



T.C.

NİĞDE ÖMER HALİSDEMİR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

HİPER-OPTİMİZE EDİLMİŞ MAKİNE ÖĞRENİM TEKNİKLERİ İLE
TAŞINMAZ DEĞERLEMESİ, YOZGAT KENTİ ÖRNEĞİ

ABDULBAKİ HAZER

OCAK 2024

T.C.
NİĞDE ÖMER HALİSDEMİR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

HİPER-OPTİMİZE EDİLMİŞ MAKİNE ÖĞRENİM TEKNİKLERİ İLE
TAŞINMAZ DEĞERLEMESİ, YOZGAT KENTİ ÖRNEĞİ

ABDULBAKİ HAZER

Yüksek Lisans Tezi

Danışman

Doç. Dr. Aslı BOZDAĞ

OCAK 2024

Abdulkaki HAZER tarafından **Doç. Dr. Aslı BOZDAĞ** danışmanlığında hazırlanan **“Hiper-Optimize Edilmiş Makine Öğrenim Teknikleri ile Taşınmaz Değerlemesi, Yozgat Kenti Örneği”** adlı bu çalışma jürimiz tarafından Niğde Ömer Halisdemir Üniversitesi Fen Bilimleri Enstitüsü **Harita Mühendisliği** Ana Bilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

Başkan : Doç. Dr. Aslı BOZDAĞ

Niğde Ömer Halisdemir Üniversitesi

2. Tez

Danışmanı : Doç. Dr. Ümit Haluk ATASEVER
Erciyes Üniversitesi

Üye : Dr. Öğr. Üyesi Fatma BÜNYAN ÜNEL
Mersin Üniversitesi

Üye : Dr. Öğr. Üyesi Münevver Gizem GÜMÜŞ
Niğde Ömer Halisdemir Üniversitesi

Üye : Dr. Öğr. Üyesi Ahmet Emin KARKINLI
Niğde Ömer Halisdemir Üniversitesi

ONAY:

Bu tez, Fen Bilimleri Enstitüsü Yönetim Kurulunca belirlenmiş olan yukarıdaki jüri üyeleri tarafından/....../20.... tarihinde uygun görülmüş ve Enstitü Yönetim Kurulu’nun/....../20.... tarih ve sayılı kararıyla kabul edilmiştir.

...../...../20...

Prof. Dr. Mustafa KARATEPE
MÜDÜR

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin bilimsel ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

Abdulkali HAZER

ÖZET

HİPER-OPTİMİZE EDİLMİŞ MAKİNE ÖĞRENİM TEKNİKLERİ İLE TAŞINMAZ DEĞERLEMESİ, YOZGAT KENTİ ÖRNEĞİ

HAZER, Abdulbaki
Niğde Ömer Halisdemir Üniversitesi
Fen Bilimleri Enstitüsü
Harita Mühendisliği Ana Bilim Dalı

Danışman : Doç. Dr. Aslı BOZDAĞ

Ocak 2024, 83 sayfa

Toplu Taşınmaz Değerlemede (TTD), Makine Öğrenim Teknikleriyle gelişmiş tahmin yöntemlerinden yararlanılarak bilimsel, doğru ve hızlı sonuçlar elde edilmektedir. Makine Öğrenimi, Coğrafi Bilgi Sistemi (CBS) ortamında düzenlenen verilerin analiz edilerek konut fiyat değerini tahmin etmede doğru karar vermeyi sağlamaktadır. Bu çalışmanın amacı; küçük ölçekli kentler sınıfındaki Yozgat kentinde Bayes Tekniği ile Hiper-Optimize Edilmiş Makine Öğrenimi Teknikleri sayesinde değer tahminleri oluşturmaktır. Bu kapsamda regresyon yöntemleri ile 2022 ve 2023 yıllarına ait taşınmaz verileri üzerinde toplu taşınmaz değerlendirme gerçekleştirilmiştir. Uygulamada eğitim verisi sonuçlarına göre Çekirdek regresyonu, test verisi sonuçlarına göre ise Topluluk regresyonu en başarılı sonuçları sağlamıştır. Çalışma, kentin bütününde bir toplu değerlendirme yapılması ve büyük bir değerlendirme sahası içinde bölgesel eşitsizliklere rağmen konut fiyat tahmin doğruluğunun metriklerle göre başarılı sonuçlar elde etmesiyle literatürden farklılaşmaktadır. Elde edilen sonuçlar, heterojen özellikler taşıyan bir değerlendirme alanı için çalışmanın konut fiyat tahmin sonuçlarının belirlenmesinde başarılı bir yaklaşım olduğunu göstermektedir.

Anahtar Sözcükler: TTD, Değerleme Yöntemleri ve Kriterleri, CBS, Makine Öğrenimi Teknikleri, Hiperparametre Optimizasyonu, Bayes Tekniği

SUMMARY

REAL ESTATE VALUATION WITH HYPER-OPTIMIZED MACHINE LEARNING TECHNIQUES, YOZGAT CITY EXAMPLE

HAZER, Abdulbaki

Nigde Omer Halisdemir University

Graduate School of Natural and Applied Sciences

Department of Geomatics Engineering

Supervisor : Assoc. Prof. Aslı BOZDAĞ

January 2024, 83 pages

Scientific, accurate and fast results are obtained by utilising advanced estimation methods with Machine Learning Techniques in Mass Real Estate Valuation (MRV). Machine Learning provides the right decision making in estimating the house price value by analysing the data arranged in the Geographical Information System (GIS) environment. The aim of this study is to create value estimates in Yozgat city, which is classified as small-scale cities, by using Bayesian Technique and Hyper-Optimised Machine Learning Techniques. In this context, collective real estate valuation was carried out on real estate data for the years 2022 and 2023 with regression methods. In the application, the Core regression provided the most successful results according to the training data results and the Ensemble regression provided the most successful results according to the test data results. The study differs from the literature by performing a collective valuation in the whole city and obtaining successful results in terms of house price prediction accuracy according to metrics despite regional disparities in a large valuation area. The results obtained show that the study is a successful approach in determining house price prediction results for a valuation area with heterogeneous characteristics.

Keywords: MRV, Valuation Methods and Criteria, Machine Learning Techniques, Hyperparameter Optimisation, Bayesian Technique

ÖN SÖZ

Bu tez çalışmasının tamamlanmasında bana destek olan herkese şükranlarımı sunuyorum. Başta aileme ve danışman hocam Doç. Dr. Aslı BOZDAĞ'a sonsuz teşekkürlerimi sunuyorum. Çalışmalarımı gerçekleştirdiğim zamanlarda birçok konuda yardımları olan yüksek lisans dönem arkadaşım Adile Gülsüm ULUCAN'a ve çok kıymetli eş danışmanım Doç. Dr. Ümit Haluk ATASEVER hocamıza da desteklerinden ötürü teşekkürü bir borç bilirim.



İÇİNDEKİLER

ÖZET	iv
SUMMARY	v
ÖN SÖZ	vi
İÇİNDEKİLER	vii
ÇİZELGELER DİZİNİ.....	ix
ŞEKİLLER DİZİNİ.....	x
SİMGE VE KISALTMALAR	xi
BÖLÜM I.....	1
GİRİŞ	1
1.1 Çalışmanın Amacı.....	4
1.2 Çalışmanın Kapsamı	5
1.3 Metodoloji.....	6
1.4 Literatür Özeti	8
BÖLÜM II.....	13
TAŞINMAZ DEĞERLEME VE YÖNETİMİ.....	13
2.1 Kavramlar	13
2.2 Taşınmaz Değerlemesinin Haritacılık Sektöründeki Önemi	14
2.3 Taşınmaz Değerlemeye Etki Eden Kriterler	15
2.4 Taşınmaz Değerleme Sürecinde Yasal Altyapı ve Mevzuat	16
2.4.1 Taşınmaz değerlendirme sürecinde ulusal ve uluslararası standartlar.....	17
BÖLÜM III	20
TAŞINMAZ DEĞERLEME SÜRECİNDE UYGULANAN YÖNTEMLER	20
3.1 Taşınmaz Değerlemede Geleneksel Yöntemler	22
3.1.1 Emsal yöntemi.....	23
3.1.2 Gelir yöntemi.....	23
3.1.3 Maliyet yöntemi	23
3.1.4 İskontolu nakit akış yöntemi.....	24
3.2 Taşınmaz Değerlemede İstatistiksel Yöntemler.....	24
3.2.1 Nominal değerlendirme yöntemi	24
3.2.2 Çoklu regresyon analizi yöntemi (ÇLR)	25

3.2.3 Hedonik model yöntemi	25
3.3 Taşınmaz Değerlemede Çok Kriterli Karar Verme Yöntemleri	25
3.4 Coğrafi Bilgi Sistemleri	28
3.4.1 Taşınmaz değerlemede mekânsal analiz süreci	28
3.4.2 Buffer ve near analizleri	30
3.5 Taşınmaz Değerlemesinde Makine Öğrenimi Yöntemleri	31
3.5.1 Hiper-optimize edilmiş makine öğrenimi	32
3.5.2 Hiperparametre optimizasyonunda bayes tekniği	33
3.6 Makine Öğrenim Algoritmaları	34
3.6.1 Topluluk regresyonu	34
3.6.2 Çekirdek regresyonu	35
3.6.3 Doğrusal regresyon	36
3.6.4 Destek vektör makineleri regresyonu	36
3.6.5 İkili karar ağacı regresyonu	37
3.7 Makine Öğrenim Algoritmalarının Başarım (Performans) Metrikleri	38
BÖLÜM IV	40
KÜÇÜK ÖLÇEKLİ KENTLERDE TOPLU TAŞINMAZ DEĞERLEME, YOZGAT KENTİ ÖRNEĞİ ÜZERİNDE ANALİZİ	40
4.1 Uygulama Sahasının Belirlenmesi ve Tanıtılması	41
4.2 Uygulama Sahasına Yönelik Taşınmaz Değerleme Kriterlerinin Belirlenmesi	43
4.3 Toplu Taşınmaz Değerleme için Veri Toplama Süreci	44
4.3.1 Yapısal özelliklere yönelik veri setinin oluşturulması	44
4.3.2 Konumsal özelliklere yönelik veri setinin oluşturulması	45
4.4 Toplu Taşınmaz Değerlemede Hiper-Optimize Edilmiş Makine Öğrenim Teknikleri ile Modellerin Oluşturulması	56
4.4.1 Modelin hiperparametre optimizasyonu (Bayes tekniği)	57
4.4.2 Model performanslarının değerlendirilmesi	63
4.5 Model Sonuçlarının Literatür Kapsamında Değerlendirilmesi	67
BÖLÜM V	70
SONUÇLAR	70
KAYNAKLAR	72
ÖZ GEÇMİŞ	83

ÇİZELGELER DİZİNİ

Çizelge 1.1. Regresyon yöntemleri ve başarımlar metrikleri.....	3
Çizelge 1.2. Çalışmanın metodolojisi	7
Çizelge 1.3. Literatürdeki modern yöntemlerin kullanılmasına yönelik çalışmalar	8
Çizelge 2.1. Taşınmaz değerlendirme mevzuatı hakkında genel bilgiler	17
Çizelge 3.1. Taşınmaz değerlendirme yöntemleri.....	22
Çizelge 4.1. Çalışmada kullanılan ve değerlendirmeye etki eden kriterler	43
Çizelge 4.2. 2022 ve 2023 yıllarına ait yapısal veriler (600 konuttan 20 tanesi).....	45
Çizelge 4.3. 2022 ve 2023 yıllarına ait konumsal veriler (600 konuttan 20 tanesi).	46
Çizelge 4.4. Uygulamada kullanılan makine öğrenimi yöntemleri ve bayes tekniği ile optimize edilmiş hiperparametreler	59
Çizelge 4.5. Eğitim verilerinin başarımlar metrikleri açısından incelenmesi	64
Çizelge 4.6. Test verilerinin başarımlar metrikleri açısından incelenmesi	65

ŞEKİLLER DİZİNİ

Şekil 3.1. CBS’de vektör ve raster veri modelleri	30
Şekil 4.1. Türkiye haritasında Yozgat kentinin lokasyonu	42
Şekil 4.2. Web sitesi üzerinden yapısal özellikleri belirlenmiş taşınmazın konumu	47
Şekil 4.3. Yozgat kent merkezi sayısallaştırılmış haritası.....	48
Şekil 4.4. Ağaçlandırma alanlarına olan uzaklıkların gösterimi.....	49
Şekil 4.5. Eğitim alanlarına olan uzaklıkların gösterimi.....	50
Şekil 4.6. Resmî kurum alanlarına olan uzaklıkların gösterimi.....	51
Şekil 4.7. Sağlık alanlarına olan uzaklıkların gösterimi	52
Şekil 4.8. Sosyo-Kültürel alanlara olan uzaklıkların gösterimi	53
Şekil 4.9. Ticaret alanlarına olan uzaklıkların gösterimi	54
Şekil 4.10. Hızlı tren garı alanına olan uzaklıkların gösterimi	55
Şekil 4.11. Yakınsama performansları	66

SİMGE VE KISALTMALAR

Simgeler	Açıklama
CR	Tutarlılık oranı
CI	Tutarlılık indeksi
RI	Ortalama rassal tutarlılık
w_i	Ağırlıklandırma faktörü
θ_i	Eşik değeri
$\hat{f}(x)$	Tahmin değeri
x_i	Veri setindeki noktalar
ε	Hata terimi (epsilon)
Y	Bağımlı değişken
X	Bağımsız değişken
β_0	Sabit terim
β_i	Regresyon katsayıları
$\varphi(x_i)$	Destek vektörleri
b	Karar sınırının düzleminin ofsetini
c_i	Her alt düğümle ilişkili olan ağırlıklandırma faktörü
$h_i(x, \theta_i)$	İç düğümdeki kararı temsil eden fonksiyon

Kısaltmalar	Açıklama
AHP	Analytic Hierarchy Process
ASA	American Society of Appraisers
AVM	Automated Valuation Models
CAD	Computer Aided Design
CAMA	Computer Assisted Mass Appraisal
CBS	Coğrafi Bilgi Sistemleri
CNN	Convolutional Neural Networks
COD	Coefficient of Dispersion
ÇKKV	Çok Kriterli Karar Verme

ÇLR	Çoklu Regresyon
DVM	Destek Vektör Makineleri
GIS	Geography Information System
GPs	Gaussian Processes
IAAO	The International Association of Assessing Officer
IVS	International Valuation Standards
IVSC	International Valuation Standards Council
KAKS	Kat Alanı Katsayısı
LSTM	Long Short-Term Memory
MARE/MAPE	Mean Absolute Percentage Error
MAE	Mean Absolute Error
MOORA	Multi-Objective Optimization on the basis of Ratio Analysis
MSE	Mean Squared Error
PRD	Price-Related Difference Value
R ²	R-Square
RICS	Royal Institute of Chartered Surveyors
RMSE	Root Mean Square Error
RNN	Recurrent Neural Networks
SPK	Sermaye Piyasası Kurulu/Kanunu
SVM	Support Vector Machines
TAKS	Taban Alanı Katsayısı
TDUB	Türkiye Değerleme Uzmanları Rehberi
TDS	Türkiye Değerleme Sistemi
TEGoVA	The European Group of Valuers' Associations
TDK	Türk Dil Kurumu
TOPSIS	Technique for Order of Preference by Similarity to Ideal Solution
TSPB	Türkiye Sermaye Piyasaları Birliği
URL	Uniform Resource Locator
VIKOR	VİseKriterijumska Optimizacija I Kompromisno Resenje
YSA	Yapay Sinir Ağları
WEB	World Wide Web

BÖLÜM I

GİRİŞ

Taşınmaz kavramı, arazi, bina, arsa, ev, bağ ve bahçe gibi çeşitli öğeleri içeren geniş bir kapsama sahiptir. Bu kavramlar sadece konut ihtiyacını karşılamakla kalmayıp aynı zamanda günümüzde önemli bir yatırım aracı olarak da değerlendirilmektedir. Taşınmaz değerlendirilmesi, 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, (Geleneksel, İstatistik, CBS, Modern) Çok Kriterli Karar Verme Analizi (ÇKKV) ve Makine Öğrenimi gibi literatürde yer alan çeşitli tekil ve toplu değerlendirme niteliğinde olan yaklaşımları içermektedir. Literatürde, geleneksel yöntemlerde; emsal yöntemi, gelir yöntemi, maliyet yöntemi ve iskontolu nakit akış yöntemine yönelik çalışmalar bulunmaktadır (Sevinç 2008, Engindeniz 2010; Çolak vd. 2022). İstatistiksel analiz yöntemleri kapsamında hedonik modelleme, çoklu regresyon analizleri ve puanlama metodolojilerine ilişkin çalışmalar yer almaktadır (Tabar vd., 2021; Kayalık ve Polat 2023). Ayrıca taşınmazlara ait sayısal verilerin değerlendirilmesi aşamasında parametreler arasında ağırlıklandırma yaparak taşınmazlar arasındaki değer farklılıklarını objektif bir şekilde ortaya koyan ÇKKV kapsamında çalışmalar bulunmaktadır (Tunca ve Üstüntaş 2019, Yağmahan, 2019; Uşak, 2019).

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; Bilgilioglu, 2018; Savaş, 2019; Ulvi ve Özkan, 2019; Zulkifley vd., 2020; Louati vd., 2021). Bu çalışmalar, farklı makine öğrenimi algoritmaları ile taşınmaz değer tahmininde bulunarak başarımleri metriklerini karşılaştırmıştır. Son yıllarda algoritma sonuçlarının başarısının artırması için hiperparametre uyumlandırılmasına ilişkin çalışmalar yapılmaktadır (Feurer ve Hutter, 2019; Kim vd., 2020; Kalliola vd., 2021; Iban, 2022). Modelin eğitildiği hiper-parametreler ayarlanarak ya da uyumlandırılarak yapay öğrenme algoritmalarının doğruluğunun artırması sağlanabilir (Iban, 2022).

Hiperparametre optimizasyonu veya ayarlaması, bir makine öğrenme sistemi için uygun hiperparametre koleksiyonunu seçme zorluğunu ifade eder. Bir hiperparametre, öğrenme sürecini düzenlemek için atanan bir değerdir. Diğer parametrelerin değerleri genellikle öğrenilir (çoğunlukla düğüm ağırlıkları) ve aynı türdeki bir makine öğrenme modelinin farklı kısıtlamalara, ağırlıklara veya öğrenme oranlarına ihtiyaç duyabileceği farklı veri modellerini genelleştirmek için uygulanır. Hiperparametre optimizasyonu, sağlanan bağımsız veriler üzerinde belirlenmiş bir kayıp fonksiyonunu en aza indiren optimum bir modelle sonuçlanan hiperparametre grubunu tanımlar. Hedef fonksiyon, bir hiperparametre grubunu kabul eder ve her biriyle ilişkilendirilen kaybı döndürür (Feurer, vd., 2015). Hiperparametreler olarak bilinen bu özellikler, modelin makine öğrenimi görevini en iyi şekilde çözerken ayarlanmalıdır. Hiperparametre optimizasyonu, doğru bir şekilde uygulandığında, makine öğrenimi modellerinin performansını artırır.

