

Hiper-optimize edilmiş makine öğrenim teknikleri ile taşınmaz değerlendirilmesi, Yozgat Kenti örneği

Abdulkazi Hazer¹, Aslı Bozdağ¹, Ümit Haluk Atasever²

¹Niğde Ömer Halisdemir Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği, Niğde, Türkiye, abakizr@gmail.com, aslibozdag@ohu.edu.tr

²Erciyes Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği, Kayseri, Türkiye, uhatasever@erciyes.edu.tr

Kaynak Göster: Hazer, A., Bozdağ, A., & Atasever, Ü. H. (2024). Hiper-optimize edilmiş makine öğrenim teknikleri ile taşınmaz değerlendirilmesi, Yozgat kenti örneği. Geomatik, 9 (3), 299-312

DOI: 10.29128/geomatik.1454915

Anahtar Kelimeler

Toplu Taşınmaz Değerleme
Makine Öğrenimi Teknikleri
Hiperparametre
Optimizasyonu
Bayes Tekniği

Araştırma Makalesi

Geliş: 18.03.2024
Revize: 17.04.2024
Kabul: 24.04.2024
Yayınlanma: 02.12.2024



Öz

Toplu taşınmaz değerlendirilmede, Makine Öğrenim Teknikleriyle gelişmiş tahmin yöntemlerinden yararlanılarak objektif, bilimsel, doğru ve hızlı sonuçlar elde edilmektedir. Bu çalışmanın amacı; küçük ölçekli kentler sınıfında yer alan Yozgat kentinde Bayes Tekniği ile Hiper-Optimize Edilmiş Makine Öğrenimi Teknikleri sayesinde değer tahminleri oluşturmaktır. Bu kapsamda Topluluk Regresyonu, Çekirdek Regresyonu, Doğrusal Regresyon, Destek Vektör Makineleri Regresyonu ve İkili Karar Ağacı Regresyonu kullanılarak 2022 ve 2023 yıllarına ait taşınmaz verileri üzerinde toplu taşınmaz değerlendirme gerçekleştirilmiş ve başarımleri metrikleri hesaplanarak karşılaştırılmıştır. Bayes Tekniği ile Hiper-Optimize edilmiş eğitim verisi sonuçlarına göre Çekirdek regresyonunda, test verisi sonuçlarına göre ise Topluluk regresyonunda en başarılı sonuçlar elde edilmiştir. Çalışma, küçük ölçekli bir kentin bütününde toplu değerlendirme yapılması ve büyük bir değerlendirme sahası içinde bölgesel eşitsizliklere rağmen konut fiyat tahmin doğruluğunun metriklere göre başarılı sonuçlar elde etmesiyle literatürden farklılaşmaktadır. Elde edilen sonuçlar, heterojen özellikler taşıyan bir değerlendirme alanı için Makine Öğrenimi Tekniklerinin Hiper-Optimize edilmesiyle elde edilen konut fiyat tahmin sonuçlarının belirlenmesinde başarılı bir yaklaşım olduğunu göstermektedir.

Real estate valuation with hyper-optimized machine learning techniques, case of Yozgat City

Keywords

Mass Real Estate Valuation
Machine Learning
Techniques
Hyperparameter
Optimization
Bayesian Technique

Research Article

Received: 18.03.2024
Revised: 17.04.2024
Accepted: 24.04.2024
Published: 02.12.2024

Abstract

In mass real estate valuation, objective, scientific, accurate and fast results are obtained by using advanced estimation methods with Machine Learning Techniques. The purpose of this study; The aim is to create value estimates in the city of Yozgat, which is among the small-scale cities, using the Bayesian Technique and Hyper-Optimized Machine Learning Techniques. In this context, collective real estate valuation was carried out on real estate data for 2022 and 2023 using Ensemble Regression, Kernel Regression, Linear Regression, Support Vector Machines Regression and Binary Decision Tree Regression, and performance metrics were calculated and compared. According to the results of the Hyper-Optimized training data with the Bayesian Technique, the most successful results were obtained in the Kernel regression, and according to the test data results, the most successful results were obtained in the Ensemble regression. The study differs from the literature in that it performs a collective valuation of a small-scale city as a whole and achieves successful results in house price prediction accuracy according to metrics, despite regional inequalities within a large valuation area. The results obtained show that it is a successful approach in determining the house price prediction results obtained by Hyper-Optimization of Machine Learning Techniques for a valuation area with heterogeneous characteristics.

1. Giriş

Taşınmaz değerlemesi, toplumun ve bireylerin beklentileri göz önüne alınarak bilimsel yöntemlerle gerçekleştirilen bir süreçtir. Bu süreç, taşınmazların ve ilgili hakların, değerlendirme anında güncel toplumsal ve ekonomik koşullara uygun bir şekilde objektif bir değerlendirme yöntemi kullanılarak belirlenmesini içermektedir (Bozdağ ve Ertunç, 2020).

Günümüzde taşınmaz değerlendirme, gayrimenkul piyasasındaki mevzuata, değerlendirme yöntemlerine ve kriterlerine yönelik karmaşıklık ve çeşitlilik nedeniyle incelenmesi gereken bir süreçtir. Bu süreç, zaman ve maliyet kayıplarını en aza indirerek toplu olarak değerlendirme işlemlerini gerçekleştirme amacını taşımaktadır. Geleneksel ve modern yöntemlerden birinin veya birlikte hibrit metodoloji olarak değerlendirildiği taşınmaz değerlendirme süreci, bir dizi kritik etkeni içerir ve bu etkenlerin doğru bir şekilde değerlendirilmesi, objektif ve güvenilir sonuçlara ulaşmada kritik rol oynamaktadır.

Taşınmaz değerlendirme sürecinin doğru, güvenilir ve tarafsız bir şekilde gerçekleştirilmesinde çeşitli yöntemler kullanılmaktadır. Bu yöntemler, Klasik, İstatistik, Coğrafi Bilgi Sistemleri (CBS), Çok Kriterli Karar Analizi ve Makine Öğrenimi gibi literatürde yer alan çeşitli tekil ve toplu değerlendirme niteliğinde olan yaklaşımları içermektedir (Sevinç 2008, Engindeniz 2010; Çolak vd. 2022; Tabar vd., 2021; Kayalık ve Polat 2023; Tunca ve Üstüntaş 2019, Yağmahan, 2019; Ünel ve Yalpir, 2019; Büyük ve Ünel, 2021; Özsubaşı ve Ertaş, 2022; Yalpir ve Ünel, 2022).

Gelişen iletişim ve bilgi teknolojileri taşınmaz değerlendirme sürecinde Makine Öğrenimi Tekniklerinin kullanımına yönelik araştırmaları artırmıştır. Makine öğrenimi, karmaşık veri setlerini analiz ederek örüntüleri tanımlama ve mantıklı kararlar alma yeteneğiyle öne çıkan bir metottur. Literatürde pek çok makine öğrenimi algoritması kullanılarak taşınmaz değer tahminine ilişkin çalışma yapılmıştır (Park ve Bae, 2014; Ravikumar, 2017; Bilgilioğlu, 2018; Savaş, 2019; Ulvi ve Özkan, 2019; Zulkifley vd., 2020; Louati vd., 2021; Türkan ve diğ., 2023). Bu çalışmalar, farklı makine öğrenimi algoritmaları ile taşınmaz değer tahmininde bulunarak başarımlarını karşılaştırmıştır. Son yıllarda algoritma sonuçlarının başarısının artırması için hiperparametre optimizasyonuna ilişkin çalışmalar yapılmaktadır (Feurer ve Hutter, 2019; Kim vd., 2020; Kalliola vd., 2021; Iban, 2022). Modelin eğitildiği hiperparametreler ayarlanarak ya da uyumlandırılarak yapay öğrenme algoritmalarının doğruluğunun artırması sağlanabilir (Iban, 2022).

Hiperparametreler, bir makine öğrenimi modelinin öğrenme sürecini yönlendiren ve modelin yapılandırılmasında kullanıcı tarafından önceden belirlenen parametrelerdir. Bu parametreler, modelin eğitimi sırasında sabit kalır ve doğrudan öğrenme işlemine katılmazlar. Örnek olarak, bir yapay sinir ağı için katman sayısı, her katmandaki nöron sayısı, öğrenme oranı ve düzenleme (regularization) terimleri hiperparametreler arasında sayılabilir. Hiperparametre optimizasyonu veya ayarlama, bir makine öğrenimi modelinin performansını maksimize etmek amacıyla en

uygun hiperparametre değerlerinin belirlenmesi sürecidir. Hiperparametre optimizasyonunun amacı, veri seti üzerinde en iyi doğrulama (validation) performansını sağlayacak hiper-parametre kombinasyonunu bulmaktır. Hiper-parametre optimizasyonu, modelin veri üzerindeki performansını önemli ölçüde artırabilmektedir. Doğru hiperparametrelerle eğitilmiş bir model, aynı modelin varsayılan hiper-parametrelerle eğitilmiş versiyonuna göre daha yüksek doğruluk veya daha düşük hata oranları elde edebilir (Feurer vd., 2019). Bu süreç, genellikle deneme-yanılma, ızgara araması (grid search), rastgele arama (random search), Bayes optimizasyonu gibi yöntemler kullanılarak gerçekleştirilir.

