

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**COĞRAFİ BİLGİ SİSTEMLERİ ENTEGRELİ MAKİNE
ÖĞRENMESİNE DAYALI TOPLU TAŞINMAZ DEĞERLEME
MODELİNİN GELİŞTİRİLMESİ**

DOKTORA TEZİ

Muhammed Oğuzhan METE

Geomatik Mühendisliği Anabilim Dalı

Geomatik Mühendisliği Programı

EKİM 2022

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**COĞRAFİ BİLGİ SİSTEMLERİ ENTEGRELİ MAKİNE
ÖĞRENMESİNE DAYALI TOPLU TAŞINMAZ DEĞERLEME
MODELİNİN GELİŞTİRİLMESİ**

DOKTORA TEZİ

**Muhammed Oğuzhan METE
(501192606)**

Geomatik Mühendisliği Anabilim Dalı

Geomatik Mühendisliği Programı

Tez Danışmanı: Prof. Dr. Tahsin YOMRALIOĞLU

EKİM 2022

ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL

**DEVELOPMENT OF MASS PROPERTY VALUATION MODEL
BASED ON GEOGRAPHIC INFORMATION SYSTEMS
INTEGRATED MACHINE LEARNING METHODS**

Ph.D. THESIS

**Muhammed Oğuzhan METE
(501192606)**

Department of Geomatics Engineering

Geomatics Engineering Programme

Thesis Advisor: Prof. Dr. Tahsin YOMRALIOĞLU

OCTOBER 2022

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 501192606 numaralı Doktora Öğrencisi Muhammed Oğuzhan METE, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “COĞRAFİ BİLGİ SİSTEMLERİ ENTEGRELİ MAKİNE ÖĞRENMESİNE DAYALI TOPLU TAŞINMAZ DEĞERLEME MODELİNİN GELİŞTİRİLMESİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Tahsin YOMRALIOĞLU**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Himmet KARAMAN**
İstanbul Teknik Üniversitesi

Prof. Dr. Arif Çağdaş AYDINOĞLU
Gebze Teknik Üniversitesi

Prof. Dr. Reha Metin ALKAN
İstanbul Teknik Üniversitesi

Doç. Dr. İsmail ÇÖLKESEN
Gebze Teknik Üniversitesi

Teslim Tarihi : **1 Eylül 2022**

Savunma Tarihi : **7 Ekim 2022**

Eşime ve oğluma,

ÖNSÖZ

Geomatik Mühendisliği, meslek olarak çok disiplinli bir yapıya sahiptir ve güncel bilişim teknolojilerinin önemli bir paydaşdır. Yapay Zeka, Büyük Veri Analitiği, Bulut Bilişim, Nesnelerin İnterneti, Yapı Bilgi Modellemesi gibi yenilikçi teknolojiler mesleğimizin birçok uygulama alanında yer edinerek çeşitli sorunların çözümüne katkı sunmaktadırlar.

Bu tez çalışmasında Arazi İdaresi kapsamında ihtiyaç duyulan konumsal veri elde etme, depolama, analiz, görselleştirme ve paylaşma aşamalarının tamamı uçtan uca ele alınmış, güncel teknolojik gelişmeler ışığında taşınmaz değerlendirme alanıyla bütünleştirilmiştir.

Yoğun ve özverili çalışmalar sonucunda ortaya çıkan bu tezin ülkemizdeki taşınmaz değerlendirme faaliyetlerine katkı sunmasını temenni ediyorum.

Çalışmalarım boyunca bilim yolunda bana ışık olan, akademiye sevdiren, disiplin ve çalışma azmiyle her zaman örnek aldığım, bilgi ve tecrübelerinden büyük istifade ettiğim, değerli hocam, danışmanım, Prof. Dr. Tahsin YOMRALIOĞLU'na şükranlarımı sunarım.

Doktora Tez İzleme Komitesinde yer alan ve süreç boyunca çalışmalarına değerli katkılar sağlayan Prof. Dr. Himmet KARAMAN ile Prof. Dr. Arif Çağdaş AYDINOĞLU hocalarıma ve Tez Jüri Üyeleri Prof. Dr. Reha Metin ALKAN ile Doç. Dr. İsmail ÇÖLKESEN hocalarıma içten teşekkürlerimi sunarım.

Desteğini her zaman hissettiren kıymetli bölüm başkanımız Prof. Dr. Mustafa YANALAK'a, tez çalışması sırasındaki desteklerinden ötürü başta Araş. Gör. Muhammed Enes ATİK ve Araş. Gör. Doğuş GÜLER olmak üzere, tüm çalışma arkadaşlarıma teşekkürlerimi arz ederim.

Hayatımın her evresinde olduğu gibi, bu tez çalışması sırasında da desteklerini ve dualarını esirgemeyen anneme, babama ve kardeşlerime teşekkür ederim.

Son olarak, üzüntü ve sevinçlerimi paylaşan, her anımda beni destekleyip yüreklendiren, tez çalışması boyunca da gösterdiği fedakarlık ve anlayışıyla teşekkürlerin en büyüğünü hak eden değerli eşim Sema'ya ve biricik oğlumuz Bera'ya en içten teşekkürü bir borç bilirim.

Bu çalışma İstanbul Teknik Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimince desteklenmiştir. Proje Numarası: MDK-2021-43080.

Ekim 2022

Muhammed Oğuzhan METE
(Yüksek Geomatik Mühendisi)

İÇİNDEKİLER

	<u>Sayfa</u>
ÖNSÖZ	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
SEMBOLLER	xvii
ÇİZELGE LİSTESİ	xix
ŞEKİL LİSTESİ	xxi
ÖZET	xxiii
SUMMARY	xxv
1. GİRİŞ	1
1.1 Problem Tanımı	3
1.2 Çalışmanın Amacı	6
1.3 Metodoloji	8
1.4 Literatür Araştırması	11
1.5 Temel Tanım ve Kavramlar	19
1.5.1 Bulut bilişim	19
1.5.2 Coğrafi bilgi sistemleri	23
1.5.2.1 Masaüstü coğrafi bilgi sistemleri.....	25
1.5.2.2 Web coğrafi bilgi sistemleri.....	27
1.5.2.3 Bulut coğrafi bilgi sistemleri	28
1.5.3 Yapay Zeka ve Makine Öğrenmesi	30
1.5.3.1 Sınıflandırma algoritmaları.....	31
1.5.3.2 Regresyon algoritmaları	32
1.5.3.3 Kümeleme algoritmaları.....	34
1.5.3.4 Derin öğrenme	35
1.5.4 Taşınmaz değerlendirme	37
1.5.4.1 Taşınmaz değerlendirme yöntemleri.....	38
1.5.4.2 Dünyada taşınmaz değerlendirme.....	43
1.5.4.3 Türkiye’de taşınmaz değerlendirme.....	46
1.5.5 Arazi İdaresi Alan Modeli (LADM)	50
1.5.5.1 LADM Değerleme Bilgi Modeli	51
1.5.6 Yapı Bilgi Modellemesi (BIM)	52
2. YAPILAN ÇALIŞMALAR	57
2.1 Çalışma Alanı	57
2.2 Kullanılan Veri Setleri	60
2.3 Taşınmaz Değerlerine Etki Eden Faktörlerin Belirlenmesi.....	62
2.4 Kavramsal Model Tasarımı	66
2.5 Veri Tabanının Oluşturulması.....	73

2.6	Veri Ön İşleme ve Dönüştürme	74
2.7	Konumsal Analizler.....	75
2.7.1	Yakınlık analizleri	76
2.7.2	Yüzey analizleri.....	77
2.7.2.1	Eğim analizi.....	78
2.7.2.2	Bakı analizi.....	79
2.7.3	Görünürlük analizleri	81
2.8	Nominal Taşınmaz Değerleme Yöntemi İle Değer Haritası Üretimi	82
2.9	Makine Öğrenmesi Yöntemleri İle Regresyon Analizi	86
2.9.1	Keşifsel veri analizi	86
2.9.2	Özellik mühendisliği	87
2.9.3	Regresyon analizi	90
2.9.4	Taşınmaz değerini etkileyen kriterlerin önem düzeyi	91
2.9.5	Doğruluk analizi.....	92
2.9.5.1	Oran çalışması	94
2.9.6	Coğrafi Bilgi Sistemleri ile öznitelik zenginleştirme	96
2.9.7	Konumsal kümeleme yöntemi ile değer bölgelerinin belirlenmesi.....	97
2.9.8	Toplu değerlendirme modellerinde genelleştirilebilirliğin incelenmesi	102
2.10	Arsa ve Bina Değerlerinin Ayırt Edilmesi.....	108
2.10.1	Yapı inşaat maliyetinin modellenmesi.....	111
2.11	Web Tabanlı Taşınmaz Değerleme Bilgi Portalının Geliştirilmesi	115
2.11.1	Coğrafi veri sunucusunun hazırlanması	115
2.11.2	Web harita kütüphanesi ile portalın geliştirilmesi	118
3.	BULGULAR.....	123
4.	SONUÇLAR.....	131
	KAYNAKLAR.....	137
	EKLER	157
	ÖZGEÇMİŞ	168

KISALTMALAR

3B	: Üç Boyutlu
3S	: Sahiplik, Sorumluluk ve Sınırlamalar
ACU	: Aurora Capacity Units
ADE	: Application Domain Extension
AEC	: Architecture, Engineering and Construction
AHS	: Analitik Hiyerarşi Süreci
AI	: Appraisal Institute
AİS	: Arazi İdaresi Sistemi
AMI	: Amazon Machine Image
API	: Application Programmin Interface
ASA	: American Society of Appraisers
AVM	: Automated Valuation Models
AWS	: Amazon Web Servisleri
BCF	: BIM Collaboration Format
BCIS	: Building Cost Information Service
BIM	: Building Information Modelling
CAMA	: Computer Aided Mass Appraisal
CBS	: Coğrafi Bilgi Sistemleri
CDN	: Content Delivery Network
CGIS	: Canada Geographic Information System
CNN	: Convolutional Neural Networks
COG	: Cloud Optimized GeoTIFF
COPC	: Cloud Optimized Point Cloud
CSV	: Comma Seperated Values
ÇKKV	: Çok Kriterli Karar Verme
ÇRA	: Çoklu Regresyon Analizi
DVM	: Destek Vektör Makineleri
EC2	: Elastic Compute Cloud
EDA	: Exploratory Data Analysis
EEA	: European Environment Agency
EPC	: Energy Performance Certificates
ETL	: Extract Transform Load
EU-DEM	: European Digital Elevation Model
EVS	: European Valuation Standarts
FaaS	: Function as a Service
FELA	: Framework for Effective Land Administration
FIABCI	: The International Real Estate Federation
FIG	: International Federation of Surveyors
FPR	: False Positive Rate
GAN	: Generative Adversarial Networks
GDAL	: Geospatial Data Abstraction Library

GiB	: Gibibytes
GPKG	: GeoPackage
GPL	: General Public Licence
GPU	: Graphics Processing Unit
GUI	: Graphic User Interface
GWR	: Geographically Weighted Regression
HPI	: House Price Index
HPSSAs	: Hosue Price Statistics for Small Areas
HTTP	: Hyper Text Transfer Protocol
IAAO	: International Association of Assessing Officers
IaaS	: Infrastructure as a Service
IDM	: Information Delivery Manual
IFC	: Industry Foundation Classes
INSPIRE	: Infrastructure for Spatial Information in Europe
ISO	: International Standards Organization
IVS	: International Valuation Standards
IVSC	: International Valuation Standards Council
KAKS	: Kat Alanı Kat Sayısı
LADM	: Land Administration Domain Model
LADM_VM	: LADM Değerleme Bilgi Modeli
LBTT	: Land and Buildings Transaction Tax
LSOA	: Lower Layer Super Output Areas
LSTM	: Long Short-Term Memory
LTT	: Land Transaction Tax
MAE	: Mean Absolute Error
MAPE	: Mean Absolute Percentage Error
MBE	: Mean Bias Error
MSOA	: Middle Layer Super Output Areas
MVDs	: Model View Definitions
MVT	: Mapbox Vector Tiles
OGC	: Open Geospatial Community
ONS	: Office for National Statistics
OSGEO	: Open Source Geospatial Foundation
OSM	: OpenStreetMap
PaaS	: Platform as a Service
PAON	: Primary Addressable Object Name
PCA	: Principal Component Analysis
PPD	: Price Paid Data
RDS	: Relational Database Service
RICS	: Royal Institution of Chartered Surveyors
RMSE	: Root Mean Square Error
S3	: Simple Storage Service
SaaS	: Software as a Service
SAON	: Secondary Addressable Object Name
SDLT	: Stamp Duty Land Tax
SHAP	: SHapley Additive exPlanations
SPK	: Sermaye Piyasaları Kurulu

STAC	: SpatioTemporal Asset Catalogs
TAKBİS	: Tapu ve Kadastro Bilgi Sistemi
TAKS	: Taban Alanı Kat Sayısı
TDUB	: Türkiye Değerleme Uzmanları Birliği
TEGoVA	: The European Group of Valuers' Associations
TKGM	: Tapu ve Kadastro Genel Müdürlüğü
TPR	: True Positive Rate
TUCBS	: Türkiye Ulusal Coğrafi Bilgi Sistemleri
TÜİK	: Türkiye İstatistik Kurumu
UML	: Unified Modeling Language
UN-GGIM	: United Nations Global Geospatial Information Management
UPRN	: Unique Property Reference Number
URL	: Uniform Resource Locator
vCPU	: Virtual Central Processing Unit
VOA	: Valuation Office Agency
VPC	: Virtual Private Cloud
WCS	: Web Coverage Service
WebGL	: Web Graphics Library
WFS	: Web Feature Service
WLC	: Weighted Linear Combination
WMS	: Web Map Service
WMTS	: Web Map Tile Service
XaaS	: Anything as a Service
XAI	: eXplainable AI
Yİ-ÜFE	: Yurtiçi Üretici Fiyat Endeksi
YSA	: Yapay Sinir Ağları

SEMBOLLER

\pounds	: Pound
Σ	: Toplam
θ	: Teta açısı
\hat{y}	: Bağımlı değişken
X_n	: Bağımsız değişken
b_0	: y-sabit değeri
b_n	: Katsayılar
G_{net}	: Taşınmazın Yıllık Ortalama Net Geliri
D_{arsa}	: Arsa değeri
R^2	: Belirleme katsayısı
\hat{y}	: Tahmini değer
\bar{R}	: Ortalama oran
R_i	: Tahmin değerinin gerçek değere oranı
\bar{A}	: Tahmin değerlerinin toplamı
\bar{S}	: Gerçek değerlerin toplamı
\tilde{R}	: Medyan değeri

ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 2.1 : PPD verisine ait öznitelikler.....	60
Çizelge 2.2 : EPC verisine ait öznitelikler.....	62
Çizelge 2.3 : Emlak listeleme şirketine ait satış ilanları verisi.....	63
Çizelge 2.4 : IFC tabanlı 3B taşınmaz değerlendirme modeli.....	72
Çizelge 2.5 : Yakınlık değerlerinin araç ve yaya erişimi için sınıflandırma aralıkları.....	77
Çizelge 2.6 : Eğim değerlerinin yeniden sınıflandırma aralıkları.....	79
Çizelge 2.7 : CBS tabanlı nominal arsa değer haritası üretiminde kullanılan kriterler ve ağırlıkları.....	85
Çizelge 2.8 : PPD-EPC verisine ait özet istatistikler.....	88
Çizelge 2.9 : Global regresyon modellerinin doğruluk metrikleri.....	94
Çizelge 2.10 : Öznitelik zenginleştirilmesi sonrası hesaplanan doğruluk metrikleri.....	97
Çizelge 2.11 : Lokal regresyon modelinin doğruluk metrikleri.....	103
Çizelge 2.12 : Emlak listeleme şirketine ait değerlendirme verisinin tanımlayıcı istatistikleri.....	104
Çizelge 2.13 : Regresyon modellerinin doğruluk metrikleri.....	107
Çizelge 2.14 : Yapı yaklaşık inşaat maliyetlerinin hesabında kullanılan cetvellerin hesap karşılaştırması.....	110
Çizelge 2.15 : Arsa değerlendirme için oluşturulan regresyon modellerinin doğruluk metrikleri.....	112
Çizelge 2.16 : Maliyet modellemesi sonucunun BCIS modeli ile kıyaslanması..	114
Çizelge B1 : Yapı yaklaşık maliyeti için malzeme metraj ve birim fiyat hesabı	165

ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 1.1 : Farklı sistem iş yükleri sırasında Aurora Sunucusuz Veritabanı ölçeklenebilirliği.	24
Şekil 1.2 : Verinin anlam ve bağlantılılığa dayalı dönüşüm süreci.	26
Şekil 1.3 : CBS’de vektör ve raster veri türleri.	26
Şekil 1.4 : Bulut CBS bileşenleri ve servis modelleri.	29
Şekil 1.5 : Yapay zeka, makine öğrenmesi ve derin öğrenme hiyerarşisi.	31
Şekil 1.6 : Karışıklık matrisi ve doğruluk hesabı.	32
Şekil 1.7 : ROC eğrisi ile sınıflandırma performansının ölçülmesi.	33
Şekil 1.8 : Yapay Sinir Ağının yapısı.	36
Şekil 1.9 : CBS destekli nominal değerlendirme yöntemi.	42
Şekil 1.10 : LADM’nin temel sınıfları.	51
Şekil 1.11 : LADM_VM’nin ana sınıfları.	53
Şekil 1.12 : BIM ve CBS entegrasyonu ile fonksiyonları.	55
Şekil 2.1 : Çalışma alanları: Birleşik Krallık ve Türkiye.	58
Şekil 2.2 : İngiltere, Galler ve İskoçya ülkelerinden oluşan Büyük Britanya Adası.	58
Şekil 2.3 : Çalışmada kullanılan yöntemlere ait iş akış şeması.	59
Şekil 2.4 : Birleşik Krallık’ta bulunan binalara ait farklı mimari türler.	61
Şekil 2.5 : Taşınmaz değerini etkileyen faktörlerin sınıflandırması.	64
Şekil 2.6 : LADM_VM ve Büyük Britanya Ülke Profili İlişkileri.	67
Şekil 2.7 : Büyük Britanya LADM Değer Bilgi Modeline ait sınıflar ve ilişkileri.	68
Şekil 2.8 : LADM_GB_VM sınıflarına ait kod listeleri.	69
Şekil 2.9 : İngiltere ve Galler ülkelerinin değerlendirme verileri ile oluşturulan örnek düzey diyagramı.	70
Şekil 2.10 : 3B taşınmaz değerlendirme amaçlı oluşturulan IFC tabanlı değerlendirme birimi modeli.	73
Şekil 2.11 : QGIS Graphical Modeler ile oluşturulan konumsal analiz modeli. ..	76
Şekil 2.12 : Büyük Britanya - ana yola yakınlık analizi haritası.	78
Şekil 2.13 : Yüzde ve derece cinsinden eğim hesabı.	79
Şekil 2.14 : Büyük Britanya - eğim analizi haritası.	80
Şekil 2.15 : Bakı analizinde eğimin yönünü belirten açı değerleri.	81
Şekil 2.16 : Büyük Britanya - bakı analizi haritası.	82
Şekil 2.17 : Büyük Britanya - deniz manzarası görünürlük analizi.	83
Şekil 2.18 : Çalışma bölgesine ait nominal değerlendirme haritası.	84
Şekil 2.19 : Keşifsel Veri Analizi.	87
Şekil 2.20 : Kriterlere ait permutasyon tabanlı önem skorları.	91

Şekil 2.21	: Bağımsız değişkenlerin SHAP değeri.	92
Şekil 2.22	: Değişkenlere ait korelasyon matrisi.	97
Şekil 2.23	: Öznitelik zenginleştirilmesi sonrası önem skorları.....	98
Şekil 2.24	: Öznitelik zenginleştirilmesi sonrası SHAP değerleri.	98
Şekil 2.25	: Nominal Ağırlıklı Çok Değişkenli Mekansal Kümeleme Analizi sonucu oluşturulan değer bölgeleri.	101
Şekil 2.26	: Büyük Londra bölgesindeki değer bölgelerinin dağılımı.	102
Şekil 2.27	: İstanbul İline ait Nominal Arsa Değer Haritası.	103
Şekil 2.28	: İzmir İline ait Nominal Arsa Değer Haritası.	105
Şekil 2.29	: Değerleme verisine ait keşifsel veri analizi.	106
Şekil 2.30	: İstanbul ve İzmir çalışma alanları için permütasyon tabanlı kriter önem skorları.	107
Şekil 2.31	: Taşınmazın toplam değerini oluşturan arsa ve yapı bileşenleri.	108
Şekil 2.32	: Arsa değerlendirme modeline ait permütasyon tabanlı kriter önem skorları.	113
Şekil 2.33	: Arsa değerlendirme modelindeki kriterlere ait SHAP değerleri.	113
Şekil 2.34	: İngiltere’de seçilen yapıli bir taşınmaza ait BCIS maliyet hesabı raporu.	114
Şekil 2.35	: Sunucusuz bulut mimarisi ile vektör veri karelerinin paylaşımı için geliştirilen sistemin iş akışı.	117
Şekil 2.36	: Sunucusuz bulut mimarisi ile raster veri karelerinin paylaşımı için geliştirilen sistemin iş akışı.	118
Şekil 2.37	: Leaflet JS ile geliştirilen Büyük Britanya taşınmaz değerlendirme bilgi portalı.....	120
Şekil 2.38	: Mapbox GL JS ile geliştirilen İstanbul taşınmaz değerlendirme bilgi portalı.	121
Şekil 2.39	: Taşınmaz değerlendirme bilgi portalı üzerinden taşınmaz bilgilerine erişim.....	122
Şekil A1	: Kümeleme analizi sonrası oluşturulan birinci değer bölgesine ait SHAP değerleri.	159
Şekil A2	: Kümeleme analizi sonrası oluşturulan ikinci değer bölgesine ait SHAP değerleri.	160
Şekil A3	: Kümeleme analizi sonrası oluşturulan üçüncü değer bölgesine ait SHAP değerleri.	161
Şekil A4	: Kümeleme analizi sonrası oluşturulan dördüncü değer bölgesine ait SHAP değerleri.	162
Şekil A5	: Kümeleme analizi sonrası oluşturulan beşinci değer bölgesine ait SHAP değerleri.	163

COĞRAFI BİLGİ SİSTEMLERİ ENTEGRELİ MAKİNE ÖĞRENMESİNE DAYALI TOPLU TAŞINMAZ DEĞERLEME MODELİNİN GELİŞTİRİLMESİ

ÖZET

Küresel arazi idaresi sisteminin temel fonksiyonlarından biri olan arazi değeri ile planlama, vergilendirme, imar uygulamaları gibi mülkiyete dayalı birçok işlemde karşılaşılmaktadır. Bu bağlamda taşınmaz değerinin uluslararası standartlara uygun, nesnel yaklaşımlar ile değerlendirilmesi oldukça önemlidir. Teknolojinin ilerlemesiyle birlikte Coğrafi Bilgi Sistemleri (CBS), Yapay Zeka ve Makine Öğrenmesi, Bulut Bilişim, Yapı Bilgi Modelleme gibi akıllı sistemlerin değerlendirme uygulamalarında kullanımı artmakta, taşınmazların değeri yüksek doğrulukla, hızlı bir şekilde belirlenebilmektedir. Taşınmazların tekil değerlemesinde kullanılan Emsal Karşılaştırma, Gelir, Maliyet gibi klasik yöntemlerden farklı olarak toplu değerlendirme yöntemi bilişim sistemlerinden faydalanarak geniş alanlarda çok sayıda taşınmazın topyekün değerlendirilmesini mümkün kılmaktadır. Öte yandan arazi idaresi sistemlerinin kavramsal model tasarımında ISO standardı olan Arazi İdaresi Alan Modeli (LADM)'yi benimseyen ülkeler, taşınmaz değerlendirme amaçlı ülke profillerini oluşturarak süreçleri daha etkin bir şekilde yürütmeyi hedeflemektedirler. Değerleme çalışmalarında CBS ve Makine Öğrenmesine dayalı yöntemlerin ön plana çıktığı görülsede bu iki yaklaşımın bütünleşik kullanımının yer aldığı çalışmalar oldukça sınırlıdır. Ayrıca toplu değerlendirme çalışmalarında taşınmazların yüzölçümü, oda sayısı gibi fiziksel özelliklerine yoğunlaşmakta, değeri oldukça etkileyen konumsal ve çevresel faktörler yeterince analiz edilmemektedir.

Tez çalışması kapsamında CBS ve Makine Öğrenmesi yöntemleri bütünleştirilerek hibrit bir değerlendirme yöntemi geliştirilmiş, konumsal analizlerle değerlendirme verilerinin zenginleştirilmesi amaçlanmıştır. Öncelikle Birleşik Krallık çalışma bölgesinde LADM'ye dayalı bir kavramsal model tasarımı yapılmış, fiziksel modele geçiş aşamasında açık kaynaklı PostgreSQL/PostGIS veritabanı oluşturulmuştur. Daha sonra CBS destekli Nominal Değerleme Yöntemi ile yakınlık, yüzey, görünürlük gibi konumsal analizler gerçekleştirilmiş, nominal arsa değer haritası oluşturulmuştur. Birleşik Krallık Kraliyet Arazi Kayıt Kurumu tarafından açık lisans ile paylaşılan gerçek konut satış verileri kullanılarak Lineer Regresyon, Rastgele Orman, XGBoost, CatBoost gibi çeşitli Makine Öğrenmesi regresyon yöntemleri ile toplu değerlendirme çalışması gerçekleştirilmiştir. Konumsal kriterler eklenmeden önce gerçekleştirilen regresyon analizi sonucunda Makine Öğrenmesi modellerinin yeterli doğruluğa ulaşamadıkları görülmüştür. CBS analizleri sonrası elde edilen konumsal kriterlerin nominal puanları öznetelik zenginleştirme yoluyla değerlendirme verisindeki taşınmazlara aktarılmıştır. Konumsal kriterlerin eklenmesi sonrası gerçekleştirilen regresyon analizinde R^2 değerinin yaklaşık %39, MAPE değerinin ise %27 civarında iyileştirildiği, yapılan oran analizleri sonucunda da çalışmanın toplu değerlendirme standartlarına uygun şekilde yeterli doğruluğa ulaştığı gözlemlenmiştir.

Öte yandan global regresyon modellerinde kriterlerin mekansal otokorelasyonu ve bölgesel önem düzeyleri dikkate alınmazken tüm çalışma bölgesi için sabit bir kriter ağırlığı alınmaktadır. Oysa değeri etkileyen faktörler konuma, çevresel ve sosyo-ekonomik etkilere bağlı olarak değişkenlik gösterebilmektedir. Mekansal otokorelasyonun hesaplanması ve tüm kriterlerin özelliklerine bağlı olarak değer bölgelerinin oluşturulması için Nominal Ağırlıklı Çok Değişkenli Mekansal Kümeleme Yöntemi geliştirilmiştir. Bu yöntem ile beş farklı değer bölgesi tespit edilmiş, her bir kümede lokal regresyon modelleri oluşturularak değerlendirme doğruluğu artırılmış, bölgelere özgü kriter önemleri ve ağırlık katsayıları elde edilmiştir. Kriter önem skorlarının için hem permütasyon tabanlı öznelik önemi hem de oyun teorisine dayanan SHAPley değerleri hesaplanmıştır. Böylece değişkenlerin bölgesel olarak değeri hangi yönde, ne derecede etkilendiğine dair sonuçlar elde edilmiştir.

Yapay zeka yöntemlerinde önyargı ve varyans dengesi, modelin öğrenme karakterini ortaya koyan önemli bir göstergedir. CBS ve Makine Öğrenmesi yöntemleri ile geliştirilen yöntem, genelleştirilebilirliğin incelenmesi amacıyla Birleşik Krallık'tan sonra Türkiye'de İstanbul ve İzmir illeri için de gerçekleştirilmiştir. Sonuçlara bakıldığında konumsal değişkenlerin katkısıyla konut amaçlı taşınmazların değeri İstanbul ve İzmir şehirleri için de yüksek doğrulukla belirlenmiştir.

Tez kapsamında ayrıca yapılı taşınmazların arsa ve bina değerlerinin ayrıştırılması için Nominal Yönteme Dayalı Parametrik Maliyet Modellemesi yaklaşımı geliştirilmiştir. Bu kapsamda yapıya ait temel bileşenlerin yeniden inşa maliyeti modellenerek toplam değerden çıkarılmış, arsa değeri Makine Öğrenmesi ile geliştirilen arsa değerlendirme modeli sonuçları ile kıyaslanmıştır. Böylelikle yapılı bir taşınmazı meydana getiren zemindeki arsanın ve üzerinde bulunan binanın değerini ayrı ayrı ifade edebilen bir değerlendirme yaklaşımı geliştirilmiştir.

Çalışmanın son aşamasında taşınmazlara ait tüm verileri ve değer haritalarını web ortamında kullanıcılarla paylaşmak için Bulut CBS tabanlı Taşınmaz Değer Bilgi Portalı geliştirilmiştir. Hem geleneksel sunucu-istemci mimarisi ile, hem de sunucusuz bulut yaklaşımı ile verilerin depolanması ve web servisleriyle paylaşılması sağlanmış, iki yöntem kıyaslanarak performans ve maliyet analizleri gerçekleştirilmiştir. Tez çalışmasında taşınmaz değerlendirme ve taşınmaz yönetimi anlamında uçtan uca tüm süreçlerin CBS ve Makine Öğrenmesine dayalı geliştirilmesi sağlanmış, sürdürülebilir arazi yönetimi paradigması çerçevesinde birlikte çalışabilir, bütüncül bir taşınmaz değerlendirme sistemi ortaya konmuştur.

DEVELOPMENT OF MASS PROPERTY VALUATION MODEL BASED ON GEOGRAPHIC INFORMATION SYSTEMS INTEGRATED MACHINE LEARNING METHODS

SUMMARY

Establishing an effective land management system has a vital role in building sustainable smart cities. Land value, which is one of the fundamental functions of the global land administration system, is encountered in many property-based transactions such as planning, taxation, zoning applications. In this sense, it is crucial to evaluate the value of properties objectively and in accordance with international standards. Advancements in technology have increased the use of intelligent systems such as Geographic Information Systems (GIS), Artificial Intelligence and Machine Learning, Cloud Computing, Building Information Modeling in mass valuation practices and improved the prediction accuracy dramatically. Unlike single-property valuation methods such as Sales Comparison, Income, and Cost approaches, which are known as classical methods, mass valuation provides evaluating a large number of properties in large areas by making use of information systems. Many countries have established a mass valuation system, especially for use in taxation studies. Moreover, other countries including Türkiye, continue to develop a national property valuation framework. On the other hand, countries that adopt a conceptual model design like ISO 19152 Land Administration Domain Model (LADM) standard, aim to carry out processes more effectively by creating country profiles for real estate valuation purposes.

Multiple Regression Analysis, Hedonic Valuation, Nominal Valuation Method, Support Vector Machines, Random Forest, Artificial Neural Networks are some of the most prominent approaches for mass valuation studies. There is also a remarkable increase in the use of ensemble Machine Learning methods in housing price prediction applications. Ensemble Machine Learning methods provides better predictive models by aggregating several methods. Yet, ensembling is less interpretable, can be computationally expensive, and lacks taking into account spatial effects. There is a need for integrating the spatial variables into the predictive model using GIS. Although it is seen that GIS and Machine Learning based methods are used in valuation practices, integrated use of these two approaches are quite limited.

In the thesis, first of all, a conceptual model based on LADM is designed in the UK study area, and an open source PostgreSQL/PostGIS database is created for transitioning to the physical model. Then, proximity, terrain, and visibility spatial analyzes are carried out in the Great Britain region covering England, Wales and Scotland. Then a nominal land value map is created with the GIS-based Nominal Valuation Method. Mass valuation process is carried out with various Machine Learning regression methods such as Linear Regression, Random Forest, XGBoost, CatBoost using HM Land Registry - Price Paid Data which records residential property sales in England and Wales. Although there are many physical variables of buildings in the valuation data, it was seen that the spatial and environmental criteria are insufficient. Therefore, the preliminary results of the regression analysis with only

physical determinants could not be performed well. In order to improve the prediction accuracy, GIS and Machine Learning based hybrid method is developed. In this sense, spatial criteria scores obtained from GIS analyses are included in the price prediction data for feature enrichment purpose. After adding locational factors to the property price data, prediction accuracy of the global regression analysis increased significantly. It is observed that the R^2 is improved by about 39% and the Mean Absolute Percentage Error value is improved by around 27%. Applying International Association of Assessors Office ratio analyzes, performance metrics such as Coefficient of Dispersion and Price-Related Differential complied with the mass appraisal standards.

Most of the house price prediction studies generate a global regression model which omits spatial variability and geographic influence of the valuation factors. Global models are based on the approach that the estimation process is location-independent or the variables have the same characteristics for the entire study area. Spatial autocorrelation of the criteria and regional feature importances could not be taken into account in the global regression models, while fixed criteria weights are applied for the entire study region. However, the factors affecting property value may vary depending on the location, environmental and socio-economic effects. Thus, Nominal Weighted Multivariate Spatial Clustering Method has been developed to calculate spatial autocorrelation and to generate value regions depending on the characteristics of the entire criteria. Hence, five different value regions have been determined with the clustering method and local regression models have been created in each cluster. Results showed that applying this novel weighted clustering approach increased the valuation accuracy and enabled obtaining region-specific feature importances and weight coefficients. To reveal local importance of the criteria that affect the property value, both permutation based feature importance and game theory based SHAPley values are calculated. SHAP summary table results shed light on how much and in which direction the variables affect the property value. The bias-variance tradeoff in artificial intelligence algorithms is an important indicator that reveals the learning characteristics of the model.

The GIS and Machine Learning hybrid valuation method is also carried out in Istanbul and Izmir provinces to examine the generalization capability of the model. According to the results, with the contribution of spatial variables, the value of residential properties is also determined with high accuracy for the cities of Istanbul and Izmir after United Kingdom case study.

In addition, within the scope of the thesis, Nominal Valuation Based Parametric Cost Modeling approach has been developed for decomposing the land and building values of the built real estates. In this context, the reconstruction cost of the basic components of the building is modeled and subtracted from the total property value, and the land value is compared with the results of the land valuation model developed with Machine Learning. Thus, a valuation approach has been developed that can separately express the value of the land on the ground and the building constructed on it.

In the last stage of the thesis, the Cloud GIS-based Real Estate Value Information Portal is developed to share all the data and value maps of the properties with the users on the web. Using both the traditional server-client architecture and the serverless cloud approach, data is stored and shared via web services, performance and cost analysis are carried out by comparing these two methods. Results showed that serverless database responded to the query faster and scaled up during high workload to decrease latency.

Hence, parcel vector data, which conveys ownership information and land values attributes, is shared directly from the PostGIS database as vector tiles. Besides S3 and AWS Lambda services are used for storing and disseminating raster-based land value map tiles. Leaflet and Mapbox GL JavaScript based web mapping libraries are used to develop the portal for providing dynamic and effective access to all information about real estates. In this study, all end-to-end processes in terms of real estate valuation and real estate management have been developed based on smart systems, and a holistic, interoperable approach has been revealed within the framework of the sustainable land management paradigm.

1. GİRİŞ

Taşınmaz mallar mülkiyet güvencesi sağlama ve değerli varlık olma özellikleri sebebiyle sosyal ve ekonomik yönlerden önemli bir çekiciliğe sahiptirler. Taşınmaz değeri, sürdürülebilir kalkınma hedeflerine ulaşmak için gerekli olan küresel arazi yönetimi modelinin önemli bir bileşenidir (Enemark, 2004). Etkin bir taşınmaz piyasasının oluşumunu destekleyen taşınmaz değerine alım satım, vergilendirme, kamulaştırma, sermaye piyasası faaliyetleri gibi birçok işlemde ihtiyaç duyulmaktadır (FAO, 2017; McDermott, Myers, ve Augustinus, 2018; UN-GGIM, 2019). Bu sebeple taşınmaz değerinin standartlara uygun, objektif bir yaklaşımla değerlendirilmesi oldukça önemlidir. Ancak taşınmaz değerini etkileyen birçok faktörün bulunması ve değerlendirme işleminin alan uzmanlığı gerektirmesi bu sürecin zorlu yönleri olarak öne çıkmaktadır. Taşınmaz değerini etkileyen çok sayıda içsel ve dışsal faktör bulunmaktadır. Değerleme çalışmalarında kullanılan bu kriterler konumsal, fiziksel ve yasal olmak üzere üç genel sınıfa ayırmak mümkündür (Bunyan Unel ve Yalpir, 2019; Wyatt, 2013; Yomralioglu, 1993).

Taşınmaza dayalı işlemlerde piyasa değerinin belirlenmesi için her yıl sayısız değerlendirme raporu oluşturulmaktadır. Öte yandan vergilendirme, kamulaştırma, imar uygulamaları, portföy yönetimi gibi çeşitli uygulamalarda hızlı ve otomatik değerlendirme yaklaşımlarına ihtiyaç duyulmaktadır. Literatürde Hedonik Değerleme, Nominal Değerleme, Çoklu Regresyon Analizi (ÇRA), Topluluk Öğrenmesi Yöntemleri, Yapay Sinir Ağları (YSA) gibi toplu değerlendirme yöntemleri yukarıda belirtilen amaçlar için yaygın olarak kullanılmaktadır (Jahanshiri, Buyong, ve Shariff, 2011; Mohd, Jamil, Johari, Abdullah, ve Masrom, 2020; Pagourtzi, Assimakopoulos, Hatzichristos, ve French, 2003; Wang ve Li, 2019). Rastgele Orman (Aydinoglu, Bovkir, ve Colkesen, 2021; Dimopoulos, Tyrallis, Bakas, ve Hadjimitsis, 2018; Ho, Tang, ve Wong, 2021; Yilmazer ve Kocaman, 2020), XGBoost (Li, 2022; Peng, Huang, ve Han, 2019), CatBoost (Wang, Wang, ve Liu, 2021; Wang ve Zhao, 2022), LightGBM (Liu, Wu, Su, Li, ve Lei, 2021; Quang, Minh, Hy, ve Bo, 2020) gibi topluluk öğrenmesi yöntemleri

birkaç zayıf tahmin modelini bir araya getirerek yüksek doğruluk sağlamaktadır. Öte yandan yorumlanması zor olan bu yöntemler yoğun bir hesaplama yükü getirmekte, değişkenlerin konuma dayalı etkilerini hesaba katmakta yetersiz kalmaktadırlar. Bu sebeple toplu değerlendirme çalışmalarında değeri önemli derecede etkileyen mekansal değişkenlerin Coğrafi Bilgi Sistemleri (CBS) ile tahmin modeline entegre edilmesine ihtiyaç vardır. Toplu değerlendirme çalışmalarında genellikle kriterlerin mekansal değişimini ve coğrafi etkisini göz ardı eden global regresyon modeli oluşturulmaktadır. Global modeller tahmin sürecinin konumdan bağımsız olduğu veya değişkenlerin tüm çalışma alanı için aynı özelliklere sahip olduğu yaklaşımına dayanmaktadır. Öte yandan, benzer özelliklere sahip veriler konumlarına göre kümelendirilerek değer bölgeleri oluşturulmalı, bu bölgelerde lokal tahmin modelleri geliştirilerek yerele özgü kriterlerin önem dereceleri ortaya çıkarılmalıdır.

Açık veri kavramı, son dönemde ülkelerin ortaya koydukları yasal irade ile önemli ölçüde artmıştır (Open Data Barometer, 2017). Açık verilerin ekonomik değer, şeffaflık, verimlilik ve kamu hizmetlerini iyileştirme gibi birçok faydası vardır (The European Data Portal, 2021). Ülkelerin ve belediyelerin açık veri portalları sayesinde kullanıcılar güncel ve doğru verilere kolaylıkla ulaşabilmektedir. Ülkemizde de son dönemde açık veri portallarının yaygınlaştığı ve coğrafi verilerin vatandaşlar ile paylaşılmasıyla birlikte endüstrileşme yolunda önemli bir katma değer oluşturduğu gözlemlenmektedir. Öte yandan Birleşik Krallık, 2010 yılından itibaren "data.gov.uk" veri portalı üzerinden çeşitli alanlarda çok sayıda veriye açık erişim sağlamıştır. Price Paid Data (PPD), İngiltere ve Galler'deki konutların çeşitli fiziksel özelliklerini ve alım-satım kayıtlarını içeren bir açık devlet verisidir (Price Paid Data, 2021). Energy Performance Certificates (EPC) verileri ise İngiltere ve Galler'deki binaların toplam yüzölçümü, enerji verimlilik değerleri, karbondioksit emisyonları, ısıtma maliyetleri gibi birçok faydalı özneliği bünyesinde barındıran bir açık veridir (EPC, 2021). Ülkenin harita kurumu Ordnance Survey de birçok temel coğrafi veri setini açık lisans ile paylaşmaktadır.

Değer haritası, planlama, yatırım yönetimi ve bölgedeki değer farklılıklarının konuma dayalı görselleştirilmesi için kullanılan güçlü bir araçtır. Arsa veya konut fiyatları posta kodu, idari birimler gibi sınırlar üzerinden gösteren çeşitli değer haritaları bulunmaktadır (Chi, Dennett, Oléron-Evans, ve Morphet, 2021c; Jennings ve

Lewis, 2017; Powell-Smith, 2018; PrimeLocation, 2021; White, 2021). Ancak bu değer haritalarının doğru ve yeterli detayda bilgiyi yansıtabilmesi için gerçek satış değerleri kullanılarak parsel ya da piksel bazında, yüksek çözünürlükle üretilmeleri gerekmektedir. Öte yandan vatandaşların anlık ve interaktif bir şekilde bilgi alabileceği parsel, bina, imar planı, yol, yeşil alan, çekim noktaları gibi coğrafi veriler ile birlikte taşınmaz değer haritalarını içeren bir web CBS arayüzüne ihtiyaç duyulmaktadır.

Tez çalışması kapsamında Uluslararası Standardizasyon Teşkilatı (International Standardization Organization - ISO)'nın 19152 Geographic information — Land Administration Domain Model (LADM) standardına uygun, birlikte çalışabilir bir taşınmaz değerlendirme modelinin tasarlanması, CBS ve Makine Öğrenmesi yöntemleri ile bütüncül bir değerlendirme sisteminin geliştirilmesi amaçlanmıştır. Çalışmanın ilk aşamasında kavramsal modelden fiziksel modele geçişin sağlanması, veri tabanının oluşturulması, konumsal verilerin ETL (Extract Transform Load) araçlarıyla standart formata dönüştürülmesi ve veri tabanına aktarılması süreçlerine yer verilmiştir. Sonrasında taşınmazlara ait kriterlerin konumsal etkilerinin nesnel bir yaklaşımla incelenmesi amacıyla CBS analizlerinin gerçekleştirilmesi, taşınmazların analiz sonucu aldıkları nominal puanların öznitelik olarak veri tabanına eklenmesi, değerlerin yüksek doğrulukla belirlenebilmesi amacıyla çeşitli Makine Öğrenmesi yöntemleri ile global regresyon analizlerinin gerçekleştirilmesini ele almaktadır. Öte yandan değeri etkileyen faktörlerin ağırlıklarının bölgesel değişimine dayalı değer bölgelerinin belirlenmesi kapsamında Nominal Ağırlıklı Çok Değişkenli Mekansal Kümeleme yönteminin geliştirilmesini ve değer bölgelerinde lokal regresyon analizlerinin gerçekleştirilmesini incelemekte, elde edilen değerlerin doğruluğunun çeşitli performans metrikleri ve oran çalışması sonucunda ölçülmesini tartışmaktadır. Çalışmanın son aşaması taşınmaz değer haritalarının üretilmesi, bulut tabanlı değer bilgi portalının geliştirilmesi ve web servisleriyle veri ve haritalara dinamik bir şekilde erişimin sağlanmasını kapsamaktadır.

1.1 Problem Tanımı

Teknolojideki gelişmelerle beraber yapay zekanın kullanımı yaygınlaştığı, çeşitli tematik alanlardaki uygulamalarında önemli bir artış olduğu görülmektedir. Güçlü ekran kartları (Graphics Processing Unit - GPU) ve bulut bilişimin sağladığı

yüksek kapasite ve hesaplama gücü ile geleneksel yöntemlerin yetersiz kaldığı karmaşık problemleri efektif bir şekilde, yüksek doğrulukla çözümlenebilmektedir (Mete ve Yomraliöglu, 2021). Kitlesel taşınmaz değerleme modellerinde yaygın kullanılan yapay zeka yöntemlerinden bazıları şunlardır: Lineer Regresyon, Polinom Regresyonu, Destek Vektör Makineleri (DVM) Regresyonu, Topluluk Öğrenmesi Regresyonları (Rastgele Orman, XGBoost, NGBost, CatBoost, LightGBM vb.) ve YSA. Doğruluk açısından Topluluk Öğrenmesi Yöntemleri (Ensemble Methods) ve YSA daha başarılı sonuçlar verdiği için son dönemlerde en çok kullanılan yöntemler olarak öne çıkmaktadırlar (Ho ve diğ, 2021; Jahanshiri ve diğ, 2011; Mohd ve diğ, 2020). Öte yandan YSA'da modelin çalışma prensibinin açıklanamıyor olmasından kaynaklı (black box model) bir dezavantaj bulunmaktadır.

Ülkemizde henüz taşınmaz değerlendirme faaliyetlerinin bütününe kapsayan özel bir kanun bulunmamaktadır. Bunun yanında değerlendirme faaliyetlerine yer veren, değer tespit çalışmaları, vergi ve harç düzenlemeleri gibi konuları içeren Kamulaştırma Kanunu, Vergi Usul Kanunu, Gelir Vergisi Kanunu, Afet Riski Altındaki Alanların Dönüştürülmesi Hakkında Kanun gibi çeşitli kanunlar taşınmaz değerlendirme mevzuatını dağınık bir şekilde oluşturmaktadır. Öte yandan 2019 yılında 4 sayılı Cumhurbaşkanlığı Kararnamesi ile Çevre, Şehircilik, İklim Değişikliği Bakanlığı, Tapu ve Kadastro Genel Müdürlüğü (TKGM) bünyesinde Taşınmaz Değerleme Dairesi Başkanlığı kurulmuş, başkanlığa taşınmazların toplu değerlendirme yöntemleriyle değerini belirlemek, değer bilgi merkezini kurmak, yönetmek ve değer haritalarının üretilmesi ile güncel tutulmasını sağlamak gibi görev ve yetkiler verilmiştir (TKGM, 2020b). Kurum ulusal ölçekte taşınmaz değerlendirme sisteminin geliştirilmesi amacıyla çalışmalarına devam etmektedir.

Avrupa İnsan Hakları Mahkemesi'ne en çok başvuru yapılan konularından biri de mülkiyet hakkının korunmasına yöneliktir (AİHM, 2021). Öte yandan, Türkiye Cumhuriyeti Adalet Bakanlığı'nın yayınladığı İnsan Hakları Eylem Planı'nda mülkiyet hakkının korunması kapsamında kamulaştırma ve imar uygulamalarında değer esaslı yaşanan sorunlar ve alınacak tedbirlerden de bahsedilmiştir (Adalet Bakanlığı, 2021). Kamulaştırma bedelinin tespiti ve tescili gibi değer uzlaşmazlığı davalarının nesnel bir yaklaşımla geliştirilecek taşınmaz değerlendirme sistemi sonucunda azalacağı, imar uygulamalarında da parsel dağıtımının değer esas alınarak yapılması ile

mevcut sorunların aşılabileceği öngörülmektedir. Etkin ve şeffaf bir değerlendirme sistemi ile devlet ve vatandaş arasında mülkiyet hakkına dair güven duygusunun artırılması ve toplumsal refaha katkı sunulması gibi kazanımların elde edilmesi mümkündür.

Birleşik Krallık'ta devlet kurumları tarafından birçok veri açık lisans ile paylaşılsa da, birlikte çalışabilirliği sağlayacak, arazi idaresi süreçlerini bütüncül bir şekilde ele alan bir sistem bulunmamaktadır. İngiltere, Galler ve Kuzey İrlanda INSPIRE altyapısının oluşturulması için çalışmalara Çevre, Gıda ve Köy İşleri Bakanlığı (Department for Environment Food & Rural Affairs - DEFRA) öncülüğünde başlanmış fakat veri temalarının çok az kısmı standartlara uygun bir şekilde dönüştürülerek paylaşılmıştır. Bu verilerden Kadastral Parsel temasındaki "INSPIRE Index Polygons" açık veri olarak paylaşılmasına karşın yakın zamanda web servisi erişimi sonlandırılmıştır. Ülkede taşınmaz değerlendirme ile ilgili çalışmalar büyük çoğunlukla Değerleme Ofisi Ajansı (Valuation Office Agency - VOA) bünyesinde yürütülmekte, fakat sistematik bir toplu değerlendirme modeli bulunmamaktadır (FIG, 2017).

Birleşik Krallık Kraliyet Arazi Kayıt Kurumu (HM Land Registry) tarafından paylaşılan PPD veri setinde konumu tarifleyen tam adres bilgisi bulunmakla birlikte, diğer veri kümeleriyle eşleşmeyi sağlayacak benzersiz bir adres tanımlayıcısı veya koordinat bilgisi içermemektedir. Öte yandan, literatürde PPD ve EPC veri setlerini birbirine bağlamak için farklı adres eşleştirme yöntemleri geliştiren birkaç çalışma bulunmaktadır (Chi, Dennett, Oléron-Evans, ve Morphet, 2021b; Fuerst, McAllister, Nanda, ve Wyatt, 2016; Powell-Smith, 2018). Chi ve diğ (2021b), 2011-2019 yılları arasında satış işlemi gerçekleştirilen konutlar için adres eşleştirmesi yaparak bütünleştirilmiş PPD-EPC veri setini açık olarak yayınlamışlardır. Ancak bu veride de kesin konum bilgisi bulunmadığı için CBS ile ayrıntılı (sokak veya parsel düzeyinde) veri analizi/analitiği yapmak mümkün değildir.

Mevcut durumda bir çok ülkede standartlara uygun, bütüncül bir değerlendirme sisteminin eksikliği öne çıkmaktadır. Değerlemeler yerel idareler veya farklı kurumlar tarafından ayrı bir düzende yürütüldüğü için benzer özelliklerdeki taşınmazların değerleri arasında çok büyük farklılıklar meydana gelmektedir (Yomralıoğlu, 2022). Ayrıca mevcut değerlendirme modelleri çoğunlukla global tahmin modellerine dayandığı için bölgesel değer farklılıklarını yansıtmakta başarısız olmakta, yerele özgü kriter

önemlerini dikkate almakta güçlük çekmektedirler. Bu bağlamda akıllı sistemlere dayalı bir toplu değerlendirme modeline ihtiyaç olduğu sonucuna varılmaktadır.

Araştırma soruları:

- 1) Coğrafi veri üreten kaynaklar ile taşınmaz değerine ihtiyaç duyan kurum-kuruluşların sistemleriyle birlikte çalışabilen, standart ve dinamik bir yapıda akıllı bir değerlendirme modeli tasarlanabilir mi?
- 2) Taşınmazların güncel değerleri Yapay Zeka ve Makine Öğrenmesi yöntemleri ile dinamik bir şekilde, yüksek doğrulukla belirlenebilir mi?
- 3) Taşınmaz değerini etkileyen kriterler ve önem ağırlıkları lokasyona göre değişir mi? Değer bölgeleri ve bölgesel kriter ağırlıkları Makine Öğrenmesi yöntemleriyle belirlenebilir mi?
- 4) CBS ile gerçekleştirilen konumsal analizlerin regresyon modellerine öznitelik olarak eklenmesiyle (öznitelik zenginleştirme) tahmin doğruluğu artırılabilir mi?
- 5) Yapılı taşınmazlarda arsa ve bina değerleri ayrı ayrı değerlendirilebilir mi? Parametrik maliyet yaklaşımı ile yapıların yeniden inşa değeri hesaplanabilir mi?

1.2 Çalışmanın Amacı

Alım-satım, emlak, vergilendirme, kamulaştırma gibi birçok faaliyette ihtiyaç duyulan taşınmaz değerlemenin yasal, ekonomik ve sosyal yönleri bulunmaktadır. Değerin doğru yöntemler kullanılarak, nesnel bir yaklaşımla, standartlara uygun şekilde belirlenmesi oldukça önem arz etmektedir. Tez çalışmasının temel amacı uluslararası standartlara uygun, güncel teknolojik araçların kullanıldığı, dinamik ve bütüncül bir taşınmaz değerlendirme sisteminin tasarlanması ve uygulanmasıdır. Böylelikle taşınmaz değerlendirme alanındaki tüm ihtiyaçlara cevap verebilecek, değere dayalı işlemlerde referans alınabilecek, nesnel ve bilimsel yaklaşıma sahip entegre bir taşınmaz değerlendirme sisteminin oluşturulması hedeflenmiştir. Bu kapsamda tez çalışması aşağıdaki alt amaçları içermektedir:

- Literatürdeki mevcut kitlesel değerlendirme yöntemleri ve uygulamalarının incelenmesi,
- Kavramsal tasarım kapsamında ISO 19152 LADM arazi idaresi standardına uygun, birlikte çalışabilir bir değerlendirme modelinin oluşturulması,
- Kavramsal veri modelinden fiziksel modele geçişin sağlanmasıyla veri tabanının oluşturulması ve verilerin ETL araçlarıyla standart bir yapıda veritabanına aktarılması,

- CBS destekli Nominal Yöntem ve Makine Öğrenmesi hibrit yöntemi ile konumsal analiz, kümeleme analizi ve regresyon analizini içeren toplu taşınmaz değerlendirme modelinin geliştirilmesi,
- Konumsal veriler ile öznitelik zenginleştirilmesi sonucunda tahmin doğruluğunun artırılması,
- Kriterlerin önem skorlarının belirlenmesi için permütasyon tabanlı önem düzeylerinin ve açıklanabilir yapay zeka ile SHapley Additive exPlanations (SHAP) değerlerinin hesaplanması,
- Doğruluk analizi ve oran çalışması yapılarak oluşturulan değerlendirme modelinin test edilmesi,
- Elde edilen değerler kullanılarak taşınmaz değer haritalarının üretilmesi,
- Yapılı taşınmazların arsa ve bina değerlerinin ayrıştırılması için nominal yönteme dayalı parametrik maliyet modellenin geliştirilmesi,
- Bulut CBS tabanlı değer bilgi portalının geliştirilmesiyle değer haritalarına ve taşınmaz verilerine web üzerinden erişimin sağlanması.

Tez çalışmasının özgün değerleri aşağıdaki şekilde sıralanabilir:

- 1) CBS ve Makine Öğrenmesi hibrit yöntemi ile toplu değerlendirme yaklaşımında öznitelik zenginleştirmeye dayalı analizlerin gerçekleştirilmesi ve değerlendirme doğruluğunun konumsal kriterlerin bütünleştirilmesi sonucunda önemli derecede artırılması.
- 2) Nominal Ağırlıklı Çok Değişkenli Mekansal Kümeleme yönteminin geliştirilmesi ile kriterlerin ağırlıklı etkileri kullanılarak değer bölgelerinin belirlenmesi ve bu bölgelere özgü kriter önemleri ile ağırlıklarının elde edilmesi sonucunda yüksek doğruluklu lokal regresyon analizinin gerçekleştirilmesi.
- 3) Nominal Yönteme Dayalı Parametrik Maliyet Modellemesinin geliştirilmesi ile yapıları taşınmazlarda arsa ve bina değerlerinin ayrıştırılması.
- 4) İngiltere ve Galler’de PPD-EPC verisi kullanılarak Makine Öğrenmesi ile ilk defa toplu değerlendirme çalışmasının gerçekleştirilmesi.
- 5) Toplu değerlendirme çalışmasının tüm süreçlerinin açık kaynaklı yazılımlar ve açık lisanslı veriler ile gerçekleştirilmesi.
- 6) Toplu değerlendirme çalışmalarında bölgesel önem düzeylerinin ilk defa kümeleme analizi sonrası SHAP yöntemi ile elde edilmesi.

7) Birleşik Krallık için LADM Değerleme Bilgi Modeli (LADM_VM) standardına dayalı ülke profilinin geliştirilmesi.

1.3 Metodoloji

Dünyada ve ülkemizde toplu taşınmaz değerlendirme ile ilgili yapılan çalışmalarda son yıllarda artış görülmektedir (Jahanshiri ve diğ, 2011; Mohd ve diğ, 2020; Pagourtzi ve diğ, 2003; Wang ve Li, 2019). Literatürdeki çalışmalara bakıldığında, ulusal ve uluslararası standartlara uygun, birlikte çalışabilir, etkin ve bütüncül bir taşınmaz değerlendirme sisteminin tüm ülkelerde önemli bir ihtiyaç olduğu ortaya çıkmaktadır. Sürdürülebilir kalkınma hedefleri kapsamında arazi idaresi sistemlerinin verimli bir şekilde oluşturulması için birçok uluslararası organizasyonun iş birliği içerisinde çalışmalar yürüttüğü görülmektedir. Tez çalışması arazi idaresinin en önemli parçalarından biri olan taşınmaz değerlendirme sisteminin güncel teknolojilerden faydalanarak tüm yönleriyle ele alınmasını ve değer esaslı tüm uygulamalarda kullanılabilir şekilde modellenmesini kapsamaktadır.

Tez kapsamında bir yurtiçi, bir de yurtdışı olmak üzere iki çalışma bölgesi belirlenmiş, yöntemlerin iki farklı bölgede, farklı veri setleri kullanılarak uygulanması ve sonuçların karşılaştırılması planlanmıştır. İlk çalışma bölgesi nüfus ve taşınmazlara dayalı işlemlerin yoğun olduğu İstanbul ve İzmir şehirleri seçilmiştir. Yurtdışında ise açık verinin yaygın olduğu, taşınmazların gerçek değer üzerinden yapılan alım-satım işlemlerine ait verilerin paylaşıldığı Birleşik Krallık'a bağlı İngiltere ve Galler ülkeleri seçilmiştir.

Tez kapsamında önerilen taşınmaz değerlendirme sisteminin kavramsal modelinin ISO/TC211 Geographic Information/Geomatics komite standartlarına uygun bir şekilde tasarlanması, kavramsal modelden fiziksel modele geçişin otomatik olarak yapılması (Model Driven Architecture) ile veri tabanının oluşturulması, ETL araçları ile tüm verilerin standart formata dönüştürülerek veri tabanına aktarılması, CBS analizleri ile taşınmaz değerini etkileyen konumsal faktörlerin değerlendirilmesi, Yapay Zeka ve Makine Öğrenmesi yöntemleriyle taşınmaz değerlerinin elde edilmesi, değer haritalarının üretilmesi ve değer bilgi portalının geliştirilmesiyle taşınmaz değerlerine web üzerinden dinamik olarak erişilebilmesi sağlanmıştır. Bu hibrit

yöntem, dünya genelinde herhangi bir şehre ve değerlendirme veri setine kolaylıkla uygulanabilir, yüksek doğruluklu bir toplu değerlendirme yaklaşımı önermektedir.

Kavramsal modelleme aşamasında LADM temelli toplu taşınmaz değerlemenin tüm amaçlara (vergilendirme, alım-satım, kamulaştırma vb.) ve taşınmaz tiplerine (arazi, arsa, bina) uygun tasarlanması ile bütüncül bir değerlendirme sistemi oluşturulmuştur. Bu kapsamda Birleşik Krallık için taşınmaz değerlendirme amaçlı LADM ülke profili oluşturulmuş, ilgili sınıflar ve kod listeleri hazırlanarak ilişkilerin tanımlaması yapılmıştır.

Veri ön işleme, dönüştürme aşamasında aykırı verilerin temizlenmesi, boş özniteliklerin kontrolü, kriterler arasında çoklu doğrusal bağlantı (multicollinearity) durumunun kontrolü gibi açıklayıcı veri analizleri (Exploratory Data Analysis - EDA) gerçekleştirilmiştir. Birlikte çalışabilirlik kapsamında ETL araçları ile verilerin uygun formata dönüştürülmesi ve veritabanına aktarılması sağlanmıştır.

Veri analizi kapsamında yakınlık, görünürlük, yüzey gibi CBS analizleri gerçekleştirilmiş, değeri etkileyen çevresel, fiziksel, yasal ve sosyo-kültürel faktörlerin değerlendirilmesi yapılmıştır. Yakınlık analizinde sağlık, eğitim merkezleri, toplu taşıma istasyonları, alışveriş merkezleri gibi önemli yerlere olan öklid mesafesi hesaplanmıştır. Görünürlük analizi kapsamında deniz, boğaz, orman gibi manzaralara sahip taşınmazları belirlemek amacıyla üç boyutlu analizler gerçekleştirilmiştir. Yüzey analizinde ise taşınmazların bulunduğu konumdaki topografik yapıyı ifade eden eğim ve bakı analizleri gerçekleştirilmiştir.

Denetimsiz öğrenme yöntemlerinden biri olan kümeleme analizinin, taşınmaz değerlendirme alanında çeşitli kullanım örnekleri bulunmaktadır (Calka, 2019; Guo, Wang, Shi, ve Cao, 2012). Benzer yapısal özelliklere sahip değer bölgelerinin tespiti için bölünmeli (partitional), hiyerarşik ve yoğunluk temelli kümeleme (clustering) algoritmaları kullanılabilir. Tez çalışmasında Nominal Ağırlıklı Çok Değişkenli Mekansal Kümeleme Analizi gerçekleştirilerek kümelenen bölgelerdeki temel kriterler ile bölgesel kriter ağırlıklarının belirlenmesi ve farklı yerleşim yerlerinin özgün şehir dokuları ile sosyo-kültürel farklılıklar sebebiyle oluşan tercihlerin kriter ağırlıklarına yansıtılması sağlanmıştır.

Analizler sonucunda taşınmaz değerlerinin belirlenmesi amacıyla ÇRA'nın yanısıra XGBoost, NGBoost, CatBoost, LightGBM, Rastgele Orman gibi topluluk öğrenmesi (ensemble) yöntemleri kullanılmıştır. Toplu değerlendirme yönteminin matematik modeli bu aşamada oluşturularak değer kestiriminin yüksek doğrulukla yapılması sağlanmıştır. Regresyon analizleri kapsamında Rastgele Arama (Randomized Search), Çapraz Doğrulanmış Ağ Araması (Cross-validated Grid Search), Regülerizasyon gibi öznitelik seçim yöntemleri uygulanmış, tahmin modelinin hiperparametre optimizasyonu gerçekleştirilmiştir.

Doğruluk analizi ve oran çalışması ile değer kestirimi tamamlanmış, taşınmazların nihai değeri elde edilmiştir. Tez çalışmasında model performansının ölçülmesi için Belirtme Katsayısı (R^2), Düzeltilmiş Belirtme Katsayısı (R^2), Ortalama Önyargı Hatası (Mean Bias Error - MBE), Ortalama Mutlak Hata (Mean Absolute Error - MAE), Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error - MAPE), Karesel Ortalama Hata (Root Mean Square Error - RMSE), Dağılım Katsayısı (Coefficient of Dispersion - COD) ve Fiyat İlişkili Farklılık (Price-related Differential - PRD) ölçütleri kullanılmıştır.

Taşınmaz değerlerinin elde edilmesi sonrasında yüksek çözünürlükle raster değer haritaları oluşturularak değer dağılımları ortaya konmuştur. Değer haritalarının üretilmesinde Nominal yöntem (Yomraliöglu, 1993) kullanılmış, faktör ağırlıkları ise Makine Öğrenmesi regresyonu sonucunda öznitelik önem skorları ile elde edilmiştir. Oluşturulan değer haritaları GeoServer coğrafi veri sunucusu üzerinden web servisi ile paylaşılmıştır. Ayrıca çalışmanın geniş alanlarda uygulanması sonucunda veri hacminin büyük olması ve yoğun web trafiğine karşı verimliliğin sağlanabilmesi için Bulut Bilişim üzerinden sunucusuz mimari ile veriler paylaşılmıştır. Web servisleriyle paylaşılan vektör ve raster formatındaki değerlendirme verilerinin web üzerinden kullanıcılarla paylaşılması, taşınmazların sözel veya grafik sorgularla değerlerinin gösterilmesi için JavaScript tabanlı web harita kütüphaneleri kullanılarak değer bilgi portalı geliştirilmiştir.

Çalışma kapsamında ağırlıklı olarak açık kaynaklı yazılımlar ve açık lisans ile paylaşılan veriler kullanılmıştır. Örneğin; kavramsal veri modelinin tasarımı için Enterprise Architect, veri tabanı yönetim sistemi olarak PostgreSQL/PostGIS, masaüstü CBS yazılımı olarak QGIS, veri ön işleme, coğrafi kodlama, Makine Öğrenmesi

yöntemlerinin uygulanması için Python kullanılmıştır. Coğrafi veriler OpenStreetMap (OSM), Ordnance Survey, Avrupa Çevre Ajansı (European Environment Agency - EEA) Copernicus Land Monitoring Service, İstanbul Büyükşehir Belediyesi Açık Veri Portalı, İzmir Büyükşehir Belediyesi Açık Veri Portalı gibi veri kaynakları kullanılarak elde edilmiştir.

1.4 Literatür Araştırması

Taşınmaz değerlemesi, taşınmazların konuma bağlı sahip oldukları fiziksel, ekonomik, yasal ve çevresel niteliklerinin bütüncül bir şekilde dikkate alınarak, güncel piyasa koşullarındaki birim değerlerinin tahmin edilmesi işlemidir (Yomralıoğlu, 1997). Dünya genelinde taşınmazların değerlemesinde yaygın olarak klasik yöntemler olarak bilinen Emsal (Karşılaştırma), Gelir ve Maliyet Yöntemi kullanılmaktadır. Fakat bu yöntemler ile sadece tekil taşınmazın kıymetlendirilmesi yapılabilmektedir. Öte yandan günümüzde vergilendirme, imar uygulamaları vb. birçok faaliyette belli bir alandaki taşınmazların kitlesel değerlemesine gereksinim duyulmaktadır. Dünyada ve ülkemizde kitlesel taşınmaz değerlendirme ile ilgili yapılan çalışmalarda son on yıllık dönemde artış görülmektedir.

Jahanshiri ve diğ (2011), kitlesel değerlendirme yöntemlerinden ÇRA, Mekansal Otoregresif Modeller, Coğrafi Ağırlıklı Regresyon (Geographically Weighted Regression – GWR) ve Kriging yöntemlerini özetleyerek avantaj ve dezavantajlarını incelemişlerdir. Çalışmada ÇRA yönteminin doğruluğunun diğer yöntemlere göre daha düşük olduğu, GWR yönteminin ise değişkenlerin konuma bağlı durumları göz önüne alındığı için taşınmaz değerlemede daha sağlıklı sonuçlar elde edildiği belirtilmektedir.

Gunes ve Yıldız (2015), TKGM'nin Tapu ve Kadastro Modernizasyon Projesi kapsamında İstanbul'un Fatih ilçesi ile Ankara'nın Mamak ilçesinde ÇRA, YSA ve Karar Ağaçları yöntemlerini kullanarak kitlesel değerlendirme çalışması gerçekleştirmişlerdir. Çalışmada değeri etkileyen kriterlerin parsel özellikleri, imar hakları, uzaklık, bina özellikleri ve bağımsız bölüm özellikleri olmak üzere beş sınıfa ayrıldığı, toplamda ise 80 bağımsız değişkenin kullanıldığı belirtilmiştir. Çalışma sonucunda en yüksek doğruluğa sahip yöntemin YSA olduğu, fakat modelin oluşturulmasında ve sonucunun açıklanmasındaki zorluklar sebebiyle ÇRA yönteminin daha kullanışlı olduğu vurgulanmıştır.

Erdem (2017) ülkemizdeki ve dünyadaki kitlesel taşınmaz değerlendirme mevzuatını ve uygulama yöntemlerini inceleyerek Türkiye için bir kitlesel değerlendirme modeli önermiş, modelin ekonomik ve sosyal yönlerden önemli katkılar sunacağı vurgulanmıştır. Amerika Birleşik Devletleri, Kanada, İspanya ve çeşitli Baltık ülkelerinin kitlesel değerlendirme faaliyetlerinin incelendiği çalışmada, ülkemizde yaşanan sorunlardan da bahsedilerek çeşitli öneriler sunulmuştur.

Yalprı (2018), farklı aktivasyon fonksiyonlarına sahip YSA ve ÇRA ile Konya ilinde kitlesel değerlendirme çalışması gerçekleştirmiştir. Çalışmada en yüksek doğruluğa sahip yöntemin adaptif aktivasyon fonksiyonuna sahip ileri beslemeli YSA olduğu belirtilmiştir.

Bilgilioğlu (2018), Makine Öğrenmesi yöntemleri ile Aksaray iline ait kitlesel taşınmaz değer haritası üretmiş, yöntemlerin performanslarını istatistiksel doğruluk analizleri gerçekleştirerek kıyaslamıştır. Ayrıca MATLAB yazılımı ile tüm yöntemlerin bir arada kullanılarak taşınmaz değerlerinin belirlenebileceği bir kullanıcı arayüzü geliştirmiştir.

Baldominos, Blanco, Moreno, Iturrarte, Bernárdez, ve Afonso (2018) Karar Ağaçları, k-En Yakın Komşuluk, DVM ve YSA gibi Makine Öğrenmesi yöntemlerini kullanarak taşınmaz değerlendirme ve listeleme yapan bir araç geliştirmişlerdir. Çalışmada İspanya'nın Madrid şehrindeki taşınmazların bir emlak web sayfasından (Idealista) gerçek zamanlı çekildiği, Python ortamında değer tahmini ve doğruluk analizlerinin gerçekleştirilmesiyle kullanıcılara fiyat üzerinden çeşitli yatırım önerilerinin sunulduğu belirtilmiştir. Uygulanan yöntemler arasında doğruluk açısından Topluluk Öğrenmesi yöntemlerinin öne çıktığı vurgulanmıştır.

Demetriou (2018), doğrusal ve doğrusal olmayan iki farklı hedonik değerlendirme modeli geliştirerek Güney Kıbrıs'ta arazi toplulaştırması için CBS destekli kitlesel değerlendirme çalışması gerçekleştirmiştir. Doğrusal olmayan ÇRA yönteminin doğrusal yöntemle kıyasla daha yüksek doğruluğa sahip olmasına karşın, her iki yöntemin arazi toplulaştırması çalışmalarında kullanılabileceği belirtilmiştir. Çalışmada ayrıca uluslararası standartlara dayalı oran çalışması gerçekleştirmiş, değerlendirme sonucunun %95 güven aralığında hesaplandığı vurgulanmıştır.

Bovkir ve Aydinoglu (2018) arazi deęerleme amalı birlikte alıřabilir bir kavramsal veri modeli geliřtirmişlerdir. Türkiye Ulusal Coęrafi Bilgi Sistemleri (TUCBS)'nin Tapu Kadastro temasının eklentisi olarak geliřtirilen TK_TasinmazDeğer modeli kullanılarak İstanbul'un Pendik ilçesinde Bulanık Mantık yöntemiyle kitlesel deęerleme alıřması gerekleřtirilmiştir. alıřmada deęeri etkileyen kriterleri temsil eden tematik grupların aęırlıklarının literatürdeki eřitli kaynaklardan faydalanılarak hesaplandığı ve ortalamaya göre normalize edildiğı açıklanmıştır. Faktörlerin aęırlıklı toplamıyla (weighted overlay) alıřma bölgesine ait deęer haritasının raster formatında üretildiğı, daha sonra deęerlerin parsellere öznitelik olarak eklendiğı görülmektedir.

Bunyan Unel ve Yalpir (2019), Konya'nın Seluklu ilçesinde ok Kriterli Karar Verme (KKV) Yöntemlerinden Analitik Hiyerarři Süreci (AHS) ve RA ile kitlesel deęerleme alıřması yaparak yöntemlerin performanslarını kıyaslařmışlardır. Deęeri etkileyen 12 kriter ile 250 parselin kitlesel deęerlemesinin yapıldığı alıřmada RA yöntemine kıyasla, AHS yöntemi ile daha yüksek doęruluęun elde edildiğı belirtilmiştir.

Dünya genelinde etkin bir arazi yönetimi sisteminin kurulması, mülkiyet hakkının korunması gibi sürdürülebilir kalkınma hedeflerini destekleyen konular üzerinde alıřan uluslararası birçok organizasyonun alıřma grupları bulunmaktadır. Etkin Arazi Yönetimi Altyapısı (Framework for Effective Land Administration - FELA), Birleřmiş Milletler Global Mekansal Bilgi Yönetimi Topluluęu (United Nations Global Geospatial Information Management - UN-GGIM) tarafından üye ülkelere arazi yönetimi ve idaresi süreçlerinde Sürdürülebilir Kalkınma Hedefleri doęrultusunda politika rehberliğı sunma amacıyla geliřtirilmiştir (UN-GGIM, 2019). Etkin arazi yönetiminin tanımlanması amacıyla yayınlanan raporda; uygun, yeterli, birlikte alıřabilir, sürdürülebilir, esnek, kapsayıcı ve amaca uygun (fit-for-purpose) arazi yönetimi kavramlarının üzerinde durulmuřtur. Öte yandan, etkin arazi idaresinin arazi deęeri ve arazi geliřtirme bileřenlerini ieren etkin arazi pazarını desteklemesinin gereklilięini belirten UN-GGIM, LADM'nin kullanılmasıyla birlikte araziye dair verilerin birlikte alıřabilir ve kolay eriřilebilir olacaęını, bunun sonucunda da ülkelerin ekonomik geliřimlerinin eřitlikçi ve adil bir vergilendirme sistemine sahip olabileceęini vurgulamaktadır.

Açık Mekansal Bilişim Birliği (Open Geospatial Community - OGC) yayımladığı teknik raporda arazi yönetimi alanında genel bir değerlendirme yaparak uygulama standartlarının tasarımı ve geliştirilmesi için atılması gereken adımlar hakkında öneriler sunmuştur (Lemmen, van Oosterom, Kalantari, Unger, ve De Zeeuw, 2019a). Ayrıca arazi yönetiminin blokzincir, uzaktan algılama vb. güncel teknolojilerle desteklenerek arazi ve insan arasındaki dinamik ilişkinin sürdürülmesi gerektiği belirtilmiştir. Bu kapsamda, standart yapıda temel bir model sunan LADM'nin kullanılması, etkin arazi idaresinin gelişimine önemli bir katkı vereceği değerlendirilmektedir. LADM'nin mali eklentisinden de bahseden raporda, temel arazi idaresi veri tabanında bulunan taşınmaz değerlendirme sicillerinin tapu ve kadastro, nüfus, adres gibi diğer kamu kurumlarının veri tabanlarıyla ilişkilendirilmesi gerektiği, bunun da LADM ana modülü ve değerlendirme modeli ile mümkün olacağı belirtilmektedir. Öte yandan LADM'nin ikinci sürümünde yer alması planlanan LADM_VM açıklanmış, bu kapsamda OGC, ISO, Uluslararası Haritacılar Birliği (International Federation of Surveyors – FIG), UN-GGIM gibi organizasyonlarla yapılacak işbirliklerine değinilmiştir.

Lemmen, Van Oosterom, Kara, Kalogianni, Shnaidman, Indrajit, ve Alattas (2019b) LADM'nin ilk sürümü üzerinde yapılması planlanan iyileştirmeler ve eklemelerden bahsederek, ikinci sürüm ile modelin daha çok semantik içereceğini belirtmiştir. Bu kapsamda FIG tarafından ISO TC 211'e Yeni Çalışma Ögesi Önerisi (New Working Item Proposal) sunulmuştur (Kara, Çağdaş, Işıkdag, van Oosterom, Lemmen, ve Stubkjær, 2017; Lemmen ve diğ., 2019a,b; van Oosterom, Kara, Kalogianni, Shnaidman, Indrajit, Alattas, ve Lemmen, 2019). Ülkelerin arazi idare sistemlerinde LADM'yi kullanabilmeleri için önerilerin sunulduğu çalışmada INSPIRE uyumlu veri altyapısına sahip ülkelerde Kadastral Parsel temasının LADM tabanlı olması sebebiyle uyum sıkıntısının olmayacağı belirtilmiştir.

Mohd ve diğ. (2020) literatürde kullanılan konut değerlendirme amaçlı kitlesel taşınmaz değerlendirme yöntemlerini özetlemiştir. YSA, Hedonik Değerleme Bulanık Mantık, DVM, Lineer Regresyon, Karar Ağaçları, Rastgele Orman, Naive Bayes, Çoklu Regresyon, Gradyan Artırma gibi birçok yöntemin açıklandığı çalışmada yöntemlerin avantaj ve dezavantajlarına da yer verilmiştir.

Yilmazer ve Kocaman (2020) ÇRA ve Rastgele Orman yöntemleriyle Ankara'nın Mamak ilçesindeki taşınmazların kitlesel değerlendirme çalışmasını gerçekleştirmişlerdir. Çalışmada TKGM tarafından üretilen 2013 – 2018 yılları arasındaki satış, değerlendirme raporları ve mahkeme kararlarını kapsayan değerlendirme verisinin kullanıldığı belirtilmiştir. Veride bulunan 96 kriterin 37'si seçilerek her iki yöntemde taşınmaz değerleri belirlenmiş, doğruluk analizleri gerçekleştirilmiştir. Değerlendirme sonuçlarına göre ÇRA yöntemine kıyasla Rastgele Orman yöntemi ile daha yüksek doğruluk elde edildiği belirtilmiştir.

Aydinoglu ve diğ (2021), TUCBS altyapısını kullanan, birlikte çalışabilir bir kitlesel taşınmaz değerlendirme modeli geliştirmiş, Makine Öğrenmesi yöntemlerinden Rastgele Orman algoritmasını kullanarak İstanbul'un Pendik ilçesinde taşınmaz değer haritası üretmişlerdir. Parsel, bina ve bağımsız bölümlerin değerlemesine olanak sunacak şekilde tasarlanan kavramsal modelde, bina ve bağımsız bölüm değerlendirme kapsamında değeri etkileyen hem coğrafi, hem de coğrafi olmayan faktörlerin baz alındığı belirtilmiştir. 1459 konut nitelikli taşınmaza ait değerlerin ve özniteliklerin kullanıldığı çalışmada değeri etkileyen kriterler; parsel planlama özellikleri, yasal özellikler, ulaşım, sosyo-kültürel faktörler, kamu hizmetleri, bina özellikleri, çevresel faktörler ve kullanım düzeyi olarak yedi sınıfa ayrılmıştır. Kavramsal model tasarımından fiziksel modele geçiş için FME yazılımında ETL araçlarının kullanıldığı, böylelikle modele uygun standart formatta verilerin veri tabanı içerisinde elde edildiği belirtilmiştir. Rastgele Orman algoritmasıyla yapılan regresyon analizi sonucunda taşınmazların değeri 0.85 korelasyon katsayısı ile, 0.08 RMSE ve 0.05 MAE ile belirlendiği açıklanmıştır. Son olarak Median Ratio, COD ve PRD oran çalışmalarıyla kitlesel değerlendirme işleminin kalitesi ölçülmüş, oranların sınır değerler içerisinde kalması ile tüm bölgeyi kapsayan taşınmaz değer haritası üretilmiştir.

Kara, van Oosterom, Çağdaş, Işıkdag, ve Lemmen (2020) LADM_VM ile taşınmazların değerini etkileyen dış faktörlerin üç boyutlu (3B) veriler kullanılarak değerlendirilmesini ve 3B konumsal analizlerinin (görünürlük, gürültü, vb.) gerçekleştirilmesini ele almışlardır. LADM_VM'nin konut tipindeki taşınmazların fiziksel özelliklerini, geometrik ve yasal durumlarıyla ele alacak şekilde tasarlandığı, konumsal ve çevresel özelliklerini dikkate almadığı vurgulanmıştır. Bu çalışma ile değeri etkileyen dış faktörlerin de ele alındığı, 3B CBS analizleri taşınmaz değerine etkisinin

irdelendiği belirtilmiştir. Çalışmada 3B görünürlük analizi kapsamında kullanılan veri türüne (LIDAR nokta bulutu, bina vektör verisi ve TOP10NL topografya haritası) göre elde edilen engel (obstacle) modelleri ile dört farklı analiz gerçekleştirilmiş, modellerin doğrulukları ve performansları kıyaslanmıştır. Son olarak görünürlük analizinin sonuç verisi ile arazi kullanım verisi bindirilerek (overlay) bir bağımsız bölümün hangi arazi sınıfında ne kadarlık görünür alana sahip olduğu hesaplanmıştır.

Kara, Çağdaş, Isikdag, van Oosterom, Lemmen, ve Stubkjaer (2021) LADM_VM kullanarak Türkiye için arazi idaresi ülke profili tasarlamış, emlak vergisi amaçlı taşınmaz değerlendirme modeli geliştirmişlerdir. Oluşturulan ülke profilinin LADM_VM ile LADM'nin ana bileşenlerinin kombinasyonu şeklinde tasarlandığı belirtilmektedir. Bu kapsamda öncelikle LADM'de varolan, ülke profiline uygun sınıflar ana bileşenden alınması (inherit), LADM'de bulunmayan kavramların ise yeni sınıf olarak modele eklenmesi, sınıf özelliklerinin ve kod değer listelerinin güncellenmesi ve sınıf ilişkilerinin ve sınırlamalarının belirlenmesi gerektiği açıklanmıştır. Mevcut değerlendirme modeline Maliyet Yöntemi (VM_CostApproach) sınıfı eklenerek bina vergisinde kullanılan yöntemin modelde tanımlanması sağlandığı, Bina Kalite Sınıfı (TR_BuildingQualityType), Parsel Kullanım Türü (TR_ParcelUseType) ve Yasal Durum (TR_LegalStatusType) gibi kod değer listelerinin eklendiği belirtilmiştir. Çalışmada kavramsal modelden fiziksel modele geçişi sağlayarak veritabanı ve coğrafi veri formatlarının oluşturulması amacıyla INTERLIS, Enterprise Architect ve ShapeChange kavramsal modelleme dili yazılımlarının kullanıldığı belirtilmiş, performans kıyaslaması yapılmıştır. Enterprise Architect yazılımının fiziksel modele otomatik dönüştürme aşamasında kısıtlarının olduğu, dönüşüm sonrası bazı düzenlemelerin gerektiği vurgulanmış, INTERLIS ve ShapeChange yazılımlarının bu konuda çeşitli avantajlarının olduğu ifade edilmiştir. Birleşik Modelleme Dili (Unified Modeling Language - UML) ve INTERLIS kavramsal şema dillerinde geliştirilen değerlendirme modeli, TKGM'nin İstanbul ili Fatih ilçesinde ürettiği kitlesel değerlendirme veri seti kullanılarak test edilmiş, veri tabanındaki veriler GML ve GeoJSON formatlarına dönüştürülmüştür. Çalışmada son olarak kitlesel değerlendirme çalışmaları için TKGM Modernizasyon Projesi ile yeni bir ülke profilinin gerekebileceği, mevcut modelin de daha detaylı ve büyük bir veri setiyle test edilmesi gerektiği vurgulanarak teknik anlamda çalışma önerilerine değinilmiştir.

Ho ve diğ (2021) DVM, Rastgele Orman ve Gradyan Artırma yöntemlerini kullanarak Hong Kong'da bulunan 40.000 konut için yüzölçümü, bina yaşı, kat seviyesi, şehir merkezine erişilebilirlik ve bakı gibi kriterlerle kitlesel değerlendirme çalışması gerçekleştirmişlerdir. Yöntemler detaylı bir şekilde açıklanarak güçlü ve zayıf yönleri de vurgulanmıştır. Çalışmada değer tahmin başarısını gösteren R^2 değeri en yüksek olan yöntem 0.90365 ile Gradyan Artırma yöntemidir.

Sisman ve Aydinoglu (2022a) global ve lokal regresyon modellerinin konut amaçlı taşınmaz değerlendirme çalışması kapsamında performanslarını kıyaslamış, değeri etkileyen kriterlerin coğrafi değişimini incelemişlerdir. İstanbul'un Pendik ilçesinde gerçekleştirilen çalışmada kullanılan GWR ve Çok Ölçekli GWR gibi lokal modellerin global modellere göre daha iyi performans gösterdiği vurgulanmış, çalışma bölgesi için yüzölçümü, kat sayısı, kat seviyesi, banyo sayısı, oda sayısı, bina yaşı, asansör, metro istasyonlarına yakınlık ve ibadet yerlerine yakınlık gibi kriterlerin öne çıktığı belirtilmiştir.

Literatürdeki çalışmalara bakıldığında, ulusal ve uluslararası standartlara uygun, birlikte çalışabilir, etkin ve bütüncül bir taşınmaz değerlendirme sisteminin tüm ülkelerde önemli bir ihtiyaç olduğu ortaya çıkmaktadır. Sürdürülebilir kalkınma hedefleri kapsamında arazi idaresi sistemlerinin verimli bir şekilde oluşturulması için bir çok uluslararası organizasyonun işbirliği içerisinde çalışmalar yürüttüğü görülmektedir. Bu tez çalışması ile arazi idaresinin en önemli parçalarından biri olan taşınmaz değerlendirme sisteminin güncel teknolojilerden faydalanarak tüm yönleriyle ele alınması, değer esaslı tüm uygulamalarda kullanılabilir kapsamda modellenmesi amaçlanmaktadır.

Konut, ofis gibi yapı taşınmazların değerlemede arsa ve bina değeri olarak ayrıştırılması, emlak vergisi, kentsel dönüşüm, arazi geliştirme gibi uygulamalar için büyük öneme sahiptir (Özdilek, 2016). Literatürde arsa ve yapı değerlerinin ayrı ayrı elde edilebilmesini amaçlayan Hedonik Değerleme (Been, Gould Ellen, ve Gedal, 2009; Malpezzi, 2003; Nichols, Oliner, ve Mulhall, 2013; Wentland, Ancona, Bagstad, Boyd, Hass, Gindelsky, ve Moulton, 2020), İndirgenmiş Maliyet (Bourassa, Hoesli, Scognamiglio, ve Zhang, 2011; Davis, Larson, Oliner, ve Shui, 2021; Davis, Oliner, Pinto, ve Bokka, 2017; Davis ve Palumbo, 2008), Arazi Kaldırıcı (Ahlfeldt ve McMillen, 2018; Bostic, Longhofer, ve Redfearn, 2007; Thorsnes, 1997) gibi çeşitli yöntemler yer almaktadır.

Hedonik Değerleme yönteminde boş arsa satış değerleri kullanılarak bir regresyon analizi gerçekleştirilmekte, arsa değeri ve bu değeri etkileyen yüzölçümü, imar durumu, topografik durum ve konumsal özellikler gibi değişkenler arasındaki ilişki matematiksel olarak ifade edilmektedir. Bu yöntem gerçek arsa satış değerlerine ulaşmanın zorluğu, arsa satışlarının diğer taşınmaz türlerine göre daha az olması ve arsaların konumdan dolayı sahip oldukları özgün özelliklerinin tespit ve değerlendirmesinin zor olması sebebiyle arsa-yapı değeri ayrıştırmasında etkin olarak kullanılamamıştır (Bourassa ve Hoesli, 2022).

İndirgenmiş Maliyet yöntemi ise yapıyı taşınmazların inşaat maliyetlerinin hesaplanması ve bu maliyetin toplam değerden çıkarılarak arsa değerinin elde edilmesi esasına dayanmaktadır. Artık yöntem olarak da bilinen bu yaklaşımda inşaat maliyetleri, yapı yıpranma durumu göz önünde bulundurularak hesaplanmaktadır. Yapıların güncel maliyetlerinin detaylı bir şekilde hesaplanmasını gerekli kılan bu yöntem için kullanılan konut değerlendirme verilerinde maliyet ile ilgili özniteliklerin genellikle yer almadığı görülmektedir (Devaney, Crosby, ve Wyatt, 2018).

Arsa ve yapı değerinin ayrıştırılmasında kullanılan bir diğer yöntem de Arazi Kaldırıcı yaklaşımıdır. Bu yöntemde geçmişte boş arsa niteliğinde satışı gerçekleşen taşınmazların zaman içinde geliştirilmesi ile birlikte yapıyı olarak satışını ve bu satışlar arasındaki değer farkını ele almaktadır. Bu yaklaşım ile arsa değerinin taşınmazın tamamına oranını belirten arazi kaldırıcı oranının yanısıra, boş arsa değerinin geliştirilmiş taşınmaz satış değerinden çıkarılması ile yapının inşaat maliyeti de elde edilebilmektedir. Aynı taşınmazın boş arsa ve yapıyı durumdaki satış değerine ulaşmadaki zorluk bu yöntemin kısıtlı yönü olarak öne çıkmaktadır (Copiello, 2021).

Devaney ve diğ (2018), yerleşim alanları, ofisler, alışveriş merkezleri, endüstriyel alanlar ve perakende depo alanları için İndirgenmiş Maliyet yöntemi ile arsa değerlerini hesaplamışlardır. Çalışmada yerleşim alanlarındaki arsaların değerlendirilmesi için Birleşik Krallık Ulusal İstatistik Ofisi'nin paylaştığı Küçük Alanlar İçin Konut Fiyat İstatistikleri (House Price Statistics for Small Areas - HPSSAs), bina değerlendirilmesi için de Bina Maliyet Bilgi Servisi (Building Cost Information Service - BCIS) tarafından paylaşılan inşaat maliyetleri verilerinin kullanıldığı belirtilmiştir. Tüm İngiltere ve seçilen belli bölgelerde taşınmazların geliştirilmiş değerinden yaklaşık inşaat maliyeti çıkarılarak arsa değerleri elde edilmiş, hem ülke geneli için hem

de şehir bazında değer indeksleri oluşturulmuştur. Çalışma Birleşik Krallık'ta arsa değerlerinin elde edilmesi ve yıllara göre değişiminin gözlemlenebilmesi anlamında önemli bir boşluğu doldurmuştur. Fakat üretilen arsa değerleri bölge bazlı ortalama değerleri ifade ettiğinden spesifik olarak herhangi bir arsanın gerçek değerini yansıtamamaktadır. Bunun yerine bölgelerin arsa değer trendini ortaya koyarak yatırım, planlama, politika geliştirme gibi amaçlar için kullanılacak sonuçlar üretmişlerdir. Çalışmanın sonuçlarına bakıldığında İngiltere'nin kuzey ve güney bölgeleri arasında arsa değerlerindeki önemli farklar göze çarpmaktadır. Ayrıca Londra ve çevresinin arsa değerinin diğer bölgelerdeki değerlere göre on kata kadar farklılıkların bulunduğu tespit edilmiştir. Çalışmada arazi kaldırıcı oranının ülke genelinde %20 ile %40 arasında değişkenlik gösterdiği, Londra bölgesinde ise bu oranın %60 civarına kadar çıktığı belirtilmiştir.

Bourassa ve Hoesli (2022), yerleşim alanlarındaki arsa değerlerinin belirlenmesinde kullanılan Hedonik Değerleme, İndirgenmiş Maliyet ve Arazi Kaldırıcı yöntemlerini ele almış, üç yöntemin de Amerika Birleşik Devletleri'nin Arizona eyaletine bağlı Maricopa bölgesinde uygulamasını gerçekleştirmişlerdir. Yöntemlerin avantaj ve dezavantajlarının yer verildiği çalışmada Hedonik ve İndirgenmiş Maliyet yöntemlerinin toplu değerlendirme standartlarında belirtilen performans metriklerine göre yetersiz kaldığı, Arazi Kaldırıcı yönteminin ise tutarlı sonuçlar verdiği belirtilmiştir.

1.5 Temel Tanım ve Kavramlar

Bu bölümde toplu taşınmaz değerlendirme çalışmalarında yer verilen CBS, Yapay Zeka ve Makine Öğrenmesi, Bulut Bilişim, Yapı Bilgi Modellemesi gibi akıllı sistemlere yönelik tanımlayıcı bilgiler aktarılmaktadır.

1.5.1 Bulut bilişim

Bulut Bilişim, ağ, sunucu, depolama, uygulama ve servis gibi ayarlanabilir bilgi işlem araçları paylaşılan bir kaynağa her yerden uygun ağ erişimi sağlayan bir modeldir. Sistemin yapılandırılması ve devreye alınması sırasında kullanıcı tarafında fazla bir çaba veya müdahale gerektirmez (Mell ve Grance, 2011).

Bulut Bilişimin ortaya çıkışı 1960'lı yıllara kadar uzanmasına rağmen, Bulut (Cloud) terimi ilk olarak 2006 yılında Google, Amazon, Microsoft ve IBM gibi büyük teknoloji

şirketleri tarafından tanınmıştır (Regalado, 2011). Ancak dünya genelinde tanınırlık kazanması Amazon Web Servisleri (AWS)'nin Elastic Compute Cloud (EC2) ürünü ile meydana gelmiştir.

Bulut Bilişim sistemlerinde özel, topluluk, genel ve hibrit olmak üzere dört dağıtım modeli bulunmaktadır (Bhat, Shah, ve Ahmad, 2011). Özel dağıtım modeli, çok sayıda çalışanı olan kuruluşlardaki kullanıcılara şirket içinde veya dışında özel bulut altyapısı sunmaktadır. İş sektörü, çalışma konusu, ilgi alanı gibi ortak hedefleri olan belirli bir grup için topluluk modeli bulut altyapısı sunulmaktadır. Genel bulut modeli servis sağlayıcısının merkezlerinde bulut altyapısının açık kullanımını mümkün kıldığı hizmet türüdür. Hibrit bulut modeli ise diğer dağıtım türlerinin birleşimi olarak görülebilir, ancak gelişmiş bulut çözümleri için özgün özellikleri barındırmaktadır (Mell ve Grance, 2011).

Helmi, Farhan, ve Nasr (2018)'a göre; Bulut Bilişim teknolojisi beş ana özellik içermektedir. Bunlar; i) İsteğe bağlı hizmet yapılandırması, ii) geniş ağ erişimi, iii) kaynak havuzu oluşturma, iv) hızlı esneklik ve v) kullandıkça öde. İsteğe bağlı hizmet yapılandırma özelliği, kullanıcıların sunucu özellikleri ve depolama gibi tercihleri istedikleri şekilde yönetebilmeleri için bilgi işlem araçları sağlamaktadır. Geniş ağ erişim özelliği, ince veya kalın istemci platformlarının standart protokollerle hizmetlere erişmesini sağlamaktadır. Bulut sistemlerinin kaynak havuzu oluşturma özelliği, çok kiracılı modeli olan birden fazla kullanıcıya dinamik olarak etkinleştirilen, konumdan bağımsız sanal ve fiziksel bilgi işlem kaynakları sağlamaktadır. Hızlı esneklik özelliği, her zaman esnek, ölçeklenebilir, isteğe bağlı, otomatik hizmet sunumu sağlamaktadır. Son olarak, kullandıkça öde özelliği, kullanım ölçümü işlevini kullanarak kaynakların izlenmesini, yönetilmesini, optimize edilmesini ve raporlanmasını sağlamaktadır.

Bulut Bilişim sistemlerinde üç ana servis türü vardır: Servis Olarak Yazılım (Software as a Service - SaaS), Servis Olarak Platform (Platform as a Service - PaaS) ve Servis Olarak Altyapı (Infrastructure as a Service - IaaS). SaaS, bilgi işlem araçları ağı olan bulut altyapısı üzerindeki uygulamaları kullanma yeteneği sağlamaktadır. Bu sayede kullanıcıların sunucu, ağ, işletim sistemi, depolama, uygulama veya bakım gibi işlemleri yönetmeleri gerekmez. Ayrıca, şirketlerin ve kuruluşların yazılım ve donanım satın almak, bilgi teknolojileri çalışanlarını istihdam etmek yerine bulut

üzerindeki bilgi sistemlerini veya uygulamalarını kullanabilmeleri sağlanmaktadır (Alfaqih ve Hassan, 2016). PaaS, tüketiciler tarafından talep edilen yazılım geliştirme uygulamaları için platformların veya uygulamaların dağıtımını sağlamaktadır. PaaS modelindeki bulut altyapısı kullanıcılar tarafından yönetilmez veya kontrol edilmez, ancak kullanıcıların platformlar ve uygulamalar üzerinde yetkileri bulunmaktadır. IaaS servis modeli bilgi işlem, depolama, ağ ve işleme gibi temel özellikler sunmaktadır. Kullanıcılar ayrıca bulut altyapısı üzerinde yönetebilecekleri ve kontrol edebilecekleri bir işletim sistemi ve uygulaması da kullanabilirler (Lněnička ve Komárková, 2013). IaaS servise modeline AWS EC2, Google Cloud Platform Compute Engine ve Microsoft Azure sanal makineleri; PaaS'a ArcGIS Server ve GeoServer; SaaS'a ise ArcGIS Online, Mapbox ve CartoDB örnek verilebilir (Mete ve Yomralıođlu, 2021).

Üç ana hizmet modeli dışında bir de isteđe bađlı olarak internet üzerinden sağlanabilecek tüm olası hizmetler ve uygulamaları ifade eden Servis Olarak Her Şey (Anything as a Service - XaaS) vardır (Duan, Fu, Zhou, Sun, Narendra, ve Hu, 2015). Bunlar arasında en çok kullanılan modellerden biri Servis Olarak Fonksiyon (Function as a Service - FaaS) modelidir. Uygulamaları bulutta dağıtmak için bir alternatif olan FaaS, kullanıcıların sunucu kurmadan veya bakımını yapmadan arka uç (backend) kodunu çalıştırabilmeleri için fonksiyonu isteđe bađlı olarak çalıştırır. FaaS genellikle mikro hizmetler oluşturmak, Hyper Text Transfer Protocol (HTTP) isteklerini işlemek, mesaj kuyruđu veya görev zamanlama amaçları için kullanılır (Goebelbecker, 2020). AWS Lambda, Google Bulut Fonksiyonları, Microsoft Azure Fonksiyonları, IBM/Apache OpenWhisk ve Oracle Cloud Fn, bulut pazarındaki FaaS örneklerinden bazılarıdır. FaaS sunucu veya küme sağlama, kapasite sağlama ve bakım gibi altyapı yönetimi işlemlerinin bulut sağlayıcısı tarafından gerçekleştirildiđi bir yürütme modeli olan sunucusuz (serverless) bilgi işlem mimarisinin temel konseptidir. Sunucusuz mimari, sunucuları düşünmeden hizmetler ve uygulamalar oluşturmayı ve çalıştırmayı sağlamaktadır. Öte yandan kullanıcılar yalnızca sunucusuz uygulama kullanıldığı zaman ödeme yaparken, sistem çalışmadığında bulut sağlayıcı kullanıcılardan veri depolama dışında herhangi bir ücret talep etmemektedir.

Bulut Bilişim hizmeti veren teknoloji şirketleri arasında AWS, Google Cloud Platform, Microsoft Azure, IBM Cloud, Oracle Cloud, Digital Ocean, Rackspace gibi önde gelen Bulut Bilişim hizmeti sağlayıcıları bulunmaktadır. Tez çalışması kapsamında, birçok

hizmet imkanı bulunması, makul hizmet maliyetleri sunması, birçok konumda veri merkezinin bulunması ve yüksek oranda kullanılabilir hizmetler sunması dolayısıyla Bulut Bilişim platformu olarak AWS tercih edilmiştir.

Amazon Web Servisleri

AWS, işlevsellik, ulaşılabilirlik, hizmet çeşitliliği, boyutlandırma ve maliyet açısından en büyük genel bulut servis sağlayıcılarından biridir (Dillmann, 2016). Airbnb, Autodesk, BP, Canon, Deloitte, Duolingo, Foursquare, Here, Hitachi, HTC, McDonalds, Netflix, Philips, Siemens ve Xiaomi gibi AWS ile işbirliği yapan birçok şirket ve kurum bulunmaktadır (AWS, 2020a). Üçüncü parti bir bulut sağlayıcısı olarak AWS, iş ortakları için bilgi işlem, depolama, ağ oluşturma, veritabanı, analitik, uygulama hizmetleri, dağıtım ve yönetim çözümleri sunmaktadır. Tez çalışmasında AWS hizmetleri arasında en çok bilinen ve kullanılan Esnek Bulut Bilişim (EC2), Basit Depolama Servisi (Simple Storage Service - S3) ve İlişkisel Veri Tabanı Servisi (Relational Database Service - RDS) ele alınmıştır.

EC2, bulut sisteminde uygulamaların güvenli, yeniden boyutlandırılabilir ve ölçeklendirilebilir dağıtımını sağlayan bir web hizmetidir. EC2 hizmeti IaaS olarak kabul edilebilir, çünkü AWS sunucu, depolama, ağ iletişimi ve sanallaştırma işlemlerinin sorumluluğunu üstlenmektedir. Öte yandan, kullanıcılar işletim sistemi, veri uygulamaları, ara katman yazılımı ve çalışma zamanından sorumludur (Shao, Di, Bai, Guo, ve Gong, 2012). Kullanıcılar, kullanıma hazır bir sanal makine oluşturmak için bir Amazon Makine İmajı (Amazon Machine Image - AMI) başlatabilir. AMI, Windows veya Linux işletim sistemleri, yazılımlar ve uygulamalardan oluşmaktadır. Sanal makinenin yönetimi ve yapılandırılması yönetim paneli üzerinden kontrol edilebilmektedir.

AWS S3, bulut ortamında güvenlik, performans, ölçeklenebilirlik ve yüksek veri erişilebilirliği sağlayan çevrimiçi bir nesne depolama hizmetidir. S3 servisi ile çeşitli uygulamalarda kullanılmak üzere internet üzerinden tekdüzen kaynak konumlandırıcısıyla (Uniform Resource Locator - URL) erişilebilen verileri nesne olarak depolamak mümkündür. Bu nesnelere Amazon'un çeşitli ülkelerde konumlandırılmış veri merkezlerinden birindeki makinelerde yedeklenerek depolanmaktadır (AWS,

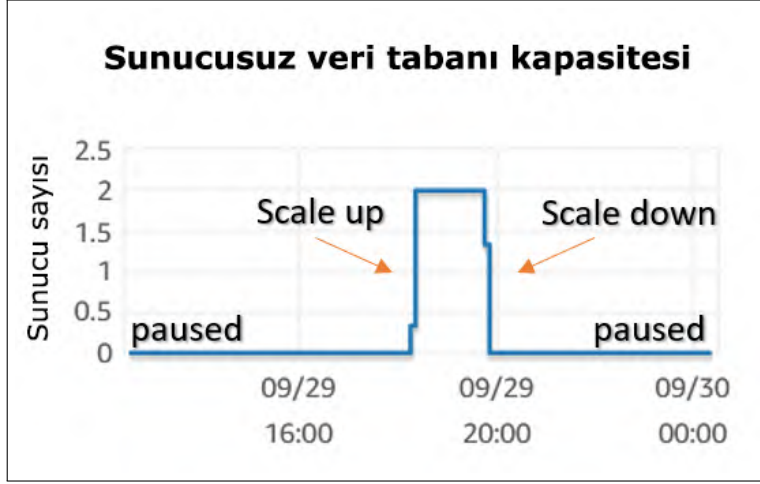
2020b). S3 veri kovanında bulunan verileri yönetmek ve kopyalama, yayınlama gibi temel işlemleri gerçekleştirmek için konsol ve komut satırı kullanılabilir.

RDS Amazon'un bulut üzerinden ilişkisel veritabanları hizmetini web ortamında sağladığı servisedir. Amazon RDS, veritabanının kurulumu, yönetimi, kontrolü ve ölçeklendirilmesi işlemlerinin kolaylıkla yürütülmesi amacıyla tasarlanmıştır. Ayrıca bu servis ile veritabanı üzerinde otomatik eklenti, yedekleme ve aşamalı kurtarma olanakları sunmaktadır (Hubbard, 2019). Kullanıcıların ihtiyaçlarına göre, ölçeklenebilir, yeniden boyutlandırılabilir veritabanı yönetimi için sistemi yavaşlatan giriş-çıkış darboğazı ve performans düşüklüğü problemlerinin çözümü için optimizasyon imkanı sağlamaktadır. SaaS olarak RDS, Amazon Aurora, MariaDB, MySQL, Oracle Database, PostgreSQL ve SQL Server gibi yaygın kullanılan veritabanı sistemlerini desteklemektedir. Ayrıca, kullanıcıların AWS Veritabanı Geçiş Hizmeti'ni kullanarak mevcut veritabanlarını RDS'e hızlı ve güvenli bir şekilde taşıma imkanı bulunmaktadır.

Amazon RDS hem MySQL hem de PostgreSQL için Amazon Aurora ile sunucusuz veritabanı imkanı sunmaktadır. Amazon Aurora Serverless, uygulama iş yüküne göre otomatik olarak başlatılıp kapatılabilen, iki yönlü ölçeklenebilen bir yapıya sahiptir. Kurulum aşamasında bellek ve Aurora Kapasite Birimlerini (Aurora Capacity Units - ACU) ayarladıktan sonra süreç içerisinde veritabanı sunucusunu yönetmeye gerek yoktur. Bağlantı sayısı ve CPU kullanımı arttığında Aurora Serverless "sıcak" duruma geçerek oldukça kısa bir gecikme süresi ile isteklere yanıt vererek ölçeklenmektedir. Öte yandan yapılandırılabilir bir süre içerisinde bağlantı olmadığına sifira ölçeklenir (Şekil 1.1). Sıcak kaynak havuzu sorgu sırasında veritabanı kümesinin aktif olarak kullanıldığı ve servis isteklerine yanıt vermeye hazır olduğu anlamına gelmektedir. Ayrıca sistem "soğuk" durumda iken sağlayıcı tarafından veri depolama dışında herhangi bir ücret alınmamaktadır.

1.5.2 Coğrafi bilgi sistemleri

CBS, fiziksel yeryüzüne ait coğrafi verilerin elde edilmesi, görüntülenmesi, depolanması, sorgulanması ve analizi gibi işlemlerin yürütüldüğü bir bilgi sistemi olarak ifade edilebilir (Burrough, 1986; Clarke, 1999; ESRI, 2018; Star ve Estes, 1990; Yomralıoğlu, 2000). Veri, donanım, yazılım, insanlar ve yöntemler gibi



Şekil 1.1 : Farklı sistem iş yükleri sırasında Aurora Sunucusuz Veritabanı ölçeklenebilirliği.

bileşenlerle tanımlanan CBS, önemli bir karar destek sistemidir. CBS tarihte problem çözme amacıyla ilk kez 1854 yılında Dr. John Snow tarafından salgın bir hastalık olan Koleranın tespitinde kullanılmıştır (GIS Geography, 2022). Kağıt ortamındaki basılı haritalardan bilgisayarlı dijital haritalama sürecine geçişte ise CBS'nin babası olarak bilinen Roger Tomlinson, Kanada Coğrafi Bilgi Sistemini (Canada Geographic Information System - CGIS) geliştirerek önemli bir adım atmış, CBS'nin bugünkü ismini almasını sağlamıştır (GIS Lounge, 2012). Öte yandan ESRI firmasının 1969 yılında kurulması ve 1981'de ilk ticari CBS yazılımı olan ARC/INFO'yu piyasaya sürmesi ile kullanıcıların coğrafi verileri bir veritabanında saklaması, çeşitli sorgu ve analizleri gerçekleştirilmesi sağlanarak konumsal veri yönetimi anlamında önemli bir yol katedilmiştir (ESRI, 2022a).

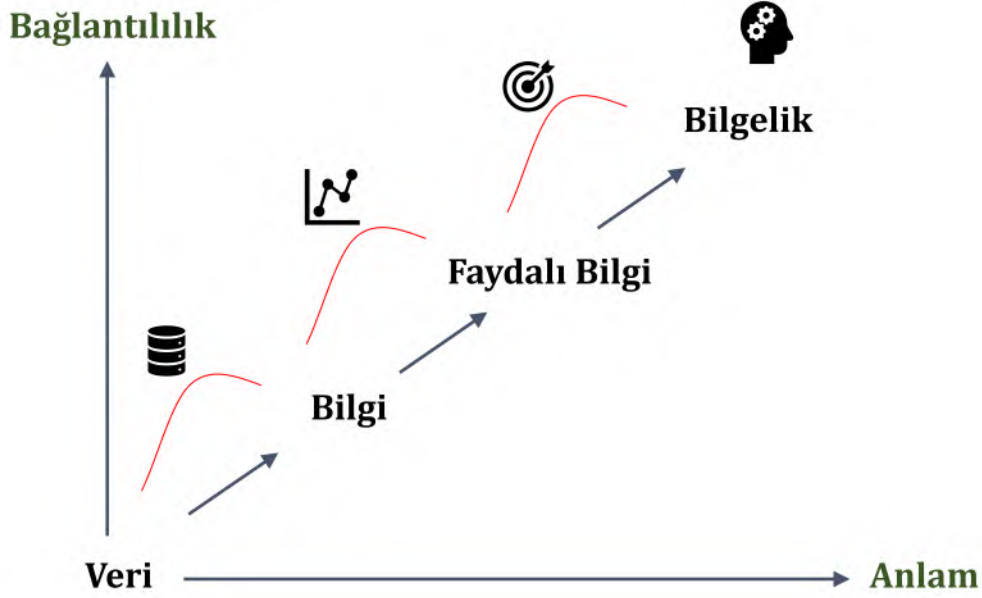
Teknolojinin ilerlemesi ile bilgisayarların gelişmesi, CBS'nin daha hızlı yayılmasını ve daha çok insana ulaşmasını sağlayarak çevre, ulaşım, sağlık, eğitim, milli güvenlik gibi farklı alanlarda karşılaşılan problemlerin çözümünde kullanılan etkili bir araç olmuştur. Konumsal veri üretiminin ve kullanımının artması, coğrafi bilgi endüstrisine giden yolda ülkeler için önemli bir katma değer oluşturmaktadır. Küresel CBS endüstrisinin 2022 yılındaki market değeri yaklaşık olarak 450 milyar \$ olarak hesaplanmış, 2025 yılında ise yatırımlar, politika geliştirme ile birlikte dijital ikiz, metaverse, blokzincir gibi teknolojik alanların katkısıyla bu değer yaklaşık 681 milyar \$ olacağı tahmin edilmektedir (Geospatial World, 2022). Öte yandan Avrupa Birliği tarafından yayınlanan Açık Veri Yönergesinde mekansal veriler en değerleri veri setleri arasında gösterilmiş, bu verilerin Avrupa

Coğrafi Veri Altyapısına (Infrastructure for Spatial Information in Europe - INSPIRE) uyumlu bir şekilde, makine tarafından okunabilir formatlarda, ücretsiz paylaşımının sağlanmasını vurgulamaktadır (Avrupa Birliği Parlamentosu ve Avrupa Birliği Meclisi, 2019). Ülkemizde ise Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, CBS Genel Müdürlüğü öncülüğünde TUCBS veri altyapısı çalışmalarının önemli bir bölümü tamamlanmış, "49 Sayılı Coğrafi Bilgi Sistemleri Hakkında Cumhurbaşkanlığı Kararnamesi", "Ulusal Akıllı Şehirler Stratejisi ve Eylem Planı İle İlgili Cumhurbaşkanlığı Genelgesi", "7221 Sayılı Coğrafi Bilgi Sistemleri İle Bazı Kanunlarda Değişiklik Yapılması Hakkında Kanun" gibi mevzuatların yürürlüğe girmesi ile CBS ekosisteminin ülke çapında etkin bir şekilde yönetilmesi ve CBS endüstrisinin olgunlaştırılması için çalışmalara devam edilmektedir (Coğrafi Bilgi Sistemleri Genel Müdürlüğü, 2021).

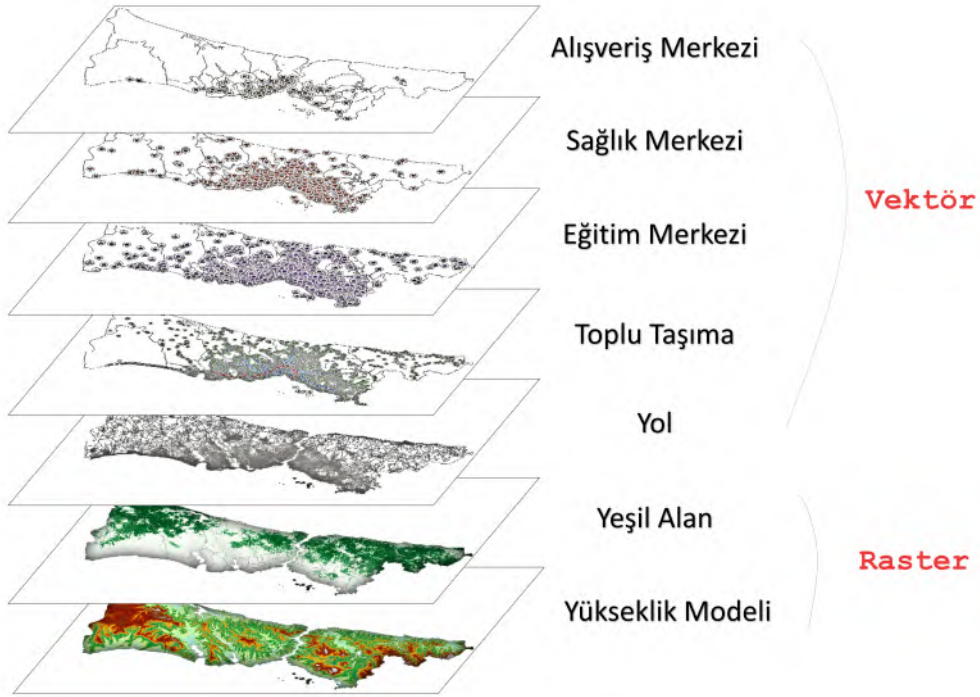
Dünya üzerinde bulunan verilerin %80'inin konum bilgisine sahip olduğu bilinmektedir (Franklin ve Hane, 1992). CBS ile coğrafi veriler ve bu verilere bağlı öznitelikler bir veritabanı içerisinde depolanır, gerektiğinde sorgu ve analizler gerçekleştirilerek ham veriden faydalı bilginin elde edilmesi sağlanır (Şekil 1.2). CBS veri yapıları temelde vektör ve raster olmak üzere ikiye ayrılmaktadır (Şekil 1.3). Vektör verilerde nokta, çizgi, poligon yapıları ile gerçek dünyadaki objeler temsil edilmektedir. Raster veride ise pikseller yardımıyla oluşturulan sürekli bir veri yapısı bulunmakta, piksel büyüklüğü ve piksel değeri ile objeler temsil edilmektedir. Raster veriler genellikle uydu görüntüleri, sayısal yükseklik modelleri, arazi örtüsü - arazi kullanımı, yoğunluk haritaları gibi verilerde karşımıza çıkmaktadır.

1.5.2.1 Masaüstü coğrafi bilgi sistemleri

CBS'nin sayısal veri entegrasyonu, görselleştirme, manipülasyon, sorgulama, analiz ve otomasyon gibi temel fonksiyonları bulunmaktadır (Yomralıoğlu, 2000). Masaüstü CBS yazılımları genellikle bu temel işlevlerin güçlü bir şekilde gerçekleştirilebildiği, bir grafik kullanıcı arayüzü (Graphic User Interface - GUI) bulunan paket programlardır. Günümüzde ArcGIS, QGIS, GRASS, SAGA, uDig, OpenJump, gvSIG, SPRING gibi birçok masaüstü CBS yazılımı bulunmaktadır. Bunlardan en yaygın kullanılanları ESRI firmasının ticari ürünü olan ArcGIS ve açık kaynaklı QGIS yazılımlarıdır.



Şekil 1.2 : Verinin anlam ve bağlantılılığa dayalı dönüşüm süreci.



Şekil 1.3 : CBS'de vektör ve raster veri türleri.

ArcGIS kullanım kolaylığı, güçlü konumsal analiz yeteneği, ayrıntılı kullanım dokümanları, geniş kullanıcı topluluğu gibi özelliklerle öne çıkmaktadır. Bilişim dünyasındaki yenilikleri CBS alanı ile hızlı bir şekilde bütünleştirerek sektöre öncülük eden ESRI firması, kamu, belediyeler, üniversiteler gibi kurum ve kuruluşlar tarafından yüksek oranda tercih edilmektedir. ESRI'nin ArcMap ve ArcGIS Pro olmak üzere iki adet masaüstü CBS ürünü bulunmakta, yakın zamanda ArcMap desteğinin kesilerek

ArcGIS Pro üzerinden geliřtirmelere devam edileceęi açıklanmıřtır (Angel, 2017). Öte yandan QGIS, 3.0 versiyonuyla birlikte önemli iyileřtirmeler yaparak ciddi bir kullanıcı kitlesine ulařmıřtır. Yazılım geliřtirme yönetim sistemi olan “SourceForge” projesi olarak ortaya çıkan Quantum GIS, QGIS adıyla Open Source Geospatial Foundation (OSGEO) çatısı altında geliřtirilmeye devam etmektedir. GNU Genel Kamu Lisansı (General Public Licence - GPL) ile sunulan yazılımın kaynak kodu düzenlenebilmekte ve bu yazılıma ücretsiz olarak sürekli eriřilebilmektedir. Kullanıcı dostu olma hedefiyle yola çıkan QGIS, ilk olarak CBS verilerinin görüntülenmesi ihtiyacını karřılamayı amaçlamıřtır. Bu kapsamda QGIS birçok raster ve vektör veri formatlarını desteklemekte, yeni formatları da eklentilerle kolayca eriřilebilir hale getirebilmektedir. Coęrafi veritabanlarında okuma ve yazma imkanı sunan QGIS, Open Geospatial Consortium (OGC)’nin Web Harita Servisi (Web Map Service - WMS), Web Harita Kareleme Servisi (Web Map Tile Service - WMTS), Web Detay Servisi (Web Feature Service - WFS), Web Kapsama Servisi (Web Coverage Service - WCS) gibi standart veri paylařım hizmetlerini desteklemektedir.

Masaüstü CBS yazılımlarında yapılan tekrarlı iřlemlerin otomatize edilebilmesi için süreç modelleme (ArcGIS Model Builder ve QGIS Graphical Modeler gibi) araçlarının kullanımı, Python Uygulama Programlama Arayüzü (Application Programmin Interface - API) ile komut satırı üzerinden analizlerin gerçekleřtirilmesi ve amaca özgü özelleřtirme imkanı bulunmaktadır. Ayrıca CBS’nin veri bilimi alanında yaygınlařması ile birlikte Python (ArcPy, PyQGIS) ve R programlama dillerinin CBS yazılımları içerisindeki kullanımları da artmıřtır.

1.5.2.2 Web coęrafi bilgi sistemleri

Masaüstü CBS yazılımları veri analizi, harita üretimi gibi amaçlar için halen yaygın olarak kullanılsa da, veri ve haritaların internet üzerinden herkese açık şekilde paylařılması ihtiyacı Web CBS olgusunu ortaya çıkarmıřtır. Verilerin görselleřtirilmesi için herhangi bir yazılım kurulumuna ihtiyaç bulunmayan Web CBS uygulamalarına tarayıcı üzerinden eriřilebilmektedir. 1993 yılında Xerox řirketi tarafından internet ortamında paylařılan harita, bilinen ilk web CBS uygulamasıdır.

JavaScript yazılım dilinde geliřtirilen web harita portalları genellikle bir altlık harita (uydu görüntüsü, topografik harita vb.) üzerinde nokta, çizgi, poligon verilerin ya

da raster görüntülerin katmanlar halinde görselleştirildiği, özneliklerin sorgulanarak filtrelemenin yapılabildiği adres arama, mesafe ölçümü gibi fonksiyonların bulunduğu web arayüzleridir. Bunların dışında tampon analizi, yakınlık analizi, konumsal birleştirme gibi analizler de web CBS uygulamaları üzerinden gerçekleştirilebilmektedir. Google Haritalar, ATLAS CBS, HGM Atlas, İBB Şehir Haritası gibi uygulamalar web CBS'ye örnek olarak gösterilebilir.


Web CBS portalı oluşturmak için çeşitli alternatifler mevcuttur. ESRI ArcGIS Web AppBuilder ile kolaylıkla online haritalar oluşturulup webde yayınlanabilmektedir. Öte yandan Leaflet, OpenLayers, MapLibre GL JS, Lizmap gibi açık kaynaklı web harita kütüphaneleri de Web CBS uygulamaları için yaygın olarak kullanılmaktadır. Genellikle sunucu-istemci mimarisi ile çalışan web CBS uygulamaları, sunucu üzerinden web servisleri ile paylaşılan coğrafi verileri HTTP protokolleri ile gelen talep üzerine kullanıcıya iletmektedir. Bunun dışında GeoJSON dosyaları da web ortamında görüntülemeye uygun yapısı sebebiyle yaygın olarak kullanılmaktadır.

1.5.2.3 Bulut coğrafi bilgi sistemleri

Bulut CBS kavramı CBS'nin Bulut Bilişim altyapısı üzerinde işlevsel olarak kullanımıyla ortaya çıkmıştır. CBS'nin sağladığı temel özelliklerin yanısıra, veri depolama, yazılım ve içerik anlamında yüksek erişilebilirlik, ölçeklenebilirlik, güvenlik ve düşük maliyet gibi avantajlar sağlamaktadır. Bulut CBS kullanıcıların verilere, haritalara ve coğrafi analiz hizmetlerine ulaşımını kolaylaştırmaktadır (Peng ve Wang, 2014). Ayrıca donanım ve yazılım kaynakları sağlama, Bilgi Teknolojileri uzmanı ve destek ihtiyaçlarını en aza indirme, maliyetleri düşürme ve gelişmiş veri yönetimini sağlama gibi birçok avantaj sunmaktadır. Öte yandan kullanıcılar kullandıkça öde özelliği sayesinde yalnızca tükettikleri hizmetlerden sorumlu tutulmaktadırlar. Bulut CBS'nin ölçeklenebilirlik özelliği, hesaplama, depolama ve ağ kapasitelerini istenen şekilde artırmayı veya azaltmayı mümkün kılarken, coğrafi veri manipülasyonunu kolaylaştırmaktadır (Diasse ve Kone, 2011).

Bulut Bilişim sistemleri, bilgi işlem kaynakları, yazılım ve uygulamaların bulut üzerinde tam bir coğrafi bilişim ortamı oluşturmasını sağlamak için donanım ve yazılım ihtiyacını bilgi işlem gücü, performans ve bütçe gereksinimlerine göre istenilen özelliklere sahip sanal makineler yardımıyla karşılayabilmektedir. Çok

kiracılı model kullanarak işleme, ağ oluşturma ve depolama istekleri için kaynak havuzu sağlamaktadır. Konumdan bağımsız havuz oluşturma sayesinde kaynaklar kullanıcı talebi doğrultusunda merkezi bulut altyapısı üzerinden birden fazla istemciye sunulmakta ve ölçeklendirilebilmektedir. IaaS servis modeli yardımıyla bulut sistemlerinde bütüncül bir CBS altyapısının oluşturulması mümkündür. Şekil 1.4'te Bulut CBS servis modelleri ve modellere ait uygulama örnekleri yer almaktadır. Bulut CBS uygulamaları, kullanıcılara coğrafi veri yönetimi, analizi ve depolamasını kolaylaştırma olanağı sunmaktadır (Bhat ve diğ, 2011). Ayrıca, işletim sistemi, CBS yazılımı, uygulamalar ve araçlar hazır bulut makinesi görüntüleri kullanılarak kolayca kurulabilmektedir.



Şekil 1.4 : Bulut CBS bileşenleri ve servis modelleri.

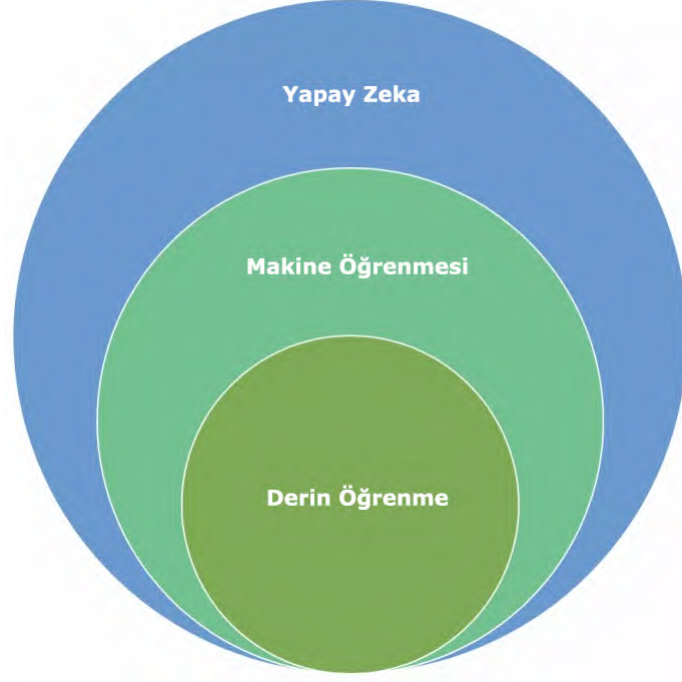
SaaS tabanlı bulut CBS uygulamalarının sayısı her geçen gün artmaktadır. Firmalar CBS çözümlerini bulut ortamına taşıyarak kullanıcılarına daha pratik, hızlı ve dinamik bir deneyim sunmaktadır. ArcGIS Online, Mapbox, CARTO, Observable bulut tabanlı hizmet veren CBS yazılımlarına örnek gösterilebilir. Öte yandan son dönemlerde bulut CBS uygulamalarında ve bulut tabanlı veri formatlarında "bulut yerlisi" (cloud native) kavramının sıklıkla kullanıldığı görülmektedir. Bulut yerlisi, mikroservisler ve API'lar ile desteklenen uygulamaların bulut bilişim üzerinde esnek bir yapıda, minimum çaba

ile dağıtılması olarak tanımlanabilir (Cloud Native Computing Foundation, 2022; Vettor ve Smith, 2022). Bulut yerlisi CBS ise konumsal verilere bulut tabanlı erişimi Bulut İçin Optimize Edilmiş GeoTIFF (Cloud Optimized GeoTIFF - COG), Mekansal-Zamansal Varlık Katalogları (SpatioTemporal Asset Catalogs - STAC), Bulut İçin Optimize Edilmiş Nokta Bulutu (Cloud Optimized Point Cloud - COPC), Zarr gibi yenilikçi veri formatları ile sağlayarak performans iyileştirmesi ve otomasyon gibi çeşitli avantajlar sunmaktadır. Bulut yerli CBS ile konumsal veriler bulut için optimize edilmiş formatlarda elde edildiğinde büyük veri dosyalarını indirmek zorunda kalmadan zengin bir veri kaynağına ve çeşitli konumsal araçlara erişmek mümkün hale gelmektedir.

1.5.3 Yapay Zeka ve Makine Öğrenmesi

Yapay zeka temel olarak öğrenme, problem çözme gibi insana özgü bilişsel özelliklerin makineler tarafından taklit edilmesi şeklinde tanımlanabilir (Russell ve Norvig, 2009). Yapay zeka uygulamaları genel olarak makine öğrenmesi (machine learning) ve derin öğrenme (deep learning) alt alanlarını içermektedir (Şekil 1.5). Makine öğrenmesi tahmine dayalı analitik veya istatistiksel öğrenme olarak bilinen, yapay zeka ve bilgisayar biliminin kesiştiği bir araştırma alanıdır (Alpaydin, 2016). Kişiye özgü öneri algoritmaları, nesne tanıma, tahmin, sınıflandırma, kümeleme gibi çeşitli uygulama alanları olan makine öğrenmesi, genel olarak verilerden bilgi çıkarımı için kullanılmaktadır.

Yapay zekanın tarihi 1950 yılında İngiliz Alan Turing'in "Makineler Düşünebilir mi? (Can Machines Think?)" felsefesiyle yola çıkarak akıllı makinelerin icadı ve yapay zekanın matematiksel olarak mümkün olup olmadığını tartışmasına dayanmaktadır (Turing, 1956). Yapay zeka (Artificial Intelligence) terimi ise ilk defa 1956 yılında bir Amerikalı bilgisayar bilimci olan John McCarthy tarafından öne sürülmüştür. Yapay zeka uygulamalarının önemli bir geçmişi olsa da, donanımsal kısıtlar sebebiyle son on yıla kadar gerçek anlamda potansiyeline ulaşamamıştır. Teknolojinin ilerlemesi ile birlikte ekran kartı destekli işlem gücü (GPU-based processing), bulut bilişim sistemleri ve kuantum bilgisayarlar sayesinde önemli bir sıçrayış gerçekleştiren yapay zeka uygulamaları günlük hayatımızda da önemli bir yer edinmiştir.



Şekil 1.5 : Yapay zeka, makine öğrenmesi ve derin öğrenme hiyerarşisi.

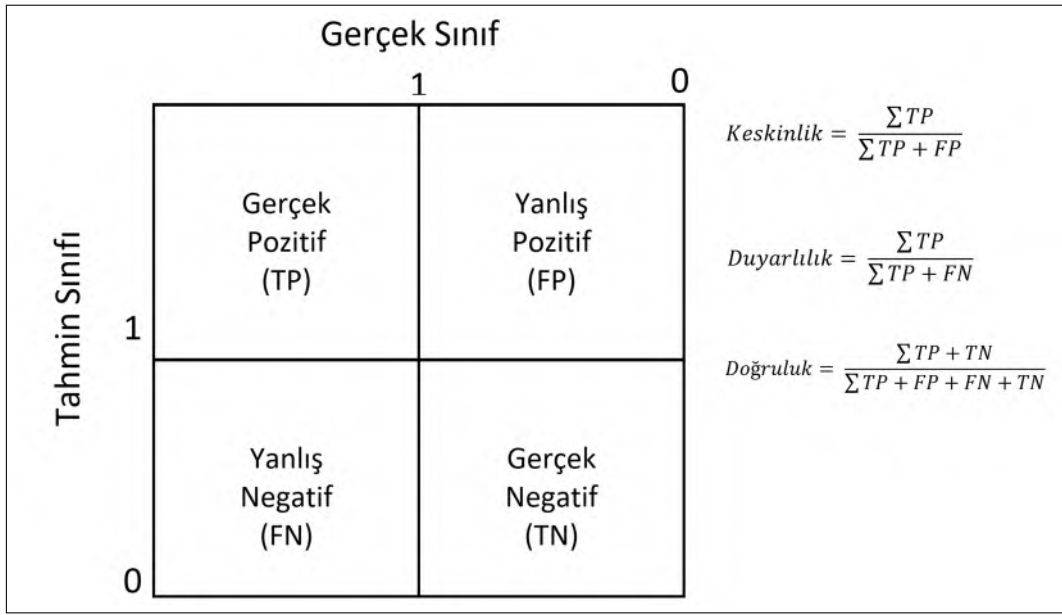
Yapay zeka ve makine öğrenmesi uygulamaları için kullanılan verilerin etiketli (labeled) ya da etiketsiz (unlabelled) olmasına göre iki yöntem grubuna ayrılmaktadır. Etiketli verilerle, yani verinin gerçekte ne olduğunun bilinip makine öğrenmesi modeline de başlangıçta bunun tanıtılması ile denetimli öğrenme (supervised learning) süreci gerçekleştirilmektedir. Öte yandan etiketsiz veri kullanılarak gerçekleştirilen denetimsiz öğrenme (unsupervised learning) yaklaşımında veri seti ile ilgili başlangıçta herhangi bir tanımlama yapılmayıp modelin bu çıkarımı yapması sağlanmaktadır. Denetimli öğrenme tabanlı makine öğrenmesi yaklaşımında tahmin ve sınıflandırma olmak üzere iki farklı uygulama alanı bulunmaktadır. Denetimsiz öğrenme modelinde ise temel bileşen analizi (Principal Component Analysis - PCA), t-SNE gibi boyut azaltma ve kümeleme algoritmaları yer almaktadır.

1.5.3.1 Sınıflandırma algoritmaları

Sınıflandırma farklı sınıflara ait nesnelere arasında bir karar sınırının belirlenmesi ile kategorilerin oluşturulmasıdır. Makine öğrenmesindeki sınıflandırma algoritmaları verilerin önceden belirlenmiş kategorilerden birine ait olma olasılığını tahmin etmek için eğitim verilerini kullanarak çeşitli dokular üzerinden benzerlikleri araştırır. Sınıflandırmaya örnek olarak uydu görüntüleri üzerinden arazi kullanımı haritası

üretimini verebiliriz. Lojistik Regresyon, Naive Bayes, DVM, K-En Yakın Komşuluk, Rastgele Orman gibi algoritmalar öne çıkan sınıflandırma yöntemlerindedir.

Sınıflandırma yöntemlerini değerlendirmek için log kaybı (log loss), çarpaz entropi (cross-entropy loss), karışıklık matrisi (confusion matrix) ve AUC-ROC eğrisi yaklaşımları kullanılmaktadır. Log loss ve cross-entropy loss ikili (binary) sınıflandırıcılar için kullanılmaktadır. Log loss değerinin sıfıra yakın olması sınıflandırmanın başarılı olduğunu ifade etmektedir. Öte yandan hata matrisi olarak bilinen karışıklık matrisi yöntemi, sınıflandırmanın performansının değerlendirilmesini sağlar. Sınıf tahminlerinin doğru ve yanlış sayılarına göre doğruluk belirlenmektedir (Şekil 1.6).




Şekil 1.6 : Karışıklık matrisi ve doğruluk hesabı (Sun Hong ve Gyu Oh, 2021).

Eğrinin Altındaki Alan anlamına gelen AUC, sınıflandırma modelinin farklı eşiklerdeki performansını gösteren bir grafikdir. Çoklu sınıflandırma modelinin performansını görselleştirmek için kullanılan ROC eğrisi Gerçek Pozitif Oran (True Positive Rate - TPR) ve Yanlış Pozitif Oran (False Positive Rate - FPR) kullanılarak çizilmektedir (Şekil 1.7).

1.5.3.2 Regresyon algoritmaları

Regresyon analizi, bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkileri kestirmek için kullanılır. Çoklu Doğrusal Regresyon, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi açıklamak için veriler arasından doğrusal eğri uyduran bir yöntemdir (1.1). Bu regresyon modeli, En Küçük Kareler yaklaşımını



Şekil 1.7 : ROC eğrisi ile sınıflandırma performansının ölçülmesi (Thompson ve Zucchini, 1989).

kullanarak gerçek değer ile tahmin edilen değer arasındaki artık değerlerin kareler toplamını en aza indirme esasına dayanmaktadır. Doğrusal regresyon, en çok kullanılan regresyon modellerinden biri olmasına karşın, doğrusal biçimde ifade edilemeyen karmaşık veriler üzerinde iyi performans gösterememektedir.

$$\hat{y} = b_0 + b_1X_1 + b_2X_2 + \dots + b_nX_n \quad (1.1)$$

öyle ki;

\hat{y} : bağımlı değişken

X_n : bağımsız değişken

b_0 : y-sabit değeri

b_n : katsayılar

Topluluk Öğrenmesi yöntemleri, daha iyi bir tahmin modeli oluşturmak amacıyla çok sayıdaki zayıf modelin birleşimi olarak tanımlanabilir. Birkaç yöntemin bir araya getirilmesiyle geliştirilen birçok Topluluk Öğrenmesi algoritması vardır. Öte yandan bagging, boosting ve stacking, en popüler Topluluk Öğrenmesi algoritmalarına temel oluşturan üç yöntemdir.

Rastgele Orman, birçok bireysel Karar Ağacından meydana getirilen bir Topluluk Öğrenmesi algoritmasıdır (Breiman, 2001). Hem sınıflandırma hem de regresyon problemlerini yüksek doğrulukla gerçekleştirebilen esnek bir algoritma olan Rastgele Orman, bagging yönteminin bir uzantısıdır. Bu yöntemde oluşturulan her bir karar ağacı için rastgele öznitelik örnekleri üretilmekte ve ilgili kararların toplanmasıyla (bootstrap ve aggregation) tahmin yapılmaktadır. Regresyon uygulaması için karar toplama yaklaşımı, verilen tüm kararların ortalaması olarak hesaplanmaktadır. Bu nedenle, Rastgele Orman regresyonu, model karmaşıklığını (varyansı) azaltarak aşırı uyumun (overfitting) önüne geçmektedir.

Bagging algoritmasının aksine, boosting algoritması her bir modelin sonucuna ağırlıklar tahsis etmektedir. Ardından model doğruluğunu iyileştirmek amacıyla bir önceki ağacın hatasından yararlanarak ağırlıkları yeniden ayarlamaktadır. Ayrıca boosting algoritması, yetersiz uyumu (underfitting) önlemek için model karmaşıklığını artırarak yanlılığı (bias) azaltmaya çalışmaktadır. Öte yandan, son zamanlarda boosting algoritmalarının kayıp (loss) fonksiyonu optimize edilerek Gradyan Artırma Topluluk Öğrenmesi yöntemleri geliştirilmiştir. XGBoost (Chen ve Guestrin, 2016), LightGBM (Ke, Meng, Finley, Wang, Chen, Ma, Ye, ve Liu, 2017) ve CatBoost (Prokhorenkova, Gusev, Vorobev, Dorogush, ve Gulin, 2017) en çok kullanılan ve yüksek doğruluğa sahip Gradyan Artırma algoritmaları olarak öne çıkmaktadırlar.

1.5.3.3 Kümeleme algoritmaları

Kümeleme analizi, etiketlenmemiş veri setini aralarındaki benzerliklerden yola çıkarak gruplandırarak bir makine öğrenmesi yaklaşımıdır. Kümeleme analizi etiketlenmemiş veri setinde boyut, şekil, renk gibi benzer dokulara göre verileri gruplandırır. Kümeleme algoritmaları Bölünmeli (Partitional / Centroid-based), Hiyerarşik (Hierarchical), Yoğunluk Tabanlı (Density-based), Dağılım Modeli Tabanlı (Distribution Model-Based) ve Bulanık (Fuzzy) olmak üzere beşe ayrılmaktadır.

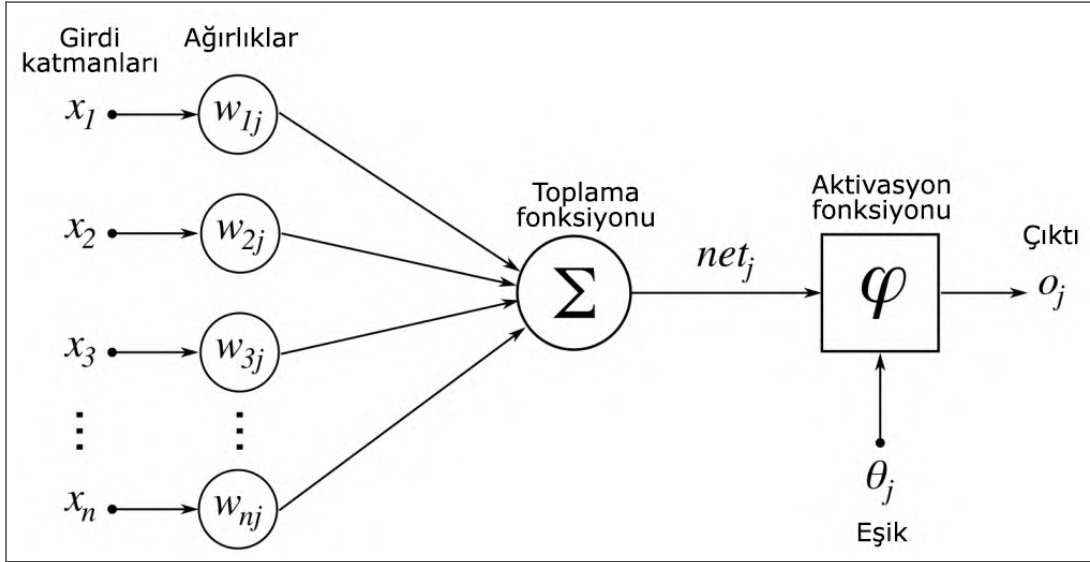
K-means kümeleme en yaygın kullanılan kümeleme algoritmasıdır. Bir denetimsiz öğrenme algoritması olan k-means, merkez tabanlı kümeleme yaparak veri noktaları arasındaki varyansı en aza indirgeme prensibine göre çalışır. Merkez tabanlı kümeleme, verileri hiyerarşik olmayan kümeler halinde gruplamaktadır. Bu kümeleme çeşidi aykırı değerlere ve başlangıç koşullarına karşı hassastır. Hiyerarşik tabanlı

kümeleme, taksonomi gibi hiyerarşik yapıya sahip veriler için kullanılan gruplandırma yöntemidir. Bu yaklaşım ile veri ağaç benzeri bir yapı (dendrogram) oluşturmak amacıyla kümelere ayrılmaktadır. Yoğunluğa dayalı kümeleme, yüksek veri yoğunluklu alanları gruplandırma esasına dayanır. Aykırı değerleri kümelerin içerisine dahil etmeyen bu yaklaşım, değişen yoğunluktaki ve yüksek boyutlardaki verilerde iyi performans gösterememektedir. DSCAN en yaygın kullanılan yoğunluk temelli kümeleme yöntemidir. Dağılım tabanlı kümeleme yaklaşımı, verilerin normal dağılımı gibi belli bir dağılım modelinden oluştuğunu varsaymaktadır. Dağılımın merkezine olan uzaklık arttıkça bir noktanın ilgili dağılıma ait olma olasılığı azalmaktadır. Veri setinin dağılım modelinin bilinmemesi durumunda bu yaklaşımın kullanılması güvenilir sonuçlar vermeyebilir. Bulanık kümeleme ise bir veri noktasının birden fazla kümeye ait olabileceği bir yumuşak kümeleme (soft clustering) yöntemidir. Kümeleme analizi sonucunda her bir veri noktası kümelere aitliği gösteren üyelik katsayısı almaktadır.

1.5.3.4 Derin öğrenme

Makine Öğrenmesinin bir alt alanı olan Derin Öğrenme, insan beyninin biyolojik yapısından ilham alınarak geliştirilen YSA temelli büyük miktarda veriden öğrenebilen algoritmalar şeklinde tanımlanabilir (Goodfellow, Bengio, ve Courville, 2016). Derin öğrenme, bilgisayarlı görü (computer vision) ile doğal dil işleme (natural language processing) alanlarına ayrılmaktadır. Bilgisayarlı görü alanında obje tespiti, obje çıkarımı, görüntü segmentasyonu ve sınıflandırması gibi uygulamalar gerçekleştirilirken, doğal dil işlemede ise duygu analizi, metin sınıflandırması, sohbet botları (chatbots) ve sanal asistanlar, makine çevirisi gibi çeşitli örnekler ön plana çıkmaktadır.

Yapay sinir ağları derin öğrenmenin temelini oluşturmaktadır. Yapay sinir ağı, girdi katmanı, gizli katman ve çıktı katmanından oluşmakta, nöronlar (neurons), sinapslar (synapses), ağırlıklar (weights), önyargı (bias) ve fonksiyonlar gibi bileşenleri içermektedir (Şekil 1.8). Yapay Sinir Ağı, yapay nöronları temel almakta ve sinaps adı verilen nöronlar arasındaki bağlantılar yardımıyla sinyali diğer nöronlara iletmektedir. Alıcı nöron sinyalleri işleyerek diğer bağlı nöronlara göndermekte, böylelikle sinyaller giriş katmanından çıkış katmanına doğru geçişi tamamlamaktadır.



Şekil 1.8 : Yapay Sinir Ağının yapısı (Hassoun ve diğ., 1995).

Derin sinir ağlar ise yapay zeka modelini iyileştirmek için her biri bir önceki katman üzerine inşa edilen, birbirine bağlı düğüm katmanlarından oluşmaktadır. Girdi değerlerinin ağırlıklı toplamı ile çıkışta aktivasyon değerinin elde edilmesine ileriye doğru yayılma (forward propagation) denmektedir. Geri yayılım (backpropagation) ise tahminlerdeki hataları hesaplamak için gradyan azaltma (gradient descent) yöntemini kullanmakta ve modelin eğitim sürecinde ağırlık ve bias değerlerini optimize etmektedir.

Derin öğrenmeyi makine öğrenmesi yöntemlerinden ayıran en önemli özellik veri sayısı arttıkça performansın da ölçeklenerek artmasıdır. Derin öğrenmede ayrıca makine öğrenmesindeki gibi veri ön işleme adımına ihtiyaç duyulmamakta, görüntü ve metin gibi yapılandırılmamış (unstructured) veriler direkt olarak işlenerek özellik çıkarma (feature extraction) işlemi otomatik hale getirilmektedir. Karmaşık problemlerin çözümünde derin ağların, yani çok katmanlı yapıların kullanılmasıyla birlikte yüksek doğruluklu sonuçlar elde edilebilmektedir.

Hızlı bilgisayarların yaygınlaşması ve yeterli sayıda veriye erişimin kolaylaşması yapay zekanın gelişiminde kritik bir rol üstlenmiştir (Kelleher, 2019). Derin öğrenmenin tarihsel gelişimine bakıldığında 1960'lı yıllarda çok katmanlı algılayıcılar (multilayer perceptron), ileri beslemeli ağlar gibi temel uygulamaların ortaya çıktığı görülmüş, fakat yapay zekayı bugünkü anlamda dönüştüren ve yaygınlaştıran olay 2012 yılında derin öğrenme devrimi olarak adlandırılan ImageNet yarışmasının sonuçlarıdır. Evrimsel Sinir Ağları (Convolutional Neural Networks - CNN) temelli

AlexNet mimarisi ile yarışmada çok sayıda görüntü kullanılarak önemli bir başarı elde etmiştir. Derin bir katman yapısına sahip bu sinir ağının hesaplama maliyeti yüksek olsa da GPU kullanımı sayesinde obje tespitinde etkin bir şekilde kullanılmıştır. 2014 yılında RCNN, 2015'te ResNet ve YOLO yöntemlerinin geliştirilmesiyle birlikte bilgisayarlı görü alanında obje tespiti uygulamaları önemli bir eşiği aşmış ve hızlı bir şekilde yapay zeka endüstrisinde yaygınlaşmışlardır.

Derin öğrenme uygulamalarının çalıştırıldığı yazılım kütüphanelerinin sayısında da son dönemde artış olduğu görülmektedir. 2007 yılında Theano; 2013'te Caffe; 2015'te Keras, MXNet ve Tensorflow; 2016 yılında ise PyTorch yazılım kütüphaneleri geliştirilmiş, derin öğrenmenin yaygınlaşmasında önemli bir etken olmuşlardır. Bunların arasında Tensorflow, PyTorch ve Keras en yaygın kullanılan kütüphanelerdir. Derin öğrenmenin uygulama alanlarına baktığımızda özellik çıkarımı, gürültü giderme gibi uygulamalarda kullanılan Otokodlayıcı (Autoencoders), zaman serileri, duygu analizi, metin üretme gibi alanlarda kullanılan Uzun Kısa Süreli Bellek (Long Short-Term Memory - LSTM); resim, müzik, harita gibi eserlerden öğrenerek yeni ürünler oluşturmayı sağlayan Çekişmeli Üretici Ağlar (Generative Adversarial Networks - GAN); zaman serileri, doğal dil işleme gibi alanlarda kullanılan, dikkat (attention) mekanizmasına dayalı, yüksek verimlilik ve doğrulukla çalışan Transformers gibi son dönemlerde yaygın olarak kullanılan yenilikçi yöntemler göze çarpmaktadır.

1.5.4 Taşınmaz değerlendirme

4721 Sayılı Türk Medeni Kanunu Madde 704'te taşınmaz mallar arazi, tapu kütüğünde ayrı sayfaya kaydedilen bağımsız ve sürekli haklar ve kat mülkiyeti kütüğüne kayıtlı bağımsız bölümler şeklinde tanımlanmaktadır (Resmi Gazete, 2001). Vatandaşlar için büyük bir önemi olan taşınmazların mevcut piyasada ekonomik olarak da bir rayiç değeri bulunmaktadır. Arz-talep, ulusal ve uluslararası finansal durum, taşınmazın konumsal ve fiziksel özellikleri gibi birçok faktör bu değeri etkileyebilmektedir (Mourouzi-Sivitanidou ve Sivitanides, 2020; Sayın, 2021; Wyatt, 2013). Taşınmaz değerlendirme, bu kriterlerin ele alınmasıyla mevcut durumdaki değer tarafsız bir şekilde belirlenmesi sürecidir (Dale ve McLaughlin, 1988; SPK, 2001; Yomralıoğlu, 1997).

Taşınmaz değerine alım-satım, vergilendirme, kentsel planlama, imar uygulamaları, sermaye piyasası faaliyetleri gibi birçok işlemde ihtiyaç duyulmaktadır. Değere dayalı işlemlerde gerçek değer kullanılmasıyla birlikte sağlıklı bir değerlendirme veri tabanının oluşturulması ve objektif yaklaşıma sahip bir değerlendirme sisteminin geliştirilmesi oldukça önemlidir.

1.5.4.1 Taşınmaz değerlendirme yöntemleri

Taşınmaz değerlendirme yöntemleri klasik ve toplu değerlendirme olarak iki gruba ayrılabilir. Klasik yöntemler, tek seferde bir taşınmazın değerlemesi için sıklıkla kullanılan Emsal (Karşılaştırma), Gelir ve Maliyet yaklaşımlarından oluşmaktadır (IVSC, 2017). Öte yandan vergilendirme, imar uygulamaları, portföy yönetimi uygulamalarında çok sayıda taşınmazın toplu değerlemesi için Hedonik Değerleme, Nominal Değerleme, ÇRA, Karar Ağaçları, Topluluk Öğrenmesi ve YSA gibi yöntemler kullanılmaktadır.

Klasik yöntemler

Klasik yöntemler Emsal karşılaştırma, Gelir ve Maliyet olmak üzere üçe ayrılmaktadır. Bu üç yöntem IVSC tarafından da kabul edilen, dünya genelinde bir çok ülkede tekil değerlendirme amacıyla yaygın olarak kullanılan yöntemlerdir.

Emsal Karşılaştırma yöntemi, birbirine benzer nitelik ve öznelilikler taşıyan, konum olarak yakın çevrede bulunan taşınmazların belli bir tarihteki satış değerlerini baz alarak değerlemeye konu taşınmazın birim değerinin belirlenmesini sağlar (Açlar ve Çağdaş, 2002). Emsal karşılaştırma yönteminin tutarlı bir şekilde uygulanabilmesi için yakın dönemde satışı gerçekleşen 5 ile 10 arasında karşılaştırılabilir taşınmazın bulunması önerilmektedir. Emsal taşınmazların bulunmasındaki zorluk bu yöntemin dezavantajı olarak öne çıkmaktadır.

Emsal karşılaştırma yönteminde geçmişte satışı gerçekleşen taşınmazların fiyatları Türkiye İstatistik Kurumu (TÜİK) tarafından yayınlanan Yurtiçi Üretici Fiyat Endeksi (Yİ-ÜFE) baz alınarak değerlendirme gününe dönüştürülmelidir (Yargıtay, 2017). Ayrıca emsal olarak belirlenen taşınmazların değerlendirme konusu taşınmaza kıyasla değeri etkileyen olumlu ya da olumsuz yönleri varsa ilave ya da eksiltmelerin yapılması gerekmektedir. Emsal karşılaştırma yöntemi sonucunda hesaplanan birim değerlerin ortalama değerden sapma oranı \pm %15 olarak kabul görmektedir. Fakat bu sınır

değerin ülkemizde pratikte %20 olarak uygulandığı görülmektedir (Açlar ve Çağdaş, 2002; Yomralıoğlu, 2022).

Gelir yöntemi de bir taşınmazın ekonomik ömrü süresince getireceği net gelirinin baz alındığı değerlendirme yöntemidir. Yıllık brüt gelirden giderlerin toplamının çıkarılmasıyla hesaplanan net gelir, yapılı taşınmazlarda arsa ve bina için ayrı ayrı değerlendirilmelidir. Son olarak değerlendirme gününde bölgedeki kapitalizasyon faiz oranı kullanılarak taşınmazın değeri gelire dayalı elde edilmektedir (1.2). Gelir yöntemi ticari taşınmazlar ile arazilerin değerlemesinde yaygın olarak kullanılmaktadır. Kapitalizasyon faiz oranı, taşınmazın türüne (kiralık konut, işyeri, kuru tarım arazisi, sulu tarım arazisi vb.) ve ekonomideki mevcut duruma (reel ve nominal faiz oranları, enflasyon vb.) göre değişkenlik gösterebilmektedir. Bu durum Gelir yönteminin olumsuz tarafı olarak göze çarpmaktadır (Ülger, Ülger, ve Yıldız, 2019).

$$D = \frac{G_{net}}{KFO} \quad (1.2)$$

öyle ki;

D: Taşınmaz Değeri

G_{net}: Taşınmazın Yıllık Ortalama Net Geliri (Rantı)

KFO: Kapitalizasyon Faiz Oranı

Taşınmaz değerlemede kullanılan klasik yöntemlerden bir diğeri de maliyet yöntemidir. Maliyet yöntemi yapılı taşınmazların yeniden inşa edilme maliyetini esas alır. Bu yöntemde yapının değerlendirme günündeki inşaat maliyeti (yeniden inşa etme veya yerine koyma maliyeti) malzeme, ekipman, işçilik, proje masrafları, vergi gibi doğrudan ve dolaylı tüm maliyetler göz önüne alınarak hesaplanır. Hesaplanan maliyetlere %25 yüklenici kârı eklenir ve yıpranma, işlevsel eskime gibi yapının zamana bağlı aşınması neticesinde oluşan değer kaybı hesaplanır. Bu yıpranmaların toplamı yapının amortisman tutarını ifade eder ve hesaplanan maliyetten düşülmesi ile birlikte yeniden inşaat maliyetinin elde edilmesini sağlar. Son olarak yapının üzerinde bulunduğu arsanın boş olduğu varsayımı ile en iyi kullanım durumuna göre değeri inşaat maliyetine eklenerek taşınmazın toplam değeri bulunmuş olur (1.3).

$$D = M + K - A + D_{arsa} \quad (1.3)$$

öyle ki;

D: Taşınmaz Değeri

M: İnşaat Maliyeti

K: Yüklenici Kârı

A: Amortisman

D_{arsa}: Arsa Değeri

Toplu değerlendirme yöntemleri

Toplu değerlendirme, çok sayıda taşınmazın değerini tahmin etmek amacıyla bir dizi faktörün istatistiksel yöntemler ve çeşitli standartlar kullanarak analiz edilmesi olarak tanımlanabilir (IAAO, 2013b). Tekil değerlemeden farklı olarak, toplu değerlendirme yaklaşımı, bir grup taşınmazın değerlemesi için istatistik ve otomatik değerlendirme yöntemlerinden yararlanır. ÇRA (Benjamin, Guttery, ve Sirmans, 2020; Yilmazer ve Kocaman, 2020; Zurada, Levitan, ve Guan, 2011), Hedonik Değerleme (Lisi, 2019; Peterson ve Flanagan, 2009; Yamani, Ettarid, ve Hajji, 2019), Nominal Değerleme (Mete ve Yomralıoğlu, 2021; Nişancı, 2005; Yomralıoğlu, 1993; Yomralıoğlu ve Nisanci, 2004), GWR (Dimopoulos ve Moulas, 2016; Huang, Wu, ve Barry, 2010; Sisman ve Aydınoglu, 2022a; Wang, Li, ve Yu, 2020), Topluluk Öğrenmesi Yöntemleri (Alfaro-Navarro, Cano, Alfaro-Cortés, García, Gámez, ve Larraz, 2020; Aydınoglu ve diğ., 2021; Gnat, 2021) ve YSA (Demetriou, 2017; Lee, 2022; Yalpir, 2018) gibi toplu değerlendirme yöntemlerini uygulayan birçok çalışma bulunmaktadır. Depolama ve hesaplama kapasitelerinin yanısıra, CBS ve Yapay Zeka alanındaki gelişmelerle birlikte Bilgisayar Destekli Toplu Değerleme (Computer Aided Mass Appraisal - CAMA) uygulamaları yaygınlaşmış ve Otomatik Değerleme Modelleri (Automated Valuation Models - AVM) birçok ülkede benimsenmiştir (Renigier-Bițozor, Żróbek, Walacik, Borst, Grover, ve D'Amato, 2022; Wang ve Li, 2019).

Nominal değerlendirme yöntemi

Bir karar destek sistemi olarak CBS, CAMA yaklaşımının önemli bir bileşenidir. Konumsal kriterlerinin taşınmaz değeri üzerindeki etkisini ortaya koymak için CBS'den yararlanmak mümkündür. Toplu değerlendirme çalışmalarında CBS'nin izleme ve görselleştirme işlevlerinin yanısıra, güçlü coğrafi analiz kabiliyeti de bulunmaktadır.

GWR, Mekansal Analiz ve Nominal Değerleme gibi CBS tabanlı toplu değerlendirme yöntemleri, geniş alanlarda bulunan taşınmazların hızlı, doğru ve objektif bir şekilde değerlendirilmesini sağlamaktadır.

Nominal Değerleme, farklı etki düzeylerine sahip kriterlerin puanlama usulüne dayalı ağırlıklı toplamını ifade eden, Ağırlıklı Doğrusal Kombinasyon (Weighted Linear Combination - WLC) yaklaşımını baz alan stokastik bir yöntemdir (Yomraliöglu, 1993). Değeri etkileyen her bir kriter belli bir ölçekte (örneğin 0-100 aralığında) puan verilerek hem arazi hem de binaların değerleri nesnel bir yaklaşımla, parametrik olarak belirlenebilmektedir. Bir taşınmazın toplam nominal değeri, parsel veya piksel alanı ile çarpılan kriter puanlarının ağırlıklı toplamı olarak hesaplanmaktadır (1.4).

$$V_i = S_i * \sum_{j=1}^k (f_{ji} * w_j) \quad (1.4)$$

öyle ki;

V: Toplam nominal değer

S: Parsel veya piksel alanı

f: Faktör puanı

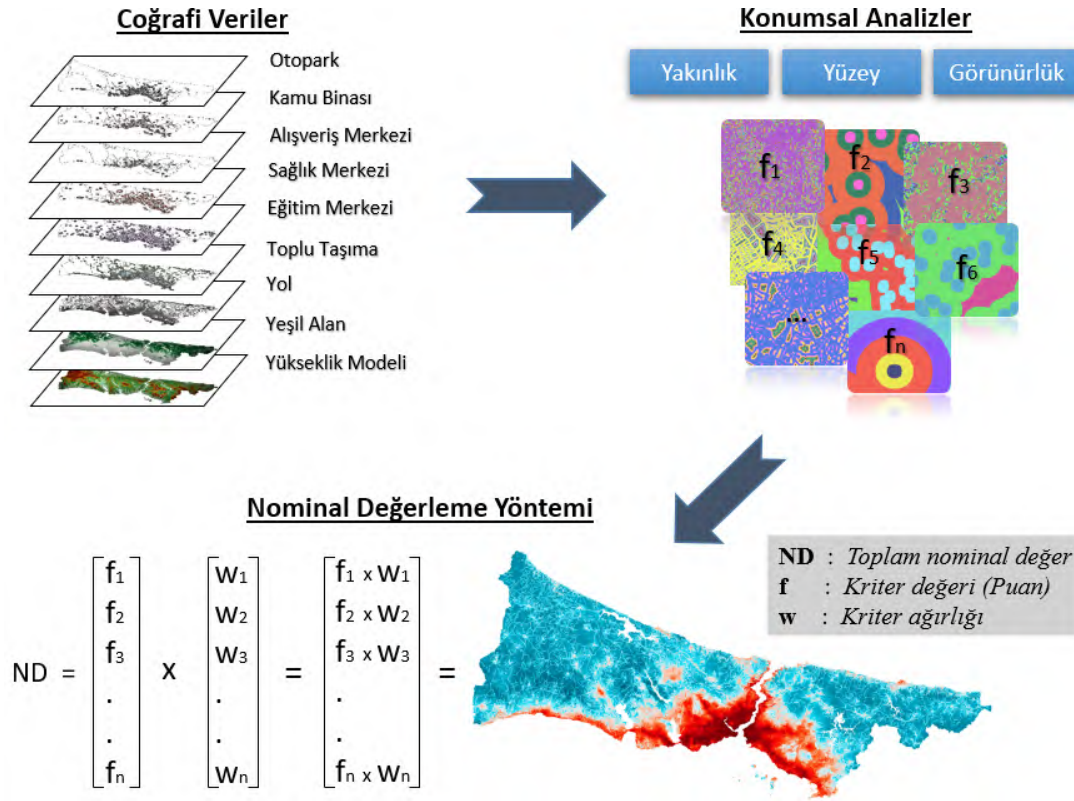
w: Faktör ağırlığı

k: Toplam faktör sayısı

Nominal Değerleme Yöntemi, diğer toplu değerlendirme yöntemlerine kıyasla birçok avantaja sahiptir. Doğrudan piyasa fiyatlarına bağlı olmadığı için mekansal analizlere dayalı değer farklılıklarını ortaya çıkarmak için bu yöntem geniş alanlardaki taşınmazlara kolaylıkla uygulanabilmektedir (Şekil 1.9). Ayrıca piksel bazlı değerlendirme yaklaşımı ile parsel ölçüğünden de hassas, yüksek çözünürlüklü nominal değer haritaları oluşturulabilir. Dengeli piyasa koşullarını yansıtan, güvenilir taşınmaz değerleri kullanılarak nominal değerlerden piyasa değerlerine ilgili para biriminde geçişin sağlanması da mümkündür.

Yapay zeka ve makine öğrenmesi ile taşınmaz değerlendirme

Makine Öğrenmesi yöntemleri finans, yatırım, gayrimenkul değerlendirme gibi çeşitli ekonomik alanlarda yaygın olarak kullanılmaktadır. Vergilendirme, planlama, mülk yönetimi gibi uygulamalar için gerçekleştirilen toplu taşınmaz değerlendirme



Şekil 1.9 : CBS destekli nominal değerlendirme yöntemi.

uygulamalarında objektif ve doğru fiyat tahmini için çoğunlukla regresyon analizleri ve YSA'dan yararlanılmaktadır. Klasik yöntemler ile yapılan toplu değerlendirme uygulamalarında değeri etkileyen kriterlerin ağırlıkları önemli bir tartışma konusudur. Kriterlerin önem düzeyi şehirlerin yapısına ya da kişilerin görüşüne göre değişebilmektedir. Genelgeçer ve olabildiğince objektif kriter ağırlıklarının belirlenebilmesi için literatürde anket çalışması, uzman görüşü, ÇKKV yöntemleri gibi yaklaşımların kullanıldığı görülmektedir. Öte yandan bu ağırlıkların piyasada oluşan arz-talep dengesi, ekonomik durum, toplumsal yönelim gibi sebeplerin sonucunda ortaya çıkan birim fiyatlara göre yapay zeka tarafından belirlenmesi daha tutarlı ve yansız değerlendirme imkanı sunmaktadır. Yapay zeka ve makine öğrenmesi ile taşınmaz değerlemede genellikle denetimli öğrenme algoritmalarından regresyon analizi kullanılarak yeterli sayıda örneklem ile tahmin modelinin eğitilmesi sağlanmaktadır. Emlak listeleme sayfaları bulunan birçok şirketin (Zillow, Rightmove, REIDIN, Endeksa gibi) ürettiği değer endeksleri ve tahmin modelleri yapay zeka yöntemlerine dayanmaktadır.

Taşınmaz değerlemede Doğrusal, Ridge, Lasso, Polinomal ve Bayeşçi Regresyon gibi çeşitli yöntemlerin yanı sıra Rastgele Orman, XGBoost gibi Topluluk Öğrenmesi

regresyon modelleri de yaygın olarak kullanılan yöntemlerdir. Yüksek doğruluklu tahmin özellikleri ve açıklanabilir yapay zeka (eXplainable AI - XAI) yöntemlerinden olan öznitelik önem skorları (feature importance) değişkenlerin modele katkısının detaylı bir şekilde incelenmesini mümkün kılmaktadır. Öte yandan SHAP, oyun teorisindeki shapley değerlerini kullanarak değişkenlerin tahmine dayalı Makine Öğrenimi modeline katkısını ölçen bir açıklanabilir yapay zeka algoritmasıdır (Lundberg ve Lee, 2017). Shapley değerleri tüm değişkenlerin modelde buldukları ve bulunmadıkları bütün olası durumların etkilerini inceleyerek sonuca verdikleri ortalama katkıyı hesaplamaktadır. Böylelikle bir faktörün pozitif ya da negatif yönde tahmin sonucuna ne kadar etki ettiği belirlenebilmektedir. Regresyon algoritmalarının açıklanabilir yapay zeka yöntemleri ile birlikte kullanımı, Rastgele Orman, XGBoost gibi karmaşık modellerin toplu değerlendirme alanında önemli bir yer edinmesini sağlamıştır. Regresyon analizlerinin dışında kümeleme analizi ile taşınmaz değerlendirme (Sisman ve Aydinoglu, 2022b), bina görüntülerinden öznitelik çıkarımı ile değerlendirme modelinin doğruluğunun artırılması (Lindenthal ve Johnson, 2021), LSTM, Transformers gibi algoritmalar ile taşınmaz değerlerinin zaman serisi analizleri (Chen, Wei, ve Xu, 2017) gibi uygulamalar da yapay zeka ve makine öğrenmesi yöntemlerinin taşınmaz değerlendirme alanında artan kullanımına dikkat çekmektedir.

1.5.4.2 Dünyada taşınmaz değerlendirme

Dünya genelinde birçok ülke arazi, arsa ve bina değerlemesi kapsamında hukuki ve teknik altyapı hazırlayarak planlama, vergilendirme gibi çeşitli amaçlar için değerlendirme çalışmalarını yürütmektedirler. Ülkeler taşınmazlara ait satış değerlerinin kayıt altına alınması amacıyla veri tabanları oluşturmakta, bu verileri arazi idaresi sistemleri içerisine entegre ederek toplu değerlendirme çalışmaları yürütmeyi hedeflemektedirler.

FIG'nin 7. Kadastro ve Arazi Yönetimi Komisyonu ve 9. Taşınmaz Değerleme ve Taşınmaz Yönetimi Komisyonu bünyesinde gerçekleştirilen anket çalışmasında ülkelerin vergilendirme amaçlı taşınmaz değerlendirme uygulamaları hakkında bilgi edinilmiştir (FIG, 2017; Kara, 2021). 22 ülkeden 24 uzmanın katılım sağladığı ankete göre ülkelerin büyük çoğunluğunun toplu değerlendirme sistemi çalışmalarının bulunduğu, fakat ülkelerin tamamını kapsayan bütüncül bir değerlendirme modelinin bulunmadığı sonucuna ortaya çıkmıştır. Anketi cevaplayan ülkelerin %65'inin toplu

değerleme sisteminin bulunduğu, Danimarka, İspanya, Slovenya, Güney Kıbrıs, Hollanda ülkelerinin kendi yazılımlarını geliştirdikleri belirtilmiştir.

Bu bölümde Birleşik Krallık'ta yer alan İngiltere ve Galler ülkelerinin taşınmaz değerlendirme alanındaki çalışmaları ele alınmış, değerlendirme çalışmalarında görev ve yetkileri bulunan ilgili kurumlar hakkında bilgi verilmesi amaçlanmıştır.

Arazi kayıt sistemleri uluslararası hukukta tapu sistemi ve Torrens senet sistemi olarak iki grupta ele alınmaktadır. Tapu sistemi "tapu tescili" ilkesine, Torrens sistemi ise "tescil yoluyla tapu senedi" esasına dayanmaktadır. İngiltere ve Galler, Torrens sisteminin değiştirilmiş versiyonu olan İngiliz sistemini benimsemişlerdir. İngiltere ve Galler'de tapu tescil işlemleri 1862'de kurulan, bakanlık dışı bir devlet kurumu olan Kraliyet Arazi Kayıt Kurumu tarafından yürütülmektedir. Kraliyet Arazi Kayıt Kurumu, taşınmaz mülkiyeti, ipotekleri ve taşınmazlara dayalı hak ve faydaları kayıt altına almaktadır. 2022 yılı başında tüm arazilerin yaklaşık %87'si kaydedilen İngiltere ve Galler'de 26 milyon tapu senedi bulunmaktadır. Kurum tarafından gerçekleştirilen taşınmaz tescillerinin 2030 yılına kadar büyük oranda tamamlanması hedeflenmektedir (HM Land Registry, 2022). Kraliyet Arazi Kayıt Kurumu, güvenli, hızlı ve kolay bir kayıt sistemi sağlamanın yanı sıra, alım-satım verilerini (PPD) ve bu işlemlere dair faydalı istatistikler ile konut değer endekslerini (UK House Price Index - UK HPI) açık veri olarak paylaşmaktadır.

VOA İngiltere, Galler'de hükümet, kamu kurumları ve yerel idarelere değerlendirme ve vergilendirme konularında destek veren bir devlet kurumudur. VOA yaklaşık 26 milyon taşınmaz için belediye vergi bantları listeleri hazırlamakta, sektörlere bağımsız ve tarafsız değerlendirme ve danışmanlık hizmeti vermektedir (VOA, 2022). Birleşik Krallık'ta VOA ile benzer görevleri bulunan İskoçya Değerlemeciler Birliği (Scottish Assessors Association), İrlanda Değerleme Ofisi (Valuation Office) ve Kuzey İrlanda Arazi ve Mülkiyet Servisi (Land and Property Service) bulunmaktadır.

Council Tax, İngiltere, İskoçya ve Galler'de kullanılan yerel bir taşınmaz vergilendirme sistemidir. 1993 yılında "Yerel Yönetim Finansmanı Yasası 1992 (Local Government Finance Act 1992)" ile uygulamaya konan vergilendirme sisteminde her taşınmaz fiziksel özellikleri, yüzölçümü, plan durumu, konumu, kullanım fonksiyonu gibi kriterlere göre değerlendirilerek vergi bantlarına atanmaktadır. İngiltere ve

İskoçya'da 1991 yılına göre sabitlenmiş A'dan H'ye kadar sekiz vergi bandı, Galler'de 2003 yılına göre sabitlenmiş A'dan I'ya kadar dokuz vergi bandı belirlenmiştir. Yeni konutlar için vergi tutarlarının hesaplanmasında VOA 1991 yılındaki emsal satışlara göre taşınmazı bir vergi bandına atamaktadır. Council tax, emlak vergisi ve kişisel verginin birleşimi şeklinde uygulanmaktadır. Bazı taşınmazlar için vergi muafiyeti, bazıları için de belli oranlarda indirim uygulanmaktadır. Genel olarak bir konutta iki veya daha fazla kişinin ikamet etmesi durumunda tam vergi alınmakta, bir kişinin ikamet etmesi durumunda ise bu verginin %75'i alınmaktadır. Boş konutlarda da vergi taşınmaz malikine yarı oranda tahakkuk ettirilmektedir. Tam zamanlı öğrencilerden ise bu vergi alınmamaktadır (URL-1).

Birleşik Krallıkta taşınmazlara yönelik alınan diğer bir vergi türü de alım-satım işlemi sonucunda ödenen vergidir. İngiltere ve Kuzey İrlanda'da Arazi Damga Vergisi (Stamp Duty Land Tax - SDLT), İskoçya'da Arazi ve Bina Alım-Satım İşlemi Vergisi (Land and Buildings Transaction Tax - LBTT), Galler'de ise Arazi Alım-Satım İşlemi Vergisi (Land Transaction Tax - LTT) olarak adlandırılan bu vergi, belli bir fiyatın üzerinde satın alınan taşınmazlar için ödenmektedir. İngiltere'de 2020 yılında alınan karara göre 500.000 £ altındaki taşınmazlar için vergi muafiyeti bulunmakta, bu tutarın üzerindeki satın alımlar için vergi ödenmektedir (URL-2).

Uluslararası boyutta değerlendirme çalışmalarında bir standart oluşturmak, değerlendirme yöntemlerini ve kurallarını açıklamak, değerlendirme faaliyetlerinin doğruluğunu, güvenilirliğini, şeffaflığını sağlamak gibi amaçlar doğrultusunda kurulmuş çeşitli mesleki değerlendirme organizasyonları bulunmaktadır. Uluslararası Değerleme Standartları Konseyi (International Valuation Standards Council - IVSC), Avrupa Değerlemeci Birlikleri Grubu (The European Group of Valuers' Associations - TEGoVA), Lisanslı Değerleme Uzmanları Kraliyet Kurumu (Royal Institution of Chartered Surveyors - RICS), Değerleme Kurumu (Appraisal Institute - AI), Değerleme Vakfı (The Appraisal Foundation), Amerikan Değerlemeciler Birliği (American Society of Appraisers - ASA), Uluslararası Değerlemeciler Birliği (International Association of Assessing Officers - IAAO), Uluslararası Taşınmaz Federasyonu (The International Real Estate Federation - FIABCI) öne çıkan meslek birliklerinden bazılarıdır.

1981 yılında Avusturya'da kurulan IVSC, değerlendirme mesleği ile ilgili genel uygulamaları ve değerlendirme yöntemlerini içeren Uluslararası Değerleme Standartları

(International Valuation Standards - IVS)'ni yayınlayan kuruluştur. Uluslararası düzeyde değerlendirme çalışmalarına standart getiren bu rehber kitap ilk olarak 1985 senesinde yayımlanmaya başlamış ve belli periyotlarda güncellenmektedir. Halihazırda 31 Ocak 2022 yılında çıkarılan baskısı kullanılmaktadır. Dünya genelinde değerlendirme çalışmalarında bir çatı kurum görevi gören IVSC'nin değerlendirme standartları bazı ülkelerde mevzuata dahil edilmişken, bazılarında ise mevzuata dahil edilmemesine rağmen ulusal değerlendirme kuruluşları tarafından kabul görerek uygulanmaktadır (IVSC, 2020).

TEGoVA, Avrupa Birliği üyesi ülkelerde yürütülen değerlendirme faaliyetlerini denetlemek, üye ülkelerin birbirleriyle uyumlu değerlendirme çalışmaları yapmalarını sağlamak, birlik tarafından belirlenen etik ilkeleri benimsetmek, değerlendirme standartlarını oluşturmak ve yaygınlaştırmak amacıyla 1997 yılında Belçika'da kurulmuştur. IVSC ile irtibatlı bir şekilde çalışmalarını yürüten birliğin bünyesinde 38 farklı ülkeden 70.000'den fazla üyeye sahip 72 kuruluş bulunmaktadır. TEGoVA değerlendirme çalışmalarında Mavi Kitap (Blue Book) olarak bilinen rehber niteliğindeki Avrupa Değerleme Standartları (European Valuation Standards - EVS) adlı kitabı yayımlamaktadır (Güngör, 1999; Messenger, 2010).

RICS ise 1868 yılında Londra İngiltere'de kurulmuş, dünya genelinde yüzlerce ülkede 130.000'den fazla üyesi (Chartered Surveyor) bulunan uluslararası değerlendirme mesleği birliğidir. Değerleme standartlarını belirlemek, etik değerleri üyelerine benimsetmek, değerlendirme yöntemlerini düzenlemek, uluslararası değerlendirme çalışmalarında güvenilirliği ve şeffaflığı sağlamak gibi görev ve sorumlulukları bulunan RICS, değerlendirme standartlarını ve değerlendirme çalışmalarında dikkat edilmesi gerekenleri içeren Kırmızı Kitap (Red Book) adında bir rehber kitap yayımlamaktadır (RICS, 2022).

1.5.4.3 Türkiye'de taşınmaz değerlendirme

Kamu kurumları, özel şirketler, belediyeler, bankalar, vatandaşlar, lisanslı değerlendirme şirketleri, lisanslı değerlendirme uzmanları, bilirkişiler gibi paydaşları olan taşınmaz değerlemesinin ülke ekonomisi için önemli bir yeri vardır. 2021 yılında taşınmazların değerinin belirlenmesi için toplam 1.084.498 adet değerlendirme raporu yazılmış, 2022 yılında ise bu sayının ilk çeyrekte toplam 311.021 adete ulaştığı görülmüştür (TDUB, 2019). Taşınmaz değerlendirme ile alakalı mevzuatımızda 2942 sayılı Kamulaştırma

Kanunu, 213 sayılı Vergi Usul Kanunu, 6306 sayılı Afet Riski Altındaki Alanların Dönüştürülmesi Hakkında Kanun, Emlak Vergisine Matrah Olacak Vergi Değerlerinin Takdirine İlişkin Tüzük gibi çeşitli kanun, yönetmelik, tüzük, yönerge ve genelgelerde hükümler yer almakta, çeşitli kurumların çalışmalarında güncel değer tespiti ihtiyacı duyulduğu görülmektedir.

2942 sayılı Kamulaştırma Kanunu'nun 11. Maddesi ülkemizde taşınmaz değerlendirme mevzuatını önemli ölçüde şekillendiren, değerlendirme çalışmalarında referans alınan değer tespit esaslarını içermektedir. Yasada taşınmazın "cins ve nevini, yüzölçümünü, kıymetini etkileyebilecek bütün nitelik ve unsurlarını ve her unsurun ayrı ayrı değerini, varsa vergi beyanını, kamulaştırma tarihindeki resmi makamlarca yapılmış kıymet takdirlerini, arazilerde taşınmaz mal veya kaynağın mevki ve şartlarına göre ve olduğu gibi kullanılması halinde getireceği net gelirini, aralarda kamulaştırılma gününden önceki özel amacı olmayan emsal satışlara göre satış değerini, yapılarda resmi birim fiyatları ve yapı maliyet hesaplarını ve yıpranma payını, her bir ölçünün etkisi açıklanmak kaydıyla bedelin tespitinde etkili olacak diğer objektif ölçüleri" esas tutarak Sermaye Piyasaları Kurulu (SPK) formatına uygun bir değerlendirme raporunun hazırlanması gerektiği ifade edilmektedir (Resmi Gazete, 1983).

1319 sayılı Emlak Vergisi Kanununa dayanan Emlak Vergisine Matrah Olacak Vergi Değerlerinin Takdirine İlişkin Tüzük'te arazi, arsa ve binaların vergi değerinin hesabına ilişkin ayrıntılı hükümler yer almaktadır. Tüzük kapsamında bölgesel, doğal ve iktisadi durumlara göre yapılacak değerlendirmede uyulacak usul ve esaslara yer verilmiştir. Örneğin Madde 7'de binalar için vergi değeri takdirinde kullanılacak tarzı, inşaatın cinsi, sınıfı, konumu, park, bahçe, okul gibi tesislere yakınlığı, belediye hizmetlerinin varlığı, büyüklük, kat sayısı, oda, banyo sayısı, müstemilatı, cephe durumu, asansör, kalorifer, klima tesisatının varlığı, manzara görme durumu gibi özelliklerin dikkate alınması gerektiği belirtilmiştir (Resmi Gazete, 1972).

Ülkemizde taşınmaz değerlendirme uygulamaları belli bir organizasyon çerçevesinde yürütülse de mevzuat alyapısının farklı yasalara eklenmiş şekilde dağınık bir yapıda bulunması çeşitli sorunlara yol açmaktadır. Özetle tüm süreçleri bütüncül şekilde ele alan bir taşınmaz değerlendirme kanuna gereksinim olduğu ortaya çıkmaktadır.

SPK, ülkemizde değerlendirme faaliyetlerinin standartlara uygun bir şekilde yürütülmesinde düzenleyici ve denetleyici rolü bulunan önemli bir kurumdur. 2499 sayılı Sermaye Piyasası Kanunu, 22. Maddesinin r bendinde SPK'nın görev ve yetkileri arasında "değerleme faaliyetinde bulunacak kurumlara yönelik şartları belirlemek ve bu kurumların listesini ilan etmek" tanımları yer almaktadır (Resmi Gazete, 1981). Ayrıca 31.08.2019 tarih ve III-62.3 sayılı Sermaye Piyasasında Faaliyette Bulunacak Gayrimenkul Değerleme Kuruluşları Hakkında Tebliğ ile birlikte değerlendirme kuruluşlarının sahip olmaları gereken sermaye, ortaklık yapısı, görev alacak uzmanların nitelikleri, yeterlilikleri, mesleki etik ve faaliyetlerin sürdürülmesine ilişkin gereksinimleri belirlenmiştir.

Türkiye Değerleme Uzmanları Birliği (TDUB), 6362 sayılı Sermaye Piyasası Kanun'unun 76'ncı maddesine dayanılarak kurulmuş, görev ve yetkileri ile çalışma esasları 02 Nisan 2014 tarih ve 28960 sayılı Türkiye Değerleme Uzmanları Birliği Statüsü ile belirlenmiştir. TDUB, taşınmaz piyasasının ve taşınmaz değerlendirme faaliyetlerinin gelişmesini sağlamak üzere araştırma, eğitim ve sertifika verme, üyeler arası dayanışma, mesleğin gerektirdiği özen ve disiplin içerisinde çalışmalar için meslek kuralları ve değerlendirme standartları oluşturma, kendi statüsünde öngörülen disiplin cezalarını verme ve ilgili konularda üyeleri temsilen ilgili kuruluşlarla işbirliği yapma gibi görevleri bulunan bir mesleki birliktir. TDUB, Gayrimenkul Değerleme Lisansına sahip olan değerlendirme uzmanları ve SPK tarafından yetkilendirilen şirketlerin üyeliği ile oluşturulmuştur. TDUB faaliyet raporlarına göre 31 Aralık 2021 tarihi itibarıyla ülke genelinde 8.652 Gayrimenkul Değerleme Uzmanı ve 145 Gayrimenkul Değerleme Şirketi görev yapmaktadır (TDUB, 2019).

TDUB'un statüsünün 7. maddesi ile üyelerinin faaliyetlerini kolaylaştırmak ve değerlemenin kalitesini artırmak üzere bölgesel ve ülke genelinde gayrimenkul değerleri konusunda veri analiz raporları oluşturmak ve yayımlamak amacıyla gayrimenkul bilgi merkezi kurma görevi bulunmaktadır. Bu doğrultuda SPK talimatları ile 23 Şubat 2016 tarihinde TDUB Gayrimenkul Bilgi Merkezi A.Ş., TDUB iştiraki olarak kurulmuştur. 18 Temmuz 2020 tarih ve 31189 sayılı "Sermaye Piyasasında Faaliyette Bulunacak Gayrimenkul Değerleme Kuruluşları Hakkında Tebliğ'de Değişiklik Yapılmasına Dair Tebliğ" ile şirket unvanı "MKK Gayrimenkul Bilgi Merkezi Anonim Şirketi" olarak düzenlenmiştir (MKK GABİM, 2022).

4 sayılı Bakanlıklara Bağlı, İlgili, İlişkili Kurum ve Kuruluşlar ile Diğer Kurum ve Kuruluşların Teşkilatı Hakkında Cumhurbaşkanlığı Kararnamesi'ne 05.02.2019 tarih ve 30 sayılı kararname ile eklenen maddelerde ülkemizin taşınmaz değerlendirme çalışmaları hakkında önemli adımlar atılmıştır. İlgili kararnamenin 478'nci maddesinin birinci fıkrasına, TKGM'nin kuruluş, görev, yetki ve sorumlulukları ile teşkilatlanmasına ilişkin usul ve esasları arasına, "toplu değerlendirme faaliyetlerini düzenlemek ve yürütmek" ifadesi eklenmiştir. TKGM'nin görev ve yetkileri arasına, 480'nci maddenin birinci fıkrasının (h) bendinde, "taşınmazların toplu değerlendirme yöntemleriyle değerini belirlemek, değer bilgi merkezini kurmak, yönetmek ve değer haritalarının üretilmesi ile güncel tutulmasını sağlamak" ifadeleri eklenmiştir. Öte yandan 483'ncü maddenin birinci fıkrasının (e) bendinde (Değişik:RG-5/2/2019-30677-CK-30/19), TKGM bünyesindeki teşkilatlara Taşınmaz Değerleme Dairesi Başkanlığı eklenmiştir. 484'nci maddenin birinci fıkrasının (e) bendinde (Ek:RG-5/2/2019-30677-CK-30/20) Taşınmaz Değerleme Dairesi Başkanlığı'nın görevleri:

- 1) Taşınmazların toplu değerlendirme yöntemleriyle değerini belirlemek, değer bilgi merkezini kurmak, yönetmek ve değer haritalarının üretilmesi ile güncel tutulmasını sağlamak.
- 2) Gereken durumlarda toplu değerlendirme çalışmalarında kullanılmak üzere tekil değerlendirme yaptırmak veya talep etmek.
- 3) Toplu değerlendirme standartlarına ilişkin çalışmaları yürütmek.
- 4) Toplu değerlendirme çalışmaları sonucunda elde edilen verilere dayanarak istatistikler ve raporlar yayımlamak.
- 5) Taşınmaz değerlendirme ve toplu değerlendirme alanlarıyla ilgili ihtiyaç analizleri ile uluslararası gelişmeler ve iyi uygulamaların takibini yapmak.
- 6) Bu bent ile verilen görev ve yetkilerin yürütülmesine ilişkin usul ve esasları belirlemek.

olarak ifade edilmiştir (Resmi Gazete, 2019).

Cumhurbaşkanlığı kararnamesi ile birlikte TKGM'ye taşınmaz değerlendirme alanında önemli sorumluluklar yüklenmiştir. Taşınmaz Değerleme Daire Başkanlığı, ülkemizde etkin bir toplu değerlendirme sisteminin oluşturulması amacıyla çalışmalarına devam etmektedir.

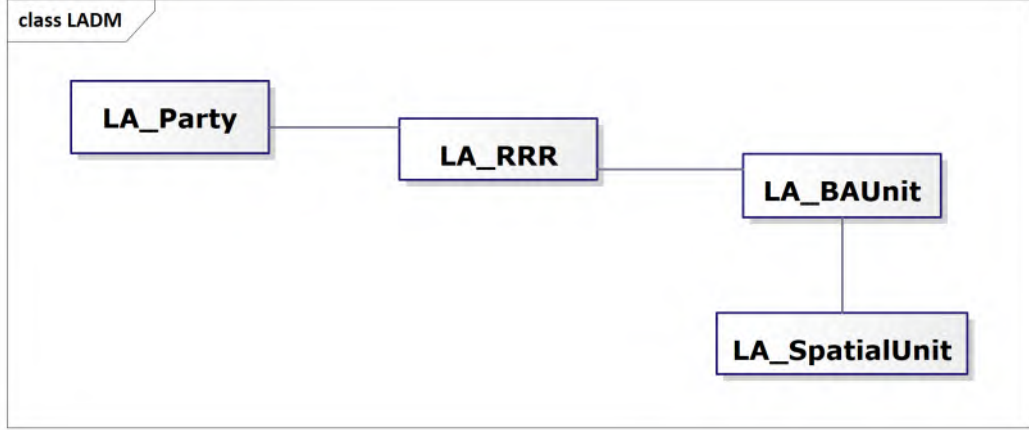
Dünya Bankası ile Türkiye Cumhuriyeti arasında 2008 yılında imzalanan Tapu ve Kadastro Modernizasyon Projesinin beş ana bileşeninden biri de taşınmaz değerlendirilmesidir. Bu bileşen ile taşınmaz değerlendirme çalışmalarında uluslararası iyi örnek uygulamalarının incelenerek Türkiye'ye uyarlanması ve bu alanda politika ve yetkinliklerin geliştirilmesi amaçlanmıştır (TKGM, 2021b). Projenin ek finansmanı kapsamında TKGM Taşınmaz Değerleme Dairesi Başkanlığı 2020 yılının Temmuz ayında "Toplu Değerleme Sisteminin Geliştirilmesi" amacıyla danışmanlık hizmeti ilanı yayınlamıştır. İlanda taşınmaz değerlendirme sisteminin oluşturulması amacıyla kitlesel değerlendirme çalışmalarını kapsayan kavramsal modelin tasarlanması, veri tabanının oluşturulması, pilot bölgelerdeki (Fatih/İstanbul, Mamak/Ankara) değerlendirme verilerinin kurulacak modelde test edilmesi gibi hedefler yer almıştır (TKGM, 2020a). İlgili kurumun Cumhurbaşkanlığı kararnamesiyle tanımlanan görev, yetki ve sorumlulukları kapsamında kitlesel değerlendirme çalışmaları devam etmektedir.

TKGM'nin yürüttüğü önemli çalışmalardan biri de Tapu ve Kadastro Bilgi Sistemi (TAKBİS) projesidir. TAKBİS, tapu ve kadastro hizmetlerinin dijital ortamda sunulmasıyla taşınmazların etkin bir şekilde yönetildiği ve vatandaşların mülkiyete dair çeşitli sorgulamalar yapabildiği temel bir e-devlet uygulamasıdır (TKGM, 2021a). Halihazırda birçok e-devlet projesi ve kamu kurumu ile entegre bir şekilde çalışan TAKBİS, taşınmaz değerlendirme çalışmaları sırasında tapu sicil ve kadastro verilerine erişim için de önemli bir bilgi kaynağıdır. TKGM'nin TAKBİS 2020 vizyon projesi ile veri kalitesinin iyileştirilmesi, konumsal verilerin zaman bağılı değişimlerinin takip edilebilmesi ve çok amaçlı/çok boyutlu kadastronun uygulanabildiği TUCBS ve LADM uyumlu bir kavramsal veri modelinin tasarımı hedeflenmektedir (Dursun, Aslan, ve Sarıyüz, 2019).

1.5.5 Arazi İdaresi Alan Modeli (LADM)

Yeryüzünü ve yeraltını, arazileri, binaları ve şehirleri kavramsal olarak modellemek için LADM, INSPIRE (Bina ve Kadastral Parsel Temaları), LandInfra, CityGML, IndoorGML gibi çeşitli uluslararası standartlar geliştirilmiştir. LADM ile taşınmazların (arazi, arsa, bina) yasal, fiziksel, geometrik, semantik özelliklerini standart bir yapıda modelleyerek etkin bir arazi idaresi sistemi oluşturulması amaçlanmıştır (ISO, 2012; Lemmen, 2012; Lemmen, van Oosterom, ve Bennett, 2015). Arazi yönetimi için temel

yapıda, geliştirilebilir bir model sunan LADM, Kisi (LA_Party), SSS (LA_RRR), TescilNesne (LA_BAUnit) ve KonumsalBirim (LA_SpatialUnit) olmak üzere dört temel sınıftan oluşmaktadır. Şekil 1.10'de LADM'ye ait temel sınıflar görülmektedir.



Şekil 1.10 : LADM'nin temel sınıfları (ISO, 2012).

Değerlemeye tabi olan taşınmazların farklı veri kaynaklarında bulunan yasal, fiziksel, çevresel, ekonomik ve geometrik özelliklerine ihtiyaç duyulmaktadır. Bu verilerin tapu kadastro, belediye gibi tüm kamu kurumlarının sicillerine bağlanarak birlikte çalışabilmesi için bir arazi idaresi altyapısı gereklidir (Lemmen ve diğ, 2019a). ISO LADM standardının ilk sürümünde vergilendirme ve taşınmaz değerlemeye ilişkin harici ExtTaxation (K4) ve ExtValuation (K7) sınıfları yer almaktadır. FIG tarafından geliştirilen LADM'nin ikinci versiyonunda kavramsal veri modelleri daha fazla semantik içerecek ve detaylı dört boyutlu profilleri barındıracak şekilde revize edilmekte, BIM/IFC, GML, CityGML, LandXML, LandInfra, IndoorGML, RDF/bağlı veri, GeoJSON gibi veri kodlamaları ile entegrasyonları sağlanmaktadır. Genişletilmiş bu model Arazi İdaresi Temelleri (LADM Fundamentals) üzerine kurulmuş olan LADM_VM'yi de kapsayacaktır (Çağdaş, Kara, Işıkdağ, van Oosterom, Lemmen, ve Stubkjaer, 2017; Çağdaş ve diğ, 2016; Kara ve diğ, 2021, 2020).

1.5.5.1 LADM Değerleme Bilgi Modeli

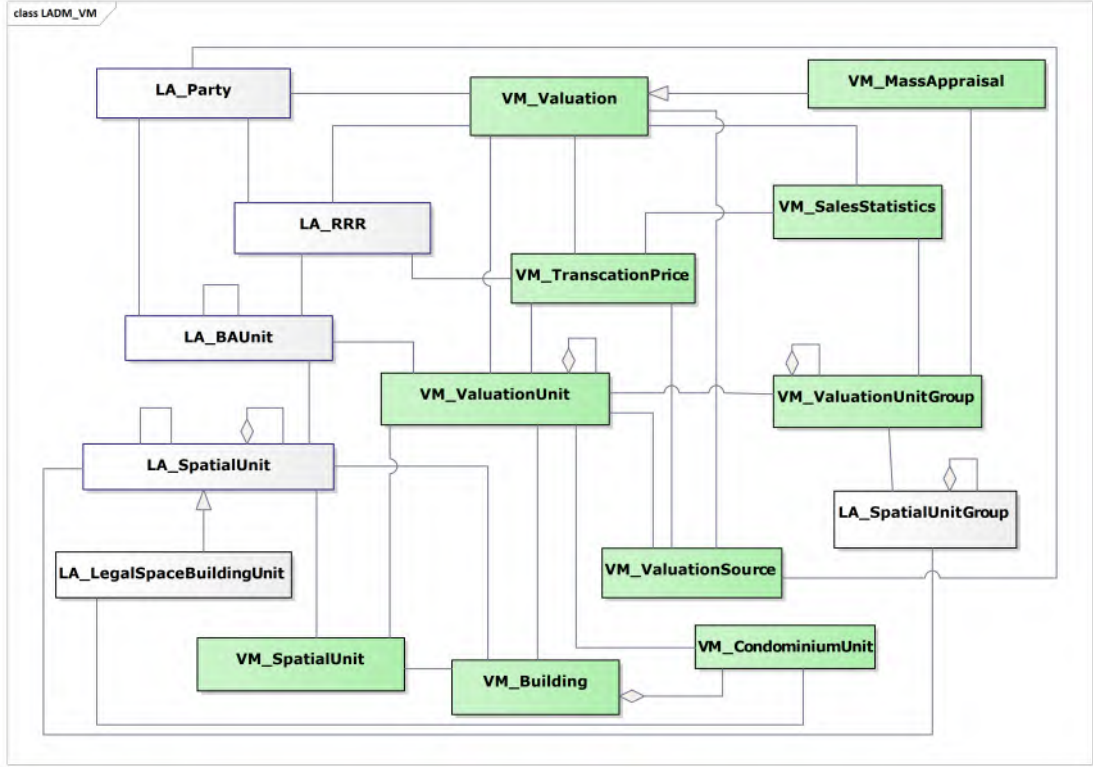
Değerleme çalışmalarında standart oluşturmak, değerlendirme yöntemlerini ve kurallarını açıklamak, değerlendirme faaliyetlerinin doğruluğunu, güvenilirliğini, şeffaflığını sağlamak gibi amaçlar doğrultusunda, IVSC, TEGoVA, RICS, IAAO gibi birçok uluslararası mesleki değerlendirme organizasyonu kurulmuştur. Uluslararası birçok kuruluşun standart çalışmaları bulunmasına karşın, taşınmaz değerlendirme çalışmalarının semantiğini

tanımlayan ve deęerlemenin dięer veri tabanları ve kamu sicilleriyle olan iliřkisini belirten bir veri modeli bulunmamaktaydı (Çaędař ve dię, 2016; Kara ve dię, 2018). LADM'nin ikinci sũrũmũ hazırlanırken sũzũ edilen uluslararası deęerleme organizasyonları ile iřbirlięine gidilmiř ve Standard on Mass Appraisal of Real Property (IAAO, 2017), Guidance on International Mass Appraisal and Related Tax Policy (IAAO, 2013a), Standards on Ratio Studies (IAAO, 2013c), Standard on Automated Valuation Models (IAAO, 2018), International Valuation Standards (IVSC, 2020) gibi standartlar baz alınmıřtır. Bũylelikle, ũlkelerin, řehirlerin veya ũzel kuruluřların tařınmaz deęerleme bilgi sistemini oluřturması iin gerekli temel kavramsal model geliřtirilmiřtir (Kara ve dię, 2017).

LADM_VM, LADM'nin ikinci versiyonunda temel paketlerden biri olarak tasarlanmıřtır. LADM_VM, deęerleme sũrelerinin semantięini tanımlayan bir kavramsal modeldir. LADM_VM tařınmaz deęerleme amalı bir arazi bilgi sistemi oluřturmak iin kullanılabilir ve dięer kamu kurumlarının kayıt sicilleri ile iliřkilendirilebilir bir yapıya sahiptir. LADM_VM, kurumların standart ve direktifleri gũz ũnũnde bulundurularak tapu-kadastro, tekil veya toplu deęerleme, tařınmaz fiyatlarının ve satıř istatistiklerinin kaydı gibi tařınmaz deęerlemenin tũm ařamalarını kapsayacak řekilde tasarlanmıřtır. LADM_VM on adet ana sınıftan oluřmaktadır (Lemmen ve dię, 2019b): (1) DegerlemeBirim (VM_ValuationUnit), (2) DegerlemeBirimGrup (VM_ValuationUnitGroup), (3) KonumsalBirim (VM_SpatialUnit), (4) Bina (VM_Building), (5) BagimsizBolum (VM_CondominiumUnit), (6) Degerleme (VM_Valuation), (7) KitleselDegerleme (VM_MassAppraisal), (8) Fiyat (VM_TransactionPrice), (9) Istatistik (VM_SalesStatistic) ve (10) DegerlemeKaynak (VM_ValuationSource). LADM_VM'ye ait kavramsal model tasarımı řekil 1.11'de gũsterilmektedir.

1.5.6 Yapı Bilgi Modellemesi (BIM)

Yapı Bilgi Modellemesi (Building Information Modelling - BIM), bir yapı tesisinin tasarım, bakım, yıkım gibi tũm yařam dũngũsũ iin bulunması gereken temel verileri makine tarafından okunabilir bir biimde depolayan veri modelinin ũretimini, iletiřimini ve analizini ieren bir dizi sũre olarak tanımlanabilir (BuildingSMART, 2022). BIM yapılarla ilgili yapı malzemesi, inřaat sınıfı, kullanım fonksiyonu, enerji



Şekil 1.11 : LADM_VM'nin ana sınıfları (Çağdaş ve diğ., 2016; Kara ve diğ., 2018).

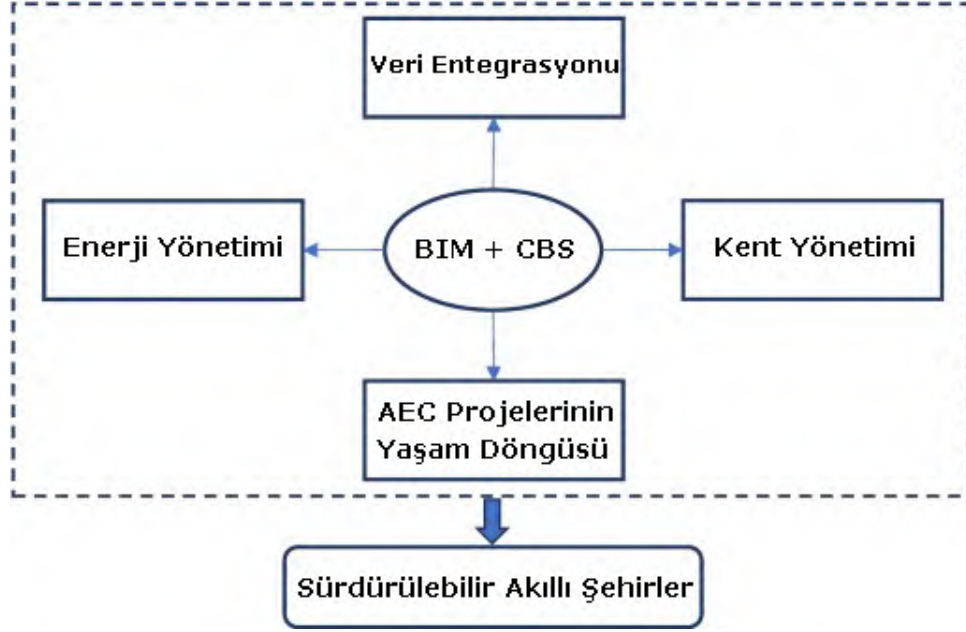
verimliliği, yüzölçümü gibi birçok geometrik ve fiziksel bilgi içermektedir. BIM'in olgunluk seviyeleri, kullanılan araçlara, standartlara ve formatlara bağlı olarak farklılık gösterir. Örneğin başlangıç olgunluk düzeyi, araç olarak kağıtlardan, biçim olarak çizgi veya yaylardan yararlanırken, ileri olgunluk düzeyi entegre web hizmetleri araçlarından ve birlikte çalışabilir veri biçimlerinden yararlanmaktadır (BSI, 2014). BIM, tesislerin yaşam döngüsünün farklı aşamalarında önemli faydalar sağlamaktadır. BIM ile inşaat aşamasından önce yapının performansının ve kalitesinin artırılmasına ve işbirliğinin geliştirilmesine katkıda bulunulabilmektedir. Tasarım açısından BIM daha doğru görselleştirmeyi, düşük seviyeli uyumsuzlukların otomatik olarak düzeltilmesini ve çeşitli disiplinlerin etkin işbirliğini sağlamakta, tasarımdaki hataların tespitini, ihmal edilmesini ve inşaat aşamasında tasarım ile uygulama arasındaki senkronizasyonu kolaylaştırmaktadır. BIM ayrıca inşaat sonrası bilgi entegrasyonu sağlayarak tesislerin yönetimine yardımcı olmaktadır (Sacks, Eastman, Lee, ve Teicholz, 2018). BIM'in farklı sektörlerde, özellikle de Mimarlık, Mühendislik İnşaat (Architecture, Engineering and Construction - AEC) endüstrisinde benimsenmesi, yukarıda belirtilen avantajlardan dolayı artmıştır (NBS, 2020). Örneğin BIM modelleri yapı ruhsatlandırma sürecinin dijitalleştirilmesi için birçok fayda sağlamaktadır

(Noardo, Malacarne, Mastrolembo Ventura, Tagliabue, Ciribini, Ellul, Guler, Harrie, Senger, Waha, ve Stoter, 2020b).

BIM için birlikte çalışabilirlik kavramı birçok farklı yazılım geliştiricisi bulunması sebebiyle standardizasyon açısından oldukça önemlidir. BIM geliştirme araçlarının modelleme yöntemlerindeki farklılıklar, veri değişimi için standardizasyon ihtiyacını doğurmaktadır. Bu bağlamda açık ve uluslararası bir standart olarak Endüstri Temel Sınıflamaları (Industry Foundation Classes - IFC) (ISO, 2020), semantikleri, öznitelikleri, ilişkileri, nesnelere, kavramları, süreçleri ve yapıların yaşam döngüsüne dahil olan tüm kişileri mantıksal olarak tanımlayarak standartlaştırılmış bir veri şeması sağlamaktadır (BuildingSMART, 2022). Özetle nesnelere ve nesnelere ilişkileri kavramsal olarak IFC'nin yapısını oluşturmaktadır. IFC'nin yanı sıra, BIM İşbirliği Formatı (BIM Collaboration Format - BCF), Model Görünüm Tanımları (Model View Definitions - MVDs) ve Bilgi Aktarma Kılavuzu (Information Delivery Manual - IDM), veri ve iş akışıyla ilgili bilgi aktarımını sağlamak için buildingSMART tarafından geliştirilen diğer standartlardır (ISO, 2016). Halihazırda ISO tarafından kabul edilen IFC4 ADD2 TC1 kararlı sürümü kullanılan IFC'nin 4.3 versiyonunun standart oylama süreci devam etmektedir. IFC şemasındaki çok sayıda varlık, mimari ve elektrik gibi farklı alanların özel ihtiyaçlarını karşılamaktadır.

BIM ve CBS entegrasyonu, bina ve çevresinin modellenmesi açısından birbirlerini tamamladıkları için son yıllarda dikkate değer bir ilgi görmüştür (Wang ve diğ., 2019). Bunun ilginin esas sebebi BIM'in binalar için zengin öznitelikler sağlamasının yanı sıra CBS'nin dış mekan için konumsal verileri sağlamasıdır. Ancak iki alanın varolan standartlarındaki modelleme farklılıkları ve coğrafi referanslama yaklaşımları gibi sebeplerden ötürü tam bir entegrasyon henüz sağlanamamıştır (Noardo, Harrie, Ogori, Biljecki, Ellul, Krijnen, Eriksson, Guler, Hintz, Jadidi, Pla, Sanchez, Soini, Stouffs, Tekavec, ve Stoter, 2020a). Bununla birlikte 3B kadastro, varlık yönetimi, kentsel çevre analizi gibi birçok uygulama alanı için BIM ve CBS entegrasyonunun büyük önem taşımaktadır. Bu nedenle literatürde BIM-CBS entegrasyonunu konu alan çok sayıda çalışma bulunmaktadır (Liu, Wang, Wright, Cheng, Li, ve Liu, 2017). Örneğin yapı ile ilgili veri kümesini depolayarak IFC'yi CityGML formatına dönüştürmeyi sağlayan bir CityGML Application Domain Extension (ADE) önerilmiştir (Biljecki, Lim, Crawford, Moraru, Tauscher, Konde, Adouane, Lawrence, Janssen, ve Stouffs,

2021). Ayrıca BIM ve CBS'den gelen verilerin entegrasyonunu kolaylaştırmak için LandInfra/InfraGML adlı bir standart geliştirilmiştir (OGC, 2016). Öte yandan OGC ve buildingSMART tarafından yayınlanan raporda IFC, CityGML ve LandInfra'nın entegrasyonunun yapı ve bulunduğu mekanın daha iyi yönetimi için büyük bir öneme sahip olduğu vurgulanmıştır (Gilbert, Rönsdorf, Plume, Simmons, Nisbet, Gruler, Kolbe, Berlo, ve Mercer, 2021). Şekil 1.12, BIM ve CBS alanlarına ait entegrasyonu ve bütünlük fonksiyonları göstermektedir.




Şekil 1.12 : BIM ve CBS entegrasyonu ile fonksiyonları (Wang ve diğ, 2019).

2. YAPILAN ÇALIŞMALAR

2.1 Çalışma Alanı

Tez kapsamında Birleşik Krallık'a bağlı İngiltere, Galler ve İskoçya ülkeleri, Türkiye'den ise İstanbul ve İzmir şehirleri iki farklı çalışma alanı olarak belirlenmiş, yöntemlerin bu iki farklı bölgede, farklı veri setleri kullanılarak uygulanması ve geliştirilen modelin genelleştirilebilirliğinin incelenmesi amaçlanmıştır (Şekil 2.1). İlk çalışma alanı açık verinin yaygın olduğu, taşınmazların gerçek değeri üzerinden yapılan alım-satım işlemlerine ait verilerin paylaşıldığı, Büyük Britanya adasını oluşturan İngiltere, Galler ve İskoçya ülkeleri seçilmiştir (Şekil 2.2). Kuzey Atlantik Okyanusu'nda bulunan Büyük Britanya'nın güneydoğusunda Fransa ve batısında İrlanda ülkeleri yer almaktadır. Toplamda 209.331 km^2 alana sahip olan Büyük Britanya, Avrupa'nın yüzölçümü bakımından en büyük adasıdır. Bu çalışma alanında Londra, Manchester, Liverpool, Birmingham, Newcastle gibi taşınmazlara yönelik yoğun işlem hacmine sahip birçok büyük şehir bulunmaktadır (Price Paid Data, 2021). İkinci çalışma alanı ise nüfusun ve taşınmazlara dayalı işlemlerin yoğun olduğu İstanbul ve İzmir illerimiz seçilmiştir. İstanbul Asya ve Avrupa kıtalarını birbirine bağlayan önemli jeopolitik konuma sahip eşsiz bir şehirdir. Büyük yatırım projeleri, imar uygulamaları, alım-satım gibi işlemlerin yoğun olduğu canlı bir taşınmaz piyasasına sahip olan İstanbul, 5.461 km^2 yüzölçümü üzerinde yaklaşık 16 milyon nüfusu barındıran kozmopolit yapısıyla öne çıkmaktadır (İstanbul Valiliği, 2020). Öte yandan İzmir ilimiz Ege Bölgesinde yer alan, 11.973 km^2 yüzölçümü ve 4.4 milyonu aşkın nüfusuyla ülkemizin önemli ekonomik, tarihi ve sosyo-kültürel şehirlerinden biridir. Yaklaşık 40 km sahil şeridinde sahip olan İzmir, Çeşme, Foça, Urla gibi önemli tatil bölgeleriyle göze çarpmaktadır (İzmir Valiliği, 2022). Kara ve deniz ulaşımında önemli bir konumda yer alan İzmir kentinde hem konut hem de ticari taşınmazlara yönelik büyük bir talep bulunmaktadır. Özellikle COVID-19 pandemi süreci ve sonrasında sahil bölgelerine gösterilen yoğun ilgi sonrası, Çeşme ilçesi birim metrekare bazında Türkiye'nin en pahalı ilçelerinden biri olmuştur (Endeksa, 2022).

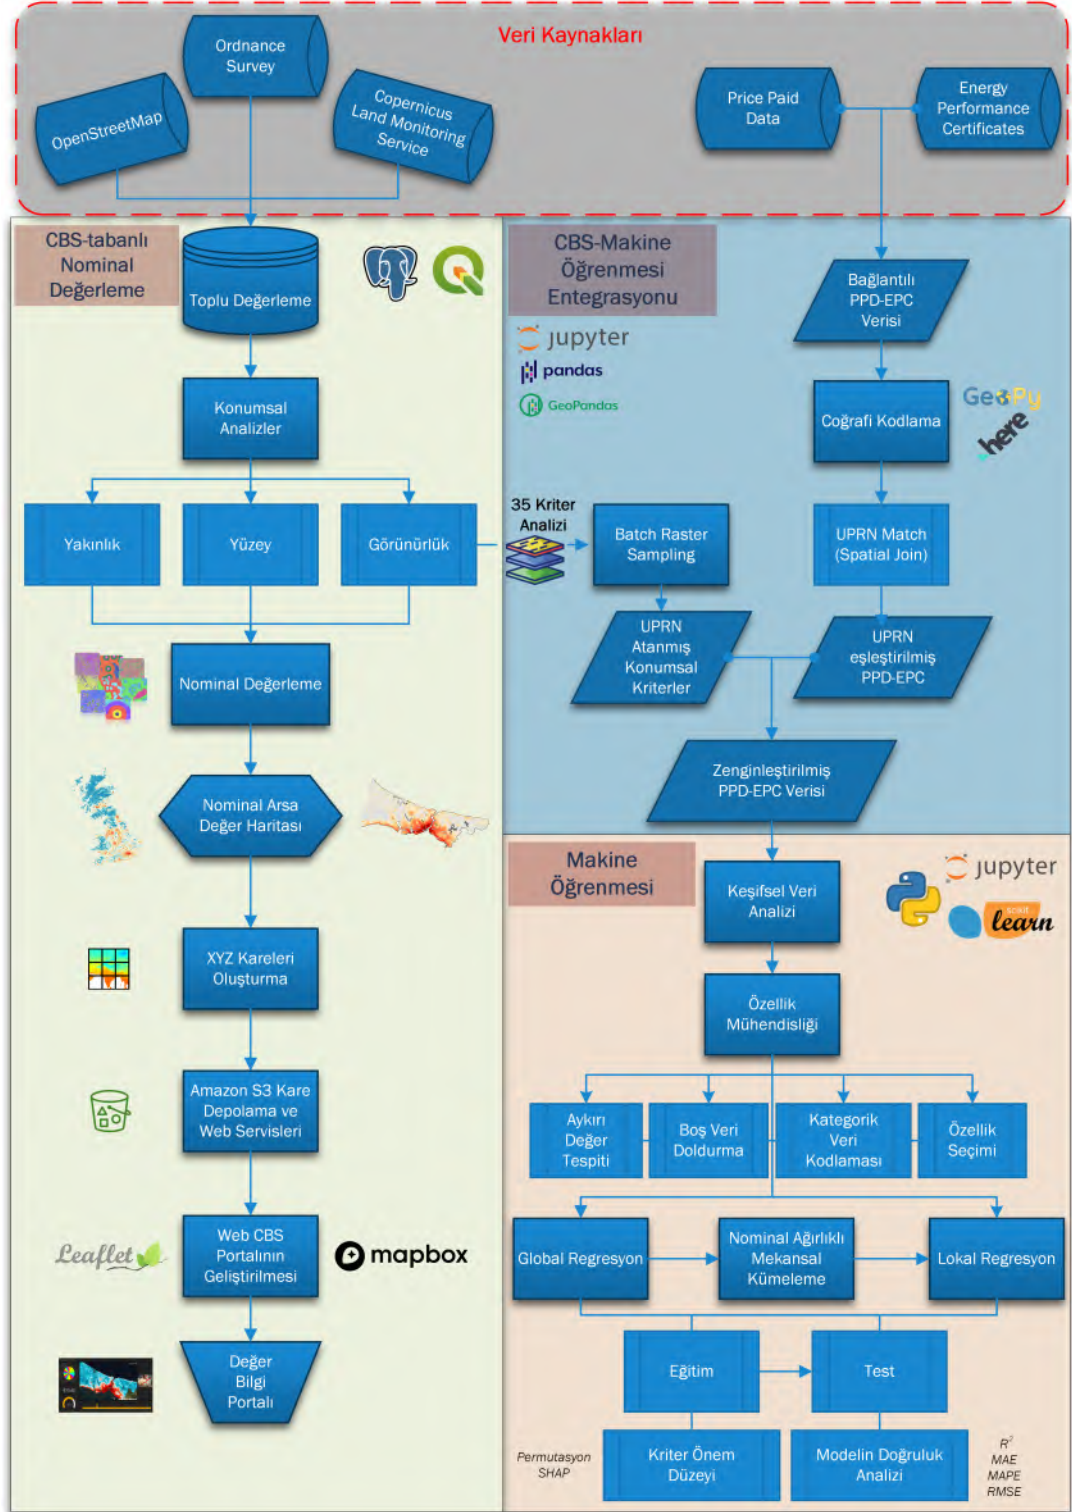


Şekil 2.1 : Çalışma alanları: Birleşik Krallık ve Türkiye.



Şekil 2.2 : İngiltere, Galler ve İskoçya ülkelerinden oluşan Büyük Britanya Adası.

Çalışmada ilk olarak Büyük Britanya bölgesi için CBS ve Makine Öğrenmesi yöntemleri kullanılarak hibrit bir değerlendirme modeli geliştirilmiş, sonrasında modelin genelleştirilebilirliğinin incelenmesi amacıyla aynı yöntem İstanbul ve İzmir şehirleri için uygulanmıştır (Şekil 2.3).



Şekil 2.3 : Çalışmada kullanılan yöntemlere ait iş akış şeması.

2.2 Kullanılan Veri Setleri

İngiltere, kamu verilerinin çoğunu son on yılda açık ve kolay erişilebilir hale getirmiştir. PPD, Kraliyet Arazi Kayıt Kurumu tarafından Mart 2012'den beri açık devlet verisini ve veri şeffaflığını desteklemek amacıyla aylık olarak yayınlanmaktadır (Price Paid Data, 2021). Veritabanında İngiltere ve Galler'de Ocak 1995'ten günümüze kadar yapılmış olan konut alım-satımlarına dair tüm kayıtlar bulunmaktadır. PPD, taşınmazlara dayalı yenilikçi ürünler ve hizmetler geliştirmek için proptech girişimleri ve start-uplar tarafından yaygın olarak kullanılmaktadır (Hogge, 2016).

PPD, toplu değerlendirme çalışmaları için fiyat kestiriminde kullanılan adres, satış tarihi, satış fiyatı, mülkiyet türü gibi birçok faydalı öznitelik içermektedir (Çizelge 2.1). PPD hem Comma Separated Values (CSV) formatında hem de SPARQL sorgularının çalıştırılmasına olanak sağlayan dört yıldızlı derecelendirmeye sahip bağlantılı veri formatında, Açık Devlet Lisansı v3.0 kapsamında paylaşılmaktadır.

Çizelge 2.1 : PPD verisine ait öznitelikler (Price Paid Data, 2021).

Öznitelik Adı	Açıklama
Transaction ID	Tescil aşamasında verilen tekil tanımlayıcı.
Price	Taşınmazın tapu senedinde belirtilen satış fiyatı.
Date of Transfer	Tapu senedindeki devir tarihi.
Property Type	Müstakil ev, apartman dairesi, villa vb. bina türleri.
Old/New	Y: Yeni bina, N: Eski bina.
Duration	F: Ev sahibi, L: Kiracı
Address	Posta kodu, Birincil Adres Nesnesi (PAON), İkincil Adres Nesnesi (SAON), Sokak, İlçe, Şehir, Bölge, Ülke.

Birleşik Krallık'taki yasal mevzuata göre, konut ve ticari taşınmazlar inşa edilirken, satılırken veya kiralanırken enerji kimlik belgesine sahip olmak zorundadırlar (UK Legislation, 2012). EPC veritabanı, karbon emisyonunu azaltıp enerji verimliliğini artırmak amacıyla 2007 yılında oluşturulmuştur. İngiltere ve Galler'deki konut ve ticari amaçlı kullanılan binaların enerji kimlik sertifikaları, Birleşik Krallık Bayındırlık, İskan ve Kamu Bakanlığı (Department for Levelling Up, Housing & Communities) tarafından 2008'den itibaren yılın her çeyrek sonunda yayınlanmaktadır. EPC veritabanında apartman dairesi, müstakil ev, ahşap bina, villa, ticari bina ve prefabrik ev gibi farklı bina türleri (Şekil 2.4) için fiziksel yapı özelliklerinden enerji kullanım maliyetlerine kadar birçok öznitelik bulunmaktadır (Çizelge 2.2). Veri seti,

geliştiriciler için hem CSV formatında hem de API servisi olarak paylaşılmaktadır (EPC, 2021).



Şekil 2.4 : Birleşik Krallık'ta bulunan binalara ait farklı mimari türler.

Ülkemizde konut vasıflı taşınmazların tekil satış değerleri vatandaşlar ile paylaşılmamakta, gerçekleşen tüm satışlar için Merkez Bankası tarafından aylık konut fiyat endeksi yayınlanmaktadır. Öte yandan alım-satım işlemlerinde tarafların taşınmaz değerini olduğundan daha düşük göstermesi sonucunda elde edilen veritabanı sağlıklı bir şekilde oluşmamaktadır. Bu sebeple ülkemiz için değerlendirme verisi olarak bir emlak listeleme şirketinin İstanbul ve İzmir şehirlerindeki 64.573 konut vasıflı taşınmaza ait 2019-2020 yılları arasındaki satış ilanları kullanılmıştır (Zingat, 2019). Veride taşınmazlara ait adres, fiyat, ilan tarihi, yüzölçümü, bina yaşı, emlak tipi (Daire, Villa, Yazlık vb.), bulunduğu kat, banyo sayısı, manzara durumu gibi bir çok fiziksel ve konumsal öznitelik mevcuttur (Çizelge 2.3).

Taşınmaz değerlerine ait veriler dışında konumsal analizlerde kullanılan ve değeri etkileyen faktörlerin önemli bir kısmını oluşturan coğrafi veriler açık veri kaynaklarından temin edilmiştir. Birleşik Krallık çalışma bölgesi için yeşil alanlar (Tree Density Cover) ve sayısal yükseklik modeli (European Digital Elevation Model - EU-DEM v1.1) verisi Avrupa Çevre Ajansı'nın Copernicus Land Monitoring Service

Çizelge 2.2 : EPC verisine ait öznitelikler (EPC, 2021).

Öznitelik Adı	Açıklama
LMK Key	Benzersiz kayıt numarası.
Building Reference Number	Taşınmazı tanımlayan tekil referans numarası.
Current Energy Efficiency	Enerji maliyeti, yani ısıtma, su ısıtma ve aydınlatma için gerekli enerjinin [kWh/yıl olarak] yakıt maliyetleriyle çarpımı (£/m ² /yıl).
Property Type	Apartman dairesi, villa vb. bina türleri.
Built Form	Ayrık, Bitişik, Blok yapı nizamı.
Environment Impact Current	Karbon emisyonuna bağlı çevresel etki oranıdır. Derecelendirme puanı ne kadar yüksek olursa, CO ₂ emisyonu o kadar düşük olur (ton/yıl).
Energy Consumption Current	12 aylık dönemde taşınmazın tahmini toplam enerji tüketimi (kWh/m ²).
CO ₂ Emissions Current	Yıllık karbon emisyonu (ton/yıl)
Lighting Cost Current	Yıllık tahmini aydınlatma enerjisi maliyeti (GBP).
Heating Cost Current	Yıllık tahmini ısıtma enerjisi maliyeti (GBP).
Hot Water Cost Current	Yıllık tahmini sıcak su enerjisi maliyeti (GBP).
Total Floor Area	Toplam faydalı kullanım zemin alanı, dış duvarların iç yüzüne göre ölçülen tüm kapalı alanların toplamıdır (m ²).
Floor Level	Binanın en alt seviyesine göre kat seviyesi (zemin kat için 0). Bodrum varsa bodrum katı 0, diğer katlar 1'den başlar.
Extension Count	Binada bulunan eklentilerin toplam sayısı.
Number Habitable Rooms	Salon, oturma odası, yemek odası, yatak odası, çalışma odası vb.
Address	Posta kodu, Adres 1 (SAON), Adres 2 (PAON), Adres 3 (Sokak/Cadde)

hizmeti üzerinden; önemli yerler (OS OpenMap – Local data), yollar (Open Roads), göller (Open Rivers), idari sınırlar ve kıyı çizgisi (Administrative and Watermark Boundary-Line) verileri Birleşik Krallık Harita Kurumu Ordnance Survey'den; raylı sistemler istasyonları, araç park yerleri ve alışveriş merkezleri verileri ise OSM üzerinden temin edilmiştir. Ülkemiz için ise coğrafi veriler İstanbul Büyükşehir Belediyesi ve İzmir Büyükşehir Belediyesi açık veri portalları ile OSM üzerinden elde edilmiştir.

2.3 Taşınmaz Değerlerine Etki Eden Faktörlerin Belirlenmesi

Taşınmaz değerini etkileyen kriterlerin belirlenmesi, değerlendirme sürecinin ilk aşamalarından biridir. Değeri meydana getiren birçok faktörün bulunması sebebiyle

Çizelge 2.3 : Emlak listeleme şirketine ait satış ilanları verisi.

Öznitelik Adı	Açıklama
İlan No	-
Adres	İl, İlçe, Mahalle.
Satış Fiyatı	Türk Lirası cinsinden satış fiyatı.
Oda Sayısı	-
Yüzölçümü	Brüt ve Net m^2 .
Emlak Tipi	Daire, Müstakil Ev, Rezidans, Villa, Köşk/Konak/Yalı, Yalı Dairesi, Yazlık, Çiftlik Evi, Prefabrik Ev.
Bina Yaşı	-
Bulunduğu Kat	-
Bina Kat Sayısı	-
Isıtma Tipi	Kombi (Doğalgaz), Soba (Doğalgaz), Kalorifer (Doğalgaz), Klima, Yerden Isıtma, Merkezi Sistem (Isı Payı Ölçer).
Banyo Sayısı	-
Manzara	Boğaz, Deniz, Göl, Nehir, Havuz, Vadi, Dağ, Cadde, Şehir, Park.
Otopark	Var/Yok.
İnterkom	Var/Yok.
Deprem Risk Durumu	Var/Yok.
Asansör	Var/Yok.
Çocuk Oyun Alanı	Var/Yok.
Giyinme Odası	Var/Yok.
Ebeveyn Banyosu	Var/Yok.

bu kriterleri belirli bir sayı ile sınırlamak oldukça zordur. Öte yandan değerlendirme kriterlerinin önemi kişilerin sosyal, kültürel ve ekonomik özelliklerine göre değişebilmektedir. Objektif ve doğru bir değerlendirme çalışmasının yapılabilmesi için değeri etkileyen kriterlerin geniş bir kapsamda ele alınması ve analiz edilmesi gerekmektedir. Değerleme kriterleri genel olarak içsel ve dışsal faktörler olarak iki gruba ayrılmaktadır. Dış faktörler taşınmazın konumsal ve çevresel özellikleri ile ilgiliyken, iç faktörler ise taşınmazın fiziksel özellikleri ile ilgilidir (Şekil 2.5).

Değeri etkileyen faktörler literatürde çeşitli sınıflar altında gruplandırılmaktadır. Genel olarak bu faktörleri çevresel, fiziksel, yasal ve sosyo-ekonomik kriterler şeklinde ele almak mümkündür (Ünel ve Yalpir, 2019).

Dışsal değerlendirme faktörleri taşınmazın bulunduğu çevre ile ilgilidir. Konum, bir taşınmazın arazi değerini belirleyen en önemli kriterlerden biridir. Taşınmaz değerine etki eden çevresel faktörler önemli yerlere yakınlık, topografya, manzara, trafik



Şekil 2.5 : Taşınmaz değerini etkileyen faktörlerin sınıflandırması.

yoğunluğu, gürültü, hava kalitesi, güneşlenme süresi, jeolojik yapı ve belediye altyapı hizmetleri olarak tanımlanabilir.

Önemli yerlere yakınlık, taşınmazın değerini önemli ölçüde artıran bir kriterdir. Yakınlık kriterlerini analiz etmek ve değerlendirmek için Ağ Tabanlı Yakınlık, Öklid Mesafesi gibi birçok yakınlık analizi yöntemi bulunmaktadır. Öte yandan şahsi araç, toplu taşıma ve yürüme gibi ulaşım modlarının tercihi de yakınlık kriterininin değerlendirilmesini etkilemektedir.

Manzara ve topografya, taşınmaz değerini etkileyen diğer önemli faktörlerdendir. Orman, göl veya deniz manzarasının bulunması taşınmaza cazibe katan, değerini artıran unsulardandır. Taşınmazın bulunduğu bölgenin eğimi de değerlendirme için önemli bir kriterdir. Düz bir arazide yer alan taşınmazlar eğimli arazilerdekilere göre daha çok tercih edilmekte ve daha yüksek değere sahip olmaktadır. Ayrıca güneye cephesine

bakan taşınmazlar güneş ışığından daha fazla yararlandıkları için daha fazla tercih edilmektedirler.

Bakı, bina kat seviyesi, dış engeller (binalar, ağaçlar vb.) binaların iç mekan gün ışığını etkileyen faktörlerden bazılarıdır. Örneğin iç mekan gün ışığı bağımsız bölümler için BIM ile simüle edilerek değerlendirilebilir.

Taşınmaz değerini etkileyen bir diğer kriter trafik yoğunluğudur. Sürekli trafik sıkışıklığı olan yollar üzerinden ulaşımı sağlanan taşınmazlar erişim sıkıntısı sebebiyle daha az tercih edilmektedir. Ayrıca trafik sıkışıklığı bölgede gürültüye ve kötü hava kalitesine neden olmaktadır. Bu faktörler, her bir bağımsız bölüm birimi için 3 boyutlu konumsal analizler kullanılarak incelenebilmektedir.

Jeolojik yapı ve belediye altyapı hizmetleri değeri etkileyen diğer çevresel faktörlerdir. Kaya, taş, çakıl, kum, kil, alüvyon gibi zemin yapıları farklı özelliklere sahiptirler. Zemin yapıları sağlam olan bölgelerde yer alan binalar depreme dayanıklı olmaları nedeniyle daha çok tercih edilmektedirler. Öte yandan su, kanalizasyon, elektrik, telekomünikasyon ve gaz gibi belediye altyapı hizmetlerinin varlığı, taşınmaz değerleri üzerinde önemli bir etkiye sahiptir.

Taşınmaz değerini etkileyen fiziksel kriterler arazi ve binalar için farklı yaklaşımlar içermektedir. Parsel yüzölçümü, parsel geometrisi (şekil ve kırık köşe noktası sayısı), parsel konumu (köşebaşı veya ara) ve parsel cephesi arazi parsellerinin yapısal özellikleridir. Arazi tipi (çorak arazi, sulak arazi), arazi verim sınıfı (iyi, orta, zayıf veya verimsiz), arazi kullanım durumu (kuru veya sulu tarım) ve arazi verimlilik değeri, tarım arazilerinin değerini etkileyen fiziksel özelliklerdendir. Öte yandan, inşaat alanı, kat sayısı, inşaat türü (çelik karkas, betonarme karkas, yığma, kerpiç, ahşap, taş duvarlı bina), yapım tarihi, malzeme sınıfı (birinci sınıf, ikinci sınıf vb.), oda sayısı, banyo sayısı, yatak odası sayısı, balkon sayısı, ısıtma, soğutma sistemi, enerji verimlilik düzeyi ve ortak hizmetler (asansör, bahçe, havuz, otopark, spor salonu) binaların değerini etkileyen yapısal özelliklerdir. Binaların fiziksel faktörleri maliyet analizine tabi tutularak yapı yaklaşık maliyeti hesaplanmasında kullanılabilir.

Yasal faktörlerin taşınmazlarda Sahiplik, Sorumluluk ve Sınırlamalar (3S) kavramı ile ilgili olması sebebiyle taşınmaz değeri üzerinde büyük önemi bulunmaktadır. Bina kullanım türü (konut, ticari vb.), irtifak hakkı (intifa hakkı, oturma hakkı, üst hakkı,

kaynak hakkı veya geçiş hakkı), ipotek, kira sözleşmesi şerhi, bina kapsama oranı, Taban Alanı Kat Sayısı (TAKS) Kat Alanı Kat Sayısı (KAKS), en yüksek bina yüksekliği, bina inşa düzeni (bitişik, ayrı veya blok), çekme mesafeleri ve maksimum kat sayısı taşınmaz değerini etkileyen yasal faktörlerdir.

Sosyo-ekonomik faktörler ise bölgedeki yaşam kalitesini ortaya koyan gelişmişlik düzeyi göstergelerini temsil etmektedir. Sosyo-kültürel gelişmişlik düzeyi nüfus yoğunluğu, bina yoğunluğu, bölgesel eğitim düzeyi, bölgesel gelir düzeyi, suç oranları, amortisman süreleri, vergi değeri ve bölgesel gelir düzeyi taşınmaz değerini etkileyen sosyo-ekonomik faktörlerdir.

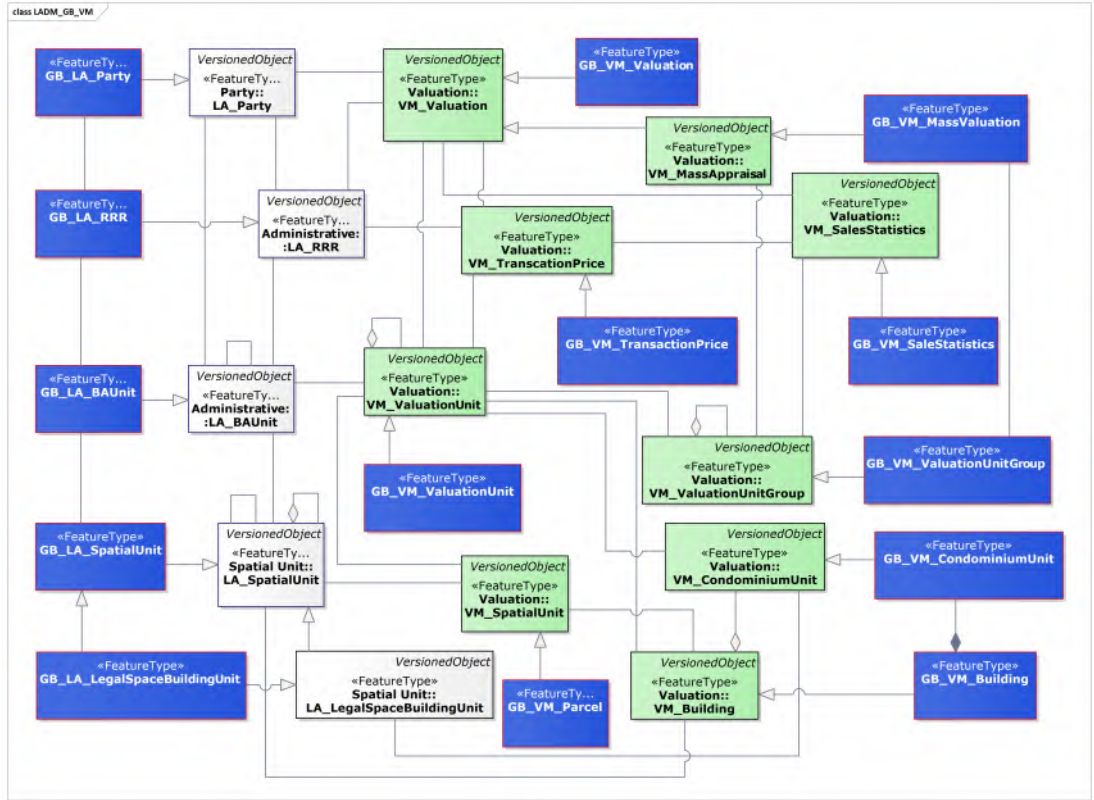
2.4 Kavramsal Model Tasarımı

LADM dünya genelinde birçok ülke tarafından Arazi İdaresi Sistemi (AİS)'nin etkin olarak yürütülmesi amacıyla kavramsal model olarak benimsenmiştir. Kavramsal modelden fiziksel modele geçişin sağlanabilmesi ve tasarlanan modelin pratikte sorunsuz ve verimli bir şekilde kullanılabilmesi için ülkelerin mevcut durumlarının tespit edilmesi ve ihtiyaçlarına yönelik planlamaların yapılması gerekmektedir. Bu amaçla LADM ülke profilleri oluşturulmakta, Kişi, 3S, TescilNesne ve KonumsalBirim arasındaki ilişkiler ülkelerin özelliklerine göre kurgulanmaktadır.

Bir ülke profili, 3S ve AİS arasındaki ilişkiyi eksiksiz bir biçimde tanımlamalıdır (Kalogianni, Janečka, Kalantari, Dimopoulou, Bydłosz, Radulović, Vučić, Sladić, Govedarica, Lemmen, ve van Oosterom, 2021). LADM ülke profili mevcut durumu ifade eden ya da olması gerekeni öneren bir model olabilmektedir. LADM profili ülkenin tüm arazi idaresi sistemini modelleyecek kapsamda olabileceği gibi sadece özel bir alanın uygulaması için de önerilebilir. Örneğin; deniz kadastro, vergi amaçlı taşınmaz değerlendirme gibi modellerin oluşturulması amaçlarına özgü bir ülke profili tasarlanabilir. (Kalogianni ve diğ, 2021)'e göre LADM ülke profili oluşturmak için aşağıdaki temel aşamaların izlenmesi gereklidir:

- 1- Ülke profilinin amaç ve kapsamının tanımlanması,
- 2- Ülkeler için arazi idaresi ihtiyaçlarının ve mevcut AİS analizi,
- 3- Kavramsal modelin oluşturulması,
- 4- Önerilen modelin değerlendirilmesi ve test edilmesi.

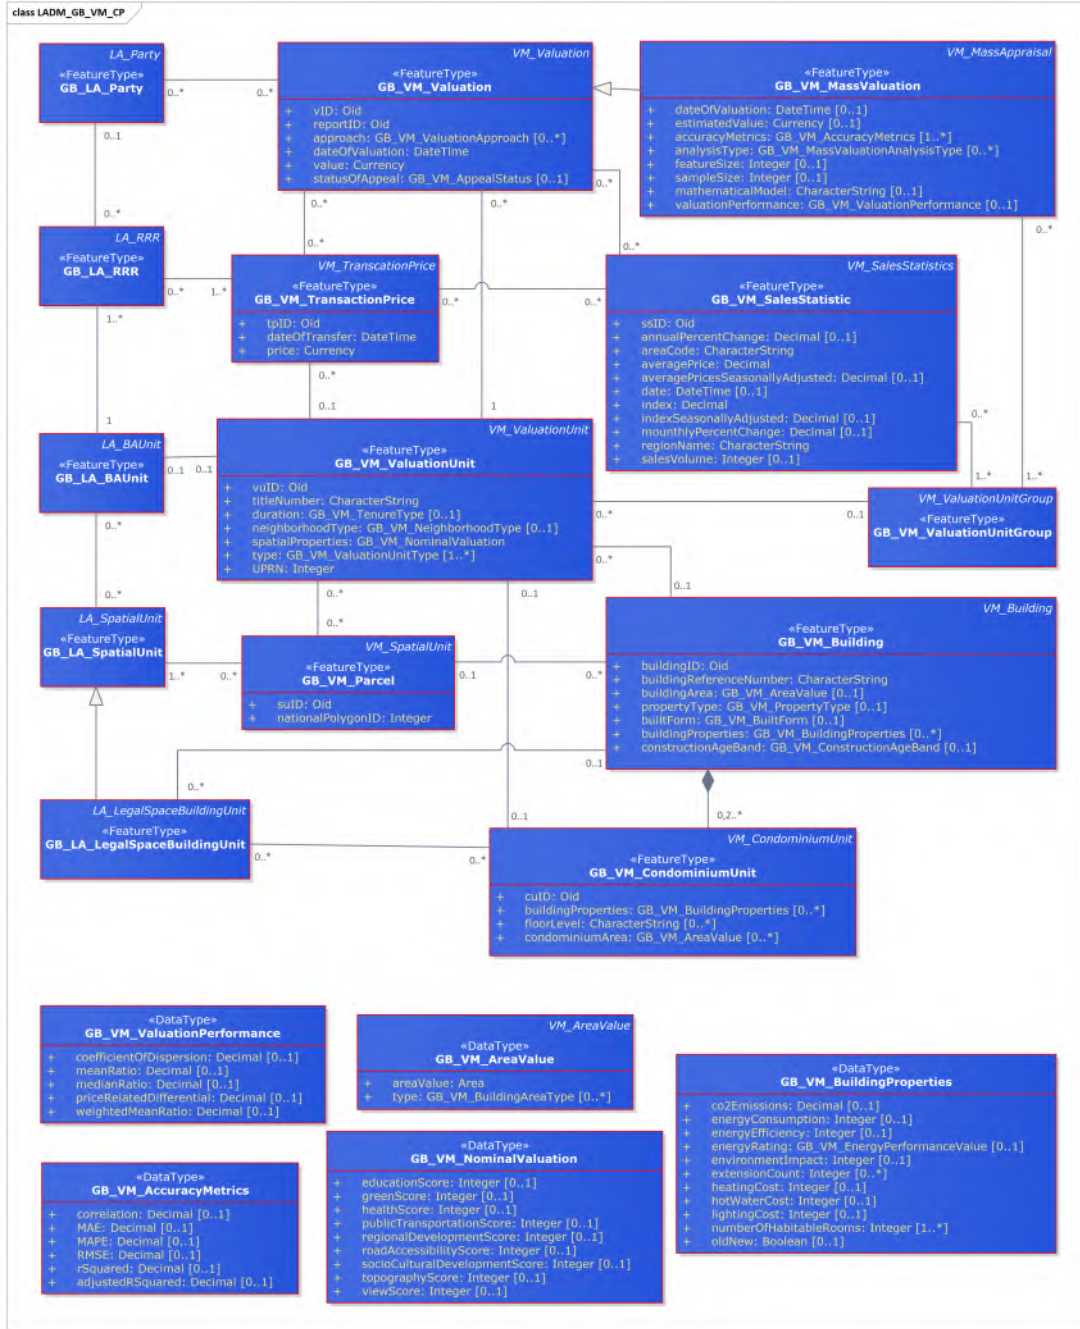
ISO LADM çalışma gurubunun paylaştığı verilere göre mevcut durumda birçok ülkeye ait ülke profili tasarlanmıştır. Bu ülkeler arasında Birleşik Krallık'a bağlı İngiltere, Galler, İskoçya ve Kuzey İrlanda bulunmamaktadır. Çalışma kapsamında bu ülkelerin mevcut durumunu ortaya koyan, toplu değerlendirme çalışmalarına altlık sunacak ülke profilinin UML şeması Enterprise Architect yazılımı kullanılarak modellenmiştir. Birleşik Krallık'ta yer alan ülkelere özgü LADM'nin temel sınıfları ülke profili kapsamında oluşturulduktan sonra Değer Bilgi Modeli ile ilişkileri tanımlanmıştır (Şekil 2.6).



Şekil 2.6 : LADM_VM ve Büyük Britanya Ülke Profili İlişkileri.

Birleşik Krallık ülkeleri arazi kayıt sistemi olarak Torrens sisteminin bir çeşidi olan İngiliz sistemini kullanmaktadır. Senet sistemine dayalı bu modelde parseller bir sözleşmede sözel olarak tariflenerek ifade edilmekte, yaklaşık geometrileri ise planlar üzerinde gösterilmektedir. Arazi yönetimi kapsamında Birleşik Krallık'ta Kraliyet Arazi Kayıt Kurumu, Bayındırlık, İskan ve Kamu Bakanlığı, Ordnance Survey, VOA gibi çeşitli kurumların önemli roller üstlendiği görülmektedir. Örneğin İngiltere ve Galler ülkelerinde paylaşılan PPD, HPI, EPC verileri taşınmazlara ait satış fiyatı, yüzölçümü, enerji sınıfı, fiyat endeksi gibi önemli öznitelikler içermektedir. İlgili kurumların görevleri ve ürettikleri veriler baz alınarak Birleşik Krallık'ta bulunan beş

ülkeye yönelik toplu değerlendirme amaçlı Büyük Britanya LADM Değer Bilgi Modeli (LADM_GB_VM) geliştirilmiştir (Şekil 2.7).



Şekil 2.7 : Büyük Britanya LADM Değer Bilgi Modeline ait sınıflar ve ilişkileri.

Oluşturulan kavramsal modelde GB_VM_Valuation sınıfı değerlendirme numarası, değerlendirme yöntemi, değerlendirme tarihi, rapor numarası, rapor durumu, taşınmaz değeri gibi öznitelikler içermektedir. GB_VM_MassValuation sınıfında toplu değerlendirme çalışmasına ait analiz türü, analiz tarihi, kriter sayısı, örneklem sayısı, matematik model, tahmin değeri, değerlendirme performansı öznitelikleri yer almaktadır. GB_VM_TransactionPrice sınıfında gerçekleşmiş satışlara satış numarası, tarih ve

satış değeri öznitelikler bulunmaktadır. GB_VM_SalesStatistics sınıfı ise geçmiş yıllarda gerçekleşen tüm satışlara ait veriler kullanılarak hesaplanan fiyat endeksine ait satış istatistik numarası, tarih, bölge kodu, bölge adı, aylık yüzde değişim, yıllık yüzde değişim, ortalama fiyat, mevsimsel olarak düzeltilmiş ortalama fiyat, indeks, mevsimsel olarak düzeltilmiş indeks, satış hacmi gibi önemli istatistik bilgileri içermektedir.

Değerleme birimi, parsel, bina ve bağımsız bölüm sınıflarında taşınmazın konumsal geometrisi hem arsa düzeyinde hem de bina/bağımsız bölüm düzeyinde tanımlanmıştır. Bu sınıflarda parsel ve binalara özgü tanımlayıcı öznitelikler yer almaktadır. GB_VM_ValuationUnit sınıfında değerlendirme birimi numarası, Benzersiz Taşınmaz Referans Numarası (Unique Property Reference Number - UPRN), değerlendirme birimi türü, bulunduğu çevrenin özelliği, sahiplik türü ve tapu numarası öznitelikleri bulunmaktadır. GB_VM_Parcel sınıfında konumsal birim numarası ile ulusal poligon numarası öznitelikleri vardır. GB_VM_Building sınıfı bina numarası, bina referans numarası, bina yüzölçümü, taşınmaz tipi, inşaat türü, bina özellikleri ve inşaat yılı gibi faydalı öznitelikler yer almaktadır. Bina sınıfına bağlı olan GB_VM_CondominiumUnit sınıfı ise bağımsız bölüm numarası, bina özellikleri, kat seviyesi ve bağımsız bölüm yüzölçümü gibi sınıfları içermektedir. Modelde yer alan tüm kod listeleri Şekil 2.8’de gösterilmektedir.



Şekil 2.8 : LADM_GB_VM sınıflarına ait kod listeleri.

LADM ülke profili oluşturulduktan sonra kavramsal modelin başarısının test edilip değerlendirilmesi gerekmektedir. Bu kapsamda modelin bir örnek düzey diyagramı (instance level diagram) oluşturulmuş, İngiltere ve Galler ülkelerine ait PPD-EPC verileri ile temsili gerçekleştirilmiştir (Şekil 2.9).



Şekil 2.9 : İngiltere ve Galler ülkelerinin değerlendirme verileri ile oluşturulan örnek düzey diyagramı.

Öte yandan kavramsal model tasarımı kapsamında üç boyutlu taşınmaz değerlendirme amaçlı LADM uyumlu BIM/IFC şema modeli oluşturulmuştur. Bu kapsamda taşınmaz değerlendirme ile ilgili sınıflar ve özellikler LADM_VM kavramsal modeli kullanılarak tanımlanmıştır. IFC şemasında yasal hakları fiziksel kaşılıklarıyla modellemek için çeşitli varlıklar kullanılabilir. Bu amaçla en çok kullanılan varlık türleri IfcZone ve IfcSpace'dir. IFC şemasındaki bu varlıklar ile taşınmaz değerlendirme bağlamında kat mülkiyeti gibi belirli mülkiyet türleri modellenerek kriterlerin nominal değerleri elde edilebilir.

IFC taşınmaz değerlendirme gibi çeşitli alan bazlı uygulamaların özel gereksinimlerini karşılamak için gereken sayıda özellik setinin (property set) farklı varlıklara eklenmesine olanak tanır. Bu kapsamda 3B taşınmaz değerlendirme yaklaşımı için yeni özellik kümeleri ve öznitelikleri oluşturulmuş, mevcut IFC versiyonuna göre sınıflar ve veri türleri belirlenmiştir. Çizelge 2.4'te kavramsal değerlendirme modellerini IFC şemasına bağlamak için kullanılacak özellik setleri, özellik adları, özellik türleri ve veri türleri gösterilmektedir. Bu süreçte BIM/IFC ile taşınmaz değerlemesi için farklı mantıksal uzayların modellenmesi gerekmektedir. Örneğin bağımsız bölümlerin değerlerinin hesaplanması için kat mülkiyetinde tanımlanmış bina, eklenti, ortak alanlar gibi bölümlerin de hesaba katılması gerekmektedir. Böylece taşınmazların nominal değerlerinin elde edilmesini sağlayan Pset_PV_CondominiumUnit ve özellikleri (fiziksel faktörler gibi) IfcSpace varlığına eklenmiştir. IfcZone varlığı birden çok IfcSpace varlık örneğinden oluşmaktadır. Değerleme birimleri IfcSpace kullanılarak temsil edilen birkaç ek içerebileceğinden, IfcZone varlığına Pset_PV_ValuationUnit eklenmiştir. Taşınmaz değerlendirme sürecinin modellenmesi sırasında uygun veri tiplerinin seçilmesine de önemli bir husustur. IFC şeması taşınmaz değerlerinin doğru şekilde temsili için gerekli birçok veri türünü içermektedir.

Örneğin IfcBoolean, binada balkon olup olmadığını gösteren değeri saklamak için kullanılabilir. IfcInteger, bağımsız bölümün bulunduğu kat gibi her zaman bir tamsayı olması gereken özellik değerlerini saklamak için kullanılabilir. IfcIdentifier ise ID gibi verilere ait tekil tanımlayıcıların saklanması için kullanılabilir.

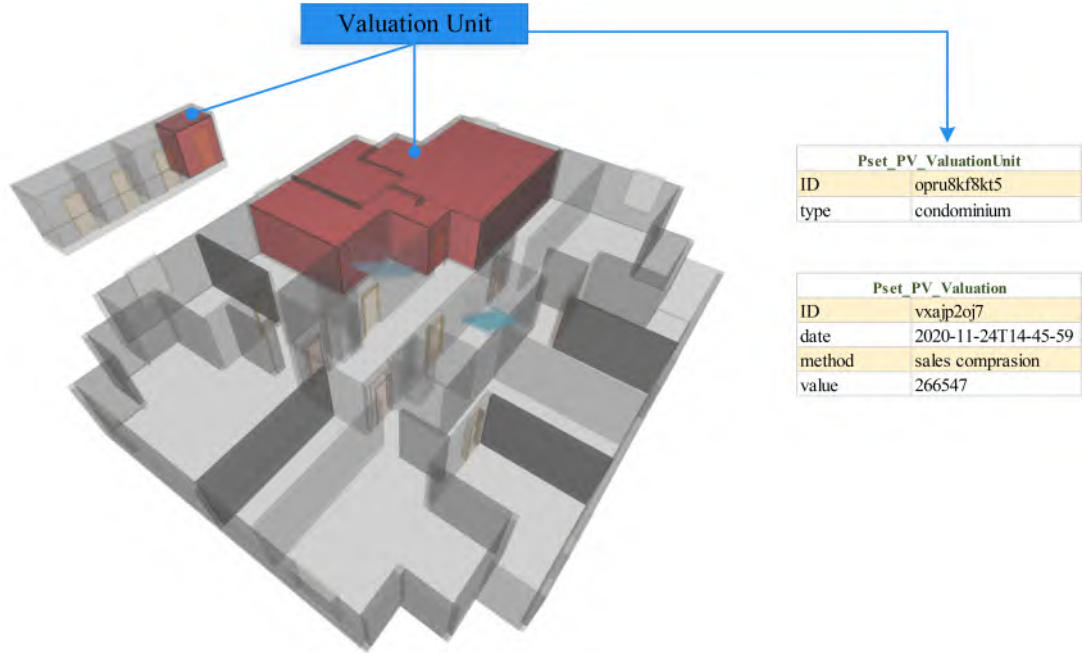
Oluşturulan kavramsal modelin gösterimi için IFC veri modelinden taşınmaz değerlendirme ile ilgili verilerin elde edilmesini sağlayan temel bir bina katı modellenmiştir. Modelin BIM geliştirme aracında oluşturulması sonrasında boşluklar ve bölgeler tanımlanmıştır. Daha sonra modele yeni özellik setleri eklenerek boşlukların ve bölgelerin öznitelikleri doldurulmuştur. Son olarak kata ait IFC verileri, BIM geliştirme aracı yardımıyla dışa aktarılmıştır. Böylece IFC şeması kullanılarak modellenen ve BIM görüntüleyicide görselleştirilen Pset_PV_CondominiumUnit için özellik değerleriyle birlikte bir bina birimi elde edilmiş, bağımsız bölümü temsil eden Pset_PV_ValuationUnit ve Pset_PV_Valuation ile değerlendirme birimi örneği ve öznitelikleri gösterilmiştir (Şekil 2.10).

Çizelge 2.4 : IFC tabanlı 3B taşınmaz değerlendirme modeli.

Özellik Seti	Özellik Adı	Veri Türü
Pset_PV_Owner	name	IfcLable
	surname	IfcLable
	fatherName	IfcLable
	pID	IfcIdentifier
	nationality	IfcLable
	ownerType	IfcLable
Pset_PV_RRR	share	IfcReal
	registrationDate	IfcDateTime
	ID	IfcIdentifier
	easement	IfcLable
	mortgage	IfcBoolean
	rentalAnnotation	IfcBoolean
	Pset_PV_RegistrationUnit	ID
Pset_PV_Parcel	type	IfcLable
	propertyNumber	IfcInteger
Pset_PV_Building	parcelNumber	IfcInteger
	area	IfcAreaMeasure
	ID	IfcIdentifier
	parcelUseType	IfcLable
	parcelGeometry	IfcBoolean
	parcelFrontage	IfcReal
	parcelLocation	IfcLable
	buildingID	IfcInteger
	ID	IfcIdentifier
	builtDate	IfcDateTime
Pset_PV_CondominiumUnit	name	IfcLable
	footprint	IfcReal
	noOfFloors	IfcInteger
	constructionType	IfcLable
	qualityType	IfcLable
	constructionDate	IfcDateTime
	heatingCooling	IfcBoolean
	floorNumber	IfcInteger
	area	IfcAreaMeasure
	volume	IfcVolumeMeasure
	useType	IfcLable
condominiumNumber	IfcInteger	
landShare	IfcLable	
noOfRooms	IfcInteger	
balcony	IfcBoolean	
energyEfficiency	IfcLable	
indoorSoundLevel	IfcLable	

Çizelge 2.4 (devam): IFC tabanlı 3B taşınmaz değerlendirme modeli.

Özellik Seti	Özellik Adı	Veri Türü
Pset_PV_CondominiumUnit	indoorDaylight	IfcRatioMeasure
	ID	IfcIdentifier
Pset_PV_CommonFacility	condominiumID	IfcInteger
	type	IfcLable
Pset_PV_Annex	tngisID	IfcIdentifier
	type	IfcLable
Pset_PV_Valuation	sID	IfcIdentifier
	ID	IfcIdentifier
	date	IfcDateTime
	method	IfcLable
Pset_PV_ValuationUnit	value	IfcReal
	ID	IfcIdentifier
	type	IfcLable
Pset_PV_ValuationUnitGroup	ID	IfcIdentifier
	type	IfcLable
Pset_PV_MassValuation	date	IfcDateTime
	algorithm	IfcLable
	value	IfcReal



Şekil 2.10 : 3B taşınmaz değerlendirme amaçlı oluşturulan IFC tabanlı değerlendirme birimi modeli.

2.5 Veri Tabanının Oluşturulması

Bir projede oluşturulacak yapı hakkında genel bir bakış açısı sunan veri tabanı, kullanılacak verilerin etkin bir şekilde depolanmasını ve yönetilmesini sağlamaktadır.

Kavramsal modelden fiziksel modele geçiş, veritabanı oluşturma aşaması ile birlikte gerçekleştirilmektedir. Bu kapsamda Birleşik Krallık LADM_VM ile oluşturulan sınıflara ait verilerin depolanacağı bir alan oluşturmak için Amazon RDS üzerinde bulut tabanlı bir PostgreSQL veritabanı oluşturulmuştur. RDS veri tabanı için 2 sanal işlemci (vCPU) ve 1 gibibytes (GiB) belleğe sahip db.t4g.micro modeli seçilmiştir. Amazon RDS, veri tabanının kurulumu, yönetimi, kontrolü ve ölçeklendirilmesi işlemlerinin kolaylıkla yürütülmesi amacıyla tasarlanmıştır. Ayrıca bu servis ile veritabanı üzerinde otomatik eklenti, yedekleme ve aşamalı kurtarma olanakları sunulmaktadır (Hubbard, 2019). Kullanıcıların ihtiyaçlarına göre, ölçeklenebilir, yeniden boyutlandırılabilir veritabanı yönetimi için sistemi yavaşlatan giriş-çıkış darboğazı ve performans düşüklüğü problemlerinin çözümü için optimizasyon imkanı sağlamaktadır.

Veri tabanının kurulmasından sonra kavramsal modeldeki sınıfların veritabanı tablolarına aktarılması amacıyla Enterprise Architect üzerinden veri tabanı bağlantısı gerçekleştirilmiş, mevcut proje veri tabanına transfer edilmiştir. Değerleme verilerinin yanı sıra, coğrafi verilerin de etkin bir şekilde depolanması ve yönetilmesi için PostgreSQL veritabanında PostGIS eklentisi kurulmuş, coğrafi verilere ait tablolar oluşturulmuştur. Son olarak FME yazılımı ile ETL araçları kullanılarak çeşitli kaynaklardan gelen farklı yapıdaki veriler modele uygun standart format ile eşleştirilerek veri tabanı içerisinde elde edilmiştir.

2.6 Veri Ön İşleme ve Dönüştürme

PPD ve EPC verisetleri, OS AddressBase Premium verilerinden alınan tam adres bilgileri dahil olmak üzere çeşitli öznitelikler içermektedir. Chi ve diğ (2021b) 2011 - 2019 yıllarını kapsayan verileri filtreleyerek iki ayrı açık veri setini adres eşleştirmesiyle bütünleştirmişlerdir. 251 eşleştirme kuralının uygulandığı çalışmada İngiltere ve Galler'de bulunan 5.732.838 konutun adres eşleştirmesinde %90'ın üzerinde başarı sağlandığı belirtilmiştir. Oluşturulan yeni veri seti Birleşik Krallık Açık Veri Deposu (UK Data Service ReShare) üzerinden erişime sunulmuştur (Chi, Dennett, Oléron-Evans, ve Morphet, 2021a).

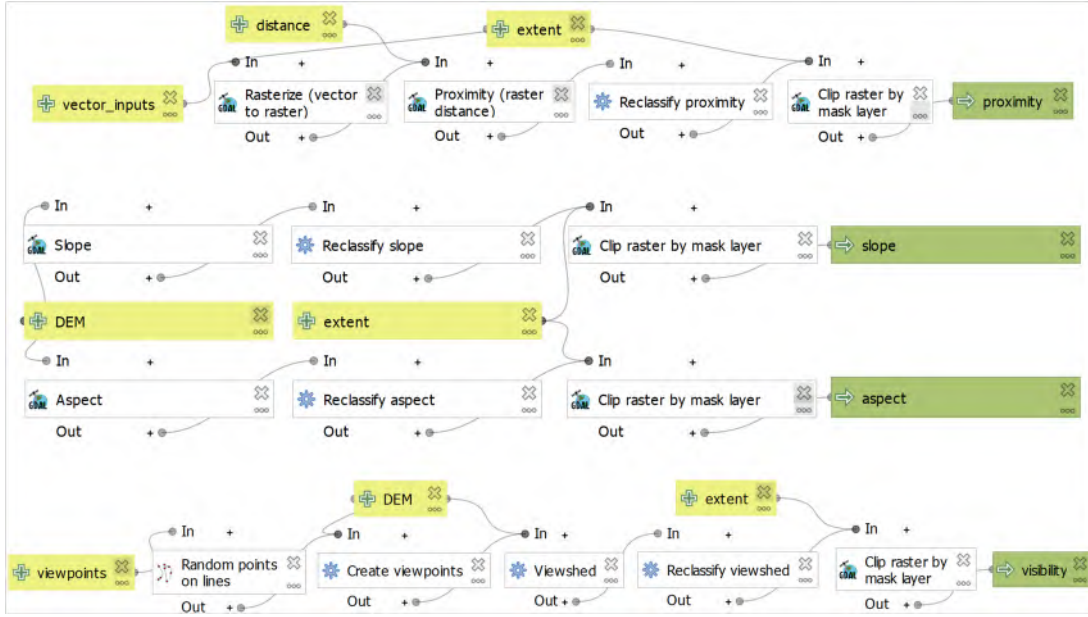
PPD-EPC bağlantılı verisi, Middle Layer Super Output Areas (MSOA), Lower Layer Super Output Areas (LSOA) ve Yerel İdari Bölge gibi Birleşik Krallık'taki çok

seviyeli konumsal birimler için CSV formatında paylaşılmaktadır. Ancak, CBS ile konumsal analizlerin gerçekleştirilebilmesi ve değer haritalarının üretilebilmesi için taşınmazların kesin konum bilgilerine (coğrafi/projeksiyon koordinatları veya benzersiz adres tanımlayıcısı) ihtiyaç vardır. Ordnance Survey AddressBase Plus/Premium ürünleri ücretsiz ve açık bir şekilde paylaşılmadığı için, bu çalışmada sözel adres bilgilerini UPRN ile eşleştirmek için alternatif bir yöntem izlenmiştir. Bu kapsamda, HERE Geocoding & Search API hizmeti kullanılarak geopy.geocoders Python kütüphanesi ile bağlantılı PPD-EPC verileri için toplu coğrafi kodlama (batch geocoding) işlemi gerçekleştirilmiştir. Jupyter Notebook ortamında 5.732.838 satır adres bilgisi 115 ayrı parçada, %99,8 başarı ile coğrafi olarak kodlanmış, koordinat bilgisi veriye öznitelik olarak eklenmiştir. İşlem sonucunda konum doğruluğunu kontrol etmek amacıyla, Birleşik Krallık Ulusal İstatistik Ofisi (Office for National Statistics - ONS)'nin LSOA idari bölge kodları kullanılmıştır.

Koordinatlı PPD-EPC verilerinin UPRN ile eşleştirilmesi amacıyla QGIS yazılımında konumsal birleştirme (Join attributes by nearest) aracı kullanılarak her bir veri noktasının en yakın UPRN konumuna atanması sağlanmıştır. Taşınmazın doğru UPRN numarası ile eşleşmesi için maksimum en yakın komşu sayısı 1 olarak belirtilmiş ve en uzak mesafe 50 metre ile sınırlandırılmıştır. Sonuç olarak, UPRN ile yüksek hassasiyetli konum bilgisine sahip PPD-EPC verileri GeoPackage (GPKG) açık coğrafi veri formatında oluşturulmuştur.

2.7 Konumsal Analizler

Taşınmaz değer haritaları, bir bölgedeki fiyat değişimlerinin ortaya konmasını sağlamakta ve yönetim, planlama, vergilendirme gibi faaliyetleri kolaylaştırmaktadır. Bölüm 2.2'de bahsedilen açık veri kaynakları kullanılarak, CBS tabanlı Nominal Değerleme yöntemi ile İngiltere, Galler ve İskoçya ülkelerinin arsa değer haritasının üretilmesi amacıyla yakınlık, yüzey ve görünürlük analizleri gerçekleştirilmiştir. Bu kapsamda işlemleri otomatize etmek ve tüm analizleri tek seferde gerçekleştirebilmek için açık kaynaklı QGIS masasüstü CBS yazılımının Graphical Modeler ve Python API (PyQGIS) arayüzleri kullanılmıştır (Şekil 2.11).



Şekil 2.11 : QGIS Graphical Modeler ile oluşturulan konumsal analiz modeli.

2.7.1 Yakınlık analizleri

Kamu binaları, toplu taşıma istasyonları, alışveriş merkezleri gibi önemli yerlere yakınlık, taşınmaz değerlemesinde en etkili faktörlerden biridir (Mete ve Yomralioğlu, 2019; Tajani, Morano, ve Ntalianis, 2018; Ünel ve Yalçın, 2019; Wyatt, 1997). Yakınlık analizi kapsamında iki konum arasındaki kuş uçuşu uzaklığı bir doğru parçası ile temsil eden Öklid Uzaklığı kullanılmış, yürüme ve araç ile ulaşım seçeneklerine göre uzaklıkların yeniden sınıflandırma aralıkları ayrı ayrı belirlenmiştir. Örneğin, gidilecek yere otobüs durağı, metro istasyonu gibi genellikle yürüyerek gidilen yerlere olan mesafe 0 ile 400 metre arasında ise, ilgili taşınmazın yakınlık puanı 100 (maksimum puan) olmaktadır. Yayaların yürümeyi tercih ettiği en rahat mesafe olarak bilinen bu aralık 0.25 mile denk gelen yaklaşık 5 dakikalık yürüme mesafesini temsil etmektedir (Manauh ve El-Geneidy, 2011; Yang ve Diez-Roux, 2012). Öte yandan, varış noktası otopark, havalimanı gibi genellikle araç ile ulaşımın tercih edildiği yerlere en fazla 1 kilometre mesafede bulunan bir taşınmaz ilgili kriterden 100 yakınlık puanı almaktadır. Yakınlık puanları erişim mesafesine göre sistemik bir şekilde azaltılmakta ve belli bir mesafeden sonrası dikkate alınmayarak 0 puan elde edilmektedir. Yakınlık değerlerinin sınıflandırma aralıkları literatürdeki çalışmalardan faydalanılarak araç erişimi ve yaya erişimi şeklinde iki gruba ayrılmıştır (Çizelge 2.5).

Öklid Uzaklığı analizi QGIS yazılımında GDAL Proximity (raster distance) aracı ile gerçekleştirilmektedir. Analizin çalıştırılabilmesi için raster formatında veri girişinin

Çizelge 2.5 : Yakınlık değerlerinin araç ve yaya erişimi için sınıflandırma aralıkları.

Erişilebilirlik Modu	Minimum (m)	Maksimum (m)	Nominal Değer
Yaya Erişimi	0	400	100
	400	600	90
	600	800	80
	800	1000	70
	1000	2000	50
	2000	3000	20
	3000	5000	10
	5000	∞	0
Araç Erişimi	0	1000	100
	1000	2000	90
	2000	3000	80
	3000	4000	70
	4000	6000	60
	6000	8000	50
	8000	10000	40
	10000	∞	0

sunulması gerekmektedir. Çalışmada kullanılan coğrafi verilerin bir çoğu vektör formatında olduğu için yakınlık analizi öncesinde vektörden raster formatına dönüşüm için Geospatial Data Abstraction Library (GDAL) Rasterize aracı kullanılmıştır. Yakınlık analizi sonrası elde edilen raster veri yeniden sınıflandırılarak 0-100 aralığında normalize edilmiştir. Son adımda çalışma bölgesine göre kesilen raster görüntünün elde edilmesi ile yakınlık analizi tamamlanmaktadır. Şekil 2.12’de Büyük Britanya’da metro istasyonlarına yakınlık analizi sonucunda üretilen harita görülmektedir.

2.7.2 Yüzey analizleri

Eğim, bakı gibi topografya özellikleri de taşınmaz değeri üzerinde önemli bir etkiye sahiptir. Taşınmazın düz bir arazide yer alması ve güneş ışığından uzun süre yararlanması (güney cephe) daha fazla tercih edilmektedir (Huang ve Hewings, 2021). Bu kapsamda EU-DEM açık verisi kullanılarak eğim ve bakı analizleri gerçekleştirilmiş ve yüzey analizi puanları 0 ile 100 arasında yeniden sınıflandırılmıştır.




Şekil 2.12 : Büyük Britanya - ana yola yakınlık analizi haritası.

2.7.2.1 Eğim analizi

Eğim, iki hücre arasındaki yükseklik farkının mesafeye oranı şeklinde tanımlanabilir. Eğim değeri ne kadar düşükse arazi o kadar düzdür. Aynı şekilde yüksek eğim değeri de arazinin engebeli olduğunu ifade eder. Eğimi geometrik olarak ifade edecek

olursak; eğim açısı teta ile tanımlandığında eğim bu açının tanjant değeridir (Şekil 2.13). Eğim hesabı hem yüzde hem de derece cinsinden ifade edilebilir.



Şekil 2.13 : Yüzde ve derece cinsinden eğim hesabı (ESRI, 2022c).

QGIS yazılımında eğim analizinin gerçekleştirilmesi için GDAL Slope aracı kullanılmış, yüzde cinsinden eğimler EU-DEM verisine bağlı olarak elde edilmiştir. Eğimin taşınmaz değerine etkisini yansıtabilmek amacıyla eğim değerleri yeniden sınıflandırılmış, düz arazilerin nominal puanının eğimli arazilere göre daha yüksek olması sağlanmıştır (Çizelge 2.6). Eğim değerlerinin yeniden sınıflandırma aralıkları için uluslararası erişilebilirlik standartlarının eğim sınıflandırma değerleri baz alınmıştır (ISO, 2001; TSE, 2011).

Çizelge 2.6 : Eğim değerlerinin yeniden sınıflandırma aralıkları.

Minimum (%)	Maksimum (%)	Nominal Değer
0	1	100
1	2	90
2	3	80
3	4	70
4	5	50
5	7	30
7	12	10
12	∞	0

Son olarak eğim analizi sonucunda elde edilen raster veri çalışma bölgesinin sınırlarına göre kırılarak eğim analizi haritası elde edilmiştir (Şekil 2.14).

2.7.2.2 Bakı analizi


Bakı, en temel ifade ile arazi yüzeyinde eğimin baktığı yönü ifade eder. Kuzeyden saat yönünde 360 derecelik birimlerle ölçülen bakı değeri, eğimin düz olduğu yerlerde -1 değerini almaktadır (Şekil 2.15).

Taşınmaz değerlendirme kapsamında bakı analizini ele aldığımızda, güneşlenme süresi sebebiyle daha çok tercih edilen Güney cephesinin değer etkisini yansıtabilmek için



Şekil 2.14 : Büyük Britanya - eğim analizi haritası.

Güney Doğudan Güney Batıya kadar olan değerler, yani 135° ile 225° arasında baki değerine sahip olan bölgeler 100 puan alacak şekilde yeniden sınıflandırılmıştır. QGIS yazılımında GDAL Aspect aracı ile gerçekleştirilen analiz sonucu elde edilen raster



Şekil 2.15 : Bakı analizinde eğimin yönünü belirten açı değerleri (ESRI, 2022b).

veri çalışma bölgesine göre kırılmış, böylece bakı analiz haritası elde edilmiştir (Şekil 2.16).

2.7.3 Görünürlük analizleri

Deniz, nehir ve orman gibi güzel manzaralar taşınmazlara önemli bir değer ve çekicilik katmaktadır (Wallner, 2012; Yu, Han, ve Chai, 2007). CBS tabanlı görünürlük analizleri iki ve üç boyutlu olarak gerçekleştirilebilmektedir. İki boyutlu görünürlük analizinde de sayısal yükseklik modeli kullanıldığı için taşınmazın manzarayı görme durumu yüksekliklere bağlı olarak hesaplanıp görünürlük haritası üretilebilmektedir. Bu sebeple toplu değerlendirme çalışmalarında manzara kriterinin değerlendirilmesi için iki boyutlu görünürlük analizi yeterli olmaktadır.

Görünürlük analizde her hücre merkezinin görünürlüğü, hücre merkezine olan yükseklik açısı ile yerel ufka olan yükseklik açısı karşılaştırılarak belirlenir. Yerel ufuk, gözlem noktası ile mevcut hücre merkezi arasındaki araya giren arazi dikkate alınarak hesaplanır. Nokta yerel ufkun üzerindeyse, görünür olarak kabul edilir. Çalışma bölgesinde manzaraların görüldüğü alanların belirlenebilmesi için QGIS Visibility Analysis eklentisi kullanılarak görünürlük analizi gerçekleştirilmiştir. Eklenti içerisinde bulunan görüş alanı (viewshed) aracı, manzara bölgeleri için yalnızca nokta verilerini girdi olarak kabul ettiğinden, deniz ve nehir hatları üzerinde rastgele noktalar oluşturulmuştur. Her bir manzara için gözlenen alanlar "Create view points" aracı ile nokta veri tipinde oluşturulduktan sonra görünürlük analizi yapılmış, görünürlük puanları 0 ile 100 arasında yeniden sınıflandırılmıştır. Elde edilen raster görüntüsü çalışma bölgesi sınırlarına göre kırılarak her bir analiz için manzara haritaları elde edilmiştir. Şekil 2.17'de Büyük Britanya bölgesine ait deniz manzarası haritası görülmektedir.



Şekil 2.16 : Büyük Britanya - bakı analizi haritası.

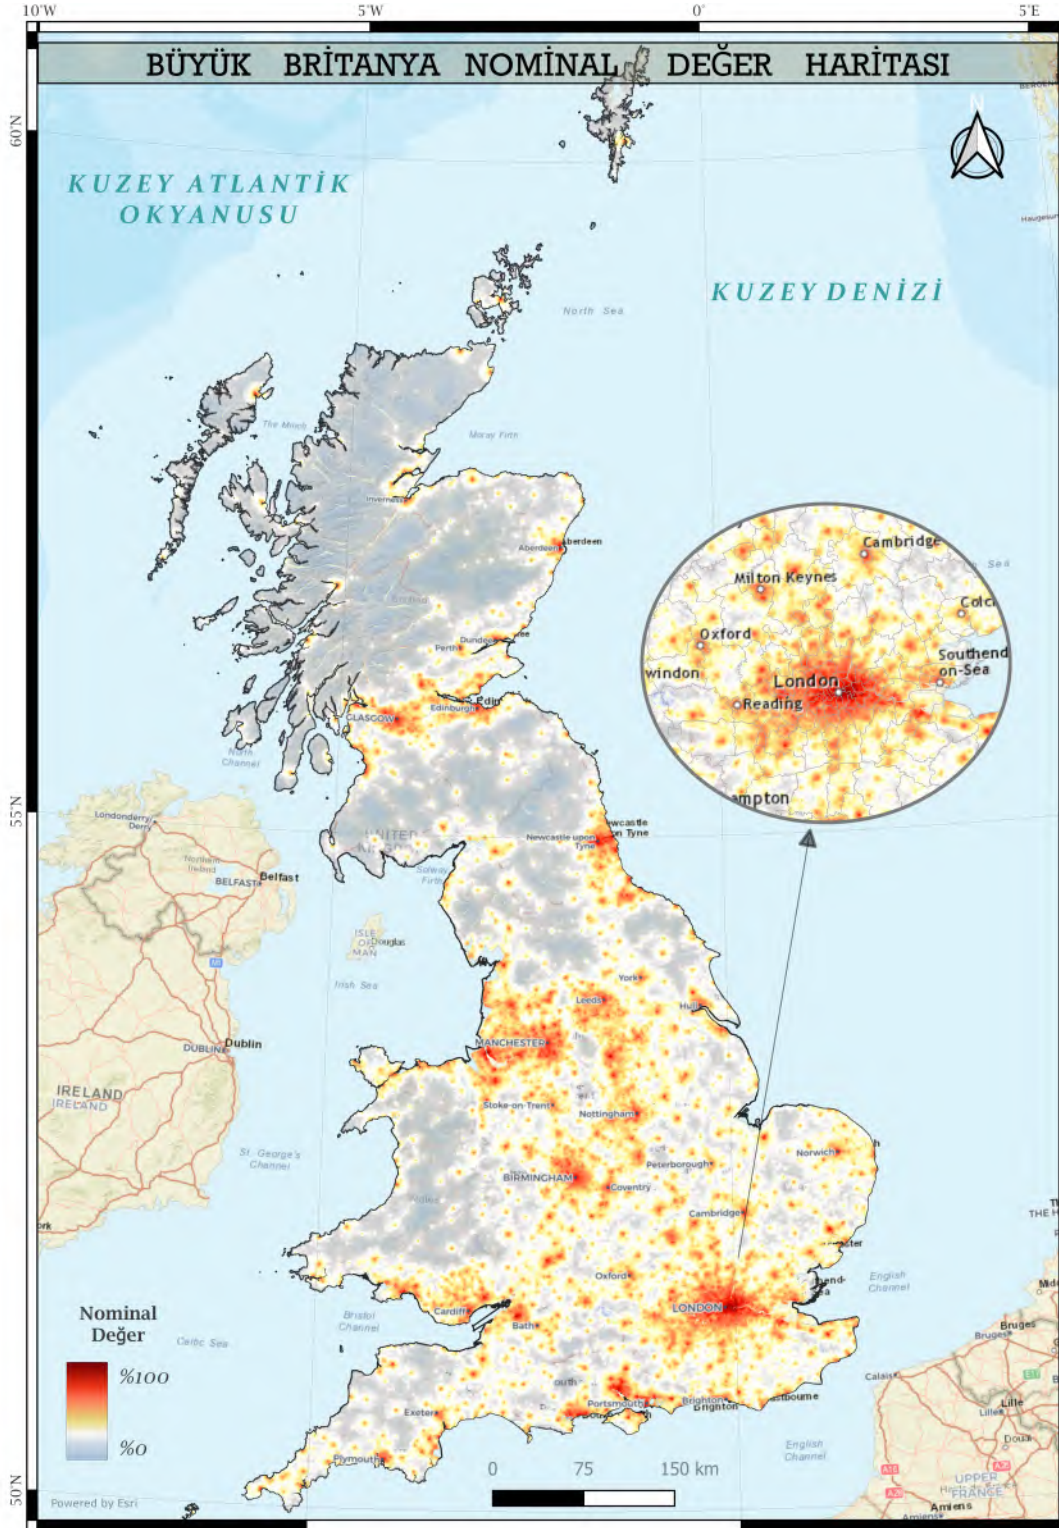
2.8 Nominal Taşınmaz Değerleme Yöntemi İle Değer Haritası Üretimi

Yakınlık, yüzey ve görünürlük gibi konumsal analizlerin gerçekleştirilmesi sonrasında çalışma bölgesine ait nominal arsa değer haritası QGIS'te raster hesaplama aracı



Şekil 2.17 : Büyük Britanya - deniz manzarası görünürlük analizi.

kullanılarak 35 kriterin ağırlıklı toplamı neticesinde üretilmiştir (Şekil 2.18). Nominal değerlendirilmede kullanılan faktör ağırlıkları, Bölüm 2.9’da Makine Öğrenmesi ile gerçekleştirilen global regresyon analizi sonucunda elde edilen konumsal değişkenlerin önem skorlarından alınmıştır (Çizelge 2.7).



Şekil 2.18 : Çalışma bölgesine ait nominal değer haritası.

Değer haritası incelendiğinde beklendiği üzere İngiltere'nin ve Birleşik Krallık'ın başkenti olan, önemli bir kültür, finans, turizm merkezi olan Londra şehri en yüksek değere sahip bölge olmuştur. Thames Nehri etrafında bulunan City of London, City of Westminster, Kensington and Chelsea, Hammersmith and Fulham bölgeleri

Çizelge 2.7 : CBS tabanlı nominal arsa değer haritası üretiminde kullanılan kriterler ve ağırlıkları.

No	Kriter	Ağırlık	Veri Seti
1	Havalimanlarına Yakınlık	0,02992	OS OpenMap
2	Sanat Merkezlerine Yakınlık	0,01048	OS OpenMap
3	Otobüs Duraklarına Yakınlık	0,00864	OS OpenMap
4	Şehir Merkezlerine Yakınlık	0,00643	OSM
5	Ana Yollara Yakınlık	0,00250	OS Open Roads
6	Tali Yollara Yakınlık	0,00378	OS Open Roads
7	Otoyol Kavşaklarına Yakınlık	0,01802	OS Open Roads
8	Otogarlara Yakınlık	0,03681	OS OpenMap
9	Araç İskelelerine Yakınlık	0,00317	OS OpenMap
10	Yolcu İskelelerine Yakınlık	0,00250	OS OpenMap
11	İtfaiye İstasyonlarına Yakınlık	0,00499	OS OpenMap
12	Yeşil Alanlara Yakınlık	0,00611	EEA Copernicus
13	Hastanelere Yakınlık	0,00781	OS OpenMap
14	Diğer Sağlık Merkezlerine Yakınlık	0,00772	OS OpenMap
15	Kütüphanelere Yakınlık	0,00480	OS OpenMap
16	Müzelere Yakınlık	0,04106	OS OpenMap
17	Otoparklara Yakınlık	0,02289	OSM
18	Polis Merkezlerine Yakınlık	0,00822	OS OpenMap
19	Limanlara Yakınlık	0,01401	OS OpenMap
20	Postanelere Yakınlık	0,00630	OS OpenMap
21	Birincil Eğitim Kurumlarına Yakınlık	0,00436	OS OpenMap
22	İkincil Eğitim Kurumlarına Yakınlık	0,00633	OS OpenMap
23	Özel Eğitim Kurumlarına Yakınlık	0,01125	OS OpenMap
24	Üniversitelere Yakınlık	0,01125	OS OpenMap
25	Alışveriş Merkezlerine Yakınlık	0,03709	OSM
26	Spor Merkezlerine Yakınlık	0,00767	OS OpenMap
27	Metro İstasyonlarına Yakınlık	0,18522	OSM
28	Tren İstasyonlarına Yakınlık	0,01054	OSM
29	Tramvay İstasyonlarına Yakınlık	0,00416	OSM
30	Turistik Bölgelere Yakınlık	0,00664	OS OpenMap
31	İbadet Yerlerine Yakınlık	0,00376	OS OpenMap
32	Bakı	0,00175	EU-DEM (v1.1)
33	Eğim	0,00780	EU-DEM (v1.1)
34	Göl/Nehir Manzarası	0,00281	OS Open Rivers
35	Deniz Manzarası	0,00553	OS Watermark

değer haritasında öne çıkan yerleşim yerleridir. Öte yandan Oxford, Cambridge, Birmingham, Manchester, Liverpool, Leeds ve Newcastle upon Tyne yüksek değer bölgesinde yer alan diğer şehirler olarak göze çarpmaktadır. Üretilen arsa değer haritasının sonuçları ONS tarafından paylaşılan arsa birim değerleri (ONS, 2022) ile

kıyalandığında şehirlerin nominal anlamda tutarlı bir değer dağılımına sahip olduğu görülmüştür.

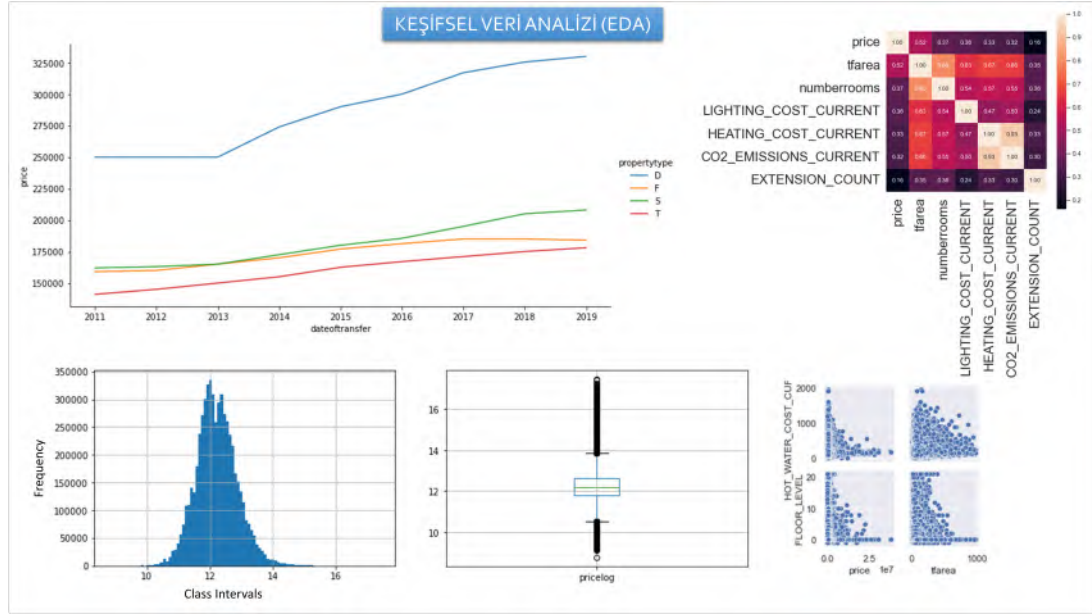
2.9 Makine Öğrenmesi Yöntemleri İle Regresyon Analizi

Makine Öğrenmesinin temel algoritma türlerinden biri olan Regresyon analizi, taşınmazların fiyat tahmini için yaygın olarak kullanılmaktadır. Tez kapsamında İngiltere ve Galler'de konut vasıflı taşınmazların değerlendirilmesi için PPD-EPC verisi kullanılarak Çoklu Lineer Regresyon, XGBoost, CatBoost, LightGBM, Rastgele Orman gibi çeşitli Makine Öğrenmesi regresyon modelleri oluşturulmuş, bu modellerin performansları çeşitli doğruluk metrikleri yardımıyla kıyaslanmıştır. Öte yandan tüm değişkenlerin regresyon modelindeki önem skorları hesaplanarak değeri ne ölçüde etkiledikleri tespit edilmiş, IAAO tarafından önerilen toplu değerlendirme standartları kapsamında oran çalışması gerçekleştirilmiştir. Çalışmada değeri önemli derecede etkileyen konumsal kriterlerin değerlendirme verilerine öznitelik olarak eklenmesi sonucunda öznitelik zenginleştirmenin model performansına etkisi incelenmiştir. Ayrıca değişkenlerin mekansal otokorelasyonun tespiti ve buna bağlı olarak lokal regresyon modellerinin gerçekleştirilebilmesi için nominal ağırlıklı mekansal kümeleme tekniği geliştirilmiş, coğrafi değişkenler baz alınarak değer bölgeleri oluşturulmuştur. Son olarak Birleşik Krallık'ta gerçekleştirilen toplu değerlendirme çalışmasında geliştirilen modelin genelleştirilebilirliğinin incelenmesi amacıyla aynı yöntem ülkemizde İstanbul ve İzmir şehirlerinde de uygulanmıştır.

2.9.1 Keşifsel veri analizi

Regresyon analizi kapsamında ilk olarak PPD-EPC verileri Jupyter Notebook Python ortamına Pandas DataFrame olarak aktarılmış, veriler hakkında detaylı bilgilerin elde edilebilmesi için keşifsel veri analizi gerçekleştirilmiştir. EDA, verilerin istatistik ve çeşitli görselleştirme teknikleri kullanılarak daha iyi anlaşılmasını sağlayan, veri bilimi projeleri için olmazsa olmaz bir adımdır. Bu aşamada tanımlayıcı istatistikler (minimum, maksimum, ortalama, standart sapma vb.) hesaplanmakta, verideki boş (null) değerler kontrol edilmekte, korelasyon matrisi, histogram, kutu grafiği, dağılım grafiği, ikili karşılaştırma grafikleri oluşturulmaktadır (Şekil 2.19). PPD-EPC veri

setinde 5.627.022 satır ile birlikte farklı kategorik ve sayısal değişkenleri içeren 23 sütun bulunmaktadır.



Şekil 2.19 : Keşifsel Veri Analizi.

Yapı türlerine göre fiyat değişiminin gösterildiği grafik incelendiğinde ortalama fiyatı en yüksek olan türün müstakil evler olduğu görülmektedir. Bu grafik ile birlikte ortalama konut fiyatlarının yıllara göre değişimi hakkında bilgi almak mümkündür. Pearson korelasyon analizine göre oluşturulan matriste ise değişkenlerin birbirleriyle olan pozitif ve negatif ilişkileri görülebilmektedir. Grafiğe göre fiyat değişkeninin yüzölçümü ve oda sayısı ile olan yüksek pozitif korelasyonu göze çarpmaktadır. Öte yandan kutu grafiği üzerinden fiyat değişkeninde aykırı verilerin bulunduğu görülmekte, detaylı inceleme ile bu değerlerin göz önüne alınması gerektiği anlaşılmaktadır. Çizelge 2.8’de sayısal verilere ait özet istatistikler yer almaktadır.

2.9.2 Özellik mühendisliği

Özellik mühendisliği (feature engineering) aşamasında aykırı değer tespiti, eksik verilerin tamamlanması, kategorik verilerin kodlanması ve özellik seçimi gibi işlemler yapılmaktadır. Aykırı değerler verilerde sapmalara yol açarak regresyon analizinde zayıf uyuma sebep olmaktadır. Aykırı değer tespiti açıklayıcı grafikler ve standart sapma gibi klasik yaklaşımlar ile yapılabileceği gibi İzolasyon Ormanı (Isolation Forest), Minimum Kovaryans Belirleyici (Minimum Covariance Determinant), Tek Sınıf DVM (One-Class SVM) gibi otomatik yöntemlerle de gerçekleştirilebilmektedir.

Çizelge 2.8 : PPD-EPC verisine ait özet istatistikler.

Kriter	Ortalama	Standart Sapma	Minimum	%25	%50	%75	Maksimum
price	258156,3	267153,5	6500	131000	195000	303000	18989400
dateoftransfer	2015,016	2,428433	2011	2013	2015	2017	2019
tfarea	93,1901	43,16808	9,7	67,98	84	106,35	968,08
numberrooms	4,653354	1,608688	1	4	5	5	20
ENVIRONMENT_IMPACT_CURRENT	56,76325	13,66182	1	48	58	67	329
HEATING_COST_CURRENT	756,5131	471,2222	-344	481	658	902	52853
FLOOR_LEVEL	0,200861	0,806919	-1	0	0	0	21
EXTENSION_COUNT	0,518774	0,750923	0	0	0	1	4
Airport	15,6753	26,2548	0	0	0	40	100
Aroad	95,23307	14,93725	0	100	100	100	100
Aspect	25,73346	43,71653	0	0	0	100	100
Broad	91,62845	16,1248	0	90	100	100	100
Coachstation	12,51758	25,19506	0	0	0	0	100
Ferry	3,346375	13,84887	0	0	0	0	100
Firestation	83,94585	14,43154	0	80	90	90	100
Hospital	74,64092	23,7455	0	60	80	90	100
Junction	60,22384	32,58338	0	50	70	90	100
Mall	20,65968	30,94356	0	0	0	50	100
Medical	82,23265	20,99117	0	80	90	100	100
Park	55,71178	32,03368	0	40	60	80	100
Police	77,18349	22,77649	0	70	80	90	100
Port	14,52603	27,69151	0	0	0	0	100
Primaryedu	89,65548	16,2495	0	90	100	100	100
art	17,57	26,02942	0	0	10	20	100
bus	15,39719	23,6663	0	0	0	20	100

Çizelge 2.8 (devam): PPD-EPC verisine ait özet istatistikler.

Kriter	Ortalama	Standart Sapma	Minimum	%25	%50	%75	Maksimum
citycenter	86,89633	14,74096	0	80	90	100	100
furteduc	36,22045	31,50948	0	10	20	50	100
library	58,89345	29,2077	0	50	50	80	100
musem	29,35526	29,65559	0	10	20	50	100
passferry	1,133851	7,054631	0	0	0	0	100
post	76,23402	23,77704	0	70	80	100	100
sports	49,41211	29,83296	0	20	50	70	100
subway	5,582976	18,82553	0	0	0	0	100
tourist	9,681462	21,42564	0	0	0	10	100
train	45,00496	32,12082	0	10	50	70	100
tram	4,143934	15,70304	0	0	0	0	100
worship	90,65571	14,47785	0	90	100	100	100
river	83,54617	37,07634	0	100	100	100	100
sea	18,68623	38,9801	0	0	0	0	100
secondaryedu	62,86277	29,68586	0	50	70	90	100
green	98,89164	10,33902	0	100	100	100	100
slope	60,26325	32,32889	0	40	70	85	100
University	49,50954	36,1532	0	0	60	80	100
CURRENT_ENERGY_EFFICIENCY	60,28597	12,6709	1	54	62	69	347
ENERGY_CONSUMPTION_CURRENT	280,4459	116,9041	-1365	205	257	327	13230
CO2_EMISSIONS_CURRENT	4,638358	2,746737	-25,4	3	4	5,5	280
LIGHTING_COST_CURRENT	83,27907	42,70702	-369	60	78	100	56351
HOT_WATER_COST_CURRENT	144,496	74,91267	-2	99	120	164	1966

Çalışmada, 3-sigma standart sapma uzaklık değeri uygulanarak aykırı değerler tespit edilmiş ve bu değerler veri setinden kaldırılmıştır. Ayrıca ortanca ve ortalama değer istatistikleri kullanılarak verideki eksik değerler makul bir yaklaşım ile doldurulmuştur. Örneğin, kat seviyesi özneliğinde bulunan boş değerler veride en çok tekrar eden ve müstakil evlerin de kat seviyesini ifade eden sıfır değeri ile değiştirilmiştir.

Neredeyse tüm regresyon algoritmaları giriş ve çıkış verilerinin nümerik değişkenlerden oluşmasını zorunlu tutmaktadır. Bu nedenle veride bulunan kategorik öznelikler kodlanarak sayısal hale dönüştürülmelidir. PPD-EPC verileri, bina türü (müstakil, apartman daireleri, yarı müstakil vb.), eski/yeni ve sahiplik türü (mülk, kira) gibi kategorik değişkenler içermektedir. Bu öznelikleri Makine Öğrenmesi regresyon modellerinde kullanılmaya hazır hale getirmek için One Hot Encoding kodlama yöntemi uygulanmış ve nominal değişkenler sayısal bir dizi oluşturacak şekilde kodlanmıştır.

2.9.3 Regresyon analizi

Veri ön işleme adımları sonrasında Makine Öğrenmesi ile bir tahmin modelinin oluşturulması için regresyon analizi gerçekleştirilmiştir. Bu kapsamda veriler scikit-learn kütüphanesinin `train_test_split` aracı kullanılarak %90 eğitim, %5 doğrulama, %5 test olacak şekilde rastgele ayrılmıştır. Öte yandan değer kestirimi için Linear Regresyon, XGBoost, CatBoost, LightGBM, Rastgele Orman gibi çeşitli regresyon modelleri oluşturulmuştur. Örnek olarak XGBoost modeline ait eğitim süreci aşağıda verilmiştir:

```
#bağımlı ve bağımsız değişkenlerin tanımlanması
X = df.iloc[:,1:]
y = df.iloc[:,0]
#eğitim ve test olarak verinin ayrılması
X_train, X_test, y_train, y_test =
train_test_split(X, y, test_size=0.05)
#test verisinin doğrulama verisine ayrılması
X_train, X_validation, y_train, y_validation =
train_test_split(X_train, y_train, test_size=0.05)
```




```
#regresyon modelinin tanımlanması ve eğitilmesi
model = XGBRegressor()
model.fit(X_train, y_train)
#eğitim sonrası tahminin gerçekleştirilmesi
xgb_y_pred_train = model.predict(X_train)
```

Modellerin tahmin başarısını görmek ve en iyi performansa sahip olanları hiper parametre optimizasyonuna tabi tutmak için başlangıçta tüm modeller ilgili algoritmaların varsayılan parametreleri ile eğitilmiştir. Eğitim aşaması sonrası modelin daha önce görmediği veriler kullanılarak tüm modeller için tahmin başarısı ölçülmüştür.


2.9.4 Taşınmaz değerini etkileyen kriterlerin önem düzeyi

Özellik seçiminin bir parçası olan özniteliklerin önem skorları, bir değişkenin tahmin sürecini ne kadar etkilediğini yorumlamak için kullanılmaktadır. Çalışmada regresyon modelleri için permutasyon önem skorları hesaplanmıştır (Şekil 2.20). Taşınmaz değerlemede çok tartışılan bir konu olan kriter ağırlıklarını makine öğrenmesi ile objektif bir şekilde belirlemek amacıyla önem skorları temsili ağırlık olarak kullanılabilir.



Şekil 2.20 : Kriterlere ait permutasyon tabanlı önem skorları.

Çalışmada değeri etkileyen kriterlerin önem düzeylerinin belirlenmesinin yanı sıra, modellerin karar verme davranışlarını anlamak ve açıklamak için SHAP değerleri hesaplanmıştır (Şekil 2.21). Böylece SHAP özet grafiği ile ilk 20 değişkenin önem durumu gösterilerek tahmin modeli üzerindeki etkileri açıklanmıştır.



Şekil 2.21 : Bağımsız değişkenlerin SHAP değeri.

2.9.5 Doğruluk analizi

Model performanslarını ölçmek için R^2 , düzeltilmiş R^2 , MBE, MAE, MAPE ve RMSE gibi çeşitli doğruluk metrikleri kullanılmıştır.

Belirleme katsayısı R^2 , bağımlı ve bağımsız değişkenlerin regresyon analizinde ne kadar ilişkili olduğunu göstermektedir (2.1). R^2 ile toplam varyans oranı hesaplanarak modelin uyum iyiliğini belirtilir. Öte yandan R^2 'nin bir özel durumu olan düzeltilmiş R^2 , uyuşumu açıklarken regresyon modelindeki değişken sayısını da hesaba katmaktadır (2.2).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (2.1)$$

$$\text{Düzeltilmiş } R^2 = 1 - \frac{(1 - R^2)(n - 1)}{n - p - 1} \quad (2.2)$$

öyle ki;

y: Gerçek değer

\hat{y} : Tahmin değeri

n : Örneklem sayısı

p : Bağımsız değişken sayısı

Modeldeki önyargı, ortalama tahmin değeri ile gerçek değer arasındaki farkı ölçer. Yüksek önyargı değeri eksik öğrenme (underfitting) ve yüksek model hatasına neden olur. Öte yandan varyans değeri rastgele bir değişkenin beklenen değerden ne kadar farklı olduğunu ifade eder. Eğitim veri setinden farklı bir veri kullanıldığında tahminler arasındaki değişim miktarını göstermektedir. Yüksek varyansa sahip bir model aşırı öğrenir ve eğitim veri seti ile iyi performans gösterir. Ancak daha önce karşılaşmadığı verilerle iyi bir genelleştirme yapamaz. Model eğitim veri setinde iyi performans gösterse de aşırı uyum (overfitting) nedeniyle test verilerinde yüksek hataya sebep olmaktadır. Doğrusal regresyon gibi basit modeller genellikle yüksek yanlılığa ve düşük varyansa sahiptir. Öte yandan Rastgele Orman gibi karmaşık modeller genellikle düşük önyargıya ve yüksek varyansa sahiptir. Bagging ve boosting tabanlı topluluk öğrenmesi algoritmaları modeldeki önyargı-varyans dengesini iyi yapılandırarak başarılı sonuçlar vermektedir (Bühlmann, 2012).

MBE temel olarak modeldeki ortalama yanlılığı ifade eder. Tahmin değerleri ile gerçek değerlerin farklarının ortalaması şeklinde hesaplanır (2.3). MAE temel olarak gerçek değer ile tahmin değeri arasındaki farkı ifade etmektedir (2.4). Hata hesabında gözlem sayısının da dikkate alınmasıyla farkların mutlak değerlerinin toplamı şeklinde hesaplanmaktadır. Öte yandan ortalama mutlak sapmayı yüzde olarak ifade eden MAPE, gerçek değer ile tahmin değeri farklarının toplamının gerçek değerlere bölünmesiyle elde edilmektedir (2.5).

$$MBE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i) \quad (2.3)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.4)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (2.5)$$

RMSE, tahmin hatalarının karelerinin toplamının ortalamasının karekökünü hesaplayarak gerçek değer ile tahmin edilen değer arasındaki farkı tanımlayan bir ölçüdür

(2.6). Düşük RMSE değeri, regresyon analizinde tahmin için daha iyi bir uyum anlamına gelmektedir.

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.6)$$

Eğitilen regresyon modelleri kullanılarak doğrulama verileri üzerinde tahminleme gerçekleştirilmiş, çeşitli doğruluk metrikleri hesaplanmıştır. Topluluk Öğrenmesi yöntemleri için, ağaç sayısı, bir ağaçtaki maksimum düzey sayısı, her yaprak düğümünde gereken minimum örnek sayısı gibi hiper parametrelere Rastgele Arama uygulanmıştır. Ardından Rastgele Arama sonuçlarına odaklanarak en iyi tahmin modelinin parametrelerini ortaya çıkarmak için Çapraz Doğrulanmış Grid Arama kullanılmıştır. Böylece yüksek doğruluklu bir tahmin için regresyon modelinin eğitim aşamasında kullanılmak üzere en iyi model parametreleri belirlenmiştir. Regresyon analizinin sonuçlarına bakıldığında Rastgele Orman algoritması R²: 0,4690; MAE: 95934,57; MAPE: 0,4614 doğruluk metrikleri ile diğer modellere kıyasla daha iyi bir performans göstermiştir (Çizelge 2.9).

Çizelge 2.9 : Global regresyon modellerinin doğruluk metrikleri.

Model	R ²	Düz. R ²	MAE	MBE	MAPE	RMSE
Linear	0,3003	0,3002	113075,3477	1205,9764	0,5673	227530,6047
XGBoost	0,4341	0,4340	98505,9861	942,2679	0,4689	204625,5031
CatBoost	0,4551	0,4550	98811,1141	964,3156	0,4737	200791,2485
LightGBM	0,4366	0,4365	101291,7355	1039,8106	0,4937	204170,2015
RastgeleOrman	0,4690	0,4689	95934,5759	927,8653	0,4614	198211,9713

2.9.5.1 Oran çalışması

Toplu değerlendirme çalışması tamamlandıktan sonra geliştirilen modelin kalitesinin test edilmesi için oran çalışması gerçekleştirilmiştir. Bu kapsamda IAAO'nun Toplu Değerleme Standardı'nda önerdiği Değerleme Düzeyi, COD ve PRD performans metrikleri hesaplanmıştır. Değerleme düzeyi, tahmin edilen değerlerin gerçek değere yakınlığını istatistiksel olarak ele almaktadır. Bu metrik ortalama oran (mean ratio), ağırlıklı ortalama oran (weighted mean ratio) ve medyan oranından (median ratio) oluşur. Bu oranların teorik olarak 1,00 olması beklenmektedir, ancak 0,90 ile 1,10 arasındaki değerlendirme seviyesi kabul edilebilir değerlerdir. Öte yandan eski veya

heterojen yerleşim alanları için 5-15 arasında, bunların dışında kalan diğer konutlar için ise 5-20 arasında değerler almalıdır. PRD, doğruluk analizi kapsamında ortalama oran (\bar{R}) (2.7) ve ağırlıklı ortalama oran (WM) (2.8) kullanılarak hesaplanan bir metriktir (2.9). 0,98 ile 1,03 arasındaki PRD oranı gerçek değer ile tahmin değeri arasındaki farkın istatistiksel olarak anlamlı olduğunu ifade eder. COD ise değerlendirme oranlarının medyan oran ile ortalama yüzde farkını ifade edilen bir performans göstergesidir (2.10). Değerlemenin tekdüzeliğini ölçen bu değer müstakil evler, yeni veya yerleşim bölgesinde homojen olarak dağılmış konutlar için 5-10 arasında olmalıdır (IAAO, 2013c, 2017).

$$\bar{R} = \frac{\sum_{i=1}^n R_i}{n} \quad (2.7)$$

$$WM = \frac{\bar{A}}{\bar{S}} = \frac{\sum_{i=1}^n A_i}{\sum_{i=1}^n S_i} \quad (2.8)$$

$$PRD = \frac{\bar{R}}{WM} \quad (2.9)$$

$$COD = \frac{100}{n} \frac{\sum_{i=1}^n |R_i - \tilde{R}|}{\tilde{R}} \quad (2.10)$$

öyle ki;

n : Örneklem sayısı

R_i : Tahmin değerinin gerçek değere oranı

\bar{A} : Tahmin değerlerinin toplamı

\bar{S} : Gerçek değerlerin toplamı

\tilde{R} : Medyan değeri

281.350 test verisi kullanılarak gerçekleştirilen analizde COD 14,92; PRD ise 1,03 olarak hesaplanmıştır. Oran çalışması sonuçlarına göre İngiltere ve Galler'deki konutların toplu değerlendirme çalışmasının IAAO oran standartlarına uygun olarak gerçekleştirildiği görülmüştür.

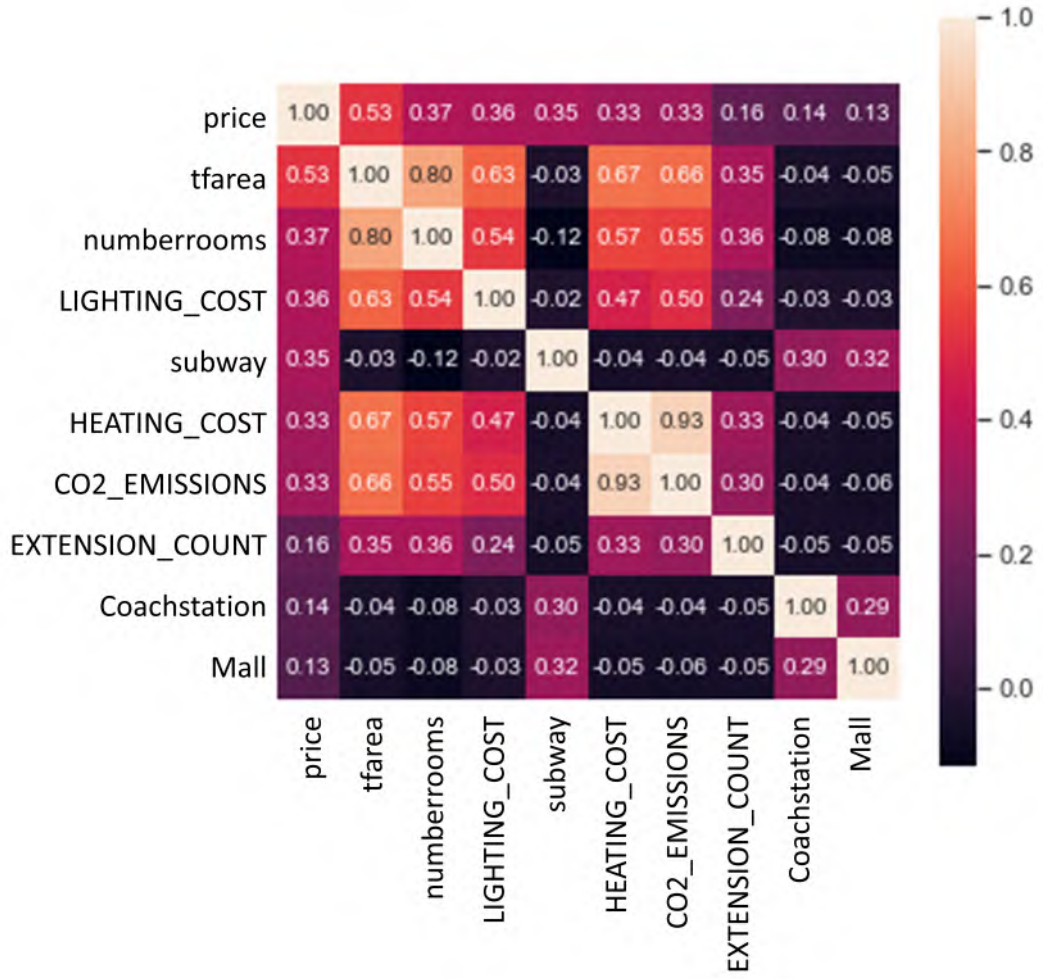
2.9.6 Coğrafi Bilgi Sistemleri ile öznitelik zenginleştirme

PPD-EPC veri seti, Makine Öğrenmesi tabanlı değerlendirme çalışmalarında fiyat tahmini için gereken birçok fiziksel öznitelik içermektedir. Ancak daha yüksek doğruluklu regresyon modelleri oluşturmak için taşınmaz değeri ile yüksek oranda ilişkili olan konumsal faktörlerin de sürece dahil edilmesine ihtiyaç vardır (Kiel ve Zabel, 2008; Mete, Guler, ve Yomralioglu, 2022; Wyatt, 1997). CBS, konumsal kriterlerin taşınmaz değeri üzerindeki etkilerini ortaya çıkarmak için kullanılacak çok sayıda analiz aracı sunmaktadır. Bu kapsamda regresyon modelinin öznitelik zenginleştirilmesi için yakınlık, yüzey ve görünürlük analizlerinin nominal puanları PPD-EPC verilerine eklenmiştir. Bölgesel istatistikler (zonal statistics), raster örnekleme (raster sampling), rasterden noktaya dönüştürme (raster to point conversion) gibi raster verilerin piksel değeri bilgisini hesaplamının birkaç yolu vardır.

Çalışmada PyQGIS üzerinden Batch Raster Sampling algoritması düzenlenmiş, 35 kriter çıktısının her birinden raster verisine karşılık gelen piksel değerini (nominal analiz puanı) elde etmek için UPRN nokta verisi üzerinde örnekleme yapılmıştır.

Konumsal kriterlerin nominal puanları, UPRN verisine yeni öznitelik sütunları olarak eklenir ve CSV dosyası olarak kaydedilmiştir. Daha sonra UPRN verisi Jupyter Notebook ortamına aktararak UPRN numarasına dayalı olarak PPD-EPC veri setiyle birleştirilmiştir. Sonuç olarak, PPD-EPC veri seti konumsal analizlerle oluşturulan 35 yeni öznitelikle zenginleştirilmiştir. Değişkenlere ait Pearson korelasyon matrisi incelendiğinde, CBS analizleri sonucunda eklenen konumsal faktörlerin fiyat değişkeni ile pozitif bir ilişkisi olduğu görülmektedir (Şekil 2.22). Fiyat değişkeninin korelasyon katsayısı metro istasyonlarına yakınlık kriteriyle %35; otogarlara yakınlık kriteriyle %14, alışveriş merkezlerine yakınlık kriteriyle de %13 olarak hesaplanmıştır.

Zenginleştirilmiş öznitelikler elde edildikten sonra Makine Öğrenmesi yöntemleri ile regresyon analizi için aynı iş akışı izlenmiştir. Regresyon modelleri Rastgele Arama ve Grid Arama kullanılarak zenginleştirilmiş öznitelikli veriler ile eğitilmiştir. Modeller için en iyi parametreler elde edildikten sonra test verilerinin tahmini aşamasında en iyi tahmin modelleri kullanılmıştır. Çizelge 2.10'da modellerin eğitim sürelerini ve doğruluk metriklerini gösterilmektedir.



Şekil 2.22 : Değişkenlere ait korelasyon matrisi.


Çizelge 2.10 : Öznitelik zenginleştirilmesi sonrası hesaplanan doğruluk metrikleri.

Model	R ²	Düz. R ²	MAE	MBE	MAPE	RMSE
Linear	0,4473	0,4472	101442,6036	821,9823	0,4987	200851,5148
XGBoost	0,7907	0,7906	65367,1736	527,1426	0,3107	123585,9848
CatBoost	0,8380	0,8379	56668,9762	568,0875	0,2660	108740,2277
LightGBM	0,8058	0,8058	65567,8885	592,9812	0,3188	119042,0076
RastgeleOrman	0,8579	0,8578	44888,7285	502,7812	0,1941	101847,7448


Son olarak öznitelik önem skorları (Şekil 2.23) ve SHAP değerleri (Şekil 2.24) hesaplanmış, konumsal kriterlerin tahmin modeline olan etkisi ortaya konmuştur.

2.9.7 Konumsal kümeleme yöntemi ile değer bölgelerinin belirlenmesi

Toplu taşınmaz değerlendirme amacıyla oluşturulan tahmin modelleri genellikle global regresyon modelleri kullanılarak oluşturulmaktadır. Global modeller, tahmin sürecinin



Şekil 2.23 : Öznitelik zenginleştirilmesi sonrası önem skorları.



Şekil 2.24 : Öznitelik zenginleştirilmesi sonrası SHAP değerleri.

konumdan bağımsız olduğu ya da çalışma bölgesinin bütünü için aynı özelliklere sahip olduğu yaklaşımına dayanmaktadır. Lokal modeller ise benzer özellikler barındıran birbirine yakın verilerin konuma dayalı gruplandırılmasıyla oluşturulan

modellerdir. Global regresyon modelleri arasında en yaygın kullanılan yöntemler ÇRA, DVM Regresyonu, Rastgele Orman, XGBoost, CatBoost, LightGBM gibi Topluluk Öğrenmesi Regresyonlarıdır. Global regresyon modellerinde çalışma bölgesi için değeri etkileyen her faktör için birer ağırlık belirlenmektedir. Geniş alanlarda yapılan toplu değerlendirme çalışmalarında kriter ağırlığının sabit bir değer ile temsil edilmesi yüksek önyargı değerine sebep olabilmektedir. Örneğin; yeşil alanlara yakınlık, iskelelere yakınlık, deniz manzarası gibi kriterler farklı coğrafi bölgelere göre görece değişkenlik gösterebilmektedir. Bu kriterlerin değeri farklı bölgelerde aynı önem derecesi ile etkilediği varsayımı model doğruluğunu düşürmektedir.

Coğrafya'nın temel yasasına göre birbirine yakın şeyler uzaktakilere kıyasla daha ilişkilidir (Tobler, 1970). Toplu değerlendirme çalışmalarında tutarlı ve yüksek doğruluklu modellerin elde edilebilmesi için benzer özellikler gösteren, birbirlerine yakın olan taşınmazların kümelendirilmesiyle (clustering) oluşturulacak değer bölgelerine ait yerel ağırlıkların belirlenmesi gerekmektedir. Bu kapsamda literatürde taşınmaz değerlendirme amaçlı konumsal yakınlığı baz alan GWR, Spatial Lag, Spatial Error lokal regresyon modelleri de kullanılmaktadır (Bitter, Mulligan, ve Dall'erba, 2007; Cellmer, Cichulska, ve Belej, 2020; Kim ve Kim, 2016; McCord, Lo, Davis, Hemphill, McCord, ve Haran, 2019; Sisman ve Aydinoglu, 2022a; Stewart Fotheringham ve Park, 2018).

Mekansal modelleme öncesinde verilerin konumsal otokorelasyon ve konumsal heterojenlik durumları incelenerek trend, değişkenlerin genel dağılımları, konuma göre bağımlılık, kümelenme durumu ve aykırı verilerin tespiti işlemleri ele alınmalıdır. Bu kapsamda Global ve Lokal Moran's I analizleri ile otokorelasyonun tespiti farklı ölçeklerde yapılabilmektedir. Global mekansal otokorelasyon indeksi, çalışma alanında verilerin komşuluk ilişkisini baz alarak coğrafi benzerlikleri özetlemektedir. Global Moran I indeksi genellikle çalışma bölgesinde kümelenme olup olmadığını belirtmektedir (2.11). Ancak bu kümelenmenin nerede olduğu konusunda bilgi verememektedir. Lokal Moran's I indeksi ise birbirine benzeyen ve farklılık gösteren verilerin nerelerde kümelendiğini detaylı bir şekilde göstermektedir. Yani konumsal ilişkinin tek bir global parametre ile özetlenmesi yerine bölgedeki tüm yerel birimlerin komşu değerlerle meydana getirdiği kümelenmelerin pozitif veya negatif yönde ilişkilendirilmesi ile ifadesi söz konusudur. Global Moran's I indeksi, p-değeri ve

z-skoru ile birlikte çalışma bölgesinde bir kümelenme olup olmadığını açıklamaktadır. İstatistiksel olarak anlamlı p-değeri, pozitif z-skoru ve pozitif Moran's I indeks değeri çalışma alanında kümelenmenin olduğunu işaret eder (Li, Calder, ve Cressie, 2007; Moran, 1950).

$$I = \frac{\sum_{i=1}^n \sum_{j=1}^n w_{i,j} (x_i - \bar{x})(x_j - \bar{x})}{\left(\sum_{i=1}^n \sum_{j=1}^n w_{i,j} \right) \sum_{i=1}^n (x_i - \bar{x})^2} \quad (2.11)$$

öyle ki;

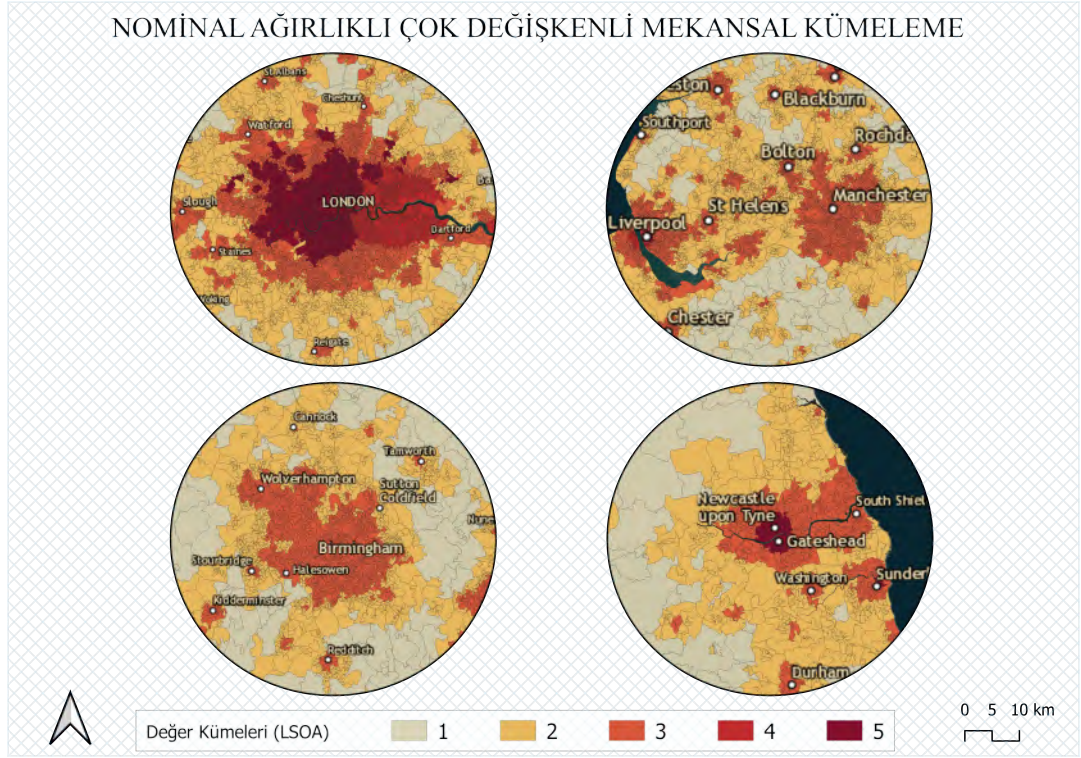
I : Moran's I istatistiği

x_i : Değişkenin herhangi bir konumdaki değeri

w : İki konum arasındaki ilişkiyi belirleyen ağırlık

PPD verisi kullanılarak yapılan analiz sonucunda İngiltere ve Galler ülkelerinde mekansal otokorelasyonun varlığı tespit edilmiştir (Moran's I İndeksi: 0.7110, z-skoru: 1832.3314, p-değeri: 1×10^{-6}). Değerleme verisinin durağan olmayan (nonstationary) yapısı sebebiyle bölgesel değer değişimlerinin bulunduğu görülmüş, bu sebeple değişkenlerin konuma dayalı ilişkilerinin modellenmesi amacıyla bir mekansal regresyon analizine ihtiyaç olduğu sonucuna varılmıştır. Bu kapsamda değer bölgelerinin tespit edilmesi için k-means yöntemi özelleştirilerek Nominal Ağırlıklı Çok Değişkenli Mekansal Kümeleme analizi gerçekleştirilmiştir. Değişkenlerin ağırlıkları ilk adımda uygulanan global regresyon modelinin önem skorları hesaplanarak elde edilmiştir. Ağırlıklı kümeleme yaklaşımı ile benzer özellikler gösteren ve coğrafi konum itibarıyla birbirine yakın olan taşınmazlar aynı kümeye dahil edilmiştir.

Kümelendirme çalışmalarında küme sayısı Dirsek (Elbow) Yöntemi, Ortalama Silüet (Average Silhouette), Boşluk İstatistiği (Gap Statistic), Dendrogram Diyagramı gibi çeşitli yöntemler ile belirlenebilmektedir. Bu çalışma kapsamında k küme sayısının belirlenmesi amacıyla dirsek yöntemi kullanılmıştır. Sezgisel bir yaklaşıma sahip olan dirsek yöntemi, değişkenlerin varyans değeri ile küme sayısının bir fonksiyonu olarak tanımlanmaktadır. Çalışmada varyans değerinin ani değişim gösterdiği dirsek noktasına göre küme sayısı tespit edilmiştir. Kümeleme analizi sonucu elde edilen değer bölgelerinin çalışma bölgesindeki dağılımı Şekil 2.25'de gösterilmiştir.




Şekil 2.25 : Nominal Ağırlıklı Çok Değişkenli Mekansal Kümeleme Analizi sonucu oluşturulan değer bölgeleri.

Büyük Londra bölgesi incelendiğinde Thames Nehri etrafında bulunan City of London, City of Westminster, Kensington and Chelsea, Hammersmith and Fulham gibi bölgelerin en yüksek değer bölgesinde yer aldığı, dış çeperlere doğru diğer değer bölgelerinin mekansal olarak kümelendiği görülmektedir (Şekil 2.26).

Çalışma bölgesinin tamamı için tek bir global model yerine tüm kriterler ele alınarak belirlenen beş farklı kümede lokal regresyon analizleri gerçekleştirilmiştir. Literatürde konut değerlendirme çalışmalarında mekansal regresyon olarak GWR yöntemi sıklıkla kullanılmaktadır. Fakat bu yöntem doğrusal bir regresyon çeşidi olduğu için doğrusal olmayan değişkenleri modellemede yetersiz kalabilmektedir. Bu sebeple çalışmada alternatif bir yöntem geliştirilerek kümeleme analizi sonrasında lokal kümelerde Rastgele Orman, XGBoost, CatBoost, LightGBM gibi topluluk öğrenmesi regresyonları kullanılmış, benzer bir yapıya sahip değer bölgelerinde yüksek doğruluklu tahmin modelleri elde edilmiştir.

Veri ön işleme adımlarından sonra PPD-EPC verisi %90 eğitim, %5 doğrulama, %5 test olarak bölünmüş ve değer kestirimi için regresyon modelleri oluşturulmuştur. Model performanslarını ölçmek için R^2 , düzeltilmiş R^2 , MAE, MAPE ve RMSE gibi çeşitli doğruluk metrikleri kullanılmıştır. Regresyon analizinin sonuçlarına



Şekil 2.26 : Büyük Londra bölgesindeki değer bölgelerinin dağılımı.

bakıldığında lokal Rastgele Orman algoritmasının tüm kümelerde en yüksek tahmin doğruluğuna erişen yöntem olduğu görülmektedir (Çizelge 2.11). Öte yandan aynı çalışma bölgesinde gerçekleştirilen global regresyon analizi sonuçlarının, kümeleme analizi sonrası oluşturulan lokal regresyon modelleri ile iyileştirildiği gözlemlenmiştir. Böylelikle konumsal bağımlılığın bulunduğu, durağan olmayan veriler için kolaylıkla kullanılacak yüksek tahmin doğruluğuna sahip bir toplu değerlendirme yaklaşımı geliştirilmiştir. Değer bölgelerine özgü kriter önemlerini ifade eden SHAP özet grafikleri EKLER bölümünde verilmiştir.

2.9.8 Toplu değerlendirme modellerinde genelleştirilebilirliğin incelenmesi

CBS ve Makine Öğrenmesi yöntemlerinin bütünleştirilmesiyle geliştirilen toplu değerlendirme modelinin genelleştirilebilirliğinin incelenmesi amacıyla Birleşik Krallık'tan sonra ülkemizde İstanbul ve İzmir şehirleri için de bir uygulama gerçekleştirilmiştir. Bu kapsamda ilgili şehirlere ait açık coğrafi veriler OSM, İstanbul Büyükşehir Belediyesi Açık Veri Portalı ve İzmir Büyükşehir Belediyesi Açık Veri Portalı üzerinden temin edilmiştir.

Çizelge 2.11 : Lokal regresyon modelinin doğruluk metrikleri.

Küme	Örnek	R ²	Düz. R ²	MAE	MBE	MAPE	RMSE
1	639.866	0,8773	0,8771	68491,3522	433,4956	0,1683	71468,3716
2	2.457.593	0,8722	0,8721	33160,7989	464,2163	0,1777	61798,1124
3	1.963.335	0,8625	0,8623	31199,4703	254,0650	0,1395	65611,0688
4	286.208	0,8264	0,8263	38587,9652	557,9056	0,1900	98211,9713
5	279.927	0,8707	0,7906	65367,1736	426,2945	0,1607	70178,1274

Değerleme verisi olarak da bir emlak listeleme şirketinin satış ilanları verisi kullanılmıştır (Çizelge 2.12).

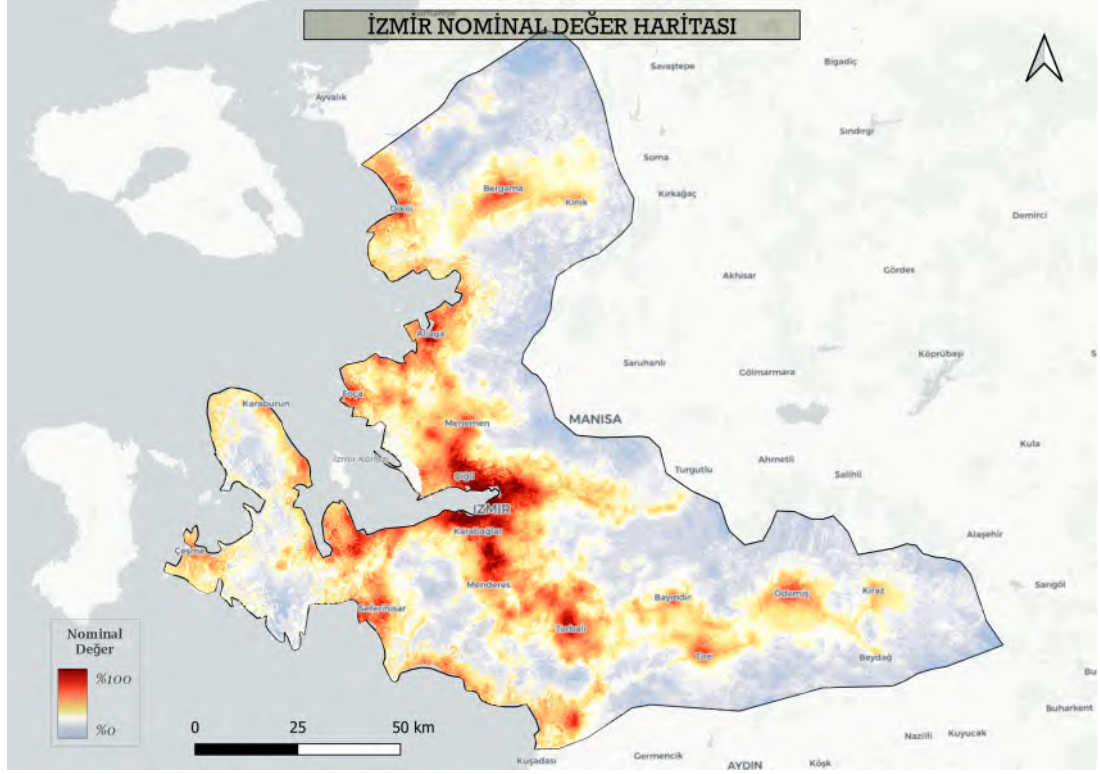
Değeri etkileyen kriterlere göre veriler elde edildikten sonra yakınlık, yüzey ve görünürlük analizleri QGIS açık kaynaklı CBS yazılımı kullanılarak gerçekleştirilmiştir. Analizler sonucunda her bir kriterin piksel değeri lineer ölçeklendirme ile normalize edilmiş, nominal puanların yüzde cinsinden yeniden sınıflandırması yapılmıştır. Sonuç olarak Nominal Değerleme Yöntemi kullanılarak 10 metre çözünürlüklü arsa değer haritaları üretilmiştir (Şekil 2.27 ve Şekil 2.28).



Şekil 2.27 : İstanbul İline ait Nominal Arsa Değer Haritası.

Çizelge 2.12 : Emlak listeleme şirketine ait değerlendirme verisinin tanımlayıcı istatistikleri.

Kriter	Ortalama	Standart Sapma	Minimum	%25	%50	%75	Maksimum
fiyat	896703,5	2434319	8250	243000	380000	750000	65000000
brutm2	146,0534	140,9786	21	100	125	155	7196
netm2	122,3306	90,49892	20	90	110	135	7195
banyosayisi	1,570434	0,777105	0	1	1	2	6
interkom	0,434064	0,495637	0	0	0	1	1
depremuygunluk	0,212683	0,409208	0	0	0	0	1
asansor	0,507222	0,499952	0	0	1	1	1
cocukoyunalani	0,132919	0,33949	0	0	0	0	1
giyinmeodasi	0,135246	0,341989	0	0	0	0	1
ebeveynbanyosu	0,322959	0,467611	0	0	0	1	1
avm	37,14334	31,74168	0	12,06847	29,666	60,41298	100
egitim	66,73777	26,80029	0	50,59322	72,26038	89,51364	100
hastane	52,22273	31,97278	0	21,62084	55,09015	79,41358	100
havalimani	7,866217	18,13438	0	0	0	6,269788	89,02721
iskele	10,93368	17,13076	0	0	2,372334	14,88746	95
metrobus	6,900514	11,93495	0	0	0	12,0301	73,33333
rayli	25,49307	29,2267	0	0	12,98622	43,59431	100
saglik	53,3476	28,1469	0	36,59567	50,5272	73,43171	100
universite	39,55837	31,03082	0	17,88994	26,37215	67,06751	100
yesilalan	79,80196	24,50412	0	75,67368	89,63134	95,69412	100

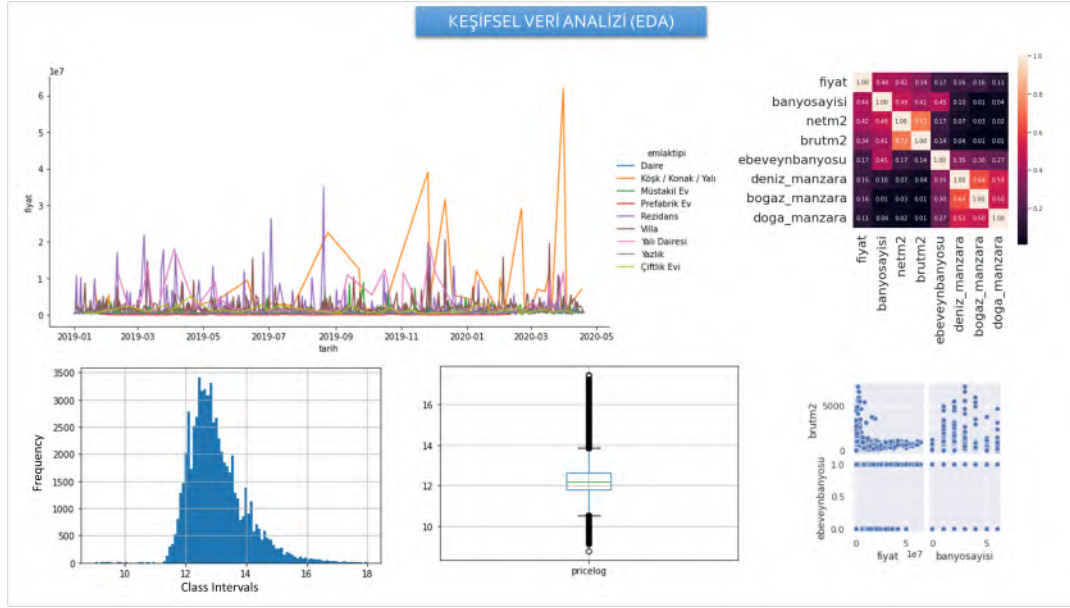


Şekil 2.28 : İzmir İline ait Nominal Arsa Değer Haritası.

Kriterlere ait nominal değerlerin her bir taşınmaza öznitelik olarak eklenmesi amacıyla konumsal birleştirme (spatial join) işlemi uygulanmış, taşınmazların konumlarına isabet eden alandaki coğrafi kriter değerleri ile değerlendirme verisi zenginleştirilmiştir. İşlem sonucunda elde edilen veri CSV formatında kaydedilerek Makine Öğrenmesi kapsamında analize hazır hale getirilmiştir.

Makine Öğrenmesi kapsamında ilk olarak veri Python Jupyter Notebook ortamında içe aktarılarak veri ön işleme adımı uygulanmıştır. İstanbul ve İzmir illerine ait değerlendirme verileri hakkında detaylı bilgi elde edilmesi için keşifsel veri analizi gerçekleştirilerek tanımlayıcı istatistikler (minimum, maksimum, ortalama, standart sapma vb.) hesaplanmış, verideki boş (null) değerler kontrol edilerek korelasyon matrisi, histogram, kutu grafiği, dağılım grafiği, ikili karşılaştırma grafikleri oluşturulmuştur (Şekil 2.29). Değerleme veri setinde 64.573 satır ve farklı kategorik ile sayısal veri türlerine sahip 21 sütun bulunmaktadır.

Özellik mühendisliği aşamasında aykırı değer tespiti, eksik verilerin tamamlanması, kategorik verilerin kodlanması ve özellik seçimi gibi işlemler yapılmıştır. Aykırı değerler verilerde sapmalara sebep olarak regresyon analizinde zayıf uyuma neden olmaktadır. Çalışmada, 3-sigma standart sapma uzaklık değeri uygulanarak aykırı



Şekil 2.29 : Değerleme verisine ait keşifsel veri analizi.

değerler tespit edilmiş ve veri setinden kaldırılmıştır. Ayrıca ortanca ve ortalama değer istatistikleri kullanılarak verideki eksik değerler makul bir yaklaşım ile doldurulmuştur. Ayrıca veride bulunan oda sayısı, emlak tipi (daire, villa, müstakil, rezidans vb.), bina yaşı, bulunduğu kat, bina kat sayısı, ısıtma tipi (doğalgaz, merkezi sistem, soba vb.), otopark (açık, kapalı, cadde vb.) gibi kategorik öznitelikler kodlanarak sayısal hale dönüştürülmüştür. Bu öznitelikleri Makine Öğrenmesi regresyon modellerinde kullanmak üzere hazır hale getirmek için One Hot Encoding kodlama yöntemi uygulanmış ve nominal değişkenler sayısal bir dizi oluşturacak şekilde kodlanmıştır.


Veri ön işleme adımlarından sonra veriler %80 eğitim, %20 test olarak bölünmüş ve değer kestirimi için Lineer Regresyon, XGBoost, CatBoost, LightGBM, Rastgele Orman gibi çeşitli regresyon modelleri oluşturulmuştur. Model performanslarını ölçmek için R^2 , düzeltilmiş R^2 , MAE, MAPE ve RMSE gibi çeşitli doğruluk metrikleri kullanılmıştır.

Eğitilen regresyon modelleri kullanılarak doğrulama verileri üzerinde tahminleme gerçekleştirilmiş, çeşitli doğruluk metrikleri hesaplanmıştır. Regresyon analizinin sonuçlarına bakıldığında Rastgele Orman algoritmasının doğruluk açısından diğer modellere göre daha iyi performans gösterdiği görülmüştür (Çizelge 2.13).

Çizelge 2.13 : Regresyon modellerinin doğruluk metrikleri.

Model	R ²	Düz. R ²	MAE	MAPE	RMSE
XGBoost	0,8699	0,8698	50294,2818	0,1557	411728,5698
CatBoost	0,8380	0,8379	56668,9762	0,1660	478740,2277
LightGBM	0,8058	0,8058	65567,8885	0,1988	499042,0076
RastgeleOrman	0,8802	0,8801	44832,3619	0,1334	342449,6063

Özellik seçiminin bir parçası olan özneliklerin önem skorları, bir değişkenin tahmin sürecini ne kadar etkilediğini yorumlamak için kullanılmaktadır. Çalışmada regresyon modelleri için permütasyon önem skorları hesaplanmıştır (Şekil 2.30).




Şekil 2.30 : İstanbul ve İzmir çalışma alanları için permütasyon tabanlı kriter önem skorları.

CBS ve Makine Öğrenmesi Yöntemlerinin bütünleştirilmesi ile Birleşik Krallık bölgesinde PPD-EPC verileri kullanılarak gerçekleştirilen toplu değerlendirme çalışması sonrasında elde edilen modelin geliştirilebilir olup olmadığını incelemek amacıyla aynı yöntem ülkemizde İstanbul ve İzmir şehirleri için uygulanmıştır. Sonuçlara bakıldığında Topluluk Öğrenmesi regresyon modellerinin performansları, CBS analizleri sonucunda elde edilen konumsal verilerle öznelik zenginleştirilmesi yapıldığında önemli derecede artmaktadır. İki farklı çalışma bölgesinde, farklı veriler kullanılarak gerçekleştirilen çalışmada önerilen hibrit yöntem ile uygulanan regresyon modellerinin doğruluk analizi sonuçlarına dayanarak geliştirilebilir olduğu sonucuna varılmıştır.

2.10 Arsa ve Bina Değerlerinin Ayırt Edilmesi

Yapılı bir taşınmazın değeri binanın maliyet değeri ile üzerinde bulunduğu arsanın değerinin toplamı şeklinde ifade edilmektedir (Şekil 2.31). Fakat pratikte taşınmazın topyekün değeri belirlenerek arsa-bina değeri ayırımı yapılmadığı görülmektedir. Nitekim tamamen aynı fiziksel özelliklere sahip farklı konumlarda bulunan iki konutun değeri arsaya özgü faktörlerden ötürü oldukça farklı olabilmektedir. Bu durumun en çarpıcı örneği İstanbul ilindeki bir daire ile Anadolu'da aynı özellikteki bir daire arasındaki fiyat farkıdır.



$$\text{TAŞINMAZIN TOPLAM DEĞERİ} = \text{ARSA DEĞERİ} + \text{BİNA DEĞERİ}$$

Şekil 2.31 : Taşınmazın toplam değerini oluşturan arsa ve yapı bileşenleri.

Ülkemizde binalar için vergi değeri 1319 sayılı Emlak Vergisi Kanununun 29'uncu maddesinin birinci fıkrasının (b) bendi uyarınca bina metrekare normal inşaat maliyetleri ile arsa veya arsa payı esas alınarak hesaplanmaktadır (Resmi Gazete, 1970). Bina metrekare normal inşaat maliyet bedelleri her yıl Hazine ve Maliye Bakanlığı ile Çevre, Şehircilik ve İklim Değişikliği Bakanlığınca müştereken

belirlenerek Emlak Vergisi Kanunu Genel Tebliği ekinde paylaşılmaktadır. İnşaat maliyet cetvelleri, yapıların yaklaşık maliyetlerini ve yıpranma paylarını hesaplamak için bir rehber niteliği taşımaktadır. Arsa değerleri ise 213 sayılı Vergi Usul Kanununun asgari ölçüde birim değer tespitine ilişkin hükümlerine göre takdir komisyonlarınca dört yılda bir sokak bazında belirlenmektedir. Sonuç olarak binaların emlak vergisi hesabı için arsa ve bina değerlerine ihtiyaç duyulmaktadır. Öte yandan Çevre, Şehircilik ve İklim Değişikliği Bakanlığı tarafından periyodik olarak Resmi Gazete’de yayımlanan "Mimarlık ve Mühendislik Hizmet Bedellerinin Hesabında Kullanılacak Yapı Yaklaşık Birim Maliyetleri Hakkında Tebliğ" ile yapıların mimarlık hizmetlerine esas olan sınıflarına göre ortalama birim maliyetleri KDV hariç, genel giderler (%15) ile yüklenici karı (%10) dahil edilerek paylaşılmaktadır. Bina inşaat maliyetleri bu tebliğe dayanarak yapı türü, bina yüksekliği gibi özelliklere göre yaklaşık bir şekilde hesaplanabilmektedir. Bina maliyet hesabı için kullanılacak bir diğer kaynak ise Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, Yüksek Fen Kurulu Başkanlığı tarafından paylaşılan İnşaat Birim Fiyatlarına Esas İşçilik-Araç ve Gereç Rayiç Listeleridir. Yapıların inşaat türüne özgü her bir imalat cinsine ait poz numarası ve birim fiyatların paylaşıldığı liste ile binalar için yaklaşık maliyet hesabının yapılması mümkündür.

Arsa ve bina değerlerinin ayrıştırılması amacıyla müstakil ve 100 m² yüzölçümüne sahip bir betonarme konutun maliyeti İnşaat Mühendisleri Odası’nın pratik hesaplamaya esas metraj birim ölçüleri tablosu baz alınarak birim fiyat rayiç listesi yardımıyla hesaplanmıştır (IMO, 2022). Betonarme karkas binanın inşaat maliyeti hesabı için piyasada en çok tercih edilen kalite ve ebatlarda malzemelerin kullanılacağı kabulü yapılarak yaklaşık maliyet toplam 325.162,83 TL hesaplanmıştır (EK 5). Yüksek Fen Kurulu Başkanlığının rayiç listelerine göre yapılan hesabı karşılaştırmak amacıyla Emlak Vergisi Kanunu Genel Tebliği’nde yer alan normal inşaat maliyet bedelleri ile Çevre, Şehircilik ve İklim Değişikliği Bakanlığı’nın yapı yaklaşık birim maliyetleri cetvelleri kullanılmış, aynı nitelikte inşa edilecek bir konutun maliyeti hesaplandıktan sonra elde edilen yaklaşık maliyetlerin birbirlerine yakın değerlere sahip olduğu görülmüştür (Çizelge 2.14).

Yapı yaklaşık maliyetinin rayiç listelere göre detaylı bir şekilde hesaplanabilmesi, arsa ve bina değerlerinin ayrıştırılmasını oldukça kolaylaştırmaktadır. Öte yandan

Çizelge 2.14 : Yapı yaklaşık inşaat maliyetlerinin hesabında kullanılan cetvellerin hesap karşılaştırması.

No	Maliyet Cetveli	Dönem	Maliyet (TL)
1	Normal İnşaat Maliyet Bedelleri	2023	236.786
2	Mimarlık ve Mühendislik Hizmet Bedellerinin Hesabında Kullanılacak Yapı Yaklaşık Birim Maliyetleri	2022/2	320.000
3	İnşaat Birim Fiyatlarına Esas İşçilik – Araç ve Gereç Rayiç Listeleri	2022/3	325.162

taşınmazları sahip oldukları fiziksel, konumsal, yasal ve sosyo-ekonomik özellikleri göz önünde bulundurarak objektif bir şekilde değerlendirebilmek için arsa değerlerine ihtiyaç bulunmaktadır. Ülkemizde kentsel alanlardaki boş arsaların az olması ve taşınmazların gerçek satış değerlerine erişemedeki zorluklar sebebiyle arsa-bina değeri ayrıştırma çalışması gerçekleştirilememiştir. Yapılı taşınmazlarda arsa ve yapı değeri ayrımını sağlıklı bir şekilde yapabilmek için daha hassas yöntemlere ihtiyaç bulunmaktadır. Arsa-yapı değerlerinin ayrıştırılabilmesi (land-structure value decomposition) amacıyla literatürde çeşitli yöntemler kullanılarak birçok çalışma gerçekleştirilmiştir. Bunlardan en yaygın olanları Hedonik Değerleme (Hedonic Pricing), İndirgenmiş Maliyet Yöntemi (Depreciated Cost Method) ve Arazi Kaldırıcı Yöntemidir (Land Leverage Method) (Bell, Bowman, ve German, 2009; Bostic ve diğ, 2007; Bourassa ve Hoesli, 2022; Knoll, Schularick, ve Steger, 2017; Netzer, 1998; Zhou ve Haurin, 2020).

Hedonik yöntemde boş arsalar için bir regresyon analizi gerçekleştirilerek arsa değeri tahmin modeli oluşturulmaktadır. Böylece kentsel alanlarda yapılı taşınmazların arsa değeri bu model ile kestirilebilmektedir. Hedonik yöntem ile geliştirilen değerlendirme modelinde verilerin çalışma bölgesinde homojen bir şekilde dağılmış olması ve yeterli sayıda örneklem bulunması model doğruluğu açısından oldukça önemlidir. Bu yöntemde dikkat edilmesi gereken en önemli husus boş arsa ile yapılaşmış arsaya ait değişkenlerin ağırlık katsayıları arasında istatistiksel olarak anlamlı bir fark olup olmadığıdır. Bu durumun tespit edilebilmesi amacıyla yapılı ve boş arsalarla yönelik iki farklı hedonik model oluşturulup bağımsız değişkenler için t-testi uygulanabilir (Gedal ve Ellen, 2018; Wentland ve diğ, 2020).

İndirgenmiş Maliyet yönteminde arsa değerlerinin elde edilebilmesi için taşınmazların inşaat maliyet bedelleri hesaplanmakta, sonrasında taşınmazın toplam değerinden

binanın maliyet bedeli çıkarılarak arsa değeri ortaya çıkarılmaktadır (Bourassa ve diğ., 2011; Davis ve diğ., 2021, 2017; Diewert, de Haan, ve Hendriks, 2014). Bu yöntemde inşaat maliyeti hesaplanırken yapının cinsi, sınıfı, yaşı gibi özellikler dikkate alınarak yıpranma payı da ele alınmaktadır. Böylece indirgenmiş yapı maliyeti elde edilerek arsa değerine geçiş sağlanmaktadır. İndirgenmiş Maliyet yönteminde yapının inşaat maliyetinin ve yıpranma durumunun detaylı bir şekilde hesaplanması gerekmektedir. Öte yandan değerlendirme verilerinde genellikle maliyet hesabında kullanılan inşaat sınıfı (lüks, birinci sınıf, ikinci sınıf, üçüncü sınıf, basit), inşaat türü (çelik, betonarme, yığma), duvar tipi (tuğla, taş), çatı tipi (fayans, kiremit, düz çatı) gibi detaylı veriler bulunmamaktadır.

Arazi Kaldırıcı yöntemi ise geçmişte boş arsa niteliğinde olup, sonradan üzerinde bir yapının inşa edildiği taşınmazların ele alındığı bir yaklaşımdır. Bu yöntemde boş arsa değerinin yapıyla taşınmaza oranlanması sonucu arsa değerini ifade eden arazi kaldırıcı katsayısı elde edilmektedir. Bu katsayının büyüklüğü arsanın, taşınmazın bütününe kıyasla sahip olduğu değeri ifade etmektedir. Arazi Kaldırıcı yöntemi bir taşınmazın belli bir zaman dilimindeki yapılaşma durumu sonrası kazandığı değeri direkt olarak sunabildiği için diğer yöntemlere göre daha sağlıklı sonuç vermektedir. Bu yöntemin olumsuz tarafı ise taşınmazların arsa ve yapılaşma sonrası satış değerlerine ulaşmadaki güçlük olarak göze çarpmaktadır.

2.10.1 Yapı inşaat maliyetinin modellenmesi

Tez çalışması kapsamında bir arsanın ve üzerinde bulunan yapının değerlerinin ayrıştırılabilmesi amacıyla Nominal Değerleme ve Makine Öğrenmesi yöntemleri kullanılarak yeni bir yaklaşım geliştirilmiştir. Bu kapsamda konumsal analizler ve regresyon analizi sonucunda arsalar ve konutlar için iki farklı türde toplu değerlendirme modeli kurulmuştur. Arsa değerlendirme modelinde taşınmazın konum, yüzölçümü, yapılaşma koşulları gibi özellikleri dikkate alınmış, geçmiş dönemlerde gerçekleşen gerçek satış değerleri ile eğitilmesi sonucunda yüksek doğruluğa sahip bir tahmin modeli elde edilmiştir. Konut değerlendirme modelinde ise arsa değerini etkileyen faktörlerin yanı sıra, bina tipi (müstakil, apartman, villa vb.), bina yüzölçümü, oda sayısı, bina yaşı, bina enerji verimliliği sınıfı gibi kriterler kullanılmıştır. Böylece oluşturulan iki değerlendirme modeli ile herhangi bir taşınmazın arsa ve konut değerlerinin


ayrı ayrı elde edilmesi sağlanmış, konut değerinden arsa değerinin çıkarılması ile yapının inşaat maliyeti elde edilmiştir.

Ülkemizde taşınmazların gerçek alım-satım değerlerine ulaşmak oldukça zordur. Arsa ve yapı değerlerinin ayrıştırılmasında kullanılan yöntemler detaylı ve güvenilirliği doğrulanmış veriler gerektirmektedir. Bu sebeple geliştirilen yöntem, gerçek satış değerlerinin açık veri olarak paylaşıldığı İngiltere ve Galler ülkelerinde uygulanmıştır. İlk olarak 2011-2019 yılları arasında gerçekleşen satışlara ait veriler arsa ve konut olarak iki ayrı gruba ayrılmıştır. Bölüm 2.7’de gerçekleştirilen konumsal analizlerin sonucunda elde edilen nominal kriter puanları mekansal birleştirme yardımıyla INSPIRE Index Polygons parsel verisine öznitelik olarak eklenmiştir. Daha sonra Makine Öğrenmesi regresyon algoritmaları kullanılarak arsa değerlendirme modeli oluşturulmuştur. Böylelikle yapı taşınmazların değerlerinin elde edilmesi için toplam taşınmaz değerinden arsa değeri çıkarılarak binanın inşaat maliyeti elde edilmiştir. Değerleme modellerinin performans testi için regresyon analizi doğruluk metrikleri kullanılmıştır. Sonuçlara bakıldığında arsa değerlendirme modelinin konut amaçlı değerlendirme modeline göre daha düşük doğruluk değerlerine sahip olduğu, buna karşın toplu değerlendirme çalışması için yeterli doğruluğa erişildiği görülmüştür (Çizelge 2.15). Arsa değerini etkileyen kriterlerin önem derecelerini ortaya çıkarmak için permutasyon (Şekil 2.32) ve SHAP (Şekil 2.33) tabanlı önem skorları hesaplanmıştır.


Çizelge 2.15 : Arsa değerlemesi için oluşturulan regresyon modellerinin doğruluk metrikleri.

Model	R ²	Düz. R ²	MAE	MAPE	RMSE
XGBoost	0,5626	0,5625	808267,1438	0,3306	2733992,0111
CatBoost	0,5226	0,5225	829765,0542	0,3611	2968592,0238
LightGBM	0,5261	0,5260	827917,4917	0,3577	2943121,7851
RastgeleOrman	0,5896	0,5895	694609,7246	0,3168	2309142,8275

CBS tabanlı bütünleşik Nominal Değerleme ve Makine Öğrenmesi yöntemi ile elde edilen bina maliyet değerleri BCIS tarafından sunulan yeniden inşa maliyeti hesaplama aracı kullanılarak test edilmiştir. BCIS, binaların yaşı, inşaat sınıfı, dıştan dışa yüz ölçümü, yapı nizamı, kat sayısı, oda sayısı, banyo sayısı, duvar tipi, çatı tipi, garaj, sığınak gibi özelliklerini dikkate alarak bölgeye özgü maliyet modellemesi yapmaktadır (BCIS, 2022). Altmış yıllık birikimi ile maliyet planlaması, proje yönetimi, yeniden inşa maliyeti, sigorta değeri hesabı gibi alanlarda hizmet veren



Şekil 2.32 : Arsa değerlendirme modeline ait permütasyon tabanlı kriter önem skorları.



Şekil 2.33 : Arsa değerlendirme modelindeki kriterlere ait SHAP değerleri.

BCIS, profesyonel kullanım için belli ücretlere sahip paketler sunmaktadır. Ücretsiz maliyet hesabı planında sadece dört taşınmazın sorgulanmasına imkan verilmektedir. BCIS ile maliyet hesabı kapsamında İngiltere’de dört farklı bölgede yapılı arsa

seçilmiştir. Seçilen taşınmazlara ait toplam taşınmaz değeri ve arsa değeri geliştirilen maliyet yöntemi ile analiz edilerek kestirilmiş, bu yaklaşımın test edilmesi için BCIS ile maliyet hesabı yapılmıştır (Şekil 2.34). Sonuçlara bakıldığında CBS destekli Nominal Değerleme ve Makine Öğrenmesi yöntemleri ile geliştirilen yaklaşımın yapı taşınmazlarda arsa ve bina değerlerinin ayrıştırılması amacıyla kullanılabileceği ortaya konmuştur (Çizelge 2.16).

BCIS®
BCIS Rebuild Calculator Results

Estimate of Rebuilding Cost from BCIS.

The rebuilding cost is estimated to be £193,000 based on the information and assumptions listed below (1).

Quality and facilities make a big difference to the rebuilding cost. While the figure above is a reasonable estimate of the likely cost for a good quality house with typical facilities, a basic quality house of the same size with minimal facilities might be rebuilt for £161,000 while an excellent quality house might cost £254,000 to rebuild.

The information we based this estimate on was:
Semi-detached 2 storey house built with brick external walls (2) and tile roof built around 2013 (3). The property is not listed and does not include any special or unusual features.
Postcode B18 5DN.
Gross external floor area: 70m² (4).
1 bathrooms.
No separate garage.

BCIS has assumed the following:
There is no cellar.
An allowance for external works has been made which might typically comprise drive or hardstanding, paths and patio, walls and fences, drainage. However there can be big differences in the scale and cost. Special or unusual features, such as long boundary walls, swimming pools etc have not been allowed for.

The prices used are for August 2022. This report was generated at 20:17:54 on 26-Aug-2022.

Şekil 2.34 : İngiltere’de seçilen yapıyı bir taşınmaza ait BCIS maliyet hesabı raporu.

Çizelge 2.16 : Maliyet modellemesi sonucunun BCIS modeli ile kıyaslanması.

Taşınmaz	1	2	3	4
Arsa Yüzölçümü (m^2)	237,76	253,20	837,22	229,90
Bina Yüzölçümü (m^2)	100,00	100,00	118,00	70,00
Yapı Nizamı	Ayrık	İkiz	İkiz	İkiz
Kat Sayısı	2	2	2	2
Oda Sayısı	7	5	6	4
Banyo Sayısı	1	1	1	1
Duvar Tipi	Tuğla	Tuğla	Tuğla	Tuğla
Çatı Tipi	Kiremit	Taş	Taş	Kiremit
Garaj	Yok	Yok	Yok	Yok
İnşa Yılı	1972	1975	2003	2013
Taşınmazın Toplam Değeri (£)	503.127	340.153	553.233	504.586
Arsa Değeri (£)	202.218	90.037	317.096	289.777
İndirgenmiş Bina Değeri (£)	300.909	250.116	236.137	214.809
BCIS Yeniden İnşa Maliyeti (£)	267.000	228.000	218.000	193.000
Fark (%)	12,7	9,7	8,3	11,3

2.11 Web Tabanlı Taşınmaz Değerleme Bilgi Portalının Geliştirilmesi

Coğrafi verilerden analizler sonucu elde edilen ürünün kullanıcılara sunulması, CBS'nin önemli adımlarından biridir. Bu sonuçların kullanıcılara ulaştırılabilmesi için çeşitli yöntemler bulunmaktadır. Günümüzde veri ve bilgiye zaman ve mekandan bağımsız ulaşabilmek amacıyla masaüstü sistemler yerine web çözümleri ile bulut bilişim sistemlerinin yaygınlaştığı görülmektedir.

Coğrafi verilerin internet üzerinden paylaşılması kapsamında çeşitli standartlarda geliştirilmiş web servisleri kullanılmaktadır. Tez çalışmasında taşınmaz değerlendirme veri ve haritalarının kullanıcılarla dinamik olarak paylaşılması için bulut üzerinde açık kaynaklı CBS araçları kullanılmıştır. Verilerin web üzerinden paylaşılması amacıyla hem geleneksel sunucu-istemci yapısı kullanılmış, hem de bulut bilişimde yenilikçi bir yaklaşım olan sunucusuz mimariler ile verilerin üçüncü kullanıcılara aktarılması sağlanarak performans, maliyet gibi unsurların karşılaştırması yapılmıştır.

2.11.1 Coğrafi veri sunucusunun hazırlanması

Sunuculu mimaride ilk olarak EC2 bulut sunucusu üzerinde CBS altyapısının oluşturulması için AWS üzerinde sanal makine kurulmuştur. İşlem adımları sırasıyla; i) işletim sistemini kurmak için bir Amazon Makine Görüntüsü seçme, ii) sanal sunucu türünü seçme, iii) sunucu yapılandırma, iv) depolama alanı ekleme, v) sunucu etiketleme ve vi) güvenlik yapılandırması şeklindedir. Gerekli işlemler tamamlandıktan sonra AWS EC2 üzerinde Ubuntu Linux işletim sistemi ile "t2.micro" bulut sunucusu oluşturulmuştur. Bu sunucuya Güvenli Kabuk Bağlantısı ile komut satırı arabirimi üzerinden erişilebilmektedir.

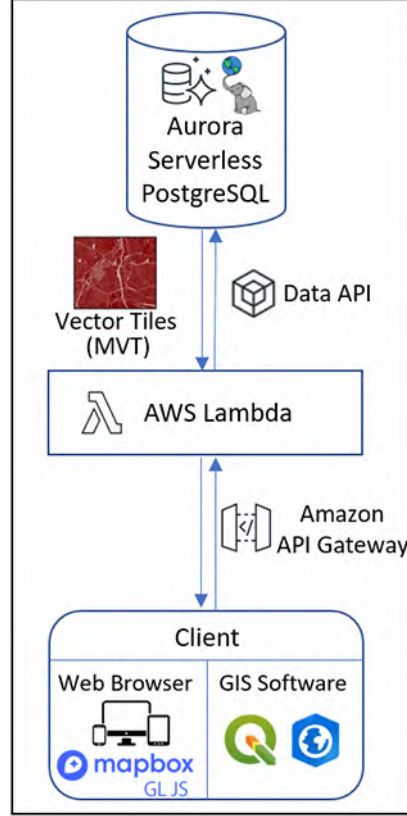
Verileri bulut ortamında depolamak için PostgreSQL nesne-ilişkisel açık kaynak veritabanı yönetim sistemi tercih edilmiştir. Bu kapsamda AWS'de Amazon RDS veritabanı sunucusu oluşturulmuş ve coğrafi veri depolamayı etkinleştirmek için PostGIS uzantısıyla birlikte PostgreSQL yüklenmiştir. Daha sonra ilçe ve mahalle sınırları, parsel sınırları, taşınmaz değerlendirme verileri gibi gerekli tüm vektör ve raster veri kümeleri veritabanına yüklenmiştir. Amazon RDS PostgreSQL veritabanını pgAdmin ve etkileşimli psql terminali kullanarak yönetmek mümkündür.

EC2 ve RDS uygulamaları kurulduktan sonra, veri paylaşımını sağlamak için Java tabanlı, açık kaynaklı coğrafi veri sunucusu olan GeoServer, EC2 bulut sürücüsüne yüklenmiştir. GeoServer ile veri paylaşımı ve veri işleme amaçlı WFS, WMS, WMTS, WCS gibi OGC standartlarının kullanımı mümkündür. GeoServer birlikte çalışabilirlik kapsamında Shapefile, GeoPackage ve GeoTIFF gibi birçok veri formatını desteklemektedir. Ayrıca PostGIS verilerinin dinamik olarak depolanmasına ve yayınlanmasına olanak sağlamaktadır. Bu amaçla PostgreSQL / PostGIS veritabanında depolanan taşınmaz verilerinin OGC servisi olarak yayınlanması için GeoServer'da Amazon RDS bulut veritabanı sunucusuna bağlanarak taşınmaz değerlendirme veri ve haritalarına erişim sağlanmıştır. Nominal değerlendirme verileri GeoServer'ın GeoWebCache eklentisi kullanılarak WMTS formatında (256X256) piksel boyutunda raster görüntü kareleri (tile) şeklinde sunulmuştur. Öte yandan parsel verileri gibi büyük boyutlu vektör verilerin web üzerinde görüntülenmesi sırasında verimliliği artırmak için GeoServer'ın Vector Tiles eklentisi kullanılarak Mapbox Vector Tiles (MVT) formatında yayınlanmıştır.

Diğer bir veri dağıtım modeli olan sunucusuz bulut mimarisinde CBS uygulamalarını koşturmak için EC2 gibi bir sanal makine oluşturmaya gerek yoktur. Bu nedenle sistem yönetimi, yazılım kurulumları/güncellemeleri ve bakım gibi tüm işlemler bulut sağlayıcısı tarafından yürütülmektedir. AWS'de sunucusuz açık kaynaklı bir konumsal bilgi sistemi altyapısının oluşturulması kapsamında coğrafi verilerin depolanması, analizi ve web servisleriyle paylaşılmasını sağlamak için Aurora Serverless PostgreSQL veritabanı ve PostGIS eklentisi kullanılmıştır. İlçe ve mahalle idari sınırları, parsel sınırları, taşınmaz değerlendirme verileri gibi gerekli tüm vektör ve raster veri setleri veri tabanına aktarılmıştır. Aurora Sunucusuz PostgreSQL veritabanına aynı Sanal Özel Bulut (Virtual Private Cloud - VPC) içerisinde RDS Sorgu Editörü, SSH Tüneli veya VPN bağlantısı kullanılarak erişmek mümkündür.

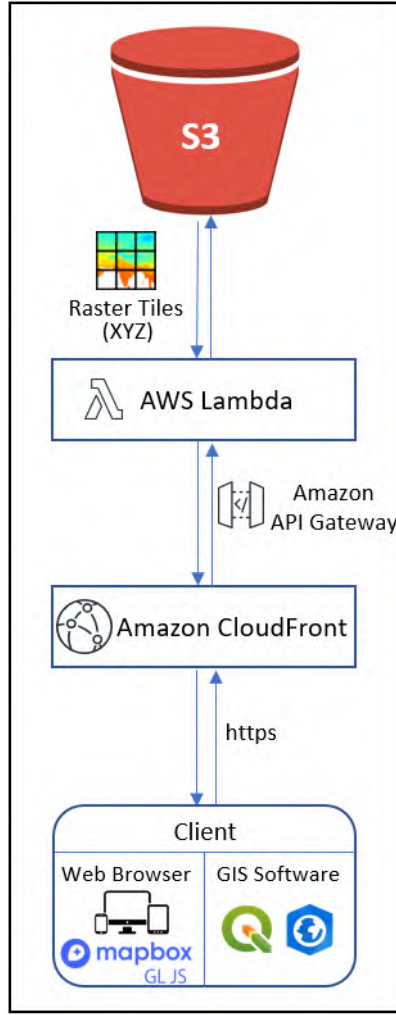
Veritabanının kurulmasından sonra web üzerinde büyük boyutlu vektör verilerin görüntülenmesi aşamasında verimliliği artırmak için parsel verisi MVT formatında yayınlanmıştır. Vektör veri kareleri PostGIS ST_AsMVTGeom() ve ST_AsMVT() fonksiyonları kullanılarak doğrudan veritabanından dinamik olarak sunulmuştur. Bu yeni mimari GeoServer, MapServer veya Mapnik gibi herhangi bir ara sunucu yazılımı kurmayı gerektirmeden harita isteklerini SQL sorgusuna dönüştürmek için bir veri

kareleme servisi kullanmaktadır (Ramsey, 2019). Web tarayıcısından bir kareleme isteği geldiğinde AWS API Gateway bu API çağrısını AWS Lambda'ya aktararak istenen karelemenin konum ve diğer bilgilerinin kontrol edilmesini sağlar. Ardından SQL sorgularını çalıştırmak için güvenli bir HTTP uç noktası sağlayan Data API aracılığıyla bu belirtilen karelemeyi veritabanından çağırır. Böylece istenen bölgeye ait vektör veri kareleri istemciye geri gönderilir (Şekil 2.35).



Şekil 2.35 : Sunucusuz bulut mimarisi ile vektör veri karelerinin paylaşımı için geliştirilen sistemin iş akışı.

Öte yandan raster tabanlı arsa değer haritalarının coğrafi web servisi olarak paylaşılması için QGIS'te "Generate XYZ Tiles (MBTiles)" aracı kullanılarak MBTiles formatında raster görüntü kareleri oluşturulmuş ve Amazon S3 obje depolama alanına (bucket) yüklenmiştir. Nesne ayarları ve paylaşım ilkeleri (genel erişim, CORS gibi) yapılandırılarak veri kareleri S3 ve Lambda hizmetleri aracılığıyla sunucusuz olarak paylaşılmıştır. Verilerin kullanıcı tarafında görüntülenme hızını artırmak amacıyla AWS CloudFront Content Delivery Network (CDN) kullanılarak uç önbelleğe alma etkinleştirilmiştir (Şekil 2.36). Önceden oluşturulmuş raster görüntü karelerinin yakınlaştırma düzeyi ve x/y koordinatlarını içeren web servisine XYZ veri kareleme protokolü aracılığıyla erişilebilmektedir.



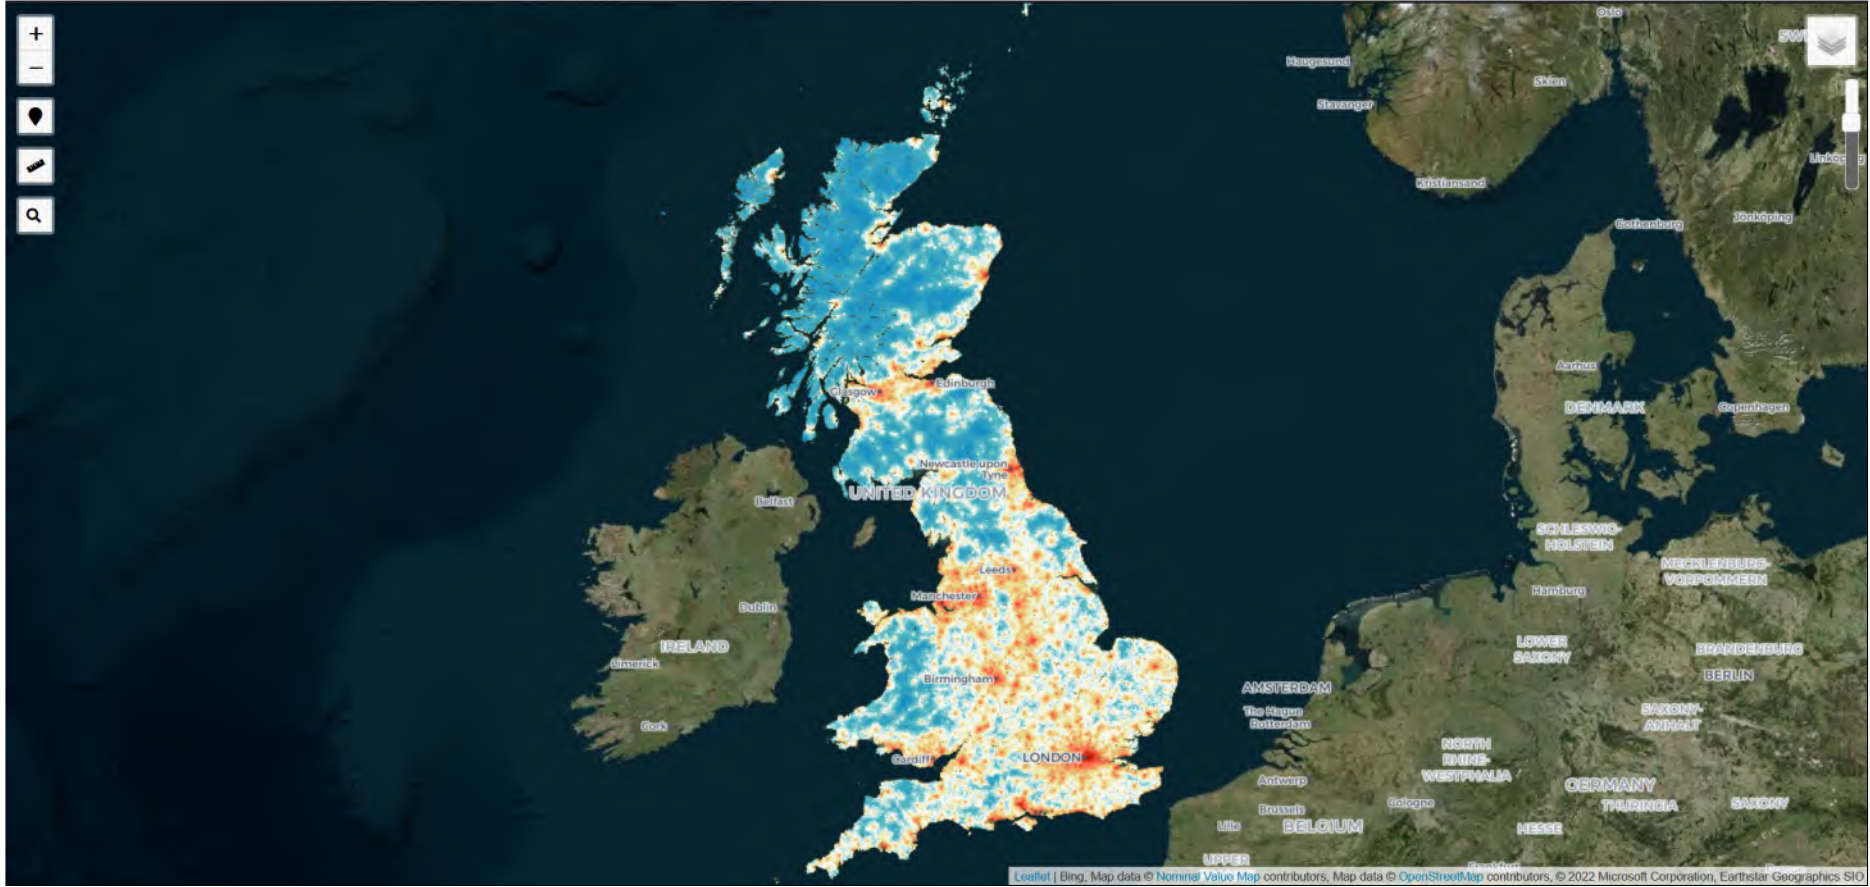
Şekil 2.36 : Sunucusuz bulut mimarisi ile raster veri karelerinin paylaşımı için geliştirilen sistemin iş akışı.

2.11.2 Web harita kütüphanesi ile portalın geliştirilmesi


Web servisleri ile yayınlanan coğrafi verilere masaüstü CBS yazılımları (QGIS, ArcGIS vb.) veya web haritalama kütüphaneleri kullanılarak tarayıcılar üzerinde erişilebilmektedir. Web tarayıcısı ile haritaların görüntülenebilmesi için ArcGIS API for JavaScript, Leaflet, OpenLayers, Mapbox GL JS gibi birçok JavaScript harita kütüphanesi bulunmaktadır. Tez çalışması kapsamında tasarım, kaynak kodunun okunabilirliği, işlevsel eklentilerin ve ayrıntılı dokümantasyonun bulunması gibi özellikler dikkate alınarak Leaflet ve Mapbox GL JS açık kaynak web haritalama kütüphaneleri kullanılmıştır. Her iki kütüphane de masaüstü ve mobil platformlar için web haritası oluşturma amacıyla Web Grafik Kitaplığını (Web Graphics Library - WebGL) kullanmaktadır. Leaflet JS kullanılarak oluşturulan Büyük Britanya arsa

değer haritası (Şekil 2.37) ve Mapbox GL JS kütüphanesi kullanılarak oluşturulan İstanbul arsa değer haritası (Şekil 2.38), geliştirilen Taşınmaz Değerleme Bilgi Portalı ile web ortamında sunulmuştur.

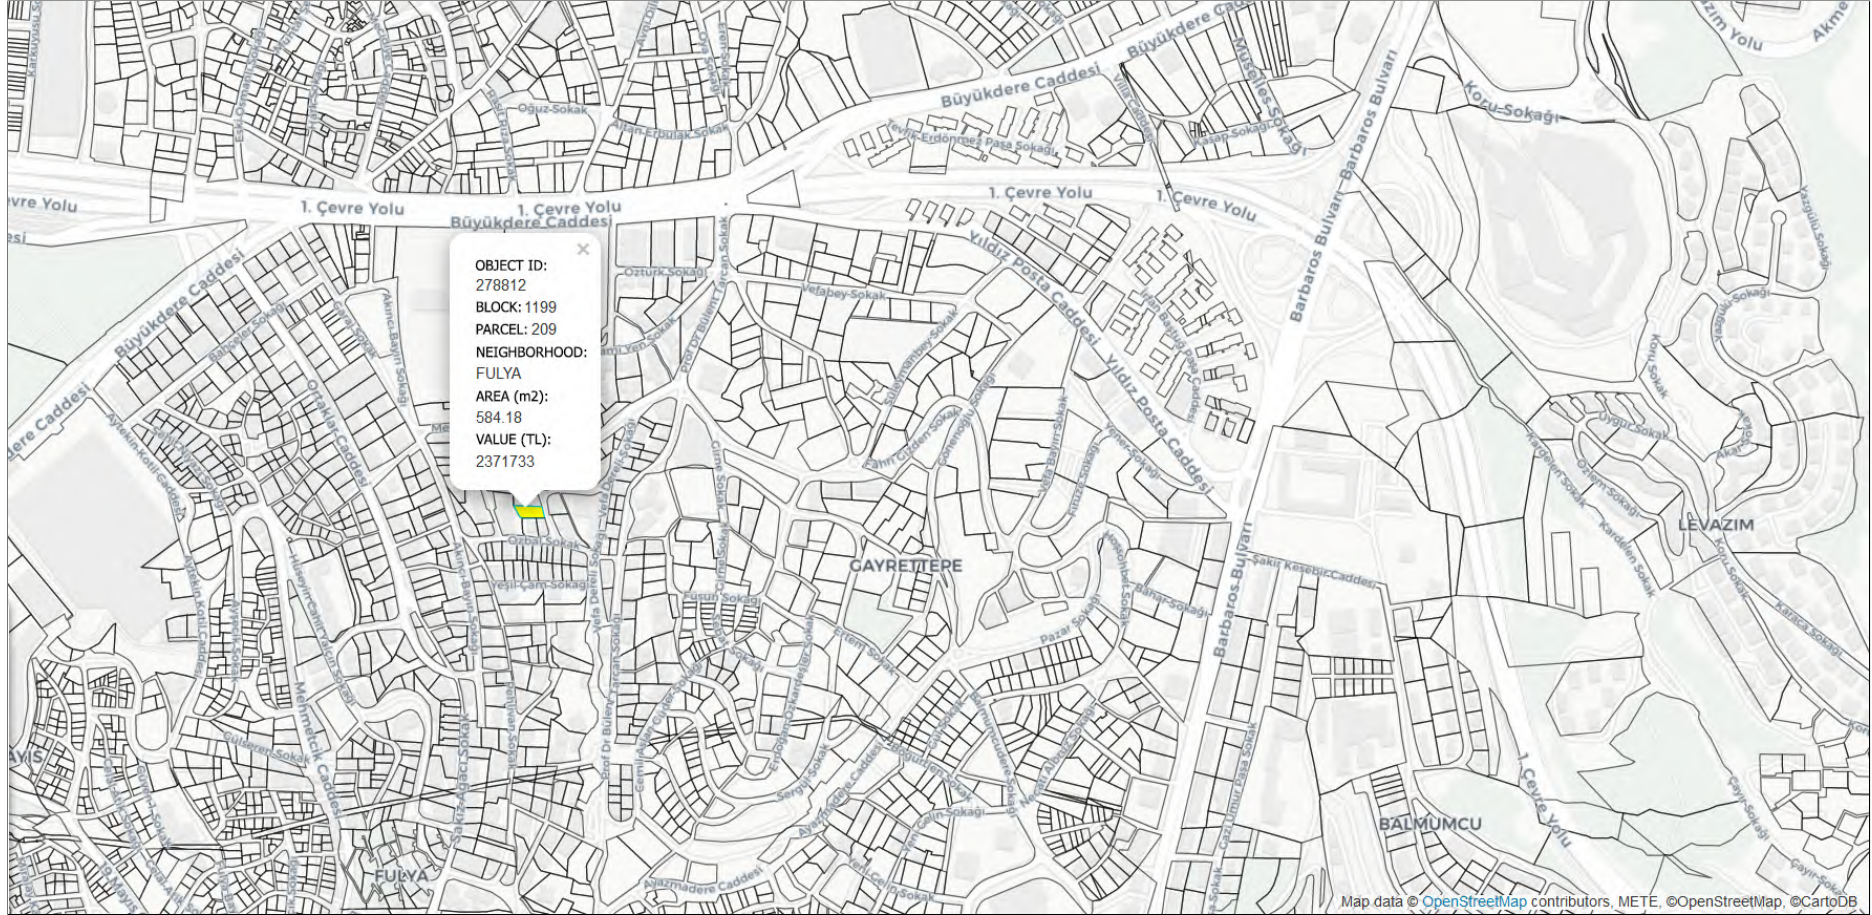
Web harita kütüphaneleri, masaüstü ve mobil platformlarla uyumlu bir şekilde çalışmakta ve işlevselliği artıran birçok eklenti ile özelleştirilebilmektedirler. Leaflet ve Mapbox harita kütüphaneleri kullanılarak Bulut CBS ortamında yayınlanan taşınmaz değerlendirme veri ve haritalarına internet üzerinden dinamik bir şekilde erişilebilmektedir. Kullanıcılar nominal değer haritasını herhangi bir tarayıcı yardımıyla görüntüleyebilmekte, parsel üzerine tıklayarak veya taşınmaza ait bilgileri sorgulayarak bölgedeki herhangi bir parselin mevcut değerini öğrenebilmektedir (Şekil 2.39). Öte yandan uydu görüntüleri, topografik haritalar ve çeşitli vektör haritalar, REST API ve OGC web servisleri ile altlık harita olarak görüntülenebilmektedir. Ayrıca harita üzerinde mesafe ölçme, adres arama ve kullanıcının konum tespiti ile bulunduğu mahallenin emlak değerlerini görüntülemek de mümkündür. Geliştirilen taşınmaz değerlendirme bilgi platformuna <https://web.itu.edu.tr/metemu/nominal> web adresinden erişilebilmektedir.



Şekil 2.37 : Leaflet JS ile geliştirilen Büyük Britanya taşınmaz değerlendirme bilgi portalı.



Şekil 2.38 : Mapbox GL JS ile geliştirilen İstanbul taşınmaz değerlendirme bilgi portalı.



Şekil 2.39 : Taşınmaz değerlendirme bilgi portalı üzerinden taşınmaz bilgilerine erişim.

3. BULGULAR

LADM Değerleme Bilgi Modeli, klasik ve toplu değerlendirme çalışmaları için geliştirilebilir, temel bir kavramsal model sunmaktadır. Ükelere özgü mevcut durumların ve önerilen arazi idaresi yaklaşımlarının modellenmesi için bir ülke profiline ihtiyaç bulunmaktadır. Büyük Britanya'da yer alan ülkelerin bütüncül bir toplu değerlendirme sisteminin bulunmaması sebebiyle bu tez çalışmasında LADM_VM'nin özelleştirilmesi ile taşınmaz değerlendirme amaçlı ülke profili geliştirilmiş, bu eksikliğin giderilmesi sağlanmıştır. Kavramsal model sayesinde taşınmaz değerlendirme süreçleri ile ilgili kurumların sistemleri birlikte çalışabilir hale gelmiştir.

Taşınmaz değerini etkileyen coğrafi kriterlerin yakınlık, yüzey ve görünürlük analizleri CBS yardımıyla gerçekleştirilebilmektedir. Öte yandan ülke, şehir ölçeğindeki geniş çalışma alanlarında gerçekleştirilen toplu değerlendirme çalışmalarında çok sayıda kriterin analizinde otomasyona ihtiyaç duyulmaktadır. Açık kaynaklı CBS yazılımı QGIS'in Python API arayüzü PyQGIS ile çok sayıda konumsal analiz tüm Birleşik Krallık için hızlı ve sorunsuz bir şekilde gerçekleştirilmiştir.

Taşınmaz değer haritaları genellikle il, ilçe, mahalle gibi idari sınırlar ya da posta kodu sınırlarına göre üretilmektedir. Bu ölçekteki haritalar taşınmazlar arasındaki değer farklılıklarını ortaya koymakta yetersiz kalmaktadır. Birleşik Krallık'ta "Heatmap of UK property values" (PrimeLocation, 2021), "ONS House price per square metre and house price per room" (Jennings ve Lewis, 2017), "House Prices per Square Metre" (Powell-Smith, 2018), "Land value estimates for policy appraisal" (Birleşik Krallık Mülkiyet ve Yerel Yönetimler Bakanlığı, 2020), "Property Heatmap" (White, 2021) gibi farklı kuruluşlar tarafından üretilen çeşitli değer haritaları bulunmaktadır. Fakat bu değer haritaları ilçe veya posta kodu sınırları kullanılarak düşük detay seviyesinde üretilmişlerdir. Tez çalışması kapsamında CBS destekli Nominal Değerleme yöntemine dayalı değer haritası Büyük Britanya için 35 kriter ile 25 metre çözünürlükte üretilmiştir. Böylelikle komşu parseller arasındaki değer farklılıkları tüm bölge için ortaya çıkarılmış, yüksek hassasiyetle değerlerin ifade edilmesi sağlanmıştır.

CBS ve Makine Öğrenmesi temelli toplu taşınmaz değerlendirme çalışmalarında bir değerlendirme veri setinin analiz edilerek tahmin modelinin oluşturulabilmesi için benzersiz bir adres tanımlayıcıya veya koordinat bilgisi gibi kesin konum bilgilerine ihtiyaç vardır. PPD ve EPC veri seti, İngiltere ve Galler'de bulunan konut vasıflı taşınmazların satış fiyatlarının yanı sıra, binaların fiziksel özellikleri hakkında faydalı bilgiler içermektedir. Bağlantılı PPD-EPC veri kümesi, adres bilgisi ile LSOA yerel idari bölge bilgilerini içermesine rağmen, koordinat veya benzersiz adres tanımlayıcısı bilgileri eksiktir. PPD-EPC verisini UPRN ile eşleştirmek için, konut adresleri HERE Maps API kullanılarak %99,8 başarı ile coğrafi olarak kodlanmıştır.

Toplu taşınmaz değerlendirme çalışmasında değeri etkileyen kriterlerin ağırlıklarının nesnel bir yaklaşımla belirlenmesi önemli bir problem olarak karşımıza çıkmaktadır. Ağırlık belirlemede literatürde çeşitli yöntemler ve öneriler bulunsa da, bölgesel farklılıkları taşınmaz piyasasının doğal yapısına uygun bir şekilde hesaba katarak belirlemek oldukça zordur. Bu bağlamda Makine Öğrenmesine dayalı regresyon yöntemleri kullanılarak kriter önemleri bölgesel olarak belirlenebilmekte, değer haritaları bu ağırlıklara göre objektif bir şekilde üretilebilmektedir.

Yapay zeka ve Makine Öğrenmesi yöntemleri, geleneksel yaklaşımların yetersiz kaldığı karmaşık problemlerin çözümünde başarılı sonuçlar vermektedir. Taşınmaz değerlendirme de yapay zekanın önemli kullanım alanlarından biridir. Günümüzde taşınmaz teknolojileri olarak adlandırılan PropTech uygulamalarında kümeleme, regresyon, doğal dil işleme, zaman serileri, görüntü işleme gibi yöntemlerin kullanımının arttığı görülmektedir. Tez çalışmasında da global ve kümelendirilmiş lokal regresyon modelleriyle bütüncül bir değerlendirme modeli geliştirilmiştir.

XGBoost, LightGBM, Rastgele Orman gibi topluluk öğrenmesi yöntemleri, konut fiyat tahminleri için yaygın olarak kullanılmaktadır. Bu çalışmada, toplu taşınmaz değerlendirme amacıyla PPD-EPC veri seti üzerinde çeşitli regresyon yöntemleri kullanılmıştır. Regresyon modellerinin performans metrikleri karşılaştırıldığında, Rastgele Orman algoritmasının diğerlerinden daha yüksek doğruluğa sahip olduğu görülmüştür. Ayrıca Çoklu Doğrusal Regresyon değişkenlerin karmaşıklığını açıklamada kaldığı için vasat bir performans göstermiştir. XGBoost, CatBoost ve LightGBM regresyon modelleri Linear Regresyona göre daha iyi sonuçlar verse de, Rastgele Orman algoritmasının doğruluğuna erişememişlerdir. Öte yandan

eđitim için harcanan süreler karşılaştırıldığında, Rastgele Orman modeli en yavaş, LightGBM ise en hızlı model olarak göze çarpmıştır. CBS ve Makine Öğrenmesi yöntemlerinin bütünleştirilmesi değeri etkileyen konumsal verilerin analizinde önemli avantajlar sunmaktadır. Geliştirilen hibrit yöntemle toplu değerlendirme modelinin doğruluđu önemli derecede artırılmıştır. PPD ve EPC verileri değeri etkileyen fiziksel faktörlerle ilgili birçok özneliđe sahip olmasına rağmen, taşınmazın konumsal veya çevresel kriterlerine dair öznelikleri buldurmamaktadır. Öznelik verilerini zenginleştirmek ve tahmin doğruluđunu artırmak için CBS analizleri kullanılmış, yakınlık, yüzey ve görünürlük kriterlerinin nominal puanları veri setine dahil edilmiştir. Veri zenginleştirme işleminden sonra R^2 %38,9 artmış, RMSE ise yaklaşık %48,6 azalmıştır.

Topluluk öğrenmesi ve YSA gibi daha karmaşık modellerin en büyük en büyük dezavantajı sonuca nasıl ulaşıldığının net bir şekilde ortaya konulamamasıdır. Açıklanabilir yapay zeka yöntemleri bu noktada önemli bir katkı sunmakta, hangi kriterin hangi bölgede değeri ne yönde ve ne şiddette etkilediđi tespit edilebilmektedir. Ayrıca model doğruluđunu ve özellik önem skorlarını yorumlanabilir bir şekilde belirleyerek güven ve şeffaflık sağlamaktadır (Hagras, 2018). Hesaplanan özellik önem skorları ve SHAP değerlerine göre, konumsal faktörler konut fiyat tahmininde modele büyük ölçüde katkı sağlamıştır. Bina yüzölçümü deđişkeninden sonra, metro istasyonuna yakınlık, müzelere yakınlık, alışveriş merkezlerine yakınlık, otogarlara yakınlık ve havalimanlarına yakınlık deđişkenleri Rastgele Orman regresyon modeline katkı sağlayan en önemli özellikler olarak öne çıkmıştır. Sonuç olarak İngiltere ve Galler'de toplu taşıma istasyonlarına ve sosyo-kültürel merkezlere yakınlığın konut fiyatlarını önemli ölçüde etkilediđi sonucuna varılmıştır. Ayrıca SHAP grafiđi incelendiğinde, modelin açıklanabilirliğinin %50'den fazlasına sahip kısmını önem skorları en yüksek olan bina yüzölçümü ve metro istasyonlarına yakınlık kriterleri oluşturmaktadır.

Makine Öğrenmesi modellerinde öğrenme oranı (learning rate), maksimum derinlik (max depth), iterasyon sayısı (n estimators) gibi birçok hiperparametre bulunmaktadır. Hiperparametre optimizasyonu yapay öğrenme sürecinin önemli bir parçasıdır. Optimum parametrelerin ayarlanması ile model doğruluđu önemli ölçüde artırılabilir. Bu parametrelerin optimizasyonu etkin bir şekilde gerçekleştirmek

ve yüksek model performansı elde etmek için Rastgele Arama ve Çapraz Doğrulmalı Izgara Arama teknikleri kullanılabilir. Böylece veri setine göre modelin en iyi parametreleri çeşitli kombinasyonların denenmesi sonucunda belirlenebilmektedir. Izgara Arama özellik seçim yönteminin tek başına kullanılmasına kıyasla Rastgele Arama ve Izgara Aramanın birlikte kullanılması, daha az model eğitimi ile kapsamlı parametre aramasının daha kısa sürede tamamlanmasını sağlamıştır. Bu işlem sırasında veri ölçeği ve veri boyutu yetersiz bellek hatasına neden olduğu için çapraz doğrulamada tekrar sayısı sınırlanmıştır. Hiperparametre optimizasyonunda karşılaşılan bu sorunun üstesinden gelmek için Bulut Bilişim veya paralel işleme yöntemi kullanılabilir.

Hiperparametre optimizasyonundan sonra her bir regresyon algoritması en iyi parametreler kullanılarak eğitilmiş ve test verileri üzerindeki tahmin doğrulukları kıyaslanmıştır. Doğruluk analizi değerlendirme çalışmasının önemli aşamalarındandır. R^2 , MAE, RMSE gibi regresyon analizinin performans metriklerinin yanısıra IAAO'nun oran çalışması değerlemenin başarısını ortaya koyan önemli göstergeler sunmaktadır. Elde edilen sonuçlara göre Rastgele Orman modeli $0.8579 R^2$, 0.1941 MAPE ve 101847.74 RMSE ile konut fiyat tahmininde en başarılı algoritma olmuştur. Ayrıca çalışma bölgesinin özelliklerine göre COD ve PRD değerleri uluslararası toplu değerlendirme standardında önerilen sınır değerler içerisinde hesaplanmıştır.

Makine Öğrenmesinde denetimsiz öğrenme yaklaşımlarından biri olan kümeleme yöntemi, taşınmaz değerlendirme çalışmalarında genelde değerlerin gruplandırılması yaklaşımına dayalı kullanılmaktadır. Tez çalışmasında k-ortalama yöntemi özelleştirilerek Nominal Ağırlıklı Çok Değişkenli Mekansal Kümeleme yöntemi ile değer bölgeleri belirlenmiştir. Bu bölgelerde gerçekleştirilen lokal regresyon analizinde global modele göre daha iyi bir performans elde edilmiş, bölgesel değişimlerin ve benzerliklerin ortaya çıkarılması sağlanmıştır. Lokal regresyon modelleri oluşturulduktan sonra kriterlerin farklı değer bölgelerindeki etkisinin incelenmesi amacıyla beş farklı küme için SHAP özet grafikleri oluşturulmuştur. Taşınmazların $11,16\%$ 'sını barındıran 1. küme, en düşük ortalama birim değere sahip olan, çoğunlukla kırsal alanları kapsayan değer bölgesidir. Yüzölçümü ve oda sayısı gibi fiziksel özellikler bu kümenin en önemli kriterleri olarak öne çıkmaktadır. 2. ve 3. küme değerlendirme verisinde bulunan taşınmazların yaklaşık 77% 'sini içermektedir. Bu değer bölgeleri

öznitelik önem derecesi açısından benzer SHAP değeri sonuçlarına sahiptirler. Yüzölçümü ve oda sayısı değişkenlerinden sonra, otoparklara, tren istasyonlarına, metro istasyonlarına ve üniversitelere yakınlık, bu bölgelerde taşınmaz değerini olumlu yönde etkileyen kriterlerdir. 4. küme, İngiltere'nin önde gelen şehirlerinden Londra, Liverpool, Manchester ve Newcastle gibi yüksek değere sahip bir taşınmaz grubunu kapsamaktadır. Bu değer bölgesinin en önemli öznitelikleri metro istasyonlarına, otoparklara, alışveriş merkezlerine, otoparklara ve vapur iskelelerine yakınlık olarak göze çarpmaktadır. Diğer değer bölgelerinden farklı olarak 5. kümede müzelere yakınlık büyük önem taşımaktadır. Bu kümede yer alan Büyük Londra bölgesinde 150'den fazla müze bulunmakta ve bu müzelerin çoğunluğu gözde mahallelerde yer almaktadır. Bu nedenle müzelere yakınlık SHAP özet grafiğinde yüksek önem derecesine sahiptir. Tüm SHAP grafikleri değerlendirildiğinde, İngiltere ve Galler genelinde toplu taşıma istasyonlarına ve sosyo-kültürel merkezlere yakınlığın konut amaçlı taşınmaz fiyatlarını olumlu yönde etkilediği sonucuna varılmıştır. Öte yandan havalimanlarına yakınlık kriterinin genel olarak konut fiyatlarını olumsuz etkilediği gözlemlenmiştir. Havalimanları çevrede gürültü kirliliğine sebep olduğu için genellikle bu alanlara yakınlık konut edinimi amacıyla tercih edilmemektedir.

Makine Öğrenmesi ile geliştirilen modeller tek veri seti kullanılarak eğitildikten sonra aşırı öğrenmeden kaynaklı yeni veriler üzerinde başarısız olabilmektedir. Bu durumun tespiti için modelin genelleştirilebilirliği incelenmelidir. Bu kapsamda Büyük Britanya için geliştirilen hibrit model ülkemizde İstanbul ve İzmir şehirleri için de uygulanmış, benzer sonuçlar elde edilmiştir. Böylece geliştirilen modelin yeryüzünde herhangi bir yer için, farklı değerlendirme verileri ile uygulanabileceği ortaya konmuştur.

Yapılı taşınmazların değeri arsa ve bina değerlerinin toplamı şeklinde ifade edilmelidir. Yapılı taşınmazın arsa değerinin tespit edilmesinde ve inşaat maliyetlerini ilgilendiren bina özelliklerine ait verilere erişimdeki zorluk arsa-bina değerinin ayrıştırılmasını güçleştirmektedir (Bourassa ve Hoesli, 2022). Tez çalışması kapsamında binaların yeniden inşa maliyetlerinin tespiti için CBS ve Makine Öğrenmesi temelli parametrik maliyet modellemesi yaklaşımı geliştirilmiştir. İngiltere ve Galler ülkelerinde PPD-EPC verisi kullanılarak uygulanan yöntem sonucunda elde edilen maliyet, BCIS yapı yaklaşık maliyet modeli ile kıyaslanarak yöntemin test edilmesi sağlanmıştır. Geliştirilen yöntem ile BCIS maliyet hesabı arasındaki farka bakıldığında sapma

miktarının %15'ten az olduğu, arazi kaldıracı oranının ise yaklaşık %25-30 arasında olduğu görülmüştür. Sonuç olarak taşınmazların toplam değerinden yapı maliyeti çıkarılarak arsa değerine geçiş yapılmış, taşınmazın değeri iki bileşene ayrıştırılmıştır. Öte yandan yapı maliyet hesapları için binalara ait detaylı özniteliklere ihtiyaç bulunmaktadır. Maliyet hesabının etkin bir şekilde yapılabilmesi amacıyla BIM modelleri üzerinden gerekli tüm öznitelikler elde edilebilmektedir. Veri kaynağı olarak BIM/IFC modellerinin CBS ile birlikte kullanılması sonucunda 3B taşınmaz değerlendirme çalışmaları yüksek doğrulukla gerçekleştirilebilecektir.

Taşınmaz değer bilgi portalının geliştirilmesi aşamasında hem sunuculu, hem de sunucusuz mimariler kullanılmış, yöntemlerin performans ve mali açıdan durumları kıyaslanmıştır. Sunucusuz mimarilerin özellikle büyük veri hacminin bulunduğu uygulamalarda daha ekonomik ve daha hızlı hizmet sağladığı görülmüştür.

Bir raster görüntü dosyasını kullanıcılarla paylaşmak için GeoTIFF, COG, NetCDF gibi çeşitli veri formatlarında indirme bağlantısı sunma veya web servisleri aracılığıyla raster görüntü karelerini paylaşma gibi alternatifler mevcuttur. Çalışma kapsamında üretilen nominal değer haritasını yayınlamak için QGIS ile raster verilerin XYZ görüntü kareleri MBTiles formatında oluşturulmuş ve sunucusuz veri paylaşımı için AWS S3'e yüklenmiştir. Leaflet JS web harita kütüphanesi ile bir Web CBS portalı geliştirilerek servis edilen haritalar çevrimiçi olarak kullanıcılara sunulmuştur. Coğrafi veri depolama, işleme ve paylaşımı işlemlerde bulut tabanlı çözümlerin kullanılması, geleneksel masaüstü yaklaşımına kıyasla çok sayıda fayda sağlamaktadır. Bulut bilişim, depolama, hesaplama ve ağ hizmetlerinin etkin yönetimi için çok sayıda kaynak tahsis etmektedir. Raster formatındaki değer haritasının Amazon S3 üzerinden depolanması ve paylaşılması, ölçeklenebilirlik, güvenlik ve yüksek performans gibi kazanımlar sağlamıştır.

Taşınmaz değerlendirme verilerine faydalı öznitelikler eklemek için PPD ve EPC verilerinin ilişkilendirilmesiyle ilgili literatürde çeşitli çalışmalar bulunmaktadır (Chi ve diğ, 2021b; Fuerst ve diğ, 2016; Powell-Smith, 2018). Ancak bütünleştirilmiş PPD ve EPC verileri üzerinde Makine Öğrenmesi yöntemlerini uygulayan herhangi bir akademik çalışmaya rastlanmamıştır. Tez çalışmasında İngiltere ve Galler'de toplu taşınmaz değerlendirme çalışması için çeşitli Makine Öğrenmesi algoritmaları kullanılarak doğrulukları kıyaslanmıştır. CBS analizleri sonucu elde edilen konumsal kriter

puanlarının deęerleme veri setine öznitelik olarak eklenmesiyle birlikte regresyon modellerinin tahmin doęruluęu önemli ölçüde artırılmıştır.

4. SONUÇLAR

Bu tez çalışmasında taşınmaz değerlendirme ile alakalı sorunlar ele alınmış, CBS, Yapay Zeka ve Makine Öğrenmesi, BIM, Bulut Bilişim gibi akıllı sistemlere dayalı çözümler geliştirilmiştir. Bu kapsamda aşağıdaki sonuçlara ulaşılmıştır:

– LADM ile arazi idaresi kapsamında farklı kurumların veritabanlarında bulunan verilerin birlikte çalışabilir bir yapıda modellenmesi, taşınmaz değerlendirme süreçlerini kolaylaştırmaktadır. Bu kapsamda Birleşik Krallık için taşınmaz değerlendirme ülke profili oluşturulmuş, veri modeli sınıfları, kod listeleri ve veri türleri belirlenmiştir. Böylece ülkelerin arazi yönetiminde mevcut durumu kavramsal olarak modellenmiş, önerilen toplu değerlendirme yaklaşımının uygulanabilirliği irdelenmiştir.

– BIM bir yapı projesinin geometrisini, öznitelik bilgilerini ve semantiklerini üç boyutlu sunabilen bir sistemdir. Taşınmaz değerlendirme için önemli bir veri kaynağı haline gelen BIM'in kullanımı bina maliyetinin detaylı ve doğru bir şekilde hesaplanmasına imkan tanımaktadır. Tez çalışmasında üç boyutlu taşınmaz değerlendirme amaçlı LADM_VM'ye dayalı bir IFC modeli geliştirilmiş, tüm sınıflar için özellik setleri oluşturulmuştur. Böylece BIM'in 3B taşınmaz değerlemede kullanılabilirliğini inceleyen bir örnek uygulama geliştirilmiştir.

– Masaüstü CBS yazılımları konumsal analiz, harita üretimi gibi amaçlar için yaygın olarak kullanılsa da otomasyon veya amaca özgü özelleştirme gerektiren işlerde Bulut CBS'den faydalanmak performans ve maliyet yönlerinden önemli avantajlar sunmaktadır.

– Birleşik Krallık Kraliyet Arazi Kayıt Kurumu tarafından paylaşılan PPD konut satış verilerinde taşınmazlarla ilgili birçok fiziksel değişken bulunmasına karşın değeri önemli derecede etkileyen konumsal kritlerler yer almamaktadır. Veri setinin toplu değerlendirme çalışmalarında kullanılarak yüksek doğruluklu bir modelin geliştirilmesi amacıyla CBS ve Makine Öğrenmesine dayalı hibrit bir yöntem geliştirilmiş, konumsal

analizlerin sonucunda elde edilen nominal kriter puanları ile değerlendirme verisi zenginleştirilmiştir.

– Yapılı taşınmazların arsa ve yapı değerinin ayrıştırılarak iki farklı bileşen halinde ifade edilmesi taşınmaz geliştirme açısından önem arz etmektedir. Tez çalışması kapsamında CBS tabanlı Nominal Değerleme ve Makine Öğrenmesi yöntemlerine dayalı parametrik maliyet yaklaşımı ile arsa ve binaların değerleri için iki ayrı değerlendirme modeli geliştirilmiştir. Birleşik Krallık'ta gerçek satış değerleri kullanılarak gerçekleştirilen uygulamada taşınmazların arsa ve bina değerleri ayrı ayrı elde edilerek çapraz doğrulama yapılmış, yöntemin test edilmesi sağlanmıştır. Geliştirilen yaklaşım ile yapılı taşınmazların arsa-yapı maliyetlerinin ayrıştırılmasında CBS destekli Nominal Yöntem ve Makine Öğrenmesi regresyon analizinin kullanılabilirliği ortaya konmuştur.

– Taşınmaz değerine bağlı olarak gerçekleştirilen vergilendirme, imar uygulamaları, planlama gibi çeşitli faaliyetlerde toplu değerlendirme yöntemlerinin kullanımında son yıllarda artış görülmektedir. Hedonik Değerleme, Nominal Değerleme, Konumsal Analiz ve Regresyon Analizi, toplu değerlendirme uygulamalarında öne çıkan yöntemlerden bazılarıdır. Literatürde toplu değerlendirme çalışmaları kapsamında Makine Öğrenmesi algoritmalarının kullanıldığı çok sayıda çalışma bulunmasına rağmen taşınmaz değerini önemli oranda etkileyen konumsal faktörlerin göz ardı edildiği, fiziksel kriterlere yoğunlaşıldığı gözlemlenmektedir. Bu çalışmada Birleşik Krallık ve Türkiye çalışma bölgelerinde konutların toplu değerlemesi için CBS tabanlı Nominal Değerleme yöntemi ve çeşitli Makine Öğrenmesi algoritmaları kullanılmıştır.

– PPD ve EPC, İngiltere ve Galler'de bulunan konut amaçlı taşınmazlar hakkında birçok tanımlayıcı özellik içeren, açık devlet lisansına sahip veri setleridir. Bütünleştirilmiş PPD-EPC verileri kullanılarak, toplu değerlendirme çalışması yapmak için Makine Öğrenmesi ile yüksek doğruluklu regresyon modelleri oluşturulabilir. Bu kapsamda fiyat kestirimi için Linear Regresyon, XGBoost, LightGBM, CatBoost ve Rastgele Orman modelleri Jupyter Notebook Python ortamında oluşturulmuştur. Modellerin sonuçlarına bakıldığında Rastgele Orman algoritması tahmin doğruluğu açısından diğer regresyon yöntemlerine göre daha iyi performans göstermiştir (R^2 : 0,8379; MAPE: 0,1941; RMSE: 101847,74). Öte yandan en iyi model parametrelerini belirlemek amacıyla hiperparametre optimizasyonunu gerçekleştirmek

üzere Rastgele Arama ve Çapraz Doğrulama Izgara Arama kullanılmıştır. Optimize edilmiş modellerin ilk sonuçlardan daha yüksek doğruluğa sahip olmasına karşın, PPD-EPC veri setindeki konumsal özniteliklerin yetersizliği sebebiyle yeterli tahmin doğruluğuna erişilememiştir.

– CBS'nin güçlü konumsal analiz yeteneğinden faydalanılarak konumsal faktörlerin taşınmaz değeri üzerindeki etkileri ortaya çıkarılabilmektedir. Çalışmada PPD-EPC veri setini etkili özniteliklerle zenginleştirmek için yakınlık, yüzey ve görünürlük analizleri yapılmıştır, CBS tabanlı Nominal Değerleme yöntemi kullanılarak QGIS yazılımında Büyük Britanya'nın değer haritası oluşturulmuş ve çevrimiçi olarak yayınlanmıştır. Veri zenginleştirme işlemi kapsamında CBS analiz sonuçları konumsal birleştirme işlemi uygulanarak UPRN değerlerine atanmış, PPD-EPC verilerinin metin tabanlı adres sütunu coğrafi olarak kodlanarak UPRN ile eşleştirilmiştir. Sonuç olarak, Python'ın Pandas kütüphanesi kullanılarak UPRN sütununa dayalı iki veri kümesi birleştirilmiştir.

– Öznitelik zenginleştirme sonrası oluşturulan yeni veri seti için toplu değerlendirme kapsamında aynı iş akışı uygulanarak regresyon analizleri daha yüksek doğrulukla gerçekleştirilmiştir. Sonuçlara bakıldığında Rastgele Orman algoritmasının diğer regresyon modellerine kıyasla fiyat tahmininde daha iyi performansa sahip olduğu görülmüştür. PPD-EPC veri setine konumsal özniteliklerin eklenmesi model doğruluğunu önemli ölçüde artırmıştır. Regresyon modelinin öznitelik önem skorları ve SHAP değerleri incelendiğinde konumsal faktörlerin tahmin sürecine ciddi bir katkı sağladığı görülmektedir. Sonuç olarak yakınlık, yüzey ve görünürlük konumsal analizleri olmadan PPD-EPC verilerinde Rastgele Orman regresyon modeli kullanıldığında model doğruluğu vasat bir performans göstermiştir (R^2 : 0.4690, MAPE: 0.4614, RMSE: 198211.9713). Regresyon analizine CBS analizi sonucunda elde edilen nominal kriter puanları eklenmesi sonucunda R^2 %38,9 artmış, MAPE ve RMSE sırasıyla %26,73 ve %48,6 azalmıştır.

– Global regresyon analizi konut değerlendirme çalışmalarında mekansal olarak bağımlı değişkenleri modellemek için yetersiz kalabilmektedir. Global Moran's I ile kriterlerin mekansal değişimleri irdelendikten sonra Nominal Ağırlıklı Çok Değişkenli Mekansal Kümeleme yöntemi geliştirilmiş ve beş adet değer bölgesi oluşturulmuştur. Böylece her bir küme için yerel regresyon analizinin kullanılması ve coğrafi olarak bağımlı

faktörlerin etkisinin bu değer bölgeleri için ortaya çıkarılması sağlanmıştır. Durağan olmayan konumsal kriterler için lokal regresyon modellerinin kullanılması, daha iyi model performansı ve değer üzerindeki kriterlerin etkilerinin daha ayrıntılı bir şekilde yorumlanmasını mümkün kılmıştır.

Bu çalışmada CBS ve Makine Öğrenmesi hibrit yaklaşımı ile PPD-EPC verileri kullanılarak İngiltere ve Galler'de bulunan konut amaçlı taşınmazların toplu değerlendirilmesi yüksek doğrulukla gerçekleştirilmiştir. Önerilen hibrit yaklaşımın dünyanın herhangi bir yeri için, taşınmaz değerlendirme verilerine kolaylıkla uyarlanabileceği, ülkelerin ve değerlendirme kuruluşlarının otomatik değerlendirme çalışmalarında bu yöntemi uygulayarak yüksek doğruluk elde edebileceği öngörülmektedir.

Bu alanda gelecekte yapılacak çalışmalarda, PPD ve EPC verilerinin bütünleştirme işlemi Ocak 2020'den günümüze kadarki dönemi de içerecek şekilde uygulanabilir. Böylelikle İngiltere ve Galler'de COVID-19 etkilerinin konut fiyat piyasası üzerindeki etkilerini gözlemlemek ve yakın dönemde yapılan alım-satım işlemlerinin de regresyon analizine dahil edilmesiyle tahmin modellerini geliştirmek mümkün olacaktır. ANOVA, LSTM, Transformers gibi yöntemler ile zaman serisi analizleri gerçekleştirilerek hem fiyat tahmini hem de mevsimsellik, trend gibi örüntülerin elde edilmesi mümkün olacaktır. Ayrıca CityGML/CityJSON veya BIM verileri ile üç boyutlu CBS analizleri yapılarak binaların farklı kat seviyelerindeki için manzaranın bağımsız bölümlerin değerine etkisi ortaya çıkarılabilir.

Çalışma kapsamındaki diğer öneriler aşağıda sıralanmıştır:

– Taşınmaz değerlendirme uygulamalarının önemli bir kısmında kamu kurumları paydaş olarak yer almaktadır. Değerleme faaliyetlerinin etkin bir şekilde yürütülebilmesi için kapsamlı bir mevzuata ihtiyaç bulunmaktadır. Ülkemizde taşınmaz değerlendirme alanında yaşanan sorunların kaynaklarından biri de mevzuatta değerlendirme faaliyetlerini bütüncül bir şekilde ele alan bir kanunun bulunmamasıdır. Mevzuat altyapısının düzenlenmesiyle değer farklılıklarının ortadan kaldırılması, standartlara önemli ölçüde uyulması, kurumlar arası yetki ve sorumlulukların net bir biçimde belirlenmesi gibi faydaların yanısıra, tekil ve toplu değerlendirme çalışmalarında önemli bir aşamanın kaydedileceği düşünülmektedir.

– Ülkemizde toplu değerlendirme çalışmalarının sağlıklı bir şekilde yürütülmesinin önündeki en büyük engel gerçek satış değerlerine erişilememesidir. Tapu harcı, emlak vergisi gibi kamu gelirlerinin yüksek oranlarla vatandaşa yansıtılması değer beyanında gerçek değer saklanmasına sebep olmaktadır. Bu sorunun aşılması için öncelikle vergi oranlarının revize edilmesi, sonrasında ise gerçek değer beyanı için vatandaşları teşvik edici uygulamaların hayata geçirilmesi gerekmektedir. Böylece kısa süre içerisinde sağlıklı bir değer veritabanı oluşturma imkanı olacak, toplu değerlendirme çalışmaları da bu verilere dayanarak tutarlı bir şekilde gerçekleştirilebilecektir.

– Kentsel dönüşüm, arsa ve arazi uygulamaları, kamulaştırma ve irtifak değerinin belirlenmesi gibi faaliyetlerde CBS, Makine Öğrenmesi, BIM gibi akıllı sistemlerle değer esaslı uygulama yapılarak taşınmaz değerinin belirlenmesi değer tespitinde nesnel bir yaklaşım getirecek, bu faaliyetler sonucunda yaşanan anlaşmazlıkların da önüne geçilmesini sağlayacaktır.

– Toplu değerlendirme çalışmalarında kullanılan verilerin doğruluğu sonucu direkt etkileyen önemli bir unsurdur. Ülkemizde değerlendirme faaliyetlerinde ihtiyaç duyulan veriler kurumlar tarafından açık lisans ile paylaşılmamaktadır. TUCBS ve CBS mevzuatı ile veri paylaşımı ve birlikte çalışabilirlik anlamında önemli aşamalar kaydedilse de, değerlendirme faaliyetlerinin doğru ve etkin bir şekilde yürütülebilmesi için kamu kurumları tarafından üretilen verilerin kişisel bilgilere yer verilmeden açık bir şekilde paylaşılması gerekmektedir.

– Birleşik Krallık'ta konut satış verilerinin açık veri lisansı ile paylaşılması hem konut fiyat endeksleri üretilmesine, hem de toplu değerlendirme çalışmalarına önemli bir katkı sunmaktadır. Öte yandan ülkede kadastro çalışması yapılmadığından arazi ve arsalara ait parsellerin kesin koordinatlarından oluşan bir geometrisi bulunmamakta, yaklaşık geometriler tapu planları yardımıyla Kraliyet Arazi Kayıt Kurumu veritabanında tutulmakta, bu veriye de belli bir ücret karşılığında ulaşılabilir. Bu sebeple değerlemede önemli bir unsur olan parsellerin net yüzölçümü bilgisi karışıklığa sebep olmaktadır. Ayrıca PPD verisinde satışa konu taşınmazın türü binalar için detaylı bir şekilde belirtilmişken, arsa satışlarına diğer kategorisinde yer verildiği için bu veriyi ayıklamak uzun uğraş gerektirmektedir. Tapu planları verisinin açık lisans ile paylaşılması ve arsa satışlarının PPD verisinde net bir şekilde tanımlanması değerlendirme

açısından doğru bilgiye hızlı erişimi sağlayarak süreçlerin iyileştirilmesine katkı sağlayacaktır.

– BIM verileri yapılar hakkında detaylı bilgiler içermektedir. Yapı inşaat maliyetlerinin belirlenmesi amacıyla BIM modellerinin kullanılması bina değerlendirme çalışmalarında önemli avantajlar sağlamaktadır. Özellikle bina ve arsa değerinin ayrıştırılması çalışması kapsamında BIM kullanılarak bina inşaat maliyeti hesaplanabilir, toplam değerden yapı maliyet değeri çıkarılarak arsa değerleri kentsel alanlarda yüksek doğrulukla belirlenebilir.

– Toplu değerlendirme çalışması sonucunda değer haritaları genellikle iki boyutlu olarak üretilmektedir. Düşey mülkiyete konu binalarda bağımsız bölümlerin değerlerinin daha anlaşılır ifade edilebilmesi için üç boyutlu gösterimlere ihtiyaç bulunmaktadır. Değerleme çalışması sonrasında elde edilen veriler üç boyutlu kent modelleri ile bütünleştirilerek CesiumJS gibi javascript tabanlı harita kütüphaneleri ile web üzerinden sunulabilir.

KAYNAKLAR

- Açlar, A. ve Çağdaş, V.** (2002). *Taşınmaz (gayrimenkul) değerlemesi*. TMMOB Harita ve Kadastro Mühendisleri Odası, Ankara.
- Adalet Bakanlığı** (2021). İnsan Hakları Eylem Planı. Teknik Rapor, Türkiye Cumhuriyeti Adalet Bakanlığı.
<https://rayp.adalet.gov.tr/resimler/1/dosya/insan-haklari-ep02-03-202115-14.pdf>
- Ahlfeldt, G.M. ve McMillen, D.P.** (2018). Tall Buildings and Land Values: Height and Construction Cost Elasticities in Chicago, 1870–2010. *The Review of Economics and Statistics*, 100(5), 861–875.
https://doi.org/10.1162/REST_A_00734
- AİHM** (2021). Avrupa İnsan Hakları Mahkemesi, Dava İstatistikleri.
https://www.echr.coe.int/Documents/Overview_19592020_ENG.pdf
- Alfaqih, T.M. ve Hassan, M.M.** (2016). GIS Cloud: Integration between cloud things and geographic information systems (GIS) opportunities and challenges. *International Journal on Computer Science and Engineering (IJCSE)*.
- Alfaro-Navarro, J.L., Cano, E.L., Alfaro-Cortés, E., García, N., Gámez, M. ve Larraz, B.** (2020). A Fully Automated Adjustment of Ensemble Methods in Machine Learning for Modeling Complex Real Estate Systems. *Complexity*, 2020, 1–12.
<https://doi.org/10.1155/2020/5287263>
- Alpaydin, E.** (2016). *Machine Learning: The New AI*. MIT Press, the mit press sürüm.
- Angel, J.** (2017). ArcMap Continued Support.
<https://www.esri.com/arcgis-blog/products/arcgis-desktop/announcements/arcmap-continued-support/>
- Avrupa Birliği Parlamentosu ve Avrupa Birliği Meclisi** (2019). Açık Veri ve Kamu Sektörü Bilgisinin Yeniden Kullanımı Hakkında Yönerge (Directive (EU) 2019/1024 of the European Parliament and of the Council of 20 June 2019 on open data and the re-use of public sector information).
<https://eur-lex.europa.eu/legal-content/EN/TXT/?qid=1561563110433{&}uri=CELEX:32019L1024>
- AWS** (2020a). Amazon Web Services. Case Studies & Customer Success Stories.
<https://aws.amazon.com/solutions/case-studies/all>
- AWS** (2020b). Amazon Web Services. Simple Storage Service.
<https://aws.amazon.com/s3>

- Aydinoglu, A.C., Bovkir, R. ve Colkesen, I.** (2021). Implementing a mass valuation application on interoperable land valuation data model designed as an extension of the national GDI. *Survey Review*, 53(379), 349–365.
<https://doi.org/10.1080/00396265.2020.1771967>
- Baldominos, A., Blanco, I., Moreno, A., Iturrarte, R., Bernárdez, Ó. ve Afonso, C.** (2018). Identifying Real Estate Opportunities Using Machine Learning. *Applied Sciences*, 8(11), 2321.
<https://doi.org/10.3390/app8112321>
- BCIS** (2022). Residential Rebuilding Cost Calculator.
<https://calculator.bcis.co.uk/calculator/calculator.aspx>
- Been, V., Gould Ellen, I. ve Gedal, M.** (2009). Teardowns and Land Values in New York City. Teknik Rapor, Lincoln Institute of Land Policy, Newyork.
- Bell, M.E., Bowman, J.H. ve German, J.C.** (2009). The assessment requirements for a separate tax on land. In **R.F. Dye ve R.W. England** (düzenleyenler) *Land Value Taxation: Theory, Evidence, and Practice*, bölüm 8, (s.171–194). Lincoln Institute of Land Policy.
- Benjamin, J.D., Guttery, R.S. ve Sirmans, C.F.** (2020). Mass Appraisal: An Introduction to Multiple Regression Analysis for Real Estate Valuation. *Journal of Real Estate Practice and Education*, 7(1), 65–77.
<https://doi.org/10.1080/10835547.2004.12091602>
- Bhat, M.A., Shah, R.M. ve Ahmad, B.** (2011). Cloud Computing: A solution to Geographical Information Systems(GIS). *International Journal on Computer Science and Engineering*, 3(2), 594–600.
- Bilgilioglu, S.S.** (2018). *Makine öğrenmesi teknikleri ile mekansal karar destek sistemlerinin geliştirilmesi: Aksaray ili örneği. Doktora Tezi*, Aksaray Üniversitesi.
- Biljecki, F., Lim, J., Crawford, J., Moraru, D., Tauscher, H., Konde, A., Adouane, K., Lawrence, S., Janssen, P. ve Stouffs, R.** (2021). Extending CityGML for IFC-sourced 3D city models. *Automation in Construction*, 121, 103440.
<https://doi.org/10.1016/J.AUTCON.2020.103440>
- Birleşik Krallık Mülkiyet ve Yerel Yönetimler Bakanlığı** (2020). Land value estimates for policy appraisal.
<https://www.gov.uk/government/publications/land-value-estimates-for-policy-appraisal-2019>
- Bitter, C., Mulligan, G.F. ve Dall'erba, S.** (2007). Incorporating spatial variation in housing attribute prices: A comparison of geographically weighted regression and the spatial expansion method. *Journal of Geographical Systems*, 9(1), 7–27.
<https://doi.org/10.1007/S10109-006-0028-7/TABLES/9>
- Bostic, R.W., Longhofer, S.D. ve Redfearn, C.L.** (2007). Land Leverage: Decomposing Home Price Dynamics. *Real Estate Economics*, 35(2), 183–208.
<https://doi.org/10.1111/J.1540-6229.2007.00187.X>

- Bourassa, S.C., Hoesli, M., Scognamiglio, D. ve Zhang, S.** (2011). Land leverage and house prices. *Regional Science and Urban Economics*, 41(2), 134–144.
<https://doi.org/10.1016/J.REGSCIURBECO.2010.11.002>
- Bourassa, S.C. ve Hoesli, M.E.R.** (2022). Hedonic, Residual, and Matching Methods for Residential Land Valuation. *SSRN Electronic Journal*.
<https://doi.org/10.2139/SSRN.4148824>
- Bovkir, R. ve Aydinoglu, A.C.** (2018). Providing land value information from geographic data infrastructure by using fuzzy logic analysis approach. *Land Use Policy*, 78, 46–60.
<https://doi.org/10.1016/j.landusepol.2018.06.040>
- Breiman, L.** (2001). Random forests. *Machine Learning*, 45(1), 5–32.
<https://doi.org/10.1023/A:1010933404324>
- BSI** (2014). BS 1192-4:2014 Collaborative production of information Part 4 : Fulfilling employer’s information exchange requirements using COBie - Code of practice.
<https://knowledge.bsigroup.com/products/collaborative-production-of-information-fulfilling-employer-s-information-exchange-requirements-using-cobie-code-of-practice/standard>
- Bühlmann, P.** (2012). *Bagging, Boosting and Ensemble Methods*, bölüm Statistical Methodology, (s.985–1022). Berlin, Heidelberg: Springer Berlin Heidelberg.
https://doi.org/10.1007/978-3-642-21551-3_33
- BuildingSMART** (2022). Industry Foundation Classes (IFC) - An Introduction.
<https://technical.buildingsmart.org/standards/ifc>
- Bunyan Unel, F. ve Yalpir, S.** (2019). Valuations of building plots using the AHP method. *International Journal of Strategic Property Management*, 23(3), 197–212.
<https://doi.org/10.3846/ijspm.2019.7952>
- Burrough, P.A.** (1986). Principles of Geographical. *Information Systems for Land Resource Assessment*. Clarendon Press, Oxford.
- Çağdaş, V., Kara, A., Işıkdağ, Ü., van Oosterom, P., Lemmen, C. ve Stubkjaer, E.** (2017). A Knowledge Organization System for the Development of an ISO 19152:2012 LADM Valuation Module. In *FIG Working Week 2017*, cilt 39, (s.1–20). Helsinki: International Federation of Surveyors (FIG).
- Çağdaş, V., Kara, A., van Oosterom, P., Lemmen, C., Işıkdağ, Ü., Kathmann, R. ve Stubkjær, E.** (2016). An Initial Design of ISO 19152:2012 LADM based Valuation and Taxation Data Model. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, IV-2/W1(2W1), 145–154.
<https://doi.org/10.5194/isprs-annals-IV-2-W1-145-2016>

- Calka, B.** (2019). Estimating Residential Property Values on the Basis of Clustering and Geostatistics. *Geosciences*, 9(3), 143.
<https://doi.org/10.3390/geosciences9030143>
- Cellmer, R., Cichulska, A. ve Belej, M.** (2020). Spatial Analysis of Housing Prices and Market Activity with the Geographically Weighted Regression. *ISPRS International Journal of Geo-Information*, 9(6), 380.
<https://doi.org/10.3390/IJGI9060380>
- Chen, T. ve Guestrin, C.** (2016). XGBoost: A Scalable Tree Boosting System. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, (s.785–794). New York, NY, USA: ACM.
<https://doi.org/10.1145/2939672>
- Chen, X., Wei, L. ve Xu, J.** (2017). House Price Prediction Using LSTM. *arXiv*.
<https://doi.org/10.48550/arxiv.1709.08432>
- Chi, B., Dennett, A., Oléron-Evans, T. ve Morphet, R.** (2021a). A new attribute-linked residential property price dataset for England and Wales 2011-2019.
<https://doi.org/10.5255/UKDA-SN-854240>
- Chi, B., Dennett, A., Oléron-Evans, T. ve Morphet, R.** (2021b). A new attribute-linked residential property price dataset for England and Wales, 2011–2019. *UCL Open Environment*, 2(07).
<https://doi.org/10.14324/111.444/UCLOE.000019>
- Chi, B., Dennett, A., Oléron-Evans, T. ve Morphet, R.** (2021c). Delineating the Spatio-Temporal Pattern of House Price Variation by Local Authority in England: 2009 to 2016. *Geographical Analysis*, 0, 1–20.
<https://doi.org/10.1111/GEAN.12287>
- Clarke, K.** (1999). *Getting started with GIS*. Prentice-Hall Inc., NJ, United States.
- Cloud Native Computing Foundation** (2022). What is cloud-native? (Bulut yerlisi nedir?).
<https://www.cncf.io/>
- Copiello, S.** (2021). An Empirical Study of Land Leverage as a Function of Market Value Using a Spatial Autoregressive Model. In **M. Pierluigi, O. Alessandra, R. Paolo, S. Leopoldo ve T. Francesco** (düzenleyenler) *Appraisal and Valuation. Green Energy and Technology*, (s.29–41). Springer, Cham.
https://doi.org/10.1007/978-3-030-49579-4_3
- Coğrafi Bilgi Sistemleri Genel Müdürlüğü** (2021). Coğrafi Bilgi Sistemleri Mevzuat Kitabı.
<https://webdosya.csb.gov.tr/db/cbs/icerikler/mevzuat-kitabi-dijital-web-020721-rv-20210702093531.pdf>
- Dale, P.F. ve McLaughlin, J.D.** (1988). *Land information management: an introduction with special reference to cadastral problems in Third World countries*. Clarendon Press Oxford.

- Davis, M.A., Larson, W.D., Oliner, S.D. ve Shui, J.** (2021). The price of residential land for counties, ZIP codes, and census tracts in the United States. *Journal of Monetary Economics*, 118, 413–431.
<https://doi.org/10.1016/J.JMONECO.2020.12.005>
- Davis, M.A., Oliner, S.D., Pinto, E.J. ve Bokka, S.** (2017). Residential land values in the Washington, DC metro area: New insights from big data. *Regional Science and Urban Economics*, 66, 224–246.
<https://doi.org/10.1016/J.REGSCIURBECO.2017.06.006>
- Davis, M.A. ve Palumbo, M.G.** (2008). The price of residential land in large US cities. *Journal of Urban Economics*, 63(1), 352–384.
<https://doi.org/10.1016/J.JUE.2007.02.003>
- Demetriou, D.** (2017). A spatially based artificial neural network mass valuation model for land consolidation. *Environment and Planning B: Urban Analytics and City Science*, 44(5), 864–883.
<https://doi.org/10.1177/0265813516652115>
- Demetriou, D.** (2018). Automating the land valuation process carried out in land consolidation schemes. *Land Use Policy*, 75, 21–32.
<https://doi.org/10.1016/j.landusepol.2018.02.049>
- Devaney, S., Crosby, N. ve Wyatt, P.** (2018). Residual Land Values: Measuring Performance and Investigating Viability. Teknik Rapor, Investment Property Forum (IPF) Research Programme.
- Diase, A. ve Kone, F.** (2011). Proposed of a GIS Cloud (GIS-C) System Architecture in Private Used. In *Future Intelligent Information Systems*, (s.55–63). Springer.
- Diewert, W.E., de Haan, J. ve Hendriks, R.** (2014). Hedonic Regressions and the Decomposition of a House Price Index into Land and Structure Components. *Econometric Reviews*, 34(2), 106–126.
<https://doi.org/10.1080/07474938.2014.944791>
- Dillmann, J.** (2016). Comparing Cloud Providers: Amazon vs. Google vs. Microsoft.
<https://www.inovex.de/blog/comparing-cloud-providers>
- Dimopoulos, T. ve Moulas, A.** (2016). A Proposal of a Mass Appraisal System in Greece with CAMA System: Evaluating GWR and MRA techniques in Thessaloniki Municipality. *Open Geosciences*, 8(1), 675–693.
<https://doi.org/10.1515/geo-2016-0064>
- Dimopoulos, T., Tyralis, H., Bakas, N.P. ve Hadjimitsis, D.** (2018). Accuracy measurement of Random Forests and Linear Regression for mass appraisal models that estimate the prices of residential apartments in Nicosia, Cyprus. *Advances in Geosciences*, 45, 377–382.
<https://doi.org/10.5194/adgeo-45-377-2018>

- Duan, Y., Fu, G., Zhou, N., Sun, X., Narendra, N.C. ve Hu, B.** (2015). Everything as a Service (XaaS) on the Cloud: Origins, Current and Future Trends. In *Proceedings - 2015 IEEE 8th International Conference on Cloud Computing, CLOUD 2015*, (s.621–628). Institute of Electrical and Electronics Engineers Inc.
<https://doi.org/10.1109/CLOUD.2015.88>
- Dursun, İ., Aslan, M. ve Sarıyüz, F.** (2019). AİTM Kapsamında TAKBİS 2020 Projesi. In *TMMOB 6. Coğrafi Bilgi Sistemleri Kongresi*, (s.1–11). Ankara.
- Endeksa** (2022). Türkiye'nin En Değerli İlçeleri Belli Oldu.
<https://www.endeksa.com/tr/blog/yazi/turkiyenin-en-degerli-ilceleri-belli-oldu>
- Enemark, S.** (2004). Building Land Information Policies. In *UN, FIG, PC IDEA Inter-regional Special Forum on The Building of Land Information Policies in the Americas*, (s.1–20). Aguascalientes, Mexico: FIG.
- EPC** (2021). Energy Performance of Buildings Data.
<https://epc.opendatacommunities.org/>
- Erdem, N.** (2017). Türkiye İçin Bir Taşınmaz Değerleme Sistemi Yaklaşımı. *Geomatik Dergisi*, 2(1), 18–36.
- ESRI** (2018). What is GIS?
<https://www.esri.com/en-us/what-is-gis/overview>
- ESRI** (2022a). History of GIS - Timeline of Early History & the Future of GIS.
<https://www.esri.com/en-us/what-is-gis/history-of-gis>
- ESRI** (2022b). How Aspect works.
<https://pro.arcgis.com/en/pro-app/2.8/tool-reference/spatial-analyst/how-aspect-works.htm>
- ESRI** (2022c). How Slope works.
<https://pro.arcgis.com/en/pro-app/2.8/tool-reference/spatial-analyst/how-slope-works.htm>
- FAO** (2017). Valuing land tenure rights. Teknik Rapor, Food and Agriculture Organization of the United Nations, Rome.
www.fao.org/tenure
- FIG** (2017). Questionnaire for the development of ISO 19152:2012 LADM Valuation Module.
<https://wiki.tudelft.nl/bin/view/Research/ISO19152/ValuationQuestionnaire>
- Franklin, C. ve Hane, P.** (1992). An Introduction to Geographic Information Systems: Linking Maps to Databases [and] Maps for the Rest of Us: Affordable and Fun. *Database*, 15(2), 12–15.
- Fuerst, F., McAllister, P., Nanda, A. ve Wyatt, P.** (2016). Energy performance ratings and house prices in Wales: An empirical study. *Energy Policy*, 92, 20–33.
<https://doi.org/10.1016/J.ENPOL.2016.01.024>

- Gedal, M. ve Ellen, I.G.** (2018). Valuing urban land: Comparing the use of teardown and vacant land sales. *Regional Science and Urban Economics*, 70, 190–203.
<https://doi.org/10.1016/j.regsciurbeco.2018.03.006>
- Geospatial World** (2022). GEOBUIZ 22: Global Geospatial Industry Outlook. Teknik Rapor, Geospatial World.
- Gilbert, T., Rönsdorf, C., Plume, J., Simmons, S., Nisbet, N., Gruler, H., Kolbe, T., Berlo, L.V. ve Mercer, A.** (2021). Built environment data standards and their integration: an analysis of IFC, CityGML and LandInfra. Teknik Rapor, OGC & buildingSMART International.
https://buildingsmart-1xbd3ajdayi.netdna-ssl.com/wp-content/uploads/2021/02/IDBE_Standards_Integration_v1.1_28_JAN_2021.pdf
- GIS Geography** (2022). The Remarkable History of GIS.
<https://gisgeography.com/history-of-gis/>
- GIS Lounge** (2012). History of GIS.
<https://www.gislounge.com/history-of-gis/>
- Gnat, S.** (2021). Property Mass Valuation on Small Markets. *Land*, 10(4), 388.
<https://doi.org/10.3390/land10040388>
- Goebelbecker, E.** (2020). Function as a Service (FaaS) Explained.
<https://www.scalyr.com/blog/function-as-a-service-faas/>
- Goodfellow, I., Bengio, Y. ve Courville, A.** (2016). *Deep Learning*. MIT Press, mit press sürüm.
<https://mitpress.mit.edu/9780262035613/>
- Gunes, T. ve Yildiz, U.** (2015). Mass valuation techniques used in land registry and cadastre modernization project of Republic of Turkey. In *FIG Working Week 2015*, (s.1–18). Sofia, Bulgaria.
- Güngör, E.** (1999). *Gayrimenkul Değerlemesi ve Türkiye’de Sermaye Piyasalarında Gayrimenkul Ekspertiz Şirketlerine Yönelik Düzenlemeler Yapılmasına İlişkin Öneriler*. Sermaye Piyasası Kurulu.
- Guo, K., Wang, J., Shi, G. ve Cao, X.** (2012). Cluster analysis on city real estate market of China: based on a new integrated method for time series clustering. *Procedia Computer Science*, 9, 1299–1305.
<https://doi.org/10.1016/J.PROCS.2012.04.142>
- Hagras, H.** (2018). Toward Human-Understandable, Explainable AI. *Computer*, 51(9), 28–36.
<https://doi.org/10.1109/MC.2018.3620965>
- Hassoun, M.H. ve diğ** (1995). *Fundamentals of artificial neural networks*. MIT press.
- Helmi, A.M., Farhan, M.S. ve Nasr, M.M.** (2018). A framework for integrating geospatial information systems and hybrid cloud computing. *Computers & Electrical Engineering*, 67, 145–158.
- HM Land Registry** (2022). HM Land Registry.
<https://www.gov.uk/government/organisations/land-registry/about>

- Ho, W.K., Tang, B.S. ve Wong, S.W.** (2021). Predicting property prices with machine learning algorithms. *Journal of Property Research*, 38(1), 48–70.
<https://doi.org/10.1080/09599916.2020.1832558>
- Hogge, B.** (2016). GOVLAB Open Data's Impact.
<https://odimpact.org/case-united-kingdoms-hm-land-registry-price-paid-data.html>
- Huang, B., Wu, B. ve Barry, M.** (2010). Geographically and temporally weighted regression for modeling spatio-temporal variation in house prices. *International Journal of Geographical Information Science*, 24(3), 383–401.
<https://doi.org/10.1080/13658810802672469>
- Huang, Y. ve Hewings, G.** (2021). More Reliable Land Price Index: Is There a Slope Effect? *Land*, 10(3), 261.
<https://doi.org/10.3390/LAND10030261>
- Hubbard, A.** (2019). Amazon EC2 to S3: A guide to AWS products.
<https://searchaws.techtarget.com/feature/Amazon-Web-Services-product-directory>
- IAAO** (2013a). *Guidance on International Mass Appraisal and Related Tax Policy*. International Association of Assessing Officers.
- IAAO** (2013b). *Standard on Mass Appraisal of Real Property*. International Association of Assessing Officers.
- IAAO** (2013c). *Standards on Ratio Studies*. International Association of Assessing Officers.
- IAAO** (2017). *Standard on Mass Appraisal of Real Property*. International Association of Assessing Officers.
- IAAO** (2018). *Standard on Automated Valuation Models (AVMs)*. International Association of Assessing Officers.
- IMO** (2022). Yapı Yaklaşık Maliyet Hesabı.
<https://www.imo.org.tr/TR,76522/birim-fiyat-ve-ucretler.html>
- ISO** (2001). Accessibility and usability of the built environment (ISO/TC 59/SC 16).
<https://www.iso.org/committee/291991.html>
- ISO** (2012). *ISO 19152:2012 Geographic information-Land Administration Domain Model (LADM)*. International Organization for Standardization.
- ISO** (2016). ISO 29481-1:2016 - Building information models — Information delivery manual — Part 1: Methodology and format.
<https://www.iso.org/standard/60553.html>
- ISO** (2020). ISO 16739-1:2020 - Industry Foundation Classes (IFC) for data sharing in the construction and facility management industries - Part 1: Data schema (ISO 16739-1:2018).
<https://standards.iteh.ai/catalog/standards/cen/10755a4c-7554-4735-92c2-27a57d2b2a79/en-iso-16739-1-2020>

- IVSC (2017).** Uluslararası Değerleme Standartları Konseyi.
<https://www.ivsc.org/files/file/view/id/812>
- IVSC (2020).** *International Valuation Standards*. International Valuation Standards Council.
- Jahanshiri, E., Buyong, T. ve Shariff, A.R.M. (2011).** A review of property mass valuation models. *Pertanika Journal of Science and Technology*, 19(SPEC. ISSUE), 23–30.
- Jennings, M. ve Lewis, R. (2017).** House price per square metre and house price per room, England and Wales.
<https://www.ons.gov.uk/economy/inflationandpriceindices/articles/housepricepersquaremetreandhousepriceperroomenglandandwales/2004to2016>
- Kalogianni, E., Janečka, K., Kalantari, M., Dimopoulou, E., Bydłoz, J., Radulović, A., Vučić, N., Sladić, D., Govedarica, M., Lemmen, C. ve van Oosterom, P. (2021).** Methodology for the development of LADM country profiles. *Land Use Policy*, 105, 105380.
<https://doi.org/10.1016/j.landusepol.2021.105380>
- Kara, A. (2021).** *Taşınmaz değerlemesine yönelik uluslararası bir veri modeli geliştirilmesi ve modelin Türkiye örneğinde uygulanması*. Phd thesis, Yıldız Teknik Üniversitesi.
- Kara, A., Çağdaş, V., Işıkdag, Ü., van Oosterom, P., Lemmen, C. ve Stubkjær, E. (2017).** Towards an International Data Standard for Immovable Property Valuation. In *FIG Working Week 2017*, (s.1–31). Helsinki, Finland: International Federation of Surveyors (FIG).
- Kara, A., Çağdaş, V., Isikdag, U., van Oosterom, P., Lemmen, C. ve Stubkjaer, E. (2021).** The LADM Valuation Information Model and its application to the Turkey case. *Land Use Policy*, 104, 105307.
<https://doi.org/10.1016/j.landusepol.2021.105307>
- Kara, A., Çağdaş, V., Van Oosterom, P. ve Stubkjaer, E. (2018).** Supporting Fiscal Aspect of Land Administration through a LADM-Based Valuation Information Model. In *2018 WORLD BANK CONFERENCE ON LAND AND POVERTY*, (s.1–34). Washington DC.
<https://research.utwente.nl/en/publications/supporting-fiscal-aspect-of-land-administration-through-an-ladm-b>
- Kara, A., van Oosterom, P., Çağdaş, V., Işıkdag, Ü. ve Lemmen, C. (2020).** 3 Dimensional data research for property valuation in the context of the LADM Valuation Information Model. *Land Use Policy*, 98, 104179.
<https://doi.org/10.1016/j.landusepol.2019.104179>
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q. ve Liu, T.Y. (2017).** LightGBM: A Highly Efficient Gradient Boosting Decision Tree. In *Advances in Neural Information Processing Systems (NIPS 2017)*, cilt 30, (s.3146–3154).
- Kelleher, J.D. (2019).** *Deep Learning*. MIT Press, mit press sürüm.

- Kiel, K.A. ve Zabel, J.E.** (2008). Location, location, location: The 3L Approach to house price determination. *Journal of Housing Economics*, 17(2), 175–190.
<https://doi.org/10.1016/j.jhe.2007.12.002>
- Kim, B. ve Kim, T.** (2016). A Study on Estimation of Land Value Using Spatial Statistics: Focusing on Real Transaction Land Prices in Korea. *Sustainability*, 8(3), 203.
<https://doi.org/10.3390/su8030203>
- Knoll, K., Schularick, M. ve Steger, T.** (2017). No Price Like Home: Global House Prices, 1870-2012. *American Economic Review*, 107(2), 331–53.
<https://doi.org/10.1257/AER.20150501>
- Lee, C.** (2022). Designing an optimal neural network architecture: an application to property valuation. *Property Management*.
<https://doi.org/10.1108/PM-12-2021-0106>
- Lemmen, C.** (2012). *A Domain Model for Land Administration*. *Doktora Tezi*, Netherlands Geodetic Commission, Publications on Geodesy, Delft.
- Lemmen, C., van Oosterom, P. ve Bennett, R.** (2015). The Land Administration Domain Model. *Land Use Policy*, 49, 535–545.
<https://doi.org/10.1016/j.landusepol.2015.01.014>
- Lemmen, C., van Oosterom, P., Kalantari, M., Unger, E.M. ve De Zeeuw, C.** (2019a). OGC White Paper on Land Administration. Teknik Rapor, Open Geospatial Consortium (OGC).
<http://docs.opengeospatial.org/wp/18-008r1/18-008r1.html>
- Lemmen, C., Van Oosterom, P., Kara, A., Kalogianni, E., Shnaidman, A., Indrajit, A. ve Alattas, A.** (2019b). The scope of LADM revision is shaping-up. In *8th International FIG workshop on the Land Administration Domain Model*, (s.1–36). Kuala Lumpur, Malaysia.
- Li, H., Calder, C.A. ve Cressie, N.** (2007). Beyond Moran's I: Testing for Spatial Dependence Based on the Spatial Autoregressive Model. *Geographical Analysis*, 39(4), 357–375.
<https://doi.org/10.1111/J.1538-4632.2007.00708.X>
- Li, Z.** (2022). Extracting spatial effects from machine learning model using local interpretation method: An example of SHAP and XGBoost. *Computers, Environment and Urban Systems*, 96, 101845.
<https://doi.org/10.1016/J.COMPENVURBSYS.2022.101845>
- Lindenthal, T. ve Johnson, E.B.** (2021). Machine Learning, Architectural Styles and Property Values. *The Journal of Real Estate Finance and Economics* 2021, (s.1–32).
<https://doi.org/10.1007/S11146-021-09845-1>
- Lisi, G.** (2019). Property valuation: the hedonic pricing model-location and housing submarkets. *Journal of Property Investment & Finance*, 37(6), 589–596.
<https://doi.org/10.1108/JPIF-07-2019-0093>

- Liu, X., Wang, X., Wright, G., Cheng, J.C., Li, X. ve Liu, R.** (2017). A State-of-the-Art Review on the Integration of Building Information Modeling (BIM) and Geographic Information System (GIS). *ISPRS International Journal of Geo-Information* 2017, Vol. 6, Page 53, 6(2), 53.
<https://doi.org/10.3390/IJGI6020053>
- Liu, Y., Wu, Y., Su, L., Li, W. ve Lei, J.** (2021). Stacking-Based Ensemble Learning Method for House Price Prediction. *Lecture Notes in Networks and Systems, 232 LNNS*, 224–237.
https://doi.org/10.1007/978-3-030-90318-3_22/FIGURES/8
- Lněnička, M. ve Komárková, J.** (2013). Cloud solutions for GIS and cloud-based testing of web-based GIS applications. *Scientific papers of the University of Pardubice. Series D, Faculty of Economics and Administration. 28 (3/2013)*.
- Lundberg, S.M. ve Lee, S.I.** (2017). A Unified Approach to Interpreting Model Predictions. In *Proceedings of the 31st International Conference on Neural Information Processing Systems*, (s.4768–4777). Curran Associates Inc.
<https://arxiv.org/abs/1705.07874v2>
- Malpezzi, S.** (2003). Hedonic Pricing Models: A Selective and Applied Review. *Housing Economics and Public Policy, 1*, 67–89.
<https://doi.org/10.1002/9780470690680.CH5>
- Manaugh, K. ve El-Geneidy, A.** (2011). Validating walkability indices: How do different households respond to the walkability of their neighborhood? *Transportation Research Part D: Transport and Environment, 16(4)*, 309–315.
<https://doi.org/10.1016/J.TRD.2011.01.009>
- McCord, M., Lo, D., Davis, P.T., Hemphill, L., McCord, J. ve Haran, M.** (2019). A spatial analysis of EPCs in The Belfast Metropolitan Area housing market. *Journal of Property Research, 37(1)*, 25–61.
<https://doi.org/10.1080/09599916.2019.1697345>
- McDermott, M., Myers, M. ve Augustinus, C.** (2018). VALUATION OF UNREGISTERED LANDS: A Policy Guide. Teknik Rapor, United Nations Human Settlements Programme (UN-Habitat).
- Mell, P. ve Grance, T.** (2011). The NIST definition of cloud computing.
<https://csrc.nist.gov/publications/detail/sp/800-145/final>
- Messenger, R.** (2010). Valuation at the Centre of EU Real Estate Policy, The European Group of Valuers Associations (TEGoVA).
<https://tego.va.org/>
- Mete, M.O., Guler, D. ve Yomralioglu, T.** (2022). Towards a 3D Real Estate Valuation Model Using BIM and GIS. *Lecture Notes in Networks and Systems, 393*, 945–962.
https://doi.org/10.1007/978-3-030-94191-8_77/COVER/

- Metem, M.O. ve Yomraliöglu, T.** (2019). Creation of Nominal Asset Value-Based Maps using GIS: A Case Study of Istanbul Beyoölu and Gaziosmanpasa Districts. *GI_Forum 2019*, 7(2), 98–112.
https://doi.org/10.1553/giscience2019_02_s98
- Metem, M.O. ve Yomraliöglu, T.** (2021). Implementation of serverless cloud GIS platform for land valuation. *International Journal of Digital Earth*, 14(7), 836–850.
<https://doi.org/10.1080/17538947.2021.1889056>
- Metem, M.O. ve Yomralioölu, T.** (2021). Açık Kaynaklı Bulut CBS Yardımıyla Kitlemel Taşınmaz Deöerleme Uygulaması. *Harita Dergisi*, 2021(165), 28–42.
- MKK GABİM** (2022). MKK Gayrimenkul Bilgi Merkezi A.Ş.
<https://mkkgabim.com.tr/>
- Mohd, T., Jamil, N.S., Johari, N., Abdullah, L. ve Masrom, S.** (2020). An Overview of Real Estate Modelling Techniques for House Price Prediction. In **N. Kaur ve M. Ahmad** (düzenleyenler) *Charting a Sustainable Future of ASEAN in Business and Social Sciences*, (s.321–338). Springer Singapore.
https://doi.org/10.1007/978-981-15-3859-9_28
- Moran, P.A.P.** (1950). Notes on Continuous Stochastic Phenomena. *Biometrika*, 37(1/2), 17.
<https://doi.org/10.2307/2332142>
- Mourouzi-Sivitanidou, R. ve Sivitanides, P.** (2020). *Market analysis for real estate*. Routledge.
<https://www.routledge.com/Market-Analysis-for-Real-Estate/Mourouzi-Sivitanidou-Sivitanides/p/book/9780367233501>
- NBS** (2020). 10th National BIM Report.
<https://www.thenbs.com/knowledge/national-bim-report-2020>
- Netzer, D.** (1998). The relevance and feasibility of land value taxation in the rich countries. In **D. Netzer** (düzenleyen) *Land Value Taxation: Can It and Will It Work Today*, (s.1–284). Cambridge, MA: Lincoln Institute of Land Policy.
- Nişancı, R.** (2005). *Coörafi Bilgi Sistemleri ile Nominal Deöerleme Yöntemine Dayalı Piksel Tabanlı Kentsel Taşınmaz Deöer Haritalarının Üretilmesi. Doktora Tezi*, KTÜ Fen Bilimleri Enstitüsü, Trabzon.
- Nichols, J.B., Oliner, S.D. ve Mulhall, M.R.** (2013). Swings in commercial and residential land prices in the United States. *Journal of Urban Economics*, 73(1), 57–76.
<https://doi.org/10.1016/J.JUE.2012.06.004>

- Noardo, F., Harrie, L., Ohori, K.A., Biljecki, F., Ellul, C., Krijnen, T., Eriksson, H., Guler, D., Hintz, D., Jadidi, M.A., Pla, M., Sanchez, S., Soini, V.P., Stouffs, R., Tekavec, J. ve Stoter, J.** (2020a). Tools for BIM-GIS Integration (IFC Georeferencing and Conversions): Results from the GeoBIM Benchmark 2019. *ISPRS International Journal of Geo-Information* 2020, Vol. 9, Page 502, 9(9), 502.
<https://doi.org/10.3390/IJGI9090502>
- Noardo, F., Malacarne, G., Mastrolembu Ventura, S., Tagliabue, L.C., Ciribini, A.L., Ellul, C., Guler, D., Harrie, L., Senger, L., Waha, A. ve Stoter, J.** (2020b). Integrating Expertises and Ambitions for Data-driven Digital Building Permits – The EUNET4DBP. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLIV-4-W1-2020(4/W1)*, 103–110.
<https://doi.org/10.5194/isprs-archives-XLIV-4-W1-2020-103-2020>
- OGC** (2016). OGC Land and Infrastructure Conceptual Model Standard (LandInfra).
<https://www.ogc.org/standards/landinfra>
- ONS** (2022). Median house prices by lower layer super output area: HPSSA dataset 46.
<https://www.ons.gov.uk/peoplepopulationandcommunity/housing/datasets/medianpricepaidbylowerlayersuperoutputareahpssadataset46>
- Open Data Barometer** (2017). Open Data Barometer 4th Edition.
<https://opendatabarometer.org/4thedition/>
- Özdilek, Ü.** (2016). Property Price Separation between Land and Building Components. *Journal of Real Estate Research*, 38(2), 205–228.
<https://doi.org/10.1080/10835547.2016.12091443>
- Pagourtzi, E., Assimakopoulos, V., Hatzichristos, T. ve French, N.** (2003). Real estate appraisal: a review of valuation methods. *Journal of Property Investment & Finance*, 21(4), 383–401.
<https://doi.org/10.1108/14635780310483656>
- Peng, Y. ve Wang, Y.** (2014). Geographic information system in the cloud computing environment. In *Computer Engineering and Networking*, (s.893–902). Springer.
- Peng, Z., Huang, Q. ve Han, Y.** (2019). Model Research on Forecast of Second-Hand House Price in Chengdu Based on XGboost Algorithm. *2019 IEEE 11th International Conference on Advanced Infocomm Technology, ICAIT 2019*, (s.168–172).
<https://doi.org/10.1109/ICAIT.2019.8935894>
- Peterson, S. ve Flanagan, A.** (2009). Neural Network Hedonic Pricing Models in Mass Real Estate Appraisal. *Journal of Real Estate Research*, 31(2), 147–164.
<https://doi.org/10.1080/10835547.2009.12091245>
- Powell-Smith, A.** (2018). House prices by square metre in England & Wales.
<https://houseprices.anna.ps>

- Price Paid Data** (2021). Price Paid Data.
<https://www.gov.uk/government/statistical-data-sets/price-paid-data-downloads>
- PrimeLocation** (2021). Heatmap of UK property values.
<https://www.primelocation.com/heatmaps/>
- Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A.V. ve Gulin, A.** (2017). CatBoost: unbiased boosting with categorical features. *arXiv preprint*, (s.6638–6648).
<https://arxiv.org/abs/1706.09516v5>
- Quang, T., Minh, N., Hy, D. ve Bo, M.** (2020). Housing Price Prediction via Improved Machine Learning Techniques. *Procedia Computer Science*, 174, 433–442.
<https://doi.org/10.1016/J.PROCS.2020.06.111>
- Ramsey, P.** (2019). Serving Dynamic Vector Tiles from PostGIS.
<https://info.crunchydata.com/blog/dynamic-vector-tiles-from-postgis>
- Regalado, A.** (2011). Who coined ‘cloud computing’. *MIT Technology Review*, 31.
- Renigier-Biłozor, M., Żróbek, S., Walacik, M., Borst, R., Grover, R. ve D’Amato, M.** (2022). International acceptance of automated modern tools use must-have for sustainable real estate market development. *Land Use Policy*, 113, 105876.
<https://doi.org/10.1016/j.landusepol.2021.105876>
- Resmi Gazete** (1970). Emlak Vergisi Kanunu.
<https://www.mevzuat.gov.tr/MevzuatMetin/1.5.1319.pdf>
- Resmi Gazete** (1972). EMLAK VERGİSİNE MATRAH OLACAK VERGİ DEĞERLERİNİN TAKDİRİNE İLİŞKİN TÜZÜK.
<https://www.mevzuat.gov.tr/MevzuatMetin/2.5.73995.pdf>
- Resmi Gazete** (1981). Sermaye Piyasası Kanunu.
<https://www.mevzuat.gov.tr/MevzuatMetin/1.5.2499.pdf>
- Resmi Gazete** (1983). Kamulaştırma Kanunu.
<https://www.mevzuat.gov.tr/mevzuatmetin/1.5.2942.pdf>
- Resmi Gazete** (2001). Türk Medeni Kanunu.
<https://www.mevzuat.gov.tr/mevzuatmetin/1.5.4721.pdf>
- Resmi Gazete** (2019). 30 Sayılı Cumhurbaşkanlığı Kararnamesi.
<https://www.resmigazete.gov.tr/eskiler/2019/02/20190205-7.pdf>
- RICS** (2022). Royal Institution of Chartered Surveyors (RICS).
<https://www.rics.org/uk/>
- Russell, S. ve Norvig, P.** (2009). *Artificial Intelligence: A Modern Approach*. Prentice Hall.
- Sacks, R., Eastman, C., Lee, G. ve Teicholz, P.** (2018). *BIM Handbook: A Guide to Building Information Modeling for Owners, Designers*, cilt 3. New Jersey: John Wiley & Sons, Inc., Hoboken.

- Sayın, Z.M.** (2021). *House Price Dynamics In İzmir's Neighborhoods: A Comprehensive Approach*. Master thesis, İzmir Institute of Technology.
- Shao, Y., Di, L., Bai, Y., Guo, B. ve Gong, J.** (2012). Geoprocessing on the Amazon cloud computing platform—AWS. In *2012 first international conference on agro-geoinformatics (agro-geoinformatics)*, (s.1–6). IEEE.
- Sisman, S. ve Aydinoglu, A.C.** (2022a). A modelling approach with geographically weighted regression methods for determining geographic variation and influencing factors in housing price: A case in Istanbul. *Land Use Policy*, 119(106183).
<https://doi.org/10.1016/j.landusepol.2022.106183>
- Sisman, S. ve Aydinoglu, A.C.** (2022b). Improving performance of mass real estate valuation through application of the dataset optimization and Spatially Constrained Multivariate Clustering Analysis. *Land Use Policy*, 119, 106167.
<https://doi.org/10.1016/J.LANDUSEPOL.2022.106167>
- SPK** (2001). Sermaye Piyasası Mevzuatı Çerçevesinde Gayrimenkul Değerleme Hizmeti Verecek Şirketler İle Bu Şirketlerin Kurulca Listeye Alınmalarına İlişkin Esaslar Hakkında Tebliğ, Seri: VIII, No: 35, Resmi Gazete, Sayı: 24491.
<http://mevzuat.spk.gov.tr/Onceki/MevzuatDosya.aspx?nid=1821&dt=2>
- İstanbul Valiliği** (2020). Nüfus Bakımından Türkiye'nin En Büyük Kenti: İstanbul.
<http://www.istanbul.gov.tr/nufus-bakimindan-turkiyenin-en-buyuk-kenti-istanbul>
- Star, J. ve Estes, J.E.** (1990). *Geographic information systems: an introduction*, cilt303. Prentice Hall Englewood Cliffs, NJ.
- Stewart Fotheringham, A. ve Park, B.** (2018). Localized Spatiotemporal Effects in the Determinants of Property Prices: A Case Study of Seoul. *Applied Spatial Analysis and Policy*, 11(3), 581–598.
<https://doi.org/10.1007/S12061-017-9232-8/TABLES/5>
- Sun Hong, C. ve Gyu Oh, T.** (2021). TPR-TNR plot for confusion matrix. *Communications for Statistical Applications and Methods*, 28(2), 161–169.
<https://doi.org/10.29220/CSAM.2021.28.2.161>
- Tajani, F., Morano, P. ve Ntalianis, K.** (2018). Automated valuation models for real estate portfolios: A method for the value updates of the property assets. *Journal of Property Investment and Finance*, 36(4), 324–347.
<https://doi.org/10.1108/JPIF-10-2017-0067>
- TDUB** (2019). TDUB Faaliyet Raporları.
<https://tdub.org.tr/faaliyet-raporlari?lang=tr>

- The European Data Portal** (2021). The Open Data Maturity (ODM) Report 2021. Teknik Rapor, European Union, Luxembourg.
https://data.europa.eu/sites/default/files/landscaping_insight_report_n7_2021.pdf
- Thompson, M.L. ve Zucchini, W.** (1989). On the statistical analysis of ROC curves. *Statistics in Medicine*, 8(10), 1277–1290.
<https://doi.org/10.1002/SIM.4780081011>
- Thorsnes, P.** (1997). Consistent Estimates of the Elasticity of Substitution between Land and Non-Land Inputs in the Production of Housing. *Journal of Urban Economics*, 42(1), 98–108.
<https://doi.org/10.1006/JUEC.1996.2015>
- TKGM** (2020a). Tapu ve Kadastro Modernizasyon Projesi Ek Finansmanı - Gayrimenkul Değerleme Bileşeni Kapsamında Toplu Değerleme Sisteminin Geliştirilmesi İçin Danışmanlık Hizmetleri.
https://www.tkgm.gov.tr/sites/default/files/2020-11/ihale_ilani.pdf
- TKGM** (2020b). Toplu Değerleme ve Veri Yönetimi Birimi.
<https://www.tkgm.gov.tr/tr/icerik/toplu-degerleme-ve-veri-yonetimi-birimi>
- TKGM** (2021a). Tapu ve Kadastro Bilgi Sistemi (TAKBİS).
<https://www.tkgm.gov.tr/bt-db/tapu-ve-kadastro-bilgi-sistemi-takbis>
- TKGM** (2021b). Tapu ve Kadastro Modernizasyon Projesi (TKMP).
<https://www.tkgm.gov.tr/tapu-ve-kadastro-modernizasyon-projesi-tkmp>
- Tobler, W.R.** (1970). A Computer Movie Simulating Urban Growth in the Detroit Region. *Economic Geography*, 46, 234.
<https://doi.org/10.2307/143141>
- TSE** (2011). TS 9111 - Özürlüler ve hareket kısıtlılığı bulunan kişiler için binalarda ulaşılabilirlik gerekleri.
<https://yalova.csb.gov.tr/bina-girisleri-icin-erisilebilirlik-standartlari-haber-231920>
- Turing, A.M.** (1956). Can a machine think. *The World of Mathematics*, 4, 2099–2123.
- UK Legislation** (2012). The Energy Performance of Buildings (England and Wales) Regulations (No: 3118).
- Ülger, C.B., Ülger, N.E. ve Yıldız, N..** (2019). *Taşınmaz Mal Değerlemesi*. Yem Yayınevi.
- UN-GGIM** (2019). Framework for Effective Land Administration (FELA). Teknik Rapor, United Nations Committee of Experts on Global Geospatial Information Management (UN-GGIM).
http://ggim.un.org/meetings/2018-Deqing-Expert-Group/documents/Concept_Note.pdf
- Ünel, F.B. ve Yalprı, ü.** (2019). Türkiye’de Taşınmazların Değerini Etkileyen Kriterlere Yaklaşım. *Geomatik*, 4(2), 112–133.
<https://doi.org/10.29128/geomatik.499681>

- URL-1.** Council Tax.
<https://www.gov.uk/council-tax>
- URL-2.** Stamp Duty Land Tax.
<https://www.gov.uk/stamp-duty-land-tax/residential-property-rates>
- van Oosterom, P., Kara, A., Kalogianni, E., Shnaidman, A., Indrajit, A., Alattas, A. ve Lemmen, C.** (2019). Joint ISO/TC211 and OGC Revision of the LADM: Valuation Information, Spatial Planning Information, SDG Land Indicators, Refined Survey Model, Links to BIM, Support of LA Processes, Technical Encodings, and Much More on Their Way! In *FIG Working Week 2019*, (s.1–25). Hanoi, Vietnam.
- Vettor, R. ve Smith, S.** (2022). Architecting Cloud-Native .NET Apps for Azure.
<https://docs.microsoft.com/tr-tr/dotnet/architecture/cloud-native/>
- VOA** (2022). Valuation Office Agency (VOA).
<https://www.gov.uk/government/organisations/valuation-office-agency/about>
- Wallner, R.** (2012). GIS Measures of Residential Property Views. *Journal of Real Estate Literature*, 20(2), 224–225.
<https://doi.org/10.1080/10835547.2014.12090338>
- Wang, D. ve Li, V.J.** (2019). Mass appraisal models of real estate in the 21st century: A systematic literature review. *Sustainability*, 11(7006), 1–14.
<https://doi.org/10.3390/su11247006>
- Wang, D., Li, V.J. ve Yu, H.** (2020). Mass Appraisal Modeling of Real Estate in Urban Centers by Geographically and Temporally Weighted Regression: A Case Study of Beijing’s Core Area. *Land*, 9(143).
<https://doi.org/10.3390/LAND9050143>
- Wang, H., Pan, Y. ve Luo, X.** (2019). Integration of BIM and GIS in sustainable built environment: A review and bibliometric analysis. *Automation in Construction*, 103, 41–52.
<https://doi.org/10.1016/J.AUTCON.2019.03.005>
- Wang, T., Wang, Y. ve Liu, M.** (2021). A Price Prediction Method Based on CatBoost. *Proceedings - 2021 International Conference on Culture-Oriented Science and Technology, ICCST 2021*, (s.403–408).
<https://doi.org/10.1109/ICCST53801.2021.00090>
- Wang, Y. ve Zhao, Q.** (2022). House Price Prediction Based on Machine Learning: A Case of King County. *7th International Conference on Financial Innovation and Economic Development*, (s.1547–1555).
<https://doi.org/10.2991/AEBMR.K.220307.253>
- Wentland, S.A., Ancona, Z.H., Bagstad, K.J., Boyd, J., Hass, J.L., Gindelsky, M. ve Moulton, J.G.** (2020). Accounting for land in the United States: Integrating physical land cover, land use, and monetary valuation. *Ecosystem Services*, 46, 101178.
<https://doi.org/10.1016/J.ECOSER.2020.101178>
- White, M.** (2021). Property Heatmap.uk.
<https://www.propertyheatmap.uk/>

- Wyatt, P.** (2013). *Property Valuation*. Wiley-Blackwell, 2nd sürüm.
<https://www.wiley.com/en-ao/Property+Valuation%2C+2nd+Edition-p-9781118624685>
- Wyatt, P.J.** (1997). The development of a GIS-based property information system for real estate valuation. *International Journal of Geographical Information Science*, 11(5), 435–450.
<https://doi.org/10.1080/136588197242248>
- Yalpr, Ş.** (2018). Enhancement of parcel valuation with adaptive artificial neural network modeling. *Artificial Intelligence Review*, 49(3), 393–405.
<https://doi.org/10.1007/s10462-016-9531-5>
- Yamani, S.E., Ettarid, M. ve Hajji, R.** (2019). Building Information Modeling Potential For An Enhanced Real Estate Valuation Approach Based On The Hedonic Method. In *Building Information Modelling (BIM) in Design, Construction and Operations III*, cilt 1, (s.305–316). WIT Press.
<https://doi.org/10.2495/bim190261>
- Yang, Y. ve Diez-Roux, A.V.** (2012). Walking Distance by Trip Purpose and Population Subgroups. *American Journal of Preventive Medicine*, 43(1), 11–19.
<https://doi.org/10.1016/J.AMEPRE.2012.03.015>
- Yargıtay** (2017). 5. Hukuk Dairesi, 2017/6099 E., 2017/24836 K.
<https://karararama.yargitay.gov.tr/YargitayBilgiBankasiIstemciWeb/>
- Yilmazer, S. ve Kocaman, S.** (2020). A mass appraisal assessment study using machine learning based on multiple regression and random forest. *Land Use Policy*, 99(104889).
<https://doi.org/10.1016/j.landusepol.2020.104889>
- Yomralioğlu, T.** (1993). *A Nominal Asset Value-Based Approach For Land Readjustment And Its Implementation Using Geographical Information Systems*. Phd. thesis, University of Newcastle upon Tyne.
- Yomralioğlu, T. ve Nisanci, R.** (2004). Nominal asset land valuation technique by GIS. In *FIG Working Week 2004*, (s.1–9). Athens, Greece.
- Yomralioğlu, T.** (1997). Eşdeğer İlkesine Dayalı Arsa ve Arazi Düzenlemesi Modeli. *JEFOD Kentsel Alan Düzenlemelerinde İmar Planı Uygulama Teknikleri*, 1(1), 139–152.
- Yomralioğlu, T.** (2000). *Coğrafi bilgi sistemleri: Temel kavramlar ve uygulamalar*. Karadeniz Teknik Üniversitesi.
- Yomralioğlu, T.** (2022). Taşınmaz değerlemesi ders notları, İstanbul teknik Üniversitesi, İstanbul.
- Yu, S.M., Han, S.S. ve Chai, C.H.** (2007). Modeling the value of view in high-rise apartments: A 3D GIS approach. *Environment and Planning B: Planning and Design*, 34(1), 139–153.
<https://doi.org/10.1068/b32116>


- Zhou, Y. ve Haurin, D.R.** (2020). On the Determinants of House Value Volatility. *Journal of Real Estate Research*, 32(4), 377–395.
<https://doi.org/10.1080/10835547.2010.12091292>
- Zingat** (2019). Zingat API Platformu.
<https://lp.zingat.com/zingat-api/>
- İzmir Valiliği** (2022). İzmir Valiliği.
<http://www.izmir.gov.tr/ilcelerimiz>
- Zurada, J., Levitan, A. ve Guan, J.** (2011). A Comparison of Regression and Artificial Intelligence Methods in a Mass Appraisal Context. *Journal of Real Estate Research*, 33(3), 349–388.
<https://doi.org/10.1080/10835547.2011.12091311>

EKLER


EK A : Deęer Kümelerine Ait SHAP Grafikleri

EK B : Yapı Yaklaşık Birim Maliyet Hesabı


EK A: Değer Kümelerine Ait SHAP Grafikleri




Şekil A1 : Kümeleme analizi sonrası oluşturulan birinci değer bölgesine ait SHAP değerleri.




Şekil A2 : Kümeleme analizi sonrası oluşturulan ikinci değer bölgesine ait SHAP değerleri.



Şekil A3 : Kümeleme analizi sonrası oluşturulan üçüncü değer bölgesine ait SHAP değerleri.



Şekil A4 : Kümeleme analizi sonrası oluşturulan dördüncü değer bölgesine ait SHAP değerleri.



Şekil A5 : Kümeleme analizi sonrası oluşturulan beşinci değer bölgesine ait SHAP değerleri.

EK B: Yapı Yaklaşık Birim Maliyet Hesabı

Çizelge B1 : Yapı yaklaşık maliyeti için malzeme metraj ve birim fiyat hesabı.

No	İmalat Cinsi	Poz Numarası	Tanım	Birim Fiyat	Metraj	Fiyat (100m ²)
1	Duvar	15.220.1004	135 mm kalınlığında yatay delikli tuğla (190 x 135 x 190 mm) ile duvar yapılması	142,33	0,15	6404,85
2	Beton Demiri	15.160.1004	Ø 14 - Ø 28 mm nervürlü beton çelik çubuğu, çubukların kesilmesi, bükülmesi ve yerine konulması	19290,13	34,00	65586,44
3	Beton	15.150.1005	Beton santralinde üretilen veya satın alınan ve beton pompasıyla basılan, C25/30 basınç dayanım sınıfında, gri renkte, normal hazır beton dökülmesi (beton nakli dahil)	1046,16	0,38	39754,08
4	Kalıp	15.180.1003	Plywood ile düz yüzeyli betonarme kalıbı yapılması	173,93	2,60	45221,80
5	Kalıp İskelesi	15.185.1005	Çelik borudan kalıp iskelesi yapılması	25,44	2,80	7123,20
6	İş İskelesi	15.185.1013	Ön yapımlı bileşenlerden oluşan tam güvenli, dış cephe iş iskelesi yapılması. (0,00-51,50 m arası)	40,58	1,43	5802,94
7	İç Sıva	15.275.1102	200/250 kg kireç/çimento karışımı kaba ve ince harçla sıva yapılması (iç cephe sıvası)	107,06	2,40	25694,40
8	Dış Sıva	15.275.1101	250/350 kg çimento dozlu kaba ve ince harçla sıva yapılması (dış cephe sıvası)	118,70	1,30	15431,00
9	Tavan Sıvası	15.275.1103	250/350 kg kireç/çimento karışımı kaba ve ince harçla sıva yapılması tavan sıvası)	110,26	0,90	9923,4
10	Badana (iç)	5.540.1252	Yeni sıva yüzeylere üç kat beyaz kireç badana yapılması	38,65	3,00	11595,00
11	Boya (iç)	15.540.1257	Yeni sıva yüzeylere macun ve astar uygulanarak iki kat su bazlı ipekmat boya yapılması (iç cephe)	81,41	0,42	3419,22
12	Boya (dış)	15.540.1324	Brüt beton, sıvalı veya eski boyalı yüzeylere, astar uygulanarak silikon esaslı su bazlı boya yapılması	67,03	0,42	2815,26

Çizelge B.1 (devam): Yapı yaklaşık maliyeti için malzeme metraj ve birim fiyat hesabı.

No	İmalat Cinsi	Poz Numarası	Tanım	Birim Fiyat	Metraj	Fiyat (100m ²)
13	Fayans - Seramik	15.380.1055	(25x33 cm) veya (25x40 cm) anma ebatlarında, her türlü desen ve yüzey özelliğinde, I.kalite, renkli seramik duvar karoları ile 3 mm derz aralıklı duvar kaplaması yapılması	145,71	0,30	4371,30
14	Ahşap Pencere	15.515.1001	Ahşaptan kasa ve pervazlı tek satırlı pencere yapılması ve yerine konulması	662,38	0,12	7948,56
15	Cam	15.470.1003	Ahşap doğramaya çita ile 5+5 mm kalınlıkta 12 mm ara boşluklu çift camlı pencere ünitesi takılması	839,76	0,10	8397,60
16	Çatı	15.320.1001	Mevcut ahşap, betonarme yada çelik aşıklar üzerine, 50 mm poliüretan yalıtımlı (üstü 0.50 mm kalınlıkta boyalı galvanizli sac ve altı 0.40 mm kalınlıkta boyalı galvanizli sac) çatı paneli ile çatı örtüsü yapılması	392,46	1,33	52197,18
17	Döşeme Kaplaması	15.375.1054	(42,5x42,5 cm) veya (45x45 cm) anma ebatlarında, her türlü desen ve yüzey özelliğinde, I.kalite, renkli seramik yer karoları ile 3 mm derz aralıklı döşeme kaplaması	149,74	0,90	13476,60
TOPLAM:						325162,83

ÖZGEÇMİŞ

Ad Soyad: Muhammed Oğuzhan METE

ÖĞRENİM DURUMU :

- **Lisans** : 2017, İstanbul Teknik Üniversitesi, İnşaat Fakültesi, Geomatik Mühendisliği Bölümü
- **Yüksek Lisans** : 2019, İstanbul Teknik Üniversitesi, Geomatik Mühendisliği Bölümü

MESLEKİ DENEYİMLER:

- 2017 yılında İstanbul Teknik Üniversitesi'nde Lisans öğrenimini tamamladı.
- 2019 yılında İstanbul Teknik Üniversitesi'nde Yüksek Lisans öğrenimini tamamladı.
- 2019 yılında İstanbul Teknik Üniversitesi'nde Doktora öğrenimine başladı.
- 2018 yılının Nisan ayından itibaren İstanbul Teknik Üniversitesi Geomatik Mühendisliği Bölümü'nde Araştırma Görevlisi olarak çalışmaktadır.

DOKTORA TEZİNDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- **Mete M.O.** ve Yomralioglu T., 2021. Implementation of serverless cloud GIS platform for land valuation. *International Journal of Digital Earth*, 14:7, 836-850. DOI: 10.1080/17538947.2021.1889056 (SCI Makale).
- **Mete M.O.** ve Yomralioğlu T., 2021. Açık Kaynaklı Bulut CBS Yardımıyla Kitlesel Taşınmaz Değerleme Uygulaması. *Harita Dergisi*, 165, 28-42 (Makale).
- **Mete M.O.** ve Yomralioglu T., 2022. A hybrid approach for mass valuation of residential properties through Geographic Information Systems and Machine Learning integration. *Geographical Analysis*. DOI: 10.1111/gean.12350 (SCI Makale).
- **Mete M.O.**, Guler, D. ve Yomralioglu T., 2022. Towards a 3D Real Estate Valuation Model Using BIM and GIS. In: Ben Ahmed, M., Boudhir, A.A., Karas, İ.R., Jain, V., Mellouli, S. (eds) *Lecture Notes in Networks and Systems, Innovations in Smart Cities Applications Volume 5. SCA 2021 vol 393*. Springer, Cham. DOI: 10.1007/978-3-030-94191-8_77 (Kitap Bölümü).

- **Mete M.O.** ve Yomraliöglu, T., 2022. GIS & Machine Learning based Mass Appraisal of Residential Properties in England & Wales. *30th GISRUK Conference 2022*, 5-8 Nisan, 2022 Liverpool, İngiltere. DOI: 10.5281/zenodo.6410120 (Tam Metin Bildiri).
- **Mete M.O.** ve Yomraliöglu, T., 2022. CBS ve Makine Öörenmesi Yöntemleri ile Konut Amaçlı Taşınmazların Toplu Deöerlemesi. *XI. TUFUAB*, 12-14 Mayıs 2022 Mersin (Tam Metin Bildiri).
- **Mete M.O.** ve Yomraliöglu, T., 2022. Mass Valuation of Real Estate Using GIS-based Nominal Valuation and Machine Learning Methods. *28th Annual Conference of the European Real Estate Society (ERES)*, 22-25 Haziran, 2022 Milano, İtalya (Tam Metin Bildiri).

DİöER YAYINLAR, SUNUMLAR VE PATENTLER:

- **Mete M.O.**, Guler D., Yomraliöglu T., 2018. Development of 3D Web GIS Application with Open Source Library. *Selcuk Univ. J. Eng. Sci. Tech.*, 6, Special Issue, pp. 818-824. DOI: 10.15317/Scitech.2018.171. (Makale)
- **Mete M.O.** ve Yomraliöglu, T., 2019. Creation of Nominal Asset Value-Based Map With GIS: Case Study Of Istanbul Beyöglu & Gaziosmanpaşa Districts. *GI_Forum*, DOI: 10.1553/giscience2019_02_s98 (Makale).
- **Mete M.O.** ve Yomraliöglu T., 2019. CBS ile Nominal Taşınmaz Deöer Haritası Üretiminde Çözünürlük Araştırması. *Türkiye Arazi Yönetimi Dergisi*, 1, 16-23 (Makale).