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 makineleri 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 başarımleri ise Çizelge 1.1’de şöyledir;

Çizelge 1.1. Regresyon yöntemleri ve başarımleri

<u>Regresyon Yöntemleri</u>	<u>Eğitim-Test Başarımleri</u>
Topluluk Regresyon(Ensemble Regression)	MSE (Ortalama Kare Hatası)
Çekirdek Regresyonu(Kernel Regression)	RMSE (Kök Ortalama Kare Hatası)
Doğrusal Regresyon(Linear Regression)	MAE (Ortalama Mutlak Hata)
Destek Vektör Regresyonu (SVM Regression)	MARE/MAPE (Ortalama Kare Hatası) R^2 (Korelasyonun karesi)
İkili Karar Ağacı Regresyonu (Binary Decision Tree Regression)	COD (Dağılım Katsayısı) PRD (Fiyat Farklılık Değeri)

Bayes Tekniği ile Hiper-Optimize Edilmiş Makine Öğrenimi Teknikleri sonuçları güncel piyasa değerleri ile karşılaştırılarak bu yöntemlerin eğitim verisi için başarımleri; Topluluk Regresyonu (MSE:5.0923e+10, RMSE:2.2566e+05, MAE:1.6374e+05, MARE/MAPE:0.1233, R^2 :0.9021, COD:35.6602, PRD:0.9996), Çekirdek Regresyonu (MSE:2.9687e+10, RMSE:1.7230e+05, MAE:1.2801e+05, MARE/MAPE:0.1004, R^2 :0.9426, COD:37.3398, PRD:1.0000), Doğrusal Regresyon (MSE:1.4864e+11, RMSE:3.8554e+05, MAE:2.5870e+05, MARE/MAPE:0.1919, R^2 :0.7056, COD:34.0646, PRD:1.0000), Destek Vektör Regresyonu (MSE:1.4796e+11, RMSE:3.8466e+05, MAE:2.0843e+05, MARE/MAPE:0.1431, R^2 :0.7351, COD:32.2881, PRD:0.9553) ve İkili Karar Regresyonu (MSE:1.6448e+11, RMSE:4.0556e+05, MAE:2.3951e+05, MARE/MAPE:0.1672, R^2 :0.6742, COD:38.0355, PRD:1.0000) olarak hesaplanmıştır.

Bu yöntemlerin test verisi için başarımleri; Topluluk Regresyonu (MSE:1.2743e+11, RMSE:3.5698e+05, MAE:2.2056e+05, MARE/MAPE:0.1654, R^2 :0.7179, COD:35.7938, PRD:1.0122), Çekirdek Regresyonu (MSE:1.6099e+11,

RMSE:4.0124e+05, MAE:2.7196e+05, MARE/MAPE:0.2196, R2:0.6841, COD:40.8706, PRD:1.0487), Doğrusal Regresyon (MSE:1.1665e+11, RMSE:3.4155e+05, MAE:2.4687e+05, MARE/MAPE:0.2065, R2:0.7503, COD:32.4851, PRD:1.0455), Destek Vektör Regresyonu (MSE:1.6731e+11, RMSE:4.0904e+05, MAE:2.4355e+05, MARE/MAPE:0.1777, R2:0.6252, COD:31.8641, PRD:0.9943) ve İkili Karar Ağacı Regresyonu (MSE:1.6881e+11, RMSE:4.1086e+05, MAE:2.5068e+05, MARE/MAPE:0.1961, R2:0.6265, COD:36.6186, PRD:1.0347) olarak hesaplanmıştır.

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 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 Çalışmanın Amacı

Taşınmazlar kentsel alanda farklı terimlerle ifade edildikleri gibi değerlendirme süreçleri ve yöntemleri de bu açıdan değişkenlik göstermektedir. Literatürde geleneksel, istatistiksel, çok kriterli karar analizleri ile modern yöntemler sıklıkla uygulanan yöntemler olarak öne çıkmaktadır.

Günümüzde Makine Öğrenimi yöntemleri taşınmaz değerlendirme gerçekleştirmek için çok sayıda taşınmaza dair yapısal ve konumsal özellikleri analiz ederek ilişkilendirmekte ve taşınmazlara ilişkin değer tahminleri yapabilmektedir. Algoritmaların tahmin sonuçları

başarım metrikleri ile karşılaştırılması doğrultusunda elde edilen sonuçların başarısı tartışılmaktadır. Son yıllarda bu başarının artırılması ve iyileştirilmesine yönelik yeni yaklaşımlar yer almaktadır. Bu yaklaşımlardan biri olan Bayes Tekniği ile Hiper-Optimize edilmiş Makine Öğrenimi Teknikleri değerlendirme süreçlerinde elde edilen değer tahminlerinin iyileştirilmesinde kullanılmaktadır.

Bu tez çalışmasında, Türkiye'nin Yozgat kentinde değer değişimini etkileyen kriterlere yönelik CBS ile mekânsal analizlerden ve Makine Öğrenim Tekniklerinden yararlanarak regresyon analizlerinin hiperparametre optimizasyonu ile doğruluğu yüksek tahmin sonuçlarının ve başarım metriklerinin elde edilmesi amaçlanmıştır.

Çalışmanın hedefleri;

- Yapısal ve konumsal özelliklere dair parametreleri belirlemek amacıyla, internet üzerinden uygun gayrimenkul satış sitelerinden ilgili materyallerin toplanması ile CBS ortamında veri tabanı oluşturulması,
- Kentin mevcut çalışmalardan farklı olarak bir bütün halinde incelenerek taşınmaz değerlendirme sürecinde bölgesel mekânsal analizinin yapılması,
- Taşınmaz değer değişiminin yüksek doğrulukla tahmin edilmesine yönelik Hiper-Optimize edilmiş Makine Öğrenimi Tekniklerinin kullanılarak başarım metriklerinin analiz edilmesi ve
- Çalışmanın küçük ölçekteki kentlerde bölgesel eşitsizliklerin önlenmesinde toplu taşınmaz değerlemesi için bir yaklaşım olarak önerilebilmesi,

Şeklinde ifade edilmektedir.

1.2 Çalışmanın Kapsamı

Bu tez çalışmasının kapsamı, Makine Öğrenimi Teknikleri ile hiperparametre optimizasyon yöntemi üzerine odaklanarak oluşturulacak modelin taşınmaz değerlendirme sürecindeki performansını değerlendirmek ve küçük ölçekli kentlerde toplu taşınmaz değerlendirme gerçekleştirebilmektir.

Bu tez çalışması, dört bölümden oluşmaktadır. Bu bölümler;

Tezin ilk bölümünde, tezin amacı, kapsamı ve çalışmanın literatürden olan farklılığı yer almaktadır. Literatür özeti kısmında genel olarak literatür çerçevesi ele alınmış ve bu doğrultuda çalışmanın literatüre olan katkıları irdelenmiştir. Ayrıca çalışmanın metodolojisi Çizelge 1.2 ile şematik olarak gösterilmiştir.

İkinci bölümde, toplu taşınmaz değerlendirme ve yönetimi konusunda, değerlemenin teorik altyapısı kavramsal ve hukuksal boyutlarıyla detaylı bir şekilde ele alınmıştır.

Üçüncü bölümde, taşınmaz değerlemede kullanılan yöntemler; geleneksel, istatistiksel, çok kriterli karar verme, CBS ve makine öğrenimi olmak üzere dört ana başlık altında ele alınmış; özellikle makine öğrenimi yöntemleri ve başarımleri detaylı bir şekilde sunulmuştur.


Dördüncü bölümde ise çalışmanın hedefleri doğrultusunda, toplu taşınmaz değerlendirme alanında CBS destekli Makine Öğrenimi Teknikleri (Topluluk Regresyonu, Çekirdek Regresyonu, Doğrusal Regresyon, Destek Vektör Makineleri Regresyonu, İkili Karar Ağacı Regresyonu) yer almaktadır. Bunların hiperparametre optimizasyonu tekniklerinden *Bayes Optimizasyonu kullanılarak* model oluşturulması, eğitimi ve testi gerçekleştirilmiştir. Başarımleriyle kapsamlı bir değerlendirme yapılarak elde edilen sonuçlar karşılaştırılmış ve mevcut literatür ile kıyaslanmıştır.

1.3 Metodoloji

Çalışmanın metodolojisi şematik olarak Çizelge 1.2’de özetlenmiştir. Buna göre;

- Araştırma süreci; uygulama araçları ve kullanılan yöntem olarak giriş bölümünde,
- Veri setleri; uygulama sahasının belirlenmesi, konumsal ve konumsal olmayan veri setlerinin oluşturulması ve mekânsal analizi materyal oluşturma bölümünde,
- Değer tahminleri ve başarımleri; yöntem, uygulama ve yorumlama olarak modelleme ve bulgular bölümünde,
- Uygulamadan elde edilen katkı ise sonuç bölümünde olmak üzere ifade edilmektedir.

Çizelge 1.2. Çalışmanın metodolojisi



1.4 Literatür Özeti

Bu bölümde, taşınmaz değerlendirme sürecinde kullanılan Makine Öğrenimi Tekniklerine ilişkin çalışmalara yer verilmiş ve literatürde yer alan çalışmaların; referansı, amacı ve kullanılan Makine Öğrenim algoritmaları Çizelge 1.3'te özetlenmiştir.

Çizelge 1.3. Literatürdeki modern yöntemlerin kullanılmasına yönelik çalışmalar

Referanslar	Çalışmanın Amacı	Makine Öğrenimi Algoritmaları
Park ve Bae, (2014)	Makine öğrenmesi algoritmalarının tahmin başarımlarını karşılaştırma ve gayrimenkul piyasası için daha hassas ve doğru konut fiyat tahmini oluşturma	C4.5 (Öznitelik Karar Ağacı), RIPPER (Hata Azaltımı Üretmek için Tekrarlanan Artımlı Budama), Naïf Bayes (Olasılık Temelli Sınıflandırma)
Baldominos vd., (2018)	Makine öğrenim algoritmaları ile taşınmaz değerlerinin fiyatlarının belirlenmesi	K En Yakın Komşular, Ağaç Toplulukları regresyonu, Destek Vektör Regresyonu, Çok Katmanlı Algılayıcı,
Mora-Garcia vd., (2018)	Konut fiyatlarını tahmin etmek için büyük verilerin kullanılmasında çeşitli makine öğrenme algoritmalarının performansının analizi	Doğrusal Regresyon, Rastgele Orman
Savaş, (2019)	Taşınmazın değerinin tespitinde kullanılan kriterlerin her birinin ağırlıkları da hesaplanarak değerlemede hangi kriterin mutlaka bulunması gerekliliği ve hangi kriterlerin taşınmaz fiyatına en yakın tahmini değer sonucunun belirlenmesinde etkili olduğunun incelenmesi	Çoklu Lineer Regresyon Analizi, Destek Vektör Regresyon, Destek Vektör Makineleri
Dimopoulos ve Bakas, (2019)	Makine öğrenimi modellerinin mülklerin toplu değerlendirilmesi için yeteneklerinin nasıl kullanılabileceği araştırılarak bu modellerdeki duyarlılık analizinin önemini vurgulamak ayrıca otomatik değerlendirme modellerinin (AVM) değerlendirme uzmanının günlük işleri için kullanılabilmesi için hassasiyetinin ölçülmesi	Rastgele Orman ve Regresyon Analizi

Çizelge 1.3.(Devam) Literatürdeki modern yöntemlerin kullanılmasına yönelik çalışmalar

Aubry vd., (2019)	Likit olmayan ve heterojen gerçek varlıklar için otomatik (yani makine tarafından üretilen) değerlemelerin doğruluğunu ve kullanılabilirliğinin incelenmesi, Hedonik model ve YSA modelinin karşılaştırılması analizi	Yapay Sinir Ağları (YSA)
Alfaro-Navarro vd., (2020)	Konut fiyatlarının tahmin edilmesi için geliştirilen tekniklerin hata ölçütleri açısından incelenmesi	Bagging(Torbalama), XgBoost(Aşırı Gradyan Güçlendirme), Random Forest(Rastgele Orman)
Tabar ve Şişman, (2020)	Bulanık mantık kullanılarak belirlenen kriterlere dayalı olarak arsa değerlendirme sürecinde bulanık mantığın kullanılabilirliğinin ölçülmesi	Bulanık Mantık
Yılmaz ve Kocaman, (2020)	Rastgele orman ve çoklu regresyona dayalı makine öğrenimi algoritmalarını kullanarak 2013-2018 yılları arasındaki transfer fiyatlarını kullanarak bir toplu değerlendirme gerçekleştirilmesi	Çoklu Regresyon Analizi, Rastgele Orman
Steurer vd., (2020)	Otomatik Değerleme Modelleri (AVM's) Makine Öğrenimi algoritmalarına dayalı olarak ev fiyatlarının tahmin edilmesi	Rastgele Orman
Pai ve Wang, (2020)	Makine Öğrenimi Tekniklerinin taşınmaz fiyatlarının tahmininde gerçek veriler ile tahmin verileri ile arasındaki performans farklarını inceleme	Regresyon Ağaçları, Destek Vektör Makineleri, Yapay Sinir Ağlarında Genel Regresyon, Geri Yayılım Sinir Ağları
Tabar vd., (2021)	Konut fiyatlarından elde edilen verilerle makine öğrenimi algoritmaları kullanılarak toplu değerlemenin yüksek doğrulukla gerçekleştirilmesi	Regresyon Analizi, Yapay Sinir Ağları
Mete ve Yomralıoğlu, (2021)	Makine Öğrenmesi algoritmalarının CBS ile entegre kullanılmasıyla birlikte taşınmaz değer tahmin modelinin oluşturulması	Aşırı Gradyan Güçlendirme, Lightgbm (açık kaynaklı bir gradient boosting framework), Rastgele Orman, Xgboost Catboost (kategorik değişkenlere odaklanan bir gradient boosting)

Çizelge 1.3.(Devam) Literatürdeki modern yöntemlerin kullanılmasına yönelik çalışmalar

Esen ve Tokgöz, (2021).	Gayrimenkul değer tespiti için gerekli kriter ve değişkenlerin yerine en az değişkeninin kullanıldığı uygulanabilir nitelik azaltma modeli geliştirilmesi	Bulanık Mantık
Yu vd., (2021).	Veri madenciliği ve makine öğrenmesine dayalı gayrimenkul fiyatlandırma yöntemleri üzerine bir araştırma.	Martingale method (finansal varlığın değerini kontrol), O-U process (Ornstein-Uhlenbeck Process-Salınım Süreci)
Iban, (2022)	Konut fiyatlarının toplu taşınmaz değerlemesinde ağaç tabanlı Makine Öğrenimi Tekniklerinin uygulanması	Rastgele Orman, Xgboost, Lightgbm, Gradient Boosting
Chou vd., (2022)	Makine Öğrenimi Teknikleri ile fiyat tahmini yaparak optimum performansın belirlenmesi	Regresyon Ağacı (CART), YSA (ANN'ler), Destek Vektör Regresyonu (SVR)
Guliker vd., (2022)	Hollanda'nın beş büyük belediyesinde gayrimenkul değerlerini modellemek için üç farklı hedonik fiyatlandırma modeli (doğrusal regresyon, coğrafi ağırlıklı regresyon ve aşırı gradyan artırma-XgBoost) kullanarak sonuçların karşılaştırılması	Doğrusal Regresyon, Xgbc (Kategorik değişkenlere odaklanan bir gb)
Emeç ve Tekin, (2022)	Konya ilinin konut talebini öngörmek amacıyla taşınmaz değerlemede modern yöntemlerin kullanılması	Yapay Sinir Ağı (YSA), Lineer Regresyon (LR), Destek Vektör Makinesi (DVM), Gauss Proses Regresyonu (GPsR) ve Regresyon Ağacı (RA) Modelleri
Baur vd., (2023)	Tahmine dayalı modellerin gayrimenkul değerlendirme verilerinden nasıl yararlanabileceğini göstererek AVM metotlu taşınmaz değerlemesi	Knime Platformu, Yapay Sinir Ağları
Aydınoğlu vd., (2023)	Makine Öğrenimi Algoritmaları ve CBS ile çok sayıda taşınmazı entegre kullanarak eş zamanlı olarak değerlendirerek yapısal ve konumsal verilerin değere etkisinin karşılaştırılması	Çoklu Doğrusal Regresyon, Karar Ağaçları, Rastgele Orman, Genelleştirilmiş Doğrusal Modeller, Destek Vektör Makineleri

Çizelge 1.3.(Devam) Literatürdeki modern yöntemlerin kullanılmasına yönelik çalışmalar

Alkan vd., (2023)	Turizm sektörünün önde yer aldığı bir kıyı kentinde taşınmaz değer değişimleri makine öğrenmesi yöntemleri ile incelenmesi	K En Yakın Komşular, Destek Vektör Makineleri, Rasgele Orman
Ulucan, (2023)	Taşınmaz değer piyasasında pandeminin etkilerinin ölçülmesi	K En Yakın Komşular, Rastgele Orman, Karar Ağacı, Yapay Sinir Ağı
Bu Tez Çalışmasında; (2024)	Makine Öğrenim Tekniklerinin hiperparametre optimizasyon algoritmalarından Bayes Tekniği ile optimize edilerek küçük ölçekli Yozgat kent merkezinde yüksek doğrulukta toplu taşınmaz değerlendirme tahmin modeli oluşturulması	Hiperparametre Optimizasyonu, Bayes Tekniği, Topluluk, Çekirdek, Doğrusal, Destek Vektör Makineleri ve İkili Karar Ağacı Regresyonları

Makine öğrenim teknikleriyle yapılan taşınmaz değerlendirme tahmin ve karşılaştırılmasına yönelik çalışmalardan farklı olarak Bayes Tekniği ile Hiper-Optimize edilmiş Makine Öğrenimi Tekniklerinin kullanıldığı taşınmaz değerlemesi üzerine çalışmalar incelenmiştir.

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 (R^2 , 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 atıf 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 taşınmaz değerlendirme süreçlerinde modellerin değiştirilmesi veya hiperparametre değerlerinin gerçek durum fiyat tahmini için ayarlanması konusunda az çaba sarf edildiği görülmektedir (Kalliola vd., 2021). Bununla birlikte uygulamalar Melbourne, New York ve Helsinki gibi metropol kentlerde gerçekleştirilmiştir. Bu tez çalışması, küçük ölçekli kentlerde toplu taşınmaz değerlendirme kapsamında farklı regresyon modellerinin Hiper-Optimize edilerek iyileştirilmesi ve başarı oranının kıyaslanmasıyla literatüre önemli bir katkı sağlayacaktır.

BÖLÜM II

TAŞINMAZ DEĞERLEME VE YÖNETİMİ

Tezin ikinci bölümünde, taşınmaz değerlemeye yönelik temel kavramlar, değerlemenin harita sektöründeki rolü, taşınmaz değerlendirme için kriterler, değerlendirme sürecinde yasal altyapı ve mevzuat ve ulusal ve uluslararası değerlendirme standartlarından bahsedilmiştir.

17.02.1926 tarihli ve 743 sayılı Türk Medeni Kanunu'nda "gayrimenkul" ifadesi kullanılırken, 22.11.2001 tarihinde resmi gazete’ de kabul edilen 4721 sayılı yeni Türk Medeni Kanunu'nda "taşınmaz" terimi kullanılmaya başlanmıştır. Aynı değişiklik, 3194 sayılı İmar Kanunu, 2942 sayılı Kamulaştırma Kanunu, 3402 sayılı Kadastro Kanunu, 2644 sayılı Tapu Kanunu gibi birçok önemli mevzuatta da etkisini göstermiştir (Candaş, 2012). Ek olarak, 4721 sayılı Türk Medeni Kanunu'nun (2001), 704. Maddesi, taşınmaz mülkiyetinin konusunu oluşturan arazi, tapu kütüğünde ayrı sayfaya kaydedilen bağımsız ve sürekli haklar ile kat mülkiyeti kütüğüne kayıtlı bağımsız bölümleri, taşınmaz mallar olarak tanımlamaktadır (TMK, 2021).

2.1 Kavramlar

Taşınmaz değerlemeye yönelik kavramlar aşağıdaki başlıklarla özetlenebilir;

Taşınmaz Mülkü (Gayrimenkul): Türk Dil Kurumu (TDK) sözlüğünde taşınmaz; “taşınmayan (1), ev, tarla vb. taşınamayan (mülk), gayrimenkul (2)” şeklinde ifade edilmiştir (TDK, 2023).

Değer: Bir nesnenin sağladığı toplam yarar, tasarruf ve kullanım değeri olarak ifade edilen bir kavramdır. Diğer bir deyişle, değer, belirli bir malın, hizmetin veya fikrin taşıdığı yararlı vasfı ifade eder. Değer, bir malın talep edilebilirliği ve varlığının miktarı ve derecesine göre artarak ya da azalarak şekillenmektedir.

Mülkiyet Hakkı: Kişilerin taşınmaz mallarının geometrik ve hukuki haklarını tasarruf etme ve kullanma haklarını güvence altına alarak koruyan haktır (Aktaş, 2022).

Taşınmaz Değerlemesi: Taşınmazların karakteristik özelliklerinin belirlenmesi, yapısal ve konumsal verilerin toplanarak analiz edilmesi ve mevcut piyasa koşullarına uygun birim fiyatlarının belirlenmesi sürecidir. Bu değerlendirme süreci, bir gayrimenkulün mali değerini belirlemek ve güncel piyasa koşullarına göre değerini analiz etmek amacıyla gerçekleştirilir.

Taşınmaz Yönetimi: Değerleme sektöründe, mülk değerlerinin belirlenmesine odaklanan ve değerlemeye yönelik tüm aktörler ve uygulamaları içeren mevzuatı ile bir bütün olan disiplindir. Bu disiplin, mülk sahiplerinin varlıklarının optimum değerini bilimsel ve tarafsız bir şekilde belirlemek, yatırımcılara ve yerel yöneticilerin kentsel ve bölgesel bağlamda kentin gelişimine yönelik rehberlik etmek amacıyla geliştirilmiştir (Ulucan, 2023).

2.2 Taşınmaz Değerlemesinin Haritacılık Sektöründeki Önemi

Harita mühendisliği temelde taşınmaza ilişkin geometrik ve hukuki haklarının belirlenmesinde ve mülkiyet durumunun ortaya konulmasında görev yapmaktadır. Bu anlamda taşınmazın kadastral durumunun belirlenmesi sağlanarak taşınmaza yönelik ilk değerler ortaya konulmasında harita sektörü önem taşımaktadır. Böylece taşınmazın kadastral durumu ortaya konulduktan sonra vergilendirme aşamasında bu taşınmazın kullanılabilirliği ve vergilendirme süreci gerçekleştirilebilir.

Kadastral durumu belirli taşınmaz üzerinde yapılacak her türlü plan ve plan üzerindeki değişiklik harita sektörü ile ilişkilidir. Geliştirilecek bir imar uygulamasının getireceği değerlerin belirlenmesinde imar durumu ve imara yönelik kavramlar (TAKS, KAKS, hmax, vb.) harita sektörünün ilgili alanında kalmaktadır.

Harita sektörü aynı zamanda kamu yararı amaçlı yapılan arazi toplulaştırma ya da bir tren yolu güzergâhının oluşturulması ve bir gölet alanın kamulaştırılması gibi uygulamalarda harita ve arazi üzerinde teknik süreçlerde aktif olarak rol almaktadır. Bu süreçlerde gerçekleştirilecek arazi derecelendirmesi ya da kamu yararı amaçlı kamulaştırma uygulamalarındaki bedelin tespiti süreçlerinde değerlendirme aşamalarında yer almaktadır.

Tüm bu değerleme süreçlerinde harita sektörünün aktif olarak yer alması uygulamaların teknik ve ekonomik boyutunu harita mühendislerinin sürece ilişkin yetkinliğini sağlamaktadır. Bu nedenle taşınmaz değerleme süreçleri harita sektöründe incelenmesi aktif olarak yeni yaklaşımların araştırılması ve uygulanmasını gerekli kılmaktadır.

Bu tez çalışmasında, yeni teknolojiler kullanılarak değerleme sürecine katkı sağlamak amaçlanmıştır. Bu kapsamda kent ölçeğinde toplu taşınmaz değerleme sürecinde çeşitli hiper- optimize edilmiş makine öğrenme algoritmalarının kullanımının detaylı bir şekilde incelenmesi ve tahmin doğruluklarının değerlendirilmesi sağlanmıştır. Gelecekte kamu sektöründe değerlemeye yönelik yapay zekâ teknikleri ile objektif ve bilimsel uygulanabilirliğin artırılmasında tez çalışması önem taşımaktadır.

2.3 Taşınmaz Değerlemeye Etki Eden Kriterler

Taşınmaz değerleme sürecinde en doğru sonucu elde etmek için değerlemeye ilişkin özelliklerin bir başka deyişle kriterlerin (faktör, parametre, vb.) detaylı bir şekilde incelenmesi önem arz etmektedir. Çalışmalarda değerleme kriterleri sınıflandırılır ve sayısal ifadelere dönüştürülerek değerlemeye ilişkin yöntemler yardımıyla gerçek değer tahmin edilmesi amaçlanmaktadır. Bu kriterler, yapısal, konumsal ve çevresel özellikler gibi sınıf ya da faktörlere ayrılarak, her biri kendi içinde çeşitli yöntemlerle ayrıntılı bir şekilde değerlendirilir ve taşınmaz değer hesabı gerçekleştirilir (Saraç, 2012).

Literatürde taşınmaz değerlemeye etki eden kriterler çok sayıda araştırmacı tarafından incelenmiştir. Bunlar;

- Taşınmazın tasarruf ve kullanım amacı, yerele özgü özellikleri, konumsal özellikleri ve mevzi özellikleri (Yomralıoğlu, 1997),
- Yasal, fiziksel, çevresel ve sosyo-ekonomik faktörler (Özkan, 2009),
- Sosyal ve çevresel kriterler, kişisel kriterler ve diğer kriterler (Uygun, 2011),
- Taşınmazın tasarruf etme amacı, bölgesel ve yerel özellikleri, taşınmazın konumu ve yasal kullanım durumu (Yağmahan, 2019),
- Yerele özgü niteliklerden farklı olarak kişilerin objektif bakış açısında göre değişen özellikler (Çakır ve Sesli, 2013),

Olarak ifade edilmiştir.

2.4 Taşınmaz Değerleme Sürecinde Yasal Altyapı ve Mevzuat

Türkiye'de değerlemede kapsamlı olarak bir yasal düzenleme bulunmamakta ancak vergilendirme, tapu, kadastro ve planlamaya yönelik uygulanan mevzuatlar incelendiğinde her bir mevzuatın amacı, türü, şekli ve yönetim biçimine göre bir değerlendirme süreci, değerlendirme kriterleri ve bedel tespit yöntemi bulunmaktadır (Köktürk ve Köktürk, 2015; Candaş, 2012; Erdem, 2018). Bu mevzuatlardan; Kamulaştırma, Emlak Vergilendirilmesi, Özelleştirme, Devletleştirme, Arsa ve Arazi Düzenlemeleri ve Kırsal Arazi Düzenlemesinde Toplulaştırma Uygulamaları gibi uygulamaların yer aldığı mevzuatlarda taşınmaz değerlemeye yönelik yönergeler olduğu görülmektedir (Uzer, 2009).

Yasal mevzuatta değerlemeye yönelik geçen bazı kavramlar ve açıklamaları Çizelge 2.1’de ifade edilmiştir.

Mevcut mevzuatlarda değerlendirme aşamaları, değerlendirme kriterleri, mevcut kavramsal ifadeler ve değerlemede kullanılan yöntemler konusunda bir bütünlük ve standart bulunmamaktadır. Taşınmaz değerlendirme, mevzuatlar çerçevesindeki tutarsızlık ve uygulamalardaki farklılık sorunu, Avrupa ve Dünya genelinde bir arayışa yol açmıştır. Bu kapsamda, 2011 yılında Uluslararası Değerleme Standartları, 2012 yılında Avrupa Değerleme Standartları ve 2013 yılında Taşınmazın Toplu Değerlemesinde Standart gibi standartları oluşturmayı amaçlayan tebliğler yayınlanmıştır. Türkiye’de değerlendirme sürecinde standart oluşturmaya yönelik 2017 yılında Uluslararası Değerleme Standardı Tebliği yayınlanmıştır.

Çizelge 2.1. Taşınmaz değerlendirme mevzuatı hakkında genel bilgiler

Bilgi Konusu	Açıklama
Yer, Konum, Tanım, Tapu Kayıtları, Plan, Proje, Ruhsat, Şema vb. Dokümanlar	Gayrimenkulün fiziksel özellikleri ve resmi belgeleri hakkında bilgiler.
Takyidat ve Devir Sınırlamaları	Gayrimenkulün üzerindeki herhangi bir kısıtlama veya devir sınırlamasına dair bilgiler
Alım Satım İşlemleri ve Hukuki Değişiklikler	Son üç yılda gerçekleşen alım satım işlemleri ve hukuki durumdaki değişikliklere ilişkin bilgiler
İmar Durumu ve Bölge Bilgileri	Gayrimenkulün ve çevresindeki bölgenin imar durumu ve planlama bilgileri
Durdurma Kararı, Yıkım Kararı, Riskli Yapı Tespiti vb. Durumlar	Gayrimenkule dair alınan durdurma, yıkım, riskli yapı tespiti gibi kararlara ilişkin bilgiler
Yapılan Sözleşmeler (Satış Vaadi, Kat Karşılığı İnşaat, Hasılat Paylaşımı vb.)	Gayrimenkule ilişkin yapılan sözleşmelere dair bilgiler
Yapı Ruhsatları, Tadilat Ruhsatları, Kullanım İzinleri ve Mevzuata Uygunluk	İlgili belgelerin durumu ve mevzuata uygunluğu hakkında bilgiler
Değerleme Yapılan Projeler ve Yapı Denetimi Kuruluşu Bilgileri	Proje bazında yapılan değerlemeler ve denetimleri gerçekleştiren kuruluşların bilgileri
Projeye İlişkili Detaylı Bilgi ve Olası Projelerin Etkisi	Eğer belirli bir projeye istinaden değerlendirme yapılıyorsa, projeye dair detaylı bilgiler ve olası etkiler

2.4.1 Taşınmaz değerlendirme sürecinde ulusal ve uluslararası standartlar

Uluslararası Değerleme Standartları, dünyada değerlendirme sürecinde uzmanlar için rehberlik eden, sınır ötesi işlemleri yürütebilmeyi, değerlendirme faaliyetlerinin güvenilirliğini ve şeffaflığını sağlamayı, hukuki ve vergisel konularda çözümler sunmayı hedefleyen ve uluslararası düzeyde güvenilir değerlendirme taleplerini karşılamayı amaçlayan standartların oluşturulduğu bir sistemdir. Bu amaçlar doğrultusunda, uluslararası alanda birçok mesleki değerlendirme örgütü kurulmuştur. Bunlar arasında IVSC (Uluslararası Değerleme Standartları Konseyi), TEGOVA (Avrupa Değerlemeci Birlikleri Grubu), RICS (Kraliyet Yeminli Sörveyörler Enstitüsü) ve ASA (Amerikan Değerleme Derneği) gibi büyük çaplı kurumlar bulunmaktadır (Khamrabaeva, 2020).

Uluslararası Standartlar

Uluslararası Değerleme Standartları, değerlendirme aşamasına ilişkin ilkeleri ve tanımları belirleyen, değerlendirme yöntemlerini ortaya koyan, veri toplama ve analiz sürecini açıklayan ve değerlendirme raporlama ve kalite kontrol süreçlerini ifade eden geniş bir kapsama sahiptir (IVS, 2011).

Ulusal Standartlar

Ülkeler, kendi değerlendirme standartlarını oluşturabilir. Ulusal standartlar, her ülkenin yasal altyapısına ve değerlendirme düzenlemelerine dayanmaktadır. Türkiye'de değerlendirme sürecine ilişkin ulusal standartlar, yönergeler ve tebliğler bulunmaktadır (TSPB, 2023).

Türkiye'nin ulusal standartları hakkında bazı bilgiler aşağıda yer almaktadır. Bunlar;

Türkiye Değerleme Standartları (TDS) Türkiye'de değerlendirme sürecinde en geniş kabul gören standartların Türkiye Değerleme Uzmanları Birliği (TDUB) tarafından hazırlandığı tespit edilmiştir. TDS, Türkiye'nin koşullarına ve ihtiyaçlarına özel olarak tasarlanmış olup uluslararası standartlarla uyumlu bir yapıya sahiptir.

Türkiye Değerleme Uygulama Rehberi (TDUB) Türkiye'de değerlendirme aşamalarını ve sürecini daha detaylı bir şekilde düzenlemek amacıyla “Türkiye Değerleme Uygulama Rehberi” sıkça başvurulanan bir kaynaktır. Bu rehber, değerlendirme aşamalarındaki adımları, kullanılan yöntemleri, veri niteliklerini ve analizini ve raporlama gerekliliklerini detaylı bir biçimde ele almaktadır.

Sermaye Piyasası Kurulu (SPK) Standartları Türkiye'de sermaye piyasası faaliyetleri değerlendirme süreci kullanılmaktadır. SPK (Sermaye Piyasası Kurulu), sermaye piyasası araçları ile ilgili standartları ve yönergeleri yasalar çerçevesinde duyurmaktadır. Bu standartlar, sermaye piyasası araçlarının değerlemesinde kullanılan metotları, değerlendirme kuruluşlarının uyacakları kuralları ve raporlama gerekliliklerini ayrıntılı bir şekilde tanımlar.

SPK, TDUB ve TDS'nin öngördüğü standartlar, değerlendirme sürecinin kalitesini artırmayı, değerlendirme lisansı alan uzmanların yetkinliklerinin çerçevesini oluşturmayı, tarafsızlık ve şeffaflık ve güvenilir değerlendirme sonuçları elde etmeyi amaçlamaktadır. Ayrıca yine bu standartlar gayrimenkul değerlendirme işlemlerinin dünya genelinde kabul görmüş olması

değerleme sürecinin uygun bir şekilde yürütülmesinin güvencesidir. "Sermaye Piyasasında Değerleme Standartları Hakkında Tebliğ (III-62.1)" 01.02.2017 tarih ve 29966 sayılı Resmî Gazete’de yayımlanarak yürürlüğe girmiştir. Bu tebliğ, sermaye piyasasında değerleme işlemlerinin standartlarını belirlemek amacıyla hazırlanmıştır (URL-1).



BÖLÜM III

TAŞINMAZ DEĞERLEME SÜRECİNDE UYGULANAN YÖNTEMLER

Taşınmaz değerlendirme yöntemleri; Tekil Değerleme, geleneksel yöntemler olarak, Toplu değerlendirme ise; istatistiksel, ÇKKV, CBS ve modern yöntemler olarak dört farklı şekilde literatürde yerini almıştır.

Geleneksel değerlendirme yöntemlerinde genellikle Karşılaştırma (Emsal), Gelir ve Maliyet yöntemlerini kullanır. IVSC'nin 2011 raporuna göre, bu değerlendirme yöntemlerin her biri farklı kriter, taşınmaz niteliği ve uygulama yaklaşımlarını içermektedir (IVSC, 2011). Geleneksel değerlendirme yöntemleri tekil değerlendirme olarak da ifade edilebilir. Tekil değerlendirme, tek parsel, yapı ya da işletme ölçeğindeki para ve sermaye piyasasına ilişkin işlemler, alım-satım işlemleri ile kredi ve yatırım amaçlı gerçekleştirilen değerlendirme süreçlerini kapsayan geleneksel bir değerlendirme yöntemidir (İlhan ve Öz, 2020).

İstatistiksel olarak değerlendirme yöntemleri, taşınmazların geleneksel yöntemlere göre daha objektif ölçütlerle konumsal ve yapısal özelliklerine yönelik puanlama ve istatistiksel analizlerle değerlendirildiği yöntemlerdir. Nominal, çoklu regresyon ve hedonik yöntemler örnek verilebilir. Pek çok taşınmaza ilişkin veri toplu bir şekilde değerlendirilebildiği ve kıyaslanabildiği için toplu taşınmaz değerlendirme yöntemleri olarak sınıflandırılır.

ÇKKV teknikleri değerlemede yer alan taşınmazların değerine etki eden konumsal ve konumsal olmayan özelliklerin önem düzeylerinin belirlenmesinde kullanılan yöntemlerdir. Analitik hiyerarşik analiz (AHP) sıklıkla kullanılan bir ÇKKV yöntemi olup uzman görüşlerine dayalı olarak taşınmaz değerini etkileyen kriterlerin ağırlıklandırılmasında kullanılmaktadır. Ayrıca TOPSIS (Technique for Order of Preference by Similarity to Ideal Solution), AHP (Analytic Hierarchy Process), MOORA (Multi-Objective Optimization on the basis of Ratio Analysis), ELECTRE (Elimination Et Choix Traduisant la Realite), ve VIKOR (Vlsekriterijumska Optimizacija I Kompromisno Resenje) gibi yöntemler de çalışmalarda AHP ile birlikte değer değişimin önceliklendirilmesinde ya da sıralandırılmasında kullanılmaktadır. ÇKKV yöntemleri

çok sayıda taşınmaza yönelik önceliklendirme ve sıralama gerçekleştirebildiğinden toplu değerlendirme yöntemleri içerisinde sınıflandırılabilir.

Son yıllarda bilgi ve iletişim teknolojilerinin gelişmesiyle birlikte çevrimiçi olarak taşınmazlara yönelik pek çok veriye anında erişim sağlanabilirken bu kadar büyük hacme sahip verilerin hesaplanmasında ve taşınmaz değerine yönelik tahminlerin gerçekleştirilmesinde makine öğrenim teknikleri kullanılmaya başlanmıştır. Makine öğrenim teknikleri toplu taşınmaz değerlemenin gerçekleştirilmesinde çok sayıda verinin objektif nitelikte değerlendirilmesi ve karşılaştırılmasında başarılı tahmin sonuçları üretmektedir. Makine öğrenimi ile gerçekleştirilen toplu taşınmaz değerlendirme taşınmazların bir bütün olarak değerlendirme sürecinde ele alınması mülkiyet bilgilerinin toplanması, yönetimi, tasarım kararlarının alınması ve verilerin bir arada değerlendirilmesi ile maliyeti düşüren nitelikte bir değerlendirme sürecidir (Erdem, 2017).

Uygulamalarda geleneksel yöntemler kullanılmaya sıklıkla devam edilmesine rağmen bilgi teknolojileri geliştikçe ve veri depolama ve kullanıcı niteliği değişip geliştikçe modern yöntemlerinde günlük hayatta kullanımı giderek artmaktadır.

Söz konusu toplu taşınmaz değerlemenin tüm bu olumlu özellikleri dikkate alınınca toplu taşınmaz değerlemede kullanılan değerlendirme yöntemleri kullanılabilirliğine yönelik tespit edilmesi önemlidir. Bu kapsamda toplu taşınmaz uygulamalarının sistematik, geliştirilebilir ve güncellenebilir bir yapıya sahip olması, modern teknoloji ve istatistiksel yöntemleri içermesi, düzenli toplanan güncel veri yönetimine sahip olması ve değerlendirme sürecinin bilimsel, objektif ve adil yönetiliyor olması özellikleri ile değerlendirme yöntemleri içinde sınıflandırılması gerekmektedir. Buna yönelik olarak taşınmaz değerlendirme yöntemleri için yöntemlerin kullanılabilirliğini ifade eden Çizelge 3.1’de sınıflandırma literatür yardımıyla gerçekleştirilmiştir (IAAO 2013; Barańska, 2013).

Çizelge 3.1. Taşınmaz Değerleme Yöntemleri



3.1 Taşınmaz Değerlemede Geleneksel Yöntemler

Geleneksel yöntemler çoğunlukla kullanılan yöntemler açısından; emsal yöntemi, gelir yöntemi, maliyet yöntemi ve iskontolu nakit akış yöntemi olarak uygulanmaktadır.

Tekil değerleme, genellikle tek parsel, tek yapı ve tek işletme ölçeğindeki alım-satım işlemleri, para ve sermaye piyasasına ilişkin işlemler ile kredi ve yatırım amaçlı gerçekleştirilen değerleme çalışmalarını kapsayan geleneksel bir değerleme yöntemidir (İlhan ve Öz, 2020).

Literatürde; Akkaynak (2017), Bursa ili Yenişehir ilçesinde değerlemeye tabi taşınmazın benzer nitelikteki diğer taşınmazların belirlenmesi ve ilgili verilere ulaşmak ve uygulama yürütmek için emsal yöntemini kullanmıştır. Gündoğmuş ve Taşçı (2017), Denizli ili Çivril İlçesinde hünnap üretimi yapan işletmelerden elde edilen verileri kullanarak, kapama hünnap bahçesi ve birim hünnap ağacı değerlerini gelir yöntemiyle belirlemeyi amaçlamıştır. Taktak ve Demir (2010), Afyonkarahisar ili bölgesinde Termal Otel Geliştirme uygulaması kapsamında iskontolu nakit akış yöntemini kullanmıştır.

3.1.1 Emsal yöntemi

Bu yöntem karşılaştırma esasına dayanmaktadır. Karşılaştırma sürecinde belirli bir bölgede bir sınır içerisinde bu değerlemenin yapıyor olması, güncel piyasa değerlerinin ve yakın zamanda satılan taşınmazların kıyaslanma sürecinde bulunması gerekmektedir. Aynı zamanda farklı özelliklerin (konum, büyüklük, çevre düzenlemeleri, kullanım, bina, hizmet kalitesi vb.) taşınmaz fiyatlarını nasıl etkilediğinin belirlenmesi de emsal değerlendirme yönetimin bir sonucudur (Almy, 2014).

Emsal yönteminin etkili bir şekilde uygulanabilmesi için, karşılaştırma yapılan taşınmazların benzer özelliklere sahip olması kritik bir öneme sahiptir. Bu sebeple, emsal taşınmaz seçimi özenle gerçekleştirilmeli ve değerlendirme sürecinde değer tespiti yapılacak olan yapıyla mümkün olduğunca benzer niteliklere sahip olmalarına özen gösterilmelidir.

3.1.2 Gelir yöntemi

Gelir yaklaşımı yönteminde esas alınan ölçüt, gayrimenkulden elde edilebilecek net gelirdir. Kentsel alan için taşınmazdan elde edilen net gelir, üzerinde varsa yapıdan elde edilen gelir ve yapıya ilişkin diğer bağımsız yapısal tesislerin getirisi ve arsa payından oluşmaktadır. Arsalar yıpranma payı olmadan sürekli olarak kullanılabilirken yapıların kullanım süreleri artıkça yıpranması nedeniyle sınırlıdır. Bu nedenle, net gelirin parasal karşılığının belirlenmesinde; arsa, yapı ve yapıya ilişkin diğer yapısal tesislerin bağımsız bölümlerinin değerleri de hesaplanır (Deveci ve Yılmaz, 2009).

Kırsal alanda bir taşınmazın değerlemesi söz konusu olduğunda arazide var olan tüm doğal kaynaklar ve sulama vb. yapay tesisler ya da bir enerji nakil hattının arazi üzerinden geçmesiyle oluşan olumsuz özellikler araziden elde edilecek net gelirin hesaplanmasında kullanılır.

3.1.3 Maliyet yöntemi

Maliyet yöntemi, bir yapının baştaa yeniden üretilmesi bedeline dayanan bir değerlendirme yöntemi olup genel olarak yüklenici yöntemi olarak da adlandırılır. Bu yöntem, fabrika, hastane, otel, yönetim yapıları ve sanayi alanı gibi üzerinde yapı bulunan ve kira geliri

bilinmeyen gayrimenkullerin deęerlemedesinde kullanılır. Maliyet yöntemi, bir gayrimenkulü satın almanın dışında gayrimenkulün aynısı, benzeri veya aynı kullanımı ve yararı sağlayacak başka bir gayrimenkulü inşa edebileceęi olasılıęına dayandırılmaktadır (Öztürk vd. , 2011).

Maliyet yöntemi yaklaşımında temel ilke, yapılmış taşınmazların deęerleme tarihindeki güncel maliyet bedeline ulaşmaktır. Bu yöntemde, taşınmazlar üzerindeki binalar ve çeşitli ekonomik deęeri olan bağımsız bölümler yıpranma payları, bakım ve onarım harcamaları gibi çeşitli giderleri ile toplam yapı maliyet bedelinden çıkartılarak, yapıların inşa ve elde etme maliyetleri hesaplanır.

3.1.4 İskontolu nakit akış yöntemi

İskontolu Nakit Akış Yöntemi için geleneksel yöntemlerde iskontolu nakit akışına baęlı “Nakit Deęer Formülü” uyarlaması olan bir gelir yöntemi denilebilir (Karakuş, 2011). Ayrıca şirketler ve hisse deęerleri için bir şirketin satıldığı zamandaki tüm hisse deęerleri ile birlikte olan alım satım deęeridir.

3.2 Taşınmaz Deęerlemede İstatistiksel Yöntemler

Taşınmaz deęerlemede istatistiksel yöntemler; nominal deęerleme, çoklu regresyon, hedonik ve mekânsal analiz yöntemleridir. Literatürde istatistiksel yöntemlere yönelik gerçekleştirilen pek çok çalışma yer almaktadır (Karaduman 2023; Doldur ve Alkan 2021).

3.2.1 Nominal deęerleme yöntemi

Nominal Deęerleme teknięi, taşınmaz deęerleme sürecinde yapısal özelliklere ve konumsal özelliklere ilişkin CBS tabanlı kullanıma sahip puanlama geliştiren bir toplu deęerleme yaklaşımıdır. Bu yöntemde, taşınmaz deęerini etkileyen kriterler belirlenerek bu kriterlerin uzman görüşüne yönelik puanlaması gerçekleştirilir. Konumsal ve yapısal özelliklere yönelik belirlenen kriterler için atanan puanların toplamı ve bu toplam puanın tavan ile taban puanları arasında normalizasyon işlemi gerçekleştirilir.

Buna bağılı olarak her bir taşınmazın normalize edilen değerlerine göre değer katsayısı hesaplanır. Bu hesaplanan değer katsayıları normalize edilmiş piyasa değerleri ile karşılaştırılarak değer farklılıkları ortaya konulur.

Çok sayıda taşınmazın değerlendirilmesi durumlarında nominal değerleme tekniğı, belirlenen değerlerin temel alındığı ve kolayca rayiç bedele dönüştürülebildiğı bir model sunmaktadır (Yomralıoğlu, 1995; Doldur ve Alkan, 2021).

3.2.2 Çoklu regresyon analizi yöntemi (CLR)

Çoklu regresyon yöntemi hem uygulayıcılar hem de akademisyenler arasında geniş kabul gören ve en çok kullanılan yöntemlerden biridir.

Bu yöntemde, piyasa değeri olarak geçen tek bir bağımlı değişken bulunur ve bu bağımlı değişkeni etkileyen konumsal ve yapısal özellikleri ifade eden birden fazla bağımsız değişken bulunmaktadır. Bu yöntemde, taşınmazın değerini en fazla etkileyen kriterler analiz edilir ve gerçeğe en yakın fiyat tahmini gerçekleştirme çabası gösterilir (Amca, 2016).

3.2.3 Hedonik model yöntemi

"Hedonik fiyatlama modeli" konut fiyatlarını etkileyen unsurların belirlenmesinde kullanılan niceleyici bir yöntemdir. (Demircan, 2021). Metro istasyonlarının konut fiyatına etkisini araştırmak amacıyla internet satış sitelerinden 2019'da toplanan 349 konut incelenmiş, iki istasyondaki konut alanları için fiziksel, lokasyonel ve çevresel faktörler hedonik fiyat yöntemiyle analiz edilerek sayısal çalışma yapılmıştır.

3.3 Taşınmaz Değerlemede Çok Kriterli Karar Verme Yöntemleri

ÇKKV yöntemleri arasında TOPSIS, AHP, MOORA, ELECTRE ve VIKOR gibi yöntemler sıklıkla kullanılan tekniklerdir. Bu yöntemler, farklı kriterlere göre değerlendirilen alternatifler arasında en doğru tercihi yapmak için kullanılır.

Taşınmaz değerlendirme, taşınmazın özelliklerine göre değerinin belirlenmesi açısından bir karar problemidir. Bu nedenle değerlendirme süreci bir karar problemi olarak ele alınarak objektif ve bilimsel nitelikte sonuçların elde edilmesi sağlanabilir. ÇKKV yönteminin

temel yapısı karar verme sürecini sistematik bir yöntem haline getirmeye ilişkindir. Söz konusu üzerinde karar verilecek varlık bir taşınmaz değeri ise bu taşınmazın değeri etkileyen sayıda çok kriterli bir yöntem ile ele alarak o taşınmazın değerine yönelik bir değer üzerinde karar verme sağlanır.

AHP tekniği ÇKKV tekniklerinden biri olarak değerlemede sıklıkla kullanılmaktadır (Demirel vd., 2018). İlk kez Saaty (1980) tarafından geliştirilen bu yöntemde uzman görüşü eşliğinde elde edilen kriterlerin ikili karşılaştırma yöntemi matrisleri ile model oluşturularak değerlendirilmesi sağlanır. Bu yöntem, taşınmaz değerlendirme sürecinde değere etki eden taşınmazların özelliklerini ifade eden kriterlerin önem düzeylerini ağırlıklandırılmasını sağlayarak bölgesel bağlamda taşınmazların birbirine göre değişimleri ortaya konulmasını sağlamaktadır. Literatürde taşınmaz değerlendirme sürecinde AHP yöntemi sıklıkla kullanılmaktadır (Ball ve Srinivasan, 1994; Timor, 2011; Tunca ve Üstüntaş, 2019; Alkan ve Durduran, 2020; Bozdağ ve Ertunç, 2020; Alkan ve Durduran, 2021). Bu çalışmalarda uzman görüşüne dayalı olarak 9 veya 5’li likert ölçeklerinde anket uygulamaları yapılır ve yapılan anket uygulaması sonuçları AHP’nin hiyerarşik yapısı içinde değerlendirilmektedir. AHP ile oluşturulan taşınmaz problemlerindeki süreç şöyle tanımlanabilir:

- Hedeflerin, kriterlerin ve alternatiflerin hiyerarşik yapıya uygun nitelikte belirlenmesi sağlanır.
- Bu alternatif veya kriterlerin birbirine göre önem düzeyinin ölçülmesinde ölçek sıralaması gerçekleştirilir.
- Alternatif ya da kriterlerin ikili karşılaştırma değerleri kullanılarak (nxn) boyutunda ikili karşılaştırma matrisleri hazırlanır ve normalize edilir.
- Normalize edilmiş matrisin satırlarının toplanmasıyla hesaplanan kriterler için öncelik vektör matrisi oluşturulur.
- Öncelik vektör matrisindeki her bir kriter için elde edilen öncelik değerlerinin, o kritere ait ikili karşılaştırma matrisinde yer alan sütundaki elemanlarla çarpılması sağlanarak ağırlıklandırılma gerçekleştirilmiş toplam matris elde edilecektir.
- Ağırlıklandırılması gerçekleştirilmiş toplam matristeki satır toplamaları, öncelik matrisinde yer alan satır değerlerine bölünerek (nx1) boyutlu son matris oluşturulur. Matristeki değerlerin aritmetik ortalaması sonucu λ_{max} değeri hesaplanır.

- Tutarlılık indeks değeri hesaplanır. Bu değer Eşitlik 3.1’de ifade edilmiştir:

$$CI = (\lambda_{\max} - n)/(n - 1) \quad (3.1)$$

CI: Tutarlılık İndeksi

- Saaty ve Vargas (1982)’de hazırlanan Ortalama Rassal Tutarlılık Tablosu Eşitlik 3.2’de yer alan CI’nın kullanılması ile tutarlılık oranının hesaplanması sağlanmaktadır.

$$CR = CI/RI \quad (3.2)$$

CR: Tutarlılık Oranı

RI: Ortalama Rassal Tutarlılık

- Tutarlılık oranının her katılımcı için 0.10 değerinden küçük çıkması önemlidir. 0.10’dan büyük çıkan tutarlılık oranı için ikili karşılaştırma matrisi tekrar gözden geçirilmeli ve her katılımcının kararları gözden geçirilmelidir. Gerekirse baştan değerlendirme yapılarak adımlar tekrarlanmalıdır.

ÇKKV tekniklerinde AHP ile değerlemede yer alan kriterlerin taşınmaz olan etkilerinin ağırlıklarının ölçülmesi sağlanabilir. ÇKKV yöntemlerinden biri olan TOPSİS kullanılarak taşınmazların mevcut özelliklerine yönelik değerlerinde bir sıralama ya da önceliklendirme yapılması sağlanabilir.

Hwang ve Yoon (1981) tarafından geliştirilen TOPSIS tekniği ideal çözüme en kısa mesafeyi ve en kötü veya negatif ideal çözüme en uzak mesafeyi tanımlarken en iyi çözümü veya alternatifi bulmaya olanak sağlamaktadır (Hwang ve Yoon, 1981; Kumar ve Gark, 2018). TOPSİS basit, rasyonel ve net bir mantık içermesi nedeniyle her alternatife göre performansın kontrol edilmesini kolaylaştıran bir mantık içermektedir (Roszkowska, 2011).

TOPSIS yöntemi 6 adımdan oluşan bir çözüm sürecini içermektedir (Büyükkaracıgan, 2021). Bu süreç;

Adım 1: Başlangıç Karar Matrisinin Oluşturulması (A)

Adım 2: Normalize edilmiş Karar Matrisinin (R) Oluşturulması

Adım 3: Ağırlıklandırılmış Karar Matrisinin Oluşturulması (V)

Adım 4: İdeal çözüm ($* A$) ve Negatif İdeal çözümden uzak ($- A$) vektör oluşturma

Adım 5: Ayrımcılık Tedbirlerinin Hesaplanması

Adım 6: İdeal Çözüm için Görelî Yakınlığın Hesaplanması

Literatürdeki çalışmalarda TOPSIS yöntemi taşınmaz değerlendirme sürecinde sıklıkla kullanılmıştır (Özer, 2010; Yertutan ve Çetinyokuş, 2021).

3.4 Coğrafi Bilgi Sistemleri

Coğrafi Bilgi Sistemleri (CBS), coğrafi konumla ilişkilendirilmiş nicel ve nitel verilerin toplanması, depolanması, sorgulanması, ilişkilendirilmesi, mekânsal analiz edilmesi ve kullanıcıya sunulması amacıyla tasarlanmış bir bilgi sistemidir (Alkan ve Durduran, 2021).

CBS, coğrafi unsurları haritalar üzerinde görselleştirmek, konumsal ilişkileri anlamak ve kararlar almak için kullanılan güçlü bir araç olup, harita tabanlı veri analizi ve yönetimi için yaygın olarak kullanılmaktadır. CBS'nin toplu taşınmaz değerlendirme aşamalarında kullanımı, verilerin toplu bir şekilde analiz edilerek mekânsal ve yapısal özelliklerin incelenip taşınmaz değer haritalarının oluşumuna katkı sağladığı görülmüştür. Bu haritalar, mekânsal analizler, sorgulamalar, en uygun yer seçimi analizi, yapı birim fiyatlarının belirlenmesi ve yatırım yapılacak bölgelerin tanımlanması gibi çeşitli süreçlere katkıda bulunur.

3.4.1 Taşınmaz değerlemede mekânsal analiz süreci


Mekânsal analiz, mekânsal verileri kullanarak ve ilişkilendirerek verinin özelliğini ve kapsamını yansıtacak nitelikte sayısal harita üretimi işlemidir. Taşınmaz değerlemede taşınmazın çevresinde yer alan eğitim tesisleri, sağlık tesisleri, yeşil alanlar ve ulaşım

tesisleri ve resmi kurumlar gibi donatılara olan yakınlık mesafeleri ölçüt alınarak taşınmazın mekânsal durumu analiz edilebilir. Farklı donatılar için yapılmış bu mekânsal analizler birleştirilmesiyle sentez haritalar elde edilir. Mekânsal analizler kullanıcıların coğrafi verileri etkili bir şekilde yönetmelerini, analiz etmelerini ve sonuçları görselleştirmelerine imkân sağlar. Mekânsal analizler CBS ortamında gerçekleştirilir.

Masaüstü CBS yazılımları, genellikle güçlü bir şekilde gerçekleştirilebilen temel işlevlere sahip, grafik kullanıcı arayüzü içeren paket programlardır. Bu yazılımlar, coğrafi verileri etkili bir şekilde işlemek ve coğrafi analizler gerçekleştirmek için tasarlanmıştır (Mete, 2022).

CBS yazılımları kullanım kolaylığı, güçlü konumsal analiz yetenekleri, ayrıntılı kullanım dokümantasyonları ve geniş bir kullanıcı topluluğu gibi özellikleri ile öne çıkmaktadır. Bu özellikler, kullanıcıların coğrafi verileri etkili bir şekilde yönetmelerini, analiz etmelerini ve sonuçları görselleştirmelerini sağlar. CBS'nin sunduğu geniş araç yelpazesi, farklı sektörlerden profesyonellerin ve araştırmacıların ihtiyaçlarına uygun çözümler sunar. Ayrıca, güçlü konumsal analiz yetenekleri, kullanıcılara coğrafi verileri üzerinde derinlemesine analizler yapma ve karmaşık konumsal ilişkileri anlama imkânı tanır.

Aşağıda Çevre ve Şehircilik Bakanlığı resmi sitesinden alınan görselle CBS veri altyapısına ilişkin örnek bir raster görünümü sunulmuştur (URL-2), (Şekil 3.1).



Şekil 3.1. CBS’de vektör ve raster veri modelleri

3.4.2 Buffer ve near analizleri

"Tampon analizi" (Buffer analysis) ve "Yakınlık analizi" (Near analysis) CBS ve coğrafi analizlerde kullanılan iki farklı kavramdır, ancak genellikle benzer bağlamlarda kullanılırlar.

Tampon Analizi: Tampon analizi, belirli bir nokta, çizgi veya alan etrafında belirli bir uzaklık içindeki bölgeleri belirlemek için kullanılır. Bu, bir konumun etrafında dairesel bir tampon oluşturarak, bu tampon içindeki diğer detayları belirleme işlemi olup temelde bir konumun etki alanını belirleme amacına hizmet eder. Örneğin, bir okulun etrafındaki 1 km’lik bir tampon bölgesi içindeki diğer detayları belirlemek denilebilir.