Bu çalışmada, Yozgat kentindeki imar ve şehircilik süreçlerinde değişen taşınmaz değerlerinin toplu olarak tahmin edilmesinde modern analiz tekniklerinden olan makine öğrenimi yöntemleri kullanılmıştır. Bu yöntemler arasında Topluluk Regresyon, Çekirdek Regresyonu, Doğrusal Regresyon, Destek Vektör Regresyonu ve İkili Karar Ağacı Regresyonu gibi regresyon algoritmaları yer almaktadır. Çalışma, web ortamındaki erişilebilir gayrimenkul satış sitelerinden elde edilen 2022-2023 yıllarına ait 600 adet konut verisinin yapısal ve konumsal özelliklerinin, CBS tabanlı programda mekânsal analizi yapıp sonrasında programlama diliyle Hiper-Optimize edilmesi üzerine odaklanmaktadır. Modelin yapılandırılması ve Yozgat kenti toplu taşınmaz değerlendirme tahmininin başarılı bir şekilde gerçekleştirilmesi için hiperparametrelerin doğru bir şekilde belirlenmesi aşamasında kullanılan regresyon yöntemleri ve başarımlarını karşılaştırılmıştır. Elde edilen eğitim verisi sonuçlarına göre, Bayes Tekniği ile Hiper-Optimize edilmiş Çekirdek Regresyonu en başarılı sonuçları gerçekleştirmiştir. Elde edilen test verisi sonuçlarında farklı regresyonlar başarılı olsa da genel olarak bakıldığında, Bayes Tekniği ile Hiper-Optimize edilmiş Topluluk Regresyonu en başarılı sonuçları gerçekleştirmiştir.

Çalışma, küçük ölçekli bir kenti ele alması ve bu kentin tamamından toplanan 600 farklı veri setini içeren toplu bir tahmin modeli üretmesi ve makine öğrenim tekniklerinde hiper optimizasyon kullanması ile literatürdeki diğer çalışmalardan farklılaşmaktadır. Ayrıca çalışmada Bayes Tekniği (Bayesian Algorithm) ile Hiper-Optimize edilmiş Makine Öğrenim Teknikleri kullanılarak iyileştirilmiş biçimde kentin genel taşınmaz değer profili ortaya konulmuştur. Araştırma, kentin taşınmaz değer profilinin belirlenmesiyle birlikte, gelecekteki imar ve şehircilik yatırımlarında bölgesel eşitsizlikleri önleyerek planlama süreçlerine rehberlik edebilecek nitelikte yerel yönetimlere yönelik bir yol haritası sunmaktadır.

1.1. Literatür araştırması

Taşınmaz değerlendirme sürecinde kullanılan Makine Öğrenimi Tekniklerine ilişkin son yıllarda yapılan çalışmalar artmıştır. Literatürde makine öğrenimi tekniklerinin kullanıldığı çalışmalar içeriklerine göre Tablo 1'deki gibi ifade edilebilir.

Tablo 1. Literatürdeki makine öğrenimi yöntemlerin kullanılmasına yönelik bazı çalışmalar.

Çalışmaların amacı	Referanslar
Gayrimenkul piyasası için daha hassas ve doğru konut fiyat tahmini gerçekleştirilmesinde farklı makine öğrenim algoritmalarının birbirlerine göre hata ölçütlerinin karşılaştırılması	(Baldomino ve diğ., 2018; Mora-Garcia vd., 2018; Alfaro-Navarro vd., 2020; Tabar ve Şişman, 2020; Yılmaz ve Kocaman, 2020; Pai ve Wang, 2020; Tabar vd., 2021; Mete ve Yomraloğlu, 2021; Iban, 2022; Chou vd., 2022; Emeç ve Tekin, 2022; Aydınöğlü vd., 2023).
Taşınmazın değerinin tespitinde hangi kriterlerin taşınmaz fiyatına en yakın tahmini değer sonucunun belirlenmesinde etkili olduğunun incelenmesi veya değişken azaltılması	(Savaş, 2019; Esen ve Tokgöz, 2021)
Otomatik değerlendirme modellerinin (AVM) kullanılabilirliği için hassasiyetinin ölçülmesi	(Dimopoulos ve Bakas, 2019; Steurer vd., 2020; Baur vd., 2023)
Veri madenciliği ve makine öğrenmesine dayalı gayrimenkul fiyatlandırma yöntemleri üzerine araştırılması	(Yu vd., 2021)
Turizm sektörünün önde yer aldığı bir kıyı kentinde taşınmaz değer değişimleri makine öğrenmesi yöntemleri ile incelenmesi	(Alkan ve diğ., 2023)
Taşınmaz değer piyasasında pandeminin etkilerinin ölçülmesi	(Ngoc ve diğ., 2020; Grybauskas ve diğ., 2021; Mora-Garcia, 2022; Kaklauskas ve diğ., 2023; Ulucan, 2023)
Bayes Tekniği ile Hiper-Optimize edilmiş Makine Öğrenimi Tekniklerinin kullanıldığı taşınmaz değerlemesi üzerine çalışmalar	(Kim vd. 2020; Lee ve Park 2020; Milunovich 2020; Iban 2021; Kalliola vd., 2021; Calainho vd., 2022)

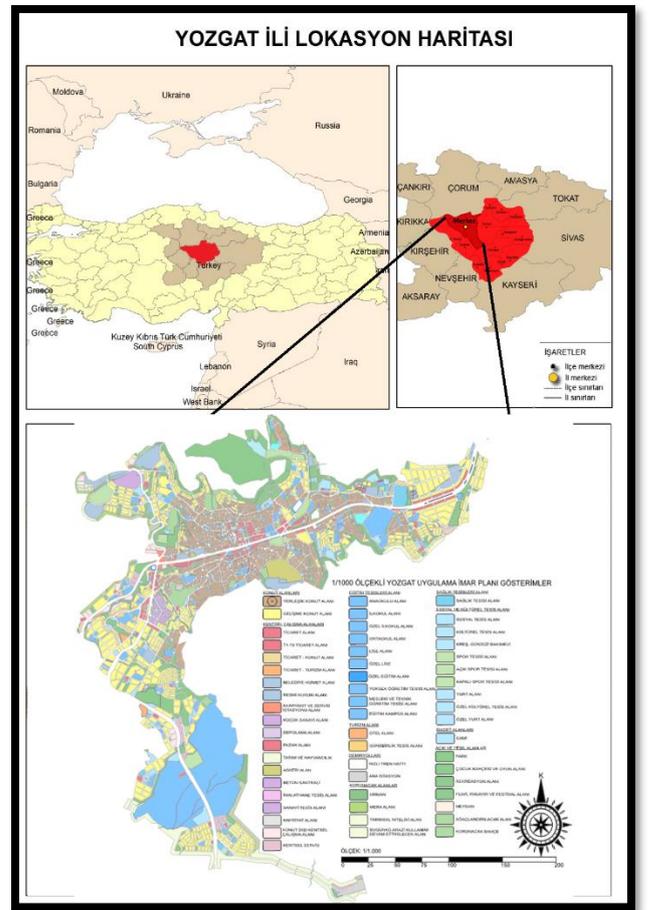
Makine öğrenim teknikleriyle yapılan taşınmaz değerlendirme tahmin ve karşılaştırılmasına yönelik çalışmalardan son yıllarda Bayes Tekniği ile Hiper-Optimize edilmiş Makine Öğrenimi Tekniklerinin kullanıldığı taşınmaz değerlendirme üzerine çalışmalar artmaktadır (Iban, 2021; Kalliola vd., 2021; Calainho vd., 2022).

Bu çalışmalarda taşınmaz değerlendirme süreçlerinde modellerin değiştirilmesi veya hiperparametre değerlerinin gerçek durum fiyat tahmini için ayarlanması konusunda çaba sarf edildiği görülmektedir (Kalliola vd., 2021). Ancak hiper parametre optimizasyonu ile gerçek bir iyileştirme sağlanamamıştır. Bununla birlikte uygulamalar Melbourne, New York ve Helsinki gibi büyük ölçekli metropol kentlerde gerçekleştirilmiştir. Bu çalışma literatürden farklı olarak küçük ölçekli kentlerde toplu taşınmaz değerlendirme kapsamında uygulanması ve farklı regresyon modellerinin Hiper-Optimize edilerek

iyileştirilmesi ve başarı oranının kıyaslanmasıyla literatüre önemli bir katkı sağlayacaktır.

2. Materyal

Bu çalışmada, Bayes Optimizasyon Tekniği ile Hiper-Optimize edilmiş Makine Öğrenimi yöntemlerini kullanarak, toplu taşınmaz değerlendirme süreçlerinde daha etkili ve doğru sonuçlara ulaşmak amaçlanmaktadır. Çalışma alanı olarak küçük ölçekli kentler bazında olan Yozgat kent merkezi seçilmiştir (Şekil 1). Yozgat İli Türkiye'nin Çekerek, Aydıncık ve Kadışehri ilçeleri kapsamında Karadeniz Bölgesi'nde kalan ancak genel bölgesel olarak İç Anadolu Bölgesi'nde yer alan bir ildir. Yozgat İli nüfusunun 2021 yılı itibarıyla %76,35'i şehirlerde yaşamakta ve toplam nüfusu 419.095'tir.

