



T.C.
NECMETTİN ERBAKAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**DERİN ÖĞRENME TEKNİKLERİNİ
KULLANARAK HAVA LİDAR NOKTA
BULUTLARININ SINIFLANDIRILMASI**

Fırat URAY

DOKTORA TEZİ

Harita Mühendisliği Anabilim Dalı

**Mart-2022
KONYA
Her Hakkı Saklıdır**

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Fırat URAY

Tarih:

ÖZET**DOKTORA TEZİ****DERİN ÖĞRENME TEKNİKLERİNİ KULLANARAK HAVA LİDAR NOKTA
BULUTLARININ SINIFLANDIRILMASI****Fırat URAY****Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü
Harita Mühendisliği Anabilim Dalı****Danışman: Dr. Öğr. Üyesi Abdullah VARLIK****2022, 150 Sayfa****Jüri****Dr. Öğr. Üyesi Abdullah VARLIK
Prof. Dr. Murat UYSAL
Prof. Dr. Semih EKERCİN
Doç. Dr. Hüseyin ZAHİT SELVİ
Prof. Dr. Mustafa YILMAZ**

Hava LiDAR (Light Detection and Ranging) nokta bulutlarının filtrelenmesi ve sınıflandırılması için birçok teknik geliştirilmiştir. Hesaplama verimliliği ve doğruluğun iyileştirilmesi, LiDAR nokta bulutları ile çalışırken üzerinde durulması gereken etkenlerin başındadır. Derin öğrenme teknikleri son yıllarda görüntü sınıflandırma alanında yoğun şekilde kullanılmaya başlamıştır. Elde edilen yüksek doğruluk ve son teknoloji grafik işlemcileri sayesinde hesaplama yükünün hafiflemesi ile araştırmacılar LiDAR nokta bulutlarını sınıflandırma çalışmalarını makine öğrenmesi alanına özellikle de derin sinir ağlarına kaydırmıştır. Bu tez çalışmasının amacı derin öğrenme tekniği kullanılarak 3 boyutlu (3B) LiDAR nokta bulutlarının filtrelenmesi ve sınıflandırılmasıdır. Derin öğrenme tekniklerinin görüntü işlemedeki gücünden faydalanmak için 3B LiDAR verisini 2 boyutlu (2B) görüntüye çeviren bir teknik önerilmiştir. LiDAR verilerine derin sinir ağına girdi olarak verilmeden uygulanan ön işlemlerden bahsedilmiştir. Sonraki aşamada piksel bazlı sınıflandırma yapılmış, en son aşamada ise sınıflar tekrar 3B nokta bulutuna aktarılmıştır. Eğitim ve test verisi olarak Norveç'in Bergen şehrine ve Kanada'nın Surrey şehrine ait Dayton Annotated Laser Earth Scan (DALES) LiDAR nokta bulutları kullanılmıştır. Doğruluk ölçütleri olarak Precision (Kesinlik), Recall (Duyarlılık) ve F1 puanı hesaplanmış ve Bergen veri seti için sırasıyla ortalama 0.89, 0.84 ve 0.86 ve DALES veri seti için sırasıyla 0.86, 0.89 ve 0.87 değerleri elde edilmiştir. Ayrıca, önerilen yöntemin sınıflandırma performansı çeşitli ticari yazılımların nokta bulutu filtreleme algoritmaları ile kıyaslanmıştır.

Anahtar Kelimeler: Derin Öğrenme, Fotogrametri, LiDAR, Nokta Bulutu, Sinir Ağları, Uzaktan Algılama

ABSTRACT**Ph.D THESIS****CLASSIFICATION OF AIRBORNE LIDAR POINT CLOUDS USING DEEP LEARNING****Fırat URAY****THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
NECMETTİN ERBAKAN UNIVERSITY
DOCTOR OF PHILOSOPHY
IN GEOMATICS ENGINEERING****Advisor: Dr. Abdullah VARLIK****2022, 150 Pages****Jury****Dr. Abdullah VARLIK****Prof. Dr. Murat UYSAL****Prof. Dr. Semih EKERCİN****Assoc. Prof. Hüseyin Zahit SELVİ****Prof. Dr. Mustafa YILMAZ**

Many techniques have been developed for filtering and classifying airborne LiDAR (Light Detection and Ranging) point clouds. Computing efficiency and accuracy are key factors that need to be addressed when working with LiDAR point clouds. Deep learning techniques have been used extensively in image classification in recent years. With the resulting high accuracy and reduced computational burden, the researchers shifted their focus to machine learning techniques for classification of LiDAR point clouds, especially deep neural networks. This thesis aims to create a neural network that classify and filter 3D LiDAR point clouds using deep learning techniques. To take the advantage of the power of deep learning techniques in image processing, a new workflow including conversion method of 3D LiDAR data to 2D images was proposed. Before the LiDAR data is given as input to the deep neural network, the preprocessing steps applied to the data are mentioned. In the next stage, pixel-based classification was made, and at the last stage, the class labels were transferred to the 3D point cloud again. LiDAR point cloud of Bergen city of Norway and DALES dataset, which is covering the Surrey city of Canada, were used as training and test data. Precision, Recall, and F1 scores were calculated as accuracy metrics for two dataset and mean values of 0.89, 0.84, and 0.86 for Bergen dataset and 0.86, 0.89, and 0.87 for Surrey were obtained, respectively. In addition, the classification performance of the proposed method is compared with the point cloud filtering algorithms of various commercial software.

Keywords: Deep Learning, LiDAR, Neural Networks, Photogrammetry, Point Cloud, Remote Sensing

ÖNSÖZ

Bu tez çalışmasının her aşamasında tecrübesinden ve bilgisinden yararlanmamı sağlayan değerli danışmanım Dr. Öğr. Üyesi Abdullah VARLIK hocama teşekkürlerimi sunuyorum. Tez süreci boyunca eleştirileri ve engin bilgileri ile tezin daha da iyileşmesine yardımcı olan hocalarım Prof. Dr. Murat UYSAL ve Doç. Dr. Hüseyin Zahit SELVİ'ye teşekkür ederim.

Necmettin Erbakan Üniversitesi Harita Mühendisliği bölümünde görev yapan tüm hocalarıma da teşekkür ve minnetlerimi sunarım.

Eğitim hayatım boyunca desteklerini hiç esirgemeyen sevgili annem Sevim URAY ve babam Bekir URAY'a, değerli hayat arkadaşım Ayşegül URAY ve kızım Gülce URAY'a teşekkür ve sevgilerimi sunarım.

Fırat URAY
KONYA-2022

İÇİNDEKİLER

ÖZET	1
ABSTRACT.....	2
ÖNSÖZ	3
İÇİNDEKİLER	4
SİMGELER VE KISALTMALAR	6
1. GİRİŞ.....	7
1.1. Tez Çalışmasının Amacı	11
2. KAYNAK ARAŞTIRMASI	12
3. MATERYAL VE YÖNTEM.....	16
3.1. LiDAR Sistemleri	16
3.1.1. LiDAR verilerinin sınıflandırılması.....	19
3.1.2. Sınıflandırma doğruluk ölçütleri.....	20
3.2. Performans Karşılaştırmasında Kullanılan Yazılımlar	22
3.3. Derin Öğrenme	24
3.3.1. Yapay sinir ağları (YSA)	26
3.3.2. Evrişimli sinir ağları (ESA)	30
3.3.3. Tamamen evrişimli sinir ağları (TESA)	33
4. UYGULAMA	36
4.1. Hava LiDAR Veri Setleri	36
4.1.1. Bergen 2018 LiDAR nokta bulutu.....	36
4.1.2. DALES LiDAR nokta bulutu	37
4.2. LiDAR Nokta Bulutlarının Ön İşlem Adımları	39
4.2.1. Nokta bulutu-görüntü dönüşümü	40
4.3. Ağ Mimarisinin Oluşturulması	43
4.4. Derin Sinir Ağının Eğitilmesi	45
4.4.1. 2B görüntüden 3B nokta bulutuna dönüşüm	73
5. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	74
5.1. Sınıflandırma Sonuçlarının Performans Analizi.....	74
5.1.1. Bergen 2018 veri seti için sınıflandırma sonuçları	74
5.1.2. DALES veri seti için sınıflandırma sonuçları.....	101
5.2. Sınıflandırma Sonuçlarının Yorumlanması	141
6. SONUÇLAR VE ÖNERİLER.....	144
6.1. Sonuçlar	144
6.2. Öneriler	145

7. KAYNAKLAR	146
---------------------------	------------



SİMGELER VE KISALTMALAR

Kısaltmalar

2B	: İki Boyutlu
3B	: Üç Boyutlu
ADAM	: Adaptive Moment Estimation
ASPRS	: American Society of Photogrammetry and Remote Sensing
ATIN	: Adaptive Triangulated Irregular Network
CPU	: Central Processing Unit
DÜA	: Düzensiz Üçgen Ağı
ESA	: Evrişimli Sinir Ağları
GPS	: Global Positioning System
GPU	: Graphic Processing Unit
ID3	: Iterative Dichotomiser 3
IMU	: Inertial Measurement Unit
ISPRS	: International Society for Photogrammetry and Remote Sensing
İHA	: İnsansız Hava Aracı
LAS	: Laser File
LiDAR	: Light Detection and Ranging
MLP	: Multi-Layer Perceptron
QTM	: Quick Terrain Modeler
ReLU	: Rectified Linear Unit
SAM	: Sayısal Arazi Modeli
SGD	: Stochastic Gradient Descent
SVM	: Support Vector Machine
SYM	: Sayısal Yükseklik Modeli
TESA	: Tamamen Evrişimli Sinir Ağı
YSA	: Yapay Sinir Ağları

1. GİRİŞ

Günümüzde uzaktan algılama teknolojileri özellikle büyük ölçekli alanların izlenmesi ve haritalanmasını kapsayan uygulamalarda klasik ölçüm yöntemlerinin yerini kısmen almaya başlamıştır. Uydulardan, havadan veya yerden elde edilen görüntüler ile yersel veya havadan lazer tarama teknolojilerinin tümü uzaktan algılama yöntemleridir. Haritalamanın dışında üç boyutlu kent ve bina modellemeleri, arazi kullanımının belirlenmesi, doğal afetlerin izlenmesi gibi uygulamalarda uzaktan algılamanın çalışma alanına girmektedir. Uydu görüntüleri, lazer tarama yöntemleri, hava veya yer fotoğrafları ile yeryüzünün birebir yükseklik bilgisini içeren 3B Sayısal Yükseklik Modeli (SYM) üretilebilir. Görüntülerden 3B bir model üretmek için çalışma alanının bindirmeli resimleri alınarak sonrasında ise görüntü eşleme teknikleri ile tüm resimler işlenerek çalışma alanına ait 3B konumsal bilgi içeren noktalar fotogrametrik olarak hesaplanır. Lazer tarama tekniği ile bu 3B noktalar direkt lazer sensörü aracılığıyla anlık olarak toplanabilir ve depolanabilmektedir. Görüntülerden hesaplanan noktaların konumsal doğrulukları her zaman yüksek olmayabilir bunun sebebi birçok resmin bindirmeli işlenmesi ve eşlenik noktaların bazen doğru hesaplanamamasıdır (Canaz vd., 2013). Lazer taramada ise 3B noktalar anında yüksek doğrulukta toplanabilir. Elde edilen bu noktalar ile 3B yükseklik modeli üretilebilir. Lazer tarama teknolojisi veya genel adıyla LiDAR yönteminde temel ölçüm mantığı lazer ışınının objelerin yüzeyinden yansması ve ölçülmesidir. Bu sayede kısa sürede yoğun ve yüksek doğrulukta konumsal bilgi içeren noktalar toplanabilir. Bu üç boyutlu noktaların oluşturduğu veriye nokta bulutu adı verilmektedir. LiDAR yöntemleri de kendi içerisinde verinin toplanma şekli olarak ikiye ayrılırlar. Bunlar yersel lazer ve havadan lazer tarama teknikleridir. Yersel lazer tarama tekniği yeryüzü üzerinde konumlandırılan lazer sensörünün 3B nokta toplaması ile tanımlanabilirken havadan lazer tarama insanlı veya insansız hava araçlarına monte edilen lazer sensörleri ile havada seyir halinde daha geniş alanların 3B nokta verisini toplamasıdır. Havadan lazer tarama teknolojisi diğer uzaktan algılama yöntemlerine göre daha hızlı konumsal veri toplaması ve hava şartlarından etkilenmemesi sebebiyle diğer yöntemlerden ayrılır. SYM'ler yeryüzü üzerindeki her türlü insan yapımı olan ve olmayan objelerin üç boyutlu konumsal verisini içerirken sadece çıplak arazi yüzeyini temsil eden bir başka deyişle yeryüzüne ait olmayan obje verilerinin kaldırıldığı modele ise Sayısal Arazi Modeli (SAM) ismi verilir. Bu ürün ise geniş çapta mühendislik ve çevre uygulamalarında kullanılan bir yüzey modelidir. Bu uygulamalar kapsamında yapılacak

her türlü projenin doğruluğu ile SAM'nin doğruluğu orantılı olduğu için bu modelin araziyi en doğru şekilde temsil etmesi vazgeçilmez bir unsurdur. Bu noktada devreye lazer tarama verilerinden yer noktaları ile yeryüzüne ait olmayan noktaları ayırmak başka deyişle nokta bulutu filtreleme işlemi girer. Yer ve obje noktaları birbirlerinden ayırdıktan sonra yer noktaları kullanılarak enterpole edilen yüzey SAM'yi temsil eder. SAM üretiminde lazer tarama verilerinin işlenmesi aşamasında nokta filtreleme iş yükünün %80 gibi bir geniş kısmını oluşturur.

LiDAR nokta bulutu verilerinin filtrelenmesi konusunda araştırmacılar son yirmi yıldan bu yana optimum performansla en yüksek doğruluğu verecek algoritmaları geliştirmeye devam etmektedir. Yüksek doğruluğun yanında nokta bulutu filtreleme algoritmalarının geniş alanlar içinde olabildiğince kısa sürede bu işlemi başarılı şekilde yapabilmesi geliştiricilerin araştırma konusu arasındadır. Literatürde önerilen LiDAR verisi filtreleme algoritmalarını genel olarak beş ana kategoride toplamak mümkündür. Bunlar eğim tabanlı, matematiksel morfoloji tabanlı, DÜA (düzensiz üçgen ağı – *triangular irregular network*) tabanlı, enterpolasyon tabanlı ve bölütleme tabanlı yöntemlerdir. Eğim tabanlı algoritmalar iki bitişik noktanın yüksekliklerinin farklı olması durumunda bahsi geçen noktaların farklı sınıflara ait olduğunu varsayar. Bu yöntemin hızlı ve kolay uygulanabilir olması yanında farklı arazi tiplerinde farklı eğim eşik değerlerine bağımlı olması bir dezavantaj yaratır (Brzank vd., 2005; Vosselman, 2000). Matematiksel morfoloji tabanlı algoritmalar ise nokta bulutuna bir dizi üç boyutlu morfolojik işlemlerin uygulanması ile çalışır. Tekniğin temeli morfolojik operatörleri uygularken kullanılan pencere boyutunun büyüklüğünü optimum değere ayarlamakta yatar. Zhang vd. önerdiği çalışmada değişen pencere boyutu tekniği önererek sabit boyutta ki pencerenin yol açtığı filtreleme problemlerinin önüne geçmiştir (Zhang vd., 2003). DÜA tabanlı teknikte ise karelajlara ayrılmış veride her karelaj içerisindeki en düşük kota sahip noktalar seçilerek bu noktalardan üçgenleştirilmiş bir yüzey oluşturulur (Axelsson, 2000). Ardından algoritma mevcut üçgenler ile kalan noktalar arasından eğim ve mesafeye dayanan parametreler ile üçgen yüzeye yeni noktalar ekler. Dezavantajı ise düşük kota sahip gürültülü noktaların oluşturulan üçgen yüzeye etkisi ile filtreleme performansına olumsuz etki etmesidir. Enterpolasyon tabanlı algoritmaların temel prensibi ise farklı enterpolasyon yöntemleri ile noktalardan geçirilen yüzeyler ile tüm noktaların bu yüzeye yükseklik farkları karşılaştırmasıdır. Lineer enterpolasyon yöntemini kullanan araştırmacılar, obje noktalarının oluşturulacak yüzeye olan etkisini en aza indirmek için iteratif bir strateji uygulamışlardır (Kraus vd., 1998; Lohmann vd.,

2000). Bölütleme tabanlı yöntemler ilk aşamada birbirine komşu noktaları bir matematiksel düzleme göre üç farklı parametre ile test ederek kademeli olarak gruplandırır. Sonraki aşamada bu gruplar kullanılarak uyarlanabilir bir ağırlık fonksiyonu eklenen küçük kareler yöntemi ile enterpolasyon hesaplanarak yer noktası olmayan objelere ait gruplara daha küçük ağırlıklar atanır. Deneysel bir çalışmada üzerinde iki bina bulunan küçük ve düz bir arazide enterpole edilen yüzey, binaların olduğu bölgede hata yapmıştır. Bunun sebebi olarak obje noktalarını kaldırması gerekirken daha küçük ağırlıklar atayarak yüzey enterpolasyonuna dâhil ederek yüzeyi hatalı olarak daha yüksek kotta hesapladığı ve filtreleme performansını olumsuz etkilediği rapor edilmiştir (Jacobsen vd., 2003; Tóvári vd., 2005).

Yapılan tez çalışmasında havadan LiDAR ile elde edilen 3B nokta bulutu verisi kullanılmıştır. Bu kapsamda klasik filtreleme algoritmalarından farklı olarak son birkaç yıldır özellikle görüntü işleme alanında başarısını ispatlamış makine öğrenmesi tekniklerinden birisi olan derin öğrenme yöntemleri kullanılarak LiDAR verilerinin sınıflandırılması ve filtrelenmesi araştırılmış ve yeni bir yöntem sunulmuştur. LiDAR verisinin sınıflandırılması obje noktalarının da kendi içerisinde türlerine göre kategorilere (bina, bitki örtüsü, yol vb.) ayrılması anlamına gelmektedir. Derin öğrenme tekniklerinin diğer makine öğrenmesi yöntemlerinden farkı öğrenilebilir birçok parametre içeren çok sayıda katmanın üst üste istiflenmesi ile öğrenme işlemini gerçekleştirmesidir. Bilgisayar donanımlarının hızlı teknolojik değişimleri ile birlikte araştırmacılar farklı uygulamalar kapsamında devasa boyutlardaki verileri okuyabilme ve işleyebilme olanağına sahip olmuştur. Bu teknolojik değişimlerin en iyi örneklerinden birisi grafik kartlarının işlemci ve hafızası olarak gösterilebilir. Derin öğrenme tekniklerinin ortaya konması 1980'li yıllara kadar dayanmasına rağmen çok fazla işlem yükü ve hafıza gerektiren bu hesaplama yöntemleri donanım kısıtlamaları sebebiyle uzun süre pratik bir seçenek olmamıştır (Lecun vd., 2015). Son 10 yıldır bilgisayar donanımlarındaki teknolojik ilerlemeler ile araştırmacılar özellikle görüntü işleme uygulamalarında derin öğrenmenin avantajlarından faydalanarak mevcut görüntü sınıflandırma tekniklerinden daha yüksek performansa sahip yapay sinir ağları (YSA) mimarileri geliştirmişlerdir. Sadece görüntü işleme değil yüz ve ses tanıma, insansız araç kullanımı, savunma ve güvenlik sanayii ve sağlık sektöründe derin öğrenme teknikleri yaygın olarak tercih edilmeye ve kullanılmaya başlanmıştır.

Bu tez çalışmasında, haritacılık alanında da araştırmacıların ilgisini çeken ve LiDAR nokta bulutu verilerinin işlenmesi uygulamalarında son birkaç yıldır kullanılan

derin öğrenme teknikleri araştırılmıştır. Nokta bulutu verilerinin filtrelenmesi ve sınıflandırılması uygulamalarında kullanılan derin öğrenme teknikleri temel alınarak yeni bir ağ oluşturulmuş ve bu ağın LiDAR nokta bulutlarını sınıflandırma performansı incelenmiştir. Çalışmanın ilk bölümünde LiDAR nokta bulutu verileri önışlemeden geçirilerek 2B görüntüye dönüştürülmüştür. 3B nokta bulutunun 2B'ye dönüştürülmesinin nedeni kullanılacak derin öğrenme ağı mimarisinin görüntü verilerini girdi olarak almasıdır. Havadan LiDAR tekniğinde 3B noktalar yeryüzünün üstünden kuş bakışı bir açıyla toplandığı için 2B görüntüye dönüşüm işleminde veri kaybı fazla olmaz (Rizaldy vd., 2018). LiDAR verisi önce derin sinir ağına girdi olarak verilecek resim boyutlarında bölünür. Bu bölünen her parça daha sonra görüntüye dönüştürülecektir. Her nokta bulutu parçası belirlenen sabit bir boyutta karelejlara ayrılarak her bir karelej görüntüdeki bir piksele karşılık gelecek şekilde görüntü dönüşümü tamamlanır. Karelejlardaki birden fazla nokta arasından en düşük ve yüksek kota sahip noktalar için bu noktaların yükseklik değerleri kullanılarak iki ayrı gri resim elde edilir. Bu noktaların hangi sınıfa ait olduğunu belirten etiket görüntüleri de aynı şekilde gri resim olarak üretilir ve eğitim esnasında derin sinir ağına referans veri olarak tanımlanır. Çalışmanın ikinci bölümünde derin sinir ağının mimari yapısı oluşturulur. Biyomedikal görüntülerin sınıflandırılmasında oldukça başarılı olan Ronneberger vd. tarafından geliştirilen U-Net ağı mimarisi bu tez çalışmasında temel alınmıştır (Ronneberger vd., 2015). Tez kapsamında U-Net mimarisinden türetilen PixU-net olarak isimlendirilen bir Tamamen Evrişimli Sinir Ağı (*Fully Convolutional Neural Network - TESA*), 2B'ye dönüştürülmüş LiDAR verileri ile eğitilmiş ve test verileri performans değerlendirilmesi yapılarak sınıflandırma sonuçları yine 2B olarak elde edilmiştir. Bu sonuçlar tekrar bir dönüşüm işleminden geçerek 3B nokta bulutuna aktarılmıştır. LiDAR nokta bulutunun görüntüye dönüşümü, derin sinir ağının yapısı ve eğitimi, nokta bulutunun sınıflandırılması ve sınıflandırılmış görüntülerinin nokta bulutuna dönüştürülmesi gibi metodolojik bölümler tezin materyal ve yöntem başlığı kısmında ayrıntılı olarak anlatılmıştır.

1.1. Tez Çalışmasının Amacı

Tez çalışmasının amacı LiDAR nokta bulutunda yer noktaları ve obje noktalarını sınıflandıran ve filtreleyen bir derin YSA modeli oluşturmaktır. Temel alınan U-Net ağ mimarisinden türetilen Tamamen Evrişimli Sinir Ağı (TESA), LiDAR verisinden dönüştürülen görüntüleri piksel tabanlı olarak sınıflandırmaktadır. Aynı alana ait en düşük ve en yüksek kotlu noktalardan faydalanılarak oluşturulan iki nokta bulutu görüntüsünü eş zamanlı sınıflandırıp tahminleri birleştiren derin sinir ağının elde ettiği sonuçlar ile literatüre yeni bir yöntem kazandırması bu çalışmanın ana amacıdır.

Tez çalışması kapsamında ayrıca ticari yazılımların sınıflandırma performansları ile önerilen derin sinir ağının sınıflandırma sonuçları karşılaştırılmıştır. Bu amaçla Rapidlasso firmasına ait LAStools, Terrasolid firmasına ait TerraScan ve Applied Imagery firmasına ait Quick Terrain Modeler (QTM) yazılımları ile test LiDAR verileri sınıflandırılmıştır. Sınıflandırılan LiDAR nokta bulutları yine tez kapsamında geliştirilen yazılım ile değerlendirilmiştir.

2. KAYNAK ARAŞTIRMASI

Son yıllarda yeryüzünün, orman örtüsünün ve şehirlerin 3B modellerinin üretilmesi fotogrametrik araştırmaların ana odak noktası olmuştur. Havadan LiDAR veya lazer tarama teknolojisi karmaşık dikey yapıları ve yer yüzeyini çok yüksek hassasiyetle dijital ortama aktarma yeteneği sayesinde yukarıda bahsedilen uygulamalarda sıklıkla tercih edilir duruma gelmiştir.

LiDAR sistemlerinin bu avantajları göz önünde bulundurulduğunda, 3B bina modellemesi, elektrik güç hatlarının denetimi, deformasyon izlenmesi ve arazi örtüsünün sınıflandırılması gibi birçok mühendislik uygulamasında kullanılmaktadır (Cheng vd., 2019). Bu uygulamalara altlık olacak veriyi sağlamak için ise SAM üretilmesi elzemdir. Bir başka deyişle 3B nokta bulutundaki yeryüzüne ait noktaların obje noktalarından ayrılması gerekmektedir. Bu işleme nokta bulutu filtreleme adı verilir. Obje noktalarının da kendi içerisinde türlerine göre ayrılması işlemi de sınıflandırma olarak isimlendirilir. Özellikle son yirmi yıldır LiDAR verilerinin filtrelenmesi üzerine oldukça fazla araştırma yapılmıştır (Axelsson, 1999; Q. Chen vd., 2007; Evans vd., 2007; Kraus vd., 1998; Lohmann vd., 2000; Meng vd., 2009; Sithole vd., 2004, 2005; Zhang vd., 2003; Zhang vd., 2005). Bu bölümde klasik filtreleme algoritmalarından kısaca bahsedilirken tez kapsamında konusu araştırılan derin sinir ağları ile LiDAR nokta bulutu filtreleme ve sınıflandırma teknikleri ayrıntılı şekilde incelenmiştir.

Eğim tabanlı algoritmalar ilk olarak Vosselman tarafından önerilmiştir (Vosselman, 2000). Arazi yüzeyinin keskin değişiklikler barındırmadığını varsayarak, iki komşu noktanın arasındaki eğim belli bir eşik değerin üstündeyse noktalarda birisi obje noktası olmalıdır fikrini savunur. Fakat bu varsayım uçurum veya tepe gibi engebeli arazi tipleri söz konusu olduğunda başarısızdır. Bu sorunu çözmek için Susaki, eşik değerleri yerel arazi tiplerine göre düzenleyerek bu yöntemi değiştirmiştir (Susaki, 2012). Bu değişiklik ile yöntem, karmaşık arazi tiplerinde daha iyi sonuçlar vermiştir. Morfolojik tabanlı algoritmalar ise her zaman kademeli uyarlanan stratejileri benimser. Filtreleme eşik değerleri, filtreleme penceresinin boyutu değişikçe uyarlanabilir şekilde hesaplanır (Zhang vd., 2003). Bu tekniğin ana sorunu, uygun bir filtreleme penceresi ayarlamasıdır. Büyük bir filtreleme penceresi arazi detaylarını düzleştirirken, daha küçük bir pencere büyük objeleri filtreleyemez. Hui vd., kademeli morfolojik yaklaşımı çok seviyeli Kriging enterpolasyon tekniği ile birleştirerek geliştirmiştir (Hui vd., 2016). DÜA tabanlı algoritmalar, filtreleme için aşamalı bir yöntem kullanır. Karelajlara ayrılan nokta

bulutunda her kareladaki en düşük kotlu noktalar kullanılarak bir DÜA yüzeyi oluşturulur. Ardından, her noktanın üçgenlenmiş ağ yüzeyine göre açısı ve mesafesi hesaplanır. Açısı ve mesafeler daha önceden tanımlanmış eşik değerlerden küçük ise noktalar DÜA'ya eklenir. Bu işlem şartları sağlayan noktalar bitene kadar tekrarlanır (Axelsson, 2000). Filtreleme doğruluğu kademeli olarak iyileşirken, oluşturulan DÜA arazi yüzeyini daha ayrıntılı şekilde temsil eder. İlk oluşturulan DÜA, filtreleme sonuçlarına büyük bir etkiye sahiptir. İlk olarak seçilen düşük kotlu noktalar doğru şekilde seçilmezse nihai sonuçlarda daha büyük filtreleme hatası oluşur. Bu problemi çözmek için Zhao vd., morfolojik açınım operatörü uygulayarak üçgenleme için daha doğru nokta seçimini önermiştir. Yaptığı çalışmanın deneysel sonuçları, klasik yöntemin sağlamlığını arttırdığını göstermiştir (Zhao vd., 2016). Enterpolasyon tabanlı algoritmaların temeli olarak görülen çalışmada tüm noktalara eşit ağırlık katsayısı verilerek oluşturulan referans bir yüzeyden tüm noktaların bu yüzeyle arasındaki yükseklik farkları hesaplanır. Yüzeyin altında kalan noktalara daha büyük ağırlık katsayısı verilirken, yüzeyin üstünde kalan noktalara daha küçük ağırlıklar verilir. Bu işlem iteratif olarak hesaplanırken her seferinde küçük ağırlıklara sahip noktalar filtrelenerek kaldırılır. İterasyon işlemi önceden belirlenen eşik değerin üzerinde ağırlık katsayısına sahip nokta kalmayınca dek devam eder (Kraus vd., 1998).

Klasik filtreleme algoritmaları önceden tanımlanmış kurallara ve basit eşik değerlerine dayanan yöntemler olurken daha sonrasında yerini Destek Vektör Makineleri (*Support Vector Machine*) ve Rastgele Orman (*Random Forest*) gibi makine öğrenmesi tekniklerine bırakmıştır (Serna vd., 2014; Tran vd., 2018). Bu tekniklerin sınırlaması ise veri özelliklerindeki değişikliklere duyarlı olan el yapımı özelliklere gereksinim duymasındır. Genelde bu yöntemler her bir noktayı bağımsız şekilde sınıflandırırken komşu noktalara atanan etiketleri hesaba katmaz (Wang vd., 2019).

Son yıllarda bilgisayarla görme alanında gerçekleşen gelişmeler, 3B nokta bulutu verilerine ulaşılabilirliğini oldukça arttırmıştır. Dijital verilerinin benzeri görülmemiş hacmi, çeşitliliği ve ivmelenmesi, bu verilerin yönetimi ve işlenebilir veriye dönüştürülmesi için kullanılan mevcut kapasiteleri aşmaktadır. Günümüzde derin öğrenme tekniklerine olan ilgi oldukça artmıştır. Evrimsel Sinir Ağlarının (*Convolutional Neural Networks - ESA*) gelişimi, büyük ölçekli veri setlerinin ve yüksek performanslı hesaplama kaynaklarının ulaşılabilirliği ile birlikte derin öğrenme eşi görülmemiş bir popülerlik kazanmıştır. 2B ESA'ların görüntü etiketleme (*image labeling*), anlamsal bölümlendirme (*semantic segmentation*), nesne algılama (*object detection*) ve hedef izleme

(*target tracking*) gibi çeşitli görüntü tanıma problemlerindeki başarısı, bu yöntemlerin 3B anlamsal bölümlenme problemlerine de uygulanmasına teşvik etmiştir. Nokta bulutlarının homojen olmayan ve düzensiz yapıları nedeniyle 2B ESA'ların doğrudan 3B sınıflandırma işlemine genişletilmesi pratikte olanaksızdır. Böyle bir durumda görüntü tabanlı ESA'lar ile çalışabilmek için girdi verilerinin görüntüye dönüştürülmesi gerekmektedir. Bu sebeple, birçok derin öğrenme yaklaşımı 3B verilerin normal 2B görüntülere dönüştürülmesini ve ardından 2B etiketlerin 3B verilere geri dönüşümünü izler, bu şekilde 3B verilerin anlamsal bölümlenmesi yapılır (Chen vd., 2021).

Qi vd., sınıflandırma sonuçlarını iyileştirmek için çoklu görünüm yaklaşımı içeren iki farklı ağ mimarisini hacimsel yöntemlerle birleştirmiştir (Qi vd., 2016). Çalışmalarında 3B objenin farklı açılardan 2B görünümünü oluşturarak her bir görüntü ağ tarafından işleme katılır. Su vd., benzer şekilde 3B objenin farklı konumlardan elde edilmiş 2B görüntülerini işlediği ve bu görüntüleri sınıflandırdığı bir ESA önermiştir (Su vd., 2015). Görüntüler üzerinde piksel tabanlı sınıflandırma yapabilen tam evrişimli ağ tasarımı Boulch vd., nokta bulutunun çoklu 2B görüntülerini kullanan bir tam evrişimli sinir ağı (TESA) önermiştir (Boulch vd., 2017). Lawin vd., 3B nokta bulutu verisinin renk, derinlik ve yüzey normalleri özelliklerini kullanarak 2B görüntülere dönüştürerek tasarladıkları 2B ESA da anlamsal bölümlenme yapmıştır (Lawin vd., 2017). Yersel tekniklerle elde edilen nokta bulutunda araç tanıma çalışmasında voksellerle çalışan bir 3B TESA, Li vd., tarafından önerilmiştir (Li vd., 2017). Bir diğer çalışmada yine voksellere ayrılan nokta bulutunu yedi farklı kategoride sınıflandıran bir 3B TESA ağ önerilmiştir (Huang vd., 2016). Derin öğrenme yöntemlerinin nokta bulutu sınıflandırma çalışmalarında kullanıldığı diğer yaklaşımlar da 3B nesne tanıma üzerine dayalı bir teknik (Wu vd., 2015), 3B voksel tabanlı bir diğer teknik ise Maturana vd., tarafından önerilmiştir (Maturana vd., 2015). Bu bahsedilen çalışmalar hava LiDAR nokta bulutuna nispeten daha yoğun ve daha küçük alanları kapsayan, yersel LiDAR teknikleri ile elde edilen, bazıları da iç mekâna ait nokta bulutu verileri üzerinde uygulanan yöntemlerdir. Hava LiDAR verileri, yersel tekniklerinden farklı olarak çalışma alanından kuş bakışı açıyla veri toplayan ve daha geniş alanları kapsayan bir yöntemle elde edilir. Bu nedenle yukarıda bahsedilen derin öğrenme tekniklerini hava LiDAR nokta bulutu verilerini sınıflandırma çalışmalarında uygulamak için araştırmacılar farklı çözümler önermişlerdir. Araştırmacıların çoğunlukla 3B nokta verilerini 2B görüntülere çevirmelerinin başlıca nedeni ise konumsal bilgi içeren milyonlarca nokta verisinin bir sinir ağına katılarak eğitilmesi oldukça fazla hafıza ve işlemci gücü gerektirdiğinden çok

pratik olmayan bir yöntemdir, ayrıca ESA'ların görüntü işlemedeki gücünden tamamen faydalanmak için 3B-2B dönüşümü tercih edilmiştir. Nokta bulutlarının sırasız ve düzensiz yapıda olması araştırmacılar için bir başka problem teşkil etmektedir. Noktaları direkt kullanarak eğitilen derin sinir ağı PointNet isimli teknik (Qi vd. 2017) literatüre bu konu üzerinde öncü bir çalışma olarak kazandırılmıştır.

Hu vd., yaptığı çalışmada hava LiDAR nokta bulutunu yer ve obje noktaları olarak sınıflandıran, nokta-görüntü dönüşümüne dayalı bir ESA önermiştir. Komşu noktalar arasındaki kot farkını hesaba katan bu teknik yer noktaları ile obje noktaları arasında belirli bir yükseklik farkı olduğunu varsayar ve ESA'nın bunu ayırt edip öğrenebilmesini sağlar. Çalışmalarında toplamda 17 milyon nokta içeren bir nokta bulutu verisi ile eğittikleri ağı, International Society for Photogrammetry and Remote Sensing (ISPRS) tarafından sağlanan veri setini filtreleyerek test etmiş ve karşılaştırdıkları diğer algoritmalara kıyasla oldukça düşük hata oranı elde etmişlerdir (Hu vd., 2016). LiDAR verisi ve yüksek çözünürlüklü hava resimlerini birleştirerek bir TESA'nın eğitildiği çalışmada anlamsal bölümlenmede oldukça yüksek bir doğruluk skoru elde edilmiştir (Liu vd., 2017). 3B nokta bulutu verilerini çeşitli öznitelikleri ile birlikte çok katmanlı 2B görüntülere dönüştürdükleri çalışmada Rizaldy vd., LiDAR sistemlerinin kendine has özelliklerinden yoğunluk ve çoklu dönüş numarası bilgilerini birer görüntü katmanı olacak şekilde dönüştürerek ve çok ölçekli hale getirerek eğitiminde kullandıkları bir TESA önermişlerdir (Rizaldy vd., 2018). Yousefhussein vd., PointNet yöntemini temel alarak geliştirdikleri teknikle LiDAR nokta bulutu verilerini ve özniteliklerini direkt olarak kullanan bir TESA önermişlerdir (Yousefhussien vd., 2018). Başka bir çalışmada Huang vd., PointNet tekniğini temel alan, nokta bulutu verisini çok ölçekli alt kümelere bölerek her kümeden noktaların özniteliklerini derin sinir ağına katarak eğiten bir teknik geliştirmiştir (Huang vd., 2020).

3. MATERYAL VE YÖNTEM

Bu bölümde LiDAR sistemlerinden, hava LiDAR sistemleri ve ürünü olan 3B nokta bulutu verisinden, nokta bulutunun sınıflandırılması ve başarı metriklerinden, tez kapsamında performans karşılaştırması için kullanılan ticari yazılımlardan, yapay sinir ağları, derin öğrenme tekniği ve tez çalışmasında kullanılan veri setlerinden bahsedildi.

3.1. LiDAR Sistemleri

LiDAR, görünür veya yakın kızılötesi lazer ışını üreten aktif bir uzaktan algılama sistemidir. Bu ışın bir sensörden iletilir, bir nesneye ya da nesnelere çarparak geri yansır, bu yansımalar geri dönüş adı verilir. LiDAR sistemleri kullanıldıkları amaca ve projeye göre üç ana grup altında toplanmaktadır. Bunlar;

- Hava LiDAR (*Airbone LiDAR*),
- Yersel LiDAR (*Terrestrial LiDAR*),
- Mobil LiDAR (*Mobile LiDAR*)'dır.

Hava LiDAR sistemine entegre edilmiş Küresel Konumlama Sistemi (*Global Positioning System - GPS*) ve İnersiyal Ölçme Ünitesi (*Inertial Measurement Unit - IMU*) bilgileri ile birleştirilen bu mesafe bilgisi, lazer ışımına ait toplam dönüş sayısı ve yoğunluk değeri (yansıyan ışının gücü) bilgileriyle kayıt edilir ve nesnelere 3B temsil edilebilmesine olanak sağlar (Şekil 3.1). LiDAR sistemleri bahsedilen bu işlemi saniyede yüz binlerce kez kayıt edebilir ve 3B nokta bulutlarını koordinatlandırarak yeryüzünü sayısal ortama aktarmaya olanak sağlar (Wang vd., 2018). 3B koordinat sisteminde tanımlı nokta bulutu verileri çoğunlukla Laser (LAS) ve ascii formatında saklanır. ASPRS (Amerikan Fotogrametri ve Uzaktan Algıma Topluluğu) tarafından geliştirilen LAS dosya formatı üç boyutlu nokta bulutu verilerini depolanmasını ve kolayca paylaşılabilmesini sağlamaktadır (ASPRS, 2013). LAS dosya formatı nokta bulutu sınıfları ve kodları Çizelge 3.1'de verilmiştir.

Günümüzde piyasada bulunan hava LiDAR sistemleri çoklu dönüş adı verilen teknolojiye sahip olup ilettiği her bir lazer ışını için dört adet dönüş kaydedebilir. Çoklu dönüş özelliği, tek bir lazer ışınının ağaçların dal ve yapraklarından ilk temasta yansıma yapması sonrasında yaprakların içinden geçerek bir sonraki nesneyle teması ve tekrar geri

yansımaları şeklinde gerçekleşir. Böylece tek bir lazer ışını ile dört farklı nesneden konumsal ve spektral bilgi kayıt altına alınabilir. Lazer sensörün kaydettiği lazer ışınları ve sensöre dönüş yapan enerji ve ekoların zeminden yansıdığı örneklem bölgesine LiDAR ayak izi (*footprint*) adı verilir. Lazer sensörünün görüş alanının yeryüzü üzerindeki anlık yansıması LiDAR ayak izinin boyutuna eşittir (Şekil 3.2). Her lazer ışını konumsal bilgi (X, Y ve Z) ile beraberinde yoğunluk, dönüş numarası, toplam dönüş sayısı, sınıflandırma numarası, RGB renk değerleri, GPS zamanı, tarama açısı ve tarama yönü gibi ek bilgiler taşır. LiDAR verilerinin düzensiz ve karmaşık yapısından dolayı nokta bulutu olarak isimlendirilirler. LiDAR nokta bulutlarını kullanım amaçlarına göre daha anlamlı bilgilere dönüştürmek için veri içindeki yer yüzü, bina, bitki örtüsü, su, yol, köprü, güç direkleri, güç kabloları gibi yüzey elemanları sınıflandırılır (Uray, 2016).

Lazer ışının havada seyrettiği süre, nesnelere etkileşimi ve sensöre geri dönmesi esnasında geçen süre ölçülerek nesne ve LiDAR sensörü arasındaki mesafe hesaplanır. Denklem 3.1’de verildiği üzere;

R; mesafe,

Δt ; lazer ışınının sensörden çıkış ve dönüşü sırasında geçen zaman,


c ; ışının hızını ifade etmektedir.

$$R = \frac{(\Delta t \times c)}{2} \quad (3.1)$$


Yukarıda ki eşitliğin ikiye bölünmesinin nedeni lazer ışınının aynı mesafeyi gidiş ve dönüş olarak kat etmesidir (Habib, 2018).

Çizelge 3.1. LAS dosya formatı nokta bulutu sınıfları şeması

Sınıf Kodu	Açıklama
0	Yapay nokta
1	Sınıflandırılmamış
2	Yer
3	Düşük bitki örtüsü
4	Orta bitki örtüsü
5	Yüksek bitki örtüsü
6	Bina
7	Gürültü noktası
8	Boşa ayrılmış
9	Su



Şekil 3.1. Hava LiDAR Sistemleri şeması (<https://gmv.cast.uark.edu/scanning-2/airborne-laser-scanning/>)



Şekil 3.2. Hava LiDAR çoklu dönüş sinyalleri ve ayak izi (Diaz, 2011)

3.1.1. LiDAR verilerinin sınıflandırılması

Çoğu mühendislik uygulaması için yer yüzeyini mükemmel bir şekilde temsil eden bir altlık, projelerin doğruluğunu direkt etkileyen önemli bir referanstır. SYM ve SAM üretiminde LiDAR nokta bulutları en çok tercih edilen veri toplama tekniği olarak yer etmiştir. Günümüzde sadece uçak ile değil İnsansız Hava Araçlarına (İHA) monte edilmiş lazer tarama sistemleri ile de havadan LiDAR verisi toplanabilmektedir. Uçağa monte sistemler ile geniş alanlar için veri toplanırken nokta yoğunluğu 1 ile 10 nokta/m² arasında değişirken, İHA'lar ile daha küçük çalışma alanları için toplanan nokta bulutlarının yoğunluğu 100-1000 nokta/m² değerlerini bulmaktadır (Wallace vd., 2016). Nokta yoğunluğunun fazla olmasının sebebi genelde düşük irtifada ve bindirme oranı yüksek uçuş gerçekleştirilmesidir.

LiDAR nokta bulutunda yer yüzeyini temsil eden noktaları sınıflandırmak iş akışının en önemli adımlarından birisidir. Hava LiDAR sistemlerinde tipik nokta sınıfları yer, bina, düşük, orta ve yüksek bitki örtüsü ve suyu temsil eder. Bu sınıflandırma bilgileri kullanılarak örneğin bitki örtüsü noktaları ile orman haritaları veya bina çatı noktaları ile solar enerji potansiyel haritaları üretilebilir. Yer bilimleri ve diğer disiplinler arasındaki etkileşim için nokta bulutunun sınıflandırılmış noktaları önemli bir niteliktir (Winiwarter, 2018).

Sınıflandırma, bu tez bağlamında kontrollü sınıflandırma anlamına gelmektedir, şöyle ki sınıflandırıcıyı eğitmek için gerçek veriler kullanılır. Sınıflandırma işleminden önce LiDAR nokta bulutundan herhangi bir matematiksel hesaplama yapmak zorunlu değildir. Bazı durumlarda sınıflandırma başlamadan önce eğitimi olumsuz etkileyecek gürültü noktalarını kaldırmak faydalı olabilir. Geleneksel nokta bulutu sınıflandırma algoritmaları ön işlem olarak gürültü noktalarını filtreledikten sonra benzer özelliklere sahip noktaları gruplara ayırır. Daha sonra bu gruplar içerisinde ortak özellikler çıkarılır ve bu niteliklere göre sınıflandırma yapar. Bu özellikler geometrik, radyometrik veya başka bir nitelik olabilir.

İkili karar ağacı modeli en basit sınıflandırıcıdır. Kök düğümünden başlayarak her karar düğümünde bir niteliğe bağlı olarak ikili ayırım yapar. Sonuç üretme kısmında (yapraklarda) sınıflar (ikili durum için 0 ve 1) atanır. Daha karmaşık ağaçlar (karar düğümü sayısı sınıf sayısına eşit olan) çoklu sınıflandırma problemlerinde kullanılabilir. Karar ağaçları sınıflar arasındaki sınırları ayarlarken uzman bilgisine ihtiyaç duyarken

herhangi bir güvenilirlik ölçütü sağlamazlar. Bu durumun üstesinden gelmek için makine öğrenmesi yaklaşımları tercih edilmeye başlanmıştır.

Rastgele orman sınıflandırıcısı grup öğrencilerinin önde gelen algoritmalarındandır. Her biri tamamen rastgele bir sınıflandırıcıdan biraz daha iyi çalışan çok sayıda karar ağacından (dolayısıyla “orman”) oluşur. Girdi, tüm ağaçlara aynı zamanda verilir çıkış sınıflarından istatistikler hesaplanır. Örneğin, ağaçların %60’ı belirli bir girdi için A sınıfı sonucunu üretirse, A sınıfı için çıktı olasılığı %60 olarak hesaplanır. Karar ağaçları otomatik olarak oluşturulur. Bunun için farklı yöntemler geliştirilmiştir. ID3 (*Iterative Dichotomiser 3*), yani tekrarlı ikililikçi ağacı, ikili sınıflandırma problemlerinin çözümü için geliştirilmiş daha sonrasında C4 ve C4.5 algoritmalarına referans olmuştur. Rastgele orman algoritmalarında lineer ayırım için sınıflandırma yoktur. Tek karar ağacı lineer ayırım yapmasına rağmen birden fazla karar ağacı hesaba katıldığı zaman lineer olmayan sonuçlar üretilebilmektedir.

Bir diğer makine öğrenmesi sınıflandırıcısı SVM (*Support Vector Machine*), yani destek vektör makinesi olarak isimlendirilen bir lineer sınıflandırıcıdır. Düzlemde bulunan iki grup arasına bir sınır çizerek grupları ayırır. Bu sınırın çizileceği yer ise iki grubun elemanlarına en uzak mesafede olmalıdır. Destek vektör makinesi bu sınırın çizileceği yeri belirler. Sadece iki sınıfı lineer olarak ayırabilen destek vektör makinelerine lineer olmayan problemlerin çözümü için ilave olarak birkaç işlem adımı eklenir. Bu adımlardan birisi girdi verilerini daha yüksek boyuta dönüştürmektir (örn. $x \rightarrow x^2$).

Bölüm 2’de bahsedildiği üzere başka sınıflandırıcılar da mevcuttur fakat bu tez çalışması sinir ağlarına odaklandığı için burada bahsedilmemiştir.

3.1.2. Sınıflandırma doğruluk ölçütleri

Sınıflandırma işleminin başarısını ölçmek için birçok ölçüt mevcuttur. Bunların hepsi referans verideki gerçek değerler ile üretilen tahminlerin kıyaslanması ile yapılır. Sonuçlar hata matrisi şeklinde sunulabilir. Hata matrisinin satırları gerçek değerleri yani olması gerek değerleri temsil ederken tahmin edilen değerler sütunlarda verilir. Matrisin köşegen elemanları doğru sınıflandırılan noktaların sayısını gösterir. Basit bir hata matrisi örneği Çizelge 3.2’de verilmiştir.

Çizelge 3.2. Hata matrisine üç sınıflı bir örnek

		Tahmin edilen		
		Sınıf 1	Sınıf 2	Sınıf 3
Gerçek değer	Sınıf 1	100	0	2
	Sınıf 2	3	55	10
	Sınıf 3	11	80	120

Hata matrisi, sınıflandırma işleminin başarısını gösteren ve farklı doğruluk metriklerinin değerlerinden faydalandığı eksiksiz bir matristir. Aşağıda bahsedilen çeşitli doğruluk ölçütleri hata matrisindeki değerleri kullanır.

- Doğruluk (*accuracy*), doğru sınıflandırılmış noktaların (hata matrisinin köşegen elemanları) sayısının toplam nokta sayısına (hata matrisinde satır ve sütunların toplamı) oranını ifade eden en belirgin ölçüdür (Denklem 3.2).

$$\text{Doğruluk} = \frac{\sum_i a_{ii}}{\sum_i \sum_j a_{ij}} = \%72 \quad (3.2)$$

- Duyarlılık (*recall*), bir sınıfa ait noktaların ne kadarının doğru sınıfa atandığını gösterir. Hata matrisinde ilgili sınıfa denk gelen köşegen elemanının aynı satırdaki tüm değerlere bölünmesi ile hesaplanır (Denklem 3.3).

$$\text{Duyarlılık} = \frac{a_{ii}}{\sum_k a_{ki}} = \begin{cases} \% 98,03 \\ \% 80,88 \\ \% 56,87 \end{cases} \quad (3.3)$$

- Kesinlik (*precision*), sınıflandırılan noktaların ne kadarının doğru sınıfa ait olduğunu gösterir. Hata matrisinde ilgili sınıfa denk gelen köşegen elemanının aynı sütundaki tüm değerlere bölünmesi ile hesaplanır (Denklem 3.4).

$$\text{Kesinlik} = \frac{a_{ii}}{\sum_k a_{ik}} = \begin{cases} \% 87,72 \\ \% 40,74 \\ \% 90,91 \end{cases} \quad (3.4)$$

■ F1 skoru, duyarlılık ve kesinlik metriklerinin harmonik ortalamasının hesaplanması ile elde edilir (Denklem 3.5).

$$F1_i = \frac{2 \times \text{duyarlılık}_i \times \text{kesinlik}_i}{\text{duyarlılık}_i + \text{kesinlik}_i} = \begin{cases} \% 92,59 \\ \% 54,19 \\ \% 69,97 \end{cases} \quad (3.5)$$

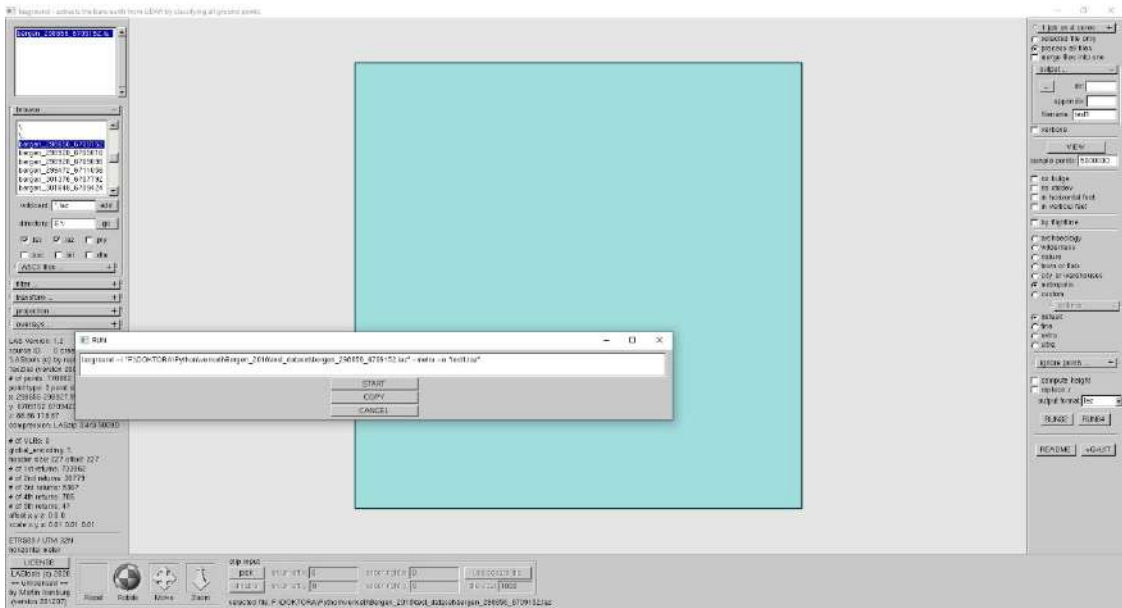
Hata matrisinde sınıf 3'e ait çok sayıda noktanın (Bknz. Çizelge 3.2; 80) sınıf 2 olarak yanlış sınıflandırılması sınıf 3'e ait duyarlılık ve F1 skoruna olumsuz etkisi olurken aynı zamanda sınıf 2'ye ait kesinlik ve F1 skoruna da olumsuz etkisi görülmektedir.

3.2. Performans Karşılaştırmasında Kullanılan Yazılımlar

Hava LiDAR nokta bulutu verilerini filtreleme ve sınıflandırma işlemleri için tercih edilen üç popüler ticari yazılım, tez çalışmasında kullanılan test verilerini sınıflandırmak ve önerilen derin sinir ağı yönteminin başarı performansını kıyaslayabilmek amacıyla bu çalışmaya dahil edilmiştir. Bahsedilen yazılımlar şunlardır;

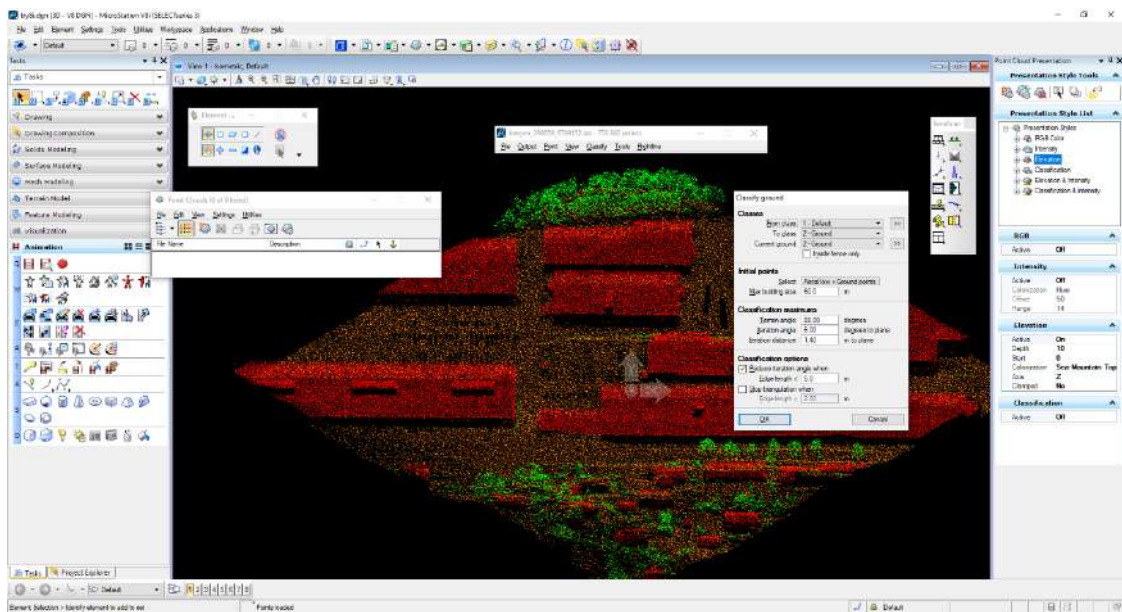
- LAStools
- TerraScan
- QT Modeller

LAStools LiDAR nokta bulutu işleme yazılımı Martin Isenburg tarafından geliştirilmiştir (<https://rapidlasso.com/lastools/>) [Ziyaret Tarihi: 22 Şubat 2021]. Bu tez çalışması kapsamında nokta bulutu verilerini sınıflandırmak için 'lasground' ve 'lasclassify' modülleri kullanılmıştır. Bu modüllerden 'lasground' Axelsson tarafından önerilen yer noktalarını diğer noktalardan ayıran filtreleme algoritmasını kullanmaktadır (Axelsson, 2000). Yer noktaları tespit edildikten sonra 'lasclassify' modülü ile bina ve bitki örtüsü sınıfları da tespit edilebilmektedir. Tez kapsamında kullanılan LiDAR test nokta bulutları için bina yoğunluğunun fazla olduğu verilerde 'lasground' modülünde 'metropolis' parametresi seçilmiş ve verideki en geniş binanın kenar uzunluğu 'step' parametresi olarak kabul edilmiştir. Bina yoğunluğunun kısmen daha az olduğu veriler için ise 'city or warehouses' parametresi seçilmiştir (Şekil 3.3).



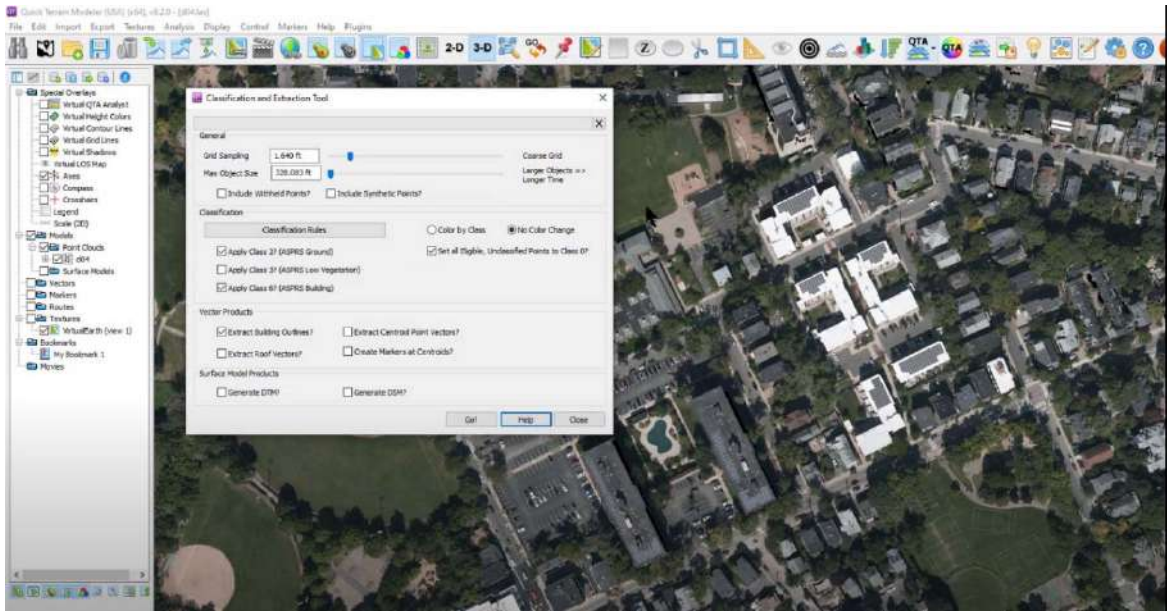
Şekil 3.3. LAStools-lasground modülünün arayüzü

TerraSolid firması tarafından geliştirilen TerraSolid yazılım paketinin içerdiği dört modülden birisi olan TerraScan, LiDAR nokta bulutlarını yer, bitki örtüsü ve bina olmak üzere üç farklı sınıfa ayırabilmektedir (<https://terrasolid.com/products/terrascan/>) [Ziyaret Tarihi: 22 Şubat 2021]. Tez kapsamında kullanılan test verileri TerraScan ile sınıflandırılırken 'Max building size' parametresi veri içerisindeki en geniş binanın kenar uzunluğu olarak belirlenirken test verilerinin hepsinde binalar bulunduğu için 'Terrain angle' parametresi ile diğer parametreler değiştirilmemiştir (Şekil 3.4).



Şekil 3.4. TerraScan yazılımının arayüzü

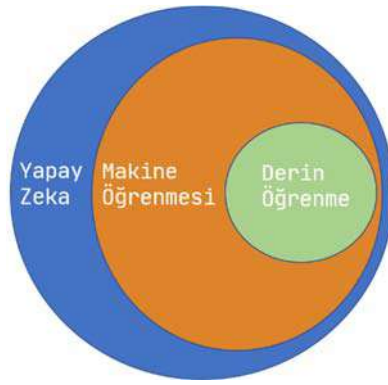
QT Modeler, Applied Imagery firması tarafından geliştirilen Amerika Birleşik Devletleri Savunma Bakanlığı başta olmak üzere birçok kuruluş tarafından da kullanılan bir LiDAR verisi görüntüleme ve işleme yazılımıdır. Yazılımın kullandığı algoritma yukarıda bahsedilen diğer iki yazılım ile temelde aynı olması sebebiyle filtreleme parametreleri veride ki en geniş yapının uzunluğuna bağlıdır. Bu parametre tez kapsamında kullanılan LiDAR test verilerinde ki yapılar göz önünde bulundurularak her veride farklı şekilde seçilmiştir (Şekil 3.5).



Şekil 3.5. Quick Terrain Modeler yazılımının arayüzü

3.3. Derin Öğrenme

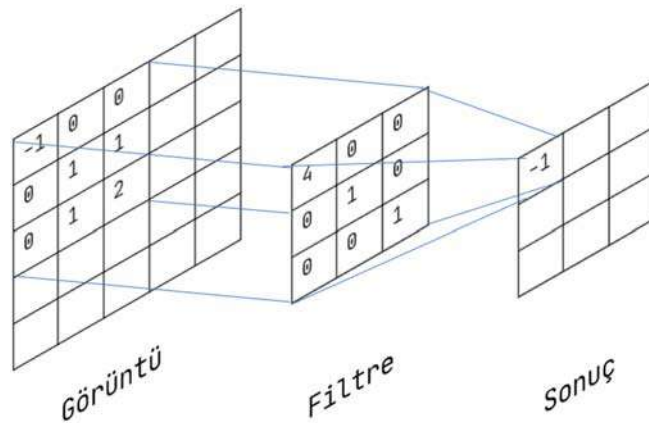
Derin öğrenme tekniklerinin temeli makine öğrenmesi algoritmalarına dayanır (Şekil 3.6). Makinelerin karmaşık problemlere insanlarla benzer şekilde çözüm üretmesiyle ilgilenen bilim dalı yapay zekâ olarak adlandırılır. İnsan beyninin karar alma mekanizmasını bilgisayarlara algoritmalar şeklinde ifade ederek bir anlamda insan zekasını taklit ederek problemlere yaklaşım sergiler. Makine öğrenme algoritmalarının eğitimi için önceden hazırlanacak verilerin özelliklerini kullanıcı belirlediği için özellik öğretimi kullanıcıya bağlıdır. Bu kullanıcıya bağlılık derin öğrenme tekniklerinde ortadan kalkmıştır. Derin öğrenme ağlarında etiketli veriden özellik çıkarımı otomatik şekilde yapılmaktadır. Derin öğrenme tekniklerinin temeli etiketli verileri alıp bunlardan ürettiği ağırlıkları anlamlandırmasıdır (Lecun vd., 2015).



Şekil 3.6. Derin öğrenmenin makine öğrenmesi ve yapay zekâ ile bağlantısı

Gelişen teknoloji ile derin öğrenme tekniklerinin ihtiyaç duyduğu büyük veri ve işlem hızı bilgisayar donanımları tarafından karşılanabilir hale gelmiştir. Güçlü grafik işlemciler ve bu işlemcilerin yeteneklerinden faydalanmayı sağlayacak paralel programlama çalışmaları artmıştır. Bu gelişmelerle beraber yapay sinir ağları ve derin öğrenme ile ilgili yapılan çalışmalara da ilgi artmıştır. Günümüzde derin öğrenme algoritmaları ses tanıma, el yazısı tanıma ve görüntü sınıflandırma problemleri üzerine yoğunlaşmış ve oldukça başarılı sonuçlar elde edilmiştir. Bu problemlerin tümünü veri anlamlandırma işlemleri olarak tanımlayabiliriz (Lecun vd., 2015).

Derin öğrenme algoritmalarının klasik yapay sinir ağından veya makine öğrenmesi algoritmalarından farkı bünyesinde veriye ait özellik haritalarını kullanıcıya bağlı kalmadan çıkarmayı sağlayan evrimsel sinir ağları bulunmasıdır. Ağa giren görüntüye farklı boyutlarda ve farklı sayılarda filtreler uygulayarak özniteliklerini çıkarabilir (Şekil 3.7). Bu özniteliklere sahip benzer görüntü parçalarını farklı bir görüntüde gördüğü zaman eşleme yaparak sunulan görüntü hakkında tahminler üretebilir.



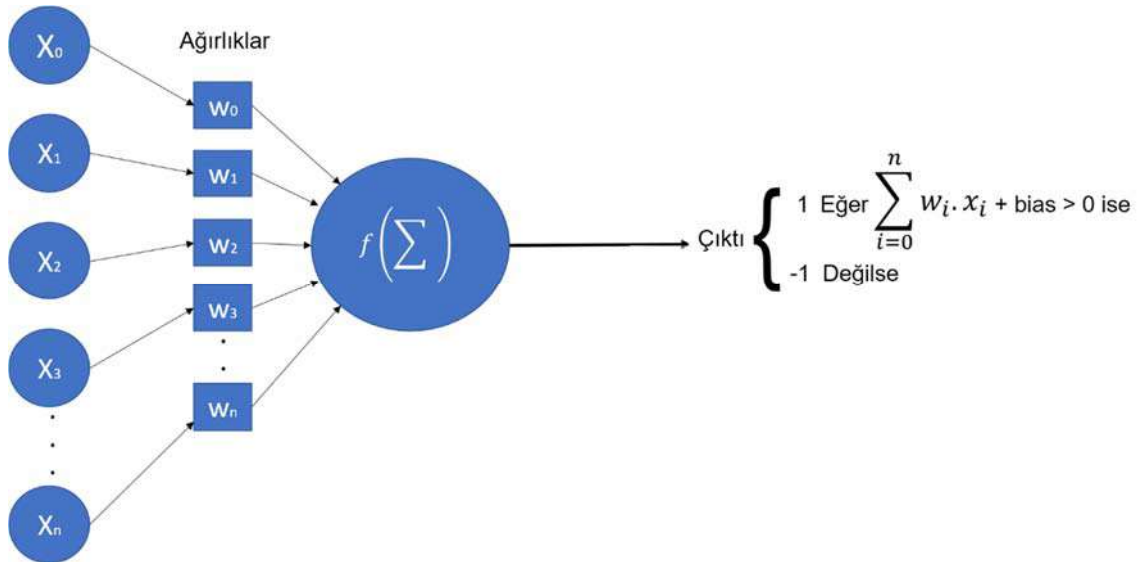
Şekil 3.7. Filtrenin görüntüye uygulandığı ve sonuç görüntü

3.3.1. Yapay sinir ağıları (YSA)

Sinir ağıları ile ilgili oldukça geniş bir literatür mevcuttur, orijinal fikir McCulloch ve Pitts tarafından insan beyninin fonksiyonlarının işleyişini taklit eden ve hesaplayan bir model olarak ortaya atılmıştır (McCulloch vd., 1943). Bu fikirden sonra birçok farklı şekilde evrilen teknik son yıllarda görüntü ve nokta bulutunda obje tanıma uygulamalarına yönelmiştir. Sinir ağlarının temel fikri, insan sinir sisteminin taklit ederek karar verme yetisini modellemektir. Sinir ağına ait bir algılayıcının temel gösterimi Şekil 3.8’de verilmiştir. 1980’li yıllara kadar doğrusal olmayan problemleri çözememe dezavantajı nedeniyle fazla popüler olamayan sinir ağıları, Rumelhart vd., tarafından ortaya koyulan paralel dağıtık işlem fikri ile tekrar ortaya çıkmıştır (Rumelhart vd., 1986). Derin öğrenme yaklaşımının temeli bu fikir ile atılmış oldu (Lecun vd. 2015). Geri yayılım algoritması, YSA’ların eğitiminde başarıyla kullanılmış ve yaygınlaşmıştır (İnik vd., 2017). Geri yayılım algoritması basit anlamda YSA’nın eğitimi için denetimli bir öğrenme algoritmasıdır. Eğitimden kasıt da aslında başlangıçta rastgele belirlenen ağırlık değerlerinin hata miktarına göre güncellenmesidir. Sinir ağı algılayıcısının matematiksel ifadesi Denklem 3.6’da verilmiştir.

$$Z = f\left(\sum_{i=0}^n w_i \cdot x_i + b\right) \quad (3.6)$$

Girdi verisinin bir görüntü olduğu varsayılırsa burada x_i ’ler, görüntünün her bir pikselini temsil ederken w_i ’ler bağlantı ağırlıklarıdır. Sapma (*bias*) b ile gösterilir, z ise girdi değerleri ile ağırlıkların çarpımının yanlılık değeri ile toplanmasının bir $f()$ fonksiyonundan geçirilmesi ile elde edilen çıktıdır. Fonksiyon $f()$ ise doğrusal olmayan bir etkinleştirme fonksiyonudur.



Şekil 3.8 Bir sinir ağına ait algılayıcının temel gösterimi

Rumelhart vd., tarafından sunulan araştırmada birden fazla katman veya doğrusal olmayan etkinleştirme fonksiyonları barındıran bir sinir ağının eğitilmesinin imkânsız olduğunu belirtirken buna rağmen geri yayılım (*backpropagation*) algoritması kullanılarak bunun mümkün olacağını göstermiştir. Etkinleştirme fonksiyonlarının katmanlarda geriye doğru türevleri hesaplanarak sinir ağının ağırlıklarının doğru şekilde güncellenebileceğini rapor etmiştir (Rumelhart vd., 1986). Bunun için matematiksel bir kayıp fonksiyonu (*loss function*) tanımlanmalıdır. Kayıp fonksiyonu, eğitim aşamasında üretilen tahmin verisi ile gerçek değer arasındaki farkı belirten bir skaler değer hesaplanması için kullanılır. Eğitimin amacı bu farkı olabildiğince küçültmektir. Kayıp fonksiyonunun değerini geri yayılım algoritmasını kullanarak küçültmek için ağırlıkların ve sapma değerlerinin güncellemeleri her sinir ağı bağlantısında hesaplanmalıdır. Bunun için ağırlıkların optimize edilmiş değerlerini bulmak önemlidir. Ayrıca hesaplanacak en iyi ağırlık değerleri modelin genelleştirilmesini sağlar böylece model daha önce görmediği veriler için daha iyi tahminler yapabilir. Denklem 3.7’de cross-entropy kayıp fonksiyonu verilmiştir.

$$L(y, y') = - \sum_i y_i \log(y'_i) \quad (3.7)$$

Burada y_i ve y'_i , i 'inci nokta için sırasıyla gerçek değer ve tahmin edilen değeri temsil ederken L ise kayıp fonksiyonu temsil etmektedir. Tahmin edilen değerler ile gerçek değerler arasındaki farkı bulmak ve bu farka etki eden ağırlıklar ve sapma

parametrelerini ne miktarda güncelleyeceğini hesaplamak için kayıp fonksiyonunun türevi Denklem 3.8'deki gibi hesaplanır.

$$\Delta w_{ij} = - \frac{\partial L(y, y')}{\partial w_{ij}} \quad (3.8)$$

Burada ağırlığa (w) göre kayıp fonksiyonunun kısmi türevi verilmiştir, j katman numarasını gösterirken i nöron numarasını temsil eder. Aynı işlem sapma değerleri içinde geçerlidir. Eğim düşümü (*gradient descent*), kayıp fonksiyonunu en küçük değeri bulacak şekilde optimize etmek için en çok tercih edilen yöntemlerden birisidir. Verilerin büyüklüğüne göre üç adet eğim düşümü algoritması (Batch Gradient Descent, Stochastic Gradient Descent (SGD), Mini-Batch Gradient Descent) tercih edilebilir. Eğim düşümü yöntemini temel alan çeşitli algoritmalar da (ADAM, Adagrad, Adadelta, Rmsprop, Nesterov Hızlandırılmış Eğim, Nadam) mevcuttur (Kurt, 2018).

Optimizasyon algoritmalarında göz ardı edilmemesi gereken bir parametrede öğrenme oranıdır. Bu parametrenin ayarlanması eğitimin süresine ve başarısına direkt etki etmektedir. Öğrenme oranı, ağırlık parametrelerinin hangi hızla güncellendiğini tanımlar. Küçük bir değer seçilirse öğrenme süresi yavaşlar, yüksek bir değer seçilirse öğrenme süresi kısalmaya başlar fakat kayıp fonksiyonunun en küçük değere ulaşması gerçekleşmeyebilir yani yakınsama olmayabilir. Buradaki yakınsamadan kasıt kayıp fonksiyonunun en küçük değerini bulabilmek için optimizasyon algoritmasının tahminlerini küçük adımlarla istenen değere yakınlaştırmasıdır. Denklem 3.9'da Olasılıksal Eğim Düşümü (*Stochastic Gradient Descent*) optimizasyon algoritmasının matematiksel ifadesi verilmiştir.

$$\theta_{t+1} = \theta_t - \eta \cdot \nabla_{\theta} J(\theta_t; x^{(i)}; y^{(i)}) \quad (3.9)$$

Burada θ , kayıp fonksiyonunun bir parametresi, η öğrenme oranı, $\nabla_{\theta} J$ ise her bir eğitim örneği $x^{(i)}$ ve etiket $y^{(i)}$ için θ parametresine bağlı eğimi temsil eder. Olasılıksal Eğim Düşümü algoritmasının diğer tekniklerden farkı tüm eğitim seti yerine rastgele seçilen bir eğitim örneğini kullanarak ağırlıklar ve sapma değerleri için en optimum sonuçları hesaplar. Bu sayede oluşabilecek hafıza yetersizliği probleminin önüne geçilmiş olur.

Tez kapsamında kullanılan bir diğer optimizasyon algoritması Olasılıksal Eğim Düşümü algoritmasından türetilmiş Adaptif Moment Tahmin (*Adaptive Moment Estimation* - ADAM) algoritmasıdır (Kurt, 2018). Birçok çalışmada eğim düşümü temelli teknikler arasında en başarılı algoritma olarak gösterilen ADAM, en doğru sonuçlara hızlı şekilde ulaşması nedeniyle popülerliğini arttırmıştır (Karpathy vd., 2015). ADAM, öğrenme katsayısını eğimin kaybolması veya aşırı artması durumlarını önlemek için günceller ve momentum değerini kullanır. Momentum, önceki eğim düşümü adımlarını hesaba dahil ederek bir sonraki adımın yönünü tespit etmeye ve salınımların önlenmesine yardımcı olan bir parametredir. Denklem 3.10'da Adam optimizasyon algoritmasının matematiksel ifadesi verilmiştir.

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\frac{v_t}{1-\beta_2^t} + \epsilon}} \frac{m_t}{1-\beta_1^t} \quad (3.10)$$

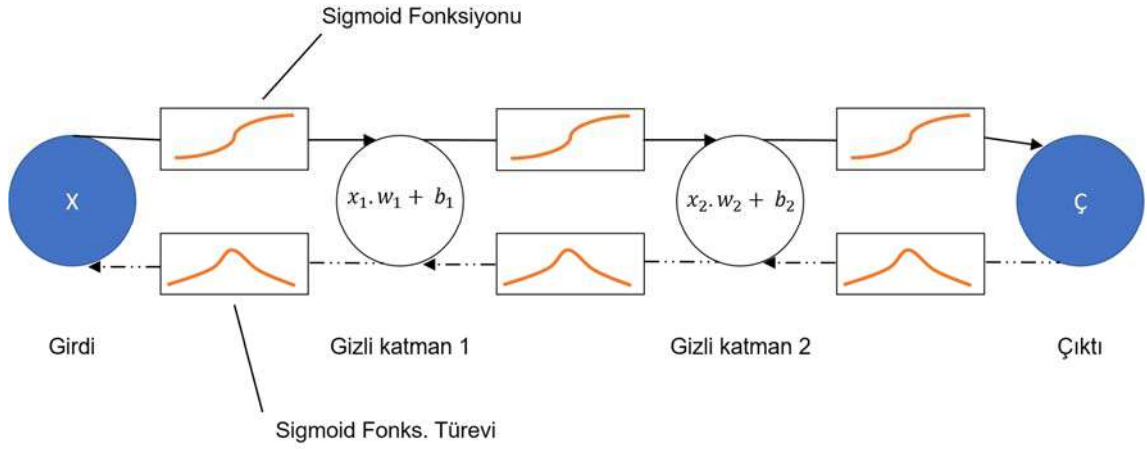
Burada θ , kayıp fonksiyonun bir parametresi, η öğrenme oranı, v_t geçmiş eğimlerin karelerinin üssel olarak ağırlıklandırılmış ortalamalarını, m_t momentumdaki geçmiş eğimlerin üssel olarak ağırlıklandırılmış ortalamalarını, β_1 , β_2 ve ϵ ise sabit katsayıları ifade eder.

Geri yayılım algoritması, kayıp fonksiyonun kısmi türevleri ile gradyanları hesaplarken optimizasyon algoritması ise hesaplanan gradyanlar ile ağırlık ve sapma değerlerine getirilecek güncellemeleri hesaplar. Eğitim aşamasında girdi olarak birçok veri ağı katıldıktan sonra ağırlıklar için optimum değerlere ulaşılır. Optimizasyon algoritmaları ile ilgili ayrıntılı bilgiye Kurt'un tez çalışmasında erişilebilir (Kurt, 2018).

Geri yayılım algoritması ile eğitilen en basit ağ örneği çok katmanlı algılayıcıdır (*multi-layer perceptron* - MLP). Çok katmanlı algılayıcılar, birden fazla algılayıcı ve doğrusal olmayan etkinleştirme fonksiyonundan oluşur (Winiwarter, 2018). Çok katmanlı algılayıcı örneği Şekil 3.9'da gösterilmiştir.

2006 yılında Hinton vd., derin sinir ağlarının etkili bir şekilde kullanılabileceğini göstermiştir (Hinton vd., 2006). Nesne tanımlama uygulamaları alanında araştırmacılar arasında en popüler yarışmalardan birisi olan ImageNet birincisi, 2012 yılında temel derin öğrenme mimarilerinden olan ESA ile bu dereceyi kazanmıştır (Krizhevsky vd., 2012). Bu mimari ile yarışmada elde edilen en iyi hata oranını %26,1'den %15,3'e düşürmüştür.

2015 yılında birinciliği kazanan algoritmanın hata oranı ise nesne tanıma probleminde bir insanın hata yapma oranına kadar düşmüştür.



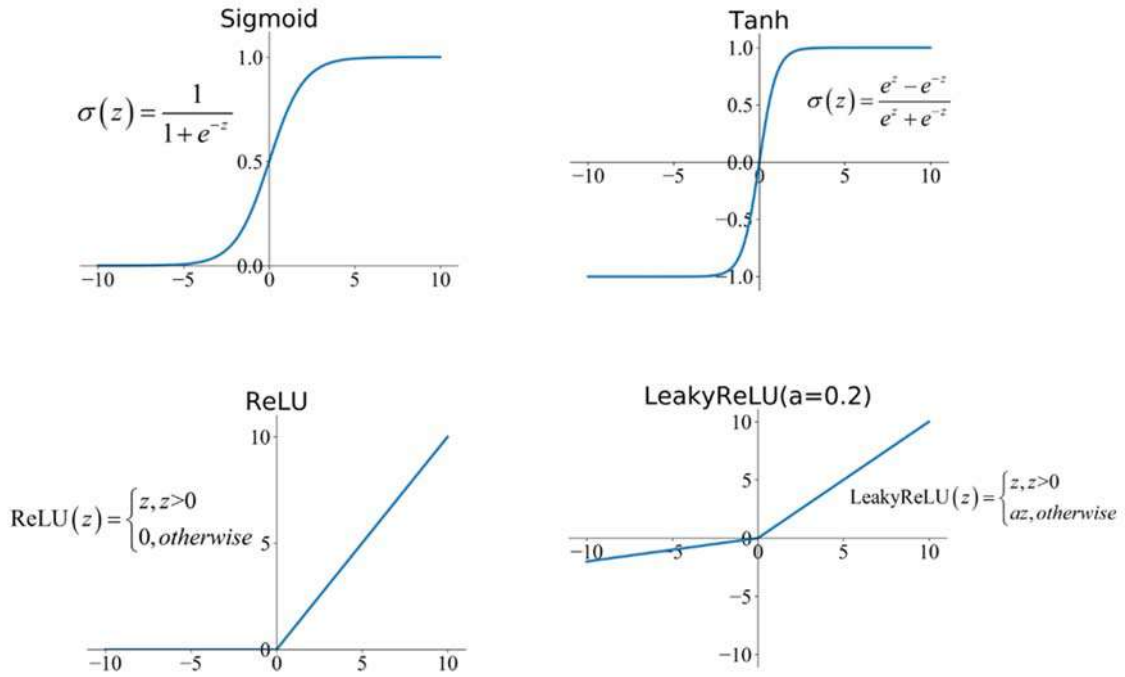
Şekil 3.9. Çok katmanlı algılayıcı örneği. Kesikli çizgi: geri yayılım algoritması, düz çizgi: ileri besleme, W_1 ve W_2 : öğrenilebilir parametreler, b_1 ve b_2 : sapma değerleri (Winiwarter, 2018).

Derin öğrenme tekniklerinin geçmişinin çok eskilere dayanmasına rağmen son on yılda elde ettiği başarıların temelinde araştırmacıların erişebildiği ve üzerinde çalışabildiği çok geniş veri setlerinin olmasıdır. Bu büyüklükteki verilerle eğilecek YSA'ların ihtiyaç duyduğu hesaplama gücü de son yıllarda bilgisayar donanımlarındaki gelişmeler ile sağlanmıştır. YSA'lardaki gizli katmanların arttırılması ile derinleşen sinir ağları her zamankinden daha çok hesaplama kaynağına gerek duyar. Bu sebeple derin ağların eğitim hesaplamaları için alışılmış bilgisayar merkezi işlem birimleri (*Central Processing Unit - CPU*) yerine daha güçlü hesaplama kapasitesine sahip grafik işleme birimleri (*Graphic Processing Unit - GPU*) tercih edilmektedir. Kullanıcıların giriş verisinde herhangi bir özellik belirtmeden eğitim yapabilen bu derin öğrenme modelleri yapısı gereği her katmanda veriye ait farklı özellikler keşfedebilir (İnik vd., 2017).

3.3.2. Evrişimli sinir ağları (ESA)

Özellikle son on yıldır bilgisayarlı görme alanında tercih edilen makine öğrenmesi yöntemlerinden birisi Evrişimli Sinir Ağları modelidir. ESA'lar, derin sinir ağlarının bir tekniği ve YSA'ların geliştirilmiş versiyonudur. Bir ESA, girdi görüntüleri alır ve görüntüye bir sınıf atar veya tamamen evrişimli bir mimariye dönüştüğünde piksel-tabanlı sınıflandırılmış görüntü şeklinde çıktı üretir. Basit bir ESA mimarisinin gösterimi Şekil

bu değerleri de belirli bir aralıkta dönüştürür. Geri yayılım algoritmasının işleyişi nedeniyle seçilen etkinleştirme fonksiyonu türevi alınabilir olmalıdır. En popüler etkinleştirme fonksiyonları Sigmoid, Tanh (Hiperbolik Tanjant Fonksiyonu), ReLU (*Rectified Linear Unit*) ve LeakyReLU'dur. Bu fonksiyonların grafik gösterimleri Şekil 3.11'de verilmiştir.



Şekil 3.11. Sigmoid, Tanh, ReLU ve LeakyReLU fonksiyonlarının grafikleri

Sigmoid fonksiyonu girdi değerleri $[0, 1]$ aralığına sıkıştırır. Dezavantajı ise x değerlerindeki değişim büyüdükçe y değerinin buna çok az tepki vermesi başka bir deyişle eğitim sırasında türevi alındığında çok küçük değerler üretmesidir. Bunun anlamı da öğrenme olayının en az düzeyde olmasıdır. Tanh fonksiyonunun aralığı ise $[-1, +1]$ olarak tanımlanır. Sigmoid fonksiyonuna göre avantajı ise tanımlı olduğu aralığın daha uzun olması nedeniyle türevinin daha çok değer alabilmesidir. Bunun anlamı da daha hızlı öğrenme gerçekleştirebilmesidir. ReLU, $[0, +\infty)$ aralığında değer alan, hesaplama yükü Tanh ve Sigmoid fonksiyonlarına göre daha az olan bir fonksiyondur. Negatif ekseninde sıfır değerini alması bunun ana sebebidir ve çok katmanlı ağlarda bu nedenle tercih edilir. Dezavantajı ise sıfır aldığı bölgede türevinin de sıfır olması yani o bölgede öğrenme gerçekleşmemesidir. ReLU'nun bu dezavantajı ise LeakyReLU fonksiyonu ile aşılmıştır. Farkı ise negatif bölgede sıfır almak yerine sıfıra çok yakın değerle üretmesidir.

LeakyReLU bunu negatif bölgedeki değerleri 0.01 katsayısı ile çarparak elde eder. Bu sayede o bölgede de öğrenme gerçekleşmiş olur (Kızrak, 2019).

Evrişim, aktivasyon fonksiyonu ve havuzlama katmanlarından sonra tam bağlantılı katman (*fully connected layer*) gelir. Kendinden önceki katmanın tüm alanlarına bağlı olan bu katmanın sayısı farklı ağ mimarilerine göre değişiklik gösterebilir. Girdi olarak verilen görüntünün tüm piksel sayıları ve bant sayısının çarpımı ile tam bağlantılı katmanın önceden belirlenen büyüklüğü matris çarpımı ile bağlanır. Örneğin, 256×256 boyutlarında bir RGB görüntü, ESA mimarisinin son katmanına geldiğinde toplam $256 \times 256 \times 3 \times 128 = 25165824$ adet nöron içerir ve tam bağlantılı katmandaki matris boyutu 1028 olarak kabul edilirse ağın sonunda 25165824×1028 boyutunda ağırlık matrisi oluşturur. Yani her bir nöron diğeri ile bağlantı kurar. Bir diğeri ağ tekniği seyreltme (*dropout*) ismi verilen, ESA ağlarının eğitim sırasında ezberleme yapmasını engelleyen metottur. Bu tekniğin temeli eğitim esnasında ağın bünyesindeki katmanlar arasındaki bazı nöron bağlantılarının rastgele kaldırılmasıdır.

ESA mimarisinin son katmanı sınıflandırma (*classification*) katmanıdır. Bu katmanın ürettiği çıkış değeri ağın öğrendiği obje veya sınıf sayısına eşittir. Örneğin tahmin edilecek sınıf sayısı 10 ise tam bağlantılı katmandaki çıkış değerinin 1028 olduğu göz önüne alındığında sınıflandırma katmanında 1028×10 boyutlarında ağırlık matrisi elde edilmiş olur. Son aşamada bu matristen tahmin yapacak sınıflandırıcı bir fonksiyona ihtiyaç duyulur. En başarılı sınıflandırıcılardan birisi olarak kabul edilen softmax fonksiyonu tahmin yapılacak her obje veya sınıf için $[0, 1]$ aralığında olasılık hesaplar ve 1'e en yakın değere sahip sınıf ağın tahmini olarak kabul edilir (İnik vd., 2017).

Çok sayıda katman içeren ESA'lar, ilk katmanlarda görüntüdeki çizgiler, eğriler ve köşeler gibi öğeleri tanıırken, ileri seviye katmanlarda daha ayrıntılı şekilleri tanımayı öğrenir. Bu özelliği ile sinir ağlarının daha karmaşık görevleri (bir resimdeki hayvanın kedi mi yoksa köpek mi olduğunu tahmin etmek) daha basit görevlere (görüntüdeki kenarların veya üçgen ve daire gibi basit şekillerin tahmini) genelleştirip ayırt edebilmesi becerisini de ortaya koyar (Winiwarter, 2018).


3.3.3. Tamamen evrişimli sinir ağları (TESA)

Görüntü işleme hem uzaktan algılama hem de bilgisayarlı görme alanlarında yaygın olarak kullanılan bir metottur. ESA'lar, bahsi geçen bu disiplinlerde oldukça yaygın şekilde kullanılmaktadır. Özellikle uzaktan algılamada (arazi örtüsü haritasının

oluşturulması vb.) tek bir pikselin sınıflandırılması önemli bir işlemdir. Bu prosedür girdi görüntüde her bir piksel için bir etiket tahmini yapmayı gerektirir ki tipik bir ESA mimarisinin çıktısında bazı değişiklikler yapılarak piksel tabanlı sınıflandırma yaptırılabilir çünkü ESA görüntünün tümüne bir sınıf tahmini yapabilen bir mimaridir. Piksel tabanlı sınıflandırmaya diğer bir örnek ise bilgisayarlı görme disiplinin yoğunlukla kullanıldığı otonom araçların trafik ve yol işaretleri gibi çeşitli özellikleri derinlik bilgisi bulunmayan tek bir görüntüden tanımlayabilmesi olarak verilebilir.

Son birkaç sene içerisinde ESA'ları piksel tabanlı tahmin yapabilen ağ mimarilerine çeviren bazı çalışmalar literatüre girmiştir (Badrinarayanan vd., 2017; Long vd., 2015). Bahsedilen bu mimariler tipik bir ESA ağının son aşamasında bulunan tam bağlantılı katmanı içermez. Bunun sebebi ise ağın son kısmındaki tüm nöronların birbirlerine bağlı olması nedeniyle tam bağlantılı katman konumsal bilgi taşımaması dolayısıyla piksel tabanlı tahmin yapamamasıdır. TESA'larda tam bağlantılı katmanın yerini orijinal görüntünün boyutu ile aynı boyuta sahip bir evrişim katmanı alır. Evrişim katmanı ise tahmin yapılması gereken sınıf sayısı kadar kanal içeren görüntünün her bir pikselinde her sınıf için tahmin olasılığını çıktı olarak üretir. TESA'ların hesaplama gücünü hafifletmek için görüntünün boyutlarını düşüren daha sonra tekrar orijinal boyutlarına getirebilen TESA'ların farklı bir ağ mimarisi olan kodlayıcı-kod çözücü içeren ağlardan U-Net bu tez çalışmasında kullanılacaktır.

U-Net, literatürde LiDAR nokta bulutlarının sınıflandırılmasında daha önce kullanılmamış bir ağ mimarisidir. Ronneberger vd., tarafından tomografi görüntülerini sınıflandırmak amacı ile yapılan çalışmada kullanılan diğer tekniklere kıyasla oldukça yüksek bir doğruluk elde etmiştir (Ronneberger vd., 2015). U-Net, tam evrişimli sinir ağı sınıfına dahil olan ve kodlayıcı ve çözümleyici olarak iki bölümden meydana gelen bir ağ mimarisidir. Adını "U" şeklindeki yapısından alan bu ağ mimarisinin sol bölümü kodlayıcı olarak adlandırılırken sağ bölümü kod çözümleyici olarak adlandırılır (Şekil 3.12). Orijinal çalışmada girdi olarak 572 x 572 piksel boyutlarındaki görüntüyü ve beraberinde sınıf etiketlerini alır ve çeşitli sayıda filtreler uygulayarak özellik haritaları çıkarır. Bununla birlikte girdi görüntünün boyutu keyfi değerlerde de seçilebilir. Filtre sayısı her iki katmandan sonra ikiye katlanarak 16, 32, 64, 128, 256 şeklinde artarken filtre boyutu sabit kalır. 18 adet katmanın ilk dokuz katmanında her görüntü için özellik haritası çıkarılırken görüntü boyutunu her iki katmanda bir yarıya düşürür. Sonraki dokuz katmanda bu görüntüler tekrar orijinal boyutuna çıkarılır.



Şekil 3.12. Orijinal U-Net ağ mimarisi (Ronneberger vd., 2015)

TESA mimarisine has bir özellik olan ara bağlantılı yapısı sayesinde kodlayıcı ve kod çözücü bölümlerdeki katmanlar kendi aralarında toplanarak ağ yapısı tamamlanmaktadır. Katmanların toplanmasındaki tek şart görüntü boyutlarının eşit olmasıdır. Kodlayıcı kısım tipik bir ESA gibi görüntüden öğrendiği bilgiyi saklar, ESA'dan farklı olarak son katmanda sınıflandırıcı bulundurmaz. Maksimum ortaklama işlemleri sonucunda çözünürlüğü küçülen görüntü, mimarinin kod çözücü bölümüne geldiğinde ortaklama işlemi esnasında sakladığı indisleri kullanarak görüntüyü orijinal çözünürlüğüne döndürür. Son katmanda sınıf sayısı kadar kanala sahip, olasılık dağılımlarını içeren görüntü çıktısı üretilir.


4. UYGULAMA

4.1. Hava LiDAR Veri Setleri

Tez çalışması kapsamında sınıflandırma amaçlı iki farklı hava LiDAR nokta bulutu veri seti kullanılmıştır. Bunlar, Norveç'e ait Bergen bölgesini kapsayan Bergen 2018 isimli LiDAR veri seti ve Kanada'nın Surrey şehrine ait DALES isimli LiDAR veri setidir.

4.1.1. Bergen 2018 LiDAR nokta bulutu

Norveç Harita Kurumu tarafından yürütülen proje kapsamında Riegl VQ-1560i lazer tarayıcı sistemi monteli Piper Aircraft P-31-350 uçağı ile toplanan havadan lazer nokta bulutu Bergen şehrinin kuzey bölümünde 60.337597°-60.525257° kuzey enlemleri ile 5.230554°-5.688727° doğu boylamları arasında kalan bölgeye aittir. (Şekil 4.1). Veri setinde bulunan toplam nokta sayısı yaklaşık 178 milyon ve ortalama nokta yoğunluğu 5 nokta/m²'dir. Konumsal bilgiler ile RGB renk bilgisi, sınıflandırma, yoğunluk ve dönüş bilgisi içeren veri seti halihazırda yer, düşük bitki örtüsü, orta bitki örtüsü, yüksek bitki örtüsü, bina ve su sınıflarına ayrılmış şekilde kullanıcılara sunulmuştur. Bölgeyi kapsayan LiDAR nokta bulutu farklı boyutlarda parçalara ayrılmış şekilde kullanıcılara sunulmuştur. Tez kapsamında yapılan çalışmada tüm nokta bulutu parçaları 272 m x 272 m boyutlarında alt parçalara bölünerek eğitim ve test verileri elde edilmiştir. Toplamda 480 parça elde edilmiş ve bunlardan 88 tanesi eğitim ve doğrulama aşaması için gerekli şartları sağlamıştır. Bölüm 4.2'de konuyla ilgili ayrıntılı bilgi verilmiştir. Veri setinde bulunan sınıfların kodları ve isimleri Çizelge 4.1'de verilmiştir.



Şekil 4.1. Bergen 2018 LiDAR nokta bulutunun kapsadığı alan ve topoğrafik gösterimi

Çizelge 4.1. Bergen 2018 veri seti için sınıf şeması

Sınıf kodu	Açıklama
2	Yer
3	Düşük bitki örtüsü
4	Orta bitki örtüsü
5	Yüksek bitki örtüsü
6	Bina

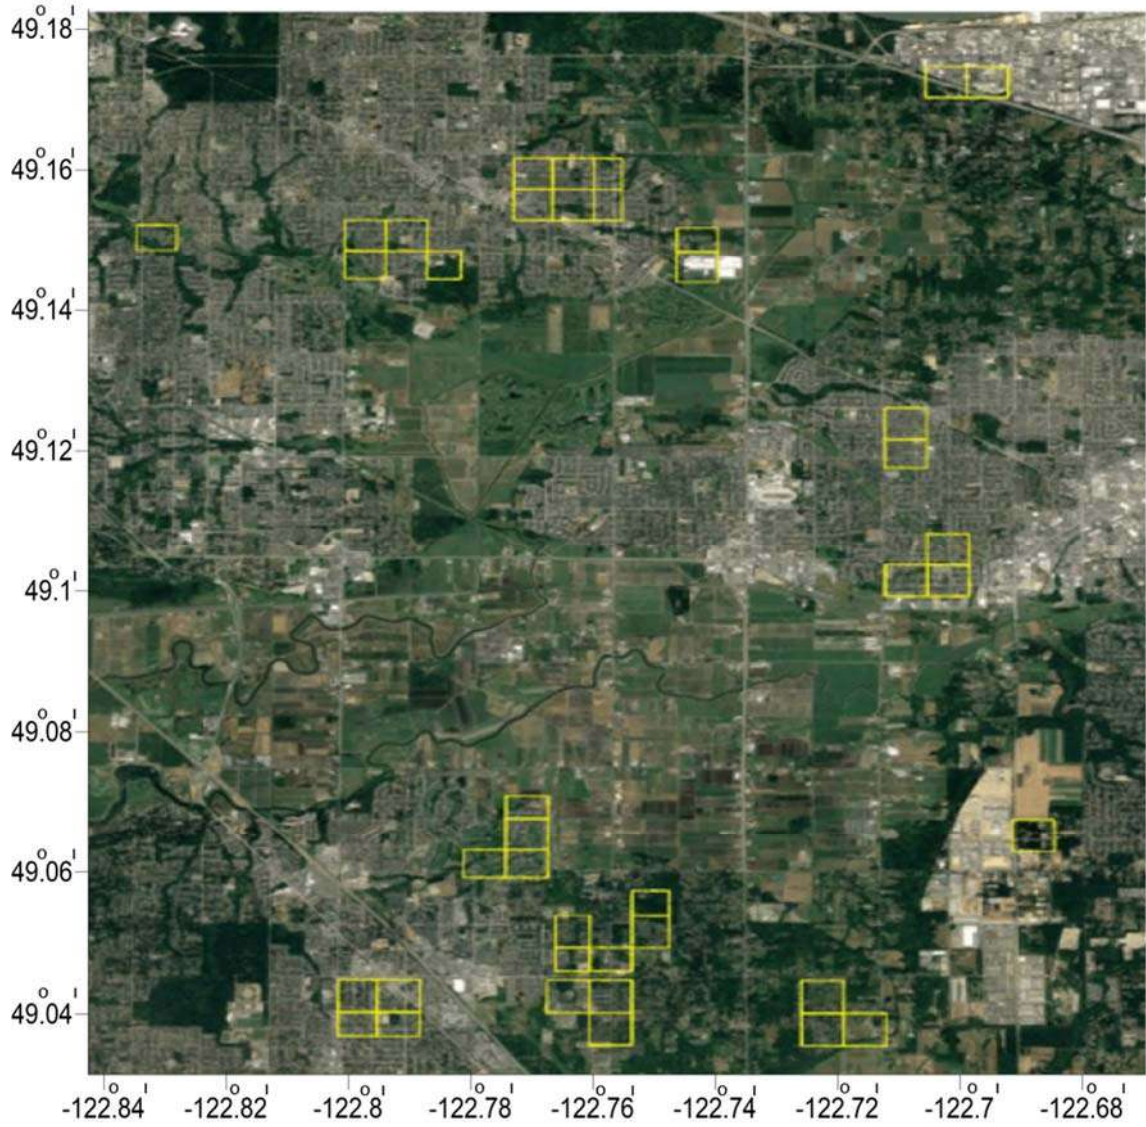
4.1.2. DALES LiDAR nokta bulutu

Dayton üniversitesi bünyesinde çalışmalarını sürdüren Varney vd. tarafından hazırlanan bu veri seti Kanada'nın Surrey şehri üzerinde Riegl Q1560 çift kanallı LiDAR sistemi ile toplanmıştır (Varney vd., 2020). Veri setlerinin bulunduğu bölge 49.031582°-49.182821° kuzey enlemleri ile 122.842993°-122.669541° batı boylamları arasında yer almaktadır. Veri setinin en göze çarpan özelliği nokta yoğunluğunun oldukça yüksek olmasıdır. DALES hava LiDAR nokta bulutu yaklaşık 50 nokta/m² yoğunluğuna sahip

olup yaklaşık yarım milyara yakın nokta içermektedir. Varney vd., LiDAR nokta bulutları ile ilgili çalışma yapan araştırmacılara yöntemlerini test etmek için hâlihazırda kullanılmak üzere her birisi 500 m x 500 m boyutlarında olan 29 adet eğitim ve 11 adet test nokta bulutu olmak üzere toplamda 40 adet veri sağlamıştır (Şekil 4.2). Bu LiDAR nokta bulutları otomatik yöntemlerle ve insan operatörler ile kontrolü yapılarak yüksek doğrulukta sınıflandırılmıştır. Yer, bitki örtüsü, bina, güç kablosu, direk, çit, kamyonet, otomobil ve sınıflandırılmamış noktalar olmak üzere toplamda sekiz sınıfa ayrılmıştır. Bergen 2018 veri setinden farklı olarak DALES LiDAR nokta bulutu verisi yoğunluk değeri içermemektedir. Veri setinde bulunan sınıfların kodları ve isimleri Çizelge 4.2’de verilmiştir.

Çizelge 4.2. DALES veri seti için sınıf şeması

Sınıf kodu	Açıklama
1	Yer
2	Bitki örtüsü
3	Otomobil
4	Kamyonet
5	Güç kablosu
6	Çit
7	Direk
8	Bina



Şekil 4.2. Surrey şehrinin uydu görüntüsü. DALES veri setinde kullanılan nokta bulutlarının konumu sarı kutular ile gösterilmiştir.

4.2. LiDAR Nokta Bulutlarının Ön İşlem Adımları

ESA'lar, görüntü işleme ve sınıflandırma, nesne takibi ve nesne bulma ve doğal dil işleme gibi alanlarda son yıllarda popülerliğini ve kullanılabilirliğini oldukça arttırmış bir teknik olmakla birlikte sınıflandırma sonuçlarının doğruluğu da klasik yöntemleri yakalamıştır. Görüntü sınıflandırmanın temel prensibi 2B görüntünün kademeli olarak çeşitli görüntü filtreleri kullanılarak en küçük öğelerine kadar çıkartılması ve bu öğelerin sinir ağına tanıtılmasıdır.

LiDAR verileri 3B değil de 2,5B olarak kabul görmekte ve çalışma alanının nadir açısından taranması nedeni ile 2B görüntüye eş değer bir projeksiyona sahiptir (Rizaldy vd., 2018). Yani bu veri görüntüye dönüştürüldüğünde veri kaybı fazla olmamaktadır. Bu noktada da sınıflandırma ve filtreleme için ESA devreye girmektedir.

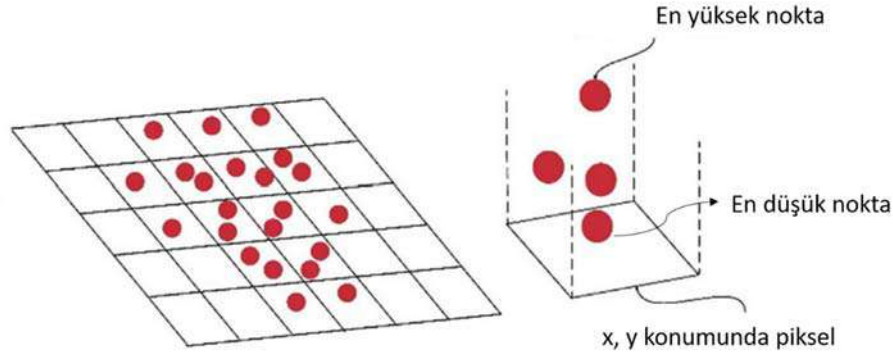
Derin öğrenme metotları günümüzde farklı programlama dilleri ile geliştirilen çeşitli kütüphaneler ile birlikte herkesin kullanımına sunulmuştur. Bu tez kapsamında da Google tarafından Python programlama dilinde geliştirilen TensorFlow kütüphanesi ve bu kütüphaneyi daha kolay kullanmayı sağlayan Keras kütüphanesi kullanılmıştır (Google, 2021). Derin sinir ağının eğitilmesi için çok sayıda çeşitli karakteristik özelliklere sahip verilere ihtiyaç duyulur. LiDAR verilerinin sınıflandırılması içinde ağın eğitiminde kullanılacak milyonlarca nokta içeren veri setleri ağda işlenmek üzere hazır hale getirilmelidir. Ön işlem için 3B nokta bulutu verisi özelliğini kaybetmeyecek şekilde 2B görüntüye dönüştürülür, bu işlemi de otomatikleştiren bir yazılım Python programlama dili kullanılarak hazırlanmıştır. Görüntüye dönüştürme işlemi ve karşılaşılan problemlerden ise 4.2.1 numaralı bölümde bahsedilmiştir.

4.2.1. Nokta bulutu-görüntü dönüşümü

LiDAR nokta bulutu nadir açısından toplandığı için bir bakıma çalışma alanının aynı açıdan 2B görüntüsünü de temsil eder, bu yüzden 2,5B veri olarak da adlandırılır. LiDAR verisi, yapıların ve objelerin cepheleri hakkında fazla bilgi içermez bu yüzden noktalar piksel olarak 2B yüzeye dönüştürüldüğünde anlamsal olarak çok veri kaybı olmaz. LiDAR verisinin karakteristik özelliklerinden dolayı birden fazla dönüş yaptığı zaman aynı koordinat değerine ait farklı yükseklik değerleri elde edilebilir ve yoğunluk değerleri de konum bilgisi ile beraber depolanır. Bu değerler farklı görüntü bantlarında aynı pikseller için kullanılabilir. Böylece LiDAR'ın karakteristik özelliklerinden yararlanılarak birden fazla bant içeren görüntüler elde edilebilir.

Derin öğrenme teknikleri için eğitim verisinde çeşitlilik ne kadar fazla olursa ağın başarı oranı da yükselecektir. Veri çoğaltma yöntemleri ile de mevcut görüntülerden daha fazla eğitim verisi elde edilebilir. Bu çoğaltma teknikleri görüntüyü ölçekleme, döndürme gibi işlemleri içerir. Literatürde nokta bulutu-görüntü dönüşümü için farklı yaklaşımlar bulunmaktadır. Bunlardan bir tanesi her nokta için bu noktaya belli bir komşulukta bulunan noktalarla beraber görüntü oluşturulması ve ağın her noktadan elde edilen görüntülerle eğitilmesidir (Hu vd., 2016). Bir diğeri ise tüm nokta bulutundan

tek bir görüntü elde edilmesidir. Bu teknikte seçilen çözünürlüğe bağlı olarak her bir piksel bir nokta tarafından temsil edilir (Rizaldy vd., 2018). Bir başka yöntemde ise nokta bulutunun farklı açılardan görünümü 2B görüntüye dönüştürülerek ağı girdi verilmiş ve eğitilmiştir (Qin vd., 2018).




Şekil 4.3. Nokta-piksel dönüşümü


Tez kapsamında geliştirilen dönüşüm yazılımı kullanılarak eğitim ve test verileri 3B nokta bulutundan 2B görüntüye dönüştürülür. Yapılan çalışmada görüntü çözünürlükleri 0,5 m ve 1 m olarak seçilmiştir. Bunun anlamı ise LiDAR nokta bulutunun 0,5 m'lik ve 1 m'lik aralıklarla karelajlara bölünmesi ve bu karelajların her birinin görüntüdeki bir piksele karşılık gelmesidir (Şekil 4.3).

LiDAR verilerinin genel olarak nokta sıklığı düzensiz ve seyrek olabilmektedir. Görüntüye dönüşüm işleminde değer atanmamış pikseller oluşur ve bu piksellerin değerleri çeşitli enterpolasyon ve komşuluk teknikleri ile elde edilebilir. Görüntünün çözünürlüğüne bağlı olarak her piksele karşılık gelen karelajlardaki noktalardan en düşük veya en yüksek kotlu noktanın yükseklik değeri o piksele atanır. Bununla beraber eğitim sırasında kullanılacak referans görüntü için piksel noktalarının etiketleri içinde bir gri görüntü üretilir (Şekil 4.4). Bu değerler veride ki en küçük ve en büyük değer aralığında normalize edilerek 0-255 gri değerlerine çevrilir (Şekil 4.5). Böylece gri tonlu bir bant görüntü elde edilmiş olur. Farklı bir yaklaşımda ise yükseklik değerinin kullanıldığı formüller yardımı ile RGB renk düzenine çevirim yapılabilir. Diğer bantlar ise yukarıda bahsedilen farklı karakteristik özellikler aracılığı ile oluşturulabilir. Yapılan çalışmada piksel noktalarının yükseklik değeri, 40 metre komşuluktaki en düşük kotlu nokta ile arasındaki yükseklik farkı, yoğunluk değerleri, dönüş numarası ve toplam dönüş sayısı kullanılarak her biri için bir bant gri görüntü elde edilmiş ve eğitim verisi görüntülerine

eklenmiştir. En düşük kotlu noktadan üretilen görüntülerde dönüş numarası kullanılırken en yüksek kotlu noktadan üretilen görüntülerde toplam dönüş sayısı kullanılmıştır. En yüksek kotlu noktaların dönüş numarası bir olacağı için bu noktalarda toplam dönüş sayısı daha fazla anlam ifade edecektir. LiDAR'ın bu karakteristik özellikleri sayesinde ağır farklı sınıflar için öğrenme kabiliyeti artmıştır.




Şekil 4.4. (a) Nokta bulutu, (b) en düşük kotlu nokta için etiket görüntüsü, (c) en yüksek kotlu nokta için etiket görüntüsü



Şekil 4.5. Nokta bulutundan üretilen gri görüntüler: (1) En düşük kotlu nokta; (2) en yüksek kotlu nokta. Görüntüler, (a) yükseklik, (b) kot farkı, (c) yoğunluk ve (d) dönüş sayısı olmak üzere dört özellik içeren banttandır.

4.3. Ağ Mimarisinin Oluşturulması

Tez kapsamında kullanılacak ve eğitilecek evrişimsel sinir ağı modeli olarak U-Net ağ mimarisi seçilmiştir (Ronneberger vd., 2015). Bu ağ mimarisinin literatürdeki benzer çalışmalarda nokta bulutları için daha önce kullanılmamış olması ve tomografi görüntüleri üzerinde elde ettiği yüksek semantik sınıflandırma yüzdesi tez çalışması için seçilme sebeplerindedir. U-Net, tam evrişimli sinir ağı sınıfına dahil olan ve kodlayıcı ve çözümleyici olarak iki bölümden meydana gelen bir ağ mimarisidir (Şekil 4.6). Adını “U” şeklindeki yapısından alan bu ağ mimarisinin sol bölümü kodlayıcı olarak adlandırılırken sağ bölümü kod çözümleyici olarak adlandırılır.



Şekil 4.6. U-Net ağ mimarisi (Uyarlanmış)

Girdi olarak 272×272 piksel boyutlarındaki görüntüyü ve beraberinde sınıf etiketlerini temsil eden görüntüyü ağa girdi olarak alır ve bu görüntülere çeşitli sayıda filtreler uygulayarak özellik haritaları çıkarır. Filtre sayısı her iki katmandan sonra ikiye katlanarak 16, 32, 64, 128, 256 şeklinde artarken filtre boyutu 3×3 , 5×5 veya 7×7 olarak seçilebilir. 18 adet katmanın ilk dokuz katmanı yani kodlayıcı kısmında her görüntü için özellik haritası çıkarılırken görüntü boyutu her iki katmanda bir yarıya düşer. Sonraki kod çözümleyici kısımda bu görüntüler tekrar orijinal boyutuna çıkarılır. TESA mimarisine has bir özellik olan seyrek bağlantılı yapısı sayesinde kodlayıcı ve kod çözümleyici kısımlardaki katmanlar kendi aralarında toplanarak ağ yapısı tamamlanmaktadır. Katmanların toplanmasındaki tek şart görüntü boyutlarının eşit olmasıdır. Son katmanda sınıf sayısı kadar görüntü kanalına sahip, sınıf tahmin dağılımlarını içeren görüntü çıktısı üretilir. Toplamda 1,900,000'den daha fazla parametre hesaplanmış olur. Katman sayısı artırılarak hesaplanan ağırlıkların sayısı çoğaltılabilir ama bu işlem aynı zamanda hesaplama yükünü de arttıracaktır.

4.4. Derin Sinir Ağının Eğitilmesi

Tez çalışmasında önerilen TESA modelinin eğitimi için 4.2.1 bölümünde bahsedilen üç boyutlu nokta bulutundan üretilen iki boyutlu görüntülerin ve bunlara karşılık gelen, her bir pikseli nokta sınıflarını temsil eden referans görüntüleri sinir ağına girdi olarak verilir. Görüntüler, girdi sırası her seferinde kendi içlerinde karıştırılarak ağa girer ve önceden belirlenen tekrarda (epok) ile derin sinir ağı eğitilir. Ağ, her tekrarda kayıp fonksiyonunun ürettiği değeri küçülterek sınıflandırma doğruluğunu arttırmaya eğilimlidir. Bunu, 3.3.1 bölümünde bahsedildiği üzere her piksel değerine verdiği ağırlıkları güncelleyerek gerçekleştirir.

Çoklu sınıfları tahmin etmesi için eğitilen derin sinir ağlarının performansına direkt etki eden etkenlerden birisi sınıflar arasındaki dengesizliktir. Yani sınıfların kendi aralarında diğer sınıflara karşı baskın olduğu durumlarda derin sinir ağı da baskın sınıfa eğimli olarak eğitilir, böylece model sadece baskın sınıfa meyilli şekilde yanlış sonuçlar üretir. Önüne geçilmesi gereken bu durum için orijinal nokta bulutundan çıkarılan her nokta bulutu için içerdiği sınıfların yüzdesini hesaplayan bir fonksiyon tez kapsamında geliştirilen yazılıma eklenmiştir. Herhangi bir sınıfın eşik değerinin altında kaldığı nokta bulutu için görüntü oluşturulmaz ve eğitim verileri içerisine dahil edilmez. Bu sayede modelin yanlış eğitilmesi engellenmiş olur. Eşik değeri 0,05 olarak belirlenmiştir.

Tez kapsamında önerilen derin sinir ağı Python programlama dili kullanılarak geliştirilmiştir. Yazılım, Google tarafından geliştirilen Tensorflow ve Keras derin öğrenme kütüphanelerinden faydalanılarak grafik işlemciyi kullanacak şekilde kodlanmıştır. Grafik işlemcinin kullanılmasının sebebi normal işlemcilere göre görüntü işleme problemlerinde devasa boyutlarda hesaplama hızına sahip olmasıdır.

Yazılım beş aşamadan oluşmaktadır. Bunlar; veri hazırlığı, modelin oluşturulması, ağın eğitimi, sonuç üretilmesi ve değerlendirme aşamasıdır.

Bölüm 4.2 ve 4.3'te LiDAR verilerini ağa girdi olacak şekilde hazırlamak için uygulanan ön işlemlerden ve ağın mimarisi hakkında bilgi verilmişti. Verilerin görüntüye dönüştürülmesi ve derin sinir ağı modeli oluşturulurken kullanılan birçok parametre bulunmaktadır. Bunlar geometrik parametreler ve sinir ağı ile ilgili hiper-parametreler olarak ikiye ayrılır. Hiper-parametreler ağın yapısını ve ağın nasıl eğitildiğini belirleyen değişkenlerin tümünü temsil eder. Geometrik parametreler aşağıdaki gibi listelenebilir;

 LiDAR noktalarının kotları

- LiDAR noktasının kotu ile 40 metre çapında komşuluğundaki en düşük kot arasındaki fark
- LiDAR noktasının yoğunluk değeri
- LiDAR noktasına ait dönüş sayısı

Hiper-parametreler ise aşağıda verilmiştir.

- Öğrenme oranı (*learning rate*), ağıın parametrelerinin hangi hızda güncelleneceğini belirler.
- Seyreltme veya bırakma (*dropout*), ağıın ezberlemesinin önüne geçmek için kullanılan, sinir ağı içerisindeki nöronların belirli bir oranının rastgele devre dışı bırakılmasına dayanan tekniktir.
- Eğitim paket sayısı (*batch size*), ağı girdi olarak verilen eğitim verisinden çıkarılan alt kümeleri temsil eder.
- Kayıp fonksiyonu (*loss function*), eğitim sırasında tahmin edilen değerler ile gerçek değerler arasındaki farkı hesaplayan fonksiyondur.

Tez kapsamında önerilen derin sinir ağı ve işlemlerin yürütüldüğü bilgisayarın donanım ve yazılım bilgisi şu şekildedir;

- İşlemci: Intel i5-6500 @ 3.2 Ghz (4 çekirdek)
- Bellek: 16 GB
- Grafik Kartı: Nvidia GeForce GTX-1060 (3 GB bellek)
- İşletim Sistemi: Windows 10
- Python 3.5
- TensorFlow 2.2.1
- CUDA 10
- cuDNN 7

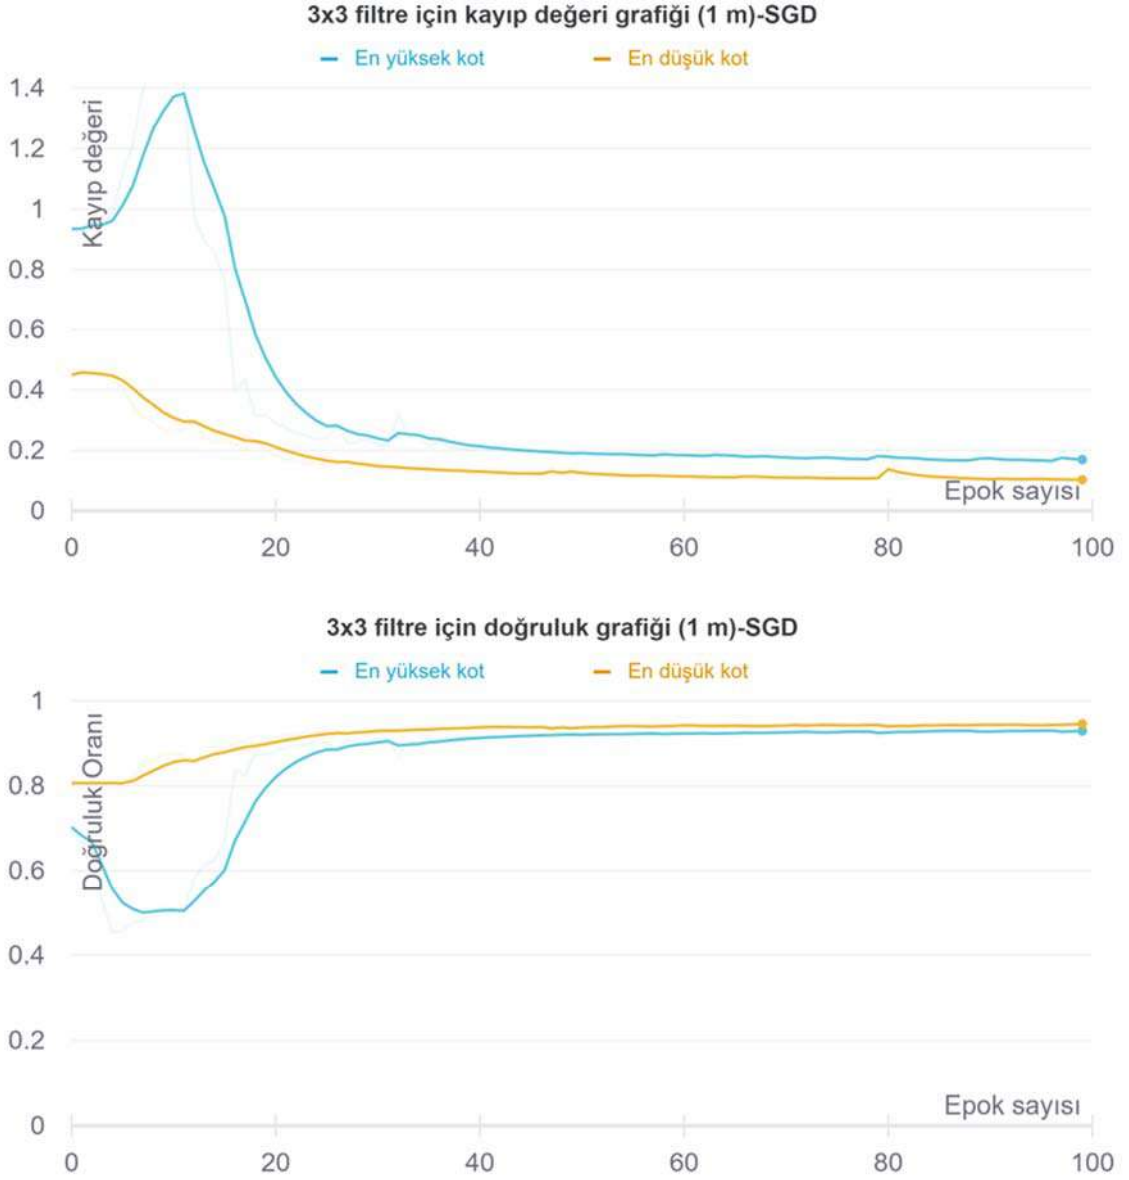
Bu tez çalışmasında önerilen TESA modeli Bergen 2018 ve DALES LiDAR veri setleri kullanılarak ayrı ayrı eğitilmiştir. Veri setlerinin eğitimi için iki farklı optimizasyon algoritması tercih edilmiş ve performansları karşılaştırılmıştır. Bunlar, Olasılıksal eğitim düşümü (*SGD*) ve Adaptif moment tahmin (*ADAM*) fonksiyonlarıdır. Bölüm 3.2.1’de bahsedildiği üzere kayıp fonksiyonunun ürettiği skaler değeri küçültmek

yani gerçek deęer ile tahmin edilen deęer arasındaki farkı en aza indirmek için aęırlıklar ile sapmaları g¼ncellemek derin ¼ęrenme teknięinin temel amacıdır. Optimizasyon algoritmasının buradaki g¼revi ise kayıp fonksiyonunun alacaęı en k¼çük deęer için aęırlıkları ve sapmaları en hızlı Őekilde g¼ncellemeye yardımcı olmaktır. Aęın performansına direkt etki edecek olması nedeniyle optimizasyon fonksiyonlarının seęimi kritik ¼nem taŐır.

¼nerilen TESA mimarisi için eęitim sırasında kullanılan hiper-parametreler, 0,5 m ve 1 m ¼z¼n¼rl¼kleri için ¼izelge 4.3'te verilmiŐtir. İlk eęitim Bergen 2018 LiDAR veri seti ile yapılmıŐtır. Her iki optimizasyon algoritması ve ¼ç farklı filtre boyutu (3x3, 5x5 ve 7x7) seęilerek 0,5 m ve 1 m ¼z¼n¼rl¼kte ¼retilen g¼r¼nt¼lerle ayrı ayrı eęitilen aę modellerinin kayıp fonksiyon deęer ve doęruluk grafikleri ayrı ayrı verilmiŐtir (Őekil 4.7-4.18). Seęilen hiper-parametreler Rizaldy vd. ¼alıŐmasından temel alınarak belirlenmiŐtir (Rizaldy vd., 2018).

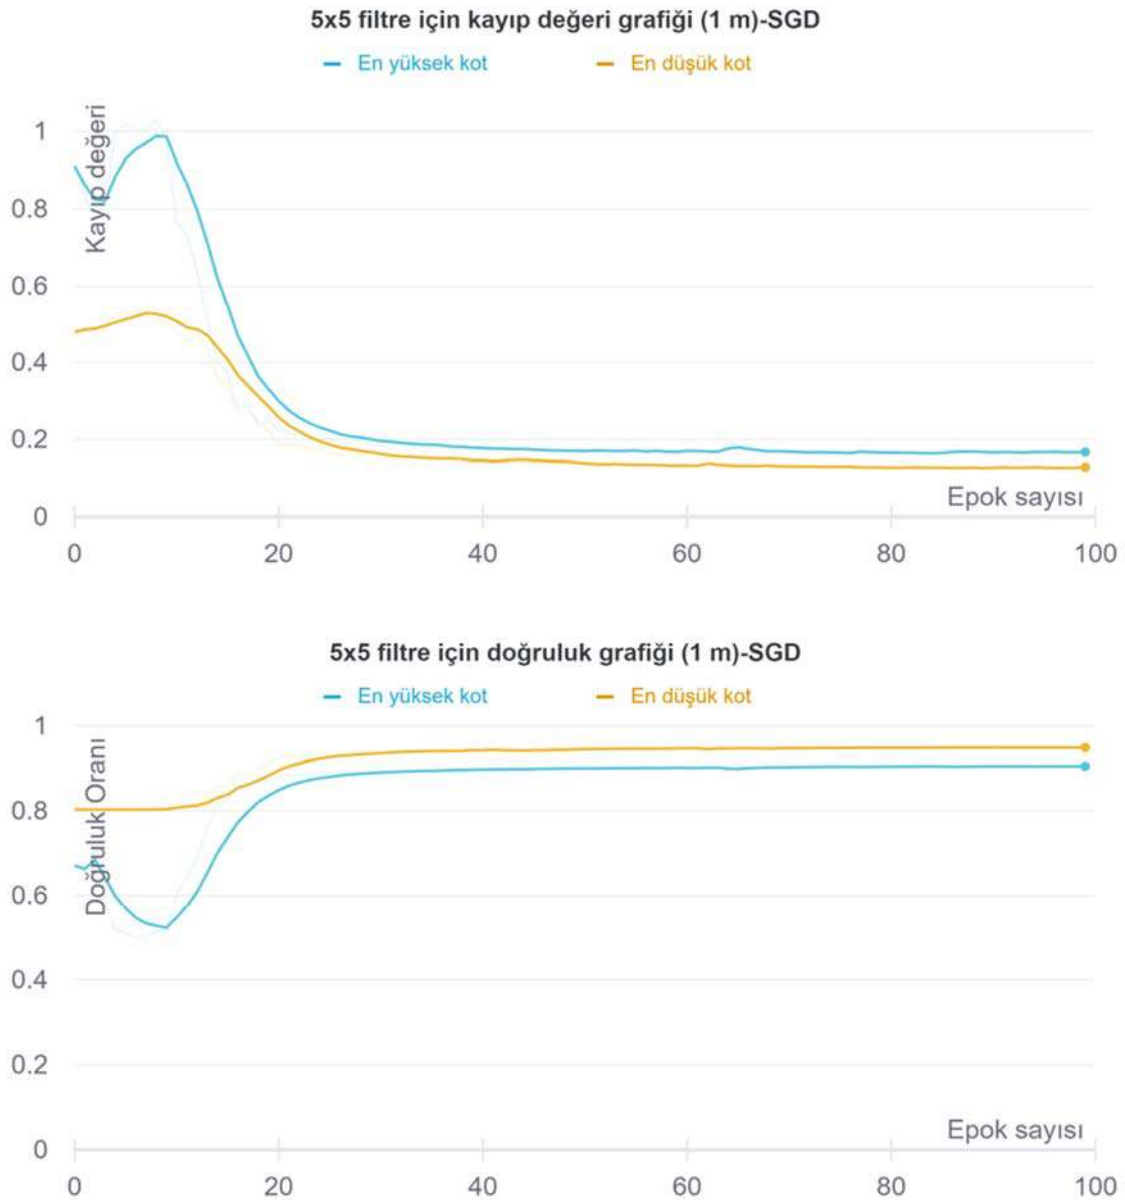
¼izelge 4.3. Bergen 2018 LiDAR veri setinin eęitimi için seęilen hiper-parametreler

Optimizasyon algoritması	Filtre boyutu	Paket b¼y¼kl¼ę¼ (0,5 m)	Paket b¼y¼kl¼ę¼ (1 m)	¼ęrenme Oranı	Epok sayısı	Seyreltme oranı
SGD	3x3	4	18	0,01	100	0,1
	5x5	4	18	0,01	100	0,1
	7x7	4	18	0,01	100	0,1
ADAM	3x3	4	18	0,01	100	0,1
	5x5	4	18	0,01	100	0,1
	7x7	4	18	0,01	100	0,1



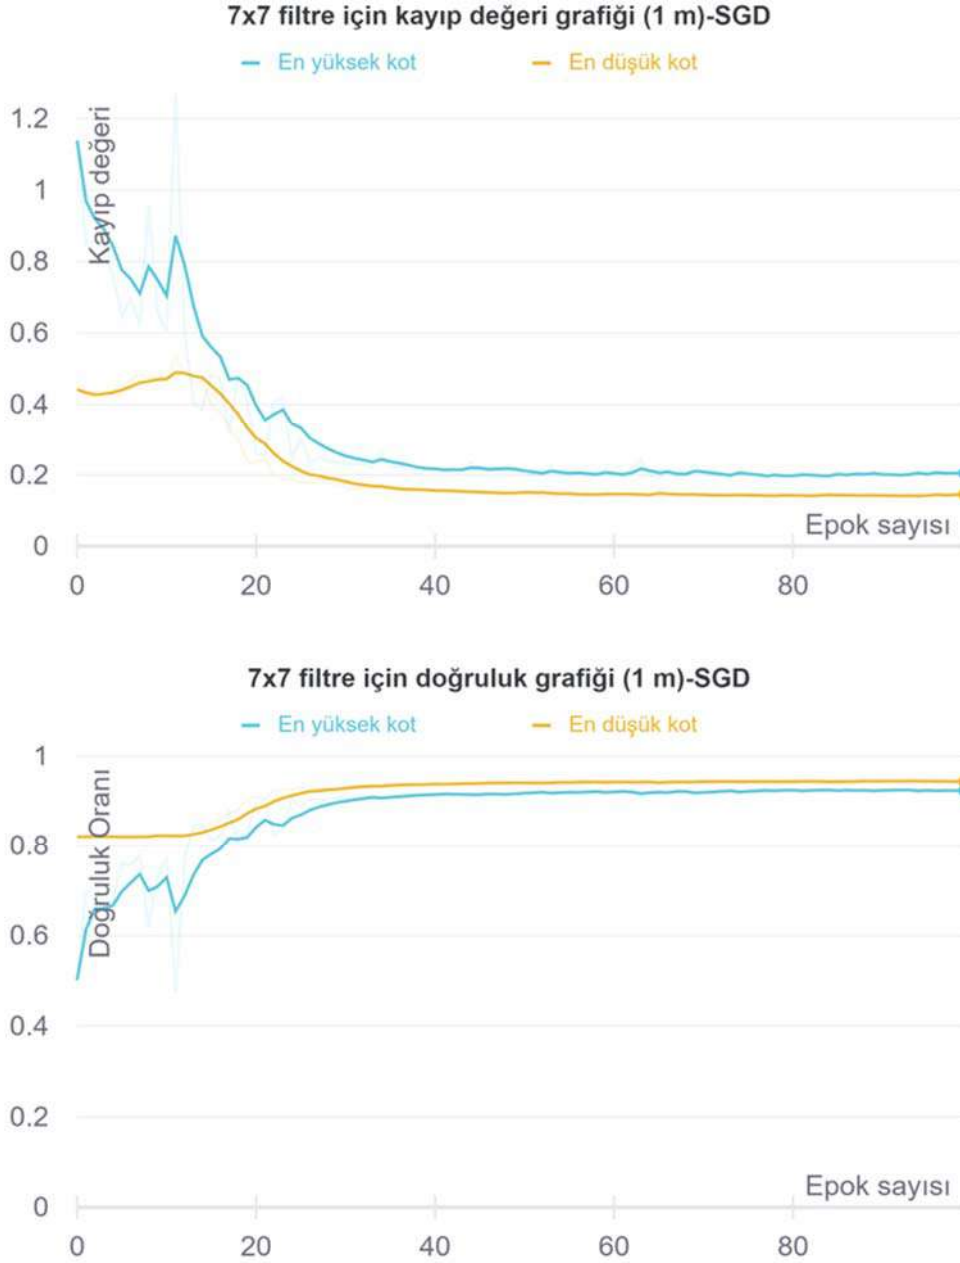
Şekil 4.7. Bergen 2018 LiDAR veri setinde 3x3 filtre boyutu ve SGD optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (1m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.7’de görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 1m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,10 ve 0,16 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,95 ve 0,93 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.



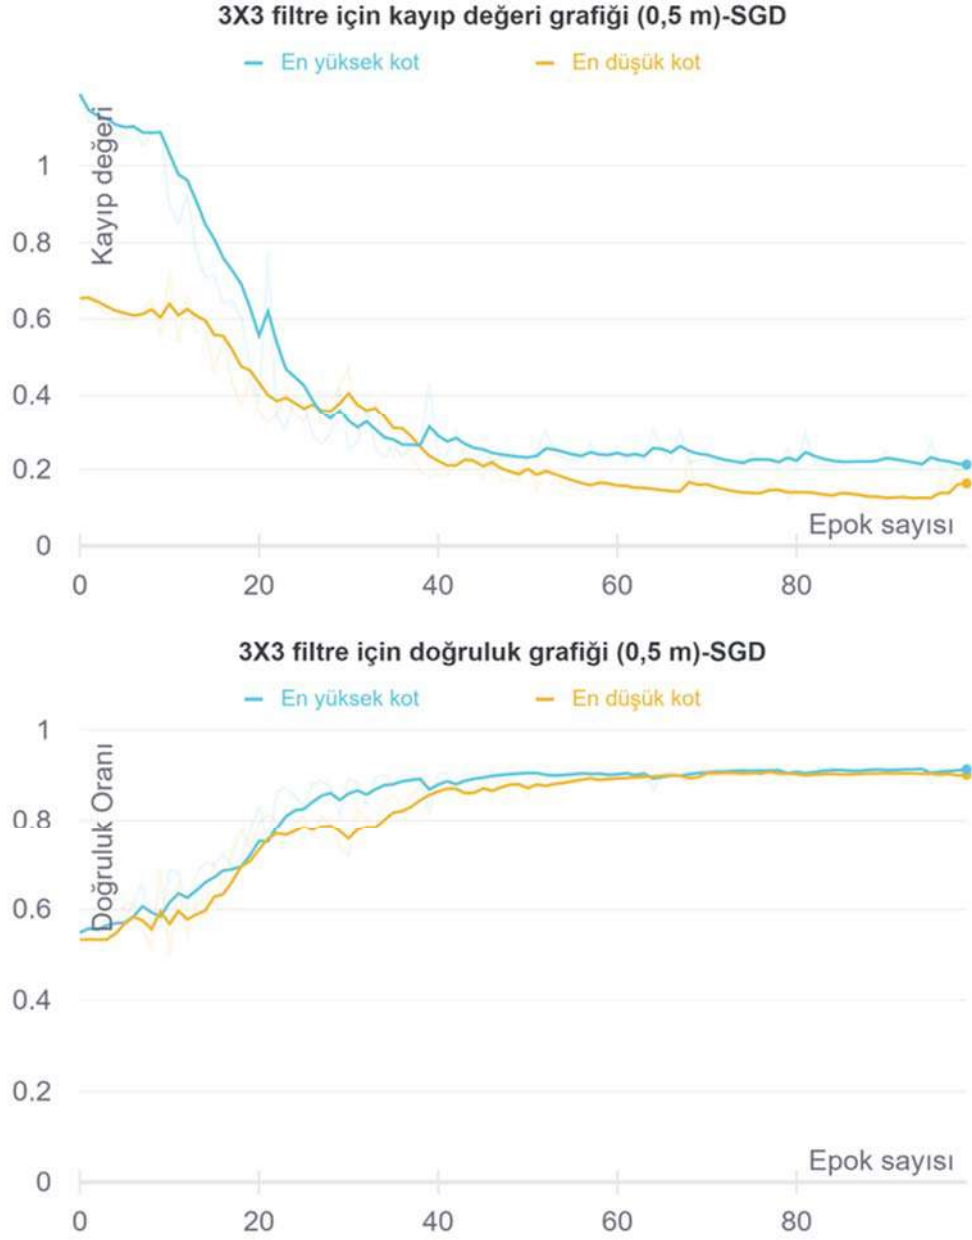
Şekil 4.8. Bergen 2018 LiDAR veri setinde 5x5 filtre boyutu ve SGD optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (1m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.8’de görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 1m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,13 ve 0,17 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,95 ve 0,91 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.




Şekil 4.9. Bergen 2018 LiDAR veri setinde 7x7 filtre boyutu ve SGD optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (1m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.9’da görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 1m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,15 ve 0,20 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,94 ve 0,92 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.



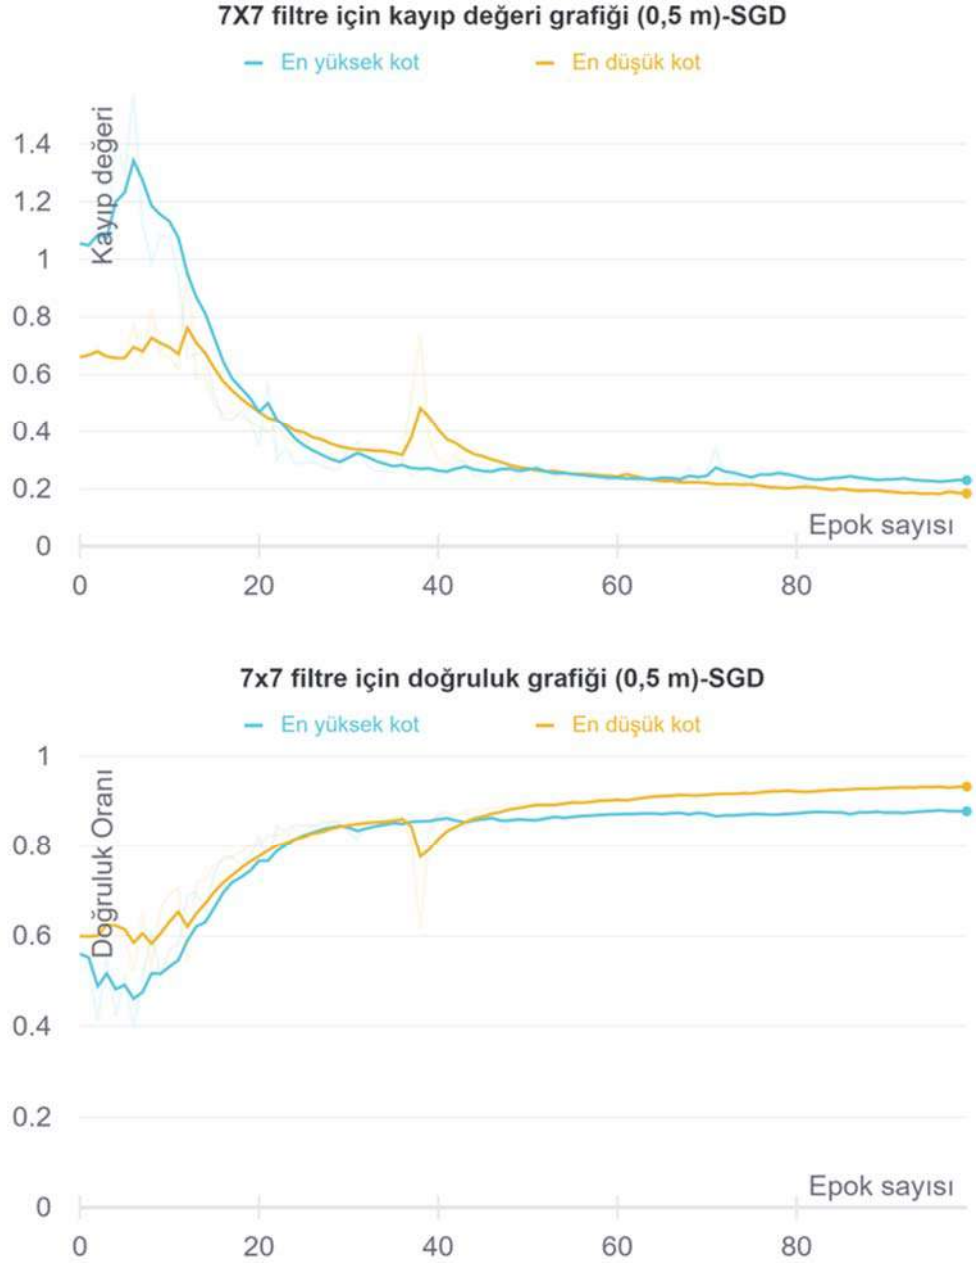
Şekil 4.10. Bergen 2018 LiDAR veri setinde 3x3 filtre boyutu ve SGD optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (0,5m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.10’da görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 0,5m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,17 ve 0,21 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,90 ve 0,92 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.




Şekil 4.11. Bergen 2018 LiDAR veri setinde 5x5 filtre boyutu ve SGD optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (0,5m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.11’de görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 0,5m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,12 ve 0,18 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,95 ve 0,94 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.



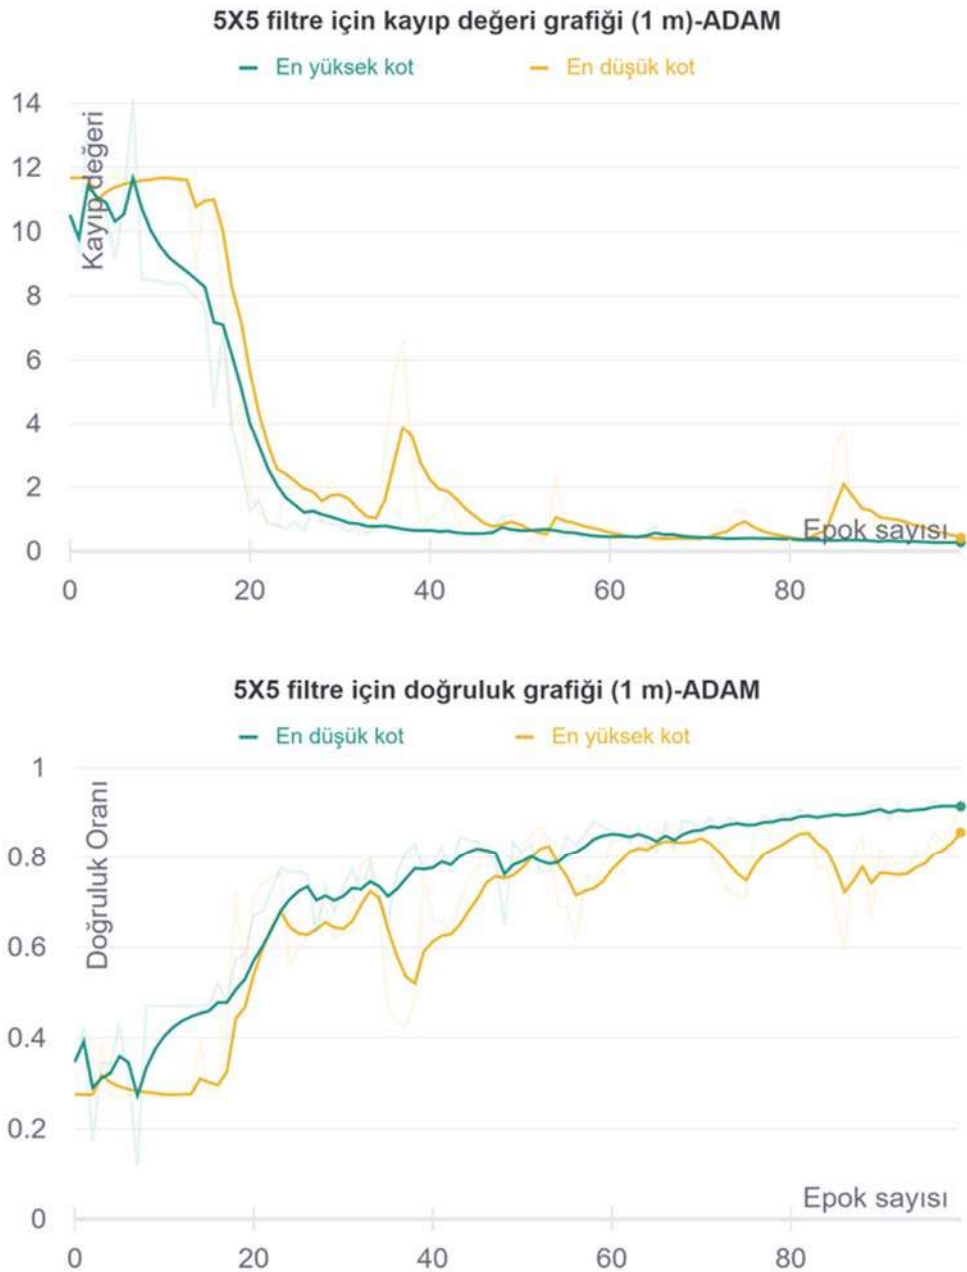
Şekil 4.12. Bergen 2018 LiDAR veri setinde 7x7 filtre boyutu ve SGD optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (0,5m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.12’de görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 0,5m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,18 ve 0,23 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,93 ve 0,88 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.



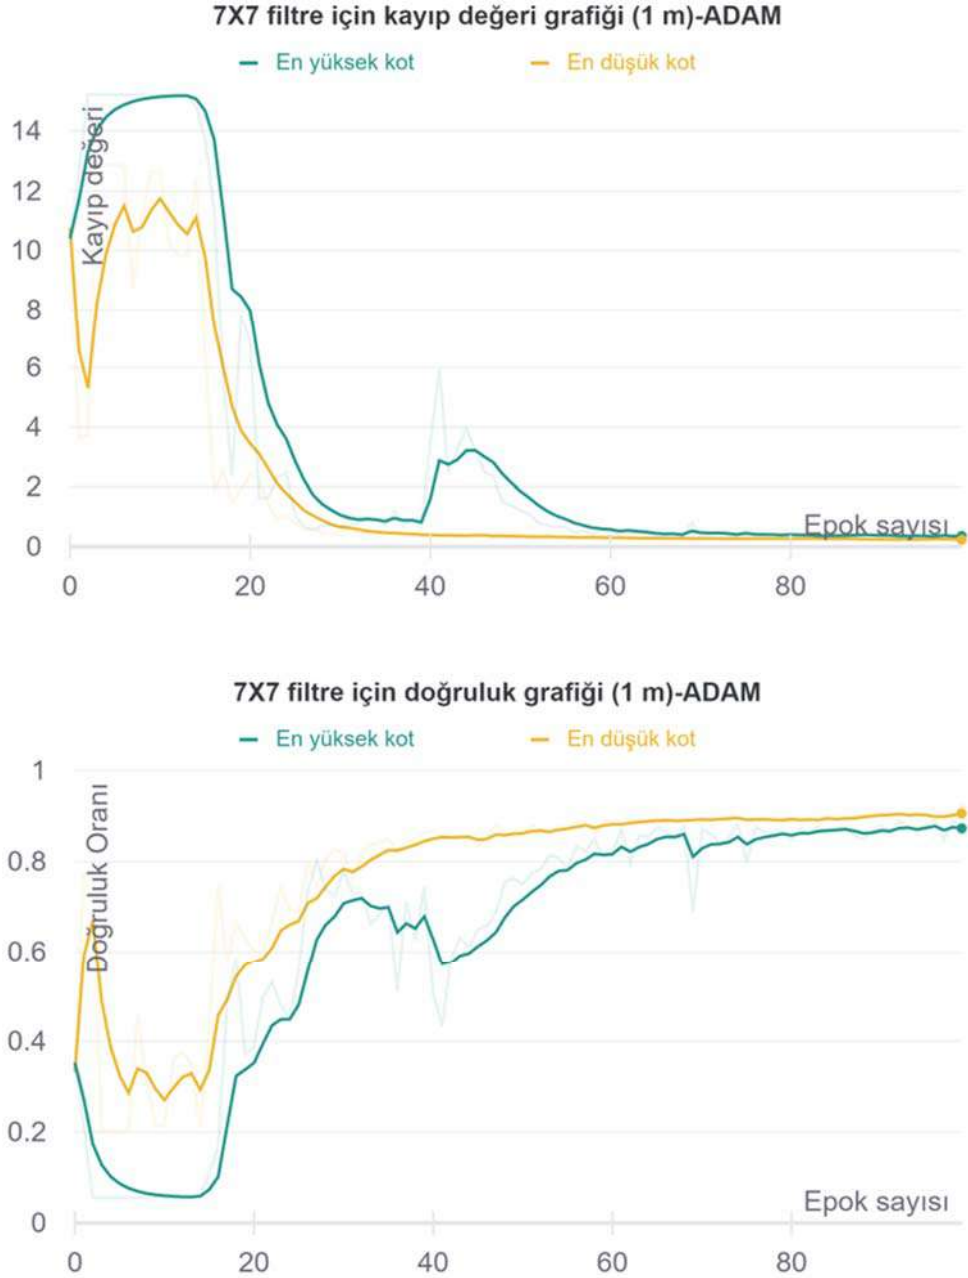
Şekil 4.13. Bergen 2018 LiDAR veri setinde 3x3 filtre boyutu ve ADAM optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (1m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.13'te görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 1m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,33 ve 0,19 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,89 ve 0,93 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.




Şekil 4.14. Bergen 2018 LiDAR veri setinde 5x5 filtre boyutu ve ADAM optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (1m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.14'te görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 1m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,21 ve 0,28 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,91 ve 0,91 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.



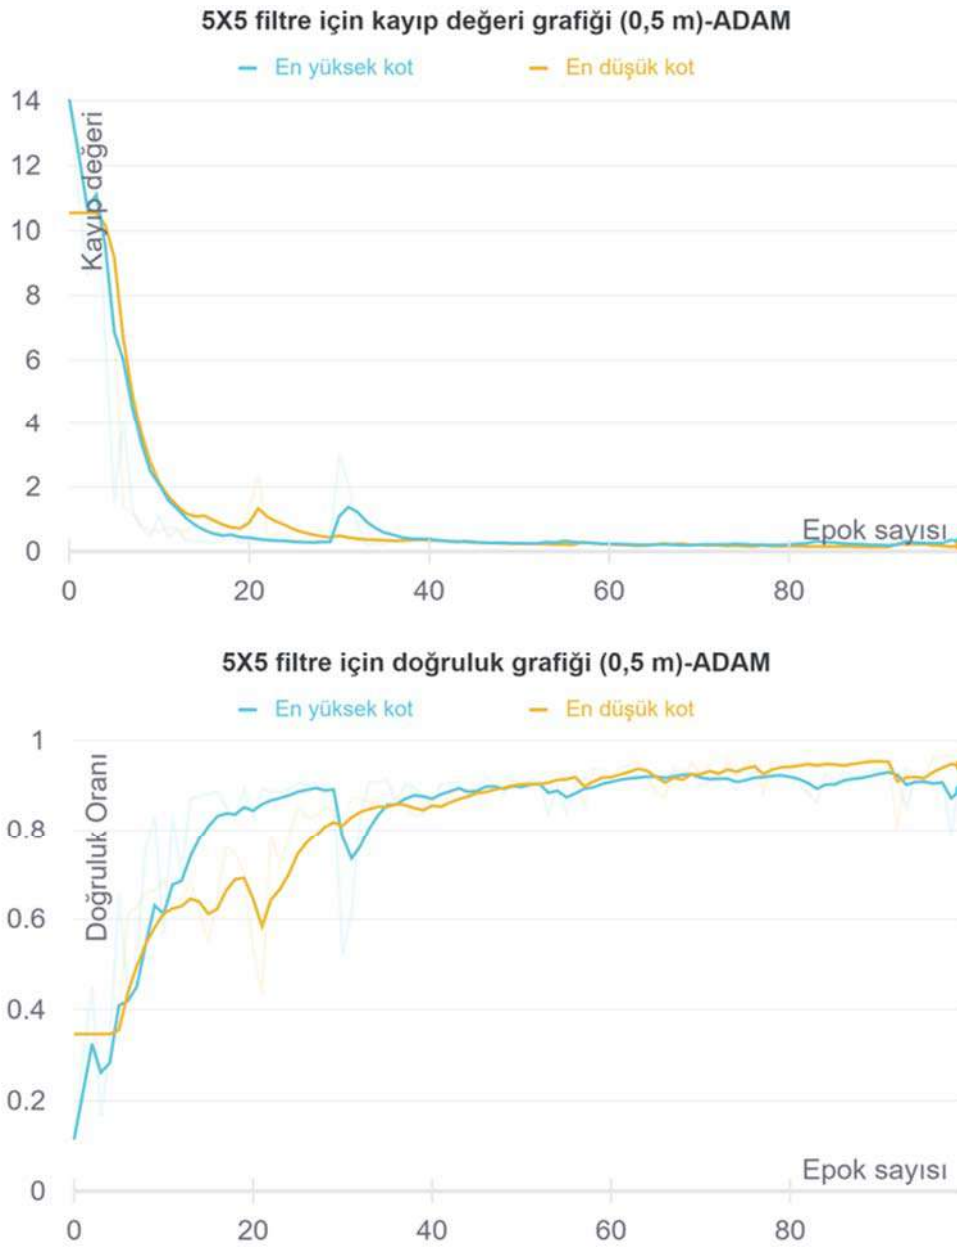
Şekil 4.15. Bergen 2018 LiDAR veri setinde 7x7 filtre boyutu ve ADAM optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (1m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.15'te görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 1m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,22 ve 0,38 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,92 ve 0,87 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.



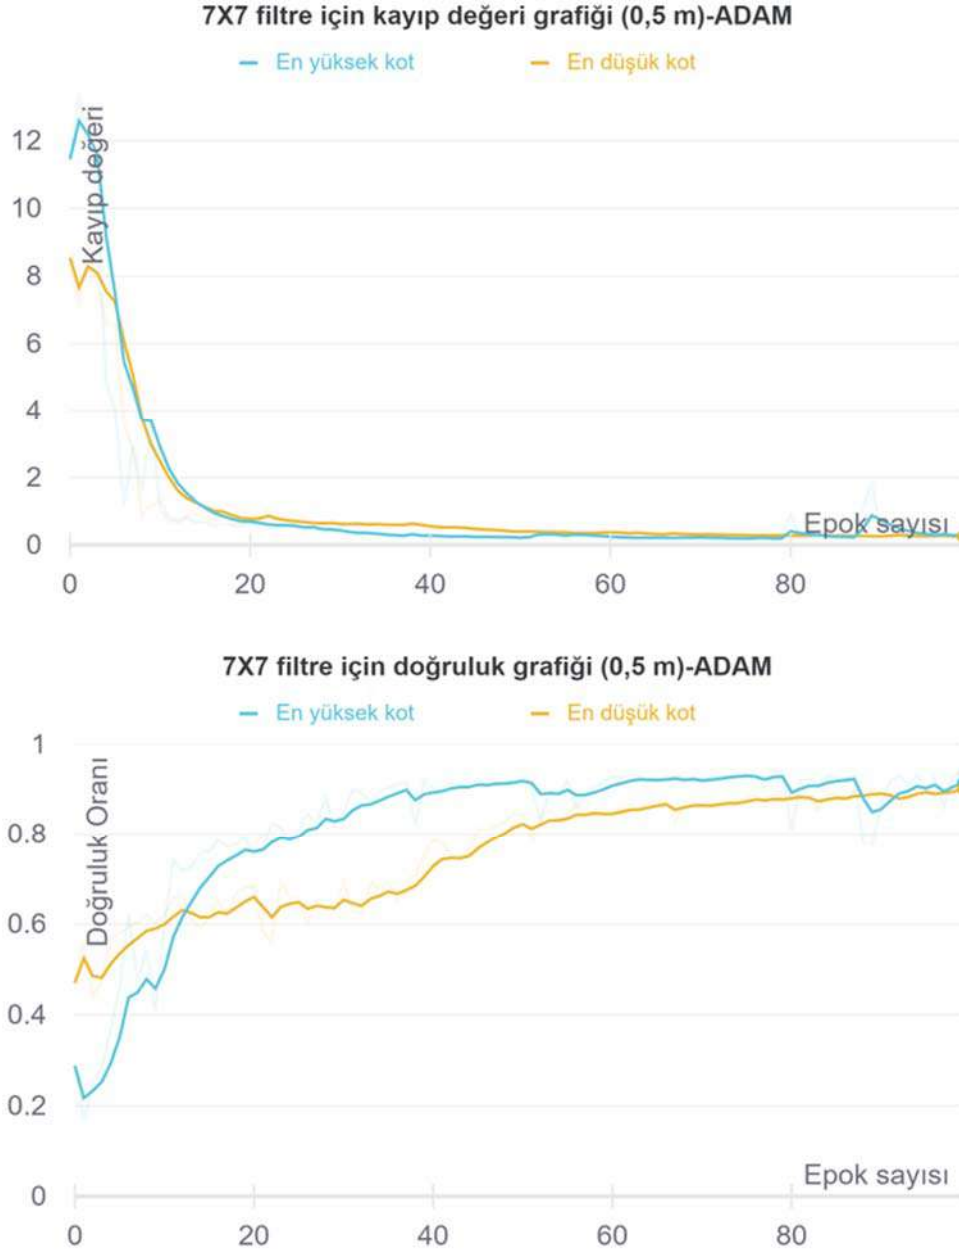
Şekil 4.16. Bergen 2018 LiDAR veri setinde 3x3 filtre boyutu ve ADAM optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (0,5m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.16’da görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 1m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,13 ve 0,07 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,96 ve 0,96 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.



Şekil 4.17. Bergen 2018 LiDAR veri setinde 5x5 filtre boyutu ve ADAM optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (0,5m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.17’de görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 1m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,18 ve 0,15 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,94 ve 0,94 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.



Şekil 4.18. Bergen 2018 LiDAR veri setinde 7x7 filtre boyutu ve ADAM optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (0,5m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.


Şekil 4.18’de görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 1m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,21 ve 0,19 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,91 ve 0,94 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.

Bergen 2018 veri seti üzerinde SGD ve ADAM optimizasyon algoritmaları kullanılarak gerçekleştirilen 12 farklı eğitim için elde edilen ortalama doğruluk değerleri en düşük ve en yüksek kot için Çizelge 4.4'te verilmiştir.

Çizelge 4.4. Bergen 2018 LiDAR veri setinin eğitim sonucu elde ettiği doğruluk değerleri


		0,5 m		1 m	
		SGD	ADAM	SGD	ADAM
Filtre boyutu	3x3	0,91	0,96	0,91	0,94
	5x5	0,95	0,94	0,91	0,93
	7x7	0,91	0,93	0,89	0,93

İkinci eğitim DALES LiDAR veri seti üzerinde gerçekleştirilmiştir. Yine her iki optimizasyon algoritması ve üç farklı filtre boyutu (3x3, 5x5 ve 7x7) seçilerek 0,5 m ve 1 m çözünürlükte üretilen görüntülerle ayrı ayrı eğitim yapılmıştır. 12 farklı eğitim sonucunda elde edilen kayıp değerleri ve doğruluk sonuçları Şekil 4.19-4.30'da verilmiştir.



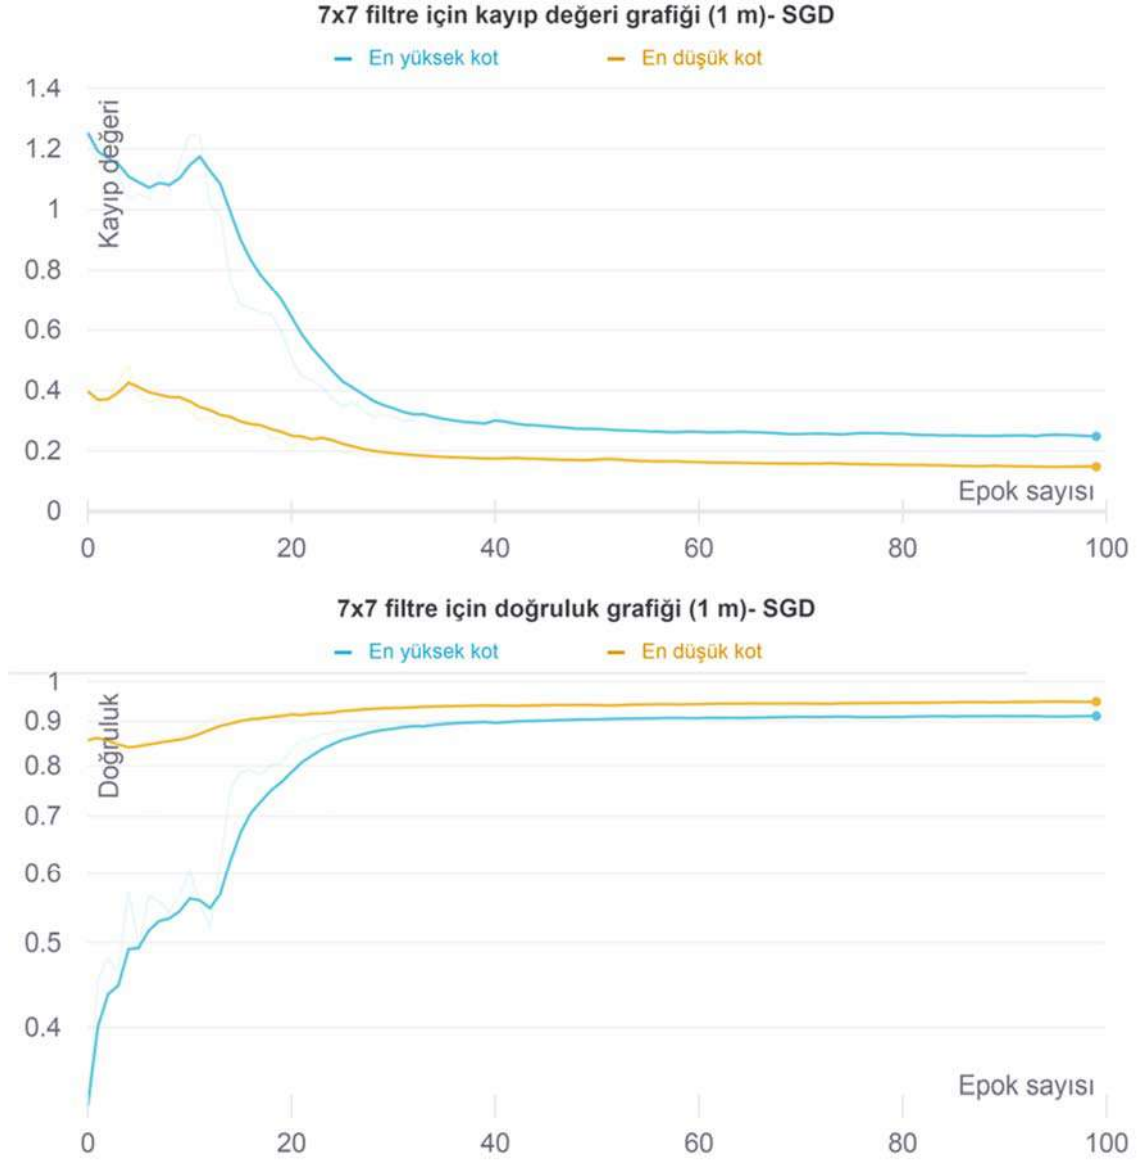
Şekil 4.19. DALES LiDAR veri setinde 3x3 filtre boyutu ve SGD optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (1m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.19’da görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 1m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,13 ve 0,23 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,95 ve 0,92 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.




Şekil 4.20. DALES LiDAR veri setinde 5x5 filtre boyutu ve SGD optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (1m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.20’de görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 1m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,13 ve 0,26 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,95 ve 0,91 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.




Şekil 4.21. DALES LiDAR veri setinde 7x7 filtre boyutu ve SGD optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (1m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.21’de görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 1m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,15 ve 0,25 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,95 ve 0,92 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.




Şekil 4.22. DALES LiDAR veri setinde 3x3 filtre boyutu ve SGD optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (0,5m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.22’de görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 1m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,26 ve 0,19 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,92 ve 0,94 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.




Şekil 4.23. DALES LiDAR veri setinde 5x5 filtre boyutu ve SGD optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (0,5m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.23'te görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 1m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,17 ve 0,21 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,94 ve 0,93 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.




Şekil 4.24. DALES LiDAR veri setinde 7x7 filtre boyutu ve SGD optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (0,5m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.24'te görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 1m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,24 ve 0,29 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,91 ve 0,90 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.




Şekil 4.25. DALES LiDAR veri setinde 3x3 filtre boyutu ve ADAM optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (1m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.25'te görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 1m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,09 ve 0,17 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,97 ve 0,94 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.




Şekil 4.26. DALES LiDAR veri setinde 5x5 filtre boyutu ve ADAM optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (1m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.26’da görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 1m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,1 ve 0,19 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,97 ve 0,93 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.




Şekil 4.27. DALES LiDAR veri setinde 7x7 filtre boyutu ve ADAM optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (1m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.27’de görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 1m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,13 ve 0,2 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,95 ve 0,93 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.




Şekil 4.28. DALES LiDAR veri setinde 3x3 filtre boyutu ve ADAM optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (0,5m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.28’de görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 1m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,27 ve 0,25 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,87 ve 0,87 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.



Şekil 4.29. DALES LiDAR veri setinde 5x5 filtre boyutu ve ADAM optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (0,5m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.29’da görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 1m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,35 ve 0,30 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,86 ve 0,90 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.



Şekil 4.30. DALES LiDAR veri setinde 7x7 filtre boyutu ve ADAM optimizasyon algoritması kullanılan model için eğitim kayıp fonksiyon ve doğruluk grafiği (0,5m çözünürlükte). Grafik değerleri yumuşatılmıştır, soluk çizgiler gerçek değerleri temsil etmektedir.

Şekil 4.30’da görüldüğü üzere en düşük ve en yüksek kotlu noktalardan 1m çözünürlükte üretilen görüntüler için 100 epok eğitim sonucunda kayıp fonksiyon için elde edilen en iyi değer (en küçük değer) sırasıyla 0,29 ve 0,34 olmuştur. Eğitimin doğruluk değerleri ise sırasıyla 0,89 ve 0,82 olarak elde edilmiştir. Piksel tabanlı doğruluğu temsil eden bu değerler için 3B nokta bulutuna dönüşüm sonrası sınıflandırma sonuçları sonraki bölümde ele alınacaktır.

DALES veri seti üzerinde SGD ve ADAM optimizasyon algoritmaları kullanılarak gerçekleştirilen 12 farklı eğitimde en düşük ve en yüksek kot için elde edilen ortalama doğruluk değerleri Çizelge 4.5'te verilmiştir.

Çizelge 4.5. DALES LiDAR veri setinin eğitim sonucu elde ettiği doğruluk

		0,5 m		1 m	
		SGD	ADAM	SGD	ADAM
Filtre boyutu	3x3	0,93	0,87	0,94	0,95
	5x5	0,93	0,82	0,93	0,95
	7x7	0,91	0,83	0,93	0,94

4.4.1. 2B görüntüden 3B nokta bulutuna dönüşüm

Piksel tabanlı sınıflandırma işleminde oldukça iyi bir performans ortaya koyan ağ mimarisinin tahminlerini 3B nokta bulutuna aktarırken aşağıda belirtilen teknikler uygulanmıştır.

- Çözünürlüğe bağlı olarak belirlenen karelajlar 2B görüntülerde bir piksele karşılık gelmektedir, bu nedenle söz konusu piksellere atanan sınıf değerleri en düşük ve en yüksek kot değerine sahip noktaların atanacağı sınıfları belirlemektedir.
- En düşük ve en yüksek kotlu noktalar dışında kalan noktalar için ise LiDAR verisinin düşey doğruluğunu referans olarak belirlenen eşik değer, yer noktalarının sınıflandırılmasında kullanılmıştır. Bergen 2018 veri seti için düşey doğruluk proje raporunda 5 cm olarak belirtilmiştir. DALES veri seti içinde eşik değer 5 cm olarak kabul edilmiştir.
- Buna göre, en düşük kot değerinin 5 cm üzerinde kalan noktalar en yüksek kotlu noktanın sınıfına atanır. Altında kalan noktalar ise yer noktası olarak sınıflandırılır.

5. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu bölümde tez kapsamında önerilen derin sinir ağının eğitim, doğrulama ve test sonuçları verilerek yorumlandı. Sinir ağının performansına etki eden faktörlerden bahsedildi. Derin sinir ağının tahminlerinin üç boyutlu nokta bulutuna aktarılmasında kullanılan teknikler ayrıntılı şekilde açıklandı. Önerilen TESA modelinin LiDAR nokta bulutu filtreleme ve sınıflandırma performansı ticari yazılımlar ile karşılaştırılarak sonuçlar tartışıldı.

5.1. Sınıflandırma Sonuçlarının Performans Analizi

Derin sinir ağının piksel tabanlı yaptığı sınıflandırma tahminleri 3B LiDAR nokta bulutuna aktarıldıktan sonra referans veriler ile kıyaslanması, sonuçların raporlanması ve hata matrislerinin çizdirilmesi amacıyla tez kapsamında Python programlama dili kullanılarak otomatik bir değerlendirme programı geliştirilmiştir. Buna göre yazılım eğitim esnasında kaydedilen en başarılı modeli ve test nokta bulutlarını girdi olarak alır. Test verileri üzerinde tahminlerini yaparak her noktaya bir sınıf atayarak etiketler. Daha sonraki aşamada referans nokta bulutu ile derin sinir ağının sınıflandırdığı nokta bulutunu kıyaslayarak 3.1.2 bölümünde bahsedilen sınıflandırma ölçütlerine göre kesinlik, duyarlık, doğruluk ve F1 puanları hesaplar.

5.1.1. Bergen 2018 veri seti için sınıflandırma sonuçları

Çizelge 5.1-5.3'te Bergen 2018 LiDAR test verisi 1 için 3x3, 5x5 ve 7x7 filtre boyutları için 1 m ve 0,5 m çözünürlükte hem SGD hem de Adam optimizasyon algoritmaları ile eğitilen modellerin sınıflandırma puanları verilmiştir.

Çizelge 5.1. Bergen 2018 LiDAR test verisi 1 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,79	0,67	0,97	0,81	0,66	0,97
	Duyarlık	0,85	0,91	0,86	0,84	0,91	0,88
	F1 Puan	0,82	0,77	0,91	0,83	0,77	0,93
	Ort. F1	0,83			0,84		
	Doğruluk	0,86			0,87		
0,5 m	Kesinlik	0,77	0,79	0,98	0,94	0,77	0,99
	Duyarlık	0,92	0,82	0,87	0,89	0,94	0,98
	F1 Puan	0,84	0,81	0,92	0,92	0,84	0,98
	Ort. F1	0,87			0,91		
	Doğruluk	0,88			0,94		

Çizelge 5.2. Bergen 2018 LiDAR test verisi 1 için 5x5 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,85	0,67	0,97	0,82	0,66	0,97
	Duyarlık	0,85	0,90	0,90	0,84	0,93	0,88
	F1 Puan	0,85	0,77	0,93	0,83	0,77	0,92
	Ort. F1	0,85			0,84		
	Doğruluk	0,89			0,87		
0,5 m	Kesinlik	0,73	0,65	0,98	0,87	0,70	0,98
	Duyarlık	0,86	0,92	0,80	0,87	0,93	0,92
	F1 Puan	0,79	0,76	0,88	0,87	0,80	0,95
	Ort. F1	0,81			0,87		
	Doğruluk	0,83			0,90		


Çizelge 5.3. Bergen 2018 LiDAR test verisi 1 için 7x7 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,85	0,64	0,97	0,73	0,65	0,97
	Duyarlık	0,86	0,89	0,88	0,86	0,88	0,80
	F1 Puan	0,85	0,75	0,92	0,79	0,75	0,88
	Ort. F1	0,84			0,81		
	Doğruluk	0,88			0,83		
0,5 m	Kesinlik	0,82	0,73	0,99	0,85	0,72	0,99
	Duyarlık	0,89	0,89	0,89	0,88	0,91	0,91
	F1 Puan	0,85	0,80	0,94	0,87	0,80	0,95
	Ort. F1	0,86			0,87		
	Doğruluk	0,89			0,90		

Çizelge 5.1’de görüldüğü üzere model en iyi sınıflandırma performansını 3x3 filtre uygulanan 0,5 m çözünürlükte oluşturulan görüntülerde ADAM optimizasyon algoritması ile elde etmiştir. En iyi model için Bergen 2018 test verisi 1’in sınıflandırma hata matrisi Çizelge 5.4’te verilmiştir.

Çizelge 5.4. Bergen 2018 LiDAR test verisi 1 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma hata matrisi


Gerçek Değer	Yer	225860 (%89,31)	22312 (%8,82)	4723 (%1,87)
	Bitki Örtüsü	4186 (%5,02)	78279 (%93,96)	844 (%1,01)
	Yapı	9039 (%2,08)	1672 (%0,38)	423821 (%97,54)
		Yer	Bitki Örtüsü	Yapı
		Tahmin Edilen		



Şekil 5.1. (a) Test veri seti 1 için Referans nokta bulutu, (b) derin sinir ağının en iyi modeli ile sınıflandırılmış LiDAR nokta bulutu

Şekil 5.1’de Bergen 2018 test verisi 1 referans LiDAR nokta bulutu ve derin sinir ağının sınıflandırdığı LiDAR nokta bulutu verilmiştir. Tez kapsamında önerilen derin sinir ağı, test verisi 1’de bina cephe ve çatı noktalarını %97,54’lük doğruluk oranı ile oldukça başarılı şekilde sınıflandırmıştır. Bitki örtüsü noktalarını sınıflandırırken de aynı performansı göstermesine rağmen yer noktalarının %8,82’lik kısmını bitki örtüsü noktası olarak yanlış sınıflandırmıştır. Bunun başlıca nedeni ise derin sinir ağının piksel bazlı sınıflandırma yaptığı için aynı pikselde ki en yüksek ve en düşük kotlu noktaların bitki örtüsü sınıfına atanması olmuştur. Bu sebeple bitki örtüsü noktalarının %5,02’lik kısmını da yer noktası olarak yanlış etiketlemiştir.

Şekil 5.2’de LAStools, TerraScan ve QT Modeller yazılımları ile sınıflandırılmış Bergen 2018 test verisi 1 LiDAR nokta bulutunun görüntüleri gösterilmiştir. Çizelge 5.5’te ise bu yazılımların sınıflandırma puanları verilmiştir. QT Modeller yazılımı sadece yer ve yapı noktalarını sınıflandırma yeteneğine sahip olduğu için bu iki sınıf dışında kalan noktaları bitki örtüsü olarak etiketlemektedir. Bitki örtüsü sınıfı için ürettiği düşük F1 puanının ana sebebi budur. Her üç yazılımda, görüntüde sağ-alt kısımda bulunan geniş binanın bir parçası olan yapıyı doğru etiketleyememiştir. Ayrıca bina cephelerinde de derin sinir ağı yöntemine kıyasla sınıflandırma performansları oldukça düşük olmuştur.



Şekil 5.2. Ticari yazılımlar ile sınıflandırılan Bergen 2018 test verisi 1 (a) LAsTools (b) TerraScan (c) QT Modeller

Çizelge 5.5. Bergen 2018 LiDAR test verisi 1 için ticari yazılımların sınıflandırma puanları

	LAsTools			TerraScan			QT Modeller		
	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
F1 Puanı	0,98	0,96	0,99	0,96	0,95	0,97	0,97	0,61	0,98
Ort. F1	0,98			0,96			0,85		

Bergen 2018 LiDAR test verisi 2 için 3x3, 5x5 ve 7x7 filtre boyutları için 1 m ve 0,5 m çözünürlükte hem SGD hem de Adam optimizasyon algoritmaları ile eğitilen modellerin sınıflandırma puanları sırasıyla Çizelge 5.6-5.9'da verilmiştir.

Çizelge 5.6. Bergen 2018 LiDAR test verisi 2 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,84	0,86	0,74	0,88	0,86	0,92
	Duyarlık	0,33	0,98	0,72	0,33	0,99	0,64
	F1 Puan	0,46	0,92	0,73	0,48	0,92	0,76
	Ort. F1	0,70			0,72		
	Doğruluk	0,86			0,87		
0,5 m	Kesinlik	0,78	0,88	0,77	0,91	0,88	0,89
	Duyarlık	0,41	0,97	0,89	0,39	0,99	0,92
	F1 Puan	0,54	0,92	0,82	0,55	0,93	0,91
	Ort. F1	0,76			0,80		
	Doğruluk	0,87			0,88		

Çizelge 5.7. Bergen 2018 LiDAR test verisi 2 için 5x5 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,85	0,86	0,39	0,86	0,86	0,89
	Duyarlık	0,33	0,97	0,69	0,33	0,99	0,66
	F1 Puan	0,47	0,92	0,50	0,48	0,92	0,76
	Ort. F1	0,63			0,72		
	Doğruluk	0,85			0,86		
0,5 m	Kesinlik	0,83	0,87	0,85	0,92	0,87	0,87
	Duyarlık	0,39	0,98	0,82	0,38	0,99	0,88
	F1 Puan	0,53	0,92	0,84	0,54	0,93	0,87
	Ort. F1	0,76			0,78		
	Doğruluk	0,87			0,88		


Çizelge 5.8. Bergen 2018 LiDAR test verisi 2 için 7x7 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,88	0,86	0,50	0,81	0,86	0,76
	Duyarlık	0,30	0,98	0,63	0,33	0,98	0,49
	F1 Puan	0,45	0,92	0,56	0,47	0,92	0,59
	Ort. F1	0,64			0,66		
	Doğruluk	0,85			0,86		
0,5 m	Kesinlik	0,78	0,87	0,90	0,80	0,88	0,75
	Duyarlık	0,39	0,98	0,81	0,41	0,97	0,86
	F1 Puan	0,52	0,92	0,85	0,54	0,92	0,80
	Ort. F1	0,76			0,75		
	Doğruluk	0,87			0,87		

Çizelge 5.6'da görüldüğü üzere model en iyi sınıflandırma performansını 3x3 filtre uygulanan 0,5 m çözünürlükte oluşturulan görüntülerde ADAM optimizasyon algoritması ile elde etmiştir. En iyi model için Bergen 2018 test verisi 2'nin sınıflandırma hata matrisi Çizelge 5.9'da verilmiştir.

Çizelge 5.9. Bergen 2018 LiDAR test verisi 2 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma hata matrisi

Gerçek Değer	Yer	74255 (%39,34)	113817 (%60,30)	669 (%0,35)
	Bitki Örtüsü	6504 (%0,78)	823777 (%99,08)	1165 (%0,14)
	Yapı	546 (%3,32)	717 (%4,36)	15193 (%92,32)
		Yer	Bitki Örtüsü	Yapı
		Tahmin Edilen		




Şekil 5.3. (a) Test veri seti 2 için Referans nokta bulutu, (b) derin sinir ağının en iyi modeli ile sınıflandırılmış LiDAR nokta bulutu

Şekil 5.3'te Bergen 2018 test verisi 2 referans LiDAR nokta bulutu ve derin sinir ağının sınıflandırdığı LiDAR nokta bulutu verilmiştir. Derin sinir ağı, test verisi 2'de bitki örtüsü noktalarını %99,08'lik doğruluk oranı ile oldukça başarılı şekilde sınıflandırmıştır. Bunun yanı sıra yer noktalarını sınıflandırma da %39,34'lük doğruluk oranı ile aynı başarıyı gösterememiştir. Bunun başlıca nedeni ise sık bitki örtüsünün bulunduğu yüksek eğimli bölgede yer noktalarını doğru şekilde belirleyememesidir.

Şekil 5.4'de LAStools, TerraScan ve QT Modeller yazılımları ile sınıflandırılmış Bergen 2018 test verisi 2 LiDAR nokta bulutunun görüntüleri gösterilmiştir. Çizelge 5.10'da ise bu yazılımların sınıflandırma puanları verilmiştir. QT Modeller burada da bitki örtüsü sınıfı için düşük F1 puanı üretmiştir. Terrascan eğimin fazla olduğu bölgede bitki örtüsü noktalarının sınıflandırmasında hata yapmıştır. Önerilen derin sinir ağı yöntemi, yapı noktalarının sınıflandırmasında F1 skoru bakımından QT Modeller yazılımını geçerek LAStools ve Terrascan yazılımlarını yakalamıştır.

Çizelge 5.10. Bergen 2018 LiDAR test verisi 2 için ticari yazılımların sınıflandırma puanları

	LAStools			TerraScan			QT Modeller		
	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
F1 Puanı	0,99	0,99	0,91	0,98	0,99	0,91	0,96	0,66	0,80
Ort. F1	0,96			0,96			0,81		



Şekil 5.4. Ticari yazılımlar ile sınıflandırılan Bergen 2018 test verisi 2 (a) LAsTools (b) TerraScan (c) QT Modeler

Bergen 2018 LiDAR test verisi 3 için 3x3, 5x5 ve 7x7 filtre boyutları için 1 m ve 0,5 m çözünürlükte hem SGD hem de Adam optimizasyon algoritmaları ile eğitilen modellerin sınıflandırma puanları sırasıyla Çizelge 5.11-5.13'te verilmiştir.

Çizelge 5.11. Bergen 2018 LiDAR test verisi 3 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,89	0,74	0,95	0,91	0,75	0,97
	Duyarlık	0,82	0,94	0,85	0,83	0,93	0,91
	F1 Puan	0,85	0,83	0,90	0,87	0,83	0,94
	Ort. F1	0,86			0,88		
	Doğruluk	0,86			0,88		
0,5 m	Kesinlik	0,83	0,82	0,96	0,96	0,82	0,98
	Duyarlık	0,89	0,89	0,78	0,89	0,95	0,97
	F1 Puan	0,86	0,86	0,86	0,92	0,88	0,98
	Ort. F1	0,86			0,93		
	Doğruluk	0,86			0,93		

Çizelge 5.12. Bergen 2018 LiDAR test verisi 3 için 5x5 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,81	0,74	0,96	0,91	0,74	0,95
	Duyarlık	0,82	0,94	0,71	0,81	0,95	0,88
	F1 Puan	0,82	0,82	0,82	0,86	0,83	0,91
	Ort. F1	0,82			0,87		
	Doğruluk	0,82			0,86		
0,5 m	Kesinlik	0,86	0,77	0,97	0,95	0,81	0,97
	Duyarlık	0,88	0,77	0,97	0,88	0,94	0,96
	F1 Puan	0,87	0,84	0,87	0,91	0,87	0,96
	Ort. F1	0,86			0,91		
	Doğruluk	0,86			0,92		


Çizelge 5.13. Bergen 2018 LiDAR test verisi 3 için 7x7 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,86	0,74	0,96	0,87	0,73	0,96
	Duyarlık	0,83	0,92	0,81	0,83	0,93	0,79
	F1 Puan	0,85	0,82	0,88	0,85	0,82	0,87
	Ort. F1	0,85			0,85		
	Doğruluk	0,85			0,84		
0,5 m	Kesinlik	0,90	0,80	0,98	0,89	0,82	0,97
	Duyarlık	0,88	0,90	0,91	0,89	0,91	0,88
	F1 Puan	0,89	0,85	0,94	0,89	0,86	0,92
	Ort. F1	0,89			0,89		
	Doğruluk	0,90			0,89		

Çizelge 5.11’de görüldüğü üzere model en iyi sınıflandırma performansını 3x3 filtre uygulanan 0,5 m çözünürlükte oluşturulan görüntülerde ADAM optimizasyon algoritması ile elde etmiştir. En iyi model için Bergen 2018 test verisi 3’ün sınıflandırma hata matrisi Çizelge 5.14’te verilmiştir.

Çizelge 5.14. Bergen 2018 LiDAR test verisi 3 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma hata matrisi

Gerçek Değer	Yer	236056 (%88,53)	28541 (%10,70)	2050 (%0,77)
	Bitki Örtüsü	6727 (%4,49)	141804 (%94,57)	1408 (%0,94)
	Yapı	3134 (%1,83)	1663 (%0,97)	166919 (%97,21)
		Yer	Bitki Örtüsü	Yapı
		Tahmin Edilen		




Şekil 5.5. (a) Test veri seti 3 için Referans nokta bulutu, (b) derin sinir ağının en iyi modeli ile sınıflandırılmış LiDAR nokta bulutu

Şekil 5.5’de Bergen 2018 test verisi 3 referans LiDAR nokta bulutu ve derin sinir ağının sınıflandırdığı LiDAR nokta bulutu verilmiştir. Yapı noktalarını %97,21’lik doğruluk oranı ile oldukça başarılı şekilde sınıflandıran derin sinir ağı, bitki örtüsü noktalarını ise %94,57’lik bir oran ile doğru etiketlemiştir. Fakat yer noktalarını sınıflandırırken doğruluğu %88,53’de kalmıştır. Daha önceki veri setlerinde olduğu gibi burada da yer noktalarının %10,70’lik kısmını yanlış şekilde bitki örtüsü sınıfına dahil etmiştir.

Şekil 5.6’da LAStools, TerraScan ve QT Modeller ile sınıflandırılmış Bergen 2018 test verisi 3 LiDAR nokta bulutunun görüntüleri gösterilmiştir. Çizelge 5.15’te ise bu yazılımların sınıflandırma puanları verilmiştir. Bu veri setinde de bina cepheleri üç yazılım tarafından da doğru sınıflandırılmamıştır.

Çizelge 5.15. Bergen 2018 LiDAR test verisi 3 için ticari yazılımların sınıflandırma puanları

	LAStools			TerraScan			QT Modeller		
	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
F1 Puanı	0,97	0,97	0,97	0,99	0,97	0,98	0,98	0,64	0,97
Ort. F1	0,97			0,98			0,86		



Şekil 5.6. Ticari yazılımlar ile sınıflandırılan Bergen 2018 test verisi 3 (a) LASTools (b) TerraScan (c) QT Modeler

Bergen 2018 LiDAR test verisi 4 için 3x3, 5x5 ve 7x7 filtre boyutları için 1 m ve 0,5 m çözünürlükte hem SGD hem de ADAM optimizasyon algoritmaları ile eğitilen modellerin sınıflandırma puanları sırasıyla Çizelge 5.16-5.19’da verilmiştir.

Çizelge 5.16. Bergen 2018 LiDAR test verisi 4 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,90	0,89	0,79	0,86	0,89	0,96
	Duyarlık	0,45	0,99	0,54	0,45	0,99	0,63
	F1 Puan	0,60	0,94	0,64	0,59	0,93	0,76
	Ort. F1	0,73			0,76		
	Doğruluk	0,89			0,89		
0,5 m	Kesinlik	0,76	0,90	0,59	0,91	0,90	0,92
	Duyarlık	0,54	0,96	0,81	0,50	0,99	0,92
	F1 Puan	0,63	0,93	0,68	0,64	0,94	0,92
	Ort. F1	0,75			0,83		
	Doğruluk	0,88			0,90		

Çizelge 5.17. Bergen 2018 LiDAR test verisi 4 için 5x5 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,92	0,89	0,58	0,93	0,89	0,94
	Duyarlık	0,45	0,99	0,52	0,45	0,99	0,50
	F1 Puan	0,60	0,94	0,55	0,60	0,94	0,65
	Ort. F1	0,70			0,73		
	Doğruluk	0,89			0,89		
0,5 m	Kesinlik	0,89	0,88	0,98	0,90	0,88	0,92
	Duyarlık	0,43	0,99	0,69	0,41	0,99	0,86
	F1 Puan	0,59	0,93	0,81	0,56	0,93	0,89
	Ort. F1	0,78			0,79		
	Doğruluk	0,89			0,88		


Çizelge 5.18. Bergen 2018 LiDAR test verisi 4 için 7x7 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,93	0,88	0,69	0,92	0,89	0,92
	Duyarlık	0,44	0,99	0,44	0,44	0,99	0,60
	F1 Puan	0,59	0,94	0,54	0,60	0,94	0,73
	Ort. F1	0,69			0,76		
	Doğruluk	0,89			0,89		
0,5 m	Kesinlik	0,86	0,89	0,97	0,88	0,89	0,84
	Duyarlık	0,47	0,98	0,76	0,46	0,98	0,88
	F1 Puan	0,61	0,94	0,85	0,61	0,94	0,86
	Ort. F1	0,80			0,80		
	Doğruluk	0,89			0,89		

Çizelge 5.16’da görüldüğü üzere model en iyi sınıflandırma performansını 3x3 filtre uygulanan 0,5 m çözünürlükte oluşturulan görüntülerde ADAM optimizasyon algoritması ile elde etmiştir. En iyi model için Bergen 2018 test verisi 4’ün sınıflandırma hata matrisi Çizelge 5.19’da verilmiştir.

Çizelge 5.19. Bergen 2018 LiDAR test verisi 4 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma hata matrisi

Gerçek Değer	Yer	131667 (%49,59)	133426 (%50,25)	440 (%0,17)
	Bitki Örtüsü	12925 (%1,08)	1180968 (%98,82)	1217 (%0,10)
	Yapı	747 (%3,57)	837 (%4,00)	19344 (%92,43)
		Yer	Bitki Örtüsü	Yapı
		Tahmin Edilen		




Şekil 5.7. (a) Test veri seti 4 için Referans nokta bulutu, (b) derin sinir ağının en iyi modeli ile sınıflandırılmış LiDAR nokta bulutu

Şekil 5.7’de Bergen 2018 test verisi 4 referans LiDAR nokta bulutu ve derin sinir ağının sınıflandırdığı LiDAR nokta bulutu verilmiştir. Bitki örtüsü noktalarını %98,82’lik doğruluk oranı ile oldukça başarılı şekilde sınıflandıran derin sinir ağı, yapı noktalarını ise %92,43’lük bir oran ile doğru etiketlemiştir. Yer noktalarını sınıflandırırken doğruluğunun %49,59’da kalmasının nedeni derin sinir ağının sık bitki örtüsü altında kalan yer noktalarını tanımlayamamasıdır. Bunun sonucu olarak yer noktaları için F1 puanı 0,64’te kalmıştır.

Şekil 5.8’de LAStools, TerraScan ve QT Modeller yazılımları ile sınıflandırılmış Bergen 2018 test verisi 4 LiDAR nokta bulutunun görüntüleri gösterilmiştir. Çizelge 5.20’de ise bu yazılımların sınıflandırma puanları verilmiştir. TerraScan bu veri setinde eğimli bölgede bitki örtüsünü tam olarak belirleyememiştir. LAStools ise bazı yapıları tespit edememiştir.

Çizelge 5.20. Bergen 2018 LiDAR test verisi 4 için ticari yazılımların sınıflandırma puanları

	LAStools			TerraScan			QT Modeller		
	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
F1 Puanı	0,99	0,99	0,73	0,99	0,99	0,94	0,98	0,80	0,91
Ort. F1	0,90			0,97			0,90		



Şekil 5.8. Ticari yazılımlar ile sınıflandırılan Bergen 2018 test verisi 4 (a) LASTools (b) TerraScan (c) QT Modeler

Bergen 2018 LiDAR test verisi 5 için 3x3, 5x5 ve 7x7 filtre boyutları için 1 m ve 0,5 m çözünürlükte hem SGD hem de Adam optimizasyon algoritmaları ile eğitilen modellerin sınıflandırma puanları sırasıyla Çizelge 5.21-5.23'te verilmiştir.

Çizelge 5.21. Bergen 2018 LiDAR test verisi 5 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,98	0,74	0,65	0,95	0,73	0,93
	Duyarlık	0,75	0,97	0,76	0,75	0,95	0,69
	F1 Puan	0,85	0,84	0,70	0,84	0,83	0,79
	Ort. F1	0,80			0,82		
	Doğruluk	0,84			0,83		
0,5 m	Kesinlik	0,95	0,77	0,68	0,96	0,76	0,88
	Duyarlık	0,79	0,94	0,80	0,78	0,96	0,81
	F1 Puan	0,86	0,84	0,74	0,86	0,85	0,85
	Ort. F1	0,81			0,85		
	Doğruluk	0,85			0,86		

Çizelge 5.22. Bergen 2018 LiDAR test verisi 5 için 5x5 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,98	0,74	0,46	0,99	0,74	0,89
	Duyarlık	0,75	0,96	0,75	0,74	0,99	0,84
	F1 Puan	0,85	0,84	0,57	0,84	0,84	0,86
	Ort. F1	0,75			0,85		
	Doğruluk	0,84			0,85		
0,5 m	Kesinlik	0,96	0,73	0,84	0,96	0,75	0,94
	Duyarlık	0,75	0,96	0,84	0,77	0,96	0,79
	F1 Puan	0,84	0,83	0,84	0,85	0,84	0,86
	Ort. F1	0,84			0,85		
	Doğruluk	0,83			0,85		


Çizelge 5.23. Bergen 2018 LiDAR test verisi 5 için 7x7 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,97	0,74	0,59	0,98	0,74	0,97
	Duyarlık	0,75	0,97	0,66	0,74	0,98	0,72
	F1 Puan	0,85	0,84	0,62	0,85	0,84	0,83
	Ort. F1	0,77			0,84		
	Doğruluk	0,84			0,84		
0,5 m	Kesinlik	0,95	0,75	0,88	0,95	0,75	0,77
	Duyarlık	0,77	0,95	0,76	0,77	0,94	0,74
	F1 Puan	0,85	0,84	0,82	0,85	0,84	0,76
	Ort. F1	0,84			0,82		
	Doğruluk	0,85			0,84		

Çizelge 5.19’de görüldüğü üzere model en iyi sınıflandırma performansını 3x3 filtre uygulanan 0,5 m çözünürlükte oluşturulan görüntülerde ADAM optimizasyon algoritması ile elde etmiştir. En iyi model için Bergen 2018 test verisi 5’in sınıflandırma hata matrisi Çizelge 5.24’te verilmiştir.

Çizelge 5.24. Bergen 2018 LiDAR test verisi 5 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma hata matrisi

Gerçek Değer	Yer	298295 (%78,38)	82051 (%21,56)	231 (%0,06)
	Bitki Örtüsü	10393 (%3,73)	267352 (%95,98)	805 (%0,29)
	Yapı	1396 (%14,96)	348 (%3,73)	7588 (%81,31)
		Yer	Bitki Örtüsü	Yapı
		Tahmin Edilen		



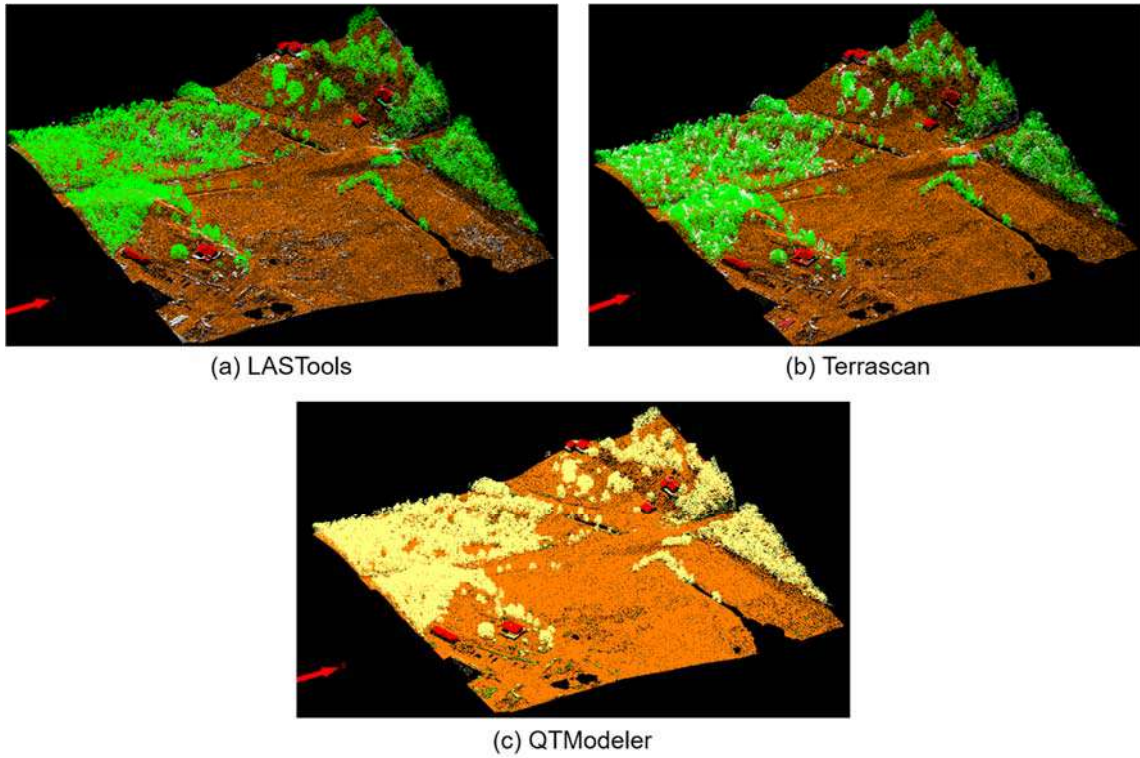
Şekil 5.9. (a) Test veri seti 5 için Referans nokta bulutu, (b) derin sinir ağının en iyi modeli ile sınıflandırılmış LiDAR nokta bulutu

Şekil 5.9’da Bergen 2018 test verisi 5 referans LiDAR nokta bulutu ve derin sinir ağının sınıflandırdığı LiDAR nokta bulutu verilmiştir. Bitki örtüsü noktalarını %95,98’lik doğruluk oranı ile oldukça başarılı şekilde sınıflandırırken yer noktalarının %21,56’lık kısmını yanlış etiketleyerek bitki örtüsü sınıfına atamıştır. Yer noktalarını sınıflandırırken doğruluğu %78,38’de kalmıştır. Yapı noktaları için doğruluğu ise %81,31’e ulaşmıştır.

Şekil 5.10’da LAStools, TerraScan ve QT Modeller yazılımları ile sınıflandırılmış Bergen 2018 test verisi 5 LiDAR nokta bulutunun görüntüleri gösterilmiştir. Çizelge 5.25’te ise bu yazılımların sınıflandırma puanları verilmiştir.

Çizelge 5.25. Bergen 2018 LiDAR test verisi 5 için ticari yazılımların sınıflandırma puanları

	LAStools			TerraScan			QT Modeller		
	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
F1 Puanı	0,99	0,99	0,93	0,99	0,99	0,88	0,99	0,76	0,87
Ort. F1	0,97			0,95			0,87		



Şekil 5.10. Ticari yazılımlar ile sınıflandırılan Bergen 2018 test verisi 5 (a) LAsTools (b) TerraScan (c) QT Modeler

Bergen 2018 LiDAR test verisi 6 için 3x3, 5x5 ve 7x7 filtre boyutları için 1 m ve 0,5 m çözünürlükte hem SGD hem de Adam optimizasyon algoritmaları ile eğitilen modellerin sınıflandırma puanları sırasıyla Çizelge 5.26-5.28’de verilmiştir.

Çizelge 5.26. Bergen 2018 LiDAR test verisi 6 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,93	0,79	0,90	0,93	0,79	0,95
	Duyarlık	0,52	0,98	0,71	0,52	0,99	0,68
	F1 Puan	0,67	0,88	0,80	0,67	0,88	0,80
	Ort. F1	0,78			0,78		
	Doğruluk	0,82			0,82		
0,5 m	Kesinlik	0,87	0,83	0,86	0,94	0,82	0,95
	Duyarlık	0,62	0,96	0,79	0,59	0,99	0,84
	F1 Puan	0,72	0,89	0,83	0,73	0,90	0,89
	Ort. F1	0,81			0,84		
	Doğruluk	0,84			0,85		

Çizelge 5.27. Bergen 2018 LiDAR test verisi 6 için 5x5 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,92	0,79	0,84	0,94	0,79	0,92
	Duyarlık	0,52	0,98	0,69	0,52	0,99	0,70
	F1 Puan	0,67	0,87	0,76	0,67	0,88	0,80
	Ort. F1	0,77			0,78		
	Doğruluk	0,82			0,82		
0,5 m	Kesinlik	0,91	0,80	0,97	0,94	0,80	0,94
	Duyarlık	0,55	0,98	0,74	0,52	0,99	0,81
	F1 Puan	0,69	0,89	0,84	0,67	0,88	0,87
	Ort. F1	0,81			0,81		
	Doğruluk	0,83			0,83		


Çizelge 5.28. Bergen 2018 LiDAR test verisi 6 için 7x7 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,92	0,79	0,87	0,90	0,79	0,94
	Duyarlık	0,52	0,98	0,68	0,52	0,98	0,65
	F1 Puan	0,67	0,87	0,76	0,67	0,88	0,77
	Ort. F1	0,77			0,77		
	Doğruluk	0,82			0,82		
0,5 m	Kesinlik	0,89	0,81	0,97	0,90	0,81	0,94
	Duyarlık	0,58	0,97	0,72	0,58	0,98	0,78
	F1 Puan	0,70	0,88	0,83	0,70	0,89	0,85
	Ort. F1	0,80			0,81		
	Doğruluk	0,83			0,84		


Çizelge 5.26’da görüldüğü üzere model en iyi sınıflandırma performansını 3x3 filtre uygulanan 0,5 m çözünürlükte oluşturulan görüntülerde ADAM optimizasyon algoritması ile elde etmiştir. En iyi model için Bergen 2018 test verisi 6’nın sınıflandırma hata matrisi Çizelge 5.29’da verilmiştir.

Çizelge 5.29. Bergen 2018 LiDAR test verisi 6 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma hata matrisi

Gerçek Değer	Yer	232690 (%59,25)	157507 (%40,11)	2499 (%0,64)
	Bitki Örtüsü	8689 (%1,13)	759901 (%98,67)	1537 (%0,20)
	Yapı	6075 (%7,06)	7656 (%8,90)	72297 (%84,04)
		Yer	Bitki Örtüsü	Yapı
		Tahmin Edilen		



(a) Referans

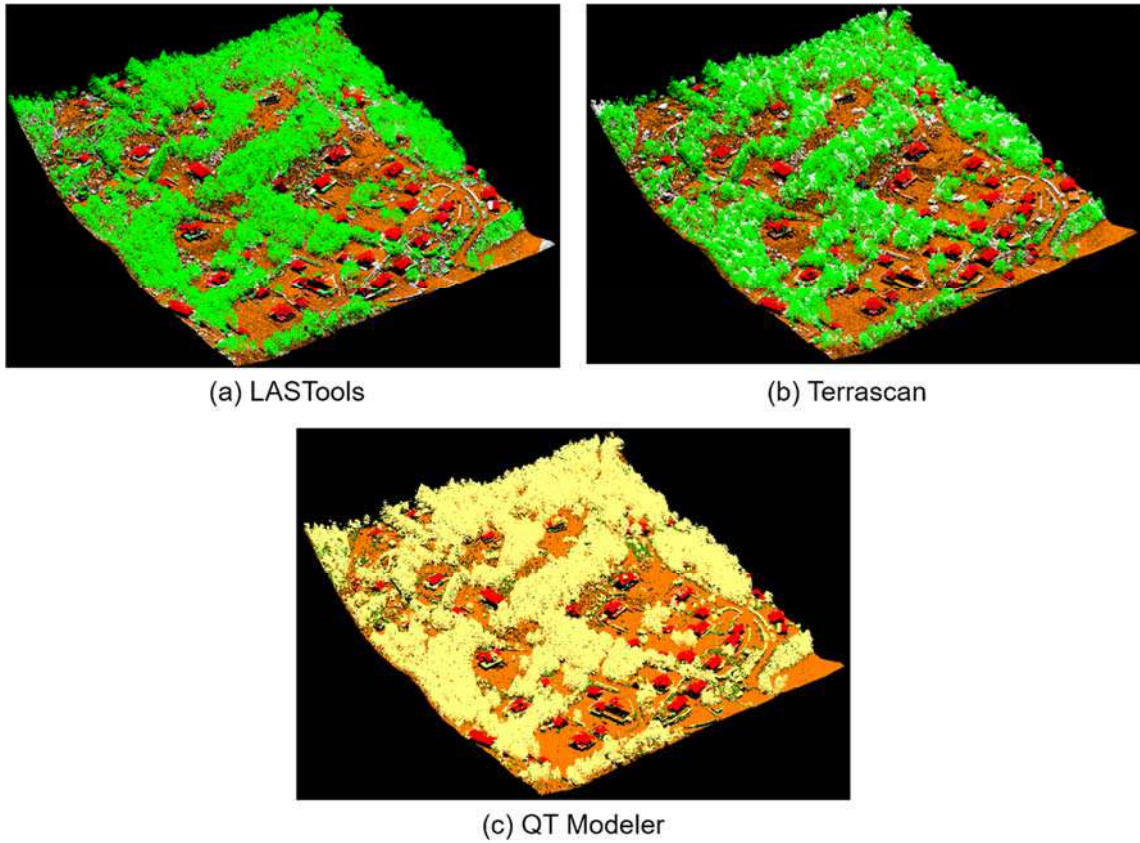


(b) Derin Sinir Ağı

Şekil 5.11. (a) Test veri seti 6 için Referans nokta bulutu, (b) derin sinir ağının en iyi modeli ile sınıflandırılmış LiDAR nokta bulutu

Şekil 5.11’de Bergen 2018 test verisi 6 referans LiDAR nokta bulutu ve derin sinir ağının sınıflandırdığı LiDAR nokta bulutu verilmiştir. Bitki örtüsü noktalarını %95,98’lik doğruluk oranı ile oldukça başarılı şekilde sınıflandırırken yer noktalarının %21,56’lık kısmını yanlış etiketleyerek bitki örtüsü sınıfına atamıştır. Yer noktalarını sınıflandırırken doğruluğu %78,38’e ulaşmıştır.

Şekil 5.12’de LAsTools, TerraScan ve QT Modeller yazılımları ile sınıflandırılmış Bergen 2018 test verisi 6 LiDAR nokta bulutunun görüntüleri gösterilmiştir. Çizelge 5.30’da ise bu yazılımların sınıflandırma puanları verilmiştir. Düşük kotlu bitkileri tespit ederken önerilen derin sinir ağı yöntemi ticari yazılımları geride bırakmıştır. Bununla birlikte bitki örtüsünün altında kalan yer noktalarının tespitinde diğer yazılımların gerisinde kalmıştır.



Şekil 5.12. Ticari yazılımlar ile sınıflandırılan Bergen 2018 test verisi 6 (a) LASTools (b) TerraScan (c) QT Modeller

Çizelge 5.30. Bergen 2018 LiDAR test verisi 6 için ticari yazılımların sınıflandırma puanları

	LAStools			TerraScan			QT Modeller		
	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
F1 Puanı	0,99	0,99	0,87	0,99	0,99	0,88	0,97	0,78	0,87
Ort. F1	0,95			0,95			0,87		

Bergen 2018 LiDAR test verisi 7 için 3x3, 5x5 ve 7x7 filtre boyutları için 1 m ve 0,5 m çözünürlükte hem SGD hem de Adam optimizasyon algoritmaları ile eğitilen modellerin sınıflandırma puanları sırasıyla Çizelge 5.31-5.33'te verilmiştir.

Çizelge 5.31. Bergen 2018 LiDAR test verisi 7 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,94	0,79	0,78	0,93	0,79	0,93
	Duyarlık	0,58	0,98	0,43	0,60	0,98	0,35
	F1 Puan	0,72	0,88	0,55	0,73	0,88	0,51
	Ort. F1	0,72			0,71		
	Doğruluk	0,82			0,83		
0,5 m	Kesinlik	0,83	0,85	0,69	0,95	0,84	0,91
	Duyarlık	0,75	0,90	0,66	0,70	0,98	0,74
	F1 Puan	0,79	0,87	0,68	0,81	0,90	0,82
	Ort. F1	0,78			0,84		
	Doğruluk	0,84			0,87		

Çizelge 5.32. Bergen 2018 LiDAR test verisi 7 için 5x5 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,93	0,79	0,68	0,93	0,80	0,90
	Duyarlık	0,58	0,98	0,31	0,61	0,98	0,38
	F1 Puan	0,72	0,87	0,43	0,74	0,88	0,53
	Ort. F1	0,67			0,72		
	Doğruluk	0,82			0,83		
0,5 m	Kesinlik	0,93	0,81	0,82	0,94	0,80	0,92
	Duyarlık	0,66	0,97	0,65	0,62	0,97	0,69
	F1 Puan	0,77	0,88	0,73	0,75	0,88	0,79
	Ort. F1	0,79			0,81		
	Doğruluk	0,84			0,84		


Çizelge 5.33. Bergen 2018 LiDAR test verisi 7 için 7x7 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,93	0,76	0,81	0,90	0,79	0,89
	Duyarlık	0,52	0,98	0,33	0,60	0,97	0,20
	F1 Puan	0,67	0,86	0,47	0,72	0,87	0,32
	Ort. F1	0,67			0,64		
	Doğruluk	0,80			0,82		
0,5 m	Kesinlik	0,91	0,82	0,93	0,90	0,83	0,90
	Duyarlık	0,68	0,96	0,57	0,70	0,95	0,75
	F1 Puan	0,78	0,89	0,71	0,79	0,89	0,82
	Ort. F1	0,79			0,83		
	Doğruluk	0,85			0,85		

Çizelge 5.31’de görüldüğü üzere bu veri setinde de model en iyi sınıflandırma performansını 3x3 filtre uygulanan 0,5 m çözünürlükte oluşturulan görüntülerde ADAM optimizasyon algoritması ile elde etmiştir. En iyi model için Bergen 2018 test verisi 7’nin sınıflandırma hata matrisi Çizelge 5.34’te verilmiştir.

Çizelge 5.34. Bergen 2018 LiDAR test verisi 7 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma hata matrisi

Gerçek Değer	Yer	132693 (%70,40)	55341 (%29,36)	446 (%0,24)
	Bitki Örtüsü	7072 (%2,34)	295100 (%97,59)	209 (%0,07)
	Yapı	420 (%4,51)	2041 (%21,90)	6859 (%73,59)
		Yer	Bitki Örtüsü	Yapı
		Tahmin Edilen		




Şekil 5.13. (a) Test veri seti 7 için Referans nokta bulutu, (b) derin sinir ağının en iyi modeli ile sınıflandırılmış LiDAR nokta bulutu

Şekil 5.13’de Bergen 2018 test verisi 7 referans LiDAR nokta bulutu ve derin sinir ağının sınıflandırdığı LiDAR nokta bulutu verilmiştir. Bitki örtüsü noktalarını %95,98’lik doğruluk oranı ile oldukça başarılı şekilde sınıflandırırken yer noktalarının %21,56’lık kısmını yanlış etiketleyerek bitki örtüsü sınıfına atamıştır. Yer noktalarını sınıflandırırken doğruluğu %78,38’e ulaşmıştır.

Şekil 5.14’de LAStools, TerraScan ve QT Modeller yazılımları ile sınıflandırılmış Bergen 2018 test verisi 7 LiDAR nokta bulutunun görüntüleri gösterilmiştir. Çizelge 5.35’de ise bu yazılımların sınıflandırma puanları verilmiştir. Önerilen derin sinir ağı yöntemi ile beraber üç ticari yazılımda düşük kotta ki yapıları sınıflandıramamıştır. Buna rağmen yapı sınıfında ki en yüksek F1 puanını derin sinir ağı yöntemi üretmiştir.

Çizelge 5.35. Bergen 2018 LiDAR test verisi 7 için ticari yazılımların sınıflandırma puanları

	LAStools			TerraScