



# Türkiye Arazi Yönetimi Dergisi

<https://dergipark.org.tr/tr/pub/tayod>

e-ISSN: 2687-5187



## Kent Ölçeğinde Konutlara İlişkin Toplu Değer Değişiminin Makine Öğrenim Algoritmaları ile Analizi

Merve TÜRKAN<sup>1\*</sup>, Aslı BOZDAĞ<sup>2</sup>, Ahmet Emin KARKINLI<sup>3</sup>, Adile Gülsüm ULUCAN<sup>4</sup>

<sup>1,4</sup>Niğde Ömer Halisdemir Üniversitesi, Harita Mühendisliği Anabilim Dalı, 51240, Merkez/Niğde

<sup>2,3</sup>Niğde Ömer Halisdemir Üniversitesi, Harita Mühendisliği Bölümü, 51240, Merkez/Niğde

### Anahtar Kelimeler:

Taşınmaz Değerlemesi  
Lineer Regresyon  
Yapay Sinir Ağları  
Regresyon Ağaçları  
Destek Vektör Regresyon  
Gauss Süreç Regresyonu

### ÖZ

Taşınmaz değerlemesi kentsel alanda konumsal ve yapısal özelliklerin tarafsız ve objektif olarak değerlendirilmesini ifade etmektedir. Bu sürecin bilimsel tanımlanmasına ilişkin pek çok çalışma yapılmıştır. Literatürdeki çalışmalarda geleneksel, istatistiksel, çok kriterli karar analizleri ve yapay zekâ yöntemleri son yıllarda sıklıkla uygulanan yöntemlerdir. Günümüzde yapay zekâ yöntemleri taşınmaz değerlendirme sürecindeki çok sayıda taşınmaza ilişkin yapısal ve konumsal özellikleri analiz ederek ilişkilendirmekte ve taşınmazlara yönelik değer tahminleri gerçekleştirebilmektedir. Bu nedenle yapay zekâ yöntemleri taşınmaz değerlendirme sürecinin yönetilmesinde önemli bir araç konumundadır. Bu çalışmada, Türkiye'nin Niğde kentinde yapısal kriterlerine ilişkin verileri bulunan 1200 taşınmazın istatistiksel analiz tekniklerinden Lineer Regresyon ve Makine Öğrenimi yöntemlerinden Yapay Sinir Ağları, Regresyon Ağaçları, Destek Vektör Regresyon ve Gaussian Process Regresyon algoritmaları kullanılmıştır. Sonuçta yapay sinir ağları yöntemi ile eğitilen modele göre elde edilen sonuçların tahmin performansının en yüksek doğruluk ( $R^2$ : %84.92, RMSE: 0.0608) sağladığı tespit edilmiştir. Çalışma, literatürden farklı olarak kent bütününde toplu olarak taşınmazların değerlendirilmesiyle gerçekleştirilmiş ve değerlemede 1200 taşınmaza ilişkin kriterler karşılaştırılarak yüksek doğrulukla değer tahmini elde edilmiştir.

## Analysis of the Mass Value Change for Housing at the Urban Scale Using Machine Learning Algorithms

### Keywords:

Real Estate Valuation  
Linear Regression  
Artificial Neural Networks  
Regression Trees  
Support Vector Regression  
Gaussian Process Regression

### ABSTRACT

Real estate valuation refers to the neutral and objective evaluation of spatial and structural features in the urban area. There have been many studies on the scientific description of this process. In the studies in the literature, traditional, statistical, multi-criteria decision analysis and artificial intelligence methods are the methods frequently applied in recent years. Today, artificial intelligence methods analyze and correlate the structural and spatial features of many real estates in the real estate valuation process and can perform value estimates for real estates. Therefore, artificial intelligence methods are an important tool in the management of the real estate valuation process. In this study, linear regression from statistical analysis techniques and Artificial Neural Networks, Regression Trees Support Vector Regression and Gaussian Process Regression algorithms from machine learning methods were used for 1200 real estates with data on their structural criteria in Niğde, Turkey. As a result, based on the model trained by the artificial neural networks method were found to provide the highest accuracy ( $R^2$ : %84.92, RMSE: 0.0608) of prediction performance. In the study was conducted the mass appraisal in real estate at the city and a high-accuracy value estimation was obtained by comparing the criteria for 1200 real estate.

### \*Sorumlu Yazar

\*(turkanmerve@gmail.com)  
(aslibozdag@ohu.edu.tr)  
(akarkinli@ohu.edu.tr)  
(adilegulsum.ulucan@mail.ohu.edu.tr)

ORCID ID 0000-0002-0161-4405  
ORCID ID 0000-000-32178-6527  
ORCID ID 0000-0001-7216-6251  
ORCID ID 0000-0001-5639-7914

Araştırma Makalesi; DOI: 10.51765/tayod.1275671

Geliş Tarihi: 02/04/2023; Kabul Tarihi: 18/08/2023

Kaynak Göster (APA): Türkan, M., Bozdağ, A., Karkinli, A.E. & Ulucan, A.G. (2023). Kent Ölçeğinde Konutlara İlişkin Toplu Değer Değişiminin Makine Öğrenim Algoritmaları ile Analizi, *Türkiye Arazi Yönetimi Dergisi*, 5(2), 66-77.

## 1. GİRİŞ

Taşınmaz kavramı arazi, bina, arsa, ev, bağ, bahçe vb. unsurları barındıran geniş bir ifade biçimidir. Taşınmazlar başta barınma ihtiyacı olarak kullanılmasının yanında günümüzde ise önemli bir yatırım aracı olarak görülmektedir. Taşınmaz değerlendirilmesi, taşınmaz ve taşınmaz ile ilgili hakların değerlendirilmesi zamanında toplumun ve yaşayanların da beklentileri alınarak ve değerlendirilmesi yöntemlerinden biri kullanılarak bilimsel bir şekilde değerlendirilmesidir. (Bozdağ & Ertunç, 2020). Taşınmaz değerlendirilmesi, imar ve şehircilik kapsamında kamulaştırma, vergi düzenlemeleri ve arazi ve arsa düzenlemeleri vb. kamusal hizmetlerde kullanılmaktadır. Ayrıca taşınmaz ve sermaye piyasası, sigortacılık ve bankacılık vb. özel sektöre yönelik çok çeşitli ve geniş alanda gerekli olan önemli bir uzmanlık alanını oluşturmaktadır. Taşınmazlar kentleşme alanında farklı terimlerle ifade edildikleri gibi değerlendirilmesi süreçleri ve yöntemleri de değişmektedir.

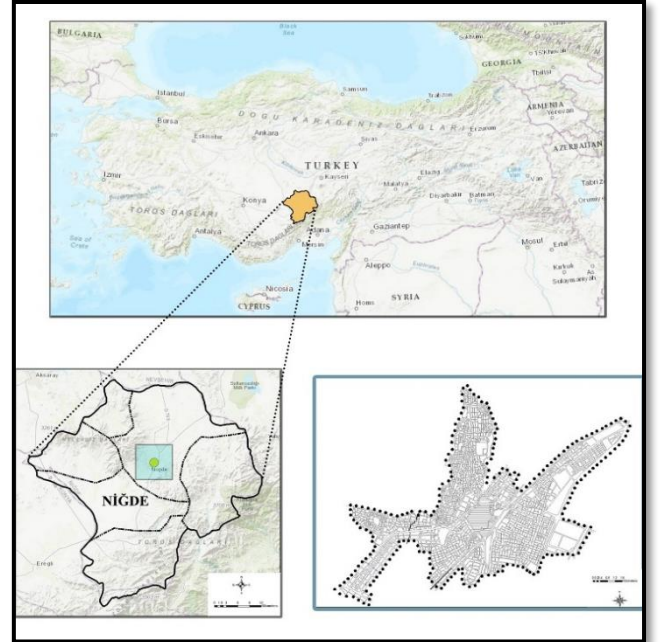
Değerlendirme sürecinde öncelikle ortaya çıkan problem taşınmazla ilişkili hakların ortaya konulabilmesidir. Çeşitli yönleriyle değerlendirilen bu haklar taşınmazın gerçek değerinin belirlenmesini sağlar. Bu hakların fiziksel, hukuksal ve konumsal olarak ortaya konularak detaylı incelenmesi gerekmektedir. Bu haklar literatürde taşınmazın değerini ilgilendiren kriterler, parametreler, özellikler ya da etmenler olarak ifade edilmiş ve tanımlanmıştır. Literatür incelendiğinde; yapısal özellikler, konumsal özellikler, kullanım özellikleri, altyapı ve ulaşım vb. çevresel faktörler, demografik yapı vb. sosyal faktörler, kişisel faktörler vb. temel parametreler olarak kullanılmaktadır (Çakır & Sesli, 2013; Demirel vd., 2018).