**Şekil 1.** Yozgat kenti genel görünümü.

2.1. Veri seti

Yozgat ilinin merkez ilçesinin imar planı doğrultusunda taşınmaz verileri uygun web adreslerinden elde edilerek konumsal ve yapısal özellikleri NetCAD 8.5'ta çalışma sahasına işlenmiş sonrasında CBS tabanlı programa aktarılarak veri tabanı oluşturulmuştur. 2022 ve 2023 yıllarına ait 600 adet yapının özelliklerine ilişkin yapısal verileri içeren veri seti Tablo 2' de sunulmuştur.

Taşınmaz değerine etki eden konumsal özelliklere ilişkin verilerin konumsal özellikleri (ağaçlandırma,

sağlık, eğitim, hızlı tren garı, resmi kurum, sosyo-kültürel ve ticaret alanları)'ne ilişkin CBS ortamında mekânsal analizler (buffer ve near) oluşturulmuştur (Şekil 2).

Ülkemizde yaşanan yüksek enflasyon ve fiyatlandırma davranışının bozulmuş olması benzer şekilde konutların doğru fiyatlandırılmasını ve zamansal fiyat değişiminin anlaşılmasını zorlaştırmaktadır. Bu kapsamda her bir konut için Jülyen tarih tanımlaması yapılmıştır. Bu sayede enflasyon nedeniyle konutlardaki zamana bağlı fiyat değişimi regresyon modellerinin

öğrenme sürecine dahil edilmiştir. Jülyen tarihi bulunulan yıl ile yılın başından bu yana geçen gün sayısının birleşiminden oluşan bir tarih biçimini ifade etmek için kullanılır. Jülyen tarih, tarih doğrudan kullanılmaktan daha basit ve ileri regresyon modelleri için daha uyumludur. Ayrıca, zamanın sürekli bir ölçüt olarak kullanılması, modelin zamanla değişen eğilimleri daha kolay yakalamasına yardımcı olmaktadır.

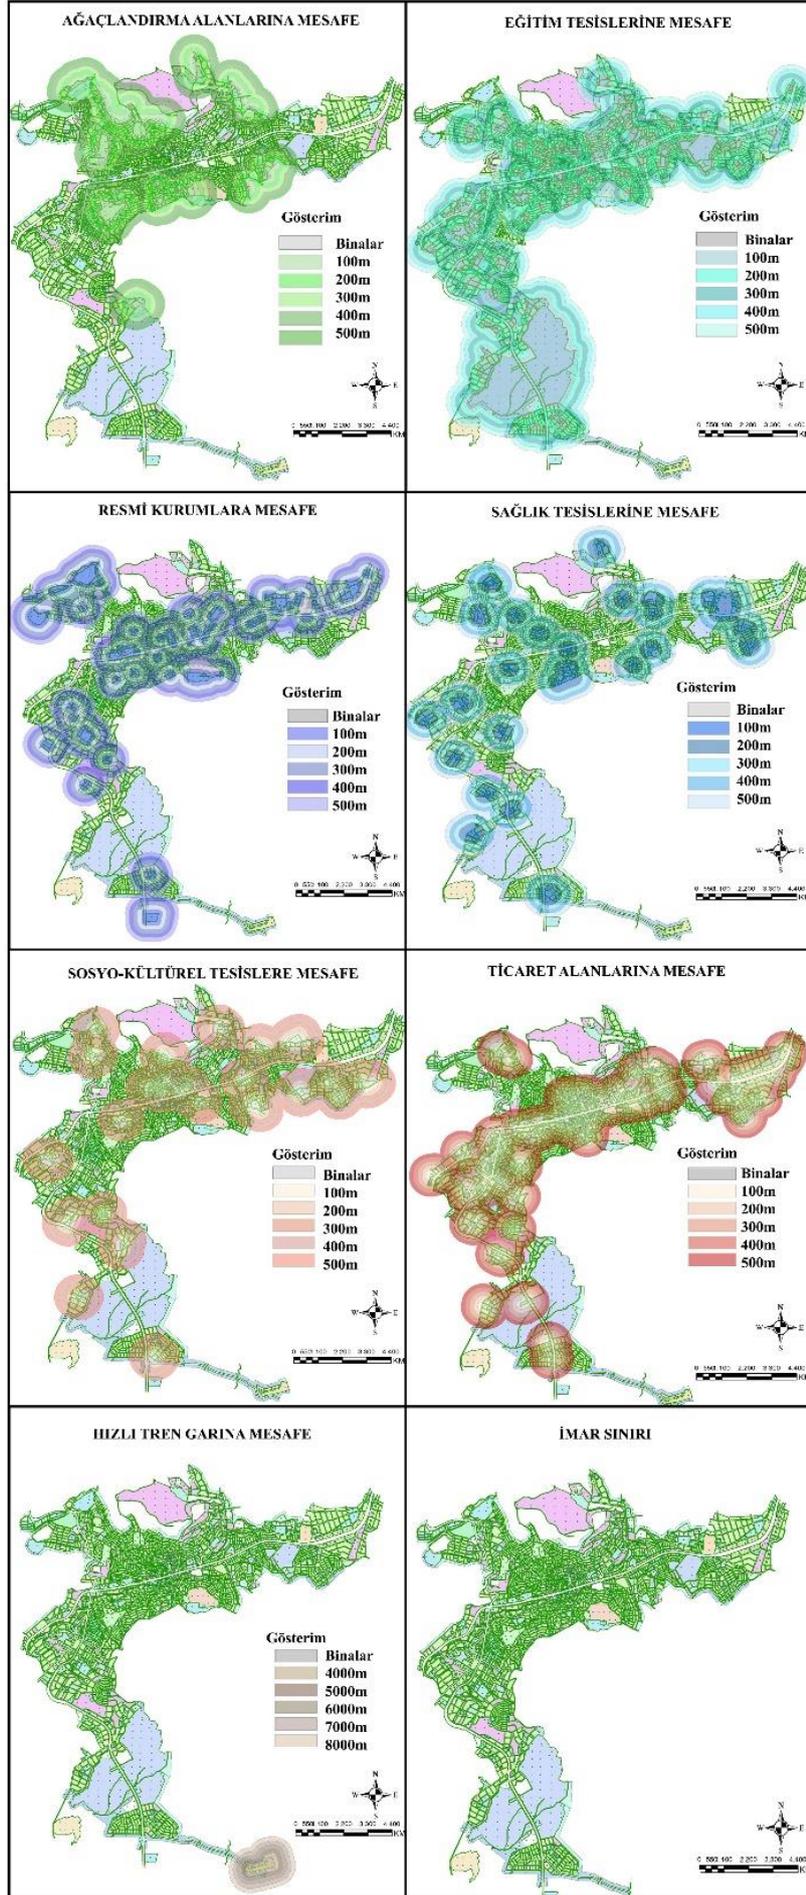
Bu konumsal özelliklere ilişkin modellemeye uygun hale getirilmiştir (Tablo 3).

Tablo 2. 2022 ve 2023 yıllarına ait yapısal veriler (600 adet taşınmazdan 6 tanesi gösterilmiştir).

Bina No	İlan Tarihi (gg.aa.yyyy)	Julian Tarih	Yapısal Özellikler		Taşınmaz Fiyatı (₺)
			AlanBrüt m2	...	
B1	13.05.2022	2022133	50	50	550,000
B2	20.05.2022	2022140	150	145	630,000
B3	9.06.2022	2022160	80	72	925,000
BB08	18.06.2023	2023169	66	55	1,250,000
BB09	18.06.2023	2023169	65	55	1,080,000
BB10	19.06.2023	2023170	65	60	1,050,000

Tablo 3. 2022 ve 2023 yıllarına ait konumsal veriler (600 adet taşınmazdan 6 tanesi gösterilmiştir).

Bina No	İlan Tarihi (gg.aa.yyyy)	Julian Tarih	Konumsal Özellikler		Taşınmaz Fiyatı (₺)
			Ağaçlandırma_Near (m)	...	
B1	13.05.2022	2022133	481.76	454.20	550,000
B2	20.05.2022	2022140	226.06	423.01	630,000
B3	9.06.2022	2022160	473.19	640.95	925,000
BB08	18.06.2023	2023169	458.47	84.46	1,250,000
BB09	18.06.2023	2023169	116.38	666.16	1,080,000
BB10	19.06.2023	2023170	294.55	269.64	1,050,000



Şekil 2. Konumsal özelliklere ilişkin mekansal analizler.

3. Yöntem

Bu çalışmada, Yozgat kentinin 2022 ve 2023 yılları Toplu taşınmaz değerlemesi için Bayes Tekniğiyle Hiper-Optimize edilmiş Makine Öğrenim Teknikleri ile taşınmaz değer tahminleri gerçekleştirilmiştir. Yapılan değer tahminleri başarımları metrikleri çerçevesinde karşılaştırılarak değerlendirilmiştir.

3.1. Hiper-parametre optimizasyonu Bayes tekniği

Kullanılan bir makine öğrenimi modelinden iyi performansı elde etmek için hiperparametre değerlerinin belirlenme sürecine hiperparametre optimizasyonu denilmektedir. Hiper parametrelerin ayarlamaları tecrübelerle göre manuel olarak yapılabilmektedir. Ancak makine öğrenmesi tekniklerinin parametre ayarlamalarının bu şekilde yapılması çok zaman alıcı bir süreçtir. Hiperparametre değerlerine aktivasyon fonksiyonları, optimizasyon algoritmaları, öğrenme oranı, epoch sayısı, düğüm ağırlıkları ve ağ yapısı örnek verilebilir (Feurer ve Hutter, 2019). Hiper-Optimize edilmiş makine öğrenimi bu hiperparametre değerlerinin otomatik ve manuel olarak ayarlanmasıyla modelin performansını artırmayı sağlar.

Hiperparametre optimizasyonunda optimizasyon için birçok teknik bulunmaktadır. Bu optimizasyon tekniklerine Izgara Arama, Rastgele Arama, Bayes optimizasyon örnek verilebilir. Izgara Arama ve Rastgele Arama yöntemlerine göre Bayes Optimizasyon yöntemi daha az deneme ile daha iyi sonuçlar elde edebilme, yüksek boyutlu verilerde görece daha etkin çalışabilme, kaynakların verimli kullanımı ve daha iyi genelleme yeteneği sağlama gibi özellikleri nedeniyle bu çalışmada tercih edilmiştir.

Bayes optimizasyonu " amaç fonksiyonu ile çalışmaktadır. Bu amaç fonksiyonu modelin performansını ölçerek modelin en iyi sonuca ulaşmasını sağlayan hiperparametre değerlerini bulmayı amaçlamaktadır. Bayes optimizasyonu, hiperparametrelerin muhtemel dağılımları hakkında bir tahmin oluşturan "prior" (öncül) bilgiye sahiptir. Optimize edilecek modelin performansını ölçen bir amaç fonksiyon belirlenir. Fonksiyon, optimize edilmek istenen modelin hata oranı, doğruluk veya başka bir performans metriğini içermektedir. Bayes optimizasyonu bir model kullanarak bu objektif fonksiyonun hiperparametre uzayındaki performans yüzeyini modellemesini özellikle optimumun konumu hakkında mümkün olduğunca fazla bilgi elde etmeyi amaçlamaktadır (Feurer vd., 2015). Bu kullanılan model genellikle Gaussian Process (GP) olabilir. Bayesi optimizasyon hiperparametre uzayında dolaşarak amaç fonksiyonunun maksimumunu araştırır. Modelin prior (çncül) bilgi ve tahminlerini kullanarak model için en iyi hiperparametre değerlerini tahmin eder.

Bayes optimizasyonunun avantajı önceki bilgi ve tahminlere sahip olduğu için akılcı gelecek için en iyi tahmini sağlayacak hiperparametre değerlerini verebilmesidir.

3.2. Makine öğrenim algoritmaları

Bu çalışmada Bayes tekniği ile oldukça başarılı teknikler olan hiperparametre topluluk regresyonu, çekirdek regresyonu, doğrusal regresyon, destek vektör regresyonu ve ikili karar ağacı regresyonu kullanılmıştır.

3.2.1. Topluluk regresyonu

Topluluk Regresyonu, bir regresyon problemini çözmek için birden fazla regresyon modelini bir araya getirilmesi ile daha güçlü bir model oluşturulmasıyla elde edilen teknik olarak adlandırılır. Bu teknik, farklı regresyonları kombinleyerek daha doğru, güçlü, sağlam ve istikrarlı tahminleme performansı elde etmeyi amaçlamaktadır. Bu yöntem, tek bir regresyon modelinin Fzayıf yönlerini güçlendirmek, modelin genel tahmin doğruluğunu artırmak ve veri setindeki verileri karmaşıklığı ve değişkenliğini ele almak için kullanılır (Dietterich, 2000; Kuhn ve Johnson, 2013).

3.2.2. Çekirdek regresyonu

Çekirdek Regresyonunda her bir veri noktasının çevresindeki veri seti ile olan ilişkilerini modellemek ve ifade etmek için bir çekirdek fonksiyonu tanımlanır. Bu fonksiyon her bir veri noktasının diğer noktalara olan etkileşimini genellikle veri noktalarının konumlarına bağlı olarak ağırlıklandırılır. Bu noktaların konumlarının etkileşim mesafesini kontrol eden bir bant genişliği parametresi bulunmaktadır (Shawe-Taylor ve Cristianini, 2004).

Çekirdek regresyonu için temel denklem Eşitlik 3.1'de ifade edilmiştir.

$$\hat{f}(x) = \sum_{i=1}^n w_i \cdot K(x, x_i) \quad (3.1)$$

$f(x)$: tahmin edilen değeri, w_i : ağırlıkları, x_i : veri setindeki noktaları, $K(x, x_i)$: çekirdek fonksiyonunu ifade etmektedir.

Çekirdek fonksiyonu, her bir veri noktasının etrafında bir ağırlıklandırma sağlar. Genellikle, veri setindeki her bir veri noktasının çevresindeki ağırlıklandırılmış değerlerin toplamı alınarak tahmin gerçekleştirilir.

3.2.3. Doğrusal regresyon

Doğrusal Regresyon, bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi modellemek için kullanılan bir istatistiksel analiz yöntemidir (Karaca ve Karacan, 2016). Bir doğru ya da düzlem kullanarak ya da bağımlı değişkenin birinci dereceden bir polinom şeklinde ifade edildiği matematiksel temele dayanmaktadır.

Doğrusal regresyon, değişkenler arasında doğrusal ilişkiler varsa ve bağımsız değişkenlerin değerleri bilindiğinde, bağımlı değişkenin değerini tahmin edilmesinde kullanılan güçlü bir yaklaşımdır. Doğrusal regresyon değişkenler arasında doğrusal ilişkilerin olup olmadığının anlaşılmasında, ya da doğrusal değil ve modelleme gerekiyorsa hangi gelişmiş tekniklere ihtiyaç duyulacağına yönelik bir öngörü sağlayabilir.

İki değişken arasında basit bir doğrusal regresyon modeli için gerekli formül [Eşitlik 3.2](#)'teki gibi ifade edilir.

$$Y = \beta_0 + \beta_1 X + \varepsilon \quad (3.2)$$

ε : hata terimi, Y: bağımlı değişkeni, X: bağımsız değişkenleri, β_0 : sabit bir terim, β_1 : regresyon katsayılarını ifade etmektedir.

3.2.4. Destek vektör regresyonu

Destek Vektör Regresyonu (DVR), Vapnik ve Cortes (1995) tarafından regresyon problemlerini çözmek için istatistiksel öğrenme teorisi alanında ortaya çıkmış destek vektör makineleri algoritması olarak kullanılan bir makine öğrenme tekniği olarak bilinmektedir ([Demir vd., 2018](#)).

DVR temel mimarisinde bir hiper düzlem oluşturur ve veri noktalarını bu hiper düzlemle regresyon tahminleri ve gerçek değerler arasındaki farkı ifade eden marj arasında tutmaya çalışmaktadır. Marj içinde kalan bu veri noktaları modelin oluşturulmasında etkilidir. Epsilon hata toleransı parametresi ile marjın içindeki verilerin ne kadar hata tolere edilebileceği ifade edilir.

DVM temel regresyon fonksiyonu [Eşitlik 3.3](#)'te şöyle ifade edilebilir:

$$f(x) = \sum_{i=1}^n (w_i \cdot \varphi(x_i)) + b \quad (3.3)$$

$f(x)$: tahmin edilen değeri, w_i : ağırlıkları, $\varphi(x_i)$: destek vektörlerini, b : karar sınırının düzleminin ofsetini temsil etmektedir.

3.2.5. İkili karar ağacı regresyonu

Karar ağaçları açıklığı ve basit yapısı sebebiyle dünyada en yaygın kullanılan makine öğrenme algoritmalarındandır ([Wu vd., 2008](#)). Karar ağaçları; sınıflandırma ağaçları, regresyon ağaçları, boyuna ağaçlar ve hayatta kalma ağaçları olarak türleri bulunmaktadır.

Karar ağacında araştırmanın başlangıç noktası olup kök olarak adlandırılır ve veri setindeki tüm örnekler buradan başlar. Bir araştırmayla ilişkili gözlemler dallarla, ögenin hedef değeri düğümlerle hakkındaki çıkarımları yapraklar temsil edilerek bir karar ağacından tahmin modeli olarak yararlanılmaktadır ([Tercan ve Atasever, 2021](#)).

Karar ağacı, her iç düğümde bir karar noktasını ve her yaprak düğümünde bir sınıflandırma sonucunu temsil eder. İç düğümde veri setindeki öznitelik seçimi yapılarak veri setinin sol ve sağ olmak üzere bölünmesi sağlanır. Her veri seti sınıflandırılarak ağacın kökünden yapraklara doğru ilerler ve yaprak düğümlerinde son bulur. İkili karar ağacı regresyonunun temel denklemi [Eşitlik 3.4](#)'da şöyle ifade edilebilir:

$$f(x) = h_1(x, \theta_1) + c_1 \cdot h_2(x, \theta_2) + \dots + c_n h_n(x, \theta_n) \quad (3.4)$$

$f(x)$: ağacın toplam tahmin değeri, $h_i(x, \theta_i)$: iç düğümdeki kararı temsil eden fonksiyon, θ_i : genellikle öznitelik veya eşik değer, c_i : her alt düğümle ilişkili olan ağırlıklandırma faktörü olup yaprak düğümlerde sınıflandırma sonuçlarına denk gelir.

3.3. Makine öğrenim algoritmalarının başarımlarını (performans) metrikleri

Veri seti üzerindeki makine öğrenim algoritmaları kullanılarak tahminler yapılır ve tahminlerin başarımlarının ölçülmesi için performans metrikleri kullanılmaktadır. Bu çalışmada başarımların metrikleri olarak; R^2 (R-Kare), MSE (Karesel Ortalama Hata), MAE (Ortalama Mutlak Hata), RMSE (Karesel Ortalama Hatanın Kökü) ve MARE/MAPE (Ortalama Mutlak Yüzdese Hata) başarımların metrikleri kullanılmıştır. R^2 , MSE, RMSE, MAE ve MARE/MAPE formülleri sırasıyla [\(3.5\)](#), [\(3.6\)](#), [\(3.7\)](#), [\(3.8\)](#) ve [\(3.9\)](#) eşitliklerinde verilmiştir.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.5)$$

$$MSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.6)$$

$$RMSE = \sqrt{MSE} \quad (3.7)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.8)$$

$$MARE/MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{|y_i|} \quad (3.9)$$

Ayrıca taşınmaz değerlemesine ilişkin çalışmalarda model başarımlarının hesaplanması için The International Association of Assessing Officer (IAAO) 2013 tarafından belirlenmiş standartlar bulunmaktadır. Bu metrikler; tahmin edilen değerlerin standart sapmasının gerçek değere oranını temsil eden dağılım katsayısı (COD) ve bir değerlendirme modelinin tahmin ettiği fiyatlar ile gerçek fiyatlar arasındaki farkın yüzdesel olarak ifade edilmesini sağlayan fiyatla ilgili farklılık değeri (PRD) olarak ifade edilebilir. COD değeri [Eşitlik \(3.10\)](#)'de, m değeri [Eşitlik \(3.11\)](#)'te ve PRD değeri [Eşitlik \(3.12\)](#)'de ifade edilmiştir ([IAAO, 2013](#)).

$$COD = \frac{100}{m} \times \left(\frac{\sum_{i=1}^n \left| \frac{y_i}{\hat{y}_i} - m \right|}{n - 1} \right) \quad (3.10)$$

$$m = \text{median}(y_i / \hat{y}_i) \quad (3.11)$$

$$PRD = \frac{\text{mean}(y_i / \hat{y}_i)}{\sum_{i=1}^n y_i / \sum_{i=1}^n \hat{y}_i} \quad (3.12)$$

4. Bulgular

Bulgular; hiper-optimize edilmiş makine öğrenim teknikleri ile modellerin oluşturulması, modelin hiperparametre optimizasyonu (bayes tekniği), model performanslarının başarımları metrikleri ve yakınsama performansları açısından değerlendirilmesi olarak incelenmiştir.

4.1. Hiper-optimize edilmiş makine öğrenim teknikleri ile modellerin oluşturulması

Model eğitiminde kullanılan tüm nümerik özniteliklere min-maks normalizasyonu uygulanmıştır. Bayes optimizasyon tekniği ile hiperparametre optimizasyonu yapılmış tüm regresyon modellerinin

eğitimi ve test aşamaları için; veriler rastlantısal olarak %85 eğitim (385 konut) ve %15 test (68 konut) verisi olarak ayrılmıştır. Tüm regresyon yöntemlerinin hiperparametre optimizasyonu 200 iterasyonda gerçekleştirilmiştir.

Modelde aşırı öğrenmeyi engellemek amacıyla tüm regresyon yöntemlerine katlama sayısı 10 olarak belirlenerek çapraz doğrulama uygulanmıştır.

4.2. Regresyon yöntemlerinin Bayes tekniği ile hiperparametre optimizasyonu

Hiper parametre optimizasyonundaki en önemli süreçlerden biri kullanılan regresyon yöntemlerinin hangi kontrol parametrelerinin optimize edileceğine karar verilmesidir. Bu kapsamda kullanılan tüm modellerin performansına ciddi etkisi olduğu bilinen ayar parametreleri tercih edilmiş ve [Tablo 4](#)'de sunulmuştur.

Tablo 4. Uygulamada kullanılan makine öğrenimi yöntemleri ve bayes tekniği ile optimize edilmiş hiperparametreler.

Makine Öğrenimi Yöntemleri	Bayes Tekniği ile Optimize Edilmiş Hiperparametreler
Topluluk Regresyonu	Yöntem ('LSBoost-zayıf tahmincilerin bir araya getirilerek güçlü bir tahminci oluşturulmasını sağlayan bir topluluk öğrenme yöntemidir-'), Toplu öğrenme döngülerinin sayısı, Öğrenme Oranı, Minimum yaprak boyutu gözlemleri, Maksimal karar bölünme sayısı, Her bölünme için rastgele seçilen tahmincilerin sayısı, Rastgele seçilen değişken sayısı
Çekirdek Regresyonu	Yöntem ('Lsquare-çekirdek ağırlıklarının tahmin etmek için kullanılan en küçük kareler yöntemidir-'), Çekirdek-Ölçek, Çekirdek-Lambda, Genişletme Boyutu Sayısı, Çekirdek-Epsilon
Doğrusal Regresyonu	Yöntem ('Lsquare-çekirdek ağırlıklarının tahmin etmek için kullanılan en küçük kareler yöntemidir-'), Doğrusal-Lambda, Doğrusal-Regularizasyon
Destek Vektör Makineleri Regresyonu	DVM-Kutu Kısıtlaması, Çekirdek Ölçeği, SVM-Epsilon, Çekirdek Fonksiyonu, SVM-Polinom Derecesi, SVM-Standard Boyutu
İkili Karar Ağacı Regresyonu	Yöntem ('LSBoost-zayıf tahmincilerin bir araya getirilerek güçlü bir tahminci oluşturulmasını sağlayan bir karar ağacı öğrenme yöntemidir-'), Her bölünme için minimum yaprak boyutu gözlemleri, Her bölünme için rastgele seçilen tahmincilerin sayısı, Her bölünme için örneklenen değişken sayısı

[Tablo 4](#)'te kullanılan regresyon yöntemlerinde (Topluluk, Çekirdek, Doğrusal, Destek Vektör Makineleri ve İkili Karar Ağacı) kullanılan parametreler ve anlamları ifade edilmiştir. Buna göre kullanılan parametreler ve seçilme nedenleri şöyle ifade edilebilir:

Topluluk Regresyonu için belirtilen parametreler topluluk regresyonu modelinin yapılandırılmasında ve eğitilmesinde kullanılmıştır. LSBoots, öğrenme döngüsü sayısı, öğrenme oranı ve diğer parametreler, modelin performansını ve genel başarısını etkileyen önemli faktörlerdir.

Çekirdek Regresyonu için belirtilen Çekirdek Regresyonu modelini yapılandırmak ve eğitmek için kullanılır. LeastSquares, çekirdek genişliği, regularizasyon katsayısı, genişleme boyutu ve epsilon

gibi parametreler, modelin performansını ve genel başarısını etkileyen önemli faktörlerdir.

Doğrusal Regresyon için belirtilen parametrelerden LeastSquares, regresyon modelini en iyi uygun hale getirmeye çalışırken, Lambda ve Regularization parametreleri, modelin genelleştirmesini ve aşırı uyuma karşı direncini kontrol etmek için kullanılır. Bu parametreler, modelin karmaşıklığı ve performansı arasında bir denge kurulmasına yardımcı olur.

Destek Vektör Makineleri Regresyonu için kullanılan bazı temel parametreler DVM regresyon modelinin şekillendirilmesi ve performansını optimize etmek için kullanılır. İyi bir model oluşturabilmek ve hiperparametreleri doğru bir şekilde seçebilmek için genellikle çapraz doğrulama gibi yöntemler kullanılır.

İkili Karar Ağacı Regresyonu için kullanılan parametreler veri setindeki desenleri öğrenerek tahminler yapar. Bu parametreler, modelin şekillendirilmesi ve genelleme yeteneğini optimize etmek için kullanılır. Çeşitli değer kombinasyonları kullanılarak çapraz doğrulama gibi tekniklerle bu parametrelerin en iyi değerleri bulunabilir.

Bu çalışmada hiper parametre süreci sonrası regresyon yöntemleri için belirlenen optimal parametreler [Tablo 5](#)'de ifade edilmiştir.

Tablo 5. Yöntemler için hesaplanan en iyi parametreler.

Yöntemler	Yöntemler için hesaplanan en iyi parametreler
Topluluk öğrenme	En iyi parametre kombinasyonu: LSBoost Yöntemi Öğrenme Döngü Sayısı: 21 Öğrenme Oranı: 0.31075 Minimum Yaprak Sayısı: 3 Maksimum Bölünme Sayısı: 4
Çekirdek regresyonu	En iyi parametre kombinasyonu: Öğrenici olarak en küçük kareler Çekirdek Ölçeği: 3.3462 Lambda Değeri: 4.4386e-06 Genişletme Boyutu: 5786
Lineer Regresyon	En iyi parametre kombinasyonu: Öğrenici En Küçük Kareler Lambda Değeri: 6.7785e-05 Düzenleştirme Yöntemi: Ridge
Destek Vektör Regresyonu	Kutu Kısıtlama Değeri: 998.59 Epsilon Değeri: 43975 Çekirdek Fonksiyonu olarak Polinom ve Polinom Seviyesi için: 4
İkili Karar ağacı Regresyonu	Minimum Yaprak Boyutu: 14 Maksimum Bölme Sayısı: 15 Örneklenecek Değişken Sayısı: 16 parametre kombinasyonu

4.3. Model Performanslarının Değerlendirilmesi

Çalışmada Bayes Tekniği ile Hiper-Optimize edilmiş Makine Öğrenimi Tekniklerinin tahmin sonuçları güncel piyasa değerleri ile karşılaştırılarak başarımleri değerlendirilmiştir. Bu sonuçlarla birlikte eğitim ve test verilerinin karşılaştırılması [Tablo 6](#) ve [Tablo 7](#)'de ifade edilmiştir.

Çekirdek regresyonu ile model sonucu R2 değeri 1'e en yakın ve MSE, MAE ve MAPE değerleri için 0'a en yakın sonuçları sağlamaktadır. Bu durumda elde edilen eğitim verisi sonuçlarına göre, Bayes Tekniği ile Hiper-Optimize edilmiş Çekirdek Regresyonu en başarılı sonuçları gerçekleştirmiştir. Ayrıca, fiyatla ilgili farklılık değerini ifade eden ve değerlendirme modelinin tahmin fiyatları ile gerçek fiyatları arasındaki fark değişiminin yüzdesel olarak ifade edilmesini sağlayan "PRD değeri" 0,98 ile 1,03 arasında olmalıdır ([IAAO, 2013](#)). Buna göre bütün algoritma sonuçlarının bu değer aralığını sağladığı tespit edilmektedir. Ancak [IAAO \(2013\)](#)'e göre COD değerinin homojen nitelikli konut alanları için bulunduğu bölgelerde %5-%10 arasında olması gerekliliği sağlamamaktadır. Bunun nedeni çalışmada kent ölçeğinde toplu nitelikte bir taşınmaz değerlendirme yapılması ve bölgesel farklılıklardan kaynaklanan veri setindeki heterojenlikten kaynaklanmaktadır. Bu durum

ile ilgili olarak [IAAO 2013](#)'te bölgesel şartlara göre bu değer değişebileceğinden bahsedilmiştir.

Topluluk regresyonu ile model sonucu R2 değeri 1'e en yakın ve MSE, MAE ve MAPE değerleri için 0'a en yakın sonuçları sağlamaktadır. Bu durumda elde edilen test verisi sonuçlarında farklı regresyonlar başarılı olsa da genel olarak bakıldığında, Bayes Tekniği ile Hiper-Optimize edilmiş Topluluk Regresyonu en başarılı sonuçları gerçekleştirmiştir. Ayrıca, fiyatla ilgili farklılık değerini ifade eden ve değerlendirme modelinin tahmin fiyatları ile gerçek fiyatları arasındaki fark değişiminin yüzdesel olarak ifade edilmesini sağlayan "PRD değeri" 0,98 ile 1,03 arasında olmalıdır ([IAAO 2013](#)). Buna göre Topluluk Regresyonu ve Destek Vektör Makineleri algoritma sonuçlarının bu değer aralığını sağladığı tespit edilmektedir. Ancak [IAAO \(2013\)](#)'e göre COD değerinin homojen nitelikli konut alanları için bulunduğu bölgelerde %5-%10 arasında olması gerekliliği sağlamamaktadır. Bunun nedeni çalışmada kent ölçeğinde toplu nitelikte bir taşınmaz değerlendirme yapılması ve bölgesel farklılıklardan kaynaklanan veri setindeki heterojenlikten kaynaklanmaktadır. Bu durum ile ilgili olarak [IAAO 2013](#)'te bölgesel şartlara göre bu değer değişebileceğinden bahsedilmiştir.

Tablo 6. Eğitim verilerinin başarımları metrikleri açısından incelenmesi.

Eğitim	Topluluk Regresyonu	Çekirdek Regresyonu	Doğrusal Regresyonu	DVM Regresyonu	İkili Karar Ağacı Regresyonu
MSE	5.0923e + 10	2.9687e + 10	1.4864e + 11	1.4796e + 11	1.6448e + 11
RMSE	2.2566e + 05	1.7230e + 05	3.8554e + 05	3.8466e + 05	4.0556e + 05
MAE	1.6374e + 05	1.2801e + 05	2.5870e + 05	2.0843e + 05	2.3951e + 05
MARE/MAPE	0.1233	0.1004	0.1919	0.1431	0.1672
R2	0.9021	0.9426	0.7056	0.7351	0.6742
COD	35.6602	37.3398	34.0646	32.2881	38.0355
PRD	0.9996	1.0000	1.0000	0.9553	1.0000

Tablo 7. Test verilerinin başarımları metrikleri açısından incelenmesi.

TEST	Topluluk Regresyonu	Çekirdek Regresyonu	Doğrusal Regresyonu	DVM Regresyonu	İkili Karar Ağacı Regresyonu
MSE	1.2743e + 11	1.6099e + 11	1.1665e + 11	1.6731e + 11	1.6881e + 11
RMSE	3.5698e + 05	4.0124e + 05	3.4155e + 05	4.0904 + 05	4.1086e + 05
MAE	2.2056e + 05	2.7196e + 05	2.4687e + 05	2.4355e + 05	2.5068e + 05
MARE/MAPE	0.1654	0.2196	0.2065	0.1777	0.1961
R2	0.7179	0.6841	0.7503	0.6252	0.6265
COD	35.7938	40.8706	32.4851	31.8641	36.6186
PRD	1.0122	1.0487	1.0455	0.9943	1.0347

Elde edilen sonuçların yakınsama performansları incelenmiştir. Bu değerlendirme, tahmin sonuçlarına ilişkin iterasyonlarına veya güncellemelerine ne kadar hızlı ve verimli bir şekilde ulaştığına ilişkin sonuçları göstermektedir. Başarımları metriklerine (R2, MSE, RMSE ve MAE) ilişkin başarı oranları daha iyi bir yakınsama performansını temsil eder. Bu metrikler, regresyon modelinin ne kadar iyi uyarlandığını ve ne kadar doğru tahminler yaptığını göstermektedir. Elde edilen sonuçların Yakınsama Performanslarının değerlendirilmesi Şekil 3’de gösterilmektedir.

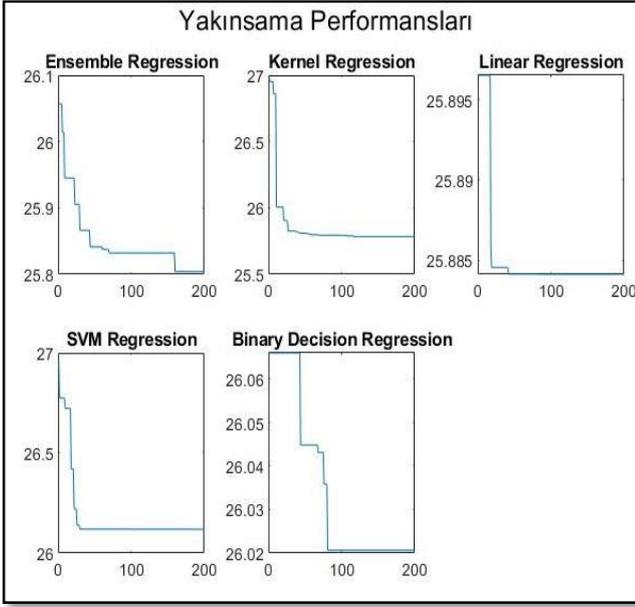
Şekil 3’de gösterilen değerlerde, 1. iterasyondan 200. iterasyona kadar geçen süreçte regresyonların logaritmik ölçekte değişimi sunulmaktadır. Bu logaritmik

değerlerdeki en ufak değişim aslında çok yüksek bir değişimi ifade etmektedir.

Görseldeki regresyon performansları son iterasyona gelindiğinde şöyledir;

- Ensemble Observed $\log(1 + \text{valLoss})$: 25.8041
- Kernel Observed $\log(1 + \text{valLoss})$: 25.7843
- Linear Observed $\log(1 + \text{valLoss})$: 25.8841
- Svm Observed $\log(1 + \text{valLoss})$: 26.1187
- Tree Observed $\log(1 + \text{valLoss})$: 26.0207

Başlangıçtaki logaritmik değere göre en fazla değişime uğrayan regresyon; eğitim verisine göre çekirdek regresyonu olmuştur.



Şekil 3. Yakınsama performansları.

4.4. Model sonuçlarının literatür kapsamında değerlendirilmesi

Model sonuçları literatür kapsamında konut fiyat tahmin modellemesine yönelik hiperparametre değerlerinden bahseden veya hiper-optimize edilmiş makine öğrenimi algoritmalarının kullanımının yer aldığı çalışmalar üzerinden gerçekleştirilmiştir.

Milunovich (2020)'de Avustralya günlük gerçek ev fiyatlarını ve büyüme oranlarını tahmin etmek için 47 farklı algoritmalarından elde edilen tahminleri kombinasyonu gerçekleştirmiştir. Bireysel algoritmaları ve modelleri optimize etmeyi düşünmediler. Model seçim problemi olarak hiperparametrelerin seçilmesi sürecini göstermişler ancak bireysel algoritmaları ve modelleri optimize etmemişlerdir.

Iban 2021'de Melbourne kentinden açık erişimli olarak sağladığı taşınmaz mal veri seti ile toplu yapay öğrenme algoritmaları (Rastgele Orman, Adaboost ve Gradyan Artırma) kullanarak, uygun hiperparametre ve bağımsız değişken seçimleri sağlanarak tahmin modelleri geliştirilmiştir. Rastgele orman ve gradyan artırma algoritmaları ile oluşturulan modellerin tahmin edilen eğitim ve test doğruluklarının %90'ın üzerinde olup Uluslararası Değerlemeciler Derneği'nin belirlenen standartlarına uygun olduğu ancak Adaboost algoritması ile üretilen algoritmanın başarılı olmadığı sonucuna varılmıştır.

Kalliola vd., 2021'de Finlandiya'nın Helsinki kentinde gayrimenkul fiyat tahmini için bir Yapay sinir ağı (YSA) modeli uygulayarak hiper-optimizasyonunu gerçekleştirmiştir. Bayesian optimizasyon algoritması kullanılarak modelin optimizasyonu yapılmış ve daha yüksek doğruluk için YSA mimarisinin hiperparametrelerinin (aktivasyon fonksiyonları, optimizasyon algoritmaları vb.) ayarlanması gerçekleştirilmiştir. Sonuçlar çeşitli metrikler (R2, RMSE, MAE) kullanılarak değerlendirilmiş ve grafiksel olarak gösterilmiştir. Buna göre modelin hiper optimizasyonunun tüm metriklerdeki performansını

iyileştirdiğini ve %8,3'lük göreceli ortalama hataya ulaştığı tespit edilmiştir.

Calainho vd., 2022'de gayrimenkul fiyat endekslerinin oluşturulmasına yönelik tek bir atf Zincirli Paasche (Chained Paasche) yaklaşımı sunmaktadır. Bu çalışmada kullanılan veriler, New York'ta 2000-2019 döneminde 29.998 ticari gayrimenkul işleminden alınan veriler ile oluşmaktadır. Çalışmada gayrimenkulün farklı zaman dilimindeki değerinin belirlenmesinde doğrusal ve doğrusal olmayan modeller kullanılmaktadır. Her zaman dilim (dönem) için hiperparametre ayarlaması, model tahmini ve fiyat tahmini gerçekleştirilir. Bu nedenle her zaman dilimi için her algoritmayı kullanarak tahmin edilen veya eğitilen bir model bulunmaktadır. Sonuçlar, makine öğrenimi algoritmaları modellerinin tahmin doğruluğunun doğrusal modellere göre daha yüksek olduğunu göstermektedir.

Literatürde yapılan çalışmalar incelendiğinde; Kalliola vd., 2021 dışında diğer çalışmaların hiperparametre tekniklerinden ve hiperparametre değerlerinden bahsettiği söylenebilirken hiperparametrelerin optimizasyonuna yönelik bir analiz gerçekleştirildikleri söylenemez. Makine öğrenme modellerinin başarı performansı, hiperparametre değerlerinin belirlenmesinden ve seçilmesinden büyük ölçüde etkilenmektedir (Kim vd., 2020). Bu kapsamda konut fiyat değerini tahmin edilmesine yönelik yapılacak çalışmalarda hiperparametre değerlerinin optimize edilerek tahmin değerlerinin belirlenmesi başarı metriklerinin artırılmasında önem taşımaktadır.

5. Sonuç

Son yıllarda geleneksel tekil değerlendirme yöntemlerinin yanı sıra, Makine Öğrenimi Teknikleri gibi gelişmiş tahmin yaklaşımları da toplu taşınmaz değerlendirme için kullanılmaktadır. Bu çalışma, Bayes Tekniği ile Hiper-Optimize edilmiş Makine Öğrenimi Yöntemlerini kullanarak, toplu taşınmaz değerlendirme süreçlerinde daha etkili ve doğru sonuçlara ulaşmayı amaçlamıştır.

Analizlere göre elde edilen veriler ışığında Çekirdek Regresyonu ile model sonucu R2 değeri 1'e en yakın ve MSE, MAE ve MAPE değerleri için 0'a en yakın sonuçları sağlamaktadır. Bu durumda elde edilen eğitim verisi sonuçlarına göre, Bayes Tekniği ile Hiper-Optimize edilmiş Çekirdek Regresyonu en başarılı sonuçları gerçekleştirmiştir. Topluluk regresyonu ile model sonucu R2 değeri 1'e en yakın ve MSE, MAE ve MAPE değerleri için 0'a en yakın sonuçları sağlamaktadır. Bu durumda elde edilen test verisi sonuçlarında farklı regresyonlar başarılı olsa da genel olarak bakıldığında, Bayes Tekniği ile Hiper-Optimize edilmiş Topluluk Regresyonu en başarılı sonuçları gerçekleştirmiştir.

Çalışmanın küçük ölçekli kentlerde kent bütününde yapıyor olması ve buna yönelik yapılan bu analizler çalışmanın öncelikli farkını ortaya koymaktadır. Çalışmanın öne çıktığı bir diğer nokta ise, taşınmaz değer değişiminin Hiper-Optimize edilmiş Makine Öğrenimi Teknikleri kullanılarak yüksek doğrulukla tahmin edildiği ve bu başarı metriklerinin detaylı bir şekilde analiz edilmesidir.

Bu çalışma;

- Küçük ölçekteki kentlerde bölgesel eşitsizlikleri önlenmesinde,
- Yerel yöneticilerin imarlı arsa ihtiyacının ve yerel halkın imarlı arsa taleplerinin gerçekleştirilmesi ve kentin sürdürülebilir nitelikli mekânsal stratejilerinin ve gelişme planlarının düzenlenmesinde,
- Toplu taşınmaz değerlendirme için kent bütününde bir yaklaşım geliştirilmesinde,
- Kentin taşınmaz değer profilinin belirlenmesinde,
- Mülk sahipleri, yatırımcılar ve gayrimenkul değerlendirme uzmanları için değerlendirme sürecinin bilimsel ve objektif nitelik kazanması ve başarılı değerlendirme tahmini yürütmeleri,
- Kent yöneticilerine imar ve şehircilik yatırımlarında bölgesel eşitsizlikleri önlemeye rehberlik oluşturulmasında,

önemli bilimsel katkılar sunmaktadır.

Bilgilendirme/Teşekkür

Makale, Abdulkaki Hazer'in "Hiper-Optimize Edilmiş Makine Öğrenim Teknikleri İle Taşınmaz Değerlemesi, Yozgat Kenti Örneği" başlıklı tezinden üretilmiştir.

Araştırmacıların katkı oranı

Abdulkaki Hazer: Literatür taraması, modelleme, düzenleme, **Aslı Bozdağ:** Literatür taraması, metot, düzenleme, **Ümit Haluk Atasever:** Modelleme, Makale yazımı, düzenleme.

Çatışma Beyanı

Herhangi bir çıkar çatışması bulunmamaktadır.

Kaynakça

- Alfaro-Navarro, J. L., Cano, E. L., Alfaro-Cortés, E., García, N., Gámez, M., ve Larraz, B., "A fully automated adjustment of ensemble methods in machine learning for modeling complex real estate systems." *Complexity*, 2020, 1-12, 2020.
- Alkan, T. ve Durduran, S. S., "Turizm kentlerinde taşınmaz değerlemenin CBS ve AHP yöntemi yardımıyla incelenmesi: Alanya kenti örneği", *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 10 (1), 178-187, 2023.
- Aydinoğlu, A. Ç., Bovkır, R. ve Çölkesen, İ., "Toplu taşınmaz değerlemede makine öğrenme algoritmalarının kullanımı ve konumsal/konumsal olmayan özniteliklerin tahmin doğruluğuna etkilerinin karşılaştırılması." *Jeodezi ve Jeoinformasyon Dergisi*, 10 (1), 63-83, 2023.
- Baldominos, A., Blanco, I., Moreno, A.J., Iturrarte, R., Bernandez, O. ve Alfonso, C., "Identifying Real Estate Opportunities Using Machine Learning", *Applied Sciences*, 8, 2321, 2018.
- Baur, K., Rosenfelder, M. ve Lutz, B., "Automated real estate valuation with machine learning models using

- property descriptions", *Expert Systems with Applications*, 213, 119147, 2023.
- Bilgilioğlu, S. S., Makine öğrenmesi teknikleri ile mekânsal karar destek sistemlerinin geliştirilmesi: Aksaray ili örneği, Aksaray Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 2018.
- Bozdağ, A. ve Ertunç, E., "CBS ve AHP yöntemi yardımıyla Niğde Kenti örneğinde taşınmaz değerlendirme", *Geomatik*, 5(3), 228-240, 2020.
- Büyük, G., ve Ünel, F. B. Comparison of modern methods using the python programming language in mass housing valuation. *Advanced Land Management*, 1(1), 23-31, 2021.
- Calainho, F. D., Van de Minne, A. M. ve Francke, M. K., "A Machine Learning Approach to Price Indices: Applications in Commercial Real Estate", *The Journal of Real Estate Finance and Economics*, 1-30, 2022.
- Chou, J.S., Fleshman, D.B. ve Truong, DN., "Comparison of machine learning models to provide preliminary forecasts of real estate prices", *J Hous and the Built Environ* 37, 2079-2114, 2022.
- Çolak, E., Memişoğlu, T. ve Nihal, G. E. N. Ç., "Hazine taşınmaz satışlarının emsal satışlarla karşılaştırılması: Trabzon İli örneği", *Geomatik*, 7(2), 163-173, 2022.
- Demir, H., Erdoğmuş, P. ve Kekeçoğlu, M., "Destek Vektör Makineleri, YSA, K- Means ve KNN Kullanarak Arı Türlerinin Sınıflandırılması." *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, Sayı 6, Sayfa 47-67, 2018.
- Dietterich, T. G. (2000, June). Ensemble methods in machine learning. In *International workshop on multiple classifier systems* (pp. 1-15). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Dimopoulos, T. ve Bakas, N., "Sensitivity analysis of machine learning models for the mass appraisal of real estate Case study of residential units in Nicosia, Cyprus", *Remote sensing*, 11(24), 3047, 2019.
- Emeç, Ş., ve Tekin, D., Housing Demand Forecasting with Machine Learning Methods. *Erzincan University Journal of Science and Technology*, 15 (Special Issue I), 36-52, 2022.
- Engindeniz, S., "Tarım arazilerinin kamulaştırılmasında gelir yöntemini uygulama esasları", *Türktarım Dergisi*, 192, 53-57, 2010.
- Esen, Y. ve Tokgöz, H., "Bulanık mantık modellemesi ile taşınmaz değerlemeye farklı bir bakış", *Mühendislik Bilimleri ve Tasarım Dergisi*, 9 (4), 1155-1165, 2021.
- Feurer, M., Springenberg, J., ve Hutter, F., "Initializing bayesian hyperparameter optimization via meta-learning." In *Proceedings of the AAAI Conference on Artificial Intelligence*, Vol. 29, No. 1, 2015.
- Feurer, M., ve Hutter, F., "Automated Machine Learning Methods, Systems", *Challenges Springer Series on Challenges in Machine Learning*, 2019
- Grybauskas, A., Pilinkienė, V. ve Stundžienė, A., "Predictive analytics using Big Data for the real estate market during the COVID-19 pandemic", *Journal of big data*, 8(1), 1- 20, 2021.
- IAAO, Standard on ratio studies. 01.01.2023 tarihinde https://www.iaao.org/media/standards/Standard_on_Ratio_Studies.pdf (30.11.2023 tarihinde erişilmiştir.) 2013.