Yakınlık Analizi: Yakınlık analizi, genellikle bir konumun diğer konumlarla olan mesafesini veya yakınlığını değerlendirmek için kullanılır. Tampon analizinden daha genel bir terim olup, belirli bir uzaklık içindeki detayları belirlemenin yanı sıra genel olarak konumların birbirlerine olan uzaklık ilişkilerini inceleyebilir ve belirli bir konumun diğer konumlarla olan mesafesini ölçme amacına hizmet eder. Örneğin, belirli bir resmi kurum binasının diğer resmi kurumlara olan mesafesini değerlendirmek.

Sonuç olarak; Tampon analizi, bir konumun etki alanını içeren dairesel bir bölgedir. Yakınlık analizi ise belirli bir konumun diğer konumlarla olan mesafeleridir. Bir diğer ifadeyle tampon analizi belirli bir etki alanını belirlerken, yakınlık analizi daha genel olarak konumların birbirlerine olan uzaklık ilişkilerini değerlendirmektedir.

3.5 Taşınmaz Değerlemesinde Makine Öğrenimi Yöntemleri

Makine Öğrenimi Teknikleri bilgisayar sistemlerinin kendi deneyimlerinden öğrenerek algoritma ve sistemlerinin çalışma performanslarını iyileştirmek ve optimize etmeye yönelik bir çalışma alanıdır. Makine Öğrenimi Teknikleri denetimli öğrenme ve denetimsiz öğrenme olmak üzere iki kategoriye ve bazı öğrenme alt disiplinlerine ayrılır. Bu disiplinler;

- Denetimli öğrenme; bir çıktı değişkenini tahmin edebilen regresyon ve verileri gruplandırma ve sınıflandırma
- Denetimsiz öğrenme; verileri gruplara atayarak kümeleme ve verileri daha analıdır hale getirmek için veri seti özellik sayısı azaltmaya yönelik boyutsal azaltma
- Güçlendirme öğrenme; geri bildirim alınarak yapılan öğrenme türü
- Yarı denetimli öğrenme; geniş veri setlerinden yararlanılarak denetimli ve denetimsiz öğrenmenin birleştirilmesi
- Transfer öğrenme; başka bir öğrenmede elde edilen sonuçların başka bir öğrenmede kullanılması
- Derin öğrenme; çok sayıda ve çok katmanlı veri ile sağlanan öğrenme
- Evrişimli sinir ağılar; görsel veri ile ve daha çok görüntü işleme ile olan öğrenme (CNN'ler örnek verilebilir)
- Rekürren Nöral ağılar; zamana bağlı veya sıralı veriye bağlı öğrenme

Genel olarak bu öğrenme türleri veri türüne ve uygulamanın amacına göre değişmektedir. Bu çalışmada, taşınmaz fiyatlarının tahmin edilmesine yönelik bir çıktı değişkeninin tahmini sağlandığından çalışmada öğrenme türü denetimli öğrenmedir.

Taşınmaz değerlemede geleneksel, istatistiksel ve ÇKKV yöntemleri kapsamında uygulamalar yapılmaktadır. Makine Öğrenimi Tekniklerinin bu yöntemlere göre pek çok avantajı bulunmaktadır. Bunlar;

- Geleneksel yöntemlere göre büyük miktarda taşınmaz özelliklerine ilişkin veriyi eğitebilir ve diğer yöntemlere göre daha kapsamlı sonuçlar üretilmesini sağlayabilir.
- Taşınmaz değerlendirme süreci non-lineer bir süreçtir bu nedenle karmaşık yapıları çözümleyerek non-lineer öğrenme gerçekleştirebilir.
- Değerlemeye etki eden faktörler arasında korelasyonun belirlenmesinde, hangi faktörlerin daha belirleyici olduğunu otomatik olarak öğrenilmesinde, en fazla etkiyi gösteren faktörün ağırlığının tespitinde ve özellik seçiminde etkin çözümler geliştirilebilir.
- Otomatik öğrenme ve test sağlayarak insan müdahalesi olmayan bilimsel ve objektif sonuçlar üretebilir.
- Makine öğrenim tekniklerinin diğer yöntemlere göre iyileştirilmesi, performansı artırılabilmesi ve optimizasyonu sağlanabilir.

3.5.1 Hiper-optimize edilmiş makine öğrenimi

Makine öğreniminin taşınmaz değerlemesinde kullanılmasının pek çok avantajları içinde kullanılan algoritmaların iyileştirilebilmesi ve optimizasyonu değerlendirme sonuçlarının başarısı açısından oldukça önemlidir. Bu kapsamda son yıllarda "Hiper-Optimize edilmiş Makine Öğrenimi" ifadesi sıklıkla kullanılmaktadır.

Oluşturulan bir makine öğrenimi modelinin en iyi performansı elde etmek için hiperparametre değerlerinin hassasiyetle ayarlandığı bir durumu ifade etmek için hiperparametre optimizasyonu kullanılmaktadır. 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 bazı teknikler bulunmaktadır. Bu optimizasyon tekniklerine grid search, random search, bayesian optimizasyon örnek verilebilir. Bu teknikler Hiper-Optimize edilmiş model için iyileştirilmiş sonuçlar elde edilmesini sağlamaktadır. Optimizasyon sürecindeki aşırı iyileştirilmesi sonucu aşırı uyum göstermesi riski de bulunmaktadır. Bu nedenle veri sayısının çok olması ve model için gerçek verilere genel olarak uyarlanması dengeli bir yaklaşım gösterecektir.

3.5.2 Hiperparametre optimizasyonunda bayes tekniği

Hiperparametre optimizasyonunda kullanılan bir teknik olan Bayesian optimizasyonu "objektif fonksiyon" ile çalışmaktadır. Bu "objektif fonksiyon" modelin performansını ölçerek modelin en iyi sonuca ulaşmasını sağlayan hiperparametre değerlerini bulmayı amaçlamaktadır.

Bayes optimizasyonu, hiperparametrelerin muhtemel dağılımları hakkında bir tahmin oluşturan "prior" (önceki) bilgiye sahiptir. Optimize edilecek modelin performansını ölçen bir objektif fonksiyon belirlenir. Fonksiyon, optimize edilmek istenen modelin hata oranı, doğruluk veya başka bir performans metriğini içermektedir. Bayesian 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. Bayesian optimizasyon hiperparametre uzayında dolaşarak objektif fonksiyonunun maksimumunu araştırır. Modelin prior (önceki) bilgi ve tahminlerini kullanarak model için en iyi hiperparametre değerlerini tahmin eder. Hiperparametre optimizasyonu algoritması uygulanırken işlem adımları şöyle özetlenebilir (Kalliola vd., 2021). Bunlar;

- Amaç fonksiyonunun f olasılık modeli oluşturulur,
- Olasılık modelinde en iyi performansı gösteren hiperparametreleri bulunur,
- Bu hiperparametrelere amaç fonksiyonuna uygulanarak performans elde edilir,

- Yeni sonuçları içeren olasılık modeli güncellenir,
- Maksimum yineme veya maksimum hesaplama süresine ulaşılan kadar adımlar tekrarlanır,

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

3.6 Makine öğrenim algoritmaları

Literatürde taşınmaz değer tahmininde modellerin değiştirilmesi veya hiperparametre değerlerinin gerçek durum fiyat tahmini için ayarlanması konusunda çok az çaba sarf edilmiştir (Kalliola vd., 2021).

Bu çalışmada Bayesian tekniği ile hiperparametre optimizasyonlu makine öğrenme algoritmaları kullanılmıştır. Bu bölümde Hiperparametre Optimizasyonu, Bayesian Tekniği ve uygulanan algoritmalar (Topluluk Regresyonu, Çekirdek Regresyonu, Doğrusal Regresyon, Destek Vektör Regresyonu ve İkili Karar Ağacı Regresyonu) tanıtılmaktadır.

3.6.1 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 zayıf yönlerini güçlendirmek, modelin genel tahmin doğruluğunu artırmak ve veri setindeki verileri karmaşıklığı ve değişkenliğini ele almak için kullanılır. Topluluk regresyonunun temel yöntemleri bulunmaktadır. Bunlar:

- *Bagging yöntemi*; farklı örneklemelerden oluşturulan alt veri kümeleri için ayrı regresyon modelleri oluşturulur ve eğitilen bir dizi modelin tahminlerinin ortalaması alınarak güçlü bir final tahmin sonucu elde edilmesiyle gerçekleştirilir.

- *Boosting yöntemi*; düşük doğruluğa sahip bir modelin güçlendirilmesi için daha çok hata yapan verilerin daha fazla eğitilmesi prensibine dayanmaktadır.
- *Stacking yöntemi*; Boosting modelinin aksine modellerin güçlü yanları birleştirilerek daha güçlü bir model elde edilmesi sağlanmaktadır.
- *Voting Regressor*; Farklı regresyon modellerinin tahminlerin ortalaması veya ağırlıklı ortalaması kullanılarak güçlü ve sağlam bir tahmin modeli elde edilmesi sağlanmaktadır.

3.6.2 Çekirdek regresyonu

Çekirdek regresyonu, veri setindeki karmaşık ilişkileri ve desenleri modellemek gibi bir regresyon problemine çözüm getirmek için kullanılan non-parametrik bir yaklaşımdır. Özellikle çekirdek regresyonu; gürültülü ve karmaşık veri setlerinde ve non-parametrik regresyon problemlerinde kullanılabilir.

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.

Çekirdek regresyonu için temel denklem Eşitlik 3.3'te ifade edilmiştir.

$$\hat{f}(x) = \sum_{i=1}^n w_i \cdot K(x, x_i) \quad (3.3)$$

$\hat{f}(x)$: 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.

3.6.3 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 3.4'teki gibi ifade edilir.

$$Y = \beta_0 + \beta_1 X + \varepsilon \quad (3.4)$$

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

3.6.4 Destek vektör makineleri regresyonu

Destek Vektör Makineleri (DVM), 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).

Temelde, Destek Vektör Makinelerinin bir regresyon versiyonu olan Destek Vektör Makineleri, lineer olarak ayrılabilirlik ve ayrılabilirlik olarak iki şekilde kullanılmaktadır. Özellikle non-lineer regresyon problemleri söz konusu olduğunda bu regresyon problemlerini çözmek için sınıflandırmanın gerçekleştirilmesi ve gürültülü veri setlerinde güçlü tahminler elde edilmesine yönelik tasarlanmıştır.

DVM 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 non-lineer problemlerde kernel fonksiyonlarını kullanarak ilişkileri modelleyebilir. Non-lineer problemlerde çalışma prensibi, örnek uzayını, lineer olarak sınıflandırabileceği bir yüksek boyuta aktarmak ve farklı örnekler arasındaki maksimum mesafenin bulunmasını sağlamaktır (Demirci, 2019). Bu durumda mesafeyi maksimum yapan ve sınıflandırmadan oluşan hataları minimize edecek bir hata toleransı parametresi gereklidir. C parametresi marjın genişliğini kontrol ederek regresyon modelinin marj içindeki verilere olan uyumluluğunu göstermektedir.

DVM temel regresyon fonksiyonu Eşitlik 3.5'te şöyle ifade edilebilir:

$$f(x) = \sum_{i=1}^n (w_i \cdot \varphi(x_i)) + b \quad (3.5)$$

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

3.6.5 İkili karar ağacı regresyonu

Karar ağacı öğrenmesi veri setini kullanarak kararlar veren ve bu kararları ağaç yapısında temsil eden istatistik, veri madenciliği ve makine öğrenimi uygulamalarında kullanılan tahmine dayalı bir modelleme tekniğidir. Karar ağaçları açıklığı ve basitliği sebebiyle dünyada en yaygın kullanılan makine öğrenme algoritmalarıdır (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 3.6'da şöyle ifade edilebilir:

$$f(x) = h_1(x, \theta_1) + c_1 \cdot h_2(x, \theta_2) + \dots + c_n h_n(x, \theta_n) \quad (3.6)$$

$f(x)$: 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.

3.7 Makine öğrenim algoritmalarının başarımları (performans) metrikleri

Veri seti üzerindeki makine öğrenim algoritmaları kullanılarak tahminler yapılır ve tahminlerin başarımlarının ölçülmesi için performans metrikleri gereklidir. Bu çalışmada başarımları metrikleri olarak; R^2 (R-Kare), MSE (Ortalama Hata Karesi), MAE (Ortalama Mutlak Hata), RMSE (Ortalama Hata Karesinin Kökü) ve MARE/MAPE (Hata Mutlak Yüzdesi) başarımları metrikleri kullanılmıştır. MSE, gerçek değer ve tahmin değeri arasındaki farka ilişkin tüm sapmaların karelerinin toplanmasıyla bulunan değerin ortalamasının hesaplanmasıyla tahmin performansının analizini sağlamaktadır (Garip, 2017). R^2 , eğitim veri seti ile kurulan matematiksel modelin test verileri üzerinde başarımlarını ölçen bir performans ölçөгüdür. RMSE sıklıkla kullanılan başarımları performans ölçütlerinden biri olarak, modelin tahmin ve gerçek değeri arasındaki farkının tespit edilmesi ile aralarındaki bu farkın hatanın büyüklüğünü ölçen bir metriktir. MARE, bir tahminin gerçek değeri olan yüzde hatalarının ortalamasını ölçen bir başarımları performans ölçütüdür. MAE, modelin gerçek değeri göre ne kadar hata yaptığını gösterir. R^2 , MSE, RMSE, MAE ve MARE/MAPE formülleri sırasıyla (3.7), (3.8), (3.9), (3.10) ve (3.11) eşitliklerinde verilmiştir.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.7)$$

$$MSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.8)$$

$$RMSE = \sqrt{MSE} \quad (3.9)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.10)$$

$$MARE/MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{|y_i|} \quad (3.11)$$

Ayrıca taşınmaz değerlemesine ilişkin çalışmalarda model başarımlarının hesaplanması için The International Association of Assessing Officers (IAAO) 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 (3.12)'de, m değeri Eşitlik (3.13)'te ve PRD değeri Eşitlik (3.14)'te ifade edilmiştir.

$$COD = \frac{100}{m} \times \left(\frac{\sum_{i=1}^n \frac{|y_i - m|}{|y_i|}}{n-1} \right) \quad (3.12)$$

$$m = \text{median}(y_i / \hat{y}_i) \quad (3.13)$$

$$PRD = \frac{\text{mean}(y_i / \hat{y}_i)}{\sum_{i=1}^n y_i / \sum_{i=1}^n \hat{y}_i} \quad (3.14)$$

BÖLÜM IV

KÜÇÜK ÖLÇEKLİ KENTLERDE TOPLU TAŞINMAZ DEĞERLEME, YOZGAT KENTİ ÖRNEĞİ ÜZERİNDE ANALİZİ

Dünya’da ve Türkiye’de geçmişten bugüne taşınmaz değerlendirme amaçlı çalışmalar yapılmış ve literatürde yerini almıştır. Taşınmaz değerlendirme teknolojinin gelişimine bağlı olarak seneler içerisinde kendi içerisinde de büyük bir dönüşüm ve gelişim yaşamıştır. Gerçekleşen çalışma yöntemlerine bakıldığında ülkeler arasında değerlendirme biçimi açısından farklılıklar olsa da ülkelerin sistemleri ve değerlemeyi ele alış yöntemlerinin mantığı benzer niteliktedir.

Tekil değerlendirme; Geleneksel yöntemlerdir. Toplu değerlendirme ise; İstatistiksel, Çok Kriterli Karar Verme, CBS ve Modern Yöntemler olarak dörde ayrılmaktadır. Özellikle bilgisayar ve internet kullanımı yaygınlaştıkça taşınmaz değerlendirme yöntemleri hız kazanarak daha adil, bütüncül ve kapsamlı bir hale bürünmüştür. Bu bağlamda tekil değerlendirme yöntemlerinin yerini çok sayıda taşınmazın aynı anda ve yüksek doğruluklarda değer tahmininin yapılabildiği gelişmiş bir yaklaşım ortaya çıkmıştır. Bu yaklaşımlar istatistiksel ve modern yöntemler olarak adlandırılmış olup tekil değerlendirme sisteminden, toplu (bütüncül-bölgesel) taşınmaz değerlendirme sistemlerine geçilmiştir. Bilgisayar destekli bu çalışmalara CAMA (Computer Assisted Mass Appraisal) denmektedir. Bu metotla toplu taşınmaz değerlendirme sistemleri birçok ülkede yaygınlaşmış ve uygulanmaya başlamıştır.

Tez çalışmasında, toplu taşınmaz değerlendirme sistemleri; ilgili mevzuatlar, yöntemler ve modeller açısından değerlendirilmiştir. Özellikle gayrimenkullerin yapısal ve mekânsal özellikleri toplanan verilerin CBS tabanlı programda veri seti uygulanmış, teknik analizler yapılmış ve oluşturulan veri seti makine öğrenim teknikleri ile işlenmiştir. İşlenen verilerin yüksek doğruluk ve kısa sürelerde elde edilebilmesi amacıyla da Makine Öğrenimi Teknikleri Bayes Tekniği ile Hiper-Optimize edilerek eğitilmiştir.

Bu çalışmada, taşınmaz değerlerinin toplu bir şekilde tahmin edilmesi için uygun yöntemler ve tekniklerin belirlenmesi üzerinde durulmuştur. Taşınmazların özellikleri ve piyasa değerleri, dikkatlice kategorize edilerek değer tahmininin gerçekleştirilebilirliği

vurgulanmıştır. Yapay zeka teknikleri, küçük ölçekli kentlerde toplu taşınmaz değerlemesinin değişimini ele alarak geleceğe yönelik öğrenme imkanı sağlamış ve başarılı tahminlerin oluşturulabilirliği test edilmiştir. Bu durum, maliklerin, uzmanların ve yatırımcıların geleceğe güven duymalarını sağlamak, yatırımlarını planlamak ve yerel yöneticilerin sosyal konut ve altyapıya yönelik yeni planlama stratejilerini değerlendirmelerine önemli bir katkı sunacaktır.

Çalışmanın bu bölümünde ise; uygulamanın gerçekleştirilmesi için uygulama sahasının belirlenmesi, toplu taşınmaz değerlemede ele alınan kriterlerinin belirlenmesi, değerlendirme modeli için veri toplama ve yapıların yapısal ve konumsal özelliklerine ilişkin veri seti oluşturulması ve analizi, veri setlerinin Makine Öğrenimi Teknikleri için puanlanması, değerlendirme modellerinin oluşturulması, model performanslarının karşılaştırılması, bulgular, katkılar ve sonuç bölümlerine yer verilmiştir.



4.1 Uygulama Sahasının Belirlenmesi ve Tanıtılması

Uygulama Sahasının Belirlenmesi: Çalışma alanı olarak Yozgat kent merkezi seçilmiştir. 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 aktarılmıştır. Çalışmalar CBS tabanlı programda yürütülerek en son programlama dili programlarında Makine Öğrenim Tekniklerinde Bayes Tekniği kullanılarak Hiper-Optimizesi ile eğitilmiştir.

Uygulama Sahasının Tanıtılması: Yozgat ili 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 ili nüfusunun 2021 yılı itibarıyla %76,35'i şehirlerde yaşamakta ve toplam nüfusu 419.095'tir. İlin yüzölçümü 13.690 km² olup km²'ye 31 kişi düşmektedir (URL-3). 2023 yılında tahmini olarak 416 bin 582 olarak kaydedilen nüfusun 209 bin 814'ünü erkek ve 208 bin 628'ini ise kadınlar oluşturmaktadır.

Şekil 4.1'de çalışma sahası seçilen il merkezinin lokasyon haritası görünümü gösterilmiştir.

YOZGAT İLİ LOKASYON HARİTASI



Şekil 4.1. Türkiye haritasında Yozgat kentinin lokasyonu

4.2 Uygulama Sahasına Yönelik Taşınmaz Değerleme Kriterlerinin Belirlenmesi

Çalışmada gerçekleştirilen literatür araştırması, taşınmaz değerleme mevzuatı ve ulusal-uluslararası standartlara göre belirlenen kriterler doğrultusunda taşınmaz değerini etkileyen faktörler aşağıdaki Çizelge 4.1’de sınıflandırılmıştır. Değerlendirilen analizler sonucunda incelenen araştırmalara göre, sadece yapısal verilerin taşınmaz değerini belirlemede yeterli değildir. Bu bağlamda, mekânsal analizlerle belirlenen konumsal veriler, değeri etkileyen kriterleri tamamlamaktadır. Çalışma kapsamında, Yozgat kentinde toplu taşınmaz değerleme yapabilmek amacıyla Makine Öğrenimi Teknikleri ve CBS kullanılarak doğruluğu yüksek tahmin sonuçlarına ulaşılmak istenmektedir. Bu doğrultuda, taşınmaz değerlemesini etkileyen kriterler, Çizelge 4.1’de gösterilen şekilde taşınmazlara ait elde edilen verilerin kategorize edilerek gösterilmesi ve detaylı bir analizden geçirilerek istenen doğruluklarda değerlendirme yapılması sağlanmıştır.

Çizelge 4.1. Çalışmada kullanılan ve değerlemeye etki eden kriterler

MEKÂNSAL VERİLER		YAPISAL VERİLER
Ağaçlandırma Alanları ▪ Parklar ▪ Ormanlık alanlar ▪ Bitki topluluğu	Resmi Kurum Alanları ▪ Adliye binası ▪ Belediye ▪ Müdürlükler ▪ Bankalar	Taşınmaz Özellikleri ▪ Taşınmaz fiyatı ▪ Metrekare (Brüt ve Net) ▪ Oda sayısı ▪ Bina yaşı ▪ Bulunduğu kat ▪ Toplam kat ▪ Isıtma ▪ Banyo sayısı ▪ Taşınmaz cephesi
Sosyokültürel Alanlar ▪ Sinema ▪ Spor tesisleri ▪ Müze-Konak ▪ Kültür merkezleri ▪ İbadethaneler	Sağlık Alanları ▪ Hastane ▪ Sağlık ocağı ▪ Eczane	
Ticaret Alanları ▪ Pazar yerleri ▪ Sanayi tesisleri ▪ AVM	Eğitim Alanları ▪ Kreş-Anaokulu ▪ İlköğretim ve Ortaöğretim ▪ Üniversite	
	Hızlı Tren Alanı ▪ Hızlı tren garı	

4.3 Toplu Taşınmaz Değerleme için Veri Toplama Süreci

Toplu taşınmaz değerlemede veri toplama süreci 5 aşamada uygulanmıştır. Bunlar;

1. 2022 ve 2023 yıllarına ait seçilen taşınmazların yapısal özellikleri (bina no, taşınmaz fiyatı, alan (brüt-net), oda sayısı, bina yaşı, bulunduğu kat, toplam kat sayısı, banyo sayısı ve ısıtma sistemi) çevrimiçi satış sitelerinden toplanmıştır.
2. Yapısal özellikleri çevrimiçi sitelerden toplanan verilerin Yozgat ili imar planı kapsamında CBS ortamında konumları belirlenmiştir.
3. 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) oluşturularak veri seti modellenmiştir.
4. 2022 ve 2023 yıllarına için taşınmazların excel ortamında yapısal ve konumsal özellikleri modellemeye uygun hale getirilmiştir.
5. Toplu taşınmaz değerlemenin yüksek doğrulukta tahmin edilebilmesi ve sürecinin analizi sağlanabilmesi amacıyla makine öğrenim tekniklerinden regresyon analizlerinin Bayes Tekniğiyle Hiper-Optimize edilerek iyileştirilmesi sağlanmıştır.

4.3.1 Yapısal özelliklere yönelik veri setinin oluşturulması

Uygulama aşamasında, Yozgat kenti imar planına dayanarak iki ayrı emlak web sitesinden elde edilen 2022 ve 2023 yıllarına ait 600 adet yapının özelliklerine ilişkin yapısal veriler toplanmıştır (URL-4; URL-5). 2022 ve 2023 yıllarına ait yapısal verileri içeren veri seti Çizelge 4.2'de sunulmuştur.

Çizelge 4.2. 2022 ve 2023 yıllarına ait yapısal veriler (600 konuttan 20 tanesi).

Bina No	İlan Tarihi (gg.aa.yyyy)	Julian Tarih	<u>YAPISAL ÖZELLİKLER</u>									
			Alan(Brüt) m ²	Alan(Net) m ²	Oda Sayısı (..+..)	Bina Yaşı	Bulunduğu Kat	Kat Sayısı	Isıtma (Doğalgaz vs.)	Banyo Sayısı	Cephesi (D-B-K-G)	Taşınmaz Fiyatı (₺)
B1	13.05.2022	2022133	50	50	2	10	3	5	8	1	6	550,000
B2	20.05.2022	2022140	150	145	4	20	2	7	5	1	6	630,000
B3	9.06.2022	2022160	80	72	3	5	1	5	8	1	10	925,000
B4	15.06.2022	2022166	130	118	4	30	8	8	10	1	6	800,000
B5	17.06.2022	2022168	142	120	4	1	4	5	10	1	8	1,490,000
B6	28.06.2022	2022179	450	300	5	20	1	2	8	2	10	2,500,000
B7	27.07.2022	2022208	130	130	4	25	5	5	8	2	10	870,000
B8	31.07.2022	2022212	130	118	4	1	5	6	8	2	4	1,200,000
B9	6.08.2022	2022218	48	40	2	10	0	5	8	1	10	550,000
B10	13.08.2022	2022225	364	345	7	1	1	3	8	4	10	5,650,000
BB01	15.06.2023	2023166	65	60	3	3	4	6	8	1	10	1,325,000
BB02	15.06.2023	2023166	35	30	2	10	0	9	8	1	6	1,050,000
BB03	15.06.2023	2023166	60	55	3	3	4	6	10	1	10	1,200,000
BB04	15.06.2023	2023166	110	90	4	10	1	5	8	1	8	1,300,000
BB05	16.06.2023	2023167	280	250	5	0	1	2	8	2	6	5,150,000
BB06	17.06.2023	2023168	135	130	4	0	6	8	8	2	8	2,100,000
BB07	18.06.2023	2023169	145	135	4	15	2	8	8	2	10	1,500,000
BB08	18.06.2023	2023169	66	55	3	0	2	3	8	1	10	1,250,000
BB09	18.06.2023	2023169	65	55	2	0	6	6	8	1	8	1,080,000
BB10	19.06.2023	2023170	65	60	3	0	3	5	8	1	8	1,050,000

4.3.2 Konumsal özelliklere yönelik veri setinin oluşturulması


Konumsal özelliklere ilişkin verileri oluşturmak için excelde verileri işlenen CBS ortamında sayısallaştırılan Yozgat Merkez veri setindeki konutların konumları analiz edilmiştir. Çizelge 4.3'te konumsal özelliklere ilişkin mekânsal analiz (uzaklık analizi) excel formatında gösterilmiştir.

Çizelge 4.3. 2022 ve 2023 yıllarına ait konumsal veriler (600 konuttan 20 tanesi).

Bina No	İlan Tarihi (gg.aa.yyyy)	Julian Tarih	KONUMSAL ÖZELLİKLER							
			Ağaçlan dırma_Near (m)	Sağlık_Near (m)	Eğitim_Near (m)	Hızlı Tren_Near (m)	Resmi Kurum_Near (m)	Sosyok ültürel_Near (m)	Ticaret_Near (m)	Taşınmaz Fiyatı (₺)
B1	13.05.2022	2022133	481.76	600.69	261.74	6531.65	1402.67	461.40	454.20	550,000
B2	20.05.2022	2022140	226.06	910.56	489.76	6491.29	966.33	174.06	423.01	630,000
B3	9.06.2022	2022160	473.19	626.78	577.60	6442.88	453.74	478.62	640.95	925,000
B4	15.06.2022	2022166	77.03	881.86	343.07	6379.21	1344.35	629.17	549.91	800,000
B5	17.06.2022	2022168	410.66	433.68	521.56	6369.52	1159.56	186.09	458.06	1,490,000
B6	28.06.2022	2022179	360.81	716.24	238.58	5952.66	486.78	542.56	682.41	2,500,000
B7	27.07.2022	2022208	357.23	85.46	738.38	6459.49	843.19	666.13	397.24	870,000
B8	31.07.2022	2022212	416.20	427.70	86.59	5697.37	591.49	931.84	521.78	1,200,000
B9	6.08.2022	2022218	381.12	197.70	315.20	7973.53	460.64	77.96	111.51	550,000
B10	13.08.2022	2022225	359.20	671.27	134.01	7782.71	1483.79	379.32	56.90	5,650,000
BB01	15.06.2023	2023166	185.46	463.91	250.70	7926.65	292.14	333.76	507.08	1,325,000
BB02	15.06.2023	2023166	481.65	487.26	428.18	5796.50	1262.39	751.49	914.57	1,050,000
BB03	15.06.2023	2023166	476.48	284.59	435.89	6515.38	428.09	940.01	499.15	1,200,000
BB04	15.06.2023	2023166	349.43	160.82	373.96	6982.72	420.57	1050.42	620.40	1,300,000
BB05	16.06.2023	2023167	175.96	258.03	594.80	7775.96	957.41	853.25	150.45	5,150,000
BB06	17.06.2023	2023168	174.91	228.68	224.50	5838.99	1376.79	727.38	342.78	2,100,000
BB07	18.06.2023	2023169	282.01	889.85	715.39	5450.36	679.31	229.83	188.28	1,500,000
BB08	18.06.2023	2023169	458.47	441.66	322.91	7354.31	915.03	269.36	84.46	1,250,000
BB09	18.06.2023	2023169	116.38	339.00	88.87	6199.25	370.83	622.38	666.16	1,080,000
BB10	19.06.2023	2023170	294.55	255.61	304.60	5548.40	795.28	457.90	269.64	1,050,000


İnternet üzerinden çevrimiçi web sitelerinden elde edilen yapısal özellikler ile ilgili veriler, CBS ortamına ilişkilendirme (join) kullanılarak aktarılmıştır. Yapısal özellikleri bu şekilde aktarılan taşınmazların konumları, internet sitesinden alınmıştır (Şekil 4.2). Bu konumlar, sayısallaştırılarak CBS ortamındaki harita üzerindeki ID numaraları yardımıyla öznitelik tablosu üzerindeki ID numaralarıyla eşleştirilerek (match) konum ve kimlik bilgisi tanımlanmıştır. Böylece internet sitelerinden toplanan verilerin

konumları ve yapısal özellikleri öznitelik tablosuna aktarılarak mekânsal analizler gerçekleştirilmiştir.




Şekil 4.2. Web sitesi üzerinden yapısal özellikleri belirlenmiş taşınmazın konumu

CBS ortamında sayısallaştırılmış veri tabanı, konum ve öznitelik verilerini içermektedir. Konumsal verileri belirlemek amaçlı her konut için bir kimlik numarası (ID) atanır. Bu ID numaraları üzerinde sorgulama yapılabilir ve öznitelik bilgilerine erişilebilir. Şekil 4.3'te konumsal özelliklere ilişkin konumsal analiz üretim aşaması ve binalara ID yükleme kısmı (open attribute table) görülmektedir. Bu kısımda excel'deki yapısal-konumsal veriler çekilerek ID'ler oluşturulup her bir binanın öznitelik ve uzaklık verileri ile eşleştirme işlemi yapılmaktadır.




Şekil 4.3. Yozgat kent merkezi sayısallaştırılmış haritası

Belirlenen konum bilgilerine göre, mekânsal analiz işlemleri gerçekleştirilir. Her bir taşınmaz için mekânsal detaylar, tampon analizi kullanılarak ölçülmüştür. Tampon analizi, coğrafi bir veri tabanındaki konum verileri etrafında belirli bir mesafede tampon bir bölge oluşturma işlemidir (Ünel vd., 2023). Bu analiz, taşınmaz değerlendirme sürecinde coğrafi verilerin belirli bir mesafedeki taşınmaza olan etkisini incelemek için kullanılan bir mekânsal analiz yöntemidir. Bu yöntem, bir taşınmazın çevresinde yer alan belirli bir mesafe kapsamında tampon bölge oluşturularak bu bölgede yer alan özellikleri analiz etmektedir. Oluşturulan bu mekansal analizler, konumsal karar alma süreçlerini iyileştirmek için veri setinde kullanılmaktadır. Bu bölümde değerlendirme sürecinde yer alan önemli kriterlerden olan konumsal kriterlerin Yozgat kent ölçeğinde dağılımları tampon analizleri ile incelenerek haritalandırılmıştır.




Şekil 4.4. Ağalandırma alanlarına olan uzaklıkların gösterimi

Ağalandırma alanları, taşınmaz değeriendirmesinde önemli bir kriter olup bu alanlara yakınlığın taşınmazın değeri üzerinde olumlu etkisi bulunabilir. Özellikle, bir taşınmazın ağalandırma sahasına yakınlığı taşınmazın görsel ve çevresel değeri artırabilir. Yozgat kenti genelinde yeşil alan durumu genellikle iyidir (Şekil 4.4).




Şekil 4.5. Eğitim alanlarına olan uzaklıkların gösterimi

Eğitim kurumlarına yakınlık, eğitim alan çocuk sahibi aileler için cezbedici bir özellik olarak kabul edilir. İyi bir eğitim altyapısına sahip olmak, çocukların okula erişimini kolaylaştırır ve genel yaşam kalitesini yükseltir. Bu nedenle, bir taşınmazın eğitim kurumlarına yakın olması, özellikle aileler için değerli bir özellik olarak algılanabilir. Özellikle Yozgat kenti için, eğitim kurumlarının homojen bir şekilde dağıldığı ve kentin genelinde yeterli düzeyde bulunduğu göz önüne alındığında, bu durum taşınmazların değerini artırabilir. (Şekil 4.5).




Şekil 4.6. Resmî kurum alanlarına olan uzaklıkların gösterimi

Taşınmaz değerlendirme sürecinde idari ve resmi kurum alanlarına yakınlığın, taşınmazın değeri üzerinde olumlu bir etkisi olduğu belirtilmektedir. Özellikle resmi kurum alanları çevresinde entegre şekilde bulunan ticari ve ofis amaçlı kullanımları çevresinde potansiyel bir cazibe bölgesi oluşturduğu ifade edilmektedir. Yozgat kentinde resmi (Şekil 4.6).




Şekil 4.7. Sağlık alanlarına olan uzaklıkların gösterimi

Sağlık tesisleri, toplumun her kesimi için büyük öneme sahip olup ulaşılabilirlik ve erişilebilirlik taşınmazların değerini etkileyen faktörler arasında bulunmaktadır. Sağlık hizmetlerine yakın olmanın, taşınmaz değerlendirme sürecindeki önemi çok yönlü bir şekilde değerlendirilebilir. Ayrıca, kronik bir rahatsızlığı olan bireyler için sağlık tesislerine yakın olmanın önemi büyüktür ve bu durum, sağlık kuruluşlarına yakın bir taşınmazın talep ve dolayısıyla değerini artırabilir. Yozgat kentinde iki büyük hastane bulunmaktadır. Bunlardan biri Türkiye'nin ilk Şehir Hastanesi, diğeri ise Bozok Eğitim ve Araştırma Hastanesi'dir. Bu sağlık tesislerine yakınlığın, taşınmaz değerlerini etkileme potansiyeli, Yozgat kentindeki sağlık altyapısının bir göstergesi olarak dikkate alınabilir (Şekil 4.7).




Şekil 4.8. Sosyo-Kültürel alanlara olan uzaklıkların gösterimi

Sosyokültürel tesisler, kent sakinlerinin sosyalleşerek yaşam kalitesini etkileyen önemli kriterler arasında yer almaktadır. Tiyatro, sinema, spor alanları gibi sosyal tesisler veya ibadethane, kütüphane, müze, konak gibi kültürel tesislerin bulunması, taşınmazın değerini artıran etmenlerden biridir. Bu alanlar bölgede yaşayanların yaşam kalitelerine ve sosyal hayatlarına katkı sağlar ve bu nedenle konut veya iş yeri arayışında olanlar tarafından aranan bir özellik olarak değerlendirilebilir (Şekil 4.8).



Şekil 4.9. Ticaret alanlarına olan uzaklıkların gösterimi

Taşınmaz değerlendirme sürecinde ticaret yerlerine olan yakınlığın büyük bir önemi vardır. Ticaret alanları başta merkezi iş alanları olmak üzere bölgedeki ekonomik canlılığı temsil ederler, bu nedenle taşınmazın değerini etkileyen önemli kriterler arasında yer alırlar. Ticaret alanlarına yakın olan taşınmazlar, potansiyel yatırımcılar, taşınmazı elde çıkarmak isteyen mülk sahipleri ve kiracılar için cezbedici bir özellik olarak algılanabilir. Ancak başta Merkezi İş alanları olmak üzere ticari alanlar; trafik, otopark sorunu, kirlilik ve gürültü gibi olumsuz etkenler nedeniyle değeri düşüren olumsuz etkelere sahiptir. Yozgat kentinin ticaret alanları, kentin merkezinde iş sektörlerinin yoğunlaştığı bir yapı sergilemektedir. Kentin kompakt ve küçük ölçekli olması, ticaret alanlarına kolay erişimi mümkün kılmaktadır (Şekil 4.9).



Şekil 4.10. Hızlı tren garı alanına olan uzaklıkların gösterimi

Taşınmaz değerlendirme sürecinde ulaşım alanlarına (Havalimanı-Trengarı-Otogar vs.) yakınlığın önemi oldukça büyüktür. Çünkü ulaşım alanlarına olan mesafe taşınmazın değer artışına ya da değer kaybetmesine neden olabilir. Örneklendirecek olursak havalimanına yakın olmak ulaşım kolaylığı bakımından olumlu bir etmen olsa da uçakların iniş-kalkış sesinden kaynaklanan gürültü olumsuz bir etmen olarak değerlendirilebilir. Yozgat'ta Kayseri yolu istikametindeki Divanlı mahallesine yapılan 2023 yılında seferlerine başlayan Yüksek Hızlı Tren Garı kentin taşınmaz değer artışına sebep olmaktadır (Şekil 4.10).

Tez kapsamında taşınmazlar için önce buffer(tampon) aracı sonrasında ise taşınmazların belirli mekânsal özelliklere olan mesafelerini tespit etmek amaçlı near aracı kullanılmıştır. Near aracı, coğrafi analizler, yüzey modellemesi, özellik analizi ve çeşitli diğer uygulamalarda kullanılan en yakın mesafesi hesaplamak için gerçekleştirilen bir coğrafi işlemdir. Bu işlem, bir noktanın, çizginin veya alanın diğer bir noktaya, çizgiye veya alana olan en yakın mesafesini ve bu yakınlığı sağlayan noktanın, çizginin veya alanın mesafesini hesaplar.

Near işlemi ile taşınmazların konumsal olarak değeri artıran kriterlere olan mesafeleri hassas bir nitelikte hesaplanarak makine öğrenim veri seti için kullanılacak öznitelik tablosuna aktarılmıştır. Sonuçta yapısal özellikler ve konumsal özelliklere ilişkin veri setleri Makine Öğrenimi Tekniklerinde analiz edilmek üzere sınıflandırılmıştır.

4.4 Toplu Taşınmaz Değerlemede Hiper-Optimize Edilmiş Makine Öğrenim Teknikleri ile Modellerin Oluşturulması

Toplu taşınmaz değerlendirme için Bayes Tekniğiyle Hiper-Optimize edilmiş Makine Öğrenim Teknikleri ile Yozgat kentinin 2022 ve 2023 yıllarının taşınmaz değer tahminleri gerçekleştirilmiştir. Yapılan değer tahminleri başarımlı metrikleri çerçevesinde karşılaştırılarak değerlendirilmiştir.

Hiper-Optimize edilmiş Makine Öğrenim Teknikleri ile elde edilen tahmin sonuçları yatırımcılar, mülk sahipleri, değerlendirme uzmanları ve kent yöneticileri açısından mülk değerini bilimsel ve objektif bir şekilde belirlemede rehberlik ederek doğru karar verme süreçlerine yardımcı olacaktır.

Bu tez çalışması, literatürdeki çalışmalardan farklı bir yaklaşım sunmaktadır. Yozgat kenti bütününde toplu değer tahmininin ele alındığı bu çalışma, farklı zamanlarda elde edilen konut fiyat bilgileri üzerinden piyasadaki değişimleri öngörmek amacıyla Bayes Tekniğiyle Hiper-Optimize Edilmiş Makine Öğrenimi Tekniklerinden regresyon analizlerini gerçekleştirmeyi hedeflemektedir.

Bu kapsamda modellemeler için işlem adımları şunlardır:

- I. Verilerin yapısal-konumsal özellikleri çevrimiçi web sitelerinden temin edildi.
- II. Verilere genel bir değerlendirme yapılarak elle(manuel) 600 adet veriden birbirine benzer nitelikte olan 147 adedi teker teker uygunluk durumuna göre ayıklandı (Bunun sebebi; enflasyonist etkilerin bulunduğu yerlerde aynı özniteliklere sahip konutlarda farklı fiyatlar çıkabilmesidir).
- III. Sınıflandırma ve regresyon problemlerinin performansının artırabilmesi için öznitelik verileri min-max normalizasyonu ile normalize edildi. Böylece her öznitelik verisi ayrı ayrı 0-1 aralığına getirilerek uygulama gerçekleştirildi.
- IV. Veriler tamamen rastlantısal olarak %85 eğitim (385 konut) ve %15 test (68 konut) verisi olarak ayrıldı.
- V. %85'lik kısımda yer alan eğitim verileri; giriş-öznitelik verilerini, çıkış-hedef konut fiyatı değeri arasındaki ilişkiyi saptamak amacıyla eğitilerek üretildi.
- VI. %15'lik kısımda yer alan test verileri doğruluk testi amacıyla kullanıldı.
- VII. Bayesian optimizasyon algoritması ile her bir regresyon tekniğinin 200 iterasyonda parametre optimizasyonu ile yazılan komut çalıştırıldı.
- VIII. Bayes Tekniği ile iterasyona başlanarak iterasyon sayısı $i=200$ olarak belirlendi. İterasyon aşamasında kodlanmış program tarafından; kontrol parametreleri, güncellenip, test edilip, doğruluğuna bakıldı.
- IX. En sonunda Makine Öğrenimi Teknikleri Bayes Tekniğiyle Hiper-Optimize edilip en iyi modeli seçmektedir. Böylece elde edilen model, iyileştirilmiş ve en başarılı modeldir. Model sonuçları incelenerek başarımlar metrikleri ve yakınsama performansları karşılaştırılmalı olarak analiz edilmiştir.

4.4.1 Modelin hiperparametre optimizasyonu (bayes tekniği)

Tez çalışmasında, Bayes Tekniği ile Hiper-Optimize edilmiş Makine Öğrenimi Tekniklerinin (Topluluk Regresyonu, Çekirdek Regresyonu, Doğrusal Regresyon, Destek Vektör Makineleri Regresyonu ve İkili Karar Ağacı Regresyonu) güncel piyasa değerlerine ilişkin tahmin sonuç performansları karşılaştırılarak başarı metrikleri değerlendirilmiştir.

Bu kapsamda üretilen modelde öncelikle Çapraz Doğrulama Yaklaşımı (K-Fold Cross-Validation) gerçekleştirilmiştir. Çapraz Doğrulama; regresyon ve sınıflandırma

analizlerinde 'aşırı öğrenme' denen bir problemi ifade etmektedir. Bu problem eğitim verisinde çok iyi sonuçlar oluştururken test verisinde aşırı öğrenme sonucunda uyumsuz sonuçlar üretebilmektedir. Buna bağlı olarak model ve asıl veri sonuçları için eğitim verisi çok yüksek doğrulukta, test verisi çok düşük doğrulukta çıkabilmektedir.

Aşırı Öğrenmeyi engellemek amacıyla her bir modelde; Çapraz Doğrulama yapılarak modeller düzenlenmiştir. Bu kapsamda aşırı öğrenmeyi engellemek için örnek sayısı $K=10$ olarak belirlenip modeller tekrar eğitilmiştir. Eğitim modelindeki veriler rastgele olarak 10'a bölünüp ardından her 10 parçanın ayrı ayrı tekrar eğitilmesi ve başarı sonuçlarının tespit edilebilmesi amacıyla Ridge regresyonu (Ridge Regresyonu, aşırı öğrenmeyi azaltmak ve regresyon katsayılarını sifıra yaklaştırmak için kullanılan bir regresyon yöntemidir.) uygulanarak 'aşırı öğrenmenin' engellenmesi sağlanmıştır.

Ridge regresyonu regresyon katsayılarının büyüklüklerini sınırlar ve aşırı uydurmayı azaltır. Modelin optimum karmaşıklık düzeyini elde etmek için lambda (λ) değeri uygun bir şekilde seçilerek kullanılır. Lambda değeri regülerleştirmenin bir parçası ve regülerleştirme kuvvetini kontrol eden bir hiperparametredir. Yüksek lambda değerleri, daha fazla regülerleştirmeye ve daha basit modellere yol açar.

Ridge regresyonu matematiksel olarak (4.1)'de şu şekilde ifade edilir:

$$\sum_{i=1}^n (y_i - \beta_0 - \sum_{j=1}^p \beta_j y_{ij})^2 + \lambda \sum_{j=1}^p \beta_j^2 \quad (4.1)$$

Modelin hiper optimizasyonu için Bayes Tekniği tercih edilmiştir. Uygulamada regresyon yöntemlerinde kullanılan en iyi Bayes optimizasyonu teknikleri Çizelge 4.4'te sunulmuştur.

Çizelge 4.4. 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 ağırlıklarını tahmin etmek için kullanılan en küçük kareler yöntemidir-'), Çekirdek-Ölçek, Çekirdek-Lambda, Genişletme Boyutu Sayısı, Çekirdek-Epsilon
Doğrusal Regresyonu	Yöntem ('Lsquare-çekirdek ağırlıklarını 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

Bu tez çalışmasında uygulamada kullanılan regresyon yöntemlerinde (Topluluk, Çekirdek, Doğrusal, Destek Vektör Makineleri ve İkili Karar Ağacı) kullanılan parametreler ve anlamları;

Topluluk Regresyonu için belirtilen parametreler şu şekildedir:

- **LSBoots (Least Squares Boosting):** Least Squares Boosting, zayıf tahmincilerin bir araya getirilerek güçlü bir tahminci oluşturulmasını sağlayan bir topluluk öğrenme yöntemidir. LSBoots parametresi, bu topluluk regresyonunda kullanılacak olan zayıf tahmincilerin sayısını belirler.
- **NumLearningCycles (Number of Learning Cycles):** Topluluk regresyonunda, her bir öğrenme döngüsünde eklenen yeni tahmincilerin sayısını belirten bir parametredir.
- **LearnRate (Learning Rate):** Her bir yeni tahmincinin katkısını düzenleyen bir faktördür. Öğrenme oranı düşükse, her tahmincinin etkisi azalır ve modelin daha yavaş öğrenmesini sağlar.
- **MinLeafSize (Minimum Leaf Size):** En küçük yaprak boyutunu belirleyen bir parametredir.
- **MaxNumSplits (Maximum Number of Splits):** Maksimum bölme sayısını belirten bir parametredir.
- **NumVariablesToSample (Number of Variables to Sample):** Her bir öğrenme döngüsünde rastgele seçilen değişken sayısını belirten bir parametredir.

Bu parametreler, topluluk regresyonu modelinin yapılandırılmasında ve eğitilmesinde kullanılır. LSBoots, öğrenme döngüsü sayısı, öğrenme oranı ve diğer parametreler, modelin performansını ve genel başarısını etkileyen önemli faktörlerdir.

Çekirdek Regresyonu için belirtilen parametreler şu şekildedir:

- **LeastSquares:** Çekirdek regresyonunda, çekirdek ağırlıklarını tahmin etmek için kullanılan en küçük kareler yöntemidir. Modelin çekirdek ağırlıklarını belirlemek için kullanılır.
- **Scale:** Çekirdek genişliğini belirten bir ölçüdür. Geniş bir çekirdek genellikle daha pürüzsüz tahminler sağlar, ancak aynı zamanda daha az esneklik anlamına gelir.
- **Lambda:** Regularizasyon parametresidir. Regularizasyon, aşırı uyumun (overfitting) önlenmesine yardımcı olur. Lambda'nın artırılması, modelin aşırı uyuma karşı daha dirençli hale gelmesini sağlar.

- NumExpansionDimension: Çekirdek regresyonunda, genişletme boyutlarının sayısını belirten bir parametredir. Bu, çekirdek genişletmelerinin kaç boyutlu olduğunu kontrol eder.
- Epsilon: Regresyon modelinin hedef değerlere ne kadar yaklaştığını belirten bir tolerans parametresidir. Epsilon, tahmin hatalarının kabul edilebilir bir düzeyde olup olmadığını kontrol eder.

Bu parametreler, 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 parametreler şu şekildedir:

- LeastSquares: Doğrusal regresyon modelinde, modelin eğim ve kesim noktasını belirleyen en küçük kareler yöntemidir. Bu yöntem, gözlemler ile modelin tahmin ettiği değerler arasındaki kare hataların toplamını minimize etmeye çalışır.
- Lambda: Regularizasyon parametresidir. Regularizasyon, modelin aşırı uyum (overfitting) eğilimini azaltmaya yardımcı olur. Lambda'nın artırılması, regresyon katsayılarının büyüklüğünü kontrol ederek modelin genelleştirmesini sağlar.
- Regularization: Regularizasyon, modelin karmaşıklığını kontrol etmek için kullanılan bir tekniktir. Doğrusal regresyonun bir türü olan Ridge (L2 regularization) veya Lasso (L1 regularization) gibi farklı yöntemlere göre farklı etkilere sahip olabilir.

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 şu şekildedir:

- **BoxConstraint:** SVM regresyonunda bir düzenleme parametresidir. Bu parametre, modelin aşırı uyuma (overfitting) eğilimini kontrol etmek için kullanılır. Yüksek BoxConstraint değerleri, modelin eğitim verilerine daha fazla uymasını sağlar, ancak bu, genelleme yeteneğini düşürebilir.
- **KernelScale:** Çekirdek fonksiyonunun ölçeğini belirten bir parametredir. SVM regresyonunda kullanılan çeşitli çekirdek fonksiyonları vardır (örneğin; lineer, polinom, rbf). KernelScale, bu çekirdek fonksiyonlarının ölçeğini kontrol eder.
- **Epsilon:** Regresyon hatalarını kontrol etmek için kullanılan bir tolerans parametresidir. Modelin tahmin ettiği değer ile gerçek değer arasındaki hata, bu epsilon değeri ile karşılaştırılır. Epsilon, regresyon hatasının kabul edilebilir bir düzeyde olup olmadığını belirler.
- **KernelFunction:** SVM regresyonunda kullanılan çekirdek fonksiyonunu belirten parametredir. Lineer, polinom, rbf gibi farklı çekirdek fonksiyonları arasından polinom fonksiyonu seçilmiştir. Bu fonksiyonlar, veri noktalarının uzayda nasıl dönüştürüldüğünü belirler.
- **Polynomial Order:** Eğer çekirdek fonksiyonu polinom ise, bu parametre polinomun derecesini belirler. Daha yüksek dereceli polinomlar daha karmaşık ilişkileri modelleyebilir, ancak aynı zamanda aşırı uyuma da neden olabilir.
- **StandardSize:** Veri noktalarının ölçeklendirilmesi için kullanılan bir parametredir. SVM regresyonunda, farklı özelliklerin ölçekleri arasındaki dengeyi sağlamak ve model performansını artırmak amacıyla veri standartlaştırma işlemi uygulanabilir.

Bu parametreler, SVM 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 bazı temel parametreler şu şekildedir:

- **MeanLeafSize:** Ağacın düğümlerinin ortalama yaprak boyutunu belirten bir parametredir. Bu değer, bir yaprak düğümünde minimum ortalama veri nokta sayısını belirler. Düşük bir MeanLeafSize değeri, daha fazla dallanmış bir ağacı ifade eder ve bu, modelin eğitim verilerine daha fazla uymasına neden olabilir.
- **MaxNumSplits:** Ağacın maksimum dallanma sayısını belirten bir parametredir. Bu değer, ağacın ne kadar derinleşebileceğini kontrol eder. Yüksek bir MaxNumSplits değeri, daha karmaşık bir model oluşturabilir, ancak aşırı uyuma yol açabilir.
- **NumVariablesToSample:** Her düğümde seçilecek rastgele özellik sayısını belirten bir parametredir. Karar ağacının her bir düğümünde, bu parametre kadar rastgele özellik seçilir ve bu özelliklere göre dallanma yapılır. Bu, modelin çeşitliliğini artırabilir ve aşırı uyumu önleyebilir.

İkili Karar Ağacı Regresyonu, 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.

4.4.2 Model performanslarının değerlendirilmesi

Tez çalışmasında, Bayes Tekniği ile Hiper-Optimize edilmiş Makine Öğrenimi Tekniklerinin tahmin sonuçları güncel piyasa değerleri ile karşılaştırılarak başarımları değerlendirilmiştir. Bu sonuçlarla birlikte eğitim ve test verilerinin karşılaştırılması Çizelge 4.5'te ve 4.6'da ifade edilmiştir.

Çizelge 4.5. Eğitim verilerinin başarımları metrikleri açısından incelenmesi

EĞİTİM	Topluluk Regresyonu	Çekirdek Regresyonu	Doğrusal Regresyon	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
R ²	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


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.

Çizelge 4.6. Test verilerinin başarımlarını metrikleri açısından incelenmesi

TEST	Topluluk Regresyonu	Çekirdek Regresyonu	Doğrusal Regresyon	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
R ²	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

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 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 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.

Elde edilen sonuçların yakınsama performansları incelenmiştir. Bir regresyon modelinin, belirli bir optimizasyon algoritması kullanılarak hiperparametrelerinin belirlenmesi sürecinde ne kadar iyi bir şekilde optimize edildiğini ifade eder. Bu değerlendirme, tahmin sonuçlarına ilişkin iterasyonlarına veya güncellemelerine ne kadar hızlı ve verimli bir şekilde ulaştığına ilişkin sonuçları göstermektedir. Bu yaklaşım, genellikle çeşitli başarımların metrikleri kullanılarak belirlenir. Başarımların metriklerine (R^2 , MSE, RMSE ve MAE) ilişkin başarımların 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 4.11’de gösterilmektedir.



Şekil 4.11. Yakınsama performansları

Şekil 4.11’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.

4.5 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.

Kim vd. (2020)’de Güney Kore’nin Busan kentindeki 547740 apartman işlem kaydına dayanan bir dizi konut fiyat verisine dayalı tahmin modeli oluşturmak için uzun kısa süreli hafıza (LSTM) adı verilen bir makine öğrenme tekniği kullanmıştır. Çalışmada hiperparametrelerin kombinasyonlarını herhangi bir özel metodoloji kullanmadan dikkate alınmıştır.

Lee ve Park (2020)’de konut fiyatlarını tahmin etmek için iki gizli katmana sahip standart bir ileri beslemeli sinir ağı ile oluşturulan geleneksel tahmin modeli ve ev fiyatı tahminlerindeki belirsizliği tanımlamak için bir Bayes sinir ağı tahmin modeli önermektedir. Bayes sinir ağı geleneksel ağıdan daha iyi performans göstermese de tahmin edilen fiyatlardaki belirsizliği ölçmek için bir araç olarak kullanılabilir olduğu görülmüştür. Bu çalışmanın bulguları, gayrimenkul sektöründe derin öğrenme araçlarının

kullanılabilirliğini ve Bayes yaklaşımının mülk değerlemesindeki belirsizliği modelleyebileceğini göstermektedir.

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.

Stubnova vd. (2020)'de Slovak Cumhuriyeti'nin Nitra şehrinde gayrimenkul değerlemesinde geleneksel ve gelişmiş yöntemlere yönelik bir inceleme gerçekleştirmiştir. Geleneksel yöntemlerden hedonik yaklaşımı temsil eden regresyon modeli ve modern ileri değerlendirme yöntemlerinden esnek hesaplama tekniklerinden biri olan yapay sinir ağları kullanılmıştır. Konut piyasası fiyat tahmininde her iki yöntemin sonuçları karşılaştırılarak değerlendirilmiştir. Modelin tahmin edilmesi için Levenberg-Marquart öğrenme algoritması, Bayesian Düzenleme öğrenme algoritması, Ölçekli Eşlenik Gradyan öğrenme algoritması ve regresyon fiyatlandırma modeli ile eğitilmiş yapay sinir ağları kullanılmıştır. Performanslar karşılaştırıldığında, yapay sinir ağlarının konut emlak piyasası fiyatının tahmin doğruluğunu artırabildiği gözlemlenmiştir. Ancak uygulamada fiyat tahmini için model mimarisinin hiper düzeyde optimizasyonu gerçekleştirilmemiştir.

Kalliola vd., 2021'de Helsinki'deki emlak fiyatlarının tahmini için sinir ağı hiperparametre optimizasyonu gerçekleştirmiş ve aynı çalışmada hiperparametre optimizasyonu teknikleri, literatürde uygulanan çalışmalar ve eksikliklerini dile getirmiştir.

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 etkilenebilir (Kim vd., 2020). Bu kapsamda konut fiyat değerini tahmin edilmesine

yönelik yapılacak çalışmalarda hiperparametre değerlerinin optimize edilerek tahmin değerlerinin belirlenmesi başarımlarının artırılmasında önem taşımaktadır.

Bu tez çalışmasının;

- Toplu bir taşınmaz değerlemesi olması,
- Tüm kentin farklı bölgesel özelliklerine rağmen modellenmesi ve heterojen yapıda olmasına rağmen yüksek doğrulukta tahminde bulunabilmesi,
- Model sonucunda kullanılan Hiper-Optimize edilmiş farklı regresyon analizlerinin sonuçlarının başarımlarının artırılmasında önem taşımaktadır.



