

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ İNŞAAT FAKÜLTESİ

CBS ve Makine Öğrenmesi Yöntemleri İle Toplu Taşınmaz Değerleme

LİSANS TASARIM PROJESİ

**010150582
Halise ÖZER**

**010170516
Hüseyin ÖZGENÇ**

Geomatik Mühendisliği

**Tez Danışmanı:
Prof. Dr. Tahsin YOMRALIOĞLU**

MAYIS, 2022

İÇİNDEKİLER

Sayfa

KISALTMALAR.....	IV
ŞEKİL LİSTESİ.....	V
TABLO LİSTESİ	VI
1. GİRİŞ	1
1.1 Genel Bilgiler	2
1.2 Problem Tanımı	2
1.3 Çalışmanın amacı	2
1.4 Metodoloji	3
1.5 Literatür Çalışması	4
2. TEMEL KAVRAMLAR	8
2.1 Coğrafi Bilgi Sistemleri.....	8
2.2 Taşınmaz Değerleme	9
2.3 Toplu (Küme) Değerleme.....	9
2.4 Nominal Değerleme.....	10
2.5 Makine Öğrenmesi	10
3. YAPILAN ÇALIŞMALAR.....	13
3.1 Çalışma Alanı	13
3.2 Taşınmaz Değerlerine Etki Eden Faktörler	14
3.3 Veri Tabanı Tasarımı.....	15
3.4 Konumsal Analizler.....	16
3.4.1 Yakınlık analizleri	17
3.4.2 Yüzey analizleri.....	20
3.4.3 Görünürlük analizleri	23
3.5 Ağırlıkların Belirlenmesi	24
3.6 Makine Öğrenmesi	25
3.6.1 Gradyan Artırma	26
3.6.2 Hafif Gradyan Hızlandırma Makineleri	26
3.6.3 XGBoost.....	27
3.6.4 CatBoost	27
3.6.5 Yapay Sinir Ağları	28
3.6.6 Rastgele Orman	28
3.6.7 Çoklu Doğrusal Regresyon	29

3.7	Nominal Taşınmaz Değer Haritası	29
4.	BULGULAR.....	35
5.	SONUÇ VE ÖNERİLER.....	36
	KAYNAKLAR.....	39
	EKLER.....	42
	EK A: Haritalar.....	43
	EK B: Tablolar.....	88

KISALTMALAR

AHP	: Analitik Hiyerarşı Prosesi
ANN	: Artificial Neural Network
AVM	: Alışveriş Merkezi
CatBoost	: Category Boosting
CBS	: Coğrafi Bilgi Sistemleri
CPU	: Central Process Unit
ÇKKV	: Çok Ölçütlü Karar Verme
ÇLR	: Çoklu Lineer Regresyon
ÇR	: Çoklu Regresyon
DVM	: Destek Vektör Makineler
DVR	: Destek Vektör Regresyon
ESRI	: Environmental Systems Research Institute
GIS	: Geographic Information Systems
GPU	: Graphics Processing Unit
LightGBM	: Light Gradient Boosting Machines
MAPE	: Ortalama Mutlak Yüzde Hata
RICS	: Royal Institution of Chartered Surveyors
SPK	: Sermaye Piyasası Kurulu
SYM	: Sayısal Yükseklik Verisi
XGBoost	: Extreme Gradient Boosting
YSA	: Yapay Sinir Ağları

ŞEKİL LİSTESİ

Sayfa

Şekil 1- Farklı disiplinler arasında CBS'nin yeri [17]	9
Şekil 2- Makine Öğrenmesi Yöntem ve Türleri [10]	12
Şekil 3- Çalışma Kapsamındaki Şehirler (İngiltere)	14
Şekil 4- Öklid uzaklığı çalışma prensibi [38]	17
Şekil 5- Londra'daki üniversitelerin öklid mesafesi ile yakınlık analizi	17
Şekil 6- Yeniden sınıflandırma yapılmış Londra üniversite yakınlık haritası	20
Şekil 7- Yüzde ve derece cinsinden değerlerin karşılaştırması [42]	20
Şekil 8- Bakı analizinin çalışma prensibi [40]	21
Şekil 9- Bakı yönlerinin açı dairesi üzerinde ifadesi [41]	22
Şekil 10- Londra eğim analizi haritası.	22
Şekil 11- Londra bakı analiz haritası	23
Şekil 12- Londra göl manzarası haritası	24
Şekil 13- Londra nominal taşınmaz değer haritası	31
Şekil 14- Manchester nominal taşınmaz değer haritası	31
Şekil 15- Liverpool nominal taşınmaz değer haritası	32
Şekil 16- Newcastle nominal taşınmaz değer haritası	32
Şekil 17- Newcastle şehri için özelliklerin önem puanları	33
Şekil 18- Liverpool şehri için özelliklerin önem puanları	33
Şekil 19- Londra şehri için özelliklerin önem puanları	34
Şekil 20- Manchester şehri için özelliklerin önem puanları	34

TABLO LİSTESİ

Sayfa

Tablo 1- Taşınmaz değerini etkileyen faktörler.	15
Tablo 2- Londra şehri için Regresyon modellerinin doğruluk metrikleri	25
Tablo 3- Londra şehri için özellik zenginleştirme sonrası doğruluk metrikleri	25
Tablo 4- Taşınmaz değerlerine etki eden kriterler ve ağırlık katsayıları.....	30

1. GİRİŞ

İnsanlık var olduğu günden beri toprak ile her daim bir ilişki içerisinde bulunmuştur. Bu ilişki bir sahiplik ilişkisidir ve bu da mülkiyet kavramını ortaya çıkartmıştır. İlk başta mülkiyet kavramı yaşamak ve barınmak için kullanılan yer anlamına gelmekte iken, zaman ilerledikçe bu görüş yerini taşınmazların yatırım amaçlı da kullanılabileceğine bırakmıştır. Böylece taşınmazların menkulleştirilmesi işlemlerinde artış yaşanmış bununla birlikte taşınmazların değer tespit çalışmalarına da büyük bir ivme kazandırmıştır [1].

Değerlemesini yapacağımız taşınmaz kavramına baktığımız zaman sözlükte “bir yerden başka bir yere özüne zarar vermeden götürülemeyen, taşınabilir olmayan, tarla, ev gibi mallar” olduğunu görmekteyiz.

Değer kavramı ise Türk Dil Kurumu sözlüğüne göre “bir şeyin para ve benzeri bir şeyle ölçülebilen ederi, karşılığı” anlamına gelmektedir [2]. Ayrıca bir eşyanın konum ve niteliklerine ve kişilerin ihtiyaçlarına göre farklılık gösteren öznel bir kavramdır. Taşınmaz konusunda değerlendirmeyi inceler isek, ilgili taşınmazın gayrimenkul projesinin ya da bir taşınmaza bağlı hak ve faydaların belirli bir tarihte bulunan muhtemel değerinin mümkün olduğu şekilde objektif olarak belirlenmesi şeklinde tanımlayabiliriz.

İlk zamanlardan günümüze kadar olan süreçte taşınmaz mallar, toplumsal servetin büyük bir bölümünü oluşturmuştur. Taşınmaz maliki olan her bir birey taşınmazının gerçek değerini bilmek ister. Sadece maliki olan bir birey değil ayrıca vergi alımı gibi birçok kamusal işlemlerde de kullanılabilmesi için taşınmaz değerinin doğru tespiti bir zorunluluktur. Taşınmazların ekonomisine konu olan kiralama, alım-satım, trampa, irtifak hakkı tesis edilmesi, tapuda aynı ve sınırlı hak tesis edilmesi, taşınmazların kısmen veya tamamen kamulaştırılması, devletleştirilmesi, ortaklığa aynı sermaye konulması gibi hemen hemen tüm işlemler ile taşınmaz gelirlerinden vergi alınabilmesi taşınmazların değerinin bilinmesine bağlıdır [3].

Toplu değerlendirme; istatistiksel inceleme sonucunda el edilen verilerin, uygun değerlendirme metodları kullanılarak sistematik ve düzenli bir şekilde uygulanması sonucunda, belirli bir tarihte birden fazla mülkün değerlemesinin yapılmasıdır. Diğer bir ifade ile toplu değerlendirme, bir grup taşınmazın, bir değerlendirme modeli kullanılarak, örneklem kümesi üzerinde yapılan istatistik testlerle sistematik değerlemesinin yapılmasıdır [4].

Toplu taşınmaz değerlendirme yönteminde, Coğrafi Bilgi Sistemi verilerin güncelliğinin tutulmasında ve değerlemenin de doğru sonuçlar vermesinde etkili olan bir bilgi sistemidir. Bu

sebeple toplu taşınmaz değerlemelerinde taşınmazların gerçek değerlerini bulmak için günümüzde en çok kullanılan sistemlerden biridir.

1.1 Genel Bilgiler

Çalışma kapsamında toplu taşınmaz değerlendirme konusunda literatür araştırmaları yapılmış ve buradan elde edilen bilgiler ile taşınmaz değerini etki eden faktörler belirlenmiştir. Çalışma bölgesi olarak Birleşik Krallık’da bulunan Londra, Manchester, Liverpool ve Newcastle şehirleri seçilmiştir. Buradaki bölgeler baz alınarak çalışma alanına ait açık coğrafi veriler temin edilmiş ve değerlendirme çalışması kapsamında kullanılmıştır. Yapılan toplu değerlendirme çalışması için “Coğrafi Bilgi Sistemleri” ve “Makine Öğrenmesi Algoritmaları” ortaklaşa kullanılmıştır.

1.2 Problem Tanımı

Taşınmaz değerlendirme çalışmaları sadece bir veya iki veri kullanılarak yapılan çalışmalar değildir. Taşınmaz değerleri etkileyen birden çok faktör bulunmaktadır. Bunlar bazen kişiye göre, bazen ise toplumun genel bir kabulü olan faktörlerdir.

Örneğin taşınmaz mal değerlemesinde yaygın olarak kullanılan yöntemlerden biri olan emsal karşılaştırma yöntemini incelediğimiz vakit, kullanıldığı bir taşınmaz mal değerlemesi çalışmasında, resmi kurumlardaki araştırmalardan sonra değerlendirme uzmanının sahaya giderek değerlendirme konusu mülke emsal teşkil edecek derecede benzer nitelik ve öznelitliklere sahip taşınmazlar bulması ve bu taşınmazlara ait satış fiyatı, kira bedeli, rayiç değeri gibi bilgileri öğrenmesi gerekmektedir. Oldukça detaylı ve yoğun bir çalışma gerektiren bu ve benzeri işlemler gerek saha gerek ise büro ortamında zaman ve dikkat gerektiren çalışmalardır [5].

Ayrıca vergilendirme işlemlerinde, beyan değerleri, kamulaştırma değeri, piyasa değeri arasında farklılar çıkması gibi problemler güncel olarak yaşanan sorunlar arasındadır. Bunlara ek olarak da gerek devlet gerekse özel kurumların arasında dahi aynı taşınmaz üzerinde farklı değer tespitleri olduğu gözlemlenebilmektedir. Bunların sonucunda ise hem vatandaşlar hem de devlet sosyal ve ekonomik anlamda zarar görmektedir. Vatandaşlar bu değerlendirme farklılıklarından ötürü mahkemelere başvurmakta ve devlet tarafında büyük vergi kayıpları olmaktadır.

1.3 Çalışmanın amacı

Çalışma kapsamında toplu taşınmaz değerlendirme işleminin “Coğrafi Bilgi Sistemi” ve “Makine Öğrenmesi” metotları kullanılarak tarafsız ve bilimsel bir yol ile yapılması amaçlanmaktadır. Bu yöntemler ile üretilcek olan değer haritası ile çalışma bölgesindeki

taşınmazların arsa değerine ve çevresine ait bilgilere tek bir platform üzerinden erişilebilmesine olanak sağlamayı ve değer esaslı çalışmalara önemli bir referans sunabilmeyi amaçlanmaktadır. Bu sayede, taşınmaz mal değerlemesinde saha çalışmaları sırasında daha pratik ve güvenilir bir şekilde veri toplama, depolama ve sorgulama yapılarak zaman ve maliyet bakımından tasarruf elde edilmesi amaçlanmaktadır.

Ayrıca, taşınmaz değerlendirme sektöründe şeffaf bir piyasa oluşturulması ve bu sektörün ihtiyacı olan veri tabanının oluşturulmasında bir referans olması amaçlanmaktadır. Bu sayede, kamu ve devlet kuruluşlarının yanı sıra; ekonomi, bankacılık, finans gibi sektörlerin taşınmaz mala endeksli işlemlerinde dolaylı olarak ülke ekonomisine katkı sağlayacağı öngörülmektedir.

1.4 Metodoloji

Taşınmazların değerinin belirlenmesinde kullanılan bir yöntemlerden biri de “nominal değerlendirme” yöntemidir. Bu yöntem daha çok taşınmazlar için parametrik değerlerinin belirlenmesi için kullanılan bir değerlendirme yöntemidir. Nominal değerlendirme yöntemi taşınmazların sahip oldukları özelliklere bağlı olarak topyekûn değerlendirilmesini gerekli kılar [6].

Toplu değerlendirme işlemi yapılırken belirlenen sınırlar içerisinde kalan taşınmazların değerleri birbirinin aynısı olarak alınmaktadır. Lakin bu şekilde yapılan değerlemelerde birçok kriter göz ardı edildiği için taşınmazların değerleri gerçeği yansıtmamaktadır. Her taşınmazın birbirine göre bazı olumlu ve olumsuz tarafları vardır. Gerçek değerlere ulaşılabilmesi için değer dağılımları oluşturulması gerekir. Değer dağılımları hesaplanırken birim rayiç bedel veya puanlama yöntemiyle bulunan parametrik değerler referans alabilir [7].

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

V: Toplam nominal değer

S: Parsel ya da piksel alanı

f: Faktör değeri (puan)

w: Faktör ağırlığı

k: Toplam faktör sayısı

Aşağıdaki tabloda Nominal Değerleme yönteminin olumlu ve olumsuz yanları verilmiştir.

Olumlu	Olumsuz
1. Nominal değerleme ile taşınmazlar arası değer dağılımı kolayca gözükebilmektedir, 2.Değere konu kriterlerin formüle edilmesiyle bilimsel bir yaklaşım ortaya çıkar, 3.Rayıç bedelden ayrı ve objektif bir şekilde elde edilmektedir, 4.Matematik modele dayalı olduğundan yoruma pek açık değildir, 5.Değer haritasının hazırlanmasına geniş tabanlı bir veri desteği sağlar, 6.Taşınmaz birim değerlerinin düzenli olarak kontrol edilmesini sağlar.	1.Dikkate alınacak değer kriterlerin sınıflandırılması ve sınırlandırılması oldukça güçtür, 2.Değer kriterlerinin formülasyonu gerekir, 3.Kriterlerin öncelik sıralaması ve kriter ağırlıklarının belirlenmesi sorundur, 4.Sübjektif kriterlerin formül ile ifadesi yoruma açıktır.

Proje kapsamında pilot uygulama alanı olarak İngiltere yer alan örnek teşkil edecek sayıda yapılı parsel seçilerek bunların “Price Paid Data” yani taşınmazların satış değerleri verileri elde edilmiştir. Bu bilgiler için Birleşik Krallık hükümetinin kamu sektörü için oluşturduğu web sitesinden yararlanılmıştır.

Çalışmanın amacına yönelik olarak, dünyada önde gelen CBS yazılım firmalarında biri olan ESRI ArcGIS ve QGIS yazılımları ile Python-3 yazılım dili ve çeşitli kütüphaneleri kullanılacaktır.

1.5 Literatür Çalışması

İnsanlığın en temel ihtiyaçlarından biri olan barınma ihtiyacı taşınmaz mallar tarafından karşılanmaktadır. Günümüzde konutların barınma ihtiyacının giderilmesinin dışında farklı şekillerde de kullanıldığı görülmektedir. Yatırım amacı olarak kullanılan taşınmaz mallara gün geçtikçe talep artmakta ve bu da değer tespit çalışmalarının önem kazanmasına yol açmaktadır.

Dünyada taşınmaz değerlemesine başlangıçta tarımsal arazilerin vergilendirilmesinde ihtiyaç duyulmuş, bu ihtiyaç zamanla; alım-satım, kiralama, sermaye piyasası, kredilendirme,

sigortacılık, kamulaştırma, devletleştirme, özelleştirme amaçlı değerlemelerle genişlemiştir [8]. Artan değerlendirme ihtiyacının karşılanabilmesi için ise ulusal taşınmaz değerlendirme sistemleri tesis edilmiştir. Değerleme alanındaki ulusal sistemlere, küreselleşmeyle birlikte, uluslararası kuruluş ve düzenlemeler de eklenmiştir.

Ülkemizde birçok farklı alanda, kamusal veya özel sektörde taşınmaz değerlemesi yapılmaktadır. Bu uygulamalar ilgili mevzuatta tanımlanan yöntemlerle ve komisyon veya kurumlarca yürütülmektedir.

- Kamulaştırma
- İmar Planı Uygulamalarında Taşınmaz Değerlemesi
- Vergilendirme
- Özelleştirme
- Medeni Yasa
- Tapu ve Kadastro İşlemleri
- Sermaye Piyasası Kurulu (SPK) gibi alanlarda taşınmaz değerlendirme işlemi ülkemizde yapılmaktadır [7].

Mekânsal ve mekânsal olmayan verilerin tek bir sistem altında toplanıp, depolanıp, saklanmasını sağlayan CBS, taşınmaz mal değerlendirme çalışmalarında sektörün ihtiyacı olan veri toplama, saklama, depolama ve hatta paylaşma ihtiyacını karşılayacak özelliktedir [4].

İngiltere’de taşınmaz değerlendirme kavramı incelendiğinde, taşınmaz değerlendirme standartları alanında faaliyet gösteren “Royal Institution of Chartered Surveyors (RICS)” yani “Lisanslı Ölçmeciler Kraliyet Enstitüsü” gibi bir kurum olduğunu görmekteyiz [7]. Taşınmaz değerlemesinde gerekli mesleki ilkeleri ve değerlendirme standartlarını içeren “Kırmızı Kitap” bu küresel organizasyon tarafından yayınlanmaktadır.

Destek Vektör Makineler (DVM), Destek Vektör Regresyon (DVR) ve Çoklu Lineer Regresyon (ÇLR) gibi makine öğrenme algoritmalarını taşınmaz değerlemede kullanılan klasik yöntemlere karşı alternatif değerlendirme yöntemi olarak kullanılabilirliği ve toplu değerlendirme sistemi oluşturma konusunda DVM’nin kullanılabilir durumda olması makine öğrenme algoritmalarının toplu değerlendirmede kullanılabilir bir durumda olduğunu göstermektedir [1].

Toplu taşınmaz değerlemesinde belirlenen kriterlerin ikili karşılaştırmalarına dayanan Çok Ölçütlü Karar Verme (ÇKKV) yöntemleri, sayısal veriler kullanılarak en uygun seçimin yapılmasına yardımcı olan sistemdir [9]. Bu yöntemlerden en yaygın kullanılanlarından biri

olan Analitik Hiyerarşi Prosesi (AHP) yöntemi, çok kriterli karar verme yönteminin nitel ve nicel çözümlemesinin birleşimidir. Bu yöntemle göre kriterler belirlenir ve önem sırasına göre bir hiyerarşi uygulanarak ağırlık hesabı yapar. Sonucunda ise çeşitli etkenlerin göreceli önemini inceler ve kararını ifade eder.

Canaz Sevgen ve Aliefendioğlu Tanrıvermiş tarafından Ankara ilinde yapılan bir çalışmada Rasgele Orman Regresyonu yönteminin, makine öğrenme teknikleri arasındaki yeri incelenmiş ve bu yöntemin gayrimenkullerin kitlesel değerlemesini nasıl yaptığı araştırılmıştır [10]. Bu araştırmadan elde edilen sonuçlara bakıldığında zaman ortalama olarak taşınmaz değerlerini doğruya yakın tahmin ettiği gözlemlenmiştir. Bu makine öğrenmesi yöntemlerinin toplu taşınmaz değerlemelerde kullanılabileceğini ve bu yöntemin de başarılı sonuçlar çıkartabildiğini ortaya koymaktadır. Makine öğrenme yöntemleriyle değerlendirilmesinin zaman ve insan gücü tasarrufu açısından pozitif etkilerinin olacağı da bu çalışma ile gösterilmiştir.

Muhammed Oğuzhan Mete'nin yapmış olduğu İstanbul çerçevesinde CBS yazılımları ile nominal değerlendirme çalışması, yapılan bu çalışma kapsamında çok önemli bir veri kaynağı olmuştur. Yapılan çalışma da tespit edilen bilimsel kriterleri kullanarak yapmış olduğu piksel bazlı nominal değerlerin elde edilmesi ve taşınmaz piyasasının standardizasyonu çalışması kapsamında kullanmış olduğu yöntemler ile seçmiş olduğu kriterlerin uyumlu olduğu görülmüştür. Seçilen kriterlere uygulanan yakınlık, görünürlük ve yüzey analizleri için belirlemiş olduğu yeniden sınıflandırma aralıklarının tutarlı olduğu görülmektedir. Çalışma kapsamında kullanılan ÇKKV ve BWM yöntemleri karşılaştırılmış, tutarlılık oranları tespit edilmiştir. Yapılan analiz sonuçları, raster tabanlı haritalara dönüştürülmüş ve piksellerin ağırlıklı toplamı ile nominal değerler hesaplanmıştır [5].

Ankara ili, Gölbaşı ilçesi için arazi değerlerini tahmin amacıyla yapılan bir çalışma da veri seti olarak 2017 yılındaki hazineye ait taşınmaz mallar seçilmiştir [11]. Taşınmaz değerine etki eden 13 parametre seçilmiştir. Makine öğrenmesi yöntemlerinden Yapay Sinir Ağları (YSA) ve Çoklu Regresyon (ÇR) yöntemi kullanılarak model oluşturulmuştur. Oluşturulan modellerin tahmin başarısı karşılaştırıldığında YSA'nın daha başarılı olduğu belirlenmiştir. Çalışma sonucunda örnek sayısının fazla olmadığı toplu taşınmaz değer tahmininde YSA'nın daha doğru tahmin yaptığı sonucu elde edilmiştir.

Kıbrıs'ın Lefkoşa şehrinde toplu konut değerlemeleri için makine öğrenmesi yöntemlerinden olan Rastgele Ormanların ve Çoklu Doğrusal Regresyon yöntemlerinin

kullanılması ve tahmin doğruluklarının belirlenmesidir [12]. Bu kapsamda kullanılan veriler Kıbrıs Tapu ve Kadastro Dairesi'nden alınmış ve modellerde kullanılacak bağımlı ve bağımsız değişkenler uzman görüşleri alınarak belirlenmiştir. Sonuç olarak iki yöntem karşılaştırılmış ve yüksek doğrulukla Rastgele Orman yönteminin toplu konut değerlemede faydalı bir yöntem olduğu belirlenmiştir.

Saint-Petersburg konut daireleri veri setine dayanan çalışmada CHAID, CART, KNN, Çoklu Regresyon Analizi, Yapay Sinir Ağları ve Yükseltilmiş Ağaçlar gibi teknikler ile Rastgele Orman tekniği karşılaştırılmıştır. Çalışma sonucunda aykırı değerlere karşı kararlılık, eksik değerlerle düzgün çalışma yeteneği ve birçok değişken yapılan toplu değerlemede Rastgele orman yönteminin diğer yöntemlere kıyasla daha doğru sonuçlar verdiği belirlenmiştir. Bu modelin, alanı 61,5 metre karenin altındaki daireler için ortalama %9,8'den daha az bir ortalama hata verdiği, Ortalama Mutlak Yüzde Hatanın (Mean Absolute Percentage Error- MAPE) ise daha büyük alana sahip daireler için %19,4 olduğu ve bunların arasında MAPE'nin ilçe 4, 5, 6, 9, 11, 12 %12,9 ve diğer ilçeler için %23,6 olduğu görülmektedir [13].

Konya ili, Selçuklu ilçesi için yapılan bu çalışmada Yazır mahallesindeki 200 taşınmazın özellikleri veri seti olarak kullanılmıştır. Bu veriler ile Yapay Sinir Ağları (YSA) ve Bulanık Mantık yöntemi ile modeller oluşturulmuştur. Elde edilen bu modellerin ortalama değeri YSA için %88,13, Bulanık Mantık Yöntemi için ise %84,39 sonucuna ulaşılmıştır. Bu çalışmanın sonucunda her iki yöntemde toplu taşınmaz değerlendirme için kullanılabileceği doğrulanmıştır. Ancak YSA ile hesaplanan değerlerin piyasa değerine daha yakın değerler tahmin etmesinden dolayı daha uygun yöntem olduğu gözlenmiştir [14].

Başka bir çalışmada yapay zekanın emlak piyasası hareketlerini anlamamıza nasıl yardımcı olabileceğini incelemek amaçlanmıştır. Bu doğrultuda emlak ihale fiyatları için tahmin modelleri oluşturulmuştur ve 2016-2020 yılları arasındaki Gana apartman müzayedelerinden elde edilen veriler kullanılmıştır. Bu modellerde Çoklu Regresyon (ÇR) ve Yapay Sinir Ağları yöntemleri kullanılmıştır. Taşınmaz değerlerini etkileyen tüm değişkenleri hesaba katan ve yatırımcıların piyasaya girebilecekleri birçok yöntemi de yansıtan iki aşamalı bir model önerilmiştir. Çalışma sonucu YSA ve Çoklu Regresyon Analizi yöntemlerinin gayrimenkul değerlendirmesi için etkin bir şekilde kullanılabileceğini göstermektedir. Ayrıca, emlak ihale piyasalarında yatırımcılar ve emlak fonu yöneticileri için önemli sonuçları vardır [15].

Başka bir uygulama da Tokat ili, Merkez ilçesi, Karşıyaka mahallesinde bulunan konut verileri ile istatistiksel yöntemlerden olan regresyon analizi ve makine öğrenmesi

yöntemlerinden YSA kullanılarak konut değeri değerlendirilmiştir ve bu yöntemlerin doğruluk değerleri karşılaştırılmıştır. İki farklı yöntemden elde edilen sonuçların doğrulukları ortalama mutlak yüzde hata (MAPE) formülüyle belirlenmiştir. Çoklu regresyon analizinde doğruluk oranı %95,0579, YSA doğruluk oranı %96,7545 elde edilmiştir. Bu sonuçlar iki yönteminde gayrimenkul değerlendirmede kullanılabilirliğini kanıtlamaktadır. Taşınmaz değerlendirmede kullanılacak kriterler bölgesel şartlar dikkate alınarak belirlenebilir ve bu bölge için uygun bir model elde edilebilir [16].


2. TEMEL KAVRAMLAR

2.1 Coğrafi Bilgi Sistemleri

Bilgi sistemleri, verinin sistematik bir şekilde toplanması, depolanması, işlenmesi ve anlamlandırılması için oluşturulmuş sistemlere denmektedir. Günümüzde artan bilgi yoğunluğu ile bu bilgilerin düzenlenmesi, kaydedilmesi ve işlenmesi bir zorunluluk haline gelmiştir. Bilgi sistemlerinin temel fonksiyonu karar vericilerin kararlarını destekleyen analiz imkânları sunarak karar verme işlemini kolaylaştırmak, bu süreci kısaltmak ve doğru karar vermeye katkı sağlamaktır. Bilgi sistemleri verileri etkin yöneterek kullanıcıya sunar ve kullanıcıların ihtiyaç duyduğu verilerin ilişkilendirilip anlaşılmasına da yardımcı olur [17].

Coğrafi bilgi ise yeryüzüne ilişkin coğrafi, mekânsal, alansal bilgiler ile doğada bulunan yol, nehir gibi somut olguları ve iklim bölgesi, nüfus yoğunluğu gibi soyut olguların bir koordinat sisteminde, konum ve biçimini gösteren geometrik bilgiler ile tanımlayan bilgilerdir [18]. Bu bilgilerin bilgisayar ortamına aktarımı, düzenlenmesi ve işlenmesi ile Coğrafi Bilgi Sistemleri (CBS) oluşturulmaktadır.

Coğrafi Bilgi Sistemleri (CBS), mekânsal kökenli grafik ve öznitelik bilgilerinin dijital ortamda toplanması, düzenlenmesi, saklanması, sorgulanması, görüntülenmesi, mekânsal analizlerinin yapılması ve bunların farklı formatlarda çıktı alınabilir olması için oluşturulan bir bilgi sistemidir.



Şekil 1- Farklı disiplinler arasında CBS'nin yeri [17]

2.2 Taşınmaz Değerleme

Taşınmazlar, özüne zarar vermeden bir yerden bir yere götürülmesi mümkün olmayan konut, bina, villa, apartman, iş yeri, fabrika, arazi, arsa vb. yapılara verilen genel bir isimdir. Taşınmazlar, günümüzde bir ihtiyaç olmanın yanında yatırım aracı olarak da tercih edilmektedir.

Taşınmaz değerlemesi; bir taşınmazın, taşınmaz projesinin ya da taşınmaza bağlı hak ve faydaların değerlendirme günündeki olası değerinin, bağımsız, tarafsız ve objektif ölçütlere dayanarak tespiti işlemidir [18]. Bir taşınmazın değerlemesini yapmak vergilendirme, kamulaştırma, imar düzenlemeleri gibi kamu işlerinde önemli olmasının yanı sıra bankacılık, sigortacılık gibi özel sektörlerin de mühim gördüğü bir konudur. Değerleme işlemi anlık bir şey olmayıp bir süreci ifade etmektedir. Taşınmaz değerlendirme kavramı genel olarak, değerlendirme yapılacak her bir taşınmazın kendine ait nitelik ve niceliklerinin analiziyle onların gerçek değerlerinin belirlenmesi sürecine verilen isimdir.

Taşınmaz değerlemeleri yapılırken genel kabuller dışında genel de öznel yaklaşımlar kullanılarak söz konusu taşınmazın değerlemesinin yapılmasından dolayı taşınmazların gerçek alım satım değerleri ile belirlenen değerleri farklılık göstermektedir. Bu öznel yaklaşım sonucunda taşınmaz değerlerinde tutarsızlıklar oluşmakta ve bunun sonucunda da değerlendirme için kriter seçimleri ile bu kriterlerin hangilerinin daha önemli olduğunun araştırılması önem kazanmaktadır.

2.3 Toplu (Küme) Değerleme

Toplu (küme) değerlendirme; İstatistiki inceleme ve sonuçların analizinin yapılmasına olanak veren değerlendirme metodlarının ve tekniklerinin sistematik ve düzenli bir şekilde uygulanması ile belli bir tarihte birden fazla mülkün değerlemesinin yapılmasıdır [19].

Toplu taşınmaz değerlemesi stokastik (istatistiksel) yaklaşımlar veya bilgisayar programları kullanarak ilgili taşınmazların değerini yaklaşık olarak belirleyebilecek yöntemlerdir. Toplu değerlendirme işlemleri genel itibariyle kamulaştırma veya vergilendirme gibi kamu kurumları işlerinde kullanılmaktadır. Bu tarz işlerde birden fazla taşınmaza değer atfedilmesi gerektiği için oluşturulan değerlendirme modeli ile örneklem kümesi üzerinde yapılan istatistik testler ile elde edilen bilgileri kullanarak, belirli bir zaman için değerlendirme kümesine değer biçen, işlemlerin istatistiksel testlerle denetlendiği değerlendirme sürecidir [4].

2.4 Nominal Değerleme

Değerleme işlemi yapılırken elde edilmek istenen, ilgili taşınmazın belirlenen andaki alım-satım değeri yani rayiç bedelini tespit etmektir. Rayiç bedel hesabında aynı bölge içerisindeki taşınmazların metrekare fiyatına bakılması ve buradan bir değer çıkartılması taşınmazın gerçek değerini tam olarak tespitinde uygun olmayacak bir yöntemdir. Zira taşınmazın diğer taşınmazlara göre farklı olumlu veya olumsuz yönleri olabileceği ve bununda değerini etkileyebileceği göz önüne alınması gerekir.

Taşınmazın değerinin belirlenmesinde rayiç bedelin yerine, bir puanlama sistemi kullanılarak elde edilecek parametrik değerlerin kullanılması ile tarafsız ve nesnel bir yaklaşım içeren nominal değerlendirme yönteminin kullanılması, daha doğru bir sonuç elde edilmesine olanak sağlayacaktır. Değeri etkileyebilecek faktörler belirlenip bu faktörler baz alınarak değer kriterleri formüle edip, tavan ve taban puanlarının tespit edilmesi gerekmektedir. Burada elde edilecek kriterlerin katsayıları taşınmazları değer bakımından birbirlerine göre durumlarını göstermektedir. Ayrıca buradaki katsayılar kullanılarak gerekmesi halinde rayiç bedel hesabı da yapılabilir. Bu şekilde her bir kriterin puanı ile ağırlık katsayısının çarpımı ile kriter puanının belirlenerek taşınmaz değerinin tespitinin yapılması işlemine “nominal değerlendirme” yöntemi denmektedir.

Taşınmazın değerini etkileyen belirlenen bütün faktörler için aynı işlem yapılır ve sonrasında kriter puanlarının toplanarak bir değer elde edilir. Bu değer piksel ya da parsel alanı ile çarpılması sonucunda ise taşınmaz değerleri nominal olarak hesaplanmış olur.

2.5 Makine Öğrenmesi

Teknolojinin gelişmesi ile günümüzde elde edilen veri miktarı hızla artmakta ve veri içerikleri çok fazla açıklayıcı unsur ve değişken içermektedir. Bu durum verilerin kompleks yapıda olmasını bu sebeple veri analizini zorlaştırmaktadır. Veriler arasındaki ilişkinin anlaşılmasını zorlaştıran bu durum için insan gücü yetersiz kalmakta bu noktada teknoloji

faýdalanmak gerekmektedir. Bu kapsamda verilerin işlenebilmesi ve anlamlı çıkarımlarda bulunabilmek için gerekli analizlerde makine öğrenmesi metotlarının kullanılması başlanmış ve zamanla bu kullanım yaygınlaşmıştır.

Makine öğrenmesi, elde edilen verilere dayanarak verilen problemin modellerini oluşturan bilgisayar algoritmalarının genel adıdır. Çok büyük miktarlardaki verinin elle işlenmesi ve analizinin yapılması zor olduğu ya da mümkün olmadığı durumlarda geçmişteki verileri kullanarak gelecek için çıkarımlarda bulunmak için makine öğrenmesi geliştirilmiştir.

Makine öğrenmesi, bilgisayarların sensörler ile elde edilen veri türlerine veya veri tabanlarına dayalı öğrenmeyi ve öğrenme sonucu tahmin yapabilmeyi sağlayan metotların tasarım ve gelişim süreçlerini amaçlayan bir bilim dalıdır [20]. Makine öğrenmesi veri modellerinin kullanıcı bağımsız oluşturulması ve bazı kompleks modeller kullanılarak geleceğe yönelik veri tahmininde bulunan veya belirli olmayan durumlarda karar verme yöntemlerinin uygulanmasıdır [21].

2.5.1 Makine Öğrenmesi Kullanım Alanları

Makine öğrenmesi günümüzde yaşantımızı etkileyen pek çok alanda geniş kullanım alanına sahiptir. Örnekleri arasında robotik ve otonom araç kontrolü, konuşma işleme ve doğal dil işleme, sinirbilim araştırmaları ve bilgisayarla görme alanındaki uygulamalar sayılabilir.

Makine öğrenimindeki günümüzdeki ilerleyişinin nedeni yeni öğrenme algoritmalarının geliştirilmesi, açık kaynak kodlu yazılımların gelişmesiyle çevrimiçi verinin artışı ve düşük maliyetli hesaplamanın kullanılabilirliğinin artmasıdır. Büyük verinin karmaşıklığı makine öğrenimini bilim, teknoloji ve ticaret alanlarının dışında sağlık, üretim, eğitim, finansal modelleme, pazarlama dahil olmak üzere hayatın birçok alanında yaygın olarak kullanılmasına yol açar [22].

Konuşma tanıma için var olan ticari sistemlerin tümü, sistem konuşmayı tanıması için eğitilirse elle programlamaya çalışmaktan daha yüksek tanıma doğruluğuna sahip olacağından makine öğrenimini kullanır [23].

Bilgisayar görüşü, yüz tanıma sistemlerinden, hücrelerin mikroskopik görüntülerini otomatik olarak sınıflandıran sistemlere kadar pek çok güncel görüş sistemi, yine makine öğrenimi kullanılarak geliştirilmiştir. Robot kontrolü, örneğin helikopter uçuşunda kontrol stratejileri elde etmek için makine öğreniminin kullanılmasının uygun olduğu, çölde 100 milden fazla yol alan bir robotun yer aldığı yakın tarihli yarışmada uzaktaki nesneleri algılama

yeteneğini geliştirmek için makine öğrenimini kullanan bir robot tarafından kazanılması ile gösterilmiştir [24].

Bu örneklerin dışında; Gayrimenkul değerlendirme, biyo-gözetim, ampirik bilimleri hızlandırmak, uzay görevleri, kanser teşhisinde kullanım, spam filtreleme, müşteri segmentasyonu, dolandırıcılık tespiti, hava tahmini vs. gibi pek çok konuda kullanılmaktadır.


2.5.2 Makine Öğrenmesi Yöntemleri ve Türleri

Makine öğrenmesi eğitim yöntemi ve veri setinin özelliklerine, yapısına göre üç temel öğrenme türüne ayrılmaktadır. Bunlar; Gözetimli Öğrenme, Gözetimsiz Öğrenme ve Destekli Öğrenmedir [25].

Gözetimli Öğrenme (Supervised Learning): Makine, eğitilme aşamasında etiketlenmiş veriler kullanılır, her bir örnek sunucu bilinen verilerden oluşmaktadır. Makine veri ve sonuç arasındaki ilişkiyi öğrenerek, sonucu bilinen veri kümesini kullanarak sonucu bilinmeyen veri hakkında tahmin yapılması veya verileri sınıflandırma kararı verilmesidir [26].

Gözetimsiz Öğrenme (Unsupervised Learning): Makine işaretlenmemiş verileri kullanmaktadır. Bu yöntemdeki amaç, benzer özelliklere sahip verilerin bir arada gruplaştırılmasıdır. Elde edilen sonuçların doğruluğu, yapılan gruplandırmada, bir araya getirilmiş sınıftaki verilerin birbirine olan benzerliği ve diğer sınıftan ne kadar farklı olduğuyla değerlendirilmektedir [27].

Destekli Öğrenme (Reinforcement Learning): Gözetimsiz öğrenme ile benzer olarak eğitim verisinde işaretlenmemiş veriler kullanılır. Bu yöntemle yapılan öğrenmenin esası ödül-ceza prensibine dayanmaktadır. Öğrenme sırasında, kazanılan ödül doğrultusunda yapılan tahminin ne kadar yanlış ya da doğru olduğunu anlar. Kazanılan ödül fazla ise o tercih yüksek puanlı olarak işaretlenmekte, yanlış tahminde ise düşük puanlı olarak belirlenmektedir [28].



Şekil 2- Makine Öğrenmesi Yöntem ve Türleri [10]

3. YAPILAN ÇALIŞMALAR


3.1 Çalışma Alanı

Çalışma alanı olarak Birleşik Krallık'ın 66 milyon nüfusa sahip İngiltere'nin Londra, Manchester, Liverpool, Newcastle şehirleri seçilmiştir. Bu şehirler birbirlerinden farklı özellikte ve nüfusta olmaları, burada bulunan taşınmazları objektif değerlendirmeye açık hale getirmektedir. Örneğin İngiltere'nin ve Birleşik Krallık'ın başkenti ve en kalabalık şehri olan Londra'nın iki bin yıldır büyük bir yerleşim yeri olması, Thames Nehri'nin bir boğaz gibi şehri iki yakaya ayırması, sanat, ticaret, eğitim, eğlence, moda, finans, sağlık, medya, profesyonel hizmetler, araştırma ve geliştirme, turizm ve ulaşım alanlarında dünyanın önde gelen şehirlerinden biri olması; buna mukabil Newcastle'ın ise daha yöresel, nüfusu az, Kuzey Denizi'ne bağlantısı olması ile bir liman kenti özelliklerini taşıması, İngiltere'deki diğer diğer şehirlere göre yaşamın daha ucuz olması gibi özellikler bakımından şehirlerin farklı özellikleri olduğu görülmektedir.

Liverpool'a baktığımız zaman İngiltere'nin Mersey Nehri Halicinin doğusunda bulunan şehir yerleşkesi olduğunu görmekteyiz. Yaklaşık MS 1200 yıllarında kurulmuş olan bu şehir, günümüzde şehrin nüfusu 500 bin civarı olduğu bilinmektedir. Bulunduğu konum itibarıyla bir liman kenti olan Liverpool, dünya deniz ticaretinin en önemli noktalarından biridir. Ayrıca şehirde bulunan büyük futbol takımları ile her sene düzenlenen "Grand National" at yarışları şehre olan ilgiyi artırmaktadır.

Manchester ise İngiltere'nin Kuzey-Batı bölgesinde bulunan bir şehirdir. Liverpool gibi bu şehirde nüfusu 500 bin civarındadır. Bulunduğu bölgede Liverpool ile beraber bölgenin merkezi konumundadır. 18. yüzyılda bu bölgeye açılan "Bridgewater Kanalı" ile bölge değer kazanmış hatta 18. yüzyılda dünyanın sanayileşmiş ilk şehri hâline gelmiştir. Manchester, Birleşik Krallık'ın en gelişmiş üçüncü ekonomisine sahiptir. Yerli ve yabancı turistlerin ilgi odağı olan bir şehirdir.

Seçilen bu şehirler, kendi içlerinde farklı özellikleri barındırmakta ve İngiltere'nin farklı bölgelerinde yer almaktadır. Bu özelliklerinin yanında ortak özelliklere de sahip oldukları ve bu ortak özellikleri belirlenerek buna uygun bir taşınmaz değerlemesi çalışması yapılmıştır. İngiltere, kalabalık nüfusu, bir ada ülkesi olması, sanayileşmeyi erkenden tamamlaması, doğası, şehir planlaması ve özellikle gerekli verilere erişimin açık ve kolay olması sebebiyle seçilmiştir.



Şekil 3- Çalışma Kapsamındaki Şehirler (İngiltere)

3.2 Taşınmaz Değerlerine Etki Eden Faktörler

Taşınmaz değerlemesi, taşınmazın değerlendirme günündeki durumunu objektif ve bağımsız ölçütlere dayanarak taşınmazın muhtemel değerinin tespitinin yapılmasıdır. Bu değerlendirme işlemi için taşınmazlar ile ilgili değer kavramına hakim olunmalı ve taşınmazlar arasındaki benzerlik ve farklılıklar tespit edilmelidir. Değerleme kriterlerinin tespitinde taşınmazlara ilişkin özelliklerin çokluğu, özelliklerin yöresel, bölgesel ve tercihlere göre değişmesi değerlendirme hususunda dikkat edilmesi gereken konulardandır [29].

Her taşınmaz, konumu ve özellikleri itibarı ile kendine özgüdür. Yani bir taşınmazın özellikleri bir başka taşınmaz ile tamamen aynı olamaz. Her taşınmazın bir başka taşınmaza göre göre avantaj ve dezavantajları vardır. Bunlara göre taşınmazların değerlerinde farklılıklar oluşmaktadır. Ayrıca alıcılarının farklı tercihleri de taşınmazları etkilemektedir. Bazı durumlarda alıcılar, almak istedikleri taşınmazların yeşil alanlara, parklara olan yakınlıkları veya turistik mekanlar gibi sosyal çevre ile olan etkileşimine bakarken bazı alıcılar hastane, okul gibi kuruma olan yakınlıklara önem vermektedir.

Taşınmaz sayısı fazla olan bir bölgede yapılan değerlendirme çalışması için ilgili taşınmazlar arasındaki değerlerin tespiti gerekir. Bu değerlendirme çalışması için bir puanlama yöntemiyle elde edilecek parametrik değerler tercih edilmiş ve buna göre 22 farklı taşınmaz kriteri seçilmiştir.

Kriterler, deęer bazında formölüze edilerek tavan ve taban puanları belirlenip, her bir taşınmaz için bir deęer katsayısı hesaplanmaktadır. Elde edilecek olan bu katsayılar, taşınmazların birbirlerine göre deęer dağılımlarını gösterecektir. Buradan dönüşüm yapılarak her bir taşınmazın rayiç bedeline ulaşılacaktır.

Faktörlerin seçiminde çalışma konusu olan bölgenin fizik, sosyal, ekonomik ve mekânsal özellikleri deęerlendirilmiş, ayrıca bir taşınmazın deęerini genel yargıda en çok etkileyebilecek olan kriterler araştırılmış ve taşınmazların deęerlemesinde kullanılacak olan faktörler seçilmiştir. Bu faktörler;

Tablo 1- Taşınmaz deęerini etkileyen faktörler.

1- Caddelere yakınlık	9- Anayollara yakınlık	17- İskelelere yakınlık
2- Otoyol kavşaklarına yakınlık	10- Polis merkezlerine yakınlık	18- İtfaiye merkezlerine yakınlık
3- Otobüs duraklarına yakınlık	11- Metro duraklarına yakınlık	19- Otoparklara yakınlık
4- Bisiklet duraklarına yakınlık	12- Hastanelere yakınlık	20- Sağlık kurumlarına yakınlık
5- Yeşil alanlara yakınlık	13- Okula yakınlık	21- Üniversitelere yakınlık
6- Gürültü alanlarına olan mesafe	14- Tarihi ve turistik alanlara yakınlık	22- Zararlı Alanlara olan mesafe
7- Şehir	15- Eğitim	23- Bakı
8- Göl manzarası	16- Kanal veya Boğaz Manzarası	

3.3 Veri Tabanı Tasarımı

Veri tabanının anlamı genel hatlarıyla, üretilen veya elde edilen verilerin depolanma yeridir. Veri tabanının en temel farkı veriyi verimli ve hızlı bir şekilde yöneterek, gerektiğinde verilerin düzenlenebilmesi kolaylığını sunmaktır. Veri tabanının tasarımı ise verilerin erişimini ve düzenlenmesini kolaylaştırmak için gereklidir. Tablolar veri tabanının ana nesneleridir. Tablolar arasındaki bağlantıyı sağlamak ve veri tabanındaki bilgileri hiyerarşik bir sırada tutmak için tasarımdan faydalanırız. Veri tabanının tasarımı, bilgilerin doğru ve tam olmasına yardımcı olur, yinleme yani gereksiz veri olmasının da önüne geçer. Veri tabanında, verilerin bulunduğu nesneler tablo olarak isimlendirilir. Her veri tabanı en az bir tablodan oluşur. Veri tabanını oluşturan tablolar, “data field” denilen veri alanlarından oluşmaktadır. Tasarım yapılarak tabloların sırası ayarlanır ve olası hataların önüne geçilmiş olur.

CBS uygulaması kullanılarak yapılan analizler kapsamında elde edilen raster veriler modellenmiştir. Sonrasında, daha önceden satış işlemi gerçekleştirilmiş, konum ve öznitelik bilgilerine sahip olduğumuz taşınmazlara CBS ortamında yapılan analizler her bir taşınmaza

aktarılmıştır. Bu şekilde çalışma sürecinde veri setlerinin organizasyonu, amaca uygun bir şekilde gerçekleştirilmiştir.

Çalışma bölgesi tek bir şehirden oluşmamakta olup çalışma kapsamında her bir şehrin idari sınırlarına ait veriler üzerinde yapılan hesaplama, analiz, haritalama gibi işlemlerde proje sınırları olarak kullanılmıştır. İtfaiye ve polis merkezlerine, alışveriş merkezlerine, eğitim kurumlarına, otopark, hastanelere, sağlık kurumlarına, tarihi ve turistik yerlere, bisiklet duraklarına, üniversitelere, okullara, yeşil alanlara, zararlı alanlara, gürültü alanlarına ait yakınlık analizlerinde bina katmanı kullanılarak gerekli nesneler özellik sorgulaması ile filtrelenip, şehirlere göre kırılarak veriler elde edilmiştir. Caddeler, sokaklar, otoyol kavşakları ve ana yolların yakınlık analizlerinde İngiltere'ye ait yol verisi kullanılmış, çalışma konusu şehirlere göre bu veriler kırılmıştır. Raylı sistem (tren, metro, hafif metro, tramvay, föniküler) duraklarına, otobüs duraklarına, iskelelerin yakınlık analizleri için toplu taşıma hatları ve istasyonları verisi kullanılmıştır. Bu veriler için Open Street Map ve Ordnance Survey tarafından paylaşılan veri tabanı kullanılmıştır. Bakı ve eğim analizleri için ASF Data Search [30] web sitesinden alınan Sayısal Yükseklik Modeli (SYM) verisi kullanılmıştır.


3.4 Konumsal Analizler

Taşınmazların bulundukları konumdan dolayı farklı fiziksel ve çevresel faktörlerden etkilenmektedirler. Bu etkilenme sonucunda taşınmazların değerleri birbirlerine göre değişiklik göstermektedir. Çalışma kapsamında taşınmazların konumsal özelliklerinden kaynaklı değer değişimlerinde CBS tabanlı nominal değerlendirme çalışması yapılmıştır. İngiltere'nin Londra, Manchester, Liverpool, Newcastle şehirlerinde belirlenen kriterler doğrultusunda ArcGIS yazılımı kullanılarak piksel bazlı konumsal analizler gerçekleştirilmiştir. Uygulama kapsamında üç temel analiz (yüzey, görünürlük ve yakınlık) yapıldı.


Nominal değerlendirme çalışması kapsamında kullanılan CBS analizleri piksel tabanlı olduğundan, konumsal veri tabanı oluşturulmuş ve raster formatına dönüştürülmüştür. Piksel tabanlı nominal değerlendirme çalışmalarında, konumsal veri tabanının oluşturulması ve raster formatına dönüştürülmesi, işin temelinin oluşturmaktadır. Bu işlem, çoğunlukla CBS yazılımları ile yapılmaktadır. Seçilecek olan piksel boyutu işin hassasiyetini ve harcanan süreyi etkilemektedir. Örneğin piksel boyutu küçültülür ise modelin doğruluğu artacak iken işlem süresi de bununla birlikte artacaktır [31].

3.4.1 Yakınlık analizleri

Yakınlık analizleri ArcGIS yazılımı üzerinden, iki nokta arası mesafeyi doğrusal bir çizgi şeklinde hesaplayan öklid uzaklığı (euclidean distance) aracı kullanılarak yapılmıştır. Öklid uzaklığı hücrelerin orta noktaları arasındaki uzaklığı temel alır. Vektör veya raster veriler ile yapılan analiz sonucunda kaynak verinin konumundan, detaylara olan uzaklığı piksel içinde saklayarak bir raster katman oluşturur. Tüm hücrelerin sonuç değerleri kesirli sayı şeklinde hesaplanır. Aşağıda öklid uzaklığı aracının çalışma prensibi gösterilmektedir.



Şekil 4- Öklid uzaklığı çalışma prensibi [38]



Şekil 5- Londra'daki üniversitelerin öklid mesafesi ile yakınlık analizi

Yakınlık analizleri kapsamında kriterlere göre mesafelerin sınıflandırması yapılmıştır. Sınıflandırma yapılırken taşınmaz değerlendirme süreçlerinde akademik kaynaklarda kullanılmış

olan sınıflandırma mesafeleri incelenmiş, akademisyenlere danışılmış ve İngiltere üzerinde değerlendirme yapılarak yakınlık analizleri kapsamında beş farklı grup oluşturulmuştur. Bu gruplar yürüme mesafesi, araç ile erişim ve sosyal beklentiler gibi değerlendirmeler sonucunda oluşturulmuştur. Belirlenen mesafeler ArcGIS yazılımı ile 0 ile 100 arasında değerler verilerek yeniden sınıflandırma (reclassification) işlemi yapılmıştır. Caddelere yakınlık, anayollara yakınlık, otoparklara yakınlık, otoyol kavşaklarına, metro duraklarına yakınlık, otobüs duraklarına yakınlık, iskelelere yakınlık, bisiklet duraklarına yakınlık, hastanelere yakınlık, sağlık kurumlarına yakınlık, itfaiye merkezlerine yakınlık, polis merkezlerine yakınlık, yeşil alanlara yakınlık, üniversitelere yakınlık, okullara yakınlık, tarihi ve turistik alanlara yakınlık, zararlı alanlara olan mesafe ve gürültü alanlarına olan mesafe değerlerinin analizleri yapılmış ve her biri aşağıda verilen puanlama sistemine göre sınıflandırılmıştır.


GRUP-1		
Caddeler, Otoparklar, Yeşil Alanlar, Bisiklet Durakları, Gürültü Bölgeleri		
Başlangıç Mesafesi(m)	Bitiş Mesafesi(m)	Yeniden Sınıflandırma Puanı
0	50	100
50	100	90
100	150	80
150	200	70
200	250	60
250	300	50
300	350	40
350	400	30
400	450	20
450	500	10
500	∞	0

GRUP-2		
Otoyol Kavşakları, Polis Merkezleri, İtfaiye Merkezleri, İskeleler, Anayollar, Zararlı Alanlar		
Başlangıç Mesafesi(m)	Bitiş Mesafesi(m)	Yeniden Sınıflandırma Puanı
0	1000	100
1000	2000	80
2000	3000	60
3000	4000	40
4000	5000	20
5000	∞	0

GRUP-3		
Metro ve Otobüs Durakları, Hastaneler, Sağlık Kurumları		
Başlangıç Mesafesi(m)	Bitiş Mesafesi(m)	Yeniden Sınıflandırma Puanı
0	100	100
100	250	90
250	500	80
500	750	70
750	1000	60
1000	1500	50
1500	2000	30
2000	30000	10
30000	∞	0

GRUP-4		
Tarihi ve Turistik Alanlar, Alışveriş Merkezleri		
Başlangıç Mesafesi(m)	Bitiş Mesafesi(m)	Yeniden Sınıflandırma Puanı
0	250	100
250	500	90
500	750	80
750	1000	70
1000	1500	60
1500	2000	50
2000	3000	30
3000	5000	10
5000	∞	0


GRUP-5		
Okullar ve Üniversiteler		
Başlangıç Mesafesi(m)	Bitiş Mesafesi(m)	Yeniden Sınıflandırma Puanı
0	200	100
200	400	90
400	600	80
600	800	70
800	1000	60
1000	1200	50
1200	1400	40
1400	1600	30
1600	1800	20
1800	2000	10
2000	∞	0




Şekil 6- Yeniden sınıflandırma yapılmış Londra üniversite yakınlık haritası

3.4.2 Yüzey analizleri

Eğim, yüksekliğin x ve y yönlerindeki değişiminin derece veya yüzde cinsinden hesaplanmasıdır. Düşey mesafenin (rise), yatay mesafeye (run) oranının tanjant açısı derece cinsinden eğimi vermektedir. Düşey mesafenin, yatay mesafeye bölünmesi ve bu değer 100 ile çarpılması sonucunda yüzde cinsinden eğim elde edilmektedir. Aşağıda bu durumun görselleştirilmesi verilmiştir.



Şekil 7- Yüzde ve derece cinsinden değerlerin karşılaştırması [42]




Şekil 8- Bakı analizinin çalışma prensibi [40]

Eğim kriterinin puanlaması yapılırken yüzde cinsinden eğim değerleri belirlenmiş ve puanlaması da buna göre yapılmıştır. Taşınmazların düz zeminlerde olmasının taşınmaza pozitif yönde etki yapılacağı düşünülerek eğimin az olduğu yerden fazla olduğu yerlere doğru verilecek olan puanın düşürülmesi gerektiği görülmüştür. Bir taşınmazın bulunduğu konumun eğim derecesinin yüksek olması yani yokuşta bulunan bir araziye kurulmuş olması taşınmazın inşaatında bazı zorluklar ile karşılaşılmasına sebebiyet verebileceği gibi taşınmazın günlük kullanımında da taşınmaza ulaşım konusunda sıkıntılar oluşturacağı öngörülmüş ve bu sebeple eğimin arttığı yerlere düşük puan verilmesi gerektiği ön görülmüştür. Binaenaleyh literatür araştırmaları kapsamında elde ettiğimiz bilgilerde bu görüşü doğrulamaktadır. Aşağıda Alkan (2021) tarafından yapılan çalışmada kullanılan eğim sınıflandırması aynı şekilde alınmış ve bu çalışmada da kullanılmıştır.

Eğim (%)		
Başlangıç	Bitiş	Yeniden Sınıflandırma
0	10	100
10	20	70
20	30	50
30	40	20
40	50	10
50	∞	0

Bakı analizi ise bir yön analizidir. Taşınmazın bulunduğu konumun SYM üzerinde kuzeye göre konumunu belirlemek için kullanılmaktadır. Analiz sonucunda bakı haritalarında dört ana yön ve bu ana yönler arasındaki ara yönler oluşmaktadır. Bakı eğimin yönüdür, en yüksek eğim değerine göre konumun yönü belirlenir. Eğimi olmayan düz yüzeyler -1, diğer yönler ise 0-360 derece arasında değerler almıştır.



Şekil 11- Londra bakı analiz haritası


3.4.3 Görünürlük analizleri

Görünürlük genel anlamda bir noktadan bir başka noktaya arada engel olmaksızın görüş sağlanabilmesidir. Bu analiz iki nokta arasında olabildiği gibi bir noktadan belli bir bölgeyi kapsayacak şekilde de yapılabilmektedir.

Yapılan bu analiz, arazinin bulunduğu yüzey üzerinden bir ya da birden fazla gözlem noktasına ait görünen veya görünmeyen alanlarını tespit amacıyla kullanılır. Analizin temelinde ölçülen ve durulan noktaların yükseklik verileri ile topografik yüzey analizleri yer almaktadır [32].

Bir taşınmaz üzerinden görülen yer (manzara) kuşkusuz ki taşınmazın değerini etkilemektedir. Genel olarak taşınmazın bir denize, suya veya boğaza bakması taşınmazın değerini artırmakta iken bu taşınmazın kanalizasyon atık tesisine veya çöplüğe bakması da değerini olumsuz yönde etkilemektedir. Bu sebeple taşınmazlar üzerinde görünürlük analizi yapmak, taşınmazların değerlendirilmesinde önemli bir kaidedir. Çalışma kapsamında manzara analizleri taşınmazın değerini artıracak şekilde sulak alanlar, göller, denizler, boğazlar ve kanallar için yapılmıştır.

Görünürlük analizinde manzarayı gören alanların değeri 100 puan görmeyen alanlar ise 0 puan alacak şekilde yeniden sınıflandırmaya tabi tutulmuştur. Yapılan çalışma için iki ayrı veri kaynağı kullanılmıştır. Sulak alanlar, göller ve denizler için ayrı bir manzara analizi yapılmış iken boğazlar veya kanallar için ayrı bir görünürlük analizi yapılmıştır. Aşağıda yapılan görünürlük analizlerine örnek olarak Londra üzerinde yapılan analizler gösterilmiştir.



Şekil 12- Londra göl manzarası haritası

3.5 Ağırlıkların Belirlenmesi

Ağırlıklandırma işlemi anket verileri, literatür araştırmaları, Analitik Hiyerarşi Sürecinden (AHP) elde edilmiş ağırlıklar gibi çeşitli yöntemler ile ağırlıkların tespiti yapılabilmektedir. Değere etki eden faktörlerin ağırlıklandırmasında genellikle literatür araştırmaları sonucunda elde edilen ağırlıkların kullanılmakta olduğu görülmektedir.

Bu çalışmada ise ağırlıklar makine öğrenmesi algoritması kullanılarak belirlenmiştir. Kullanılan “Price Paid Data (PPD)” verisi İngiltere’de bulunan konutların tam adres bilgilerini ve söz konusu konutların birçok fiziksel özelliği hakkında bilgi sağlamaktadır. Açık kaynak olan PPD veri kümesi kullanılarak makine öğrenmesi algoritmalarıyla fiyat tahmini yapılmıştır. Model başarılarını ölçmek için MAE, MAPE, RMSE, R^2 gibi doğruluk metrikleri kullanılmıştır.

(Tablo 2). Ayrıca PPD verisinin zenginleştirmek için CBS ile gerçekleştirilen yakınlık, arazi ve görünürlük analizlerinin nominal puanları çıkartılmıştır. Zenginleştirilmiş veriler elde edildikten sonra aynı makine öğrenmesi algoritmaları uygulanmıştır (Tablo 3). Bu işlemlerin sonunda ağırlıklar, özellik zenginleştirme sonrasındaki verilerle en yüksek performans gösteren CatBoost algoritması için özellik önem puanları alınarak belirlenmiştir.

Model	MAE	RMSE	R ²	MAPE
Multiple Linear Regression	149548.2085	214012.0519	0.4602	0.3605
Random Forest	137165.7877	201357.0192	0.5222	0.3293
XGBoost	135814.3472	199905.4387	0.5291	0.3227
CatBoost	134058.5093	197617.3725	0.5398	0.3183
LightGBM	140088.6993	204840.5195	0.5055	0.3336
ANN	144310.1430	207982.0775	0.4903	0.3543

Tablo 2- Londra şehri için Regresyon modellerinin doğruluk metrikleri

Model	MAE	RMSE	R ²	MAPE
Multiple Linear Regression	123990.3542	176920.1789	0.6312	0.3035
Random Forest	71154.2951	116260.5151	0.8407	0.1638
XGBoost	80503.6497	123965.9429	0.8189	0.1868
CatBoost	73540.8460	114906.4651	0.8444	0.1702
LightGBM	99576.9102	150076.5553	0.7346	0.2330
ANN	96358.6434	142577.0107	0.7605	0.2340

Tablo 3- Londra şehri için özellik zenginleştirme sonrası doğruluk metrikleri

3.6 Makine Öğrenmesi

Büyük miktarlardaki verilerin el ile işlenmesi ve bu verilerin analizinin yapılması oldukça zordur. Bu sebep ile bilgisayarın kendi kendine öğrenmesi, verileri işlemesi ve bunların analizini yapması gerekmektedir. Bu işlemleri yapmak için genellikle örnekler kullanılarak olayların girdi ve çıktıları arasındaki ilişkiler öğretilir.

Makine öğrenmesi, bilgisayarların bir diziyi tanınması, geliştirmesi veya verilerden sürekli olarak öğrenmesi ve verilere dayalı tahminler yapması ile özel olarak ayarlamalar yapma yeteneğini ifade eden yapay zekanın bir alt kategorisidir. Makine öğrenmesi, büyüyen veri bilimi alanının önemli bir yere sahiptir. Kullandığı istatistiksel yöntemler ile sınıflandırmalar ve tahminler yaparak, projelerde temel iç görü ortaya çıkarır. UC Berkeley, bir makine öğrenmesi algoritmasının öğrenme sistemini üç ana bölüme ayırır.

- i. Karar Süreci: Makine öğrenmesi algoritmaları genel olarak, bir tahmin ya da sınıflandırma yapmak için kullanılır. Etiketli ya da etiketsiz olabilecek bazı giriş verilerine dayanarak oluşturulan algoritma verilerdeki bir kalıp ile ilgili bir tahmin üretecektir.
- ii. Hata İşlevi: Modelin tahminini değerlendirmek için kullanılmaktadır. Bilinen örnekler var ise bu örnekler ile modelin doğruluğunu değerlendirilerek aralarında bir kıyaslama yapılabilir.
- iii. Model Optimizasyonu Süreci: Model, eğitim kümesindeki veri noktalarına daha iyi uyuyorsa, bu durumda ağırlıklar bilinen örnek ve model tahmini arasındaki çelişkiyi azaltmak üzere düzenlenir. Algoritma, bu değerlendirmeyi tekrarlayıp süreci en iyi hale getirerek, bir doğruluk eşiğine ulaşana kadar denk ağırlıkları otonom bir şekilde günceller [33].

3.6.1 Gradyan Artırma

Son zamanlarda veri boyutu ve çeşitliliğinin artmasıyla algoritmaların optimizasyonlarına verilen değer gittikçe artmaktadır. Gradyan artırma algoritması (Gradient Boosting), makine öğrenmesi yönteminde bağımsız tahminler yerine sıraya tahminler yapan bir topluluk algoritmasıdır. Bu yöntem zayıf tahminlerin üzerinde iterasyon yaparak bunları kademeli olarak güçlü tahminlere dönüştürmeyi amaçlamaktadır [34]. Üretilen ilk tahmin değeri ile hedef değer arasındaki fark bulunarak her bir iterasyonda bu fark daha da küçültülür.

Gradyan artırma algoritmasına ek olarak farklı algoritma tercihleri de çıkmıştır. Bunlar XGBoost, LightGBM, Catboost algoritmalarıdır. Bu algoritmalar kullanılarak daha yüksek doğruluk ile daha hızlı makine öğrenmesi yapmak için çalışma kapsamında kullanılmıştır.

3.6.2 Hafif Gradyan Hızlandırma Makineleri

LightGBM, Microsoft'un "Dağıtık Makine Öğrenmesi Yazılımı (Distributed Machine Learning Toolkit)" isimli projesi kapsamında geliştirilmiştir. Çalışma kapsamında kullanılan makine öğrenmesi yöntemlerinden biri olan LightGBM, histogram tabanlı bir algoritmadır. Sürekli değişkenleri kesikli hale getirerek hesaplama maliyetini azaltmaya yaramaktadır [43].

Light Gradient Boosting Machines (LightGBM), hızlı ve yüksek doğrulukta sonuçlar veren gradient boosting altında çalışan karar ağacı tabanlı bir makine öğrenme algoritmasıdır. Yaprak odaklı (leaf-wise) büyüme stratejisi kullanarak eğitim aşamasını gerçekleştirmektedir. diğer karar ağacı tabanlı makine öğrenme algoritmaları, ağaç seviyesinde (level-wise) büyüme stratejisini kullandığından LightGBM, bu özelliği ile onlardan ayrılmaktadır.

3.6.3 XGBoost

Carlos Guestrin ve Tianqi Chen tarafından 2016 yılında geliştirilen Extreme Gradient Boosting (XGBoost), gradient boosting algoritmasını kullanan karar ağacı tabanlı topluluk öğrenme temelli bir makine öğrenme algoritmasıdır [35]. Bu algoritma, XGBoost, regresyon ve sınıflandırma problemlerinde yapılandırılmış veya tablo halindeki veri setlerinde kullanılır sınıflandırma ve regresyon problemlerinde yapılandırılmış ya da tablo halinde olan veri setleri üzerinde kullanılır.

XGBoost, gradient boosting algoritmalarına donanım ve bellek kaynaklarını verimli bir şekilde optimize etmektedir. Hesaplama hızının yüksek olmasının yanı sıra düzenleme (regularization) yaparak modelin performansına büyük avantaj sağlamaktadır. Bu algoritma, Classification and Regression Tree (CART) algoritmasını kullanarak ağaçlarını oluşturur.

3.6.4 CatBoost

Yandex tarafından kategorik özellik desteği ile Gradient Boosting'in performansını arttırmak için geliştirilen CatBoost (Category Boosting) algoritması, LightGBM ve XGBoost'a alternatif olarak 2017 tarihinde tanıtılmıştır. Makine öğrenme yöntemleri ile güçlendirme tekniğini bir arada kullanan bir algoritma özelliğini taşıyan CatBoost yüksek öğrenme hızı, GPU desteği ile görselleştirme ve sayısal, kategorik, metin verileri ile çalışabilmesi özelliklerine sahip bir algoritmadır. Grafik oluşturarak görselleştirme sağlaması sonucunda öğrenim durumu ve ilgili parametrelerin modele etkilerini rahatça açıklanabilir hale getirmektedir. Bu sayede hem optimizasyon aşaması kolaylaşır hem de üretilen model anlaşılabilir hale getirilir.

CatBoost algoritması, sınıflandırma problemleri ve regresyon problemleri için kullanılabilir. Sabit boyuttaki zayıf karar ağaçları sınıflandırıcılarını birleştirir ve güçlü modeller geliştirilmesini sağlar. Boş veriler ile ayıklayarak onları kategorize eder ve bu sayede verilerin hazırlanması evresini daha kısa sürer. Kurduğu simetrik ağaçlar ile çok derine inmeden tahmin oranını yükselterek aşırı öğrenme probleminden kurtulur.

Model geliştirme aşamasında, veri kümesi içinde bulunan tüm özniteliklerin sayısal değerler içermesine gerek yoktur. CatBoost algoritması, veri kümesi içinde bulunan kategorik veriler üzerinde herhangi bir ön işlem adımı uygulamadan çalışabilmektedir. Ayrıca CPU dışında öğrenim süresini kısaltmak için GPU'yu kullanabilmektedir. Veri kümesi üzerindeki eksik verileri kullanarak da çalışabilme özelliğine sahiptir [36].

3.6.5 Yapay Sinir Ağları

Yapay Sinir Ağı (YSA), insan beyninin modellenmesi ile öğrenme kabiliyetini bilgisayara kazandırmayı amaçlayan yapay zeka yöntemlerinden biridir.

Genel anlamda beynin öğrenme işlevinin bilgisayar tarafından yapılmasıdır. Bu sistem, insan beyni gibi çalışarak öğrenmeye yolu ile yeni bilgiler türetebilmekte ve keşfedebilmektedir. Bunları herhangi bir yardıma ihtiyaç duymadan yapabilmektedir. Öğrenme sürecinin modellenmesi matematiksel olarak yapılır ve bilgi kendi hafızasında yapay nöronlar tarafından tutularak yapay sinir ağları oluşturulur. Ağın yapısı deneme yanılma yoluyla sağlanır.

- Doğrusal Olmama
- Paralel Çalışma
- Öğrenme
- Genelleme
- Hata Toleransı ve Esneklik
- Eksik Verilerle Çalışma
- Çok Sayıda Değişken ve Parametre Kullanma
- Uyarlanabilirlik

Yapay Sinir Ağları uygulamaları en çok tahmin, sınıflandırma, veri ilişkilendirme, veri yorumlama ve veri filtreleme işlemlerinde kullanılmaktadır.

3.6.6 Rastgele Orman

Rastgele Orman algoritması topluluk sınıflandırma algoritmaları içerisinde oldukça yaygın olarak kullanılan makine öğrenmesi algoritmalarından biridir. Sınıflandırma olarak ağacın yapısına benzemekte ve eğitim aşamasında iken oluşturulan çoklu ağaçların her biri üzerinden yeni verinin sınıfını tahmin etmektedir. Her bir tahmine “oy” denmekte ve en çok oyu alan sınıfı yeni veri sınıfı olarak atamaktadır. Örneğin bir taşınmazın değerlendirilmesinde ana yola yakınlık verisi değeri etkilediğine dair 1000 örnek var iken değeri etkilemediğine dair 200 örnek var ise burada algoritma sayısı fazla olanı alarak ana yola yakınlığın taşınmazı etkilediğine karar verecektir.

Bu algoritma, içerisindeki her bir düğümün veri setindeki özelliklerinin tamamı arasından en iyisini kullanmak yerine, her bir düğümde veri seti içerisinde rastgele seçilen özellikler arasından seçtiği en iyi veriyi kullanarak dallara ayırır [35]. Eğer karar ağaçları oluşumu sırasında düğümlerin dallara ayırma işlemi yapılmaz ve veri kümesi içerisinde bulunan bütün özellikler kullanılsaydı, oluşacak olan ağaç modelleri birbirlerinin aynı olurdu. Oluşturulan yeni ağaçların her biri içerisindeki veriler orijinal veriler ile yer değiştirmeli şekilde seçilerek oluşturulur. Sonrasında ise verilerin özellikleri arasından rastgele seçimler oluşturularak ağaç yapıları oluşturulur. Rastgele orman yöntemi, CART algoritmasını ağaçları oluşturmak için kullanmaktadır. Oluşturulan ağaçlar arasında budama işlemi yapılamaz [35].

3.6.7 Çoklu Doğrusal Regresyon

Doğrusal regresyon, sayısal bağımlı değişken olan y ile bir ya da daha fazla bağımsız değişken olan x arasındaki ilişkiyi modelleme yaklaşımıdır [37]. Bu regresyon yöntemi, bağımlı ve bağımsız değişkenler arasında bulunan karmaşık yapıyı, matematiksel modeller ile tanımlamaktadır. Özet verileri kullanarak bağımsız değişkenler vasıtasıyla bağımlı değişkenlerin değerlerini tahmin etmeye çalışır. Bu şekilde bağımsız değişkenlerin bir veya daha fazlasının bağımlı değişkenleri etkileyip etkilemediğini bulmaya çalışır.

Bağımsız değişkenlerin sayısı birden fazla ise bu “Çoklu Doğrusal Regresyon” olarak isimlendirilir. Değişkenler arasında bulunan sebep-sonuç ilişkisi ile ilgili tahminler yaparak regresyon modeli olarak isimlendirilen matematiksel bir model oluşturur. Üretilen bu model sonrasında yeterlilik kontrolüne tabi tutulur. Oluşturulan yeni model doğru modele ne kadar yaklaştığı varyans analizi kullanılarak tespit edilen değerlerin tüm varsayımları sağlayıp sağlamadığı kontrol edilir. Çıkan sonuç eğer zayıf ve yanıltıcı sonuçlar doğurmuş ise bu modelin yeterli derecede uyumlu olmadığının bir göstergesi olacaktır [38].


3.7 Nominal Taşınmaz Değer Haritası

Verilerin CBS uygulaması vasıtası ile işlenmesinden sonra her bir bölgenin verileri için gerekli yüzey, yakınlık ve görünürlük analizleri yapılmış sonrasında bu analizler QGIS uygulamasının “Sample Raster Values” aracı kullanılarak taşınmazlara aktarımı gerçekleştirilmiştir. Bu aktarım neticesinde taşınmazlar makine öğrenmesi algoritmasında kullanılmıştır. Makine öğrenmesi sonucunda her bir bölge için ağırlıkların tespiti gerçekleştirilmiş ve aşağıda bu ağırlıklar tablo halinde sunulmuştur.


Tablo 4- Taşınmaz değerlerine etki eden kriterler ve ağırlık katsayıları

Faktörler	Şehirler			
	Londra	Manchester	Newcastle	Liverpool
Anayol	1.634837768	4.831283149	2.174033234	0.137721694
AVM	10.65372869	2.940880921	4.085470228	0.632991734
Bakı	0.003660368	0.216330937	0.178315776	0.092650981
Bisiklet	0.171329636	0.002010862	0.057442542	0.016781115
Caddeler	0.607718323	0.831154963	1.668821856	1.486531432
Eğim	0.568288432	0.013587519	0.027693049	0.005968649
Gürültü	0.436228457	0.437248263	1.214160027	0.592326415
Hastane	4.142970894	3.380796496	3.367532073	1.137782122
İskele	17.27017853	2.283139007	3.954939270	4.699080135
İtfaiye	1.752638848	0.354798926	0.999401195	7.841952151
Kanal veya Boğaz	0.283224819	0.000000000	0.354265914	0.013863912
Metro İstasyonları	1.049666699	5.046574387	3.587025589	2.119783131
Okul	2.677983912	0.549187169	1.158820158	1.450969353
Otobüs Durakları	0.310670222	1.149659436	1.341893664	0.391442271
Otopark	0.332706302	0.659996438	0.899768285	0.995039794
Otoyol Kavşakları	2.334039522	4.712639235	0.579399714	1.069252753
Polis	5.170991992	6.452092041	11.28310983	1.13055798
Sağlık Kurumları	2.542999960	3.808224008	2.181316521	2.088152227
Su Alanları	0.289119717	0.204855507	0.192558959	0.000000000
Şehir Merkezi	0.083067247	0.284183719	2.016697756	1.815088957
Turistik	3.531803602	2.784777571	6.381390233	3.965626016
Üniversite	1.796311732	3.908910432	1.486111416	12.93299534
Yeşil Alanlar	0.240929381	0.332976987	0.615390528	0.823521696
Zararlı Alanlar	2.046281679	5.839307824	2.908344678	5.749408056


Makine öğrenmesi sonucunda üretilen ağırlıklar daha sonrasında ArcGIS uygulamasının “Raster Calculator” aracı kullanılarak analizler birbirleri ile ilişkilendirilmiştir. Aşağıda ağırlıkların analizlere katılması sonucunda, her bir bölge üzerinde elde edilen nominal taşınmaz değerlendirme sonucu gösterilmektedir.




Şekil 13- Londra nominal taşınmaz değer haritası



Şekil 14- Manchester nominal taşınmaz değer haritası




Şekil 15- Liverpool nominal taşınmaz değer haritası




Şekil 16- Newcastle nominal taşınmaz değer haritası


Zenginleştirilmiş verilere Makine Öğrenmesi modellerinin uygulanması sonucu en iyi performans gösteren CatBoost modelinden elde edilen öznelik önem skorları her şehir için farklılık göstermektedir.




Şekil 17- Newcastle şehri için özelliklerin önem puanları



Şekil 18- Liverpool şehri için özelliklerin önem puanları



Şekil 19- Londra şehri için özelliklerin önem puanları



Şekil 20- Manchester şehri için özelliklerin önem puanları

4. BULGULAR

- Nominal deęerleme yntemi ile bir blgenin tařınmazlarının toplu deęerlemesi yapılabilmektedir. Tařınmazın deęerini etkileyen faktrler tařınmazların kendi i özellikleri (kapladığı alan, üzerindeki yapının durumu gibi) olabileceęi gibi konumundan kaynaklı (alışveriş merkezlerine yakınlık, toplu tařımaya yakınlık gibi) özellikler de olabilmektedir. Bir tařınmazın konumundan doęan faktr sayısının ok fazla olduęu yapılan alıřma ile grlmřtr.
- CBS'nin nominal deęerleme alıřmalarında kullanılması ile elde edilen verilerin hızlı bir řekilde iřlenip analiz edilmesi ve bunları bilgiye dnřtrlmesi saęlanmaktadır. Bu verilerin tek tek her bir tařınmaza uygulanması, verilerin analizlerinin tařınmazlar zelinde CBS'yi kullanmadan yapmanın zor olduęu grlmektedir.
- İřlenen her bir veri gncel veridir. Bu verilerin gncellięi nemlidir. Ykseklik verisi kolaylıkla deęiřebilecek bir veri olmamak ile beraber yakınlık analizlerinde kullanılan her bir verinin gncel olması olduka nemlidir. rneęin yapılacak bir AVM yakınlık analizi iin eęer iki ay nce yıkılmıř bir alışveriş merkezi iin beř ay nceki veri kullanılmak istenirse analiz sonucu da hatalı olacaęı pek tabidir.
- alıřma kapsamında kullanılan verilerin bundan otuz sene evvel elde edilmesi zor veriler olacaęı grlmekte iken geliřen durumlar neticesinde internet ortamında aık kaynaklı olarak bu verilere ulařmak pekte zor olmamaktadır. Aık kaynaklı Open Street Map gibi uygulamalar, kullanıcıları sayesinde srekli gncellenmekte ve dięer kullanıcılara gncel veri saęlamaktadır. Ayrıca bu alıřma kapsamında İngiltere'nin resmi internet sitesi olan Ordnance Survey, doęru veriye ulařabilmekte kullanılacak kaynaklardan biri olduęu grlmřtr.
- CBS zerinde yapılan analizler raster formatında yapılmıřtır. Raster verilerde piksel znrlęnn nemli olduęu grlmřtr. Piksel znrlęnn fazla olduęu bazı analizlerde doęruluęun nemli lde dřtę, bazılarında ise znrlę belirli bir noktadan sonra ne kadar artırılsa da elde edilen sonucun ok deęiřmedięi grlmřtr. Ayrıca piksel znrlęn artırmak verinin boyutunu ve iřlem sresini de nemli lde artırmaktadır.
- Tařınmaz deęerleri birok kriterden etkilendięi grlmřtr. Bu kriterlerin de sayısının artırılabilmesi gibi her bir kriterin eklenmesi ile analiz sonucunun da deęiřtięi grlmektedir. Fakat bazı verilerin kullanılması ile blgenin analizi genel hatlarıyla ortaya ıktığından veri sayısını bir yerden sonra arttırmanın yksek doęruluk gerektirmeyen alıřmalarda gerekli olmadığı fark edilmiřtir.

- Yapılan analizlerin yeniden sınıflandırılması ile el edilen raster analiz sonucu, konumları belli olan taşınmazlar ile QGIS uygulamasının “Sample Raster Values” aracı kullanılarak birleştirilmiştir. Bu sayede her bir taşınmazın analizlerde aldıkları puanlar belirlenmiştir.
- Ağırlık üretiminde farklı birçok yöntem olduğu literatür araştırmalarında görülmüştür. Bu yöntemlerin her bir bölge için uygulanması, kriterlerin değişikçe hesapların yeni baştan yapılması gibi problemleri olduğu görülmüştür. Makine öğrenmesi ise bu problemlere cevap vermektedir. Ağırlıkların hesabını kendi hesaplayan ve her bölge için ufak düzeltmeler ile ortak kullanılabilecek bir uygulama sunmaktadır.
- Makine öğrenmesi yöntemleri araştırıldığında birçok farklı metot olduğu görülmüştür. Bu metotların her biri bir diğerinden ayrı sonuçlar çıkartmaktadır. Bu sonuçların farklılıklarını görmek için belirlenen birkaç metot denenmiş ve aralarından en iyisi olan CatBoost ile makine öğrenmesi metodu kullanılmıştır.
- Makine öğrenmesi pek çok değerlemede kullanılmakta olup taşınmazın mekânsal özelliklerinin de dikkate alınması önemlidir. Mekânsal özelliklerinde algoritmada kullanılmasının doğruluğu arttıran bir faktör olduğu gözlenmiştir.
- Kullanılan bazı makine öğrenme algoritmalarının her bilgisayarda çalışamayacak derecede yüksek sistem gereksinimleri olduğu görülmüştür. Özellikle ekran kartı ve RAM gibi özelliklerin iyi olması, iyi bir işlemci ile bu işlemlerin yapılması gerektiği görülmüştür. Bu sebep ile bazı algoritmaların çalışması için daha güçlü bir bilgisayar kullanılmıştır.
- Makine öğrenmesi ile elde edilen ağırlıklar arasında farklılıklar olduğu görülmüştür. Özellikle şehirler arasında her birini en çok etkileyen kriterin değiştiği görülmektedir. Aşağıda her bir verinin en yüksek değere sahip 10 özelliğin ağırlıklarının şehirler göre farklılıkları gösterilmiştir.

5. SONUÇ VE ÖNERİLER

Bu çalışma kapsamında CBS ve makine öğrenmesi yöntemleri ile toplu taşınmaz değerlemesi yapılması için İngiltere’nin Londra, Manchester, Liverpool, Newcastle şehirleri seçilmiştir. Çalışmada önce kullanılacak olan verilerin tespiti için seçilen şehirlerin sosyo-ekonomik durumları incelenmiş ve bu bölgede yaşayan maliklerin veya malik olmak isteyen kişilerin görüşleri internet ortamında araştırılmıştır. Elde edilen sonuçlar neticesinde bir taşınmazın değerini etkilediği genel olarak kabul edilen değerlendirme kriterlerinin yanında bazı kriterler de sırf bu bölgelere özel olarak eklenmiş ve analizleri yapılmıştır.

Çalışma kapsamında sadece bir CBS uygulaması kullanılmamış, sorunların çözümünde en hızlı ve en doğru sonucu hangi uygulama veriyor ise o tercih edilmiştir. Örneğin verilerin toplanması ve düzenlenmesi QGIS uygulaması ile yapılmış iken yapılan yakınlık, görünürlük, bakı ve eğim analizleri ise ArcGIS uygulaması vasıtası ile yapılmıştır. QGIS uygulamasının verileri düzenleme ve veri eklemede belirli kolaylıklar sağlamasından dolayı daha sonrasında raster formatında bulunan analizler taşınmazlar ile yine bu uygulama kullanılarak birleştirilmiştir. Öte yandan QGIS üzerinde analizleri yapmak pek çok hataya sebep olduğundan burada lisanslı ArcGIS uygulaması daha doğru sonuçlar doğurmuştur.

Taşınmaz değerlemesi günümüzde bir sektör haline gelmiş olup birçok alanda faaliyet gösterdiğini de görmekteyiz. Günümüzde özellikle pandemi sonrası dönemde taşınmazların fiyat değişimleri çok dalgalı bir halde olduğundan değerlendirme kriterlerinin güncel tutulabileceği, analizlerin hızlıca yapıp kullanılabileceği bir dijital ortama ihtiyaç artmaktadır. Bunların yanında bu kriterleri kullanarak üretilmek istenen nominal değer haritaları içinde her bir faktörün belirli bir ağırlığı olması gerekmektedir. Bu ağırlıkların her bölgeye ve şehre göre değişmesi kaçınılmaz olacaktır. Özellikle farklı şehirlerde veya ülkelerde çalışmak istenildiğinde ağırlıklar sürekli değişeceği için her biri için ayrı ayrı ağırlık bulmak, hesap yapmak zorunluluğu doğmaktadır. Bu işleminde pek kolay olmayacağı açıktır. Bu çalışma kapsamında da kullanılan makine öğrenmesi bu sorunu büyük oranda çözmektedir. Analizlerin sonuçlarının ilgili taşınmazlara aktarılması sonucunda elde edilen verileri bilgisayara öğrettiğimiz zaman kendisi buna uygun olacak şekilde ağırlıkları çıkartmaktadır. Birçok farklı makine öğrenmesi metodu bu çalışmada denenmiş ve bu öğrenme süreçleri sonuçlarının karesel ortalama hataları ve MAPE değerleri karşılaştırılarak en doğru sonucun CatBoost ile makine öğrenmesi olduğu tespit edilmiştir. Bu metot kullanılarak elde edilen ağırlıklar daha sonrasında CBS uygulaması kullanılarak nominal taşınmaz değer haritalarının üretiminde kullanılmıştır.

Elde edilen sonuçlar ve bulgular da göz önüne alınarak, bulunduğumuz şartlar altında taşınmaz değerlendirme uygulamaları için aşağıdaki öneriler yapılmıştır:

- Pandemi sonrasında taşınmaz fiyatlarında gereğinden fazla artışlar olması, halk dilinde fırsatçılık olarak tabir edebileceğimiz fiyat artışlarının olmasından dolayı vatandaş olumsuz etkilenmiştir. Bunun önüne geçilebilmesi için belediyelerin bu çalışmada da örneği olduğu gibi verileri sürekli güncelleyerek nominal taşınmaz değer haritaları oluşturmalı, buradan el edilen değerlere göre taşınmazların değerinin gereğinden fazla artırılması durumunda bu duruma müdahale edilmelidir.

- Her bir il ve ilçe belediyesinin Konumsal Veri Altyapısı (KVA) kurarak buralarda verileri güncel tutması ve her bir bölgenin fiziksel ve sosyo-ekonomik özelliklerini belirleyerek taşınmaz değerlemesinde kullanılacak olan kriterlerinin belirlenmesi sağlanmalıdır.
- Verilerin şeffaf olması, vatandaşların ve ilgili özel veya kamu kurumlarının üzerinde işlem yapacakları taşınmazların yaklaşık değerlerine erişebilmesini sağlamak amacıyla veriler internet ortamında şeffaf bir şekilde sunulmalıdır.
- Taşınmazların değerlerinin tapu kayıtlarında normalde ki değerinden farklı olması sebebiyle bu taşınmazlar üzerinden alınan vergilerde değişmektedir. Genel olarak taşınmazların değeri normalde olduğundan çok daha düşük tutularak ödenilecek olan emlak vergisi veya benzeri vergilerin de düşürülmesi sağlanır. Bundan dolayı büyük vergi kayıpları yaşanmaktadır. Yapılan bu çalışmaların kurumlarda kullanılması ile bu tarz vergi kayıplarının asgari düzeye indirilebileceği açıktır.
- Verilerin güncel kalması için belirli periyotlar ile bölgelerin incelenmesi, malikler ile görüş alışverişinde bulunulması yerinde olacaktır. Ayrıca ülkemizde en çok kullanılan emlak satış siteleri de belirli aralıklar ile incelenerek bölge hakkında bilgileri güncellemede kullanılabilir. Bu şekilde üretilecek olan taşınmaz değer haritalarının doğru ve faydalı olacağı öngörülmektedir.

KAYNAKLAR

- [1] **Savaş, B.** (2019). *Makine Öğrenme Algoritmalarının Konut Değer Tahmininde Kullanımı: Ankara Gölbaşı Uygulaması.*
- [2] **Güncel Türkçe Sözlük.** (2022, Mayıs 25). Türk Dil Kurumu: <https://sozluk.gov.tr/>
- [3] **Alkan, M., & Özfidan, F.** (2016). Taşınmaz Değerlemesine Yönelik Coğrafi Bilgi Sistemi Tasarımı ve Uygulaması. In *Karaelmas Fen ve Müh. Derg* (Vol. 6, Issue 2). <http://fbd.beun.edu.tr>
- [4] **Erdem, N.** (2017). Toplu (Küme) Değerleme Uygulama Örnekleri ve Ülkemiz İçin Öneriler. *16. Türkiye Harita Bilimsel ve Teknik Kurultayı*, 16.
- [5] **Döner, S.** (2010). *CBS Destekli Taşınmaz Mal Değer Haritalarının Oluşturulması.*
- [6] **Mete, M. O.** (2019). *Coğrafi Bilgi Sistemleri ile İstanbul İli Nominal Taşınmaz Değer Haritasının Oluşturulması.* İstanbul: İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- [7] **Erbil, E. H.** (2014). Taşınmaz Mal Değerleme Amaçlı Coğrafi Bilgi Sistemi Tasarımı. *5. Uzaktan Algılama-CBS Sempozyumu.* İstanbul.
- [8] **Yomralıoğlu, T., Nişancı, R., Çete, M., & Candaş, E.** (2011). Dünya’da ve Türkiye’de Taşınmaz Değerlemesi.
- [9] **Bozdağ, A., Ertunç, E.** (2020). CBS ve AHP Yöntemi Yardımıyla Niğde Kenti Örneğinde Taşınmaz Değerleme. *Geomatik Dergisi*, 5(3). <https://doi.org/10.29128/geomatik.648900>
- [10] **Canaz Sevgen, S., & Aliefendioğlu, Y.** (2020). Mass Appraisal With A Machine Learning Algorithm: Random Forest Regression. *Bilişim Teknolojileri Dergisi*, 13(3), 301–311. <https://doi.org/10.17671/gazibtd.555784>
- [11] **İlhan, A. T.** (2019). Yapay sinir ağları yönteminin gayrimenkullerin toplu değerlemesinde uygulanabilirliğinin araştırılması: Gölbaşı ilçesi örneği, *Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Ankara.*
- [12] **Dimopoulos, T., Tyralis, H., Bakas, N. P., & 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.
- [13] **Antipov, E. A., & Pokryshevskaya, E. B.** (2012). Mass appraisal of residential apartments: An application of Random forest for valuation and a CART-based approach for model diagnostics. *Expert Systems with Applications*, 39(2), 1772-1778.
- [14] **Karagöz, C.** (2018). Taşınmaz değerlemede yapay zekâ tekniklerinin kullanılabilirliği ve yöntemlerin karşılaştırılması, *Konya Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Yüksek Lisans Tezi, Konya.*
- [15] **Ishaku, M. M., & Lewu, H. I.** (2021). Research on the Effect of Artificial Intelligence Real Estate Forecasting Using Multiple Regression Analysis and Artificial Neural Network: A Case Study of Ghana. *Journal of Computer and Communications*, 9(10), 1-14.

- [16] **Tabar, M. E., Başara, A. C., & Şişman, Y.** (2021). Çoklu Regresyon ve Yapay Sinir Ağları ile Tokat İlinde Konut Değerleme Çalışması. *Türkiye Arazi Yönetimi Dergisi*, 3(1), 1-7.
- [17] **Öztürk, M. Z.** (n.d.). *Coğrafi Bilgi Sistemlerine Giriş*.
- [18] **Yılmaz, A., & Demir, H.** (2011). Çok Ölçütlü Karar Destek Sistemleri ile Taşınmaz Değerleme ve Oran Çalışması. *Jeoinformasyon ve Arazi Yönetimi Dergisi*, 2, 107–112. www.hkmo.org.tr
- [19] **Erdem, N.** (2017). Toplu (Küme) Değerleme Uygulama Örnekleri ve Ülkemiz İçin Öneriler. 16. *Türkiye Harita Bilimsel ve Teknik Kurultayı*. Ankara: TMMOB Harita ve Kadastro Mühendisleri Odası.
- [20] **Mitchell, T. M.** (1997). *Machine learning* (WBC/McGraw-Hill, Boston). MA.
- [21] **Murphy, K. P.** (2012). *Machine learning: a probabilistic perspective*. MIT press.
- [22] **Mahesh, B.** (2020). Machine Learning Algorithms-A Review. *International Journal of Science and Research (IJSR)*. [Internet], 9, 381-386.
- [23] **Jordan, M. I., & Mitchell, T. M.** (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260.
- [24] **Mitchell, T. M.** (2006). The discipline of machine learning (Vol. 9). Pittsburgh: Carnegie Mellon University, School of Computer Science, Machine Learning Department.
- [25] **Canepa, G. A.** (2016). What you need to know about machine learning. *Birmingham: Packt Publishing*.
- [26] **Russell, S. ve Norvig, P.** (2003). *Artificial Intelligence: A Modern Approach*, 2. Baskı, Prentice Hall, USA, 650.
- [27] **Berry, M. J., & Linoff, G. S.** (2004). *Data mining techniques: for marketing, sales, and customer relationship management*. John Wiley & Sons.
- [28] **Kaelbling, L. P., Littman, M. L., & Moore, A. W.** (1996). Reinforcement learning: A survey. *Journal of artificial intelligence research*, 4, 237-285.
- [29] **Torun, M. K.** (2009). Taşınmaz değer haritalarının Coğrafi Bilgi Sistemleri ile üretilmesi (Doctoral dissertation, Fen Bilimleri Enstitüsü).
- [30] **Earth Science Data Systems (ESDS)**, <https://search.asf.alaska.edu/#/>
- [31] **Doldur, M., & Alkan, R. M.** (2021). Nominal Değerleme Yöntemi ile CBS Destekli Taşınmaz Değer Haritalarının Oluşturulması: Avanos/Nevşehir Örneği. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 21(4), 846-863.
- [32] **Ozulu, İ. M.** (2015). Uzaktan algılama ve coğrafi bilgi sistemleri yöntemlerinin arkeolojiye uygulanması (Doctoral dissertation, Anadolu University (Turkey)).
- [33] **Berkeley:** School Of Information, <https://ischoolonline.berkeley.edu/blog/what-is-machine-learning/>
- [34] **Keleş, M. B., Keleş, A., & Keleş, A.** (2020). Makine Öğrenmesi Yöntemleri ile Uçuş Fiyatlarının Tahmini.
- [35] **Kurt, A., Buldu, B., & Cedimoğlu, İ. H.** (2020). XGBoost ve Rastgele Orman Algoritmalarının Ağ Tabanlı Saldırı Tespitine Yönelik Performanslarının Karşılaştırılması.
- [36] **Dorogush, A. V., Ershov, V., & Gulin, A.** (2018). CatBoost: gradient boosting with categorical features support. *arXiv preprint arXiv:1810.11363*.
- [37] **Kılıç, S.** (2013). Örneklem Yöntemleri. *Journal of Mood Disorders*, 3(1).



- [38] **Şahinler, S.** (2000). En küçük kareler yöntemi ile doğrusal regresyon modeli oluşturmanın temel prensipleri. Mustafa Kemal Üniversitesi Ziraat Fakültesi Dergisi, 5(1-2), 57-73.
- [39] **Şahin, Utku.** Esri Türkiye Blogu. “<https://blog.esri.com.tr/2018/12/25/arcgiste-mesafe-analizlerine-genel-bir-bakis/>”
- [40] **ESRI Tool Reference.** “<https://pro.arcgis.com/en/pro-app/2.8/tool-reference/spatial-analyst/how-slope-works.htm>”
- [41] **ESRI Tool Reference.** “<https://pro.arcgis.com/en/pro-app/2.8/tool-reference/3d-analyst/measuring-aspect.htm>”
- [42] **ESRI Tool Reference.** “<https://pro.arcgis.com/en/pro-app/2.8/tool-reference/spatial-analyst/how-slope-works.htm>”
- [43] **Muratlar, Emre R..** Veri Bilimi Okulu. “<https://www.veribilimiokulu.com/lightgbm/>”



EKLER


EK A: Haritalar



EK B: Tablolar



EK A: Haritalar



























































































































































EK B: Tablolar

Model	MAE	RMSE	R ²	MAPE
Multiple Linear Regression	49431.4673	74253.6615	0.6145	0.3425
Random Forest	45291.5087	69011.9018	0.6669	0.3118
XGBoost	45196.2676	68844.6854	0.6686	0.3094
CatBoost	44588.1181	67734.6284	0.6792	0.3059
LightGBM	46298.1075	70614.3888	0.6513	0.3184
ANN	47107.0347	71151.7328	0.6460	0.3296

Tablo 1- Manchester şehri için Regresyon modellerinin doğruluk metrikleri

Model	MAE	RMSE	R ²	MAPE
Multiple Linear Regression	46810.0630	70306.7651	0.6544	0.3247
Random Forest	29540.0063	48516.1592	0.8354	0.1981
XGBoost	31256.0446	48169.1457	0.8378	0.2122
CatBoost	28285.6507	43592.4587	0.8671	0.1928
LightGBM	38738.1057	58352.7524	0.7619	0.2677
ANN	40341.4470	60190.7464	0.7467	0.2760

Tablo 2- Manchester şehri için özellik zenginleştirme sonrası doğruluk metrikleri

Model	MAE	RMSE	R ²	MAPE
Multiple Linear Regression	39149.2446	52550.2956	0.5537	0.3657
Random Forest	36389.9855	50015.3575	0.5958	0.3477
XGBoost	37637.2304	51341.7808	0.5740	0.3580
CatBoost	36377.4960	49378.4385	0.6060	0.3472
LightGBM	37517.9474	50620.4360	0.5859	0.3573
ANN	37974.2199	51632.8812	0.5692	0.3490

Tablo 3- Liverpool şehri için Regresyon modellerinin doğruluk metrikleri

Model	MAE	RMSE	R²	MAPE
Multiple Linear Regression	29015.8667	39741.3063	0.7448	0.2764
Random Forest	19406.2909	29047.1316	0.8637	0.1771
XGBoost	20283.3217	29951.2175	0.8550	0.1851
CatBoost	19181.1229	28071.3782	0.8727	0.1766
LightGBM	22322.6467	31681.8952	0.8378	0.2084
ANN	27513.7547	38250.7125	0.7636	0.2575

Tablo 4- Liverpool şehri için özellik zenginleştirme sonrası doğruluk metrikleri

Model	MAE	RMSE	R²	MAPE
Multiple Linear Regression	44634.0962	60314.2126	0.6047	0.3420
Random Forest	41577.2474	56712.6145	0.6505	0.3195
XGBoost	42526.7316	58687.6675	0.6257	0.3239
CatBoost	41337.2239	56685.3905	0.6508	0.3174
LightGBM	42634.8245	57796.5105	0.6370	0.3326
ANN	43682.2905	59313.1846	0.6177	0.3386

Tablo 5- Newcastle şehri için Regresyon modellerinin doğruluk metrikleri

Model	MAE	RMSE	R²	MAPE
Multiple Linear Regression	35795.1270	49551.3925	0.7244	0.2781
Random Forest	22808.6219	34920.7343	0.8675	0.1592
XGBoost	23532.2656	34744.3937	0.8688	0.1668
CatBoost	22017.3464	32684.5464	0.8839	0.1565
LightGBM	26932.9291	38309.0165	0.8405	0.2004
ANN	31312.8194	44067.8443	0.7890	0.2332

Tablo 6- Newcastle şehri için özellik zenginleştirme sonrası doğruluk metrikleri