- Iban, M. C., "Taşınmaz Mal Değeri Kestiriminde Topluluk Algoritmalarının Doğruluk Analizi", 1. Uluslararası Yapay Zeka ve Veri Bilimi Kongresi, S-47, 2021.
- Iban, M. C., "An explainable model for the mass appraisal of residences: The application of tree-based Machine Learning algorithms and interpretation of valuedeterminants", *Habitat International*, 128, 102660, 2022.
- Kaklauskas, A., Zavadskas, E. K., Lepkova, N., Raslanas, S., Dauksys, K., Vetloviene, I. ve Ubarte, I., "Sustainable construction investment, real estate development, and COVID- 19: a review of literature in the field", *Sustainability*, 13(13), 7420, 2021.
- Kalliola, J., Kapočiūtė-Dzikienė, J., ve Damaševičius, R., "Neural network hyperparameter optimization for prediction of real estate prices in Helsinki." *PeerJ computer science*, 7, e444, 2021.
- Karaca, C. ve Karacan, H., "Çoklu Regresyon Metoduyla Elektrik Tüketim Talebini Etkileyen Faktörlerin İncelenmesi", *Selçuk Üniversitesi Mühendislik Fakültesi, Bilim ve Teknoloji Dergisi*, 3, 182-195, 2016.
- Kayalık, M., ve Polat, Z. A., "CBS destekli nominal taşınmaz değer haritasının 3 boyutlu sunumu: Berlin Eyaleti örneği", *Geomatik*, 8(2), 180-191, 2023.
- Kim, H., Kwon, Y., ve Choi, Y., "Assessing the impact of public rental housing on the housing prices in proximity: based on the regional and local level of price prediction models using long short-term memory (LSTM)." *Sustainability*, 12(18), 7520, 2020.
- Kuhn, M., & Johnson, K. (2013). *Applied predictive modeling* (Vol. 26, p. 13). New York: Springer.
- Lee, C., ve Park, K. K. H., Representing uncertainty in property valuation through a bayesian deep learning approach. *Real Estate Management and Valuation*, 28(4), 15-23, 2020.
- Louati H., Bechikh S., Louati A., Hung C-C. ve Said LB., "Deep convolutional neural network architecture design as a bi-level optimization problem", *Neurocomputing*, 2021.
- Milunovich, G., Forecasting Australia's real house price index: A comparison of time series and machine learning methods. *Journal of Forecasting*, 39(7), 1098-1118, 2020.
- Mete, M. O. ve Yomralioglu, T., "Implementation of serverless cloud GIS platform for land valuation", *International Journal of Digital Earth*, 14:7, 836-850, 2021.
- Mora-Garcia, R.T.; Marti-Ciriquian, P.; Perez-Sanchez, R. ve Cespedes-Lopez M.F. "A comparative analysis of manhattan, euclidean and network distances. Why are network distances more useful to urban professionals?", In *Proceedings of the 18th International Multidisciplinary Scientific Geoconference SGEM 30 June–9 July 2018*, 3–10, 2018.
- Mora-Garcia, R. T., Cespedes-Lopez, M. F. ve Perez-Sanchez, V. R. "Housing Price Prediction Using Machine Learning Algorithms in COVID-19 Times", *Land*, 11(11), 2100, 2022.
- Ngoc, N. M., Tien, N. H. ve Anh, D. B. H., "Opportunities and challenges for real estate brokers in post Covid-19 period", *Journal of Science and Technology*, 170(10), 203- 208, 2020.
- Özsubaşı, B. ve Ertaş, M. The spatial evaluation of the real estates in the Konya-Hacıyakmak Neighborhood with the analytical hierarchy process method. *Advanced Land Management*, 2(2), 51-59, 2022.
- Park, B. ve Bae, J.K., "Using machine learning algorithms for housing price prediction: The case of Fairfax County", *Virginia housing data. Expert Syst. Appl.*, 42, 2928-2934, 2014.
- Ravikumar, AS., "Real estate price prediction using machine learning, MSc research Project", School of computing national college of Ireland, 2017.
- Savaş B., Makine öğrenme algoritmalarının konut değer tahmininde kullanımı: Ankara Gölbaşı uygulaması, Konya Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, 2019.
- Sevinç, A., Firma Değerini Etkileyen Unsurlar ve Nakit Akışı Metoduna İlişkin Bir Uygulama, Kadir Has Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, İstanbul, 2008.
- Shawe-Taylor, J., & Cristianini, N. (2004). *Kernel methods for pattern analysis*. Cambridge university press.
- Steurer, M., Hill, R. J., ve Pfeifer, N., "Machine Learning Prediction Models: An Application to the Housing Market" *Graz Economic Papers*, 2020.
- Tabar, M. E., Başara, A. C., ve Şişman, Y., "Çoklu Regresyon ve Yapay Sinir Ağları ile Tokat İlinde Konut Değerleme Çalışması" *Türkiye Arazi Yönetimi Dergisi*, 3(1), 1-7, 2021.
- Tabar, M. E., ve Şişman, Y., "Bulanık mantık ile arsa değerlendirme modelinin oluşturulması", *Türkiye Arazi Yönetimi Dergisi*, 2(1), 18-24, 2020.
- Tercan, E., ve Atasever, Ü. H., "Effectiveness of autoencoder for lake area extraction from high-resolution RGB imagery: an experimental study." *Environmental Science and Pollution Research*, 28(24), 31084–31096, 2021.
- Tunca, E., ve Üstüntaş, T., "Gayrimenkul değerlendirme modelinin oluşturulmasında çok kriterli karar verme yöntemlerinin kullanılması", *TMMOB*, 6, 23-25, 2019.
- Türkan, M., Bozdağ, A., Karkınlı, 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.
- Ulucan, A. G., (2023). "Taşınmaz Değer Piyasası Üzerinde Pandeminin Etkilerinin Analizi, Niğde Kenti", *Yüksek Lisans Tezi, Niğde Ömer Halisdemir Üniversitesi*, 2023.
- Ulvi, C. ve Özkan, G., "Applicability of artificial intelligence techniques in real estate valuation and the comparison of methods", *J Geomatic*, 4(2), 134–140, 2019.
- Ünel, F. B., ve Yalpir, S. Reduction of mass appraisal criteria with principal component analysis and integration to GIS. *International journal of engineering and geosciences*, 4(3), 94-105, 2019.
- Vapnik, V. ve Cortes, C., "Support- Vector Networks." *Machine Learning*, Volume 20, pp. 273-297, 1995.
- Yağmahan, G., "Puanlama yöntemiyle taşınmaz değerlerinin belirlenmesi ve yaşam kalitesiyle ilişkisinin araştırılması", *Yüksek Lisans Tezi, Yıldız*

- Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2019.
- Yalpir, Ş., ve Ünel, F. B. Multivariate statistical analysis application to determine factors affecting the parcel value to be used mass real estate valuation approaches. *International Journal of Engineering and Geosciences*, 7(1), 32-42, 2022.
- Yu, Y., Lu, J., Shen, D., ve Chen, B., "Research on real estate pricing methods based on data mining and machine learning". *Neural Computing and Applications*, 33, 3925-3937, 2021
- Zulkifley, N. H., Rahman, S. A., Ubaidullah, N. H. ve İbrahim, İ. " House Price Prediction using a Machine Learning Model: A Survey of Literature", *International Journal of Modern Education and Computer Science(IJMECS)*, 12(6), 46-54, 2020.
- Wu, X., Kumar, V., Quinlan, J. R., Ghosh, J., Yang, Q., Motoda, H., Mclachlan, G. J., Ng, A., Liu, B., Yu, P. S., Zhou, Z., Steinbach, M., Hand, D. J., ve Steinberg, D., "Top 10 algorithms in data mining." *Knowledge and Information Systems*, 14(1), 1-37, 2008.