BÖLÜM V

SONUÇLAR

Taşınmazlar, yatırım planlamalarında önemli bir rol oynayarak projelerin geliştirilmesinden, kredi düzenlemelerine ve vergi uygulamalarına kadar birçok alanda etkili olmaktadır. Ülke ekonomilerinin büyüme veya küçülme hızını belirlemede kilit bir faktör olan taşınmaz değerlerinin objektif ve güncel bir şekilde tespiti, günümüzde planlı ve sürdürülebilir taşınmaz yönetim stratejilerinin geliştirilmesinde kritik bir öneme sahiptir. Değişen ihtiyaçlar ve artan veri yoğunluğu bağlamında, tekil taşınmaz değerlendirmelerinden ziyade çok sayıda taşınmazın eş zamanlı olarak değerlendirildiği toplu taşınmaz değerlendirme yaklaşımı daha fazla tercih edilmektedir. Bu bağlamda, geleneksel tekil değerlendirme yöntemlerinin yanı sıra, Makine Öğrenimi Teknikleri gibi gelişmiş tahmin yaklaşımları da toplu taşınmaz değerlemesi için kullanılmaktadır. Bu çalışma, Bayes Tekniği ile Hiper-Optimize edilmiş Makine Öğrenimi Yöntemlerini kullanarak, toplu taşınmaz değerlendirme süreçlerinde daha etkili ve doğru sonuçlara ulaşmayı amaçlamaktadır. Elde edilen sonuçlar, yatırım planlamaları ve stratejik karar süreçleri için önemli bir bilgi kaynağı olarak değerlendirilebilir.

Çalışma kapsamında; çevrimiçi gayrimenkul satış sitelerinden elde edilen materyallerin kullanılarak yapısal ve konumsal özelliklere dair parametrelerin belirlenerek CBS ortamında bir veri tabanı oluşturulmuştur. Bu veriler kentin bütününde incelenmiş ve taşınmaz değerlendirme sürecinde kentin konumsal ve yapısal parametrelerine yönelik mekânsal analizler haritalar üzerinde sunulmuştur. Çalışmanın küçük ölçekli kentlerde kent bütününde yapılıyor 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 başarımların metriklerinin detaylı bir şekilde analiz edilmesidir.

Analizlere göre elde edilen veriler ışığında Çekirdek Regresyonu ile model sonucu R^2 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 R^2 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.

Kısaca bu tez çalışmasının toplu taşınmaz değerlendirme literatürüne ve sektöre katkıları;

- 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 değerlemesi 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 değer tahmini yürütmeleri,
- Kent yöneticilerine imar ve şehircilik yatırımlarında bölgesel eşitsizlikleri önlemeye rehberlik oluşturulmasında,

Olarak ifade edilebilir.

Tez çalışması, benzer bir yaklaşımın küçük ölçekli bir kent bütününde başarıyla uygulanarak etkinliğini kanıtlamıştır. Önümüzdeki araştırmalarda, bu metodolojinin genelleştirilebilirlik potansiyelini daha da artırmak adına büyük ölçekli kentlerde daha geniş veri setleri kullanılması önerilmektedir. Bu şekilde, modelin uygulanabilirliği, ölçek ekonomisi dikkate alınarak daha geniş bir coğrafyada modellenabilir ve bilimsel bir çerçevede daha kapsamlı bir şekilde tartışılabilir hale getirilebilir.

KAYNAKLAR

Akkaynak, B., “Gayrimenkul Değerlemesi ve Gayrimenkul Değerlemesi Üzerine Bir Uygulama”, *Sosyal Bilimler Dergisi*, 18, (18), 695-717, 2017.

Aktaş, A., “Mülkiyet Hakkına Müdahale Kapsamında “Orman Şerhi” Uygulaması”, *İdare Hukuku ve İlimleri Dergisi*, 2022.

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.

Alkan, T. ve Durduran, S. S., “Konut Seçimi Sürecinin AHP Temelli TOPSIS Yöntemi ile Analizi”, Necmettin Erbakan Üniversitesi, *Fen ve Mühendislik Bilimleri Dergisi*, 2 (2), 12-21, 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, 2021.

Alkan, T., Dokuz, Y., Ecemiş, A. Bozdağ, A. ve Durduran, S.S., “Using machine learning algorithms for predicting real estate values in tourism centers”, *Soft Computing*, 27, 2601–2613, 2023.

Almy, R., “Valuation and assessment of immovable property.”, *OECD Working Papers on Fiscal Federalism*, (24 pp), Paris, 2014.

Amca, F., “Gayrimenkul değ rlemesi ve Denizli Merkez'de bir uygulama”, Y ksek Lisans Tezi, *Pamukkale  niversitesi Sosyal Bilimler Enstit s *, 2016.

Aubry, M., Kr ussl, R., Manso, G. ve Spaenjers, C., “Makine  ğrenimi, insan uzmanları ve ger ek varlıkların değ rlemesi”, *CFS  alıřma Kağıdı Serisi*, (No. 635)., 2019.

Aydınoğlu, A.  ., Bovkır, R. ve   lkesen,  ., “Toplu taşınmaz değ rlemede makine  ğrenme algoritmalarının kullanımı ve konumsal/konumsal olmayan  zniteliklerin tahmin doėruluėuna etkilerinin karřılařtırılması.”, *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.

Ball, J. ve Srinivasan, V.C., “Using the analytic hierarchy process in house selection”, *The Journal of Real Estate Finance and Economics*, 9(1), 1994.

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.

Barańska, A., “Real estate mass appraisal in selected countries–functioning systems and proposed solutions.” *Real Estate Management and Valuation*, 21(3), 35-42, 2013.

Bilgili  lu, S. S., “Makine  ğrenmesi teknikleri ile mek nsal karar destek sistemlerinin geliřtirilmesi: Aksaray ili  rneėi”, Doktora Tezi, *Aksaray  niversitesi Fen Bilimleri Enstit s *, 2018.

Bozdaė, A. ve Ertun , E., “CBS ve AHP y ntemi yardımıyla Niėde Kenti  rneėinde taşınmaz değ rleme”, *Geomatik*, 5(3), 228-240, 2020.

Bünyan Ünel, F., Kuşak, L., Yakar, M. ve Doğan, H. “Coğrafi bilgi sistemleri ve analitik hiyerarşi prosesi kullanarak Mersin ilinde otomatik meteoroloji gözlem istasyonu yer seçimi.”, **Geomatik**, 8 (2), 107-123, 2023.

Büyükkaracıgan, D. N., “Modern methods approach in real estate valuation”. Ankara, **Iksad Publishing House**, 130, 2021.

Candaş, E., Taşınmaz Değerlemesi İçin Mevzuat Altyapısının Modellenmesi, Yüksek Lisans Tezi, **İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü**, İstanbul, 131 s, 2012.

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, JS., 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.

Çakır, P., ve Sesli, F. A., “Arsa vasıflı taşınmazların değerine etki eden faktörlerin vebu faktörlerin önem sıralarının belirlenmesi”, **Harita Teknolojileri Elektronik Dergisi**, 5(3), 1-16, 2013.

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., Erdoğan, 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.

Demircan, K., “Metro istasyonlarının konut fiyatlarına etkisi: İstanbul örneği”, Doktora Tezi, **Y.T.Ü. Fen Bilimleri Enstitüsü**, 2021.

Demirci, M., “Destek Vektör Makineleri ve M5 Karar Ağacı Yöntemleri Kullanılarak Yağış-Akış İlişkisinin Tahmini.”, *Dicle Üniversitesi Mühendislik Fakültesi Dergisi*, Sayı 10, Cilt 3, Sayfa 1113-1124, 2019.

Demirel, B., Yelek, A., Alağuş, H. M. ve Eren, T., “Taşınmaz Değerleme Kriterlerinin Belirlenmesi ve Kriterlerin Önem Derecelerinin Çok Ölçütlü Karar Verme Yöntemi ile Hesaplanması”, *Kırıkkale University Journal of Social Sciences*, 8(2): 665- 682, 2018.

Deveci, E. ve Yılmaz, İ., “Coğrafi Bilgi Sistemleri Yardımıyla Taşınmaz Mal Değerlemesi: Afyonkarahisar İl Merkezi Örneği”, *Harita Teknolojileri Elektronik Dergisi*, 1 (1), 33-47, 2009.

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.

Doldur, M., ve Alkan, R. M., “Nominal Değerleme Yöntemi ile CBS Destekli Taşınmaz Değer Haritalarının Oluşturulması: Avanos/Nevşehir Örneği.”, *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 21(4), 846-863, 2021.

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.

Erdem, N., “Toplu (küme) değerlendirme uygulama örnekleri ve ülkemiz için öneriler”. *TMMOB Harita ve Kadastro Mühendisleri Odası 16. Türkiye Harita Bilimsel ve Teknik Kurultayı*, 3-6, 2017.

Erdem, N., “Türkiye taşınmaz değerlendirme sisteminin yeniden yapılandırılmasına yönelik bilimsel çalışma ve öneriler üzerine bir değerlendirme”, *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 7 (1), 159-170, 2018.

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

Garip, E., “Forecasting carbondioxide (CO2) emission in OECD countries with machine learning”, Doctoral Thesis, *Istanbul Medeniyet University Graduate School of Natural and Applied Sciences Department of Engineering Management*, 2017.

Guliker, E., Folmer, E., ve van Sinderen, M., “Spatial determinants of real estate appraisals in the Netherlands: A machine learning approach”, *ISPRS international journal of geo-information*, 11(2), 125, 2022.

Gündoğmuş, M. E., ve Taşçı, M., “Hünnap (Zizyphus jujube mill.) bahçelerinde gelir yöntemine göre değerlendirme: Denizli ili Çivril ilçesi örneği”, *Tekirdağ Üniversitesi Ziraat Fakültesi Dergisi*, 14(2), 2017.

Hwang, C.L. ve Yoon, K., “Multiple Attributes Decision Making Methods and Applications”, *A State of The Art Survey*, Springer-Verlag Berlin Heidelberg, New York 1981.

IAAO, (2013)., “Standard on ratio studies”., <https://www.iaao.org/media/standards/Standard on Ratio Studies.pdf>, 19 Aralık 2023.

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.

IVS, 2011, International Valuation Standards (IVS), UK, <https://www.ivsc.org/content-restricted/>, 19 Aralık 2023.

İlhan, A. T., ve Öz., N. S., “Yapay Sinir Ağlarının Gayrimenkullerin Toplu Değerlemesinde Uygulanabilirliği: Gölbaşı İlçesi Örneği.”, *Hacettepe Üniversitesi Sosyal Bilimler Dergisi*, 2(2), 160-188, 2020.

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.

Karaduman, H., “Coğrafi bilgi sistemleri ile tarım arazilerinin değerlendirilmesi: Aksaray örneği” Yüksek Lisans Tezi, *Aksaray Üniversitesi Fen Bilimleri Enstitüsü*, 2023.

Karakuş, H. H., “Kentsel alanlarda gayrimenkul değerlendirilmesi ve Balıkesir örneği”, Yüksek Lisans Tezi, *Balıkesir Üniversitesi Fen Bilimleri Enstitüsü*, 2011

Kayalık, M., ve Polat, Z. A., “CBS destekli nominal taşınmaz değer haritasının 3 boyutlu sunumu: Berlin Eyaleti örneği”, *Geomatik*, 8(2), 180-191, 2023.

Khamrabaeva, L., “Gayrimenkul değerlendirme yöntemleri: Hedonik fiyat modeli üzerine bir uygulama”, Doctoral dissertation, *Bursa Uludağ University Institute of Science and Technology*, 2020.

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.

Köktürk, E. ve Köktürk, E., “Taşınmaz Değerlemesi, Taşınmaz Hukuku – İmar Hukuku–Değerleme Yöntemleri”, *Seçkin Yayıncılık*, 2. Baskı, Ankara, 2015.

Kumar, K.; Garg, H., “TOPSIS method based on the connection number of set pair analysis under interval-valued intuitionistic fuzzy set environment”, *Comput. Appl. Math.* 37, 1319–1329, 2018.

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.

Mete, M. O., “Coğrafi bilgi sistemleri entegreli makine öğrenmesine dayalı toplu taşınmaz değerlendirme modelinin geliştirilmesi”, Doktora Tezi, *İ.T.Ü. Fen Bilimleri Enstitüsü*, 2022

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.

Özer, M., Taşınmaz Değerlendirmesinde Kullanılan Finansal ve Sayısal Yöntemler: TOPSIS ve Yeni Çoklu Kriter Modelleriyle Bir Uygulama, Yayınlanmamış Yüksek Lisans Tezi, *Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü*, İzmir, 2010.

Özkan, H. S., Taşınmaz satış fiyatına etki eden faktörlerin istatistiksel yöntemlerle araştırılması, Yüksek Lisans Tezi, *Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü*, 2009.

Öztürk, A., Erdoğan, Ş., ve Arıkan, V. S., “Analitik Hiyerarşi Süreci (AHP) Kullanılarak Tedarikçilerin Değerlendirilmesi: Bir Tekstil Firmasında Uygulama.” *Dokuz Eylül Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi*, 26(1), 93-112, 2011.

Pai, P.-F. ve Wang, W.-C., “Using machine learning models and actual transaction data for predicting real estate prices”, *Applied Sciences*, 10(17), 5832, 2020.

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.

Roszkowska, E., “Multi-criteria decision making models by applying the TOPSIS method to crisp and interval data.” *Mult. Criteria Decis. Mak. Univ. Econ.* Katow., 6, 200–230, 2011.

Saaty, T., “The analytic hierarchy process (AHP) for decision making”., *In Kobe, Japan*, Vol. 1, p. 69, 1980.

Saaty, Thomas L., ve Luis G. Vargas., “The Logic of Priorities. Massachusetts: Kluwer Nijhoff Publishing”, *University of Pittsburgh*, 1982.

Saraç, E., “Yapay sinir ağları metodu ile gayrimenkul değerlendirme”, Yüksek Lisans Tezi, *İstanbul Kültür Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, 2012.

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”, Yüksek Lisans Tezi, *Kadir Has Üniversitesi Sosyal Bilimler Enstitüsü*, İstanbul, 2008.

Steurer, M., Hill, R. J., ve Pfeifer, N., “Machine Learning Prediction Models: An Application to the Housing Market” *Graz Economic Papers*, 2020.

Štubňová M, Urbaníková M, Hudáková J, Papcunová V., “Estimation of residential property market price: comparison of artificial neural networks and hedonic pricing model”, *Emerging Science Journal*, 4(6):530–538, 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.

Taktak, F., ve Demir, H., “Termal Otel Geliştirme: Afyonkarahisar Örneği.” *Harita Teknolojileri Elektronik Dergisi*, 2(1), 20-35, 2010.

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.

Timor, M. “Analitik Hiyerarşi Prosesi”, *Türkmen Kitabevi*, İstanbul, 2011.

TSPB, Türkiye Sermaye Piyasaları Birliği, <https://tspb.org.tr/tr/>, 20.12.2023.

Tunca, E., ve Üstüntaş, T., “Gayrimenkul değerlendirme modelinin oluşturulmasında çok kriterli karar verme yöntemlerinin kullanılması”, *TMMOB*, 6, 23-25, 2019.

TDK, Türk Dil Kurumu çevrimiçi sözlük, “Taşınmaz.”, <http://sozluk.gov.tr/>, 15 Aralık 2023.

TMK, 4721 sayılı “Türk Medeni Kanunu”, Yayımlandığı Resmî Gazete Tarihi: 8/12/2001, Sayı: 24607, Yayımlandığı Düstur Tertip: 5 Cilt: 41, 20 Aralık 2023.

Ulucan, A. G., “Taşınmaz Değer Piyasası Üzerinde Pandeminin Etkilerinin Analizi, Niğde Kenti”, Yüksek Lisans Tezi, *Niğde Ömer Halisdemir Üniversitesi Fen Bilimleri Enstitüsü*, 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.

Uşak, B., “Konya Otogar Civarında Emlak Vergisine Esas Zemin Değerinin Tespiti”, Yüksek Lisans Tezi, *Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Harita Mühendisliği Ana Bilim Dalı*, Konya, 2019.

URL-1

<https://www.mevzuat.gov.tr/mevzuat?MevzuatNo=19974veMevzuatTur=9veMevzuatTertip=5>, 20 Aralık 2023.

URL-2

https://www.bulutkbs.gov.tr/giris/content/plan/dosya/PlanCBS_HTML_V.1.0/cografi_bilgi_sistemlerinde_veri_yapisi.htm/, 10 Eylül 2023.

URL-3 [https://tr.wikipedia.org/wiki/Yozgat_\(il\)](https://tr.wikipedia.org/wiki/Yozgat_(il)), 15 Ekim 2023.

URL-4 <https://www.sahibinden.com/satilik/yozyat-merkez/>, 31 Aralık 2022.

URL-5 <https://www.emlakjet.com/satilik-konut/yozyat-yozyat-merkez/>, 31 Aralık 2023.

Uygun, U., “İmar uygulamasında değer esaslı kriterlerine göre dağıtım probleminin yapay zekâ yöntemiyle çözümü”, Yüksek Lisans Tezi, *Gebze Yüksek Teknoloji Fen Bilimleri Enstitüsü*, Gebze, 2011.

Uzer, E., “Türkiye için Taşınmaz Değerleme Kurumu Oluşturulmasına Yönelik Bir Model Önerisi”, Yüksek Lisans Tezi, *Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü*, Trabzon, 2009.

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.

Yertutan, D., ve Çetinyokuş, T., “Sürdürülebilir Konut Satın Alımının Çok Kriterli Karar Verme Metotlarıyla Değerlendirmesi ve Bir Uygulama”, ***International Journal Of Engineering Research And Development***, 13(1), 32-54, 2021.

Yilmazer, S. ve Kocaman, S., “A mass appraisal assessment study using machine learning based on multiple regression and random forest”, ***Land use policy***, 2020.

Yomralıoğlu, T., “Taşınmazların Değerlendirilmesi”, ***K.T.Ü. Ders Notları***, Trabzon, 1995.

Yomralıoğlu, T., “Taşınmazların Değerlendirilmesi ve Kat Mülkiyeti Mevzuatı, Kentsel Alan Düzenlemelerinde İmar Planı Uygulama Teknikleri”, ***Jeodezi ve Fotogrametri Derneği (JEFOD) Yayını***, Trabzon, 153-167, 1997.

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.

ÖZ GEÇMİŞ

tarihinde ' ilçesinde dünyaya geldi. İlköğrenimini ' Yerköy ilçesinde tamamladı. Ortaöğrenimini Yozgat'ta Erdoğan Akdağ Fen Lisesi'nde bitirdi. ' yılında girdiği ' mezun oldu. 2020 yılından bu yana Niğde Ömer Halisdemir Üniversitesi Harita Mühendisliği Bölümü'nde Yüksek Lisans alanında çalışmalarını sürdürmektedir. ' ticari pilot sertifikası sahibidir. CBS ve Programlama Dilleri alanlarında uzmanlaşmak istemekte; Makine Öğrenimi ve Yapay Zekâ alanlarında ise kendini geliştirmektedir.

şirketinin sahibi olup Serbest Harita Mühendisi olarak haritacılık-mühendislik faaliyetleri ile çalışma hayatına başlamıştır. 2022 yılında Yozgat Belediyesi Personel Ltd. Şti.'nde ilk olarak Fen İşleri Birimi'nde sonrasında ise İmar ve Şehircilik Birimi bünyesinde Harita Mühendisi olarak çalışmaya devam etmektedir.

