

MAKİNE ÖĞRENİMİ TEKNİKLERİ VE VERİ BİRLEŞTİRME KULLANILARAK BİNA SINIFLANDIRMA: FATİH ÖRNEĞİ

Abdulkadir MEMDUHOĞLU¹

¹Dr. Öğr. Üyesi, Harran Üniversitesi, Harita Mühendisliği Bölümü, 63050, Osmanbey Kampüsü, Şanlıurfa, akadirm@harran.edu.tr

ÖZET

Şehirler, hızla artan dünya nüfusunun en çok etkilediği alanlar olup, içerisinde çeşitli türde bina barındırmaktadır. Binaların kullanım türlerinin belirlenmesi, şehir planlama, afet ve acil durum yönetimi gibi alanlarda kritik öneme sahiptir. Ancak, bina kullanım türlerinin tespiti geleneksel yöntemlerle (yerinde tespit) yapıldığında zaman ve maliyet açısından oldukça pahalıdır. Bu bağlamda, makine öğrenimi gibi yenilikçi yöntemler ve erişilebilirliği her geçen gün artan farklı kaynaklardaki mekânsal verilerin birleştirilmesiyle, bina türleri geleneksel yöntemlere göre daha hızlı ve kolay tespit edilebilmektedir.

Bu çalışmada, İstanbul ili Fatih ilçesine ait bina verileri makine öğrenme teknikleri ve veri birleştirme kullanılarak sınıflandırılmıştır. Resmi kaynaklardan elde edilen bina türleri verisi ile bir referans verisi oluşturulmuştur. Ardından, OpenStreetMap (OSM)'den elde edilen mekânsal bina verileri, Alman Havacılık ve Uzay Merkezi (DLR)'dan elde edilen bina yükseklikleri ve WorldPop Grid kaynağından elde edilen 100m çözünürlüklü nüfus raster verileri kullanılarak makine öğrenimi yöntemiyle gerçekleştirilen sınıflandırma bu referans verisiyle karşılaştırılmış ve doğruluk analizleri yapılmıştır.

Makine öğrenme işlemi için, öncül testlerle daha uygun olduğu tespit edilen XGBoost yöntemi tercih edilmiştir. Bina sınıflarının tespiti için etkili olabilecek alan, çevre, en uzun eksen uzunluğu gibi bina boyut parametreleri ve dairesellik, karelik, dönüklük gibi şekil karmaşıklığı parametreler hesaplanarak modele dahil edilmiştir. Bahsedilen diğer kaynaklardan elde edilen bilgiler de eklendiğinde, modelde toplamda 31 parametre kullanılmıştır. Ayrıca, OSM ve referans verileri karşılaştırılırken birebir eşleşen binalar kullanılmış, ticari ve mesken karışımı binalardan tespit edilebilenler, daha sağlıklı bir karşılaştırma sağlamak amacıyla kapsam dışında bırakılmıştır.

Geliştirilen model, farklı kaynaklardan ve çeşitli türdeki açık kaynaklı verileri kullanarak bina türlerini belirli bir doğrulukla sınıflandırabilmektedir. Çalışmanın sonuçları, modelin %68 F1-skoru değerine ulaşabildiğini göstermektedir. Ancak, modelin farklı bölgelerde nasıl performans göstereceği ayrıntılı analize ihtiyaç duymaktadır.

Anahtar Sözcükler: makine öğrenimi, bina sınıflandırma, mekânsal veri entegrasyonu, şehir planlama

ABSTRACT

INTEGRATION OF MACHINE LEARNING TECHNIQUES AND DATA FUSION FOR BUILDING CLASSIFICATION: FATİH CASE

Urban areas are significantly impacted by the rapidly growing global population and contain a diverse range of building types. Determining the usage types of buildings is crucial in fields such as urban planning, disaster and emergency management. However, traditional methods (on-site inspection) for identifying building usage types are time-consuming and costly. In this context, innovative methods such as machine learning and the integration of spatial data from various increasingly accessible sources enable faster and easier identification of building types compared to traditional methods.

In this study, building data from the Fatih district of Istanbul was classified using machine learning techniques and data integration. A reference dataset was created using building type data obtained from official sources. Subsequently, spatial building data obtained from OpenStreetMap (OSM), building heights from the German Aerospace Center (DLR), and 100m resolution population raster data from the WorldPop Grid were used. The classification performed using machine learning was compared with this reference dataset, and accuracy analyses were conducted.

For the machine learning process, the XGBoost method, identified as more suitable through preliminary tests, was preferred. Building shape parameters such as area, perimeter, longest axis length, and morphological parameters such as circularity, squareness, and rotation were calculated and included in the model. When combined with information obtained from the aforementioned sources, a total of 31 parameters were used in the model. Additionally, when comparing OSM and reference data, only directly matched buildings were used, and buildings with mixed commercial and residential use were excluded to ensure a more accurate comparison.

The developed model can classify building types with a certain accuracy by utilizing data from various open-source data sources. The results show that the model can achieve an F1-score of 68%. However, detailed analysis is needed to determine how the model performs in different regions.

Keywords: machine learning, building classification, spatial data integration, urban planning

1. GİRİŞ

Son yıllarda hızla artan kentleşme eğilimi, Birleşmiş Milletler'in projeksiyonlarına göre önümüzdeki yıllarda da devam edecektir (Birleşmiş Milletler, 2018). Kentleşmedeki bu artış, konut, ulaşım ve kamu hizmetlerine olan talebin yükselmesine neden olarak sosyal ve ekonomik sistemler üzerinde ciddi baskılar oluşturmakta ve şehirlerin sürdürülebilirliğini tehdit etmektedir (Glaeser, 2011). Bu bağlamda, şehirlerin planlanması ve yönetimi için mekânsal bilginin doğru ve güncel bir şekilde elde edilmesi kritik bir önem taşımaktadır.

Bina sınıflandırması, şehirlerdeki yapıların kullanım amaçlarına göre belirli kategorilere ayrılması sürecidir ve mekânsal analizlerde temel bir rol oynar. Ancak, geleneksel yöntemlerle bina sınıflandırması yapmak genellikle zaman alıcı ve maliyetlidir (Platt, 2014). Bu durum, özellikle hızlı kentleşen bölgelerde güncel ve detaylı veriye olan ihtiyacı karşılamada yetersiz kalmaktadır. Dolayısıyla, daha etkin ve otomatikleştirilmiş yöntemlere olan gereksinim artmaktadır.

Günümüzde, uzaktan algılama ve sokak görünümü görüntüleri (Street View Images) gibi farklı veri kaynakları kullanılarak bina sınıflandırması gerçekleştirilmektedir. Bu yöntemler, geniş alanlarda veri toplayabilme ve güncel bilgiyi hızlı bir şekilde elde edebilme avantajlarına sahiptir. Bununla birlikte, tek bir veri kaynağının kullanılması sınırlı bilgi sağlayabilir ve sınıflandırma doğruluğunu etkileyebilir. Bu nedenle, veri birleştirme teknikleri kullanılarak farklı veri kaynaklarının entegrasyonu, daha güvenilir ve detaylı sonuçlar elde etmeyi mümkün kılmaktadır.

Makine öğrenimi (Machine Learning, ML) teknikleri, büyük ve karmaşık veri setlerinin analizinde etkin çözümler sunarak bina sınıflandırmasında önemli bir rol oynamaktadır (Goodfellow vd., 2016). Özellikle derin öğrenme yöntemleri, görüntü verilerinden karmaşık özellikleri otomatik olarak öğrenebilme kapasitesiyle yüksek doğruluk oranları sağlamaktadır. Son dönemde, büyük dil modelleri (Large Language Models, LLMs) gibi yapay zekâ yaklaşımları da bina sınıflandırması alanında kullanılmaya başlanmıştır. LLM'ler, metin tabanlı verilerden anlam çıkarabilme yetenekleri sayesinde, örneğin yapıların metinsel tanımlarından veya sosyal medya verilerinden faydalanarak sınıflandırma yapabilmektedir (Brown vd., 2020). Özellikle, Memduhoğlu vd. (2024), OpenStreetMap (OSM) etiketlerinin LLM gömülerini (embeddings) kullanarak bina fonksiyonlarının sınıflandırılmasında önemli gelişmeler kaydetmiştir; bu da metin tabanlı verilerin bina sınıflandırmasında nasıl etkin bir şekilde kullanılabileceğini göstermektedir.

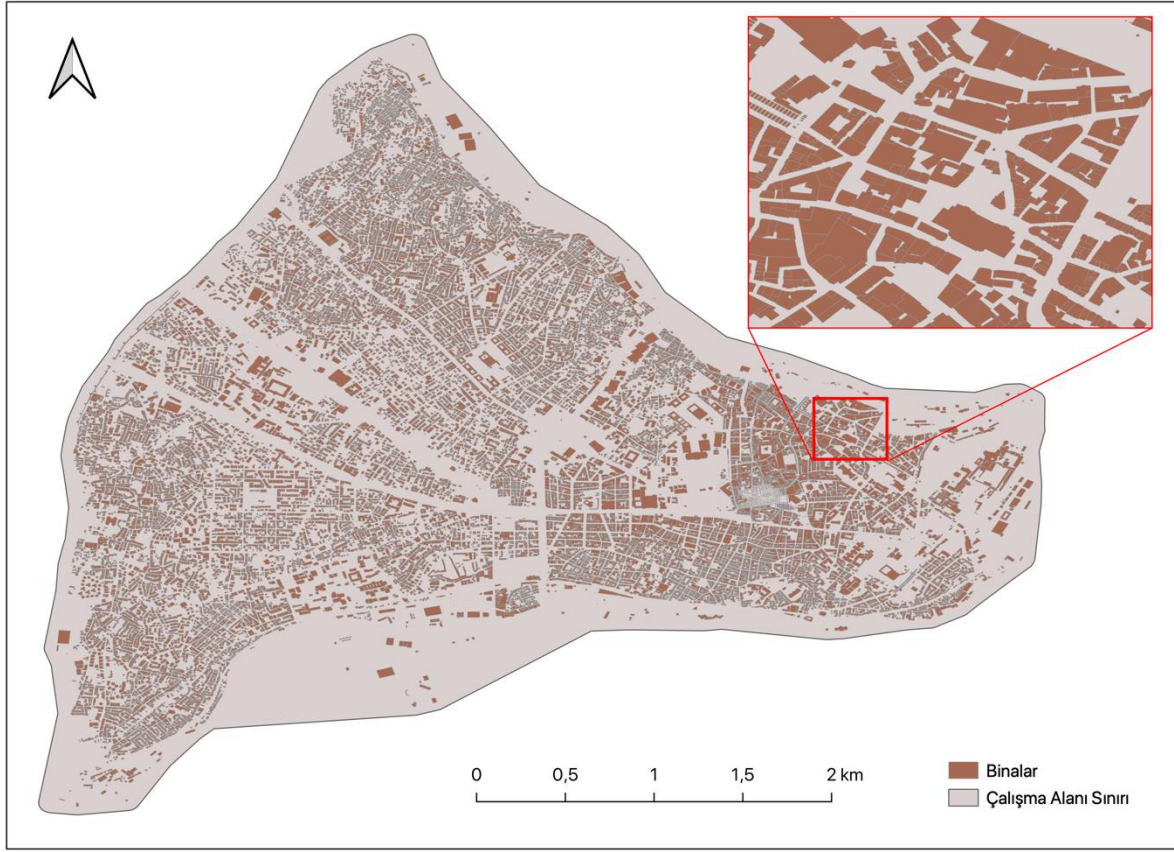
Bu çalışma, makine öğrenimi teknikleri ve veri birleştirme yöntemlerini kullanarak bina sınıflandırmasında daha etkin ve doğru sonuçlar elde etmeyi amaçlamaktadır. Farklı veri kaynaklarının entegrasyonu sayesinde, tek bir kaynaktan elde edilemeyen bilgilerin bir araya getirilmesi ve böylece sınıflandırma performansının artırılması hedeflenmektedir. Ayrıca, geleneksel yöntemlerin zorluklarını aşmak ve hızlı kentleşmenin getirdiği ihtiyaçlara cevap verebilmek için otomatikleştirilmiş ve ölçeklenebilir bir yaklaşım sunulacaktır.

Bu çalışmada, Fatih ilçesinde bulunan veriler kullanılarak binaların: boyut, şekil karmaşıklığı, mekânsal ilişkileri ve OSM bilgileri makine öğrenimi ve farklı kaynaklardan gelen veriler birleştirilerek sınıflandırılacaktır. Sonraki bölümde, çalışma alanı tanımlanacak, referans veri seti ile diğer kullanılan veri setleri detaylandırılacaktır. Üçüncü bölümde, sınıflandırma yöntemine yer verilecek olup, dördüncü bölümde ise elde edilen sonuçlar tartışılacak ve çalışmanın genel değerlendirmesi yapılacaktır.

2. ÇALIŞMA ALANI VE KULLANILAN VERİ SETLERİ

2.1. Çalışma Alanı ve Referans Veri Seti

Çalışma alanı, İstanbul'un tarihi yarımadasını ve birçok tarihi yapıyı barındıran Fatih ilçesini kapsamaktadır. Bu bölge, zengin kültürel mirası ve karmaşık kentsel dokusuyla bina sınıflandırması çalışmaları için ideal bir örnek sunmaktadır. Kullanılan veri seti, İstanbul Büyükşehir Belediyesi'nin sorumluluğu altında, 1:1.000 ölçekli topografik verilerden üretilmiştir.



Şekil 1. Çalışma alanı ve referans veri setindeki binalar

Veri setinde yer alan semantik bilgiler doğrudan bina türlerini yansıtmamaktadır. Örneğin, binaların fonksiyonlarına ilişkin net sınıflandırma etiketleri mevcut değildir. Bunun yerine, katman bilgisi, iş yeri sayısı, konut sayısı gibi çeşitli özellikler bulunmaktadır. Bu özellikler, binaların kullanım amaçlarına dair dolaylı bilgiler sunmaktadır. Bu nedenle, mevcut verilerden yararlanarak bir referans veri seti oluşturmak için bu dolaylı göstergeler kullanılmıştır. Özellikle, kat sayısı ve iş yeri veya konut birimi sayısı gibi parametreler, binaların fonksiyonel sınıflandırılmasında önemli ipuçları sağlamaktadır. Çalışmada mevcut veri setindeki dolaylı semantik bilgiler kullanılarak güvenilir bir referans veri seti oluşturulmuştur. Bu referans veri seti, makine öğrenimi modellerinin eğitimi ve doğrulanması için temel teşkil etmektedir.

Bu çalışmada, bina sınıflandırması için farklı veri kaynakları kullanılmış ve bu veriler çeşitli başlıklar altında incelenmiştir.

2.2 Bina Yüksekliği

Bina yüksekliği verisi, Alman Havacılık ve Uzay Merkezi (DLR) tarafından sağlanan World Settlement Footprint 3D (WSF3D) Bina Yüksekliği veri setinden elde edilmiştir (Esch vd., 2022). Bu veri seti, dünya çapındaki her yerleşim bölgesinde ortalama bina yüksekliğini 90 metrelik bir ölçüm ızgarası kullanarak ortaya koymaktadır. Bu sayede, çalışma alanındaki binaların yüksekliklerine dair genel bir perspektif elde edilmiştir.

2.3 Nüfus Yoğunluğu

Nüfus yoğunluğu verileri, 2010-2011 yıllarına ait WorldPop veri setinden alınmıştır (Bondarenko vd., 2020). GeoTIFF formatında ve ekvatorda yaklaşık 100 metreye denk gelen 3 ark-saniye çözünürlükte olan bu veri seti, çalışma alanındaki nüfus dağılımının detaylı bir şekilde incelenmesine olanak tanımıştır.

2.4 OSM Bina Verileri

OSM, dünya genelindeki gönüllü kullanıcılar tarafından sağlanan açık kaynaklı coğrafi bilgi platformudur. OSM, binalar hakkında geometrik bilgilerin yanı sıra, kullanıcılar tarafından anahtar:değer formatında sunulan semantik detayları da içermektedir. Örneğin, 'building:apartment' gibi bir etiket, binanın konut amaçlı kullanıldığını gösterebilir. OSM, belirli özellikler için önceden tanımlanmış anahtar ve değerlerin kullanılmasına yönelik bir rehber

sunmasına rağmen, kullanıcılar kendi etiketlerini oluşturma ve uygulama esnekliğine sahiptir. Bu durum, OSM verilerinin mekânsal dağılımı, etiketlerin sağladığı bilgi ve tamlığı açısından heterojenlik göstermesine neden olmaktadır.

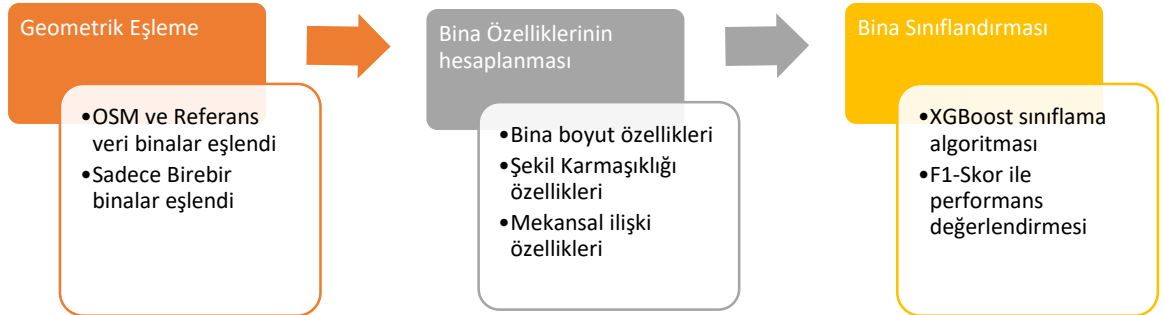
Bu çalışmada, OSM binalarının verileri, HeiGIT (2024) tarafından sağlanan Ohsome (2024) API'si kullanılarak toplanmıştır. HeiGIT, insani yardım, akıllı mobilite ve iklim değişikliği araştırmaları konusunda uzmanlaşmış kâr amacı gütmeyen bir kuruluştur. Elde edilen OSM bina verilerinin sadece geometrisi kullanılmış, etiketlerin yer aldığı semantik kısmı verilerin işlenmesindeki zorluklar nedeniyle çalışmaya dahil edilmemiştir.

2.5 İlgi Noktaları (POI) Verileri

Bina verilerine ek olarak, OSM restoranlar, mağazalar ve diğer tesisler gibi İlgi Noktaları (Point of Interest, POI) verilerini de içermektedir. Bu POI'ler genellikle belirli binalarla ilişkili olsalar da ayrı bir biçimde nokta geometri olarak temsil edilirler. Bu bağlamda, şehirlerdeki insan aktivitelerini içeren POI'leri seçmek için ohsome API üzerinden bir filtre kullanılmıştır. Bu seçim, çeşitli tesisleri (örneğin, kafeler, bankalar, sinemalar, restoranlar), sağlık kuruluşlarını, tarihi yerleri, eğlence mekânlarını (örneğin, buz pistleri, eğlence parkları, yüzme havuzları) ve çeşitli mağaza türlerini içermektedir. Bu çalışmada, POI'lerin etiket verileri kullanılmadan, yalnızca mekânsal dağılımlarına odaklanan istatistiksel bir yöntem olan Kernel Yoğunluk Tahmini (Kernel Density Estimate, KDE) yöntemi uygulanmıştır.

3. YÖNTEM VE UYGULAMA

İlk olarak, OSM'deki bina verileri geometrik olarak referans veri seti ile eşleştirilmiştir. Eşleştirme işleminden sonra, bina yüksekliği ve nüfus yoğunluğu gibi çeşitli kaynaklardan elde edilen ek veriler OSM bina veri setine entegre edilmiştir. Bu ek veriler ışığında, sınıflandırma süreci için gerekli veri seti oluşturulmuş ve özellikler hesaplanmıştır. Sınıflandırma aşamasında XGBoost algoritması kullanılmıştır. Sonuç olarak, sınıflandırma performansı analiz edilmiş ve elde edilen bulgular detaylı bir şekilde sunulmuştur. İzlenen yöntem adımları Şekil 2'de gösterilmektedir.



Şekil 2. Yöntem aşamaları

3.1 Geometrik Eşleme

Bina sınıflandırma süreci OSM'den elde edilen binaların geometrik verileri ile mekânsal referans veri seti eşleştirilerek gerçekleştirilmiştir. Bu süreçte, yalnızca birebir eşleşen binalar dikkate alınmış; bire-çok, çok-bir veya çok-açok gibi daha karmaşık eşleştirme türleri ise çalışmanın kapsamı dışında bırakılmıştır. OSM binalarının doğrudan referans veri setinin geometri yerine kullanılması, referans veri setine bağımlı olmadan gerçekleştirilecek sınıflandırma uygulamalarının yapılabirliğini test etmeyi amaçlamaktadır. Her ne kadar sınıflandırma doğruluğunu artırmak amacıyla referans veri seti üzerinde de testler yapılabilecek olsa da bu çalışma, bağımsız uygulama yeteneklerini öne çıkarmayı hedeflemektedir.

Geometrik eşleştirme işlemi, Memduhoğlu ve Başaraner (2024) tarafından önerilen Denklem 1 ile gerçekleştirilmiştir. Bu denklem, birebir eşleşen binaları seçmek amacıyla, yüksek kesişim oranlarına sahip alanları optimize edecek şekilde tasarlanmıştır. Denklem, OSM verisi ile referans veri setindeki binaların alanlarının kesişen kısmının, büyük olan bina alanının %60'ından fazla olması durumunda, bu binaların eşleşme olarak kabul edilmesine olanak sağlamaktadır.

$$\frac{\text{Alan}_{\text{kesişen}}}{\max(\text{Alan}_{\text{OSM}}, \text{Alan}_{\text{Ref}})} \geq 0.6 \quad (1)$$

Eşleştirme süreci sonucunda 6.048 bina birebir eşleştirilmiş ve bu binalar, sınıflandırma aşamasına geçmek üzere sonraki adımda değerlendirilmiştir.

3.2 Bina Özelliklerinin Hesaplanması

3.2.1 Bina Boyut Özellikleri

İlk olarak, binaların yükseklik bilgisi, Alman Havacılık ve Uzay Merkezi (DLR) tarafından sağlanan World Settlement Footprint 3D (WSF3D) raster dosyasından türetilmiştir (Esch vd., 2022). WSF3D raster verisi, küresel yerleşim yerlerindeki binaların yükseklik bilgilerini sağlamaktadır. Bu raster veri, OSM bina sınırları üzerine bindirilmiş ve her bina için ortalama yükseklik değerleri hesaplanmıştır. Ardından, bireysel binalara ait beş adet boyut özelliği hesaplanmıştır: alan (area), yükseklik (height), çevre (perimeter), hacim (volume) ve en uzun eksen uzunluğu (longest axis length).

3.2.2 Şekil Karmaşıklığı Özellikleri

Şekil karmaşıklığı özellikleri, bireysel binalar ve bina bloklarıyla ilgili olmak üzere iki düzeyde hesaplanmıştır. Bina blokları, kentsel form ve morfolojinin nicel analizi ve görselleştirilmesi için tasarlanmış açık kaynaklı bir Python kütüphanesi olan Momepy kullanılarak belirlenmiştir (Fleischmann, 2019). Momepy, binaların etrafında Voronoi diyagramları oluşturarak blokları tanımlar. Bu diyagramlar, her binanın etrafında 100 metrelik bir mesafe eşiği ile sınırlanmış ve blokların ana yollar veya diğer engeller boyunca uzanmamasını sağlamak için kırılmıştır.

Bireysel binalara ait on adet şekil karmaşıklığı özelliği hesaplanmıştır: dairesel kompaktlık (circular compactness), dışbükeylik (convexity), uzama (elongation), eşdeğer dikdörtgen indeksi (Equivalent Rectangle Index, ERI), fraktal boyut (fractal dimension), yönelim (orientation), dikdörtgensellik (rectangularity), pürüzlülük indeksi (roughness index), kare kompaktlığı (square compactness) ve karelik (squareness). Ayrıca, blok bazında yedi adet özellik hesaplanmıştır: blok alanı (block area), blok çevresi (block perimeter), blok dışbükeyliği (block convexity), blok uzaması (block elongation), blok ERI (block Equivalent Rectangle Index, ERI), blok fraktal boyut (block fractal dimension) ve blok kareliği (block squareness). Bu özelliklerden bazıları Momepy kütüphanesinde zaten uygulanmışken, diğerleri Python'da manuel olarak kodlanmıştır. Hesaplamalarda Basaraner ve Cetinkaya (2017)'de yer alan formüller kullanılmıştır. Blok bazlı özellikler, binalar için kullanılan formüllerin aynısı kullanılarak hesaplanmış, ancak bina ayak izleri yerine blok sınırları kullanılmıştır.

3.2.3 Mekânsal İlişki Özellikleri

Mekânsal ilişki özellikleri, binalar ve çevrelerindeki diğer binalar ve sokaklarla olan ilişkilerini ele almaktadır. Bu kategori ayrıca, binaların etrafındaki nüfus yoğunluğunu da içermektedir; bu, insan aktivitesi ve hizmet talebinin bir göstergesidir. Yüksek yoğunluklu alanlar, konut bölgelerini veya ticari merkezleri işaret edebilirken, daha düşük yoğunluklu alanlar endüstriyel veya kurumsal bölgelere karşılık gelebilir.

Ayrıca, şehir sınırları boyunca İlgi Noktalarının (Point of Interest, POI) yoğunluk değerlerini tahmin etmek için Gaussian Kernel Yoğunluk Tahmini (KDE) yöntemi uygulanmıştır. Bu parametrik olmayan yöntem, ayrı POI verilerini sürekli bir yoğunluk yüzeyine dönüştürerek, kentsel çevre içinde olanaklar ve altyapının mekânsal örüntülerini ortaya çıkarır ve merkezi yerleri veya sıcak noktaları (hot spots) belirler. KDE, çalışma alanı boyunca 10 metrelik çözünürlükte bir raster çıktı ile hesaplanmıştır. 10 metrelik çözünürlük, detay ve hesaplama verimliliği arasında bir denge sağladığı için seçilmiştir. Bu KDE değerleri daha sonra bina ayak izleriyle keşitirilerek her bina için ortalama yoğunluk değerleri hesaplanmıştır.

Mekânsal ilişkiler için dokuz adet özellik hesaplanmıştır: bitişiklik (adjacency), binalar arası mesafe (building distance), komşu mesafesi (neighbor distance), paylaşılan duvar oranı (shared wall ratio), sokak hizalaması (street alignment), blok bina sayısı (block building count), blok bina yoğunluğu (block building density), blok nüfus yoğunluğu (block population density) ve KDE ortalaması (KDE mean).

Bu kapsamda hem bireysel bina özellikleri hem de binaların mekânsal ilişkilerini kapsayan toplam 31 parametre hesaplanmış ve bu parametreler sınıflandırma sürecinde kullanılmak üzere hazırlanmıştır.

3.3 Bina Sınıflandırması

Veri seti, modelin eğitimi ve test edilmesi amacıyla %80 eğitim ve %20 test olarak ikiye bölünmüştür. Bu oran, makine öğrenimi modellerinin genelleme yeteneğini değerlendirmek için yaygın olarak kullanılmaktadır. Ancak, veri dağılımında konut binalarının baskın olması, sınıf dağılımında dengesizliğe yol açmıştır. Sınıf dağılımındaki dengesizlik, model değerlendirmesinde kullanılan özelliklerin seçiminde kritik bir rol oynamaktadır. Doğruluk (accuracy) metriği, dengesiz sınıf dağılımlarında yanıltıcı olabilir çünkü sınıf boyutlarındaki farklılıkları dikkate

almaz (Branco vd., 2016; Galar vd., 2011). Bu nedenle, modelin performansını daha adil ve dengeli bir şekilde değerlendirmek için makro ortalama F1-skoru kullanılmıştır.

F1-skoru, kesinlik (precision) ve duyarlılık (recall) değerlerinin harmonik ortalamasıdır. Kesinlik, doğru pozitif sonuçların tüm pozitif tahminlere oranını ifade ederken, duyarlılık, doğru pozitif sonuçların tüm gerçek pozitif örneklere oranını temsil eder. F1-skoru aşağıdaki formülle hesaplanır:

$$F1\text{-skoru} = \frac{2 \times \text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}}$$

Bu skor, tüm sınıflar için ayrı ayrı hesaplanmış ve makro ortalama alınarak genel performans değerlendirilmiştir. Bu yaklaşım, her sınıfa eşit ağırlık vererek dengesiz veri setlerinde daha doğru bir performans ölçümü sağlamaktadır. Literatürde sekiz sınıfa kadar bina sınıflandırma örnekleri bulunmakla birlikte, bu çalışmada referans veri setinin manuel olarak oluşturulması ve çalışma alanındaki çok çeşitli binaların yoğunluğu nedeniyle binalar iki temel sınıfta, mesken ve mesken olmayan olarak, sınıflandırılmıştır.

Bu çalışmada, XGBoost algoritması kullanılmış ve varsayılan parametreler tercih edilmiştir: öğrenme hızı 0.3, maksimum ağaç derinliği 6 ve 100 tahminci. Modelin optimizasyonunda, çok sınıflı logaritmik kayıp fonksiyonu (mlogloss) kullanılmıştır. Bu kayıp fonksiyonu, sınıf etiketlerinden sapmaları cezalandırarak modelin doğruluğunu değerlendirmektedir.

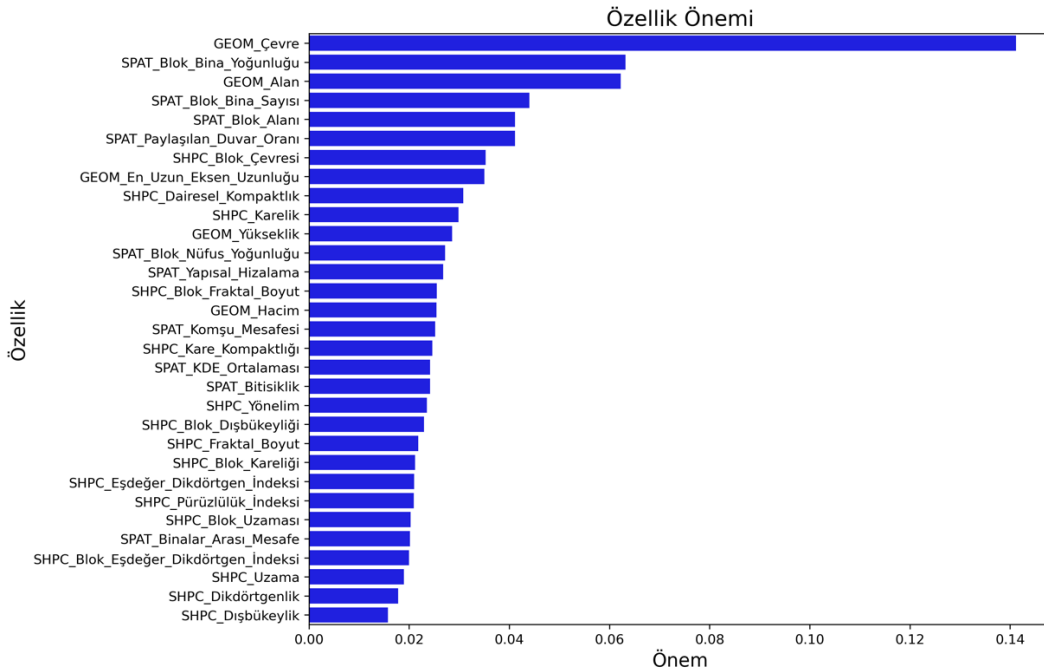
Uygulama, Python (v3.10) ortamında, Apple M1 çipine sahip bir macOS (v14.5) işletim sistemi üzerinde gerçekleştirilmiş ve Apple'ın Metal Performance Shaders (MPS) cihazı kullanılmıştır. Bu donanım ve yazılım kombinasyonu, modelin eğitim ve değerlendirme süreçlerinde yüksek performans sağlamıştır.

