür. Bir veri kümesinde T eğitim kümesi ve diğer kümede R test kümesi yer almaktadır. Bu iki kümenin kesişimi boş küme, birleşimi de tüm veri kümesi olarak adlandırılmaktadır. Veri kümesi rastgele karıştırılır ve veri kümesini k-adet kadar eşit olarak rastgele

bölünür. K-katlı çapraz doğrulama, K kadar yineleme içerir, her yinelemede bir parça veri test kümesi olarak, diğer parçalarda eğitim kümesi olarak kullanılır. Tüm tahmin hatası, yinelemelerin hata oranının ortalamasıdır. K değeri literatürde 2, 5, 10 değerlerini alırken, genelde k=10 değerini alır (Ghojogh & Crowley, 2019). Bu çalışmada da 10 değeri alınmıştır.

3.2. ARIMA Modeli

ARIMA modeli otoregresif hareketli ortalama (ARMA) modelinin genel modifikasyon ile türetilmiş halidir. Bu model ARIMA (p,d,q) olarak sınıflandırılır. Burada p veri kümesinin otoregresif kısımlarını, d entegre veri kümesinin parçalarını ve q ise veri kümesinin hareketli ortalama kısımlarını gösterir. p, d, q negatif tamsayılar değildirler. Akaike Bilgi Kriterleri (AIC) istatistiksel modeli ölçmek için yaygın olarak kullanılan bir ölçütüdür. Modelin uyumluluğunu nicel olarak ölçmek için kullanılır. İki veya daha fazla modeli karşılaştırırken, en düşük AIC'ye sahip olanın genellikle gerçek verilere daha yakın olduğu kabul edilir (Mondal, Shit & Goswami, 2014). ARIMA modeli Python programlama dili kullanılarak yapılmıştır. AIC kriterine göre model oluşturulmuş ideal p, d, q değerleri tespit edilmiştir. Performans ölçümü ortalama mutlak değer yüzdesine göre hesaplanmıştır. Python dilinden faydalanılarak, optimum p, d, q modeli belirlenmiştir. Şekil 5’te aşamaları gösterilmiştir.



Şekil 5. ARIMA Yaklaşımının Gerçek Veriye Uygulanma Aşamaları

Kaynak: Ghojogh, B., & Crowley (2019)

Evren ve Örnekleme

Kestirim çalışmalarının başarısı öznitelik seçiminden çok fazla etkilenmekte olup özniteliklerin seçimi ile öznitelik verilerinden oluşturulan kombinasyonun kümesi oldukça önemlidir. Çok fazla sayıda değişken veya az sayıda değişken kullanımından daha önemlisi kullanılan özniteliklerin kombinasyonudur. Çalışmada makine öğrenme metoduyla, Konut fiyat endeksinin (KFE) aylık değeri kestirilmeye çalışılmıştır. Konut talebinde ABD Dolarının yerli para biriminin alternatifi olarak kullanılması ve inşaat sektöründe maliyet unsuru oluşturduğu düşünüldüğünden analize dahil edilmiştir. Ekonomik büyümenin konuta olan talebi artıracığı, BİST 100 endeksinin ve Tüketici Güven Endeksinin yükselmesinin toplumsal

morali artırarak harcamaları olumlu etkileyeceği varsayımları ile söz konusu değişkenler model içinde yer almaktadır. Yine öznitelik kümesinde yer alan Tüketici Fiyat Endeksi (TÜFE) ve Tahvil Faizleri (TVHFL) modelde yer alan diğer değişkenlerdir. Bu özniteliklerin seçiminde literatürden faydalanılmış ve mümkün olduğunca korelasyonun az olduğu düşünülen özniteliklerin seçimine dikkat edilmiştir. Seçilen makroekonomik değişkenler arasında para arzının bulunması gerektiği düşünülebilir. Fakat Lee (1992) çalışmasında para arzındaki değişmelerin, faiz oranı ve enflasyon değişkenleri ile aralarında güçlü bir korelasyon olduğunu iddia etmekte olup çalışmada para arzına yer verilmemiştir. Bu bağlamda konut fiyatlarını etkilediği düşünülen konut fiziksel özellikleri yerine seçilmiş makroekonomik değişkenler öznitelik olarak tercih edilmiştir. Benzer şekilde Türkiye’de makroekonomik değişkenler ve konut fiyatları arasındaki ilişkiye yönelik Öner Badurlar (2008), Emeç ve Tekin (2022), Çetin (2022) çalışmalarında da söz konusu makroekonomik değişkenleri kullanmıştır.


Veriler Ocak-2013 ile Mayıs-2023 tarihleri arasında aylık bazda derlenmiştir. Kullanılan öznitelikler ve kaynakları Tablo 2’de yer almaktadır. Öğrenme algoritmaları ve grafiksel gösterimler için Python programlama dilinden faydalanılmıştır.

Tablo 2. Öznitelik Tanımları ve Kaynak

Öznitelik	Öznitelik Tanımları	Kaynak
TÜFE	Tüketici Fiyat Endeksi	TCMB
BİST 100	Borsa İstanbul Endeksi	Matriks
SUE	Sanayi Üretim Endeksi	TÜİK
USD/TRY	ABD Dolar Lira Kuru	Matriks
THVLF	5 Yıl Vadeli Devlet Tahvil Faiz Oranı	Investing.com
İGE	İnşaat Güven Endeksi	TÜİK
TGE	Tüketici Güven Endeksi	TÜİK
KFE	Konut Fiyat Endeksi	TÜİK

Tahmin edilmesi planlanan Konut Fiyat Değerinin değişimleri Grafik 1’de gösterilmektedir.

Grafik 1. Hedef Veriye Ait Grafik



4. Bulgular

Aşırı öğrenme probleminin üstesinden gelebilmek için Tablo 3’te veri kümesine ilişkin korelasyon tablosu oluşturulmuştur. Amerikan dolarının TUFİ ve BİST100 ile yüksek korelasyonlu olduğu tespit edilmiştir. Aşırı öğrenme probleminin giderilmesi için bu iki öznelik veri kümesinden çıkartılmıştır.

Tablo 3. Veri Kümesine İlişkin Korelasyon Tablosu

KORELASYON TABLOSU								
	TUFİ	SUE	USD/TL	TGE	BİST100	İSGE	THVLF	KFE
TUFİ	1,000	0,735	0,919	-0,717	0,839	-0,009	0,401	0,957
SUE	0,735	1,000	0,869	-0,769	0,706	0,037	0,647	0,694
USD/TL	0,919	0,869	1,000	-0,810	0,895	0,003	0,475	0,913
TGE	-0,717	-0,769	-0,810	1,000	-0,546	0,004	-0,664	-0,628
BİST100	0,839	0,706	0,895	-0,546	1,000	0,006	0,147	0,892
İSGE	-0,009	0,037	0,003	0,004	0,006	1,000	-0,125	0,024
THVLF	0,401	0,647	0,475	-0,664	0,147	-0,125	1,000	0,208
KFE	0,957	0,694	0,913	-0,628	0,892	0,024	0,208	1,000

Çalışmada, 3 farklı makine öğrenimi algoritması kullanılmış olup 3 başarı ölçütüne göre farklı tahmin hata oranları elde edilmiştir. Makine öğrenme algoritmalarına ek olarak da geleneksel tahmin yöntemlerinden ARIMA kullanılmıştır.




Tablo 4. Makine Öğrenme Algoritmaları ve ARIMA yönteminin 3 Farklı Başarı Ölçütüne Göre Sonuçları

	DT	MLP	KNN	ARİMA
MAE	5,14	5,84	8,79	73,89
MSE	110,79	138,45	499,18	9016,24
MAPE	19,31	21,56	20,79	53,89

MAE ve MSE başarı ölçütlerinde hata oranları gerçek değere göre yüzdesi alınmadığından çalışma verilerine uygun olmadığı düşünülmektedir. Çünkü konut fiyat endeksi değerleri minimumda 1,5 ve maksimumda 189 değerlerini aldığından ve bu aralık çok yüksek olduğu için, gerçek değere göre yüzde oranını almayan başarı ölçütü bu çalışma için uygun bir ölçüt olarak düşünülmemiştir. Bu bağlamda yüzde değeri alan MOYH kriterine göre en iyi algoritma seçilmiştir.