Taşınmaz değerlendirme sürecini ifade eden bu parametrelerin doğru, standart ve tarafsız şekilde değerlendirilmesinde çeşitli yöntemler kullanılmıştır. Bu yöntemler klasik, istatistik, Coğrafi Bilgi Sistemleri (CBS), çok kriterli karar analizi ve makine öğrenimi yöntemleri olarak literatürde yer almaktadır. İstatistik ve puanlama yöntemleri taşınmazlara ilişkin sayısal verilerin değerlendirilmesi aşamasında parametreler arasında ağırlıklandırma sağlayarak taşınmazlar arası değer farklılıklarını ortaya koymaktadır. (Özkan, 2009; Yağmahan, 2019; Uşak, 2019). Çok kriterli karar analizi yöntemlerinde anket vb. ölçme yöntemleri ile hem parametreler hem de toplumun görüşlerini ağırlıklandırarak değerlendirme gerçekleştirilmektedir (Tunca & Üstüntaş, 2019). CBS yöntemleri özellikle konumsal analizlerde ve veri tabanı oluşturulması süreçlerinde taşınmazlar arası değer farklılıklarını ortaya koymaktadır. (Torun, 2009; Toktaş, 2012; Mete, 2019). Günümüzde ise pek çok akademik araştırmada makine öğrenimi teknikleri ile değer farklılıkları incelenmektedir (Abidoye & Chan, 2017; Baldominos vd., 2018; Georgiadis, 2018; Dimopoulos & Bakas, 2019; Aubry vd., 2019; Alfaro-Navarro vd., 2020; Yu vd., 2021). Makine öğrenimi yöntemleri çok sayıda taşınmazın ve taşınmazla ilişkin verinin birlikte incelenmesini sağlamakta ve bilimsel bir yaklaşımla değerlendirilmesini gerçekleştirmektedir.

Bu çalışmada, Türkiye’de Niğde kentinde imar ve şehircilik sürecinde değişen taşınmazların değerlerinin tahmin edilmesinde istatistiksel analiz tekniklerinden Lineer regresyon ve makine öğrenimi yöntemlerinden Yapay Sinir Ağları (YSA), Regresyon Ağaçları, Destek Vektör Regresyon ve Gaussian Process Regresyon algoritmaları kullanılmıştır. Tahmin sonuçları güncel piyasa değerleri ile karşılaştırılarak bu yöntemlerin birbirine göre başarısı ölçülmüştür. Literatürdeki çalışmalardan farklı olarak bölgesel nitelikte birbirine yakın değer ve özellikteki veriler değil kentin tamamından toplanan 1200 farklı veri modellenmiştir. Böylece istatistiksel ve yapay zekâ yöntemleri ile kentin toplu taşınmaz değerlerine yönelik profili ortaya konulmuştur. Çalışma, kentin taşınmaz değer profilinin ortaya konulmasıyla birlikte şehrin gelecekte imar ve şehircilik yatırımlarına ilişkin bölgesel eşitsizlikleri önleyerek planlanmasında yerel yönetimlere bir yol göstermektedir.

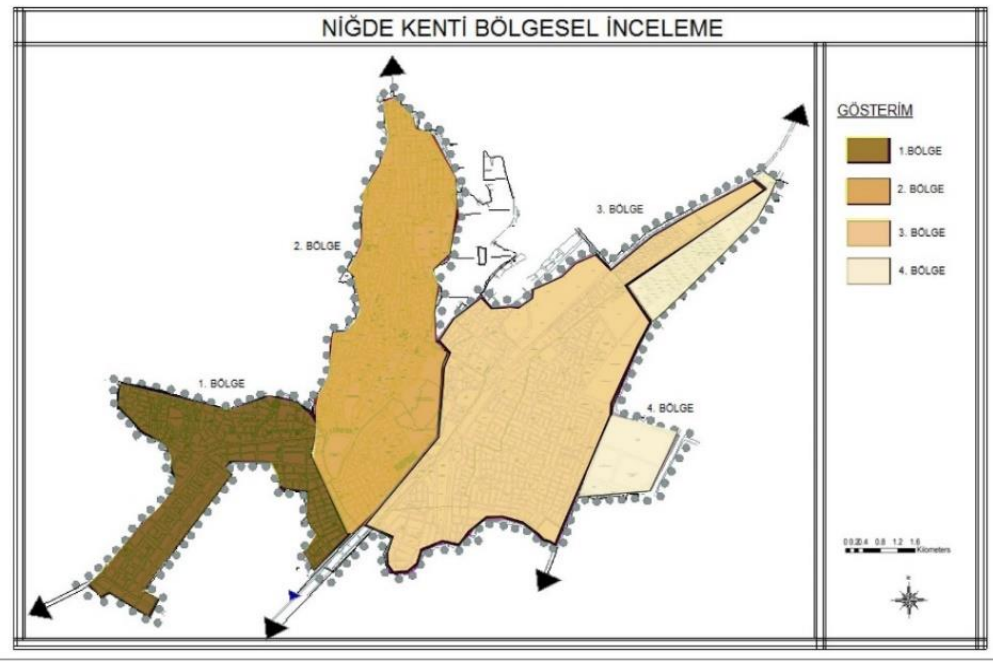
## 2. YÖNTEM

Niğde kenti çevresinde Kayseri, Nevşehir, Adana, Mersin ve Konya illeri yer almaktadır. Turizm ve hizmetler sektörü açısından gelişmiş iller arasında kalan Niğde’de 1992 yılında kurulan Üniversitenin etkisiyle imar faaliyetleri giderek artmaktadır. 2025 yılı için Niğde’de tarım sektörü başta olmak üzere hizmetler sektörü ve son sırada sanayi sektörüne ilişkin stratejik planlamalar yapılmaktadır (Niğde Çevre Durum Raporu, 2015). Çalışma alanı olarak Niğde kent merkezi belirlenmiştir. Kent merkezi olarak belirlenen alan kırsal alanın yer almadığı ve imar sınırının bittiği nokta olarak ifade edilebilir (Şekil 1).



Şekil 1. Uygulama alanı genel görünümü

Niğde Belediyesi tarafından kent imar planı çalışmaları için kent bütününde 4 farklı bölgeye ayrılmıştır. Bu ayrıma göre I. Bölge Üniversite etkisiyle gelişen ve II. Bölge ise Hastanenin etkisiyle imar faaliyetlerinin arttığı bölgelerdir (Şekil 2).

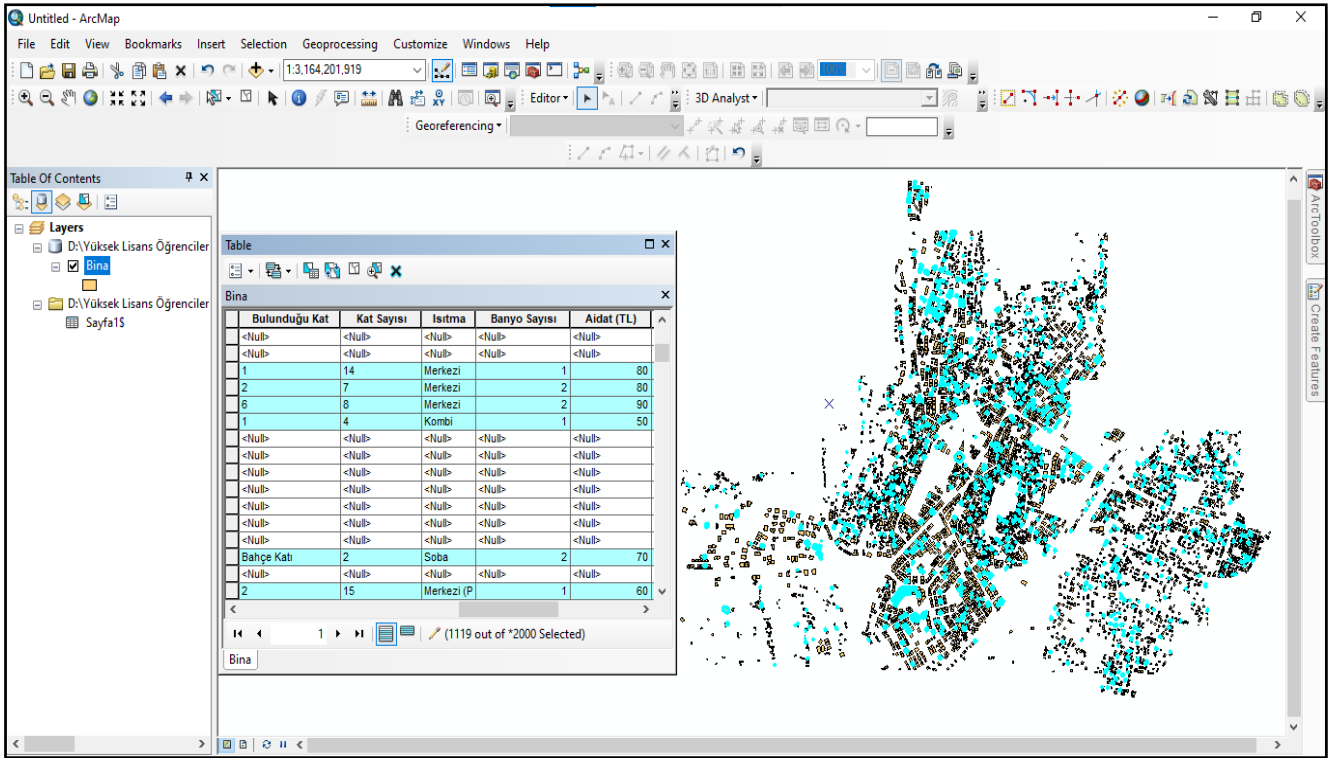


Şekil 2. Niğde kenti bölgesel değişim analizi

Şehrin eski yerleşim bölgesi III. Bölge olarak adlandırılan alan afet bölgesi ilan edilmiştir. Sanayinin yoğunlaştığı kırsal özellik gösteren alan ise IV. Bölge olarak ifade edilmiştir (Şekil 2).

Bu ayrıma göre homojen şekilde kentin tamamında taşınmaz değer değişimini yansıtan veriler internet üzerinden emlak sitelerinden toplanmıştır. Şekil 3'de

yapısal özellikleri toplanan taşınmazların kent bütününde dağılımı verilmiştir. Veri setinde toplam 1200 veri bulunmaktadır. Veri içeriğinde taşınmazların piyasa değerleri dışında yapısal özelliklerini yansıtan veriler (brüt alan (m<sup>2</sup>), oda sayısı, bina yaşı, bulunduğu kat, ısıtma şekli, banyo sayısı, krediye uygunluk, aidat ve cephe) yer almaktadır (Tablo 1).




Şekil 3. Yapısal özellikleri toplanan taşınmazların kent bütününde dağılımı

Çalışma kapsamında toplanan verilerin ArcGIS 10.6 yazılımı yardımıyla düzenlenerek bir veri tabanı oluşturulmuştur. Taşınmazlara ilişkin pafta altlığı sayısallaştırılarak ilgili yapısal özelliklere ilişkin öznitelik verisi ilişkilendirilmiştir. Oluşturulan veri

tabanı taşınmazlara ilişkin sorgulama, ilişkilendirme, mekânsal analizler gerçekleştirilme ve sonuçları görsel haritalar, tablolar ve grafikler halinde raporlayabilme olanağı sağlamaktadır (Şekil 4).

**Tablo 1.** Taşınmazların yapısal özelliklerine ilişkin elde edilen veriler

Taşınmaz Numarası	Brüt Bina Alanı (m <sup>2</sup> )	Oda Sayısı	Bina Yaşı	Kat	Isıtma	Banyo Sayısı	Aidat (TL)	Krediye Uygunluk	Cephe	Fiyat (TL)
7474	170	3+1	2	7	Merkezi (Pay Ölçer)	1	20	Evet	Doğu, Güney	290.000
122	522	7+3	5-10 arası	3	Doğalgaz	1	0	Evet	Batı, Doğu, Güney	700.000
6151	195	4+1	0	10	Merkezi (Pay Ölçer)	2	0	Hayır	Batı, Doğu, Kuzey	415.000
9495	175	3+1	0	2	Merkezi (Pay Ölçer)	1	0	Evet	Doğu, Güney, Kuzey	325.000
4698	165	3+1	4	5	Merkezi	2	0	Hayır	Batı, Kuzey	265.000
949	160	3+1	0	14	Merkezi (Pay Ölçer)	1	0	Evet	Batı, Kuzey	255.000
423	260	5+1	5-10 arası	10	Merkezi	2	0	Evet	Batı, Kuzey, Güney	200.000
8502	160	3+1	0	6	Doğalgaz (Kombi)	2	0	Evet	Doğu, Güney, Kuzey	155.000
1559	150	3+1	26-30 arası	2	Soba	1	0	Evet	Doğu, Güney	99.000
3553	155	3+1	0	1	Doğalgaz (Kombi)	2	0	Hayır	Batı, Güney, Kuzey	185.000
6039	170	3+1	1	12	Merkezi (Pay Ölçer)	1	0	Evet	Batı, Doğu, Güney	345.000
7861	560	3+1	1	2	Soba	1	0	Hayır	Batı, Doğu	420.000
...										

**Şekil 4.** Taşınmazların özniteliklerine yönelik veri tabanı

Çalışmanın sonucunda, taşınmazlara ilişkin piyasa değerleri ile tahmin değerleri veri tabanı kullanılarak karşılaştırılmıştır.

## 2.1. Yöntem

Bu çalışmada, Niğde kentinde farklı bölgelerden seçilen 1200 mülkün yapısal özelliklerine dayanarak değer tahmini yapmak için istatistiksel analiz tekniği olan Lineer Regresyon ve Makine Öğrenimi yöntemlerinden Yapay Sinir Ağları, Regresyon Ağaçları, Destek Vektör Regresyonu ve Gaussian Process Regresyonu algoritmaları kullanılmıştır. Bu yöntemler

arasından en başarılı değer tahmini gerçekleştiren model seçilmiştir. Seçilen modele göre tahmin değerleri üzerinden RRelief algoritması kullanılarak, hangi parametrelerin mülk değerlerinin değişiminde ağırlıklı etkisi olduğu analiz edilmiştir. Ayrıca çalışmada kullanılan makine öğrenimi algoritmaları, başarı metrikleri ve özellik seçim yöntemi olan RRelief hakkında bilgi verilmiştir.

## 2.2. Lineer Regresyon

Regresyon analizi, bağımlı bir değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkilerin tahmin edilmesi için kullanılan istatistiksel bir yöntemdir. Değişkenler arasındaki ilişkiyi modellemek ve ilişkinin gücünü değerlendirmek için kullanılmaktadır. Regresyon analizinde basit ve çoklu doğrusal regresyon yaygın kullanılan regresyon varyasyonları da bulunmaktadır (Andrews, 1974).

Basit doğrusal regresyon, bir bağımlı değişkenin tek bir bağımsız değişken ile arasındaki ilişkinin ifade edilmesine dayanmaktadır (Karaca & Karacan, 2016).

Basit bir doğrusal regresyon model  $\varepsilon$ 'nin bir hata olduğu Eşitlik 1 ile ifade edilir.

$$Y = \beta_0 + \beta_1 X + \varepsilon \quad (1)$$

Basit doğrusal regresyondan farklı olarak çoklu doğrusal regresyon, iki ve daha fazla bağımsız değişken ve bir bağımlı değişken arasındaki doğrusal ilişkiyi belirtmektedir.

Birçoklu doğrusal regresyon  $\varepsilon$  hata terimi,  $Y_i$ : bağımlı değişkeninin gözlenen  $i$ ' inci değerini,  $X_{ij}$ :  $j$ ' inci bağımsız değişkenin  $i$ ' inci düzeyindeki değerini,  $\beta_j$ :  $j$ ' inci regresyon katsayısı,  $k$ : bağımsız değişken sayısını ve  $n$  gözlemleri olmak üzere Eşitlik 2'deki şekilde temsil edilmektedir (Gunst & Mason, 1980).


$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ik} + \varepsilon_{ij} \quad (2)$$

$i=1,2,\dots,n$   
 $j=1, 2, \dots,k$

## 2.3. Yapay Sinir Ağları

Yapay sinir ağları ile insan beyindeki sinir hücrelerinin (nöron) organizasyon ve çalışma mekanizması taklit edilerek bilgisayar ortamında matematiksel hesaplama modelleri oluşturulur (Kunt, 2014; Boğar & Boğar, 2017). Günümüzde pek çok alanda kullanılan bir araç olan YSA verileri eğitime, öğrenme, test etme, ilişkilendirme, sınıflandırma, kontrol etme kümelenme, genelleme, ağırlıklandırma, tahmin ve optimizasyon konu ve problemlerinde kullanılmaktadır.

YSA'lar, sayısal bilgiyi yapay nöronlar ve girdi düğümleri ile işleyen ilişkilendirme yapan, iç kurallar üreten ve bu kurallara göre sonuçlar elde ederek bunları karşılaştıran bir çalışma prensibine sahiptir. Bir yapay sinir ağı mimarisi; girişler, ağırlıklar, toplama fonksiyonu aktivasyon fonksiyonu ve çıktı katmanlarından oluşur (Şekil 5).



Şekil 5. Yapay sinir ağı mimarisi (Karakoyun & Hacibeyoğlu, 2014)

Girdiler, yapay sinir hücresine dış dünyadan gelen bilgiler olup, ağırlıklar ise girdilerin hücre üzerindeki etki ve önemini gösterir. Toplam (birleştirme) fonksiyonu, hücreye gelen net girdiyi hesaplar, aktivasyon (etkinlik, eşik, transfer) fonksiyonu, toplam fonksiyonunun sonuçlarını çıktıya dönüştüren süreçtir. Hücrenin çıktısı, aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir (Öztemel, 2012; Boğar & Boğar, 2017). Bu çalışmada YSA'nın eğitiminde Levenberg-Marquardt (LM) algoritması tercih edilmiştir. Yakınsama hızının artması ve yerel minimumlara takılma riskinin azalması gibi avantajları nedeniyle LM algoritması, yapay sinir ağlarının eğitiminde sıkça kullanılan bir optimizasyon yöntemidir (Liu, 2010).

### 2.3.1. Levenberg- Marquardt (LM) Algoritması

Levenberg-Marquardt (LM) algoritması, maksimum komşuluk tabanlı en küçük kareler hesaplama yöntemidir. Bu yöntem, ağırlık ve bias parametrelerini optimize etmek için kullanılır. LM algoritması, hesaplanan ve beklenen çıkışlar arasındaki hata fonksiyonunun minimize edilmesini hedefler. Hata fonksiyonu genellikle kareler toplamı olarak ifade edilir (Hagan & Menhaj, 1994).

Geri yayılım algoritmasıyla eğitilen yapay sinir ağlarında, yerel minimuma takılma riski yüksek ve yakınsama hızı düşüktür. Geri yayılım algoritması, hata azaltmak için birinci dereceden türevi kullanırken, LM algoritması Newton yöntemi ile geri yayılım yöntemi arasında ara değerler hesaplar ve ikinci dereceden türevle hata azaltmaya çalışır (Karaboga, & Ozturk, 2009; Kurban & Beşdok, 2009).

LM algoritması, Quasi-Newton yöntemleri gibi Hessian matrisini hesaplamadan ikinci dereceden eğitim hızına yaklaşmayı hedefleyen bir algoritmadır. Kareler toplamı şeklinde ifade edilen performans fonksiyonunda, Hessian matrisi Eşitlik 3 ve eğim Eşitlik 4 ile hesaplanabilir (Günen vd., 2020).

$$H = J^T J \quad (3)$$

$$g = J^T e \quad (4)$$

Burada Jakobiyen matrisi 'J', ağ hatalarının birinci türevlerini içeren ve bias ile ağırlıklara bağlı olan bir matristir. 'e' ağ hatalarının vektörel bir temsildir. Jakobiyen matrisi, Hessian matrisini hesaplamaktan daha az karmaşık bir geri yayılım tekniği kullanılarak hesaplanabilir (Günen vd., 2020).

Levenberg-Marquardt algoritması, Newton benzeri güncelleme için Eşitlik 5'teki bu yaklaşımı Hessian matrisine uygular.

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (5)$$

Eğer  $\mu$  büyükse, bu durum küçük bir adım boyutuyla eğim inişine dönüşür. Newton'un yöntemi, bir hata minimum değerinin yakınında daha hızlı ve daha doğru olduğu için hedef, Newton'un yöntemine mümkün olduğunca hızlı bir şekilde yaklaşmaktır.

## 2.4. Destek Vektör Regresyonu (DVM)

Destek vektör makineleri (DVM), Vapnik & Cortes (1995) tarafından bulunan istatistiksel öğrenme teorisi alanında ortaya çıkmış bir makine öğrenme tekniği olarak bilinmektedir (Demir vd., 2018). DVM’de verilerin, lineer olarak ayrılabilirlikleri ve lineer olarak ayrılabilirlikleri şeklinde iki durum söz konusudur.

DVM lineer olarak ayrılan problemlerde özellikler arasından geçen hiper düzlemi bulmak amaçlanmaktadır. Hiper düzlemin bulunması için Eşitlik 6’da verilen koşul fonksiyonunun sınırlamaları ise Eşitlik 7’de ifade edilmiştir.

$$\min \left| \frac{1}{2} |w| \right| \quad (6)$$

$$y_i(wX_i + b) - 1 \geq 0 \text{ ve } y_i \in \{1, -1\} \quad (7)$$

Problemin çözümü için koşul fonksiyonun maksimum ve minimum noktalarını bulmak gerekmektedir. Bu amaçla Eşitlik 8’de verilen Lagrange formülü sıklıkla kullanılmaktadır. Sonuç olarak, lineer olarak ayrılabilir DVM problemin çözümü için Eşitlik 9 ile ifade edilen fonksiyon elde edilmektedir.

$$L(w, b, a) = \frac{1}{2} |w| - \sum_{i=1}^N a_i y_i (w x_i + b) + \sum_{i=1}^N a_i \quad (8)$$

$$f(x) = \text{sign} \left( \sum_{i=1}^N \lambda_i y_i(x x_i) + b \right) \quad (9)$$

DVM lineer olmayan problemlerde, örnek uzayını, lineer olarak ayrılabilirliği bir yüksek boyuta aktararak, farklı örnekler arasındaki maksimum mesafenin bulunması esasına dayanır (Demirci, 2019). Bu durumda mesafeyi maksimum yapacak ve sınıflandırmadan kaynaklanan hataları minimize edecek bir C parametresi eklenmesi gerekmektedir. C üst sınırının değeri arttıkça verilerdeki hata sayısı azalmakta ve  $C = \infty$  olduğunda verilerin doğrusal olarak birbirinden ayrılabilirliği tespit edilmektedir. Bu durum Eşitlik 10 olarak ifade edilmektedir.

$$L(w, b, a, \xi, \mu) = \frac{1}{2} \|w\| + C \sum_{i=1}^N \xi_i + \sum_{i=1}^N \alpha_i \{y_i(w x_i + b) - 1 + \xi_i\} - \sum_{i=1}^N \mu_i \xi_i \quad (10)$$

Lineer olmayan veri sorunu çözümü için çekirdek fonksiyonları (polinom, radyal, lineer, Pearson VII ve normal polinom kernell) aracılığıyla örnekler yüksek boyutlu bir uzaya aktarılıp çözümler bu uzayda yapılabilir.

## 2.5. Regresyon Ağaçları

Regresyon ağacı anlaşılabilirlikleri ve basitlikleri nedeniyle en iyi bilinen makine öğrenimi algoritmalarından biridir (Yang vd., 2017). Ayrıca doğrusal olmayan ilişkileri modelleme esnekliği ile literatürde oldukça popülerdir. Regresyon ağacı modelinde nihai amaç hedef parametreye göre mümkün olduğunca

homojen olan veri kümesinin alt kümelerini elde etmektir (Mahjoobi & Etemad-Shahidi, 2008).

Genellikle regresyon ağacı algoritmaları ağaç yapısını oluşturmak ve kırpma işlemi ile iki adımlı bir prosedürü takip eder (Yang vd., 2017). Regresyon ağaçları algoritmaları kök, düğüm ve dallanma kriterlerinin seçiminde izlenen yollar ile birbirinden ayrılır. Kullanılacak yöntem, modelin ve veri setinin özelliklerine göre seçilmelidir. Sonuç olarak algoritmaların seçimi model başarısını önemli ölçüde etkilemektedir. Regresyon ağacı algoritmaları; AID, CHAID, CART, ID3, C4.5, C5.0, MARS, E-CHAID, SLIQ, SPRINT ve QUEST sıklıkla kullanılan algoritmalarlardır.

## 2.6. Gauss Süreç Regresyonu

Gauss süreç regresyonu Gauss olasılık dağılımına dayanmaktadır. Doğrudan analitik yollarla hesaplama yapmadığımız fonksiyonlar ve sonsuz sayıda nesnelere hakkında çıkarım veya tahmin yaparak bir dağılım elde etmemizi sağlayan parametrik bir yöntemdir (Rasmussen & Williams, 2006). Gauss süreç regresyonu zaman serileri analizi, karmaşık sınıflandırma problemleri ve regresyon sorunlarını çözmek için yaygın olarak kullanılan başarılı bir yöntemdir. Gauss dağılımını ifade eden bir eşitlik için  $\{(x_i); i = 1, 2, \dots, n\}$  veri setinde  $x_i \in \mathbb{R}^d$  olmak üzere  $x_i$  reel değerlerin rassal değişkeni olan  $f(x_i)$  fonksiyonu olduğunu varsayalım. Bu durumda,  $f_i = f(x_i)$  ve  $[f_1, f_2, \dots, f_n]^T$  olmak kaydıyla, sınırlı sayıdaki  $f_i$  rassal değişkenlerin herhangi bir kombinasyonunun ortak dağılımı olan  $f = p(f_1, f_2, \dots, f_n)$  gauss dağılımını Eşitlik 11 ile ifade edebiliriz:

$$N(f | \mu, K) \quad (11)$$

Bu eşitlikte rassal değişkenlere ait ortalama vektörü  $\mu$  ve kovaryans matrisi  $K$  Eşitlik 12 ve 13 ile ifade edilir.

$$\mu = [\mu(x_1), \dots, \mu(x_n)]^T \quad (12)$$

$$K = \sum_{ij} = k(x_i, x_j) \quad (13)$$

## 2.7. Tahminler için Performans Metrikleri

Veri seti üzerindeki tahminler yapıldıktan sonra tahmin başarılarının analiz edilmesi için performans metrikleri gereklidir. Bu çalışmada;  $R^2$ , Ortalama Hata Karesi (MSE) ve Ortalama Hata Karesinin Kökü (RMSE) metrikleri kullanılmıştır.  $R^2$ , eğitim verileriyle kurulan modelin test verileri üzerinde ne kadar başarılı olduğunu ölçen bir performans ölçөгüdür. MSE, tahmin performansının değerlendirilmesinde gerçek değer ve tahmin değer arasındaki tüm sapmaların kareleri toplanarak bulunan değerlerin ortalamasının bulunmasıyla performans analizi sağlamaktadır (Garip, 2017; Garip & Oktay, 2018). Çok kullanılan performans ölçütlerinden biri olan RMSE, modelin tahmin ettiği değerler ile gerçek değerler arasındaki farkın bulunması ile aralarındaki hatanın büyüklüğünü ölçen bir metriktir.  $R^2$ , RMSE ve MSE formülleri sırasıyla Eşitlik 14, 15 ve 16’da verilmiştir.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (14)$$

$$MSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (15)$$

$$RMSE = \sqrt{MSE} \quad (16)$$

Ayrıca çalışmada model performanslarının belirlenmesi için Uluslararası Değerleme Çalışanları Derneği (The International Association of Assessing Officer, IAAO) tarafından tanımlanmış standart olan dağılım katsayısı (COD) ve fiyatla ilgili farklılık değeri (PRD) metrikleri de kullanılmıştır.

Dağılım Katsayısı (Coefficient of Dispersion, COD); değerlendirme modelinin tahminlerinin gerçek değerlerle ne kadar tutarlı olduğunu ölçer. COD, tahmin edilen değerlerin standart sapmasının gerçek değere oranını temsil eder. Daha düşük bir COD değeri, tahminlerin daha tutarlı ve homojen olduğunu gösterir. Yüksek bir COD değeri ise tahminler arasında daha fazla değişkenlik olduğunu ve daha az tutarlılık olduğunu gösterir. Fiyatla İlgili Farklılık Değeri (Price Related Differential, PRD), bir değerlendirme modelinin tahmin ettiği fiyatlar ile gerçek fiyatlar arasındaki farkın yüzdesel olarak ifade edilmesini sağlayan bir metriktir. COD değeri Eşitlik 17’de ve PRD değeri Eşitlik 18’de belirtilmiştir.

$$COD = \frac{100}{m} \times \left( \frac{\sum_{i=1}^n \left| \frac{y_i}{\hat{y}_i} - m \right|}{n - 1} \right) \quad (17)$$

$$m = \text{median}(y_i / \hat{y}_i)$$

$$PRD = \frac{\text{mean}(y_i / \hat{y}_i)}{\sum_{i=1}^n y_i / \sum_{i=1}^n \hat{y}_i} \quad (18)$$

## 2.8. Özellik Seçimi (ReliefF)

Özellik seçimi büyük boyutlu veri kümeleri içerisinde değişkenlerin alt küme seçimi veya öznelik seçimi olarak ifade edilen bir ön işlem sürecidir. Özellik seçimi yöntemleri veri alt kümelerini tanımlamak için filtreler ve sarmalayıcılar (filters and wrappers) öznelik seçimi için kullanılmaktadırlar.

Relief algoritması filtre tabanlı özellik seçim yöntemlerinden biri olarak ağırlık tahmininde etkili, basit ve yaygın olarak kullanılan bir yaklaşımdır (Durgabai, 2014). Rolyef algoritması, örnek-tabanlı öğrenmeden (instance-based-learning) esinlenerek Kira ve Rendell tarafından formüle edilmiştir (Urbanowicz, vd., 2018). ReliefF, orijinal Relief algoritmasının uzantısıdır. ReliefF, orijinal Relief tabanlı algoritmalarından altıncı algoritma olarak "F" varyasyonudur (Kononenko, 1994; Urbanowicz vd., 2018).

RReliefF, ReliefF'e benzer başka bir algoritmadır. RReliefF, son tahmin ağırlıklarını ( $W_j$ ) ReliefF'den farklı bir şekilde hesaplamak için orta (ara) ağırlıkları ( $W_{dy}$ ,  $W_{dj}$ ,  $W_{dy \wedge dj}$ ) kullanır.

Formüldeki " $\wedge$ " işareti, "dy ve dj" özelliklerinin kesişimini temsil etmek için kullanılan bir semboldür. Bu sembol, iki özelliğin aynı anda var olması durumunda, yani hem "dy" hem de "dj" özelliklerinin aynı zamanda etkin olması durumunda kullanılır.

Bu sembolün kullanımı, Relief algoritmasında özelliklerin etkileşimini değerlendirmek amacıyla yapılır. Yani, "dy $\wedge$ dj" ifadesi, "dy" ve "dj" özelliklerinin birleştiği durumu ifade eder. Bu şekilde, Relief algoritması, özelliklerin ayrı ayrı etkilerinin yanı sıra, bu etkileşimin de önemini değerlendirebilir.

Tüm ara ağırlıklar aşağıda sırasıyla verilen Eşitlik 19, 20 ve 21 ile hesaplanmaktadır.

$$W_{dy}^i = W_{dy}^{i-1} + \Delta_y(x_r, x_q) \cdot d_{rq} \quad (19)$$

$$W_{dj}^i = W_{dj}^{i-1} + \Delta_j(x_r, x_q) \cdot d_{rq} \quad (20)$$

$$W_{dy \wedge dj}^i = W_{dy \wedge dj}^{i-1} + \Delta_y(x_r, x_q) \cdot \Delta_j(x_r, x_q) \cdot d_{rq} \quad (21)$$

RReliefF, tüm ara ağırlıkları tamamen güncelledikten sonra aşağıda verilen Eşitlik 22'ye göre tahmin ağırlıklarını  $W_j$  hesaplar (Robnik-Sikonja & Kononenko, 1997).

$$W_j = \frac{W_{dy \wedge dj}}{W_{dy}} - \frac{W_{dj} - W_{dy \wedge dj}}{m - W_{dy}} \quad (22)$$

## 3. BULGULAR

Sonuçlar model sonuçları ve özellik seçimi sonuçları olarak incelenmiştir.

### 3.1. Model Sonuçları

Bu çalışmada, Niğde kentinde imar ve şehircilik sürecinde değişen taşınmaz değerlerinin "Yapay Sinir Ağları, Lineer Regresyon, Regresyon Ağaçları, Destek Vektör Regresyon ve Gaussian Süreç Regresyonu" algoritmaları ile toplu bir şekilde tahmin edilmesi sağlanmıştır. Tahmin sonuçları gerçek piyasa değerleri ile karşılaştırılarak bu yöntemlerin başarıları karşılaştırılmıştır. Çalışma için kullanılan veri seti %70 eğitim, %30 test olmak üzere iki parçaya bölünerek analiz edilmiştir. Veri setinden normal dağılıma uygun şekilde rastgele seçilen %70'lik eğitim verileri ile modeller kurulmuş ve daha sonra eğitime dâhil edilmemiş test verileri ile modellerin kullanılabilir olup olmadığına karar verilmiştir. Kullanılan yöntemlere göre eğitilen modellerin ve test verilerinin performans metrikleri Tablo 2'de verilmiştir. Modellerin eğitim doğruluklarına bakıldığında RMSE: 0.0349 ve R<sup>2</sup>: %92.94 değerleriyle gaussian process regresyon yöntemi en başarılı görünmesine rağmen test verileriyle yapılan kontrolde modelin aşırı öğrendiği (overfit), test verilerinde performansının düşük olduğu görülmektedir. Yapay sinir ağlarıyla oluşturulan modelin performans metrikleri eğitim için (R<sup>2</sup>: %87.12, RMSE: 0.0645) ve test verileri için (R<sup>2</sup>: %84.92, RMSE: 0.0608) olarak elde edilmiş ve en başarılı tahmin modeli olduğu tespit edilmiştir.

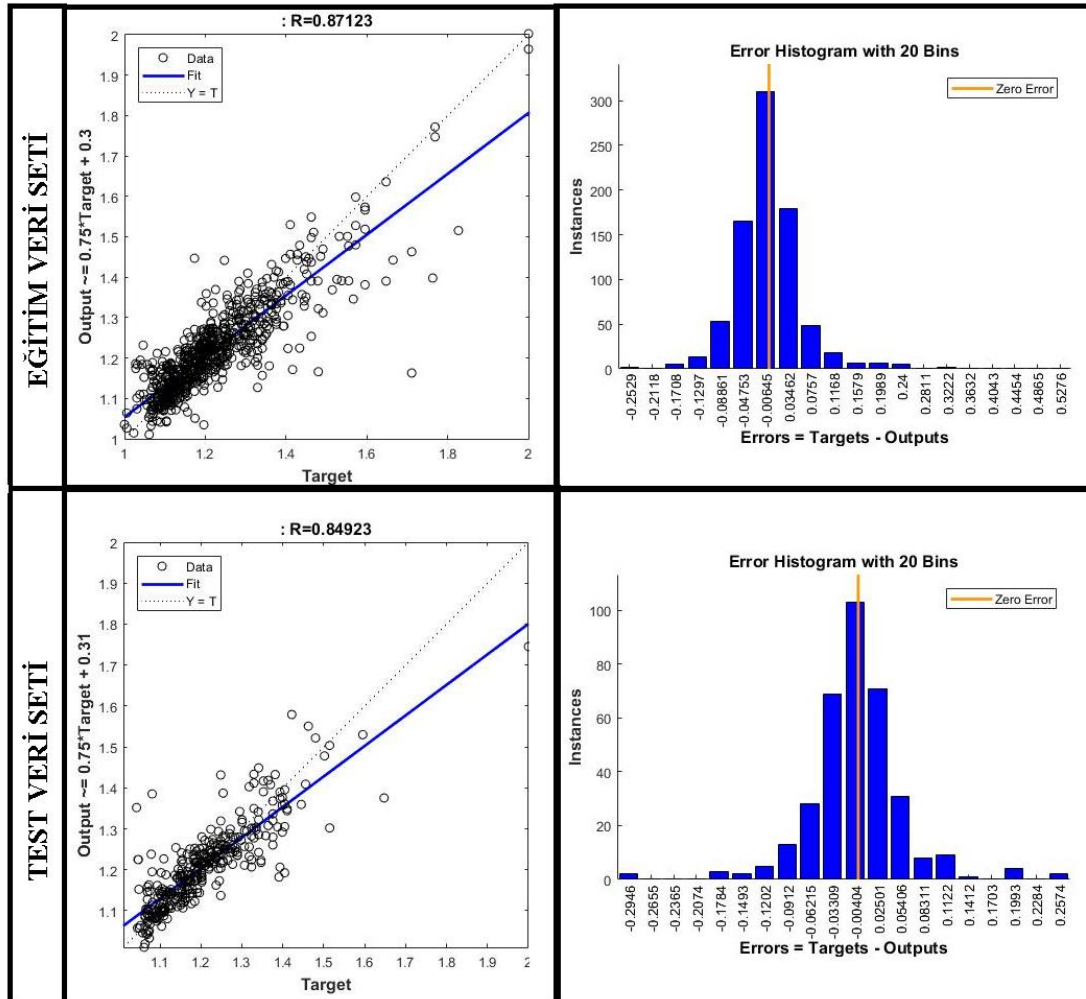
**Tablo 2.** Kullanılan modeller için hesaplanmış performans metrikleri

Yöntem	Eğitim (%70)			Test(%30)			
	MSE	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>	COD	PRD
YSA (LM, 15Neron)	0.00416	0.0645	87.12	<b>0.0608</b>	<b>84.92</b>	10.2601	1.00205
Lineer Regresyon	0.00889	0.0943	48.47	0.0860	43.94	11.4176	1.00383
Regresyon Ağaçları	0.00540	0.0735	68.67	0.0751	57.32	10.7941	1.00336
Destek Vektör Regresyon (Küçük)	0.00590	0.0768	65.77	0.0805	50.89	11.2292	1.00328
Gaussian Process Regresyon (Eksponansiyel)	<b>0.00122</b>	<b>0.0349</b>	<b>92.94</b>	0.0693	63.66	9.9226	1.00232

Tablo 2’de görüldüğü gibi Gaussian Process Regresyon test edilen modelin performans metrikleri (R<sup>2</sup>: %63.66, RMSE:0.0693) açısından yapay sinir ağlarından sonra diğer yöntemlere göre daha başarılı bir tahmin modeli oluşturulduğu tespit edilmiştir. Regresyon Ağaçları algoritması da performans metrikleri (R<sup>2</sup>: 57.32, RMSE: 0.0751) açısından Gaussian Process Regresyon ile elde edilen performans metriklerine yakın bir tahmin modeli sağlamaktadır. Destek Vektör Regresyon ve Lineer regresyon ise sağladıkları performans metrikleri açısından sırasıyla

(R<sup>2</sup>: %50.89, RMSE: 0.0805) ve (R<sup>2</sup>: %43.94, RMSE: 0.0860) en düşük performans metriklerini göstermektedir. R<sup>2</sup> değeri %70 ile %90 arasında ise modelin verileri iyi bir şekilde açıkladığı ve iyi bir uyum sağladığı kabul edilmektedir. Bu perspektiften bakıldığında YSA dışındaki modellerin veri setine uyumlu olmadığı söylenebilir.

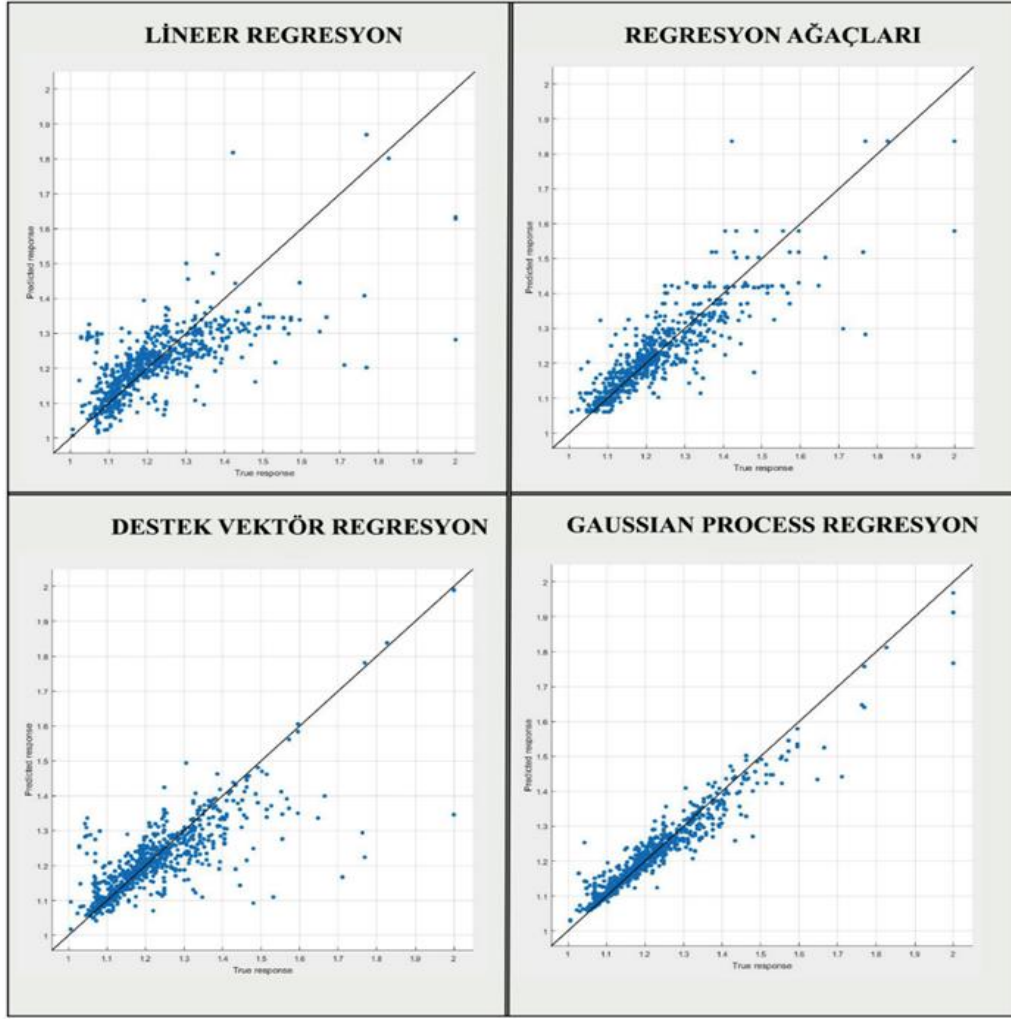
YSA ile elde edilen modelin ürettiği eğitim ve test veri setine göre tahmin değerleri ve gerçek değerler arasındaki hata histogramı ve regresyon grafiği Şekil 6’da görülmektedir.

**Şekil 6.** YSA eğitim ve test verileri için model sonuçları

Lineer Regresyon, Regresyon Ağaçları, Destek Vektör Regresyon ve Gaussian Process Regresyon algoritmaları ile oluşturulan modellerin ürettiği tahmin

değerleri ve gerçek değerlerin ne derece örttüğü ve bu iki değişken arasındaki başarıyı gösteren regresyon eğrileri Şekil 7’de görülmektedir.



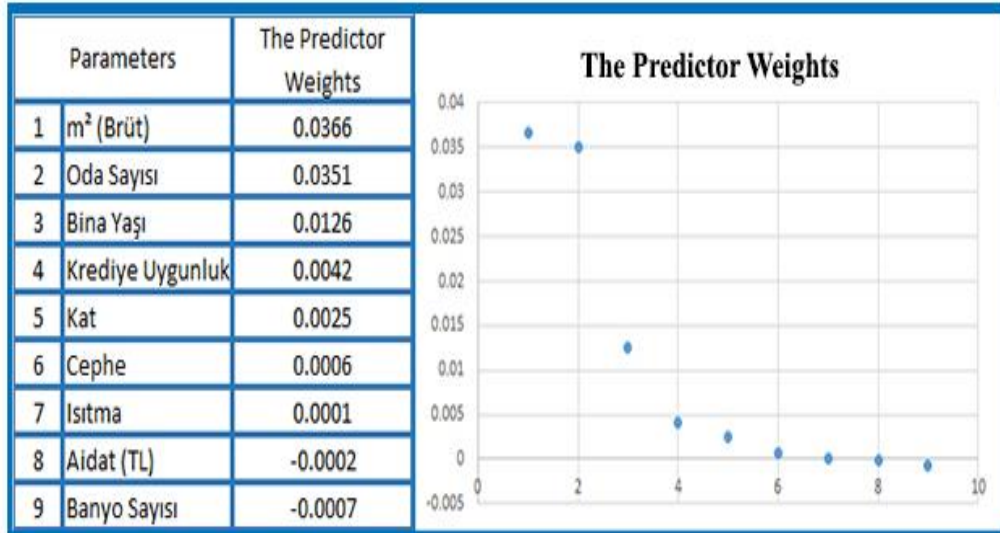


Şekil 7. Kullanılan modellere ait regresyon eğrileri

Fiyatla ilgili Farklılık Değeri (PRD) için kabul edilen aralık, 0.98 ile 1.03 arasındadır (IAAO, 2010). Yüksek PRD değeri, geriye doğru değerlendirme olarak adlandırılır ve yüksek değerli mülklerin düşük değerli mülklere göre yetersiz değerlendirildiğini gösterir. Öte yandan, küçük PRD değeri, ileriye değerlendirme olarak adlandırılır ve yüksek değerli mülklerin düşük değerli mülklere göre fazla değerlendirildiğini gösterir.

Modeller için hesaplanan PRD değerleri kabul edilebilir sınırlar içindedir.

Dağılım katsayısı (COD), piyasa fiyatı ve tahmin edilen fiyat oranlarının medyan oranından ortalama yüzde sapmasını ölçer. Daha düşük bir COD değeri, tahminlerin daha tutarlı ve homojen olduğunu gösterir. En düşük COD değeri YSA ve Gaussian Process Regresyon modellerinde elde edilmiştir.



Şekil 8. RRelieff algoritması ile hesaplanan parametre ağırlıkları

### 3.2. Özellik Seçimi Sonuçları (Rrelieff)

RRelieff algoritması ile hangi parametrenin Niğde kenti için toplu taşınmaz değerlerinin belirlenmesinde ağırlıklı etkisi olduğu tespit edilmiştir. Rrelieff algoritması ile yapılan hesaplama sonucu model kapsamında belirlenen parametrelerin ve ağırlıkların sıralaması Şekil 8’de verilmiştir. Seçilen parametreler ve yapılan hesaplamalara göre oluşturulan modelde en yüksek ağırlıkla taşınmaz değer değişimini etkileyen parametrenin Brüt alan(m<sup>2</sup>) (1) ve Oda sayısı (2) olduğu tespit edilmiştir. Ardından sırasıyla yapılaşmayı yansıtan Bina yaşı (3) Krediyeye uygunluk (4), Kat adedi (5), Cephesi (6), Isıtma özelliği (7), Aidat (8) ve Banyo sayısı (9) parametrelerinin taşınmaz değerlemede ağırlıklı etkileri bulunduğu tespit edilmiştir.

Bu sonuç, Niğde kenti için toplu taşınmaz değerlendirme sürecinde hangi parametrelere ilişkin verilerin toplanması, depolanması ve düzenlenmesine sürecine ilişkin bir yol göstermektedir.

### 3.3. Model Sonuçlarının Literatür Kapsamında Değerlendirilmesi

Bu çalışmada taşınmazların kent bütününde toplu olarak değerlendirilmesi sağlanmıştır. Toplu Taşınmaz Değerleme sistemi adil, hızlı ve eş zamanlı olarak çok sayıda taşınmazın değerlendirilmesinde kullanılan tekniklerinin tamamına verilen adlandırmadır (Erdem, 2017; Iban, 2023).

Toplu taşınmaz değerlemesinin pek çok açıdan yararları bulunmaktadır:

- Değerleme sürecinde değer tahminine katkısı olan kriterler ile olmayan kriterlerin elenmesinde yardımcı olur.
- Oluşturulan modeller tüm veri setini temsil etme özelliği göstermektedir.
- İstatistik yöntemlerde olduğu gibi korelasyon vb. çoklu bağlantı ile model performansını olumsuz etkilemesi söz konusu değildir (Iban, 2023).
- Karar vericilerin ve yatırımcıların taşınmaz piyasalarındaki yeni beklentileri, eğilimleri ve arazi kullanım kararlarının etkileri piyasa içerisinde izlenebilmesi sağlanarak üretilen modelin ürettiği veri ve bilgilerinden faydalanılabilir (Çınar & Ünel, 2022).

Bununla birlikte Toplu Taşınmaz değerlendirme sistemi ile başarılı sonuçlar elde edilmesinde bölgesel farklılıkları ortaya koyacak nitelikte konumsal özelliklerin yer alması gerekmektedir. Toplu değerlendirme Makine Öğrenim Tekniklerinin başarılı sonuçlar elde edilmesinde büyük veri setleri ile süreç yönetilmelidir. Veri setinin uyumluluğunu bozacak nitelikte sıçramalar yapan verilerin ayıklanması gerekebilir.

Son yıllarda toplu taşınmaz değerlendirme sürecine yönelik çalışmalar giderek artmaktadır. Kontrimas & Verikas (2011)’de Toplu Taşınmaz Değerlemede hesaplamalı zekâ tekniklerinin ve Iban (2023)’de Toplu Taşınmaz Değerlemede Açıklanabilir Yapay Zekâ (XAI) Tekniklerinin kullanım potansiyelini detaylı bir şekilde ele almaktadır.

Wang & Li (2019) 21. yy. ’da Toplu Taşınmaz Değerleme Modellerine ilişkin sistematik bir literatür

taraması gerçekleştirmiştir. 104 makale incelenmiş ve üç ana başlık altında modelleri gruplandırmıştır. Bunlar; Yapay zeka tabanlı modeller, CBS tabanlı modeller ve Karma tabanlı modellerdir. Araştırma, farklı verilerin özelliklerine göre farklı yöntemlerin kullanılmasının birbirinin avantajlarını tamamlayabileceği ve böylece toplu değerlendirme için karma bir model oluşturabileceği vurgusunu yapmaktadır.

Dimopoulos & Bakas (2019)’da Toplu Taşınmaz Değerleme sürecinde makine öğrenim modellerinin yeteneklerini ve mülklerin toplu değerlendirilmesi için nasıl kullanılabilirliğini araştırmıştır. Çalışmalarında bu tür modellerde duyarlılık analizinin ve otomatik değerlendirme modellerinin (AVM) önemi vurgulanmıştır.

Zurada vd., (2020)’de Toplu Taşınmaz Değerlemede çeşitli regresyon ve yapay zeka tabanlı yöntemleri uygulamış ve karşılaştırmıştır. Geleneksel olmayan regresyona dayalı yöntemlerin homojen veri setleri ile tüm simülasyon senaryolarında iyi performans gösterdiği, makine öğrenimi tekniklerinin ise daha az homojen veri kümeleri ile iyi performans gösterdiği tespit edilmiştir.

Iban (2022)’de konutların Toplu Taşınmaz Değerlemesinde Ağaç tabanlı Makine Öğrenimi algoritmalarının uygulanmasını sağlamıştır. Çalışmasında, kentsel ve konut araştırmalarında açıklanabilir yapay zeka tekniklerinin toplu taşınmaz değerlendirme sistemlerine entegre edilmesi gerektiğini göstererek analistlerin ve akademisyenlerin modelleri daha şeffaf bir şekilde açıklamaları için yol göstermektedir. Ayrıca çalışmasında Iban, Ağaç Tabanlı Makine Öğrenimi algoritmalarının bağımsız Makine Öğrenimi regresörlerinden daha iyi performans gösterdiği için toplu taşınmaz değerlendirme kullanımını savunmaktadır.

Bu çalışma, literatürde bahsedilen uygulamaların sonuçlarını destekleyen nitelikte kent ölçeğinde toplu taşınmaz değerlendirilmesinde farklı makine öğrenimi algoritmalarının başarısını çalışma ile elde edilen başarı metriklerinin sonuçları ile kanıtlamıştır. Bu algoritmalarla yapay sinir ağları yöntemiyle tahmin sonuçlarının yüksek doğrulukla (R<sup>2</sup>: %84.92, RMSE: 0.0608) elde edildiği tespit edilmiştir.

### 4. TARTIŞMA VE SONUÇ

Taşınmaz değerlendirme sürecinin tarafsız ve adil bir şekilde yönetilebilmesinde literatürde pek çok yöntem arayışı karşımıza çıkmaktadır. Yapay zeka yöntemleri akademik olarak farklı algoritmalar ile yapılan modeller kapsamında değerlendirme sürecine yeni yaklaşımlar getirmektedir. Bu çalışma kapsamında incelenen Yapay Sinir Ağları, Lineer Regresyon, Regresyon Ağaçları, Destek Vektör Regresyon ve Gaussian Process Regresyon algoritmaları ile elde edilen taşınmazların tahmin değerleri piyasa değerleri ve başarı metrikleri ile karşılaştırılmıştır. Elde edilen sonuçlarda yapısal özellikler çerçevesinde analiz edilerek tahmin sonuçları değerlendirilmiştir.

Çalışmada belirlenen yapay zekâ yöntemlerinin değerlendirme sürecine etki eden taşınmazların yapısal özellikleri vb. çok sayıda envanterini karşılaştırma, ilişkilendirme, test etme ve tahmin etmesi sağlanmıştır.

Tahmin sonuçları yapay sinir ağları yöntemiyle yüksek doğrulukla ( $R^2$ : %84.92, RMSE: 0.0608) elde edilmiştir.

Bu çalışma, literatürdeki taşınmaz değerlendirme çalışmalarında bulunan bölgesel bazlı çalışmalar dışında ölçeği kent bütününde genişleterek yapay zekâ teknikleri ile değerlemeyi gerçekleştirmiştir. Elde edilen doğruluk düzeyi kent ölçeğinde büyük çaplı veriler ile değerlendirme sürecinin yönetilebileceğine örnek teşkil etmektedir.

#### Araştırmacıların Katkı Oranı

**Merve TÜRKAN:** Literatür tarama, yazım, kontrol ve düzenleme.

**Aslı BOZDAĞ:** Veri toplama ve analizi, yorumlama, yazım.

**Ahmet Emin KARKINLI:** Metodoloji, yazım ve kontrol.

**Adile Gülsüm ULUCAN:** Kontrol ve düzenleme.

#### Çıkar Çatışması

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir.

#### Araştırma ve Yayın Etiği Beyanı

Çalışmada, araştırma ve yayın etiğine uyulmuştur.

#### KAYNAKÇA

- Abidoye, R.B. & Chan, A.P.C. (2017). Artificial Neural Network in Property Valuation: Application Framework and Research Trend. *Property Management*, 35(5), 554-571.
- Alfaro-Navarro, J-L., Cano, E.L., Alfaro-Cortes, E., Garcia, N., Gamez, M. & Larraz, B. (2020). A Fully Automated Adjustment of Ensemble Methods in Machine Learning for Modeling Complex Real Estate Systems. *Hindawi Complexity*, 5287263.
- Andrews, D.F. (1974). A Robust Method for Multiple Linear Regression. *Tecnometrics*, 16(4), 523-531.
- Aubry, M. Kräussl, R. Manso, G. & Spaenjers, C. (2019). Machine Learning, Human Experts, and the Valuation of Real Assets. *CFS Working Paper Series*, No. 635.
- Baldominos, A., Blanco, I., Moreno, A.J., Iturrarte, R., Bernandez, O. & Alfonso, C. (2018). Identifying Real Estate Opportunities Using Machine Learning. *Applied Sciences*, 8, 2321.
- Bogar, E. & Boğar, Z. (2017). Forecasting of 'Turkey's Sectoral CO2 Gas Emissions by Artificial Neural Networks. *Academia Journal of Interdisciplinary Scientific Research*, 3(2), 12-24.
- Bozdağ, A. & Ertunç, E. (2020), CBS ve AHP Yöntemi Yardımıyla Niğde Kenti Örneğinde Taşınmaz Değerleme. *Geomatik Dergisi*, 5(3), 228-240.
- Çakır, P. & Sesli, F.A. (2013). Arsa Vasıflı Taşınmazların Değerine Etki Eden Faktörlerin ve Bu Faktörlerin Önem Sıralarının Belirlenmesi. *Harita Teknolojileri Elektronik Dergisi*, 5(3), 1-16.
- Çınar, S. & Ünel, F.B. (2022). 2/B Orman Vasfını Yitirmiş Araziden Tarım Arazisine Dönüşen Taşınmazların Toplu Değerlemesi. *Geomatik Dergisi*, 7(2), 112-127.
- Demir, H., Erdoğan, P. & Kekeçoğlu, M. (2018). Destek Vektör Makineleri, YSA, K-Means ve KNN Kullanarak Arı Türlerinin Sınıflandırılması. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 6, 47-67.
- Demirci, M. (2019). Destek Vektör Makineleri ve M5 Karar Ağacı Yöntemleri Kullanılarak Yağış-Akış İlişkisinin Tahmini. *Dicle Üniversitesi Mühendislik Fakültesi Dergisi*, 10(3), 1113-1124.
- Demirel, B., Yelek, A., Alağaç, H.M. & Eren, T. (2018). Taşınmaz Değerleme Kriterlerinin Belirlenmesi ve Kriterlerin Önem Derecelerinin Çok Ölçütlü Karar Verme Yöntemi, *Sosyal Bilimler Dergisi*, 8(2), 665-682.
- Dimopoulos, T. & Bakas, N. (2019). Sensitivity Analysis of Machine Learning Models for the Mass Appraisal of Real Estate. Case Study of Residential Units in Nicosia, Cyprus. *Remote Sensing*, 11, 3047.
- Durgabai, R.P.L. (2014). Feature Selection using ReliefF Algorithm. *International Journal of Advanced Research in Computer and Communication Engineering*, 3(10), 8215-8218.
- Erdem, N. (2017). Türkiye için bir Taşınmaz Değerleme Sistemi Yaklaşımı. *Geomatik Dergisi*, 2(1), 18-39.
- Garip, E. (2017). OECD Ülkelerindeki CO<sub>2</sub> Emisyonunun Makine Öğrenmesi ile Tahmin Edilmesi, *Yüksek Lisans Tezi*, İstanbul Medeniyet Üniversitesi, Mühendislik Yönetimi ABD, İstanbul.
- Garip, E. & Oktay, A.B. (2018). *Forecasting CO<sub>2</sub> Emission with Machine Learning Methods*. International Conference on Artificial Intelligence and Data Processing (IDAP), IEEEExplore. 1-4.
- Georgiadis, A. (2018). Real Estate Valuation Using Regression Models and Artificial Neural Networks: An Applied Study in Thessaloniki. *International Journal of Real Estate and Land Planning*, 1, 98-105.
- Gunst, R.F. & Mason, R.L. (1980). *Regression Analysis and its Application: A Data-oriented Approach*, Florida: CRC Press.
- Günen, M.A., Atasever, U.H. & Beşdok, E. (2020). Analyzing the Contribution of Training Algorithms on Deep Neural Networks for Hyperspectral Image Classification. *Photogrammetric Engineering & Remote Sensing*, 86(9), 581-588.
- Hagan, M. & Menhaj, M. (1994). Training Feedforward Networks with the Marquardt Algorithm. *IEEE Transactions on Neural Networks*, 5(6), 989-993.
- IAAO, (2010). International Association of Assessing Officers (IAAO), Standard on Ratio Studies. Kansas City, MO: International Association of Assessing Officers, [Erişim Tarihi: 23.03.2023], [https://www.iaao.org/media/standards/Standard\\_on\\_Ratio\\_Studies.pdf](https://www.iaao.org/media/standards/Standard_on_Ratio_Studies.pdf)
- Iban, M.C. (2022). An Explainable Model for the Mass Appraisal of Residences: The Application of Tree-Based Machine Learning Algorithms and Interpretation of Value Determinants. *Habitat International*, 128, 102660.
- Iban, M.C., (2023). *Toplu Taşınmaz Değerlemede Açıklanabilir Yapay Zekâ (XAI) Tekniklerinin Kullanılabilirliği*, III. Uluslararası Gayrimenkul Geliştirme ve Yönetimi Konferansı ICREDM2023, 1-4 Şubat 2023, Ankara.

- Karaboga, D. & Ozturk, C. (2009). Neural Networks Training by Artificial Bee Colony Algorithm on Pattern Classification. *Neural Network World*, 19(3), 279.
- Karaca, C. & Karacan, H. (2016). Çoklu Regresyon Metoduyla Elektrik Tüketim Talebini Etkileyen Faktörlerin İncelenmesi. *Selçuk Üniversitesi, Mühendislik Fakültesi, Bilim ve Teknoloji Dergisi*, 3, 182-195.
- Karakoyun, M. & Hacıbeyoğlu, M. (2014). Biyomedikal Veri kümeleri ile Makine Öğrenmesi Sınıflandırma Algoritmalarının İstatistiksel Olarak Karşılaştırılması. *Dokuz Eylül Üniversitesi, Mühendislik Fakültesi Mühendislik Bilimleri Dergisi* 16(48), 30-41.
- Kononenko, I. (1994). *Estimating Attributes: Analysis and Extensions of RELIEF*. European Conference on Machine Learning, Berlin, 171-182.
- Kontrimas, V. & Verikas, A. (2011). The Mass Appraisal of the Real Estate by Computational Intelligence. *Applied Soft Computing*, 11(1), 443-448.
- Kunt, F. (2014). Bulanık Mantık ve Yapay Sinir Ağları Yöntemleri Kullanılarak Konya İl Merkezi Hava Kirliliği Modellenmesi, *Doktora Tezi*, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Çevre Mühendisliği ABD, Konya.
- Kurban, T. & Beşdok, E. (2009). A Comparison of RBF Neural Network Training Algorithms for Inertial Sensor Based Terrain Classification. *Sensors*, 9(8), 6312-6329.
- Liu, H. (2010). *On the Levenberg-Marquardt Training Method for Feed-forward Neural Networks*. 6th International Conference on Natural Computation, IEEE, 1, 456-460.
- Mahjoobi, J. & Etemad-Shaidi, A. (2008). Hindcasting of Wave Parameters Using Different Soft Computing Methods. *Applied Ocean Research*, 30(1), 28-36.
- Mete, M.O. (2019). Coğrafi Bilgi Sistemleri ile İstanbul İli Nominal Taşınmaz Değer Haritasının Oluşturulması, *Yüksek Lisans Tezi*, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Geomatik Mühendisliği ABD, İstanbul.
- Niğde Çevre Durum Raporu, (2015). Niğde İli 2014 Yılı Çevre Durum Raporu, *Niğde Valiliği Çevre ve Şehircilik İl Müdürlüğü*, Niğde.
- Özkan, S. (2009). Taşınmaz Satış Fiyatına Etki Eden Faktörlerin İstatistiksel Yöntemlerle Araştırılması, *Yüksek Lisans Tezi*, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Geomatik ABD, İstanbul.
- Öztemel, E. (2012). *Yapay Sinir Ağları*, İstanbul: Papatya Yayıncılık.
- Rasmussen, C.E. & Williams, C.K.I. (2006). *Gaussian Processes for Machine Learning*, Cambridge, MA: MIT press.
- Robnik-Sikonja, M. & Kononenko, I. (1997). *An Adaptation of Relief for Attribute Estimation in Regression*. Machine Learning: Proceedings of the Fourteenth International Conference (ICML'97), 5, 296-304.
- Toktaş, M. (2012). Hazine Arazileri için CBS Destekli Değer Haritalarının Üretilmesi: Afyonkarahisar Örneği, *Yüksek Lisans Tezi*, Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Jeodezi ve Fotogrametri ABD, Afyonkarahisar.
- Torun, M.K. (2009). Taşınmaz Değer Haritalarının Coğrafi Bilgi Sistemleri ile Üretilmesi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, *Yüksek Lisans Tezi*, Geomatik Mühendisliği ABD, İstanbul.
- Tunca, E. & Üstüntaş, T. (2019). *Gayrimenkul Değerleme Modelinin Oluşturulmasında Çok Kriterli Karar Verme Yöntemlerinin Kullanılması*. TMMOB 6. Coğrafi Bilgi Sistemleri Kongresi, 23-25 Ekim 2019, Ankara.
- Urbanowicz, R.J., Meeker, M., Cava, W., La., Olson, R.S. & Moore, J.H. (2018). Relief-based Feature Selection : Introduction and Review. *Journal of Biomedical Informatics*, 85, 189-203.
- Uşak, B. (2019). Konya Otogar Civarında Emlak Vergisine Esas Zemin Değerinin Tespiti, *Yüksek Lisans Tezi*. Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, Harita Mühendisliği ABD, Konya.
- Vapnik, V. & Cortes, C. (1995). Support-Vector Networks. *Machine Learning*, 20, 273-297.
- Wang, D., & Li, V.J. (2019). Mass Appraisal Models of Real Estate in the 21st Century: A Systematic Literature Review. *Sustainability*, 11(24), 7006.
- Yağmahan, G. (2019). Puanlama Yöntemiyle Taşınmaz Değerlerinin Belirlenmesi Ve Yaşam Kalitesiyle İlişkinin Araştırılması, *Yüksek Lisans Tezi*, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği ABD, İstanbul.
- Yang, L., Liu, S., Tsoka, S. & Papageorgiou, L.G. (2017). A Regression Tree Approach Using Mathematical Programming. *Expert Systems With Applications*, 78, 347-357.
- Yu, Y. Lu, J. Shen, D. & Chen, B. (2021). Research on Real Estate Pricing Methods Based on Data Mining and Machine Learning. *Neural Computing and Applications*, 33, 3925-3937.
- Zurada, J., Levitan, A., & Guan, J. (2020). A Comparison of Regression and Artificial Intelligence Methods in A Mass Appraisal Context. *Journal of Real Estate Research*, 33(3), 349-388.



© Author(s) 2023.

This work is distributed under <https://creativecommons.org/licenses/by-sa/4.0/>