

Derin Öğrenme Tekniği ile Sınıflandırılan Hava LiDAR Nokta Bulutlarında Geometrik Özelliklerin Etkisi

(Effects of the Geometric Features on Deep Learning Based Classification of LiDAR Point Cloud Data)

Fırat URAY

Necmettin Erbakan Üniversitesi, Harita Mühendisliği Bölümü, 42090, Konya
furay@erbakan.edu.tr

Geliş Tarihi (Received): 14.06.2023

Kabul Tarihi (Accepted): 30.01.2024

ÖZ

Hava Lidar nokta bulutu verilerinin sınıflandırılması halen araştırmacıların ilgilendiği popüler konularının başında gelmektedir. Sınıflandırma işlemi, nokta bulutu verisinde her bir noktaya ait olduğu ögenin etiketinin verilmesi ile anlamlı kategorilere ayrılması olarak tanımlanabilir. Lidar nokta bulutundan anlamlı ve doğru veri çıkarımı yer bilimleri ve diğer bilim dalları için büyük önem arz etmektedir. Devasa boyutlara ulaşan nokta bulutu verisini işlemek ve yüksek doğrulukta sınıflara ayırmak bu açıdan önemlidir. Bu çalışmada, derin öğrenme tekniklerinin temelini oluşturan çok katmanlı algılayıcılar (ÇKA) ile sınıflandırılan hava Lidar nokta bulutu verisinin doğruluğuna etki eden 3 boyutlu geometrik özelliklerin önemi araştırılmıştır. Bu kapsamında konumsal, renk ve yansımama bilgisi dışında sekiz geometrik özelliğin sınıflandırma işlemine etkisi ayrı ayrı irdelenmiştir. Geometrik özelliklerin her bir sınıf ile ilişkisi çıkarılmış ve sınıflandırma doğruluğuna etkisi ortaya koymulmuştur. Çalışma kapsamında Fransa'nın Louhans kentine ait hava Lidar nokta bulutu verisi üç ana kategoride (yeryüzü, bitki örtüsü ve binalar) sınıflandırılmıştır. Sınıflandırma sonucunda elde edilen F1 puanları yeryüzü, bitki örtüsü ve bina sınıfı için sırasıyla 0,99, 0,98 ve 0,96 olmuştur.

Anahtar Kelimeler: Uzaktan Algılama, Lidar, Nokta Bulutu, Derin Öğrenme, Sınıflandırma.

ABSTRACT

Classification of Airborne Lidar point cloud data is still one of the most popular topics of interest for researchers. Classification can be defined as the segmentation of each point in the point cloud data into meaningful categories by giving the label of the item it belongs to. Extracting meaningful and accurate data from the lidar point cloud is of great importance for earth sciences and other disciplines. In this respect, it is important to process the massive point cloud data and classify it with high accuracy. In this study, the importance of 3D geometric features that affect the accuracy of airborne lidar point cloud data classified by multi-layer perceptron (MLP), which form the basis of deep learning techniques, was investigated. In this context, the effects of eight geometric features on the classification process, apart from spatial, color and intensity information, were examined separately. The relationship of geometrical features with each class and its effect on classification accuracy have been revealed. Within the study, airborne lidar point cloud data of Louhans, France were classified in three main

categories (*ground, vegetation and buildings*). The F1 scores produced were 0.99, 0.98 and 0.96 for the ground, vegetation and building class, respectively.

Keywords: Remote sensing, Lidar, Point Cloud, Deep Learning, Classification.

1. GİRİŞ

3 boyutlu (3B) nokta bulutlarından anlamlı veri çıkarımı uzun yıllardır araştırmacıların ilgisini çeken bir konu olmuştur. Fotogrametrik veya çeşitli lazer sensörleri ile toplanabilen 3B nokta bulutu verisi, pratikte kullanılmadan önce bazı ön işlemlerden geçmelidir. Bunların başında daha önceden tanımlanmış sınıflara göre her bir noktanın otomatik şekilde etiketlenmesi gelmektedir. Sınıflandırma adı verilen bu işlemin dağınık bir yapıya sahip nokta bulutu verisine uygulanması asıl zorluğu beraberinde getirmektedir. Yüksek karmaşık yapıya sahip bölgelerde bu zorluk daha da artmaktadır.

Nokta bulutu verisi 3B konumsal bilginin yanı sıra kaynağına bağlı olarak renk ve yansımama bilgisi de içerebilir. Tüm bu bilgileri kullanarak sınıflandırma işlemi yapmak ileri seviye donanıma ve hızlı işlem yapabilme yeteneğine ihtiyaç duyar. Basit ve belirli kurallara dayanan algoritmaların birbirine benzeyen objeleri sınıflandırma yetenekleri sınırlıdır. Bu yüzden karmaşık yapıya sahip 3B verileri sınıflandırmada makine öğrenmesi algoritmaları son yıllarda üstün başarılar göstermiştir. Makine öğrenmesi teknikleri, sınıflar arasındaki ilişkileri ve algoritmeye verilen özelliklerini öğrenir ve tam otomatik şekilde sınıflandırmayı tamamlar. Bu teknikler karmaşık obje tipleri içeren verilerde klasik sınıflandırma tekniklerine göre daha uygundur (Guo ve diğerleri, 2015).

LiDAR nokta bulutunda yapılar ve objeler 3B noktalardan oluşan gruplar ile tespit edilebilir. Birbirine komşu noktaların dağılımı ile yerel geometrileri hesaplanabilir. Bir LiDAR noktasının K kadar yakın komşu noktaları veya merkezi ilgili nokta olacak şekilde küçük bir geometrik şekil (küre, daire veya silindir) ile çevrelenmiş bölgede bulunabilir (Demantke ve diğerleri, 2011).

Komşuluk kavramı ve temel prensipleri bu çalışmanın kapsamında olmayıp başka bir araştırmada ayrıntılı şekilde verilmiştir (Filin ve Pfeifer, 2005).

Nokta bulutu gibi büyük veri yiğinlarının anlamlı gruplara ayrılıp sınıflandırılması işlemi birçok farklı alan için büyük önem taşır, bunlar robotik (Maturana ve Scherer, 2015), otonom sürüs (Wang ve diğerleri, 2017), şehir planlama (Chauhan ve diğerleri, 2014), kültürel miras (Grilli ve diğerleri, 2017) ve 3B modelleme (Özdemir ve Remondino, 2021) olarak örnek verilebilir. Sınıflandırma işlemi prosedürü üzerine birçok farklı yaklaşım literatürde sunulmuş olsa da (Grilli ve diğerleri, 2017) makine öğrenmesi tekniklerinin popülerleşmesi ile hatırlı sayılır bir ilerleme kat edilmiştir (Atik ve diğerleri, 2021, Hackel ve diğerleri, 2016, Hu ve diğerleri, 2020, Lai ve diğerleri, 2022, Weinmann ve diğerleri, 2017).

Makine öğrenmesi modelini oluşturmak kadar bu modele giren veriyi de anlamak büyük önem taşır. Tıpkı bir korelasyon matrisinin görevi gibi özelliklerin önemi de özellikler ile çıktıların arasındaki ilişkiyi anlamaya izin verir. Ayrıca model ile alakasız olan özelliklerin anlaşılmasına yardımcı olur. Modeli eğitirken özelliklerin etki puanlarını göz önünde bulundurarak modelin boyutunu düşürerek kaynak kullanımını azaltılabilir. Yüksek etki puanına sahip özellikler korunurken model için fazla önem arz etmeyen düşük etki puanına sahip özellikler eğitim sürecinden çıkarılabilir. Böylece sadece modeli daha basitleştirmekle kalmaz aynı zamanda eğitimi hızlandırırken modelin performansı artırılmış olur. Modelin yorumlanabilirliği açısından da özelliklerin hesaplanması hem modelin performansının kaynağını ortaya koyar hem de daha açıklanabilir hale getirir.

Weinmann ve diğerleri (2015), çalışmalarında Mobil LiDAR ile üretilen 3B nokta bulutundan geometrik niteliklerin çıkarılmasında seçilecek yerel komşuluk şartlarının araştırılması ve elde edilen geometrik özelliklerden hangilerinin sınıflandırmaya daha çok etkisini olduğunu araştırmıştır. Seyfeli ve Ok (2022), geometrik özelliklerin çıkarılmasında en yakın komşuluk, küresel ve silindirik komşuluk ilişkileri üzerine bir araştırma yapmış. Bir başka çalışmada nokta bulutundaki komşuluk öznitelikleri ile bina çıkarımı gerçekleştirilmiş (Yıldız Erdemir ve Yastıklı, 2018). Atik ve diğerleri (2021), geometrik özelliklerin farklı ölçeklerdeki komşuluklardan çıkarımı ve 8 tane makine öğrenmesi tekniği ile LiDAR nokta bulutu sınıflandırılması üzerine bir çalışma yapmıştır. Yine farklı ölçeklerde geometrik özelliklerin

sınıflandırmaya etkisini araştıran çalışmalarda U-Net mimarisini kullanılmış ve güncel tekniklerin çoğundan başarılı sonuçlar ortaya koymuştur (Wan ve diğerleri, 2023, Yuanwei ve diğerleri, 2023).

Geometrik özelliklerin değerlerinin sınıflara göre dağılım histogramlarını kullanarak sınır ağında eğitimde kullanmak için ön eleme yapan ve daha sonra seçilen özellikler ile sınıflandırma performansı ölçen çalışma da mevcuttur (Kurdi ve diğerleri, 2023). Geometrik özelliklerin yanında renk verisi içeren ve bu iki niteliği kombine ederek sınıflandırma yapan çalışmalar da yüksek doğrulukta sonuçlar üretmiştir (Ji ve diğerleri, 2023). LiDAR nokta bulutlarında komşuluk özelliklerini öne çıkarıyan yeni ağ modülleri de önerilmiş ve sınıflandırma performansları güncel çalışmaların önüne geçmiştir (Xu ve diğerleri, 2023, Zhou ve Ling, 2023, Zhan ve diğerleri, 2023). Yine nokta komşuluklarını grafik sınır ağlarına benzer bir modelde eğiterek Mobil LiDAR verisinin sınıflandırmasını yapan çalışmalar mevcuttur (Wan ve diğerleri, 2022).

Bu çalışmada hava LiDAR nokta bulutundaki noktaların 3B geometrik özelliklerini çıkarılarak derin öğrenme tekniklerinden Çok Katmanlı Algılayıcı (ÇKA) ile nokta bulutu sınıflandırılması doğruluğuna etkisi incelenmiştir (Uray, 2023). Geometrik özellikler nokta bulutundaki her bir nokta ve belirli komşuluğunda bulunan noktalardan üretilen kovaryans matrisinden elde edilir. Literatürde nokta bulutu sınıflandırma çalışmalarında en çok kullanılan 8 farklı geometrik nitelikten olan özdeğerlerin toplamı ($\sum \lambda$), çok değişkenlik (omnivaryans, O_λ), özentropi (E_λ), eşyönsüzlük (anistropi, A_λ), doğrusallık (L_λ), küresellik (S_λ), dikeylik (V_λ) ve düzlemsellik (P_λ) hesaplanmıştır (Weinmann ve diğerleri, 2015). Bu özellikler ile birlikte 3B koordinatları ve yansımaya değerinden faydalılarak farklı kombinasyonlar oluşturulmuş ve geometrik özelliklerin sınıflandırma etkilerini araştırmak için birçok model eğitilmiştir.

Derin öğrenme ağının eğitiminde Fransa'nın Louhans kentine ait hava LiDAR nokta bulutu ve ağın doğrulaması için ise yine Fransa'nın Manosque şehrine ait hava LiDAR nokta bulutu verisi kullanılmıştır. Veri setleri zemin, bitki örtüsü ve binalar olmak üzere üç ana sınıfta etiketlenmiş halde araştırmacılar sunulmuştur. Geometrik özellikler açık kaynak kodlu CloudCompare (2023) yazılımı ile hesaplanmış, derin sınır ağı modellerinin oluşturulması, eğitilmesi ve test edilmesi Python programlama dili ile yazılan uygulamada yapılmıştır. Eğitim ve test işlemleri

Google Colab platformunda Tesla T4 grafik işlemcisi ile gerçekleştirılmıştır.

2. YÖNTEM

a. Komşuluk Seçimi ve Özelliğ Çıkarıımı

Nokta bulutu verisinde belirli bir komşulukta geometrik özelliklerin çıkartılmasında birçok farklı yöntem izlenebilir. Bu komşuluk ilişkileri yarıçapı belli olan bir küre (Lee ve Schenk, 2002), veya bir silindir (Filin ve Pfeifer, 2005), 3B uzayda Öklit mesafesine göre seçilen bir küre içerisinde komşu noktalar (Linsen ve Prautzsch, 2001) veya 2B uzayda Öklit mesafesine göre seçilmiş bir silindir içerisinde dahil olan komşu noktalar olarak tanımlanabilir (Niemeyer ve diğerleri, 2014).

Komşuluk belirlenirken seçilen farklı parametrik değerler üzerine yapılan çalışmalar mevcuttur. Weinmann vd. (2015), her bir nokta için komşusu olan farklı sayıda noktalar kullanarak sınıflandırma doğruluğuna etkisini araştırmış ve en yakın komşuluk kriterine göre 50-75 nokta arası optimum değer olarak rapor edilmiştir (Weinmann ve diğerleri, 2015). Weinmann vd. (2015), yaptığı bir başka çalışmada sınır ağlarını kullanan sınıflandırıcı için geometrik özelliklerin hesaplanması komşuluk değeri için 50 adet nokta seçildiğinde optimum sonuçları verdiği rapor etmiştir (Weinmann ve diğerleri, 2017).

Çalışma kapsamında kullanılan hava LiDAR verilerinin ortalama nokta yoğunluğu 13 nokta/m² olmasından dolayı ideal komşuluk kriteri her bir noktanın merkez kabul edildiği 1 m yarıçapındaki küre olarak seçilmiştir ve bu küre içerisinde dahil olan noktalar CloudCompare yazılımı ile hesaplanmıştır. Bu sayede geometrik özelliklerin hesaplanabilmesi için hem yaklaşık 40 komşu nokta seçilmiş hem de hesaplama maliyeti sınırlı tutulmuş olur. En yakın komşuluk algoritmasının kullanılabilirliği de Weinmann vd. (2015) tarafından test edilmiştir (Weinmann ve diğerleri, 2015). Komşuluk belirlemek için yarıçapı belli küre seçilmesine dair ayrıntılı bir çalışmada Demantké vd. (2011) tarafından rapor edilmiştir (Demantké ve diğerleri, 2011).

Yerel komşuluklar belirlendikten sonra noktaların konumsal bilgileri dikkate alınarak geometrik özelliklerini çıkarılabilir. Komşu noktaların 3B koordinatları belirli şekil ilkelerini tespit etmek için türetilen özdeğerlerin (çok değişkenlik) hesaplanması kullanılır (Jutzi ve Gross, 2009). Temel Bileşen Analizi teknigi ile komşu noktalardan faydalananarak kovaryans matris oluşturulur ve daha sonra bu matristen özdeğerler

türetilir. Özdeğerler ile farklı geometrik özellikler hesaplanır (Guan ve diğerleri, 2016). Özdeğerler vektörünün üç elemanı bulunmaktadır, bunlar; λ_1 , λ_2 , λ_3 ile ifade edilirler. Komşu noktaların koordinatları ile 3 x 3 boyutlarında kovaryans matristen türetilen özdeğerler bir şekli temsil ederler. Kovaryans matris (1) numaralı eşitlikte verilmiştir.

$$\text{cov}(N) = \frac{1}{|N|} \sum_{p \in N} (p - \bar{p})(p - \bar{p})^T \quad (1)$$

N komşuluk kümelerinin merkezi p olarak temsil edilir. Özdeğerler, düzlemsel ve doğrusal uyumluluğu ölçer. Özdeğerlerden birisi büyük diğerleri sıfıra yakın olduğu zaman 3B bir çizgiyi belirtirler. İki özdeğer birbirine yakın değerlere sahip ve diğerinin sıfıra yakın ise 3B bir düzleme oluşturur. Üç değerde büyük ise 3B bir küre veya belirsiz bir şekli temsil ederler (Zheng ve diğerleri, 2017). Çalışma kapsamında hesaplanan ve eğitimde kullanılan geometrik özellikler Tablo 1'de verilmiştir.

Tablo 1. Sınıflandırmada kullanılan geometrik özellikler

Özellik	Formül
Özdeğerler toplamı	$\sum \lambda_i$
Çok değişkenlik	$(\prod \lambda_i)^{\frac{1}{3}}$
Özentropi	$-\sum \lambda_i \ln(\lambda_i)$
Eşyönsüzlük	$(\lambda_1 - \lambda_3) / \lambda_1$
Doğrusallık	$(\lambda_1 - \lambda_2) / \lambda_1$
Küresellik	λ_3 / λ_1
Düzlemsellik	$(\lambda_2 - \lambda_3) / \lambda_1$
Dikeylik	$1 - \langle [001], \lambda_3 \rangle $

b. Sınıflandırma

3B nokta bulutundan çıkartılan geometrik özellikler sınıflandırıcıya eğitim verisi olarak girdi verilir ve model eğitimi gerçekleştirilir. Eğitimden önce veriler önişlem adımlarından geçirilir, bunun için her satırı bir 3B nokta ile ve buna karşılık gelen her bir sütun konum bilgisi, renk, yoğunluk ve geometrik özellikler ile temsil edilen matris veri yapısı oluşturulur. Her bir özellik yani her bir sütun kendi içerisinde en büyük ve en küçük değerleri kullanılarak [0,1] aralığında ölçeklenir. Bu işlem eğitim için hesaplama yükünü düşürmeye ve eğitimin doğruluğunu artırmaya yardımcı olur (Grandio ve diğerleri, 2022). Her bir noktaya karşılık gelen sınıf ise her bir sınıf için farklı bir kodlama (yer noktaları:1, bitki örtüsü:2 ve bina noktaları:3) kullanılarak matris verisinin son

sütununda saklanır. Eğitim aşamasında noktaya ait özellikler karşılık gelen sınıf için ağırlıklarılarak verideki her bir nokta için işlem tekrarlanır. Tüm bu işlem adımları ise her iterasyonda (epok) baştan tekrar gerçekleştirilir.

LiDAR verisi ve çalışma alanı ile ilgili fazla ön bilgiye sahip olmadan sınıflandırıcıya hesaplanabilen tüm özellikler girdi olarak verilebilir. Fakat bazı özellikler çok ilgiliyken bazı özellikler daha az uygun veya alakasız olabilir. Teoride çoğu sınıflandırma tekniğinin verilerin boyutuna karşı duyarsız olduğu düşünülse de gereksiz ve alakasız bilgiler modelin performansını etkilemektedir (Weinmann ve diğerleri, 2017).

Hughes fenomeni, özellikle yüksek boyutta verilerin sabit sayıda eğitim verisi kullanılsa dahi girdi olarak verilen özelliklerin sayısındaki artış belli bir eşik değeri aşlığında sınıflandırma performansını olumsuz etkilediğini savunur (Hughes, 1968). Tüm nokta bulutu verisi eğitim ve test veri seti olmak üzere ikiye ayrılır. $\gamma = \{s_i\}$ ile ifade edilen eğitim veri seti, η ($i = 1, \dots, \eta$) adet s_i eğitim örneği barındırır. Her bir eğitim örneği $s_{i,i} = (x_i, l_i)$ bünyesinde d -boyutlu özellik uzayında bir özellik vektörü $x_i \in \mathbb{R}^d$ ve bunlara karşılık gelen η 'nin sınıf sayısını ifade ettiği sınıf etiketleri $l_i \in \{1, \dots, \eta\}$ bulundurur. Yine $\gamma^* = \{s_i\}$ ile ifade edilen test veri seti, m adet s_i * eğitim örneği d -boyutlu özellik uzayında özellik vektörü $x_i \in \mathbb{R}^d$ barındırırken sınıflandırma sonuçlarını değerlendirmek için karşılık gelen etiketlerden $l_i \in \{1, \dots, \eta\}$ faydalıdır.

Sınıflandırma işlemi için rastgele orman algoritması (Breiman, 2001), destek vektör makinaları (Cortes ve Vapnik, 1995), doğrusal ayırmaya analizi (Etemad ve Chellapa, 1997) gibi birçok farklı strateji uygulanabilir. Çalışma kapsamında makine öğrenmesi tekniklerinden derin öğrenme ağlarının temelini oluşturan ÇKA ile model eğitimleri ve testler gerçekleştirilmiştir.

c. Çok Katmanlı Algılayıcı

Bu çalışmada LiDAR nokta bulutlarını sınıflandırmak için ileri beslemeli bir derin sinir ağı algoritması olarak bilinen ÇKA kullanılmıştır. Birçok katman içeren ileri beslemeli sinir ağı, girdi ve çıktı (örn. sınıflar) verileri arasında lineer olmayan ilişkileri öğrenir. Ağ mimarisi, birçok nöron (hesaplama birimi) barındıran girdi katmanı, gizli katmanlar ve çıktı katmanından meydana gelir. Aslında, hesaplama birimlerinin birbirleriyle olan bağlantıları ağı oluştururken her bir hesaplama birimi girdilerin ağırlıklarını hesaplar ve

aktivasyon fonksiyonuna gönderir (Schmidhuber, 2015). Nöronlardaki hesaplamanın basit formülü eşitlik 2'de verilmiştir.

$$y_j^h = \sigma_j(\sum_{i=1}^n (W_{i,j}^h * x_i^{h-1}) + b_j^h) \quad (2)$$

Bu eşitlikte y_j^h , bir önceki katmandan (h-1) girdi verisini $X = \{x_1, x_2, \dots, x_n\}$ ($i \in [1, n]$) kullanan j'inci nöronun çıktısıdır. $W_{i,j}$, (h) katmanındaki ağırlık, b_j , sapmayı ve n ise girdi sayısını (veya bir önceki katmandaki nöron sayısını) ifade eder. Aktivasyon fonksiyonu (σ_j) girdi veriler doğrusal olmayan fonksiyonları öğrenir.

Gizli katmanların sayısı mimarının karmaşıklığını belirtirken derin sinir ağı tanımını bu özelliklerinden alırlar. Sinir ağıının parametreleri (ağırlıklar ve sapma değerleri) gradyan azaltma ile geri yayılım algoritmasını kullanılarak denetimli öğrenilir. Buradaki öğrenme ifadesinden kasıt gerçek değerler ile çıktı değerler arasındaki hatanın (hata hesaplama veya kayıp fonksiyonu) en aza indirilmesidir. Eşitlik 3'te hata fonksiyonu olarak en küçük ortalama kareler formülü verilmiştir.

$$E(W) = \frac{1}{2} \sum_{i=1}^n (y_j^h - \underline{y}_j)^2 \quad (3)$$

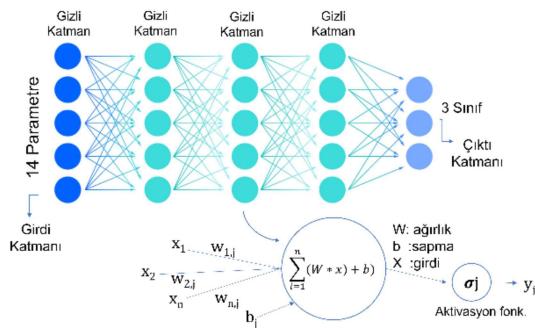
Son katmandaki nöron j için üretilen çıktı y_j^h ve nöronun gerçek çıktı \underline{y}_j dir. Geri yayılım algoritmasını kullanarak hata fonksiyonunun çıktısını küçültmek için ağırlıkların (W) ve sapma değerlerinin güncellemleri her nöron bağlantısında hesaplanmalıdır. Bunu optimizasyon teknikleri yardımıyla hata fonksiyonunun kısmi türevini alarak gerçekleştirir. Sapma değerlerinin güncellenmesi içinde benzer bir işlem yapılır.

Stokastik gradyan inişi (SGI) algoritması iteratif şekilde hata fonksiyonunun çıktısını azaltmayı hedefler. Bunu yapmak için de her epokta doğru yönde fonksiyonu güncellemesi gereklidir. Bu yönü bulmak için kısmi türevden yararlanılır. Ağırlıkların optimize edilmiş değerlerini bulmak büyük önem taşır.

Optimizasyon algoritmaları ile ilgili ayrıntılı bilgiye Kurt'un çalışmasında ulaşılabilir (Kurt, 2018). Bununla birlikte hesaplanan ağırlık değerleri modelin genelleştirilmesini sağlar, model bu sayede daha önce görmediği veriler için daha iyi tahminler yapabilir (Uray, 2022).

Çalışma kapsamında optimizasyon algoritması olarak SGD, öğrenme oranı ise 0.001 seçilmiştir.

Epok sayısı 200 olarak belirlenirken gizli katman sayısı 20 seçilerek ağ mimarisi oluşturulmuştur (Şekil 1).



Şekil 1. Derin sinir ağının mimarisi

c. Geometrik Özelliklerin Önem Değerlendirilmesi

Özellik seçimi için birçok farklı teknik Saeys ve diğerleri (2007) tarafından ayrıntılı incelenmiştir. Çalışmada bahsedilen teknikler, özellikler ile sınıflar arasındaki ilişkiyi belirleyerek alakalı özellikleri ortaya koyar ve özelliklerin kendi aralarındaki ilişkiyi de çıkararak alakasız özelliklerin elimine edilmesini sağlar. Bunu verideki tüm noktalar için bir özelliğin değerlerini barındıran vektörü bu noktalara karşılık gelen sınıf etiketleri ile karşılaştırarak yapar. Bu karşılaştırma ile sınıflandırma işlemine etki eden özelliklerin etki düzeyini gösteren bir metrik hesaplanarak yorumlanabilir.

3. BULGULAR

Bu bölümde ilk olarak çalışmada kullanılan LiDAR veri seti hakkında bilgi verilmiştir (Bölüm 3.a). Sonrasında konumsal bilgi, renk ve seçilen geometrik özelliklerin seçimi bölüm 3.b'de verilmiştir. Ardından bölüm 3.c'de derin sinir ağının eğitimi ve sınıflandırma sonuçları sunulmuştur.

a. LiDAR Veri Seti

Çalışma kapsamında Fransa'nın Louhans ve Manosque kentlerine ait hava LiDAR nokta bulutu verisi kullanılmıştır. LiDAR verileri Fransa Ulusal Coğrafi ve Orman Bilgi Enstitüsü tarafından kullanıcılarla sunulmaktadır (IGN, 2023). Eğitim ve test verisi olarak Louhans nokta bulutu, genelleştirme ve doğrulama verisi olarak Manosque nokta bulutu kullanılmıştır. Louhans verisinin nokta yoğunluğu $13 \text{ nokta}/\text{m}^2$ olup yaklaşık 3.4 milyon adet konumsal, renk, yansımaya ve 8 geometrik özelliği hesaplanmış nokta içermekte ve üç ana kategoride (yer, bitki örtüsü

ve bina) sınıflandırılmıştır (Şekil 2). Nokta bulutunun %60'lık kısmı eğitim (2 milyon), kalan %40'ı ise test (1.4 milyon) için bir kurala bağlı kalmadan rastgele noktalar seçilerek ayrılmıştır. Eğitim verisinin test verisine oranının bu şekilde seçilmesi kabul gören genel bir optimum oran olmuştur (Kartal ve Sekertekin, 2022; Singh ve Girase, 2022).

Manosque verisinin nokta yoğunluğu ise $12 \text{ nokta}/\text{m}^2$ olup yaklaşık 3.2 milyon adet üç sınıfa ayrılmış konumsal, renk, yansımaya ve 8 geometrik özellik barındıran nokta içermektedir (Şekil 3). Tablo 2'de iki veri için tüm sınıflara ait nokta sayısı verilmiştir.

Makine öğrenmesi tekniklerinde özellikle eğitim verisi ile eğitilip test edilen modeller daha önce görümediği veri setlerinde sınıflandırma yaptığından sonuçlar test verisinin sınıflandırma sonuçları kadar başarılı olmayıabilir. Bunun sebebi, modelin eğitim verisindeki topografiya ve geometrik özelliklerini öğrenip ezberleme yapması ve eğitildiği veriye karşı yanlış sonuçlar üretmesidir. Li vd. tarafından hava LiDAR nokta bulutlarını sınıflandırmak için oluşturulan ağ modelinin de genelleştirme performansı irdelenmiş ve eğitim ve doğrulama verileri arasında ortalama F1 puanı açısından %29'luk bir fark ortaya konulmuştur (Li ve diğerleri, 2020). Genelleştirme ile ilgili ayrıntılı bilgiye Neyshabur ve diğerleri (2017), tarafından yapılan çalışmada erişilebilir.

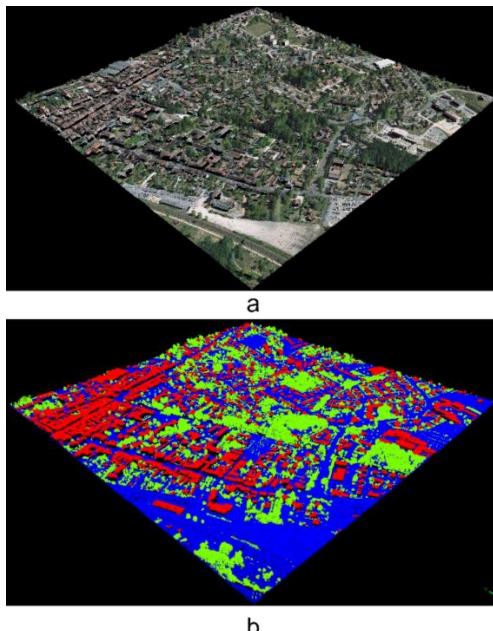
b. Geometrik Özelliklerin Seçimi

Komşuluk sınırları belirlenmiş 3B noktaların her birisi için oluşturulan kovaryans matrisinden türetilen özdeğer elemanları, geometrik özelliklerin çıkarılmasında kullanılır. Bölüm 2(a)'da bahsedilen 8 adet özellik ile birlikte 3B noktaların konum (X, Y, Z), renk (kırmızı, yeşil, mavi) ve yansımaya bilgisi LiDAR nokta bulutunun sınıflandırılmasında derin sinir ağına girdi olarak verilir (Şekil 4).

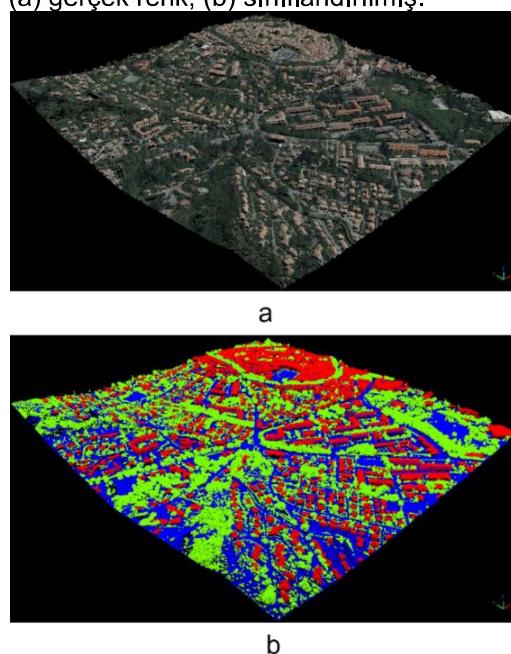
Tablo 2. Test ve doğrulama verilerine ait nokta sayıları

	Nokta bulutu	Sınıf	Nokta sayısı
Eğitim ve Test verisi	Louhans	Yer	1718568
		Bitki örtüsü	1012666
		Bina	568580
Doğrulama verisi	Manosque	Yer	1221203
		Bitki örtüsü	1149854
		Bina	570563

Çalışma kapsamında yapılacak geometrik özellik önem değerlendirmesi, ilk olarak tüm özelliklerden oluşan kombinasyon setinin sınır ağına girdi verilmesi ve eğitilmesi, sonuçlara göre sınıflandırmaya en az etki eden özelliklerin sırasıyla setten çıkarılarak yeni set ile sınır ağının tekrar eğitilmesi şeklindekidır. Farklı özellikler ile oluşturulan girdi kombinasyonları Tablo 3'te verilmiştir. Geometrik özelliklerin hesaplanması Bölüm 2.a'da açıklanmıştır şekilde gerçekleştirılmıştır.



Şekil 2. Louhans Hava Lidar nokta bulutu. (a) gerçek renk, (b) sınıflandırılmış.



Şekil 3. Manosque Hava Lidar nokta bulutu. (a) gerçek renk, (b) sınıflandırılmış.

X	Y	Z	R	G	B	Yanısim	Sınıf	OdegerTop	Omnivaryans	Ozentropi
-0.350	7.780	193.240	83	88	85	1.338.000	1.000	0.369	0.002	0.535
-0.340	8.350	193.190	173	164	176	1.921.000	1.000	0.225	0.014	0.447
-0.410	8.920	193.040	158	158	164	2.445.000	1.000	0.281	0.018	0.527
-0.300	9.490	193.010	136	136	138	3.269.000	1.000	0.216	0.007	0.450
-0.310	10.520	193.000	194	185	196	1.688.000	1.000	0.308	0.003	0.529
-0.460	6.650	193.290	166	169	174	2.678.000	1.000	0.215	0.001	0.463
-927.050	100.840	181.710	125	137	146	1.604.000	1.000	0.182	0.006	0.430
-926.390	100.500	181.710	100	108	105	1.019.000	1.000	0.462	0.051	0.691
-926.590	101.110	181.690	111	120	118	1.320.000	1.000	0.372	0.036	0.580
-925.840	100.850	181.900	92	97	91	522.000	1.000	0.315	0.008	0.572

Şekil 4. LiDAR verisinde noktaların özellikleri

c. Derin Sinir Ağının Eğitimi

Geometrik özelliklerin sınıflandırma performansını değerlendirmek için Tablo 3'te verilen her özellik kombinasyonu ile sınır ağının eğitilmiştir. Derin sınır ağının oluşturulmasında Python dili ile yazılmış Scikit-learn kütüphanesi kullanılmış, ağa girdi olarak verilen özelliklerin ön işlemi için Pandas ve Numpy kütüphanelerinden faydalanyılmıştır. Girdi verilerini belli bir aralığa ölçeklemek, sınır ağının eğitiminde tüm özelliklerin ağa eşit katkı yapmasını sağlar. Bu nedenle LiDAR nokta bulutunda derin sınır ağına verilen tüm özellikler [0, 1] aralığında ölçeklendirildikten sonra eğitime dahil edilmiştir. Modelerin eğitiminde epok sayısı 200 olarak seçilmiştir. Eğitim, Google Colab platformunda 15 GB belleğe sahip Tesla T4 grafik işlemci yardımıyla gerçekleştirilmiştir. Özellik setlerinin eğitim süreleri Tablo 8'de verilmiştir.

Tablo 6 ve Tablo 7'de sırasıyla test ve doğrulama verilerine ait sınır ağının her sınıf için ürettiği ve ortalama F1 puanları verilmiştir. Tablo 8'de veri setlerinin eğitim süreleri verilmiştir. K10 setinden itibaren eğitim süresinin düşmesinin sebebi eğitim sırasında yakınsamanın son on epok boyunca değişmemesi ve bu nedenle eğitimi sonlandırmasıdır.

Bu çalışma kapsamında yapılan deneylerde ilk aşamada tüm konumsal, renk ve geometrik özellikler derin sınır ağının modelinde eğitilmiş ve LiDAR verisi üzerindeki tahminleri ile noktaların gerçek sınıf değerleri karşılaştırılarak doğruluk analizi yapılmıştır. Ardından özellik vektöründeki değerlerden bir tanesinin bulunduğu veri sütununun kendi içerisinde tüm değerler rastgele yer değiştirilirken diğer sütunlardaki değerler aynı kalacak şekilde düzenlenir (Tablo 3 ve Tablo 4). Daha önceden eğitilen model bu manipüle edilmiş özellik vektörü üzerinde tahminde bulunarak elde edilen doğruluğu, özellik vektörünün orijinal hali üzerinde yaptığı tahmin ile kıyaslayarak arasındaki farkı hesaplar. Bu iş akışı tüm özellikler için 100 kez tekrarlanır. Farkların ortalaması ile değiştirilen özelliğin sınıflandırmaya etkisi bulunmuş olur. Doğruluk kıyaslamasında en az farkın çıktığı iterasyonda değiştirilen özelliğin etkisinin en az

olduğu kabul edilir ve bir sonraki eğitim için özellik vektöründen tamamen çıkartılır.

Tablo 3. Geometrik özelliklerin orijinal hali

X	Y	Z	...	Özellik A	Sınıf
X_1	Y_1	Z_1	...	G_1	1
X_2	Y_2	Z_2	...	G_2	0
:	:	:	:	:	2
X_n	Y_n	Z_n	...	G_n	0

Tablo 4. Bir geometrik özelliğin rastgele yer değiştirilmiş gösterimi

X	Y	Z	...	Özellik A	Sınıf
X_1	Y_1	Z_1	...	G_(n-m)	1
X_2	Y_2	Z_2	...	G_(n-i)	0
:	:	:	:	:	2
X_n	Y_n	Z_n	...	G_(n-l)	0

Test ve doğrulama için kullanılan LiDAR nokta bulutları daha önceden sınıflandırıldığı için bu sınıflar gerçek değer olarak kabul edilmiştir. Tablo 5'te verilen modeller ile tekrar sınıflandırılan LiDAR verilerinde, her bir nokta için tahmin edilen sınıf ile ait olduğu gerçek sınıfı karşılaştırılmıştır. Her model için hata matrisi ve genel doğruluk hesaplanırken duyarlılık (recall), kesinlik (precision) ve bunların harmonik ortalaması F1 puanları hesaplanmıştır. Bu değerlerin formülleri eşitlik 4-7'de verilmiştir.

$$\text{Genel Doğruluk} = \frac{GP + GN}{GP + GN + YP + YN} \quad (4)$$

$$\text{Duyarlılık} = \frac{GP}{GP + GN} \quad (5)$$

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

$$F1 = 2 * \frac{\text{kesinlik} * \text{duyarlılık}}{\text{kesinlik} + \text{duyarlılık}} \quad (7)$$

Burada GP, gerçek pozitif tahminleri temsil ederken GN, gerçek negatifleri, YP, yanlış pozitifleri ve YN, yanlış negatifleri ifade eder. GP, hata matrisinde köşegen elemanların toplamını diğer bir ifadeyle pozitif sınıfın doğru tahmin sayısını verir. GN ise negatif sınıfın doğru tahmin sayısını ifade eder. YP ise pozitif olarak tahmin edilen fakat gerçekte negatif olan tahminlere eşittir. YN, negatif sınıf olarak tahmin edilen fakat gerçekte pozitif olan tahminlerin sayısını verir.

Tablo 5. Özellik kombinasyon setleri

Set adı	Özellikler
K1	{X, Y, Z, R, G, B, Yansıma, Özdeğer Toplamı, Çok değişkenlik, Özentropi, Anistropi, Doğrusallık, Küresellik, Dikeylik, Düzlemsellik}
K2	{X, Y, Z, R, G, B, Yansıma, Özdeğer Toplamı, Çok değişkenlik, Özentropi, Doğrusallık, Küresellik, Dikeylik, Düzlemsellik}
K3	{X, Y, Z, R, G, B, Yansıma, Çok değişkenlik, Özentropi, Doğrusallık, Küresellik, Dikeylik, Düzlemsellik}
K4	{X, Y, Z, R, G, B, Çok değişkenlik, Özentropi, Doğrusallık, Küresellik, Dikeylik, Düzlemsellik}
K5	{X, Y, Z, R, G, B, Çok değişkenlik, Doğrusallık, Küresellik, Dikeylik, Düzlemsellik}
K6	{X, Y, Z, R, G, B, Doğrusallık, Küresellik, Dikeylik, Düzlemsellik}
K7	{X, Y, Z, R, G, B, Doğrusallık, Dikeylik, Düzlemsellik}
K8	{X, Y, Z, R, G, B, Doğrusallık, Düzlemsellik}
K9	{X, Z, R, G, B, Doğrusallık, Düzlemsellik}
K10	{Z, R, G, B, Doğrusallık, Düzlemsellik}
K11	{R, G, B, Doğrusallık, Düzlemsellik}
K12	{R, G, Doğrusallık, Düzlemsellik}
K13	{R, G, Düzlemsellik}
K14	{R, G}

Tablo 6. Test verisinde üretilen F1 (%) puanları.
En yüksek puanlar koyu yazılmıştır.

Özellik Seti	Yer	Bitki Örtüsü	Bina	Ortalama F1 puanı
K1	0,99	0,97	0,95	0,970
K2	0,99	0,98	0,96	0,977
K3	0,99	0,98	0,96	0,977
K4	0,99	0,97	0,95	0,970
K5	0,99	0,97	0,95	0,970
K6	0,99	0,97	0,95	0,970
K7	0,99	0,97	0,95	0,970
K8	0,99	0,97	0,94	0,967
K9	0,96	0,96	0,88	0,933
K10	0,93	0,95	0,80	0,893
K11	0,89	0,93	0,67	0,830
K12	0,87	0,92	0,58	0,790
K13	0,79	0,78	0,56	0,710
K14	0,73	0,69	0,55	0,657

Tablo 7. Doğrulama verisinde üretilen F1 (%) puanları. En yüksek puanlar koyu yazılmıştır.

Özellik Seti	Yer	Bitki Örtüsü	Bina	Ortalama F1 puanı
K1	0,27	0,86	0,53	0,553
K2	0,29	0,88	0,51	0,560
K3	0,28	0,87	0,52	0,557
K4	0,28	0,87	0,52	0,557
K5	0,28	0,85	0,54	0,557
K6	0,28	0,84	0,55	0,557
K7	0,28	0,83	0,56	0,557
K8	0,27	0,80	0,58	0,550
K9	0,43	0,85	0,55	0,610
K10	0,63	0,89	0,64	0,720
K11	0,73	0,91	0,60	0,747
K12	0,73	0,91	0,62	0,753
K13	0,54	0,70	0,61	0,617
K14	0,53	0,52	0,62	0,557

4. TARTIŞMA

Tablo 5'te verilen özellik setleri ile sırasıyla eğitilen sınır ağının sınıflandırma performansı test verisinde ilk set ile son set arasında F1 puanı için yaklaşık %32'lük düşüş olmuştur. Yer noktaları sınıfı için yaklaşık %26'lık azalma olan F1 puanında, bitki örtüsü sınıfı için %29 ve bina sınıfı için yaklaşık %41'lük düşüş görülmüştür. Geometrik özelliklerden çok değişkenlik, dikeylik ve düzlemsellik, genel doğruluğa sırasıyla %13, %8 ve %2'lük etkiyle en yüksek üç nitelik olmuştur. Diğer taraftan tüm özellikler göz önünde bulundurulduğunda Z (yükseklik), R (kırmızı renk) ve G (yeşil renk), sırasıyla %40, %28 ve %24 ile en yüksek etki eden üç özellik olmuştur (Şekil 6).

Test verisi için bina sınıfındaki performans düşüşü K8 ile K11 setleri arasında bariz şekilde görülmektedir. Bunun sebebi olarak özellik setlerinden sırasıyla çıkarılan X, Y ve Z koordinatları gösterilebilir. Bu üç koordinatın özellik setinden çıkarılması bina sınıfı için üretilen F1 puanını toplamda %27 düşürmüştür. Bitki örtüsü için ise K13 setinde doğrusallık özelliği çıkarıldığında F1 puanının %14 düşüğü gözlemlenmiştir. Yine aynı şekilde yer sınıfının F1 puanı içinde doğrusallık özelliğinin çıkarılması %8'lük düşüşe sebep olmuştur.

Test verisi için K1-K8 özellik setleri arasında modelin sınıflandırma performansı en üst seviyede olmuştur. Bunun başlıca sebebi özellik setlerinin koordinat bilgisi barındırmamasıdır. Bir başka deyişle eğitim ve test verisinin aynı LiDAR verisinden seçilmesi modelin konum bilgisini öğrendiği veriyi daha başarılı sınıflandırmasına

yardımcı olmuştur. Tam tersi şekilde K1-K8 setlerinin doğrulama verisindeki performans düşüğünün sebebi de modelin öğrendiği konum bilgisinden farklı bir konum bilgisi içeren veriyi sınıflandırmaya çalışmasıdır.

Doğrulama verisi için K8 setine kadar modelin ürettiği üç sınıf için ortalama F1 puanı %56'da kalmıştır. X ve Y koordinatları çıkarılarak, doğrusallık ve düzlemsellik dışında tüm geometrik özellikler de çıkarıldığında K9 setinden itibaren ortalama F1 puanı yükselmeye başlamıştır. İlk olarak Y koordinatı çıkarıldığında yer sınıfı için %16 artan F1 puanı, bitki örtüsü için ise %5 artarken ortalama F1 %6 artış göstermiştir. Daha sonra K10 setinde X koordinatı da çıkarıldığında ortalama F1 puanı %11 daha artarken, yer sınıfı için %20, bina sınıfı için %9 ve bitki örtüsü için %4 daha artmıştır. K11 setinde Z değeri de çıkarıldığında ortalama F1 %3 artarken asıl yükseliş yer sınıfında %10 daha artarak olmuştur (Şekil 7). Fakat test verisindeki Z değerinin çıkarılması ortalama F1 puanına %6 düşüş ile etki ederken sınıflandırmada olumsuz olarak en çok etkilediği bina sınıfında %13'lük düşüşe sebep olmuştur. Yükseklik değerinin sonucu bu şekilde etkilemesi Weinmann vd. (2017), yaptığı çalışmada da ifade edilmiştir (Weinmann ve diğerleri, 2017).

Bunun sebebi olarak, eğitim verisindeki koordinatlar ile eğitilen modelin, farklı bir bölgeye ait doğrulama verisindeki koordinatları kullanırken yeterince verim alamaması gösterilebilir.

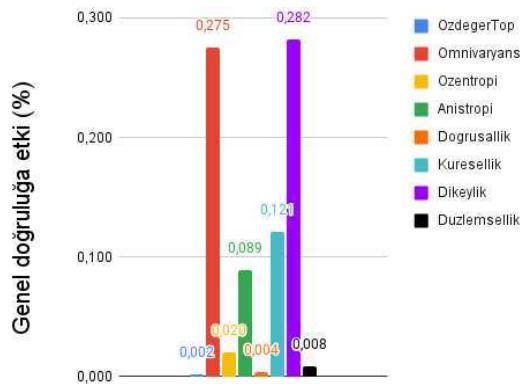
Modellerin genel performansına bakıldığından, üç sınıf için üretilen en yüksek ortalama F1 puanı %98 olurken, konum ve renk bilgisi ile beraber sadece doğrusallık ve düzlemsellik kullanıldığında ise en yüksek ortalama F1 puanı %97 olmuştur (K8 seti). Test ve eğitim noktalarının aynı veriden yani benzer topoğrafya ve arazi örtüsüne ait olması nedeniyle üretilen puanların yüksek olması normal karşılanabilir. Modelleri asıl zorlayan farklı bir arazi tipine sahip doğrulama verisi üzerinde yaptığı tahminler olmuştur. Aynı zamanda modellerin genelleştirme performansını da göz önüne sermiştir (Tablo 7).

Eğitilen modeller arasında en yüksek ortalama F1 puanı üreten K12 seti olmuştur, buna göre yer sınıfı için %73, bitki örtüsü için %91 ve bina sınıfı ise %62 olmuştur. K13 ve K14 setlerinde doğrusallık ve düzlemsellik özellikleri de çıkarıldığında ortalama F1 puanlarında %20'lük düşüş görülmüştür. Sadece 8 geometrik özellik (Özdeğer Toplamlı, Çok değişkenlik, Özentröپi, Anistropi, Doğrusallık, Küresellik, Dikeylik,

Düzlemsellik) kullanarak eğitilen farklı bir model, doğrulama verisinde yer sınıfı için %86, bitki örtüsü için %89 ve bina sınıfı için %63 F1 puanı üretirken ortalama F1 puanı olarak %79'a ulaşmıştır. Bu değer ile Tablo 7'de verilen tüm setlerden daha yüksek bir başarı elde etmiştir. Bölüm 3.c'de ayrıntılı şekilde anlatılan yöntem ile modelin genel doğruluğa etkisi incelendiğinde, dikeylik, çok değişkenlik ve küresellik en çok etki eden ilk üç özellik olmuştur. Bir örnek ile açıklamak gerekirse, her bir noktaya denk gelen dikeylik değerleri rastgele yer değiştirildiğinde modelin genel tahmin doğruluğu değerlerin orijinal haline göre %28,2 azalmıştır. Genel doğruluğa olan etki çok değişkenlik ve küresellik için ise sırasıyla %27,5 ve %12,1 olmuştur (Şekil 5).

Test ve doğrulama verilerindeki sınıflandırma sonuçlarına ait hata matrisi Şekil 8'de verilmiştir. Bu matriste her sınıf için gerçek ve tahmin edilen nokta sayıları karşılaştırılmış, her satırda gerçek değer belirtilirken her sütunda tahmin edilen sınıflar nokta adedi olarak gösterilmiştir. Matrisin

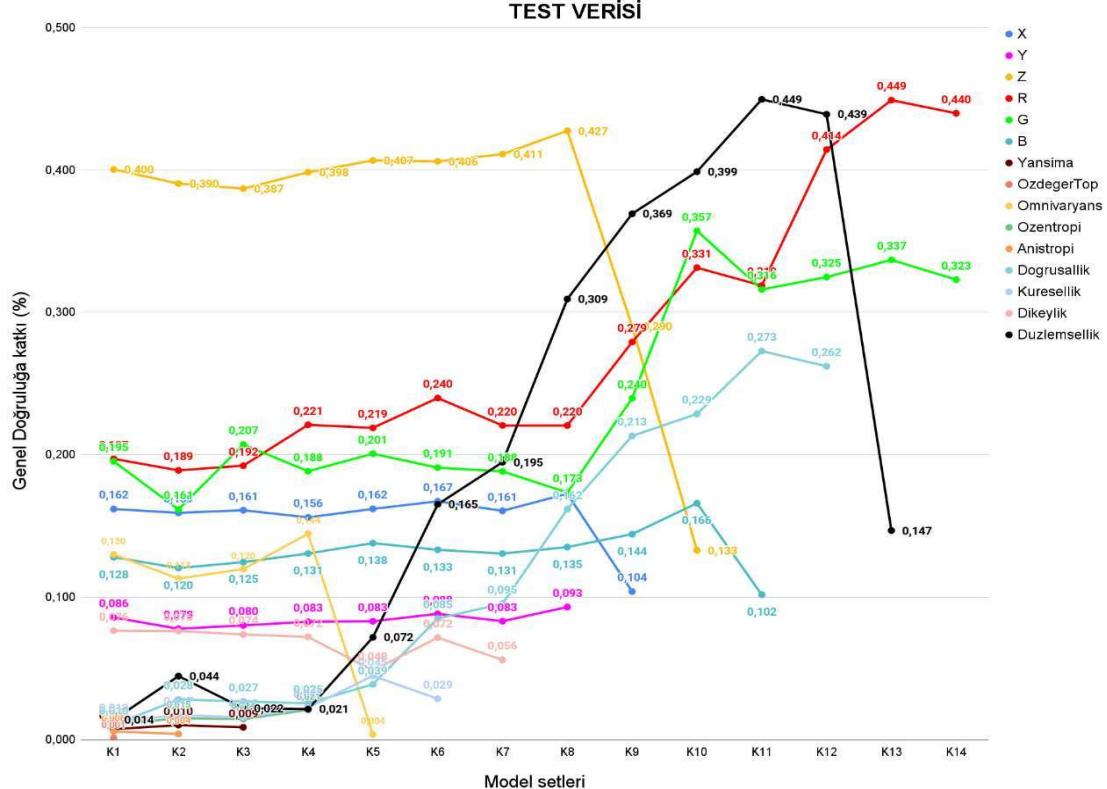
köşegen değerleri doğru tahmin edilen nokta sayılarını vermektedir.



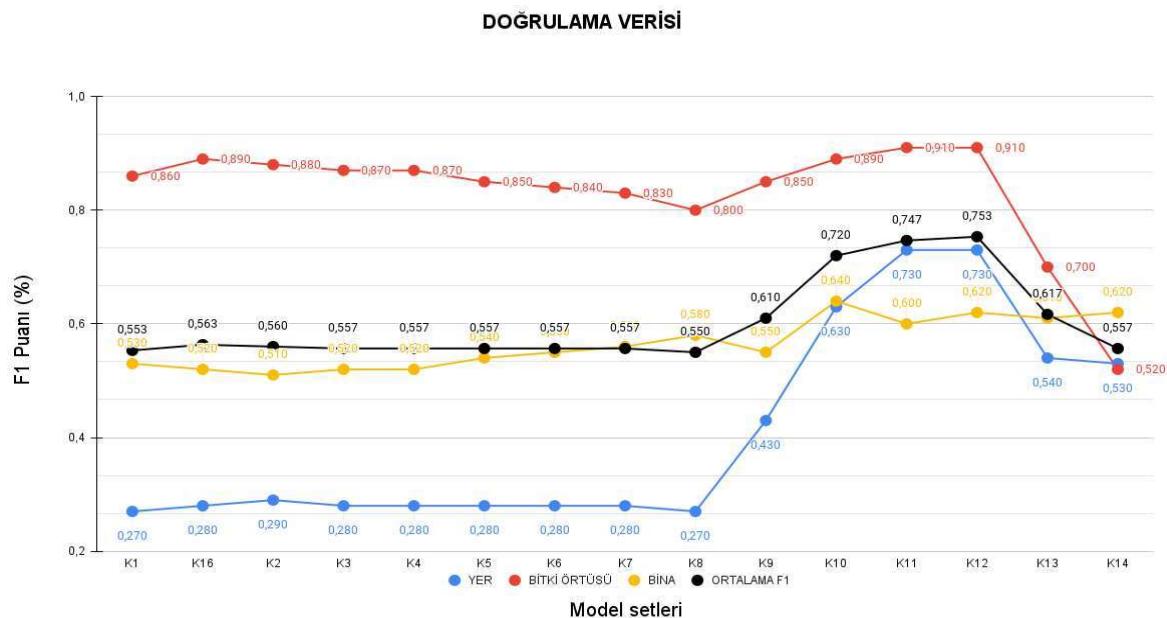
Şekil 5. Geometrik özelliklerin test verisinde genel doğruluğa etkisi (Konum ve renk bilgisi dahil edilmeden)

Tablo 8. Veri setlerinin eğitim süreleri (sn)

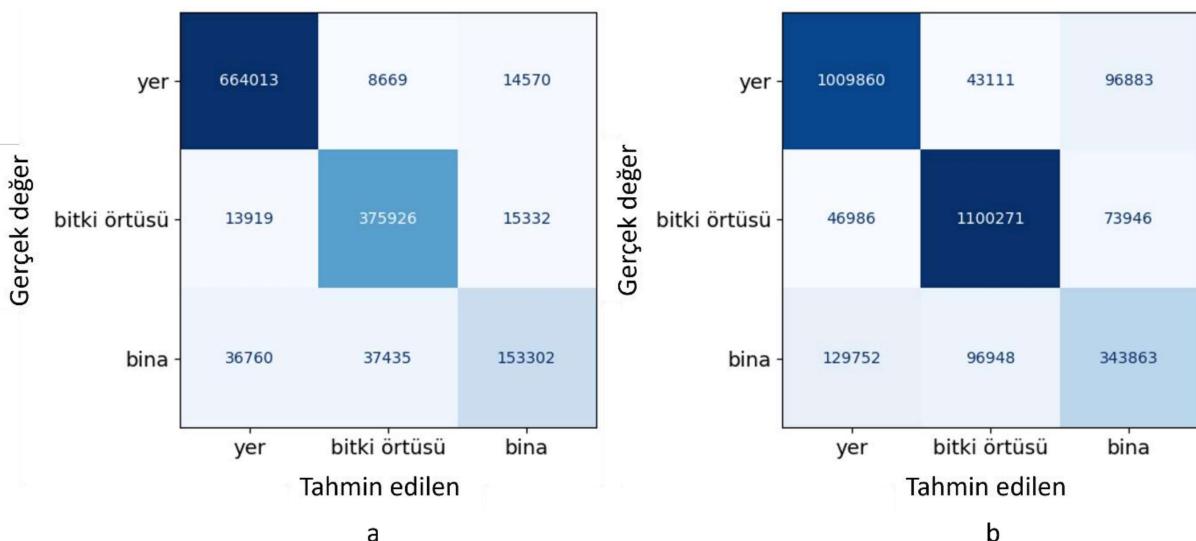
	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	K11	K12	K13	K14
Süre (sn)	707	688	599	863	1040	1195	865	1117	1158	740	582	616	429	482



Şekil 6. Test verisinde konumsal, renk ve geometrik özelliklerin her set için genel doğruluğa etkisi



Şekil 7. Doğrulama verisinde her model seti için üretilen F1 (%) puanları



Şekil 8. Test ve doğrulama verilerinde K14 modeli için üretilen hata matrisleri (a; test verisi, b: doğrulama verisi)

5. SONUÇ

Bu çalışmada derin öğrenme tekniklerinden çok katmanlı algılayıcı ile LiDAR nokta bulutlarının sınıflandırılmasında geometrik özelliklerin seçimi ve sınıflandırma sonuçlarına etkisi araştırılmıştır. Eğitilen modelin genelleştirme performansını görmek için daha önce görmediği bir LiDAR verisinin sınıflandırması yapılmış ve elde edilen sonuçlar da verilmiştir.

Son yıllarda 3B nokta bulutlarının makine öğrenmesi teknikleri ile sınıflandırılmasında eğitim

icin özellik çıkarımı ve seçimi konusu ayrı bir araştırma alanı olmuştur. Bu kapsamda yapılan çalışmalarla sınıflandırmaya etki eden en önemli özellikler türetilmeye ve hesaplama maliyetini düşüren parametrelerle odaklanılmıştır. Bu çalışmada da farklı geometrik özellik setleri ile eğitilen modellerin birbirinden bağımsız iki farklı topografya sahip LiDAR verisi üzerindeki sınıflandırma performansı test edilmiştir. Koordinat sistemleri de birbirinden farklı olan bu verilerde yatay koordinatların beklentiği gibi sınıflandırma etkisi geometrik özelliklerin gerisinde kalmıştır. Özellikle Yeryüzüne ait

noktaların sınıflandırma performansına doğrudan etkisi olan yatay koordinatların eğitim verisinden çıkarılması bu noktaların tespitin doğruluunu artırmıştır. Ayrıca özellik setlerinin seçiminde açıkça görüleceği üzere renk bilgisinin de sınıflandırmaya etkisi oldukça fazla olmuştur. Kırmızı, yeşil ve mavi renklerin doğruluğa etkisi sırasıyla %28, %24 ve %13 olmuştur.

Çalışmanın sonuç çıktıları, kullanılan iki LiDAR verisi özelinde, sınıflandırma doğruluğunu artırbilmek için birçok özelliğin eğitim verisine gereksiz yere dahil edilmemesi gerektiğini savunan hipotezi desteklediğini göstermiştir. Bu görüşü desteklemek için daha fazla ve farklı arazi tiplerine sahip verilerde testler yapılabilir. Ayrıca fazla sayıda özelliğin ağa girdi olarak verilmesinin de hesaplama yükünü artıracığı göz önünde bulundurulmalıdır. Literatürdeki çalışmalar, LiDAR verisinden özellikler çıkarılırken seçilen komşuluk mesafesi ve biçiminin de geometrik özelliklerin hesaplanmasına etki edeceğini ve farklı değerler üreteceğini rapor etmiştir (Weinmann ve diğerleri, 2017, 2015, Saeys ve diğerleri, 2007, Hao ve diğerleri, 2023, Nong ve diğerleri, 2023).

Derin sinir ağlarının eğitiminde kullanılan verilere karşı daha yanlış bu tip verilerde daha başarılı sonuçlar üretmesi fakat eğitim verisinin tipinden farklı özellikler içeren test verilerinde aynı başarıyı gösterememesi olağan bir sonuctur. Bu durum makine öğrenmesinin en büyük dezavantajlarından birisi olarak gösterilebilir (Özdemir ve diğerleri, 2021). Bu çalışmada da farklı bir arazi tipine sahip LiDAR nokta bulutu ile eğitilen modellerin bir diğer arazi tipine ait noktaları sınıflandırırken nasıl bir performans ortaya koyacağı verilmiştir.

Gelecek çalışmalarla komşuluk seçiminin sınıflandırma performansına etkilerini ve eğitim verisi ile doğrulama verileri arasındaki arazi tipi farklılıklarını dikkate alarak en optimum sınıflandırma sonucunu veren modeller önerilebilir.

ORCID

Fırat URAY  <https://orcid.org/0000-0001-9555-3190>

KAYNAKLAR

Atik, M. E. ve Duran, Z. (2022). Selection of Relevant Geometric Features Using Filter-Based Algorithms for Point Cloud Semantic Segmentation. *Electronics*, 11(20), p. 3310. doi:10.3390/electronics11203310

- Atik, M. E., Duran, Z. ve Seker, D. Z. (2021). Machine Learning-Based Supervised Classification of Point Clouds Using Multiscale Geometric Features. *ISPRS International Journal of Geo-Information*, 10(3), 187. <https://doi.org/10.3390/ijgi10030187>
- Breiman, L. (2001). Random forests. *Machine Learning* 45(1), pp. 5–32.
- Chauhan, I., Brenner, C., Garg, R. D. ve Parida, M. (2014). A New Approach to 3D Dense LiDAR Data Classification in Urban Environment. *Journal of the Indian Society of Remote Sensing*, 42(3):673–678, <https://doi.org/10.1007/s12524-013-0354-4>
- Chehata, N., Guo, L. ve Mallet, C. (2009). Airborne lidar feature selection for urban classification using random forests. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Paris, France, Vol. XXXVIII-3/W8, pp. 207–212.
- CloudCompare (2023). Erişim adresi: <https://github.com/cloudcompare/cloudcompare>.
- Cortes, C. ve Vapnik, V. (1995). Support-Vector Networks. *Machine Learning*, 20, 273-297.
- Demantké, J., Mallet, C., David, N. ve Vallet, B. (2011). Dimensionality based scale selection in 3D lidar point clouds. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Calgary, Canada, Vol. XXXVIII-5/W12, pp. 97–102.
- Etemad, K. ve Chellapa, R. (1997). Discriminant Analysis for Recognition of Human Face Images, *Jos a*, 14(8), 1724-1733.
- Filin, S. ve Pfeifer, N. (2005). Neighborhood systems for airborne laser data. *Photogrammetric Engineering & Remote Sensing*, 71(6), pp. 743–755.
- Grandio, J., Riveiro, B., Soilán, M., Arias, P. (2022). Point cloud semantic segmentation of complex railway environments using deep learning. *Automation in Construction*, 141.
- Grilli, E., Menna, F. ve Remondino, F. (2017). A review of point clouds segmentation and classification algorithms. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42(3/W3), pp. 339-344.

- Guan, H., Li, J., Cao, S. ve Yu, Y. (2016). Use of mobile LiDAR in road information inventory: a review. *International Journal of Image and Data Fusion*, 7(3), 219–242. <https://doi.org/10.1080/19479832.2016.1188860>
- Guo, B., Huang, X., Zhang, F. ve Sohn, G. (2015). Classification of airborne laser scanning data using JointBoost. *ISPRS Journal of Photogrammetry and Remote Sensing*, 100, 71–83. <https://doi.org/10.1016/j.isprsjprs.2014.04.015>
- Hackel, T., Wegner, J. D. ve Schindler, K. (2016). Contour Detection in Unstructured 3D Point Clouds. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1610–1618. <https://doi.org/10.1109/CVPR.2016.178>
- Hu, Q., Yang, B., Xie, L., Rosa, S., Guo, Y., Wang, Z., Trigoni, N. ve Markham, A. (2020). *Randla-Net: Efficient semantic segmentation of large-scale point clouds*. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, pp. 11105–11114. <https://doi.org/10.1109/CVPR42600.2020.0112>
- Hughes, G. F., (1968). On the mean accuracy of statistical pattern recognizers. *IEEE Transactions on Information Theory* 14(1), pp. 55–63.
- IGN. (2023). LIDAR HD. Erişim adresi: <https://geoservices.ign.fr/lidarhd>.
- Ji, H., Yang, S., Jiang, Z., Zhang, J., Guo, S., Li, G., Zhong, S., Liu, Z. ve Xie, Z. (2023). BEMF-Net: Semantic Segmentation of Large-Scale Point Clouds via Bilateral Neighbor Enhancement and Multi-Scale Fusion. *Remote Sensing* 15, no. 22: 5342. <https://doi.org/10.3390/rs15225342>
- Jutzi, B. ve Gross, H. (2009). Nearest neighbour classification on laser point clouds to gain object structures from buildings. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Hannover, Germany, Vol. XXXVIII-1-4-7/W5.
- Kartal, S. ve Sekertekin, A. (2022). Prediction of MODIS land surface temperature using new hybrid models based on spatial interpolation techniques and deep learning models. *Environmental Science and Pollution Research*, Vol. 29(44).
- Kurdi, F. T., Amakhchan, W., Gharineiat, Z., Boulaassal, H. ve Omar, E. K. (2023). Contribution of Geometric Feature Analysis for Deep Learning Classification Algorithms of Urban LiDAR Data. *Sensors* 2023, 23, 7360.
- Kurt, F. (2018). *Evrişimli Sınır Ağlarında Hiper Parametrelerin Etkisinin İncelenmesi* (Yüksek Lisans Tezi). Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Lai, X., Jianhui, L., Li, J., Liwei, W., Hengshuang, Z., Shu, L., Xiaojuan, Q. ve Jiaya, J. (2022). Stratified Transformer for 3D Point Cloud Segmentation. *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. <https://doi.org/10.1109/CVPR52688.2022.00831>
- Lee, I. ve Schenk, T. (2002). Perceptual organization of 3D surface points. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Graz, Austria, Vol. XXXIV- 3A, pp. 193–198.
- Li, W., Wang, F. ve Xia, G. (2020). A geometry-attentional network for ALS point cloud classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 164, 26-40. <https://doi.org/10.1016/j.isprsjprs.2020.03.016>
- Linsen, L. ve Prautzsch, H. (2001). Local versus global triangulations. *Proceedings of Eurographics*, Manchester, UK, pp. 257–263.
- Maturana, D. ve Scherer, S. (2015). Voxnet: A 3D convolutional neural network for real-time object recognition. *Intelligent Robots and Systems (IROS)*, 2015 IEEE/RSJ International Conference on (pp. 922-928). IEEE.
- Neyshabur, B., Bhojanapalli, S., McAllester, D. ve Srebro, N. (2017). *Exploring Generalization in Deep Learning*. 31st Conference on Neural Information Processing Systems (NIPS 2017).
- Niemeyer, J., Rottensteiner, F. ve Soergel, U. (2014). Contextual classification of lidar data and building object detection in urban areas. *ISPRS Journal of Photogrammetry and Remote Sensing*, 87, pp. 152–165.
- Nong, X., Bai, W. ve Liu, G. (2023). Airborne LiDAR point cloud classification using PointNet++ network with full neighborhood features. *Plos One* 18(2), e0280346.

- Özdemir, E., Remondino, F. ve Golkar, A. (2021). An Efficient and General Framework for Aerial Point Cloud Classification in Urban Scenarios. *Remote Sensing*, 13(10). <https://doi.org/10.3390/rs13101985>
- Saeys, Y., Inza, I. ve Larranaga, P. (2007). A review of feature selection techniques in bioinformatics. *Bioinformatics*, 23(19), pp. 2507–2517.
- Schmidhuber, J. (2015). Deep Learning in neural networks: An overview. *Neural Networks*, 61, pp. 85–117. <https://doi.org/10.1016/j.neunet.2014.09.003>
- Seyfeli, S. ve Ok, A. O. (2022). Automatic Classification Of Urban Objects From Mobile Laser Scanning Data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLVIII-4/W4/W3-2022, 171–177. <https://doi.org/10.5194/isprs-archives-XLVIII-4-W3-2022-171-2022>
- Singh, S. ve Girase, S. (2022). Semantic Segmentation of Satellite Images for Water Body Detection. *Algorithms for Intelligent Systems*, Chapter 64, pp. 831-840.
- Uray, F. (2022). *Derin Öğrenme Tekniklerinin Üç Boyutlu Nokta Bulutu Verisi Filtrelemede Kullanılması* (Doktora Tezi). Necmettin Erbakan Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- Uray, F. (2023). LiDAR Nokta Bulutunun Derin Öğrenme ile Sınıflandırılmasında Geometrik Özelliklerin Etkisi. *TUFUAB XII. Teknik Sempozyumu*, 2023.
- Wan, J., Zeng, Z., Qiu, Q., Xie, Z. ve Xu, Y. (2023). PointNest: Learning Deep Multiscale Nested Feature Propagation for Semantic Segmentation of 3-D Point Clouds. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 16, pp. 9051-9066, <https://doi.org/10.1109/JSTARS.2023.3315557>
- Wan, J., Xu, Y., Qiu, Q. ve Zhong, Xie. (2023). A geometry-aware attention network for semantic segmentation of MLS point clouds. *International Journal of Geographical Information Science*, 37(1). <https://doi.org/10.1080/13658816.2022.2111572>
- Wang, L., Zhang, Y. ve Wang, J. (2017). Map-Based Localization Method for Autonomous Vehicles Using 3D-LIDAR. *IFAC-Papers OnLine*, 50(1), pp.276-281.
- Weinmann, M., Jutzi, B., Hinz, S. ve Mallet, C. (2015). Semantic point cloud interpretation based on optimal neighborhoods, relevant features and efficient classifiers. *ISPRS Journal of Photogrammetry and Remote Sensing*, 105, pp. 286–304.
- Weinmann, M. (2016). Reconstruction and analysis of 3D scenes – From irregularly distributed 3D points to object classes. Springer, Cham, Switzerland.
- Weinmann, M., Jutzi, B., Mallet, C. ve Weinmann, M. (2017). Geometric Features And Their Relevance For 3d Point Cloud Classification. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, IV-1/W1(1W1), 157–164. <https://doi.org/10.5194/isprs-annals-IV-1-W1-157-2017>
- Xu, Y., Tang, W., Zeng, Z., Wu, W., Wan, J., Guo, H. ve Xie, Z. (2023). NeiEA-NET: Semantic segmentation of large-scale point cloud scene via neighbor enhancement and aggregation. *International Journal of Applied Earth Observation and Geoinformation*. 119, 103285, ISSN 1569-8432, <https://doi.org/10.1016/j.jag.2023.103285>
- Yıldız Erdemir, M. ve Yastıklı, N. (2018). Lidar Nokta Bulutu Yerel Komsuluk Öznelilik Verileri Kullanılarak Bina Çıkarımı. *VII. Uzaktan Algılama ve CBS Sempozyumu Uzal-Cbs2018*. <https://doi.org/10.15659/uzalcbs2018.7008>
- Yuanwei, B., Zhang, L., Liu, Y., Huang, Y. ve Liu, H. (2023). A local-global feature fusing method for point clouds semantic segmentation. *IEEE Access*, vol. 11, pp. 68776-68790, <https://doi.org/10.1109/ACCESS.2023.3293161>
- Zhan, L., Li, W. ve Min, W. (2023). FA-ResNet: Feature affine residual network for large-scale point cloud segmentation. *International Journal of Applied Earth Observation and Geoinformation*, 18, <https://doi.org/10.1016/j.jag.2023.103259>
- Zheng, M., Lemmens, M. ve van Oosterom, P. (2017). Classification of mobile laser scanning point clouds from height features. *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.* XLII-2/W7, 321–325. <https://doi.org/10.5194/isprs-archives-XLII-2-W7-321-2017>
- Zhou, C. ve Ling, Q. (2023). GAF-Net: Geometric Contextual Feature Aggregation and Adaptive Fusion for Large-Scale Point Cloud Semantic Segmentation. *IEEE Transactions on Geoscience and Remote Sensing*, 61. <https://doi.org/10.1109/TGRS.2023.3336053>