En iyi sonuçlar MOYH kriterine göre, tahminleme başarısı açısından Karar ağacı %80,69, K-en yakın komşu %79,21, çok katmanlı algılayıcılar %78,49 doğrulukta kestirim yapmış makine öğrenmesi algoritmalarıdır. Buna karşın geleneksel yöntemlerden ARIMA, MOYH kriterine göre tahminleme başarısı açısından %46,11 oranla başarılı olmuştur. Karar ağacı algoritmasında, ABD Doları Lira kuru özneliğinin etkisi %72,3 ile en çok etkileyen öznelik olmuş, sırasıyla en çok etkileyen diğer öznelikler ise %14,58 ile SUE, %5,61 THVLF ve % 4,25 ile ISGE ve %3 ile TGE’dir.

MOYH başarı ölçütüne göre en başarılı sonuca karar ağacı algoritması %79,21’ ile ulaşmıştır. Grafik 2’te Konut fiyat endeksi değerleri ile (mavi renk) tahmin değerleri (kırmızı renk) gösterilmektedir. Grafik 3’te bu değerler KNN algoritması için ve Grafik 4’de MLP algoritması için gösterilmiştir. Değerler test verilerin içinden rastgele 100 adet gerçek veri ve ona karşılık gelen tahmin değerleri kullanılarak çizilmiştir.

Grafik 2. Konut Fiyat Endeksi Gerçek Değerler ile Tahmin Değerlerinin Grafiği (Karar Ağacı, DT)**Grafik 3.** Konut Fiyat Endeksi Gerçek Değerler ile Tahmin Değerlerinin Grafiği (KNN)**Grafik 4.** Konut Fiyat Endeksi Gerçek Değerler ile Tahmin Değerlerinin Grafiği (MLP)

5. Sonuç ve Öneriler

Çalışmada hangi model ve yöntemin konut fiyatı kestirimi üzerinde daha iyi etkiye sahip olduğunu test etmek ve makroekonomik değişkenlerin eklenmesinin konut fiyatı tahmini için yararlı olup olmadığını karşılaştırmak için çeşitli analizler yapılmıştır. Bu bağlamda çalışmada konut fiyatlarının ülke makroekonomik değişkenlerinden etkilendiği düşünülerek ABD Doları Lira kuru, ekonomik büyüme, Tüketici Fiyat Endeksi ve Tüketici Güven Endeksi gibi göstergelerden oluşan öznitelik kümesi 3 farklı makine öğrenme algoritması ve karşılaştırmalı olarak ARIMA modeli kullanılarak, olası konut fiyatları öngörülme çalışılmıştır. Aynı zamanda oluşturulan öznitelik kümesinde aşırı öğrenme probleminin üstesinden gelebilmek için, öznitelikler arasında korelasyon tablosu oluşturulmuş TUFİ ve BİST100 öznitelik kümesinden çıkartılmıştır.

Konut fiyatlarının kestirimini sağlayacak en uygun model ve değişkenleri saptamak amacıyla yapılan analiz sonuçlarında, makine öğrenme algoritmalarının ARIMA modeline göre çok daha başarılı sonuçlar verdiği tespit edilmiş olup söz konusu bulgu Chen vd. (2017) ile paralellik göstermektedir. Bu bağlamda MOYH kriterine göre, kestirim başarısı açısından Karar ağacı %80,69, K-en yakın komşu %79,21, çok katmanlı algılayıcılar %78,49 doğrulukta kestirim yapmış makine öğrenmesi algoritmalarıdır. Buna karşın geleneksel yöntemlerden ARIMA, MOYH kriterine göre tahminleme başarısı açısından %46,11 oranla başarılı olmuştur. Diğer yandan Karar ağacı algoritmasında, konut fiyatlarında belirleyici olduğu düşünülen makroekonomik değişkenlerden ABD Doları Lira kuru özniteliğinin etkisi %72,3 ile en çok etkileyen öznitelik olmuş, sırasıyla en çok etkileyen diğer öznitelikler ise %14,58 ile SUE, %5,61 THVLF ve % 4,25 ile ISGE ve %3 ile TGE’dir.

Makine öğrenme algoritmaları sonucunda söz konusu veri kümesindeki makroekonomik değişkenlerden özellikle ABD Dolar Lira kurunun %72,9 oranı ile en etkili öznitelik olduğu tespit edilmiştir. Elde edilen sonuç konut fiyatları ile kur arasındaki ilişkisinin araştırıldığı Bahmani-Oskooee ve Wu (2018)’nin çalışmaları ile paralellik göstermektedir. Bu bağlamda 18 OECD ülkesi için yaptıkları çalışmalarında kurdaki değişimlerin konut fiyatlarını etkilerken benzer şekilde konut fiyatlarının da kurları etkilediği sonucuna ulaşmışlardır. Yine Benson vd. (1999) ABD Bellinghamda yer alan konut fiyatları ile kur arasındaki ilişkiye yönelik çalışmalarında, döviz kurundaki %10’luk artışın konut fiyatlarını %7,7 oranında yükselttiği sonucuna ulaşmışlardır. Türkiye için ise Öner Badurlar (2008) ve Gebeşoğlu (2019) çalışmalarında kur ile konut fiyatları arasındaki ilişkisinin varlığına işaret eden bulgular tespit etmişlerdir. Bu bağlamda yapılan çalışmalarla desteklenen çalışma bulguları özellikle konut fiyat kestiriminde kur değişkeninin dikkate alınması gerekliliğine vurgu yapmaktadır. Keza yüksek faiz oranlarına sahip olup düşük kur uygulanan ülkelerde hem yerli para değer kazanmakta hem de yüksek yurtiçi faiz sebebi ile konut talebinde de azalma görülebileceği düşünülmektedir. Diğer yandan değer kazanan yerli para sonucunda net ihracat geliri ve talep düzeyi azalabilmekte ve nihayetinde konut talebinde de azalma görülebilmektedir. Türkiye’de kur ve konut fiyatları arasındaki ilişkinin bir diğer sebebi de konut maliyetlerinin dövizle bağlı olması ve inşaat maliyetlerinin döviz kuru ile paralel hareket etmesi olarak düşünülmektedir.

Analiz bulguları konut fiyat kestiriminde en etkili ikinci özniteliğin %14,58 oranı ile ekonomik büyüme olduğunu göstermektedir. Ekonominin büyümesi, makroekonomik istikrarsızlığın olmadığı dönemlerde gerçekleşmekte ve uzun vadeli yatırımların yapılabilmesi ile konuta olan talep de artmaktadır. Gerek ekonomik faaliyetlerdeki yeri gerekse konuta ilişkin işlem oranlarının büyüme içindeki yüksek oranı analiz sonucunu destekler niteliktedir. Elde edilen bu sonuç Englaund ve Ioannides (1997) ve Davis ve Heathcote (2001) çalışmaları ile paralellik göstermektedir.

Bu çalışmada, konut fiyat endeksinin makroekonomik faktörlerden önemli ölçüde etkilendiği gözlemlenmiştir. Türkiye’de inşaat sektörünün lokomotif bir sektör olmasından ve ABD doları lirasının

hem sektör girdilerinde hem de ülke ekonomisindeki tüm makroekonomik göstergelerde etkili olmasından dolayı, kur etkisinin çok daha yüksek olduğu düşünülmektedir. Bundan sonraki çalışmalarda, farklı makroekonomik ve finansal göstergeler kullanılarak daha başarılı sonuçlara ulaşmanın mümkün olacağı düşünülmektedir. Diğer yandan çalışmanın bir sonraki aşamalarında hibrit modellerin kullanılması planlanmaktadır.

Kaynaklar

- Abidoye, R.B. & Chan, A.P.C. (2017), Modeling Property Values in Nigeria Using Artificial Neural Network. *Journal of Property Research*, 1-18.
- Abraham, M. (2016), Determinants of Residential Property Value in New Zealand: A Neural Network Approach, Department of Applied Business, New Zealand Government Institute of Technology (Whitireia). *Auckland*, 1-24.
- Adetunji, A.B., Akande, O.N., Ajala, F.A., Oyewo, O., Akande, Y.F., & Oluwadara, G. (2022), House Price Prediction Using Random Forest Machine Learning Technique, *Procedia Computer Science*, 199, 806-813.
- Akay, E.Ç., Topal, K.H., Kizilarlan, S. & Bulbul, H. (2019), Forecasting of Turkish Housing Price Index: ARIMA, Random Forest, Arıma-Random Forest. *Pressacademia*, 10(10), 7-11.
- Bahmani-Oskooee, M. & Wu, T. (2018), Housing Prices and Real Effective Exchange Rates in 18 OECD Countries: A Bootstrap Multivariate Panel Granger Causality. *Economic Analysis and Policy*, 60, 119-126.
- Barut, Z. & Bilgin, T.T. (2023), Konut Fiyatlarının Tahmini için Polinomsal Regresyon ve Yapay Sinir Ağları Yöntemlerinin Uygulamalı Karşılaştırılması. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 27(1), 152-159.
- Benson, E.D., Hansen, J.L., Schwartz, A.L. & Smersh, G.T. (1999), Canadian/U.S. Exchange Rates and Nonresident Investors: Their Influence on Residential Property Values. *Journal of Real Estate Research*, 18(3), 433-461
- Bork, L. & Møller, S.V. (2015), Forecasting House Prices in The 50 States Using Dynamic Model Averaging and Dynamic Model Selection. *International Journal of Forecasting*, 31(1), 63-78.
- Burhan, H.A. (2023), Konut Fiyatları Tahmininde Makine Öğrenmesi Sınıflandırma Algoritmalarının Kullanılması: Kütahya Kent Merkezi Örneği. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, (76), 221-237.
- Chen, X., Wei, L., & Xu, J. (2017). House price prediction using LSTM. arXiv preprint arXiv:1709.08432.
- Çetin, D.T. (2022), Antalya-Isparta-Burdur Bölgesi Konut Fiyat Endeksinin Makroekonomik Göstergeler ve Hisse Senedi Endeksi Kullanılarak Yapay Zeka ile Tahmini. *Abant Sosyal Bilimler Dergisi*, 22(3), 1363-1380.
- Davis, M.A. & Heathcote, J. (2005), Housing and the Business Cycle. *International Economic Review*, 46(3), 751-784.
- Demary, M. (2009), The Link Between Output, Inflation, Monetary Policy and Housing Price Dynamics. <https://Mpra.Ub.Uni-Muenchen.De/15978/>, (Erişim Tarihi: 22.05.2023).
- Doğan, O., Bande, N., Genç, Y., & Akyön, F.Ç. (2022), Keçiören/Ankara Özelinde Konut Rayiç Değerlerinin Yapay Sinir Ağları Metodu Kullanılarak Tahmini. *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, 2022(35).
- Ecer, F. (2014), Türkiye'deki Konut Fiyatlarının Tahmininde Hedonik Regresyon Yöntemi ile Yapay Sinir Ağlarının Karşılaştırılması. *International Conference on Eurasian Economies*, 1-10.

- EMEÇ. Ş. & TEKİN, D. (2022), Housing Demand Forecasting with Machine Learning Methods. *Erzincan University Journal of Science and Technology*, 15(Special Issue I), 36-52.
- Englaund, P. & Ioannides, Y.M. (1997), House Price Dynamics: An International Empirical Perspective. *Journal of Housing Economics*, 6, 119-136.
- Gebeşoğlu, P.F. (2019), Housing Price Index Dynamics in Turkey, Special Issue on Applied Economics and Finance. *Journal of Yaşar University*, 14 (Special Issue), 100-107.
- Ghojogh, B., & Crowley, M. (2019), The Theory Behind Overfitting, Cross Validation, Regularization, Bagging, and Boosting: Tutorial. *arXiv preprint arXiv:1905.12787*.
- Imandoust, S.B., & Bolandraftar, M. (2013), Application of K-Nearest Neighbor (Knn) Approach for Predicting Economic Events: Theoretical Background. *International Journal of Engineering Research and Applications*, 3(5), 605-610.
- Kayakuş, M., Terzioğlu, M., & Yetiz, F. (2022), Forecasting Housing Prices in Turkey by Machine Learning Methods. *Aestimum*, 80, 33-44.
- Kotsiantis, S.B. (2013), Decision Trees: A Recent Overview. *Artificial Intelligence Review*, 39, 261-283.
- Iacoviello, M. (2000), House Prices and the Macroeconomy in Europe: Results From A Structural VAR Analysis.
- Lee, B.S. (1992), Causal Relations Among Stock Returns, Interest Rates, Real Activity and Inflation. *Journal of Finance*, 47, 1591-1603.
- Mankiw, N.G. (2010), *Makroekonomi*, (Çeviri Editörü: Ömer Faruk Çolak), Ankara: Efil Yayınevi.
- Mondal, P., Shit, L., & Goswami, S. (2014), Study of Effectiveness of Time Series Modeling (ARIMA) in Forecasting Stock Prices. *International Journal of Computer Science, Engineering and Applications*, 4(2), 13.
- Oral, M., Okatan, E. & Kırbas, İ. (2021), Makine Öğrenme Yöntemleri Kullanarak Konut Fiyat Tahmini Üzerine Bir Çalışma: Madrid Örneği. In *3 Rd International Young Researchers Student Congress*, 263-272.
- Öner Badurlar, İ. (2008), Türkiye’de Konut Fiyatları ile Makroekonomik Değişkenler Arasındaki İlişkinin Araştırılması. *Anadolu Üniversitesi Sosyal Bilimler Dergisi* 8(1), 223-238
- Özkan, G., Yalpir, S. & Uygunol, O. (2007), An Investigation on the Price Estimation of Residable Real-Estates by Using ANN and Regression Methods. In *12th Applied Stochastic Models and Data Analysis International Conference (ASMDA)*.
- Park, B., & Bae, J.K. (2015), Using Machine Learning Algorithms for Housing Price Prediction: The Case of Fairfax County, Virginia Housing Data. *Expert Systems with Applications*, 42(6), 2928-2934.
- Popescu, M.C., Balas, V.E., Perescu-Popescu, L. & Mastorakis, N. (2009), Multilayer Perceptron and Neural Networks. *WSEAS Transactions on Circuits and Systems*, 8(7), 579-588.
- Rovnyak, S., Kretsinger, S., Thorp, J. & Brown, D. (1994), Decision Trees For Real-Time Transient Stability Prediction. *IEEE Transactions on Power Systems*, 9(3), 1417-1426.
- Sarker, I. H. (2021), Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science*, 2(3), 160.
- Shi, S., Mangioni, V., Ge, X. J., Herath, S., Rabhi, F., & Ouyse, R. (2021), House Price Forecasting From Investment Perspectives. *Land*, 10(10), 1009.

- Singh, J., & Banerjee, R. (2019), A Study on Single and Multi-Layer Perceptron Neural Network. *In 2019 3rd International Conference on Computing Methodologies and Communication (ICCMC)* 35-40.
- Thamarai, M. & Malarvizhi, S.P. (2020), House Price Prediction Modeling Using Machine Learning. *International Journal of Information Engineering & Electronic Business*, 12(2).
- Ustalı, N. K., Tosun, N., & Tosun, Ö. (2021), Makine Öğrenmesi Teknikleri ile Hisse Senedi Fiyat Tahmini. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 16(1), 1-16.