Uygulama sonucunda Fatih ilçesinde yer alan binalar ortalama %68 F1-Skoru değeriyle sınıflandırılmıştır. Bu sonuca ait istatistikler Tablo 1'de gösterilmiştir.

Çizelge 1. Sınıflandırmaya ait istatistik bilgileri

| | Kesinlik | Duyarlılık | F1-Skoru |
|-----------------------|----------|------------|-------------|
| Mesken | 0.9 | 0.97 | 0.93 |
| Mesken olmayan | 0.63 | 0.33 | 0.43 |
| <i>Makro ortalama</i> | 0.76 | 0.65 | 0.68 |

XGBoost algoritması, gradyan artırma stratejisini kullanarak ardışık ağaçlar oluşturarak ve her bir ağacın yaprak bazlı genişlemesiyle özellik önemini belirleyebilir. Bu bağlamda sınıflandırmaya giren 31 parametrenin sonuca hangi oranda katkı yaptığı Şekil 3'te gösterilmiştir.



Şekil 3. Sınıflandırma sonuçlarına etki eden özelliklerin önemi

Sınıflandırmaya binaların çevre özelliđi diđer özelliklere göre açık ara en fazla katkısı gerçekteřirmiş. Çevre özelliđini sırayla: blok bina yoğunluđu, alan, blok bina sayısı ve blok alanı gibi özellikler takip etmiştir. En önemli ilk on özellik içinde dört adet mekânsal iliřki ve üç adet boyut özelliđi ve üç adet boyut özelliđi yer almıştır.

4. SONUÇ VE TARTIřMA

Bu çalışmada, farklı veri kaynaklarının birleřtirilmesi ve makine öğrenmesi yöntemlerinin kullanımıyla, şehir planlama uygulamaları için kritik öneme sahip binaların temel kullanım türlerine göre sınıflandırılması gerçekteřtirilmiştir. Geleneksel yöntemlerle tespiti zahmetli olan bu sınıflandırma süreci, çeřitli kaynaklardan elde edilen bina özelliklerinin yanı sıra, binaların boyut, şekil karmařıklıđı ve mekânsal iliřki gibi türlerine etki edebilecek ek özelliklerin hesaplanmasıyla zenginleřtirilmiştir. Sınıflandırma performansı, %68 F1-Skoru ile umut verici sonuçlar ortaya koymuştur; ancak pratik uygulamalar için iyileřtirilmesi gereken noktalar mevcuttur.

Referans verisi olarak kullanılan belediye verilerinin sahadaki gerçekte büyük oranda yansıttıđı düşünülse de bu verilerin doğrudan bina türlerini içermemesi sonuca etki etmiş ve bu etkinin istatistiksel anlamlılıđına dair kesin bir kanıya varılmasını engellemiştir. Bu durum, çalışmanın en belirgin zayıflıklarından birini oluřturmaktadır ve gelecekteki arařtırmalarda daha doğrudan ve detaylı referans verilerinin kullanılması gerekliliđini göstermektedir.

Makine öğrenmesi algoritmalarının temel zayıflıklarından biri olan geniş ve çeřitli eğitim verisine duyulan ihtiyaç, bu çalışmada da önemli bir faktör olarak ortaya çıkmıştır. Elde edilen verilerin %80'i eğitim için kullanılmış olup, modelin farklı cođrafî bölgelerdeki performansı belirsizliđini korumaktadır. Farklı bölgelerde benzer doğrulukta sınıflandırma yapabilmek için, o bölgelere ait temsil edici ve yeterli miktarda eğitim verisinin modele dahil edilmesi gerekebilir. Bu durum, modelin genelleřtirilebilirliđi konusunda sınırlamalar getirmekte ve makine öğrenmesi algoritmalarının genel bir sorunu olarak dikkat çekmektedir.

Modelde kullanılan 31 özellik arasında, bazı özelliklerin sınıflandırma performansına diđerlerine kıyasla daha az katkı sađladığı tespit edilmiştir. Buna ek olarak, özellikler arasında yüksek korelasyonun bulunması, modelin etkinliđini olumsuz yönde etkileyebilmekte ve bu durum modele aşırı öğrenme riski getirebilmektedir. Gelecek çalışmalarda, model performansını artırmak amacıyla düşük katkı sađlayan ve yüksek oranda korelasyon gösteren özelliklerin, detaylı istatistiksel analizler ile tespit edilip modelden çıkarılması hedeflenebilir. Özellikle bu süreçte, öz nitelik seçimi yöntemlerinin (örneğin, Lasso, Ridge gibi düzenleřtirme teknikleri) kullanılması önerilmektedir. Bu tür yöntemler, modelin genel performansını iyileřtirebilir ve aşırı uyum riskini azaltabilir.

Özelliklerin sınıflandırma doğruluđuna katkılarına bakıldıđında, binaların boyutları ve mekânsal iliřkilerinin model performansına en önemli katkıyı sađladığı gözlemlenmiştir. Bölgesel varyasyonlar bulunsada çalışma alanında bina kullanım türlerinin özellikle bina boyutlarıyla güçlü bir iliřkiye sahip olduđu sonucuna varılmıştır. Gelecek çalışmalarda, bu tür mekânsal parametrelerin bölgesel farklılıklarının incelenmesi ve modele bölgesel uyarlamalar yapılması, genel doğruluđu daha da artırabilir.

Çalışma temel olarak iki sınıf üzerinden gerçekteřtirilmiş olsa da sınıf sayılarının artırılması potansiyel bir geliştirme alanı olarak öne çıkmaktadır. Ancak bu durumda, yeni sınıfları istatistiksel olarak anlamlı bir şekilde temsil edecek yeterli ve kaliteli eğitim verisinin temin edilmesi kritik önem taşımaktadır. Eğitim verisinin yetersizliđi veya dengesiz dađılımı, modelin genel performansını ve genelleřtirilebilirliđini olumsuz etkileyebilir.

Sonuç olarak, bu çalışma, şehir planlama uygulamaları için binaların temel kullanım türlerine göre sınıflandırılmasında makine öğrenmesi yöntemlerinin uygulanabilirliđini ve potansiyelini ortaya koymuştur. Elde edilen sonuçlar umut verici olmakla birlikte, veri kalitesi, eğitim verisinin çeřitliliđi ve modelin genelleřtirilebilirliđi konularında daha derinlemesine arařtırmalara ihtiyaç duyulmaktadır. Gelecekteki çalışmalarda, daha kapsamlı ve nitelikli veri setlerinin kullanılması, özellik seçiminin optimize edilmesi ve model parametrelerinin hassas bir şekilde ayarlanmasıyla sınıflandırma doğruluđunun artırılması hedeflenmelidir.

KAYNAKLAR

- Basaraner, M., & Cetinkaya, S.,** 2017. Performance of shape indices and classification schemes for characterising perceptual shape complexity of building footprints in GIS. *International Journal of Geographical Information Science*, 31(10), 1952–1977. <https://doi.org/10.1080/13658816.2017.1346257>
- Birleşmiş Milletler,** 2018. Dünya Kentleşme Beklentileri: 2018 Revizyonu. Ekonomik ve Sosyal İşler Departmanı, Nüfus Bölümü. <https://population.un.org/Wup/Publications/Files/WUP2018-KeyFacts.pdf>. [Erişim Tarihi: 12.03.2023].
- Bondarenko, M., Kerr, D., Sorichetta, A., Tatem, A.,** 2020 Census/projection-disaggregated gridded population datasets, adjusted to match the corresponding UNPD 2020 estimates, for 183 countries in 2020 using Built-Settlement Growth Model (BSGM) outputs . University of Southampton. <https://eprints.soton.ac.uk/444005/>
- Branco, P., Torgo, L., & Ribeiro, R. P.,** 2016. A survey of predictive modeling on imbalanced domains. *ACM computing surveys (CSUR)*, 49(2), 1-50.
- Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., ... & Amodei, D.,** 2020. Language models are few-shot learners. *Advances in Neural Information Processing Systems*, 33, 1877–1901.
- Esch, T., Brzoska, E., Dech, S., Leutner, B., Palacios-Lopez, D., Metz-Marconcini, A., ... & Zeidler, J.,** 2022. World Settlement Footprint 3D-A first three-dimensional survey of the global building stock. *Remote sensing of environment*, 270, 112877.
- Fleischmann, M.,** 2019. Momepy: Urban morphology measuring toolkit. *Journal of Open Source Software*, 4(43), 1807.
- Galar, M., Fernandez, A., Barrenechea, E., Bustince, H., & Herrera, F.,** 2011. A review on ensembles for the class imbalance problem: Bagging-, boosting-, and hybrid-based approaches. *IEEE Transactions on Systems, Man, and Cybernetics - Part C: Applications and Reviews*, 42(4), 463–484.
- Glaeser, E. L.,** 2011. *Triumph of the city: How our greatest invention makes us richer, smarter, greener, healthier, and happier*. Penguin Press.
- Goodfellow, I., Bengio, Y., & Courville, A.,** 2016. *Deep learning*. MIT Press.
- HeiGIT,** 2024. Heidelberg Institute for Geoinformation Technology. <https://heigit.org/>
- Memduhoglu, A., & Basaraner, M.,** 2024. Semantic enrichment of building functions through geospatial data integration and ontological inference. *Environment and Planning B: Urban Analytics and City Science*, 51(4), 923-938.
- Memduhoğlu, A., Fulman, N., & Zipf, A.,** 2024. Enriching building function classification using large language model embeddings of OpenStreetMap tags. *Earth Science Informatics*. <https://doi.org/10.1007/s12145-024-01463-8>
- Ohsome API,** 2024. OpenStreetMap history data analytics platform. <https://ohsome.org/>
- Platt, R. H.,** 2014. *Land use and society: Geography, law, and public policy* (3rd ed.). Island Press.