

İç mekân harita yapımı için makine öğrenmesiyle nokta bulutlarının sınıflandırılması

Sena Varbil^{1*}, Alper Şen¹

¹Yıldız Teknik Üniversitesi, Davutpaşa Kampüsü, İnşaat Fakültesi, Harita Mühendisliği Bölümü, Esenler, İstanbul.

Öz: İç mekânlara ait 3-Boyutlu nokta bulutu sınıflandırması, iç mekân harita yapımı, iç mekân navigasyonu, bina yenileme, tesis yönetimi vb. uygulamalarda iç mekân modellerinin oluşturulmasında büyük önem taşımaktadır. Bu çalışmada, Stanford Üniversitesi tarafından üretilen S3DIS (Stanford 3D Indoor Scene) veri setinde bulunan ofis odalarına ait nokta bulutları makine öğrenmesi yöntemlerinden Rasgele Orman (RO) ve Çok Katmanlı Algılayıcı (ÇKA) ile sınıflandırılarak iç mekân haritaları oluşturulmuştur. Giriş verileri için X, Y, Z ve R, G, B öznitelik bilgileri kullanılmıştır. Sınıflar tavan, zemin, duvar, kapı, pencere, kolon, masa, sandalye, pano, dağınıklık ve kitaplık nesnelerini kapsamaktadır. Eğitim ve test verilerinde iç mekân haritalarının oluşturulması amacıyla duvar, kapı, pencere, kolon, pano ve kitaplık bir sınıf (birleştirilmiş sınıf-1); masa, sandalye ve dağınıklık bir sınıf (birleştirilmiş sınıf-2) halinde birleştirilmiştir. Eğitim verisi için bir ofis kullanılmış ve beş ayrı ofiste test edilmiştir. RO yöntemiyle ortalama %88, ÇKA yöntemiyle ortalama %85 sınıflandırma doğruluğu elde edilmiştir. Böylece özellikle yüksek doğrulukla sınıflandırılan tavan ve birleştirilmiş sınıf-1 nesnelere sayesinde iç mekân haritaları da yüksek doğrulukla elde edilmiştir.

Anahtar Sözcükler: İç mekân, Nokta bulutu, Sınıflandırma, Makine öğrenmesi, Rasgele Orman, Çok Katmanlı Algılayıcı

Classification of indoor point clouds using machine learning for indoor mapping

Abstract: 3-Dimensional point cloud classification of interior spaces is of great importance in the creation of interior models in applications such as indoor mapping, indoor navigation, building renovation, facility management, etc. In this study, point clouds of office rooms in the S3DIS (Stanford 3D Indoor Scene) dataset produced by Stanford University were classified with Random Forest (RF) and Multilayer Perceptron (MLP) machine learning methods, and indoor maps were created. For input data, attributes X, Y, Z and R, G, B were used. The classes include ceiling, floor, wall, door, window, column, table, chair, board, clutter, and bookcase objects. To create indoor maps in the training and test data, the classes were merged as follows: wall, door, window, column, board, and bookcase were merged into one class (merged class-1), and table, chair, and clutter were merged into another class (merged class-2). An office was used for the training data and tested in five different offices. The RF method achieved an average classification accuracy of 88%, and the MLP method achieved an average accuracy of 85%. Thus, indoor maps were obtained with high accuracy, especially thanks to the ceiling and merged class-1, which were classified with high accuracy.

Keywords: Indoor, Point cloud, Classification, Machine learning, Random Forest, Multi-Layer Perceptron

1. Giriş

Son yıllarda lazer tarayıcıların ve dijital görüntülerin hızla gelişmesiyle birlikte, mekânsal 3-Boyutlu (3B) nokta bulutu verileri birçok alanda yaygın olarak kullanılmaya başlanmıştır (Hsieh & Ruan, 2023). İç mekân ortamlarıyla ilişkili 3B mekânsal bilgi risk ve afet yönetimi, insan hareket yollarının belirlenmesi ve tesis yönetimi gibi çeşitli uygulamalarda giderek daha fazla talep görmektedir (Gunduz vd., 2016). Dış mekâna ait nokta bulutlarının sınıflandırılmasında önemli ilerlemeler kaydedilmiştir. Ancak iç mekân sahnelerinin dar bir çevreye, çeşitli yapısal özelliklere ve kolon, duvar vb. birçok engelleme sahip olması nedeniyle sınıflandırılması hâlâ bir sorundur (Wu vd., 2020). Bu nedenle, iç mekânların doğru ve güncel durumunu yansıtan üç boyutlu modellere ve güncel mekânsal verilere olan ihtiyaç giderek artmaktadır. İç mekân modelleme, çeşitli araç ve teknolojilerle desteklenen bir süreçtir; iç mekânların fiziksel ve işlevsel özellikleri dijital olarak temsil edilir ve yönetilir. İç mekân haritaları iç mekân ölçümlerinin sonucu olarak modelleme ile temsil, birçok iç odaklı uygulamanın temelini oluşturur (Deng vd., 2022). İç mekân ortamlarının 3B modelleri, yeniden tasarımdan izleme ve simülasyona kadar bir dizi farklı uygulama alanında kullanılabilirler için giderek daha fazla önem kazanmaktadır. Görüntülerden veya nokta bulutlarından otomatik olarak 3B iç mekânların yeniden oluşturulması süreci daha kolay, hızlı ve ekonomik hale getirmektedir (Díaz-Vilariño vd., 2015). Nokta bulutu elde edildikten sonra, genellikle içerdiği yararlı bilgilerin anlaşılması için sınıflandırılması gereklidir. Bu nedenle nokta bulutu bölütleme teknolojisi birçok uygulama için büyük önem taşır (Hsieh & Ruan, 2023). Nokta bulutu semantik bölütlemesi, nokta kümesindeki her noktayı sınıflandırmayı hedefler. Semantik bölütleme otonom navigasyon, sanal gerçeklik, robot nesne etiketleme ve yüksek kaliteli iç mekân haritalama gibi birçok gerçek dünya uygulamasına büyük ölçüde fayda sağlar (Lin vd., 2021). Nokta bulutu için geleneksel bölütleme yöntemleri birçok araştırmacının çalışmalarıyla sürekli olarak geliştirilmiştir. Bununla birlikte, geleneksel nokta bulutu bölütleme yöntemleri, manuel olarak etiketleme yoluyla tasarımcıların deneysel bilgiye sahip olmasını gerektirmektedir. Nokta bulutu bölütlemesinde kullanılması gereken bir dizi eşik değeri bulunur ve bu yöntemler genellikle karmaşık olduğundan, yalnızca belirli görevler için uygunken genel olarak performansları zayıf kalmaktadır (Zhao vd., 2020).

İç mekân konumlandırma için birçok teknik mevcut olsa da iç mekân konum bilgisini ölçümlerden çıkarabilen sınırlı sayıda algoritma ve yöntem bulunmaktadır. Üç boyutlu mekânsal veri edinimi, şehir ve bina modelleme alanında bilimsel ve teknolojik olarak hızla ilerlemektedir. Bu ilerlemeler, iç mekân modelleme ve harita yapımı için daha gelişmiş donanım, yazılım, standartlar, teknikler ve uygulamaların ortaya çıkmasını sağlamaktadır. Sensörler, iç mekân bilgisi ediniminde anahtar bir rol oynamaktadır (Gunduz vd., 2016). İç mekân nokta bulutu veri toplama sistemleri, fiziksel yapılarına göre el tipi, sırt çantası ve el arabası gibi sınıflara ayrılabilir. Araba konfigürasyonu, geniş bir sensör seçimi ve ağırlık esnekliği sunarak daha güçlü sensörlere erişim sağlar. Bu durum, daha güçlü sensörlerle daha yoğun nokta bulutu verisi sağlayabilir. Ancak, daha güçlü sensörlerin kullanımı araç maliyetini artırabilir ve manevra kabiliyetini azaltabilir. Özellikle dar alanlarda veya sınırlı alanlarda (merdivenler veya dar koridorlar gibi) fiziksel kısıtlamalarla karşılaşılabilir. Öte yandan, elde taşınabilir cihazlar daha fazla manevra kabiliyetine sahiptir ve satın alırken daha fazla esneklik sağlayabilirler. Ancak, bu cihazların sınırlı ağırlık taşıma kapasitesi ve pil ömrü, harita yapımı sensörünün özelliklerini ve tamamlayıcı sensörlerin kullanımını kısıtlayabilir. Bu durum, belirli özelliklerin entegrasyonunda ve ek sensörlerin kullanımında bazı sınırlamalara yol açabilir. Veri işleme ve sensör senkronizasyonunda temel unsur, genellikle LiDAR veya RGB-D kamerası gibi donanımları içinde barındıran harita yapımı sensörüdür (Otero vd., 2020). Böylece 3B tarayıcılar büyük miktarda veriyi yakalayarak yapay zeka destekli makinelerin dünyayı daha doğru algılamasını ve tanımasını sağlamaktadır (Shan vd., 2023).

Kartografik harita yapımının başlıca odak noktasının mekânsal bilginin etkin bir şekilde aktarımını geliştirmek olduğu düşünüldüğünde, nokta bulutları ve örgülü (meshed) modeller genellikle harita olarak kabul edilmezken, mimari CAD çizimleri ve Yapı Bilgi Modellemesi (Building Information Modeling, BIM) ise ilkel haritalar olarak düşünülebilir. İç mekân

ortamlara ait kartografik özellikler taşıyan haritalarının yapımı, iç mekânları modelleyen diğer disiplinlerle hem örtüşmekte hem de onlardan ayrılmakta ve iç mekân temsiline nispeten keşfedilmemiş bir alanı temsil etmektedir. Bu bağlamda, nokta bulutlarının bölütlenmesi sonucunda elde edilen nesne sınıfları kullanılarak kartografik haritaların yapımı önemli bir araştırma konusudur (Chen & Clarke, 2020). İç mekânlarda insanlar için haritaların oluşturulması, özellikle büyük ve karmaşık yapılar için oldukça önemlidir. Bu tür haritalar, ziyaretçilere veya çalışanlara mekân içindeki konumlarını belirleme ve istedikleri hedefe yönlendirme konusunda yardımcı olabilir. İç mekânın güncel durumunu yansıtan nokta bulutlarının yüksek doğruluklu nesne sınıflarını sağlayacak biçimde bölütlenmesi ile iç mekâna ait haritalarının oluşturulması ve bu haritalardan iç mekân navigasyon ağ modellerinin otomatik olarak üretimi iç mekân navigasyonu sistemlerinin önemli bileşenleri arasında yer alır (Bilgili vd., 2022).


Armeni vd. (2016) tarafından büyük ölçekli ve renkli S3DIS (Stanford 3D Indoor Scene) iç mekân veri seti üretilmiş ve hiyerarşik bir yaklaşım kullanılarak tüm bir binanın 3B nokta bulutunun anlamsal ayrıştırılması için bir yöntem önerilmiştir. Çalışmada önce noktalar arasındaki boşluk örüntülerini temel alan bir algoritma ile yatay ve düşey eksenler kullanılarak nokta bulutu yatay ve düşey alanlara bölütlenmiştir. Aşırı bölütlenmiş alanlar, topolojik düğüm noktaları arasındaki ilişkiler kullanılarak birleştirilmiştir. Böylece ana ayırıcı niteliğinde olan binaya ait duvar noktaları sınıflandırılmıştır. Diğer nesnelere, belli bir koordinat sistemine getirilen bölütlenmiş alanlarda 3B kutular gezdirilerek sınıflandırılmıştır. Bu yöntem ile tahmin edilen sınıf etiketleri, uzmanlarca manuel olarak sınıflandırılarak üretilen referans (ground truth) etiketleri ile karşılaştırıldığında tavan ve zemin sınıfı için sırasıyla %71.61 ve %88.70 doğruluk; duvar, kolon ve pencere gibi temel bina elemanlarına ait sınıflar için ise %67.38 genel doğruluk elde edilmiştir. Poux vd. (2020) tarafından, 3B iç mekân nokta bulutlarını etkili bir şekilde kümelenmesi için denetimsiz bir bölge büyüme bölütlemesi yaklaşımı sunulmuştur, optimal parametreleri tanımlamak için öğrenme tabanlı sezgisel bir süreç önerilmiş ve S3DIS veri seti üzerinde test edilmiştir. Nesne tabanlı sınıflandırma için ortalama %88.10 F1 doğruluk elde edilmiştir. Chen vd. (2021) tarafından, dikkat modülü ile halka gruplama sinir ağı adlı yeni bir ağ mimarisi önerilmiştir. Önerilen ağ mimarisinin performansı S3DIS, ScanNet ve NYU-V2 gibi veri kümeleri üzerinde değerlendirilmiş ve S3DIS veri setinde en iyi genel doğruluk ve ortalama kesişim (mean intersection-over-union, mIoU) değerleri elde edilmiştir. Çalışma sonucunda genel doğruluk %87.05 olarak elde edilmiştir. Su vd. (2022) tarafından, çok ölçekli seyrek evrişime dayalı çok ölçekli bir öznetelik birleştirme modülü ve kanal dikkat mekanizmasına dayalı bir kanal öznetelik filtreleme modülü önerilmiştir. S3DIS veri seti üzerinde yapılan çalışmada önerilen yöntem ile %74.90 ile en yüksek doğruluk metriği elde edilmiştir. Hsieh ve Ruan (2023) tarafından, iç mekân nokta bulutlarında sütun, giriş, duvar, zemin ve tavan noktalarını otomatik olarak bölütlemek için dinamik grafik evrişimli sinir ağı kullanılmıştır. S3DIS iç mekân veri setinin kullanıldığı çalışmada %86.90 doğruluk elde edilmiştir.

Bu çalışmada, Stanford Üniversitesi tarafından üretilen S3DIS veri setinde bulunan bazı ofis odalarına ait nokta bulutlarının makine öğrenmesi yöntemlerinden Rasgele Orman (RO) ve Çok Katmanlı Algılayıcı (ÇKA) ile sınıflandırılarak iç mekân haritalarının oluşturulması amaçlanmaktadır. Veri setindeki her sınıf için kesinlik, duyarlılık, F1 skor ve doğruluk değerleri hesaplanmıştır. Uygulamadaki tüm işlemler ve sınıflandırma aşamaları Python programlama diline ait Scikit-learn kütüphanesi kullanılarak, görselleştirmeler ise Cloud Compare ve ArcGIS Pro yazılımları ile yapılmıştır. RO yöntemiyle ortalama %88, ÇKA yöntemiyle ortalama %85 sınıflandırma doğruluğu elde edilmiştir. Böylece özellikle yüksek doğrulukla sınıflandırılan tavan ve birleştirilmiş sınıf-1 kesişimleri sayesinde iç mekân haritaları da yüksek doğrulukla elde edilmiştir.

2. Metodoloji

Bu çalışmaya ait iş akışı, verinin düzenlenmesi, sınıfların birleştirilmesi, normalizasyon, RO ve ÇKA ağ modellerinin oluşturulması, model parametrelerinin belirlenmesi, bir ofis için eğitim (%70) ve test (%30) setlerinin belirlenmesi ile model

eğitiminin gerçekleştirilmesi, beş farklı ofise ait nokta bulutu sınıflandırmasının doğruluk metrikleri ile değerlendirilmesi adımlarından oluşmaktadır. Şekil 1’de çalışmaya ait akış diyagramı verilmiştir.



Şekil 1: İç mekân nokta bulutu verisinin makine öğrenmesi yöntemleriyle sınıflandırılması iş akış şeması

2.1 Min-Max Normalizasyonu

Min-max normalizasyon tekniği, değişkenlere ait ortalama ve varyans değerleri birbirinden anlamlı derecede farklı olduğu durumlarda kullanılır ve orijinal veri seti üzerinde doğrusal bir dönüşüm gerçekleştirir (Kiran & Vasumathi, 2020). Bu çalışmada, X, Y, Z, R, G, B değerleri min - max normalizasyonu kullanılarak normalize edilmiştir. Min-max normalizasyonu Eşitlik 1’de gösterilmiştir.

$$X'_i = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (1)$$

Burada X'_i normalizasyon değerini, X_i öznelik değerini, X_{min} en küçük öznelik değerini, X_{max} en büyük öznelik değerini ifade etmektedir.

2.2 Kullanılan Makine Öğrenmesi Yöntemleri

2.2.1 Rastgele Orman (RO) Yöntemi

Rastgele Orman (RO), ilk olarak Breiman (2001) tarafından bulunmuştur. Rastgele Orman, birçok karar ağacını belirli bir kombinasyon kullanarak bir araya getiren topluluk öğrenme yöntemidir. (Sun vd., 2024). Her ağaç, etiketlenmemiş bir örneğin sınıfını belirlemek için temel sınıflandırıcı işlevini yerine getirir. Bu süreçte, her sınıflandırıcı, tahmini sınıf etiketi için oy kullanır ve ardından en yüksek oyu alan sınıf etiketi, örneğin sınıflandırılmasında kullanılır (Fawagreh vd., 2014).

Yeni bir x örneğinde tahmin yapmak için; B rastgele orman ağaç sayısı, $C_b(x)$ b 'inci rastgele orman ağacının tahmini olduğunda aşağıdaki eşitlik elde edilir (Hastie vd., 2009):

$$C_{ro}^B(x) = \text{çoğunluk oyu}\{C_b(x)\}_1^B \quad (2)$$

2.2.2 Çok Katmanlı Algılayıcı (ÇKA) Yöntemi

Çok Katmanlı Algılayıcı (ÇKA), bilginin giriş katmanından çıkış katmanına, gizli katmanlardan geçerek tek yönlü olarak aktığı, katmanlı ileri beslemeli geri yayımlı bir sinir ağıdır (Bishop, 1995) ÇKA'nın giriş katmanında, veriler alınır ve ardından toplama fonksiyonu kullanılarak bir aktivasyon fonksiyonuna iletilir. Her katmanda bu aktivasyon fonksiyonları kullanılarak hesaplamalar yapılır ve çıkış bir sonraki katmana iletilir. Bu işlem, çıkış katmanına ulaşana kadar tekrarlanır. Çıkış katmanında hesaplanan hatalar geri yayılım algoritmaları ile ağırlıkların güncellenmesinde kullanılır ya da nihai karar verilir. ÇKA modelinin performansı eğitim verilerinin sayısına, değişken seçimine, gizli katman ve düğüm sayılarına, öğrenme ve momentum katsayıları ve iterasyon sayısı gibi eğitim parametrelerine bağlıdır. Öğrenme ve momentum

katsayıları, öğrenme sürecinin hızını ve etkinliğini kontrol eder (Taud & Mas, 2018). Çıktı hesaplama Eşitlik 2'de gösterilmiştir (Sen & Gumus, 2023).

$$I_j = \sum_i w_{ij} O_i + \theta_j \quad (3)$$

Burada, I_j j düğümünün çıktısını; w_{ij} i ve j düğümü arasındaki ağırlığı, O_i bir önceki katmandan gelen i düğümünün çıktısını ve θ_j j düğümünün eşik değerini ifade eder.

2.2.3 Model Değerlendirme Ölçütleri

Makine öğrenmesi modellerinin performansını değerlendirmek için kullanılan çeşitli metrikler bulunmaktadır. Bu çalışmada, model değerlendirmesi için eşitlik (4), (5), (6) ve (7)'de verilen doğruluk, duyarlılık, kesinlik ve F1 skoru metrikleri kullanılmıştır. Bu metrikler, modellerin başarılarını değerlendirmek ve karşılaştırmak için kullanılmaktadırlar.

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (4)$$

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (5)$$

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (6)$$

$$\text{F1 Skoru} = \frac{2 \times \text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (7)$$


Burada; doğru pozitif (DP) modelin doğru bir şekilde pozitif bir durumu tanımladığı durumu, doğru negatif (DN) doğru bir şekilde negatif bir durumu tanımladığı durumu, yanlış pozitif (YP) aslında negatif olan bir durumu pozitif olarak tanımladığı durumu, yanlış negatif (YN) ise modelin aslında pozitif olan bir durumu negatif olarak tanımladığı durumu temsil etmektedir.

3. Çalışma Alanı ve Veriler

Bu çalışmada S3DIS (Stanford 3D Indoor Scene Dataset) veri seti kullanılmıştır. Veri seti, her tarama konumunda, 360° dönüş sırasında farklı açılarda üç adet yapılandırılmış ışık sensörünü birleştirerek 18 RGB ve derinlik görüntüsü yakalayabilen Matterport Kamera ile oluşturulmuştur. Veri kümesi, her taranan alan için renkli nokta bulutları içermektedir. Çoğunlukla eğitim ve ofis kullanımına yönelik üç farklı binadan taranan altı büyük ölçekli iç mekân alanından toplanmıştır. Veri setinde toplam 70 496 düzenli RGB ve 1413 eş dikdörtgen RGB görüntüsü bulunur. Ayrıca veri kümesindeki tüm görüntüler 1080x1080 çözünürlükte depolanmıştır. Tüm veri setinde yapısal elemanlar (tavan, zemin, duvar, giriş, sütun, pencere ve kapı) ve yaygın olarak bulunan eşyalar ve mobilyalar (masa, sandalye, kanepe, kitaplık ve tahta) olmak üzere 12 sınıf bulunmaktadır (Armeni vd., 2016). Veri X, Y, Z, R, G, B ve uzmanlarca manuel olarak sınıflandırılarak üretilen referans (ground truth) etiketinden oluşmaktadır. Bu çalışmada makine öğrenme yöntemi ile sınıflandırmak üzere S3DIS veri setinde ofis kullanımına yönelik hazırlanmış veri setleri eğitim ve test verisi olarak ayrılmıştır. Ofis 1 verisi, %70'i eğitim %30'u test olarak ayrılmıştır. Bu oranların öğrenme performansı için uygun olduğu deneysel olarak gözlemlenmiştir. Buna ek olarak, beş ayrı ofis verisi üzerinde elde edilen test sonuçlarına göre modelin eğitimde aşırı uyum (overfitting) göstermediği de anlaşılmaktadır.

4. Uygulama ve Bulgular

Çalışma alanında tavan, zemin, duvar, kapı, pencere, kolon, masa, sandalye, pano, dağınıklık ve kitaplık olarak toplam 11 sınıf bulunmaktadır. Eğitim ve test verilerinde iç mekân haritalarının oluşturulması amacıyla duvar, kapı, pencere, kolon, pano ve kitaplık bir sınıf (birleştirilmiş sınıf-1); masa, sandalye ve dağınıklık bir sınıf (birleştirilmiş sınıf-2) olacak şekilde sınıflar Python programlama dilinde kod yazılarak birleştirilmiştir. Tavan için 0, zemin için 1, birleştirilmiş sınıf-1 için 2, birleştirilmiş sınıf-2 için ise 3 etiketi verilmiştir. Nokta bulutlarına ait sınıflar işaret anahtarındaki (lejanttaki) renklerle Şekil 2’de gösterilmiştir.



Şekil 2: Nokta bulutlarına ait 11 adet sınıf: (a) Ofis 1, (b) Ofis 2, (c) Ofis 3, (d) Ofis 4, (e) Ofis 5, (f) Ofis 6

Sonrasında öz niteliklere (X, Y, Z, R, G, B) min-max normalizasyonu yapılmıştır. Daha sonra RO ve ÇKA yöntemine göre model parametreleri Python dilinde döngüler yardımıyla (parametre değişkenlerini içeren) liste yapısı kullanılarak deneysel olarak sınanmıştır ve en iyi parametreler seçilmiştir. Ofis 2 için sınıflandırma sonuçları Tablo 1’de, Ofis 3 için sınıflandırma sonuçları Tablo 2’de, Ofis 4 için sınıflandırma sonuçları Tablo 3’te, Ofis 5 için sınıflandırma sonuçları Tablo 4’te ve Ofis 6 için sınıflandırma sonuçları Tablo 5’te gösterilmiştir.

Tablo 1: Ofis 2 verisi için sınıflandırma sonuçları

Sınıf	Kesinlik		Duyarlılık		F1 Skor	
	RO	ÇKA	RO	ÇKA	RO	ÇKA
0	0.98	0.96	0.99	0.99	0.99	0.97
1	1.00	1.00	0.58	0.49	0.73	0.66
2	0.89	0.90	0.89	0.83	0.89	0.86
3	0.42	0.39	0.60	0.72	0.49	0.50

Doğruluk: 0.83 (RO), 0.80 (ÇKA)

Ofis 2 için RO yöntemiyle %83, ÇKA yöntemi ile %80 genel doğruluk elde edilmiştir. Tavan (0 etiketi) RO yöntemiyle %99, ÇKA yöntemiyle %97; zemin (1 etiketi) RO yöntemiyle %73, ÇKA yöntemiyle %66; birleştirilmiş sınıf-1 (2 etiketi) RO yöntemiyle %89, ÇKA yöntemiyle %86; birleştirilmiş sınıf-2 (3 etiketi) RO yöntemiyle %49, ÇKA yöntemiyle %50 F1 doğruluğu elde edilmiştir. Tavan, zemin ve birleştirilmiş sınıf-1 için RO yöntemi; birleştirilmiş sınıf-2 için ise ÇKA yönteminin daha iyi sonuç verdiği görülmüştür.

Tablo 2: Ofis 3 verisi için sınıflandırma sonuçları

Sınıf	Kesinlik		Duyarlılık		F1 Skor	
	RO	ÇKA	RO	ÇKA	RO	ÇKA
0	0.99	0.98	0.99	0.93	0.99	0.96
1	0.97	0.98	1.00	1.00	0.99	0.99
2	0.88	0.86	0.96	0.89	0.92	0.88
3	0.87	0.69	0.64	0.63	0.74	0.66

Doğruluk: 0.91 (RO), 0.87 (ÇKA)

Ofis 3 için RO yöntemiyle %91, ÇKA yöntemi ile %87 genel doğruluk elde edilmiştir. Tavan (0 etiketi) RO yöntemiyle %99, ÇKA yöntemiyle %96; zemin (1 etiketi) RO yöntemiyle %99, ÇKA yöntemiyle %99; birleştirilmiş sınıf-1 (2 etiketi) RO yöntemiyle %92, ÇKA yöntemiyle %88; birleştirilmiş sınıf-2 (3 etiketi) RO yöntemiyle %74, ÇKA yöntemiyle %66 F1 doğruluğu elde edilmiştir. Tavan, birleştirilmiş sınıf-1 ve birleştirilmiş sınıf-2 için RO yöntemi daha iyi sonuç vermiş; zemin için ise iki yöntemin aynı sonucu verdiği görülmüştür.

Tablo 3: Ofis 4 verisi için sınıflandırma sonuçları

Sınıf	Kesinlik		Duyarlılık		F1 Skor	
	RO	ÇKA	RO	ÇKA	RO	ÇKA
0	0.98	0.96	0.98	0.99	0.98	0.97
1	0.97	0.98	0.99	0.99	0.98	0.98
2	0.95	0.95	0.87	0.82	0.91	0.88
3	0.54	0.46	0.77	0.77	0.63	0.58

Doğruluk: 0.90 (RO), 0.87 (ÇKA)

Ofis 4 için RO yöntemiyle %90, ÇKA yöntemi ile %87 genel doğruluk elde edilmiştir. Tavan (0 etiketi) RO yöntemiyle %98, ÇKA yöntemiyle %97; zemin (1 etiketi) RO yöntemiyle %98, ÇKA yöntemiyle %98; birleştirilmiş sınıf-1 (2 etiketi) RO yöntemiyle %91, ÇKA yöntemiyle %88; birleştirilmiş sınıf-2 (3 etiketi) RO yöntemiyle %63, ÇKA yöntemiyle %58 F1 doğruluğu elde edilmiştir. Tavan, birleştirilmiş sınıf-1 ve birleştirilmiş sınıf-2 için RO yöntemi daha iyi sonuç vermiş; zemin için ise iki yöntemin aynı sonucu verdiği görülmüştür.

Tablo 4: Ofis 5 verisi için sınıflandırma sonuçları

Sınıf	Kesinlik		Duyarlılık		F1 Skor	
	RO	ÇKA	RO	ÇKA	RO	ÇKA
0	0.97	0.95	0.98	0.94	0.97	0.95
1	0.96	0.96	0.99	1.00	0.97	0.98
2	0.95	0.94	0.88	0.85	0.91	0.90
3	0.52	0.49	0.70	0.74	0.59	0.59

Doğruluk: 0.90 (RO), 0.88 (ÇKA)

Ofis 5 için RO yöntemiyle %90, ÇKA yöntemi ile %88 genel doğruluk elde edilmiştir. Tavan (0 etiketi) RO yöntemiyle %97, ÇKA yöntemiyle %95; zemin (1 etiketi) RO yöntemiyle %97, ÇKA yöntemiyle %98; birleştirilmiş sınıf-1 (2 etiketi) RO yöntemiyle %91, ÇKA yöntemiyle %90; birleştirilmiş sınıf-2 (3 etiketi) RO yöntemiyle %59, ÇKA yöntemiyle %59 F1 doğruluğu elde edilmiştir. Tavan ve birleştirilmiş sınıf-1 için RO yöntemi daha iyi sonuç vermiş, zemin için ÇKA yöntemi, birleştirilmiş sınıf-2 için ise iki yöntemin aynı sonucu verdiği görülmüştür.


Tablo 5: Ofis 6 verisi için sınıflandırma sonuçları

Sınıf	Kesinlik		Duyarlılık		F1 Skor	
	RO	ÇKA	RO	ÇKA	RO	ÇKA
0	0.97	0.96	0.98	1.00	0.98	0.98
1	0.99	0.99	0.94	0.92	0.97	0.96
2	0.91	0.92	0.86	0.82	0.88	0.86
3	0.55	0.51	0.67	0.73	0.61	0.66


Doğruluk: 0.87 (RO), 0.85 (ÇKA)

Ofis 6 için RO yöntemiyle %87, ÇKA yöntemi ile %85 genel doğruluk elde edilmiştir. Tavan (0 etiketi) RO yöntemiyle %98, ÇKA yöntemiyle %98; zemin (1 etiketi) RO yöntemiyle %97, ÇKA yöntemiyle %96; birleştirilmiş sınıf-1 (2 etiketi) RO yöntemiyle %88, ÇKA yöntemiyle %86; birleştirilmiş sınıf-2 (3 etiketi) RO yöntemiyle %61, ÇKA yöntemiyle %66 F1 doğruluğu elde edilmiştir. Zemin ve birleştirilmiş sınıf-1 için RO yöntemi; birleştirilmiş sınıf-2 için ÇKA yöntemi; tavan için ise iki yöntemin aynı sonucu verdiği görülmüştür.

Yapılan uygulama sonucunda en yüksek doğruluk RO yöntemi için %91 ile Ofis 3 verisi; ÇKA yöntemi için ise %88 ile Ofis 5 verisi olmuştur. Ofis 3 ve Ofis 5 verisi ile ilgili referans sınıfları, tahmin edilen sınıflar ve DP, DN, YP ve YN sınıfları işaret anahtarındaki (lejanttaki) renklerle Şekil 3 ve Şekil 4'te gösterilmiştir. Şekil 3 ve Şekil 4'te referans sınıflarının (Şekil 3a) tahmin edilen sınıflar (Şekil 3b) ile karşılaştırılması yoluyla doğru ve yanlış tahminlerin (Şekil-3c) incelenmesi sonucunda, tavan, zemin, duvar, kapı, pencere, kolon ve sandalye gibi sınıflarının yeterince doğru sınıflandırıldığı, ancak masa, pano, kitaplık ve dağınıklık gibi sınıflarda hatalı tahminlerin olduğu görülmektedir.



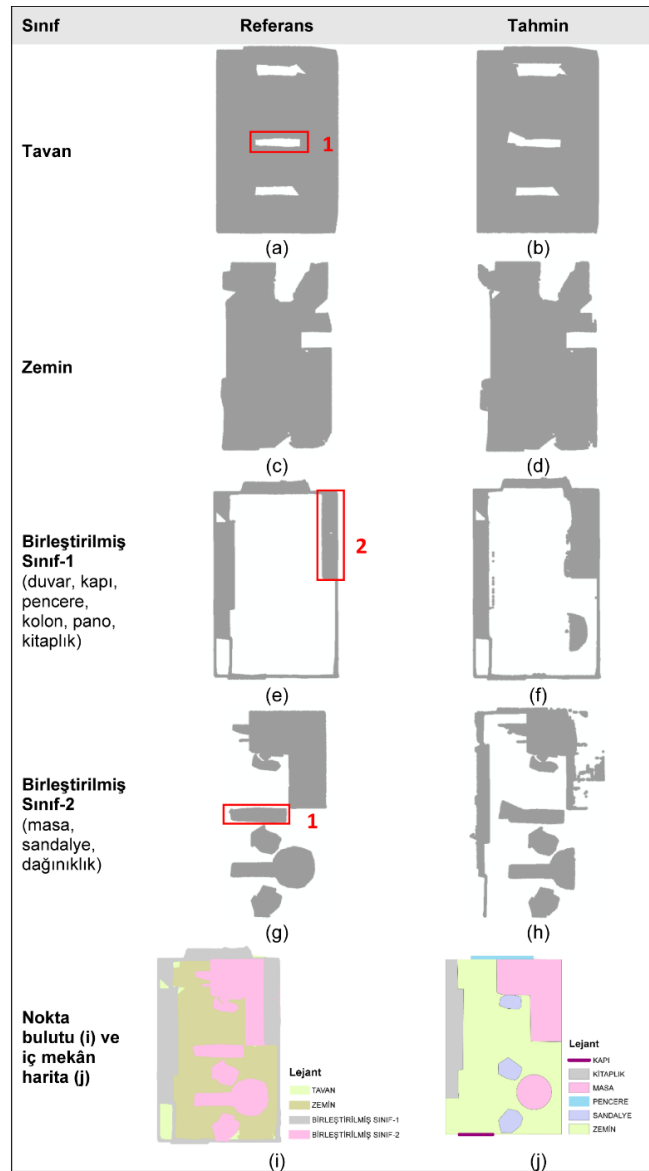
Şekil 3: Ofis 3 verisi üzerindeki RO'ya göre doğruluk sonuçları: (a) Referans sınıflar, (b) tahmin edilen sınıflar, (c) doğru sınıflandırma (DP ve DN) ve yanlış sınıflandırma (YP ve YN)



Şekil 4: Ofis 5 verisi üzerindeki ÇKA'ya göre doğruluk sonuçları: (a) Referans sınıflar, (b) tahmin edilen sınıflar, (c) doğru sınıflandırma (DP ve DN) ve yanlış sınıflandırma (YP ve YN)

Sınıflandırılan nokta bulutunun harita yapımına uygunluğu ArcGIS Pro yazılımı kullanılarak incelenmiştir. Noktaların dış sınırlarına uyan çokgenler Minimum Sınırlayıcı Geometri (Minimum Bounding Geometry) aracında bulunan dışbükey gövde (convex hull) ve daire gibi geometriler kullanılarak oluşturulmuş ve manuel olarak köşe noktaları düzeltilmiştir. RO yöntemi kullanılarak sınıflandırılan Ofis 5 nokta bulutuna ait referans veri sınıfları tavan, zemin, birleştirilmiş sınıf-1, birleştirilmiş

sınıf-2 ve tüm nokta bulutu Şekil 5 (a, c, e, g, i)'de verilmiştir. Tahmin edilen veri sınıflarına ait tavan, zemin, birleştirilmiş sınıf-1, birleştirilmiş sınıf-2 ve sonuç harita ise Şekil 5 (b, d, f, h, j)'de verilmiştir. Tavan noktalarında bulunan boşluğun sebebi dağınıklık sınıfına ait aydınlatma nesnesidir (Şekil 5'te 1 numaralı kırmızı çerçeve). Sonuçlar incelendiğinde referans (Şekil 5a ve 5c) ve sınıflandırılan (Şekil 5b ve Şekil 5d) tavan ve zemin nokta bulutlarının birbirine çok yakın olduğu görülmektedir. Zemin üzerinde yer alan nesnelere nedeniyle nokta verisinin zeminin tümünü kapsamadığı ve zeminde çeşitli boşluklara sahip olduğu görülmektedir. Bu nedenle zemin noktaları harita yapımı için uygun bir nesne sınıfı değildir. Şekil 5j'de gösterilen harita incelendiğinde, zemin (aynı zamanda iç duvar), kapı, pencere, masa, sehpa ve sandalyelerin çizilebildiği görülmektedir. Birleştirilmiş sınıf-1'de yer alan iki kitaplıktan biri çizilebilecek kadar sınıflandırılabilmiş, ancak Şekil 5e'de 2 numaralı kırmızı çerçeve içinde yer alan diğer kitaplık yeterince sınıflandırılmamıştır. Bunun nedeni, kitaplığın masa üzerinde yer alması ile karmaşık bir yapı göstermesidir. Bu yüzden bu nesne haritada çizilememiştir. Ayrıca masa sınıfındaki sehpa nesnesine ait nokta bulutunun yaklaşık yarısı, birleştirilmiş sınıf-2 (Şekil 5h) yerine yanlışlıkla birleştirilmiş sınıf-1'de sınıflandırılmıştır (Şekil 5f). Ancak yine de daire geometrisi ile çizilerek haritada gösterilebilmiştir (Şekil 5j). Sonuç olarak sınıflandırılan noktalar incelendiğinde hatalı sınıflandırma genellikle kitaplık ve masa nesnelerinde gerçekleşmiş, bu nesne sınıflarının çiziminde birtakım güçlükler yaşanmıştır.



Şekil 5: Ofis 5 için RO ile sınıflandırma sonucunda harita yapımı: (a, c, e, g, i) Referans nokta bulutu, (b, d, f, h) sınıflandırılan nokta bulutu ve (j) sonuç harita.

5. Sonuç ve Öneriler

Eğitim verisi için bir ofis kullanılmış ve beş ayrı ofiste test edilmiştir. RO yöntemiyle ortalama %88, ÇKA yöntemiyle ortalama %85 sınıflandırma doğruluğu elde edilmiştir. İç mekân nokta bulutu sınıflandırmasında RO yöntemi ÇKA yöntemine genelde üstünlük sağlamıştır. Her iki yöntem tavan, zemin ve birleştirilmiş sınıf-1 (duvar, kapı, pencere, kolon, pano ve kitaplık) sınıflarını etkili bir şekilde tahmin etmiştir. Ancak, birleştirilmiş sınıf-2'de bulunan masa, sandalye ve dağınıklık nesnelere tahmin etmekte her iki yöntem de yeterli olamamıştır. Yine de birleştirilmiş sınıf-2'de bulunan nesnelere için harita üzerinde çizim yapmaya yeterli olacak kadar doğru tahmin çoğunlukla yapılabilmektedir. İç mekân harita yapımı ve yaya navigasyonu için gerekli tüm sınıflar (tavan, zemin ve birleştirilmiş sınıf-1) yüksek doğrulukla sınıflandırılmıştır. Bu çalışma, makine öğrenimi kullanılarak iç mekân nokta bulutlarının sınıflandırma performansını harita yapımı için değerlendirmiştir. Böylece, RO ve ÇKA yöntemlerinin iç mekân nokta bulutlarının sınıflandırılmasında literatürde gösterilen yöntemlere göre yeterli doğruluk sağladığı (Armeni vd., 2017; Chen vd., 2021; Hsieh & Ruan, 2023; Poux vd., 2020; Su vd., 2022) ve tahmin edilen nesne sınıflarının iç mekân harita yapımında kullanılabildiği tespit edilmiştir. Gelecek çalışmalarda iç mekân nokta bulutlarının sınıflandırması için farklı makine öğrenimi yöntemlerinin performansı sınanabilir. Bu çalışmada iç mekân haritası yarı otomatik olarak yapılmış olup ileride Python gibi programlama dillerinin geometri kütüphaneleri kullanılarak tam otomatik olarak çizilmesi yoluyla iç mekân harita yapımının değerlendirilmesi araştırılabilir.

Yazar Katkısı

Sena Varbil: Literatür taraması, Veri işleme, Sınıflandırma uygulaması, Yazım. **Alper Şen:** Fikir, Literatür taraması, Denetleme, Veri toplama ve işleme, Analiz.

Çıkar Çatışması Beyanı

Yazarlar, bu çalışmada bilinen ilgili herhangi bir finansal veya finansal olmayan çıkar çatışması olmadığını beyan eder.

Kaynaklar

- Armeni, I., Sener, O., Zamir, A. R., Jiang, H., Brilakis, I., Fischer, M., & Savarese, S. (2016). 3d semantic parsing of large-scale indoor spaces. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1534-1543.
- Bilgili, A., Şen, A., & Başaraner, M. (2022). İç mekân navigasyonu ağ modelleri: Karşılaştırmalı bir inceleme. *Jeodezi ve Jeoinformasyon Dergisi*, 9(2), 108-126.
- Bishop, C. M. (1995). *Neural Networks for Pattern Recognition*. Oxford University Press.
- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.
- Chen, J., & Clarke, K. C. (2020). Indoor cartography. *Cartography and Geographic Information Science*, 47(2), 95-109.
- Chen, X. T., Li, Y., Fan, J. H., & Wang, R. (2021). RGAM: A novel network architecture for 3D point cloud semantic segmentation in indoor scenes. *Information Sciences*, 571, 87-103.
- Deng, Y., Ai, H., Deng, Z., Gao, W., & Shang, J. (2022). An overview of indoor positioning and mapping technology standards. *Standards*, 2(2), 157-183.
- Díaz-Vilariño, L., Khoshelham, K., Martínez-Sánchez, J., & Arias, P. (2015). 3D modeling of building indoor spaces and closed doors from imagery and point clouds. *Sensors*, 15(2), 3491-3512.
- Fawagreh, K., Gaber, M. M., & Elyan, E. (2014). Random forests: from early developments to recent advancements. *Systems Science & Control Engineering: An Open Access Journal*, 2(1), 602-609.
- Gunduz, M., Isikdag, U., & Basaraner, M. (2016). A review of recent research in indoor modelling & mapping. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 41, 289-294.

- Hastie, T., Tibshirani, R., Friedman, J. H., & Friedman, J. H. (2009). *The elements of statistical learning: data mining, inference, and prediction*. New York: Springer.
- Hsieh, C. S., & Ruan, X. J. (2023). Automated Semantic Segmentation of Indoor Point Clouds from Close-Range Images with Three-Dimensional Deep Learning. *Buildings*, 13(2), 468.
- Kiran, A., & Vasumathi, D. (2020). Data mining: min-max normalization based data perturbation technique for privacy preservation. *Proceedings of the Third International Conference on Computational Intelligence and Informatics: ICCII 2018*, 723-734, Singapore: Springer Singapore.
- Lin, H., Wu, S., Chen, Y., Li, W., Luo, Z., Guo, Y., Wang, C., & Li, J. (2021). Semantic segmentation of 3D indoor LiDAR point clouds through feature pyramid architecture search. *ISPRS Journal of Photogrammetry and Remote Sensing*, 177, 279-290.
- Otero, R., Lagüela, S., Garrido, I., & Arias, P. (2020). Mobile indoor mapping technologies: A review. *Automation in Construction*, 120, 103399.
- Poux, F., Mattes, C., & Kobbelt, L. (2020). Unsupervised segmentation of indoor 3D point cloud: Application to object-based classification. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 44, 111-118.
- Sen, A., & Gumus, K. (2023). Comparison of Different Parameters of Feedforward Backpropagation Neural Networks in DEM Height Estimation for Different Terrain Types and Point Distributions. *Systems*, 11(5), 261.
- Shan, D., Zhang, Y., Wang, X., Luo, W., Meng, X., Liu, Y., & Gao, X. (2023). An Efficient Point Cloud Semantic Segmentation Method Based on Bilateral Enhancement and Random Sampling. *Electronics*, 12(24), 4927.
- Su, Y., Jiang, L., & Cao, J. (2022). Point Cloud Semantic Segmentation using Multi Scale Sparse Convolution Neural Network. *arXiv:2205.01550*.
- Sun, Z., Wang, G., Li, P., Wang, H., Zhang, M., & Liang, X. (2024). An improved random forest based on the classification accuracy and correlation measurement of decision trees. *Expert Systems with Applications*, 237, 121549.
- Taud, H., & Mas, J. F. (2018). Multilayer perceptron (MLP). *Geomatic approaches for modeling land change scenarios*, 451-455.
- Wu, H., Yang, H., Huang, S., Zeng, D., Liu, C., Zhang, H., Guo, C., & Chen, L. (2020). Classification of point clouds for indoor components using few labeled samples. *Remote Sensing*, 12(14), 2181.
- Zhao, J., Zhang, X., & Wang, Y. (2020). Indoor 3D point clouds semantic segmentation bases on modified pointnet network. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43, 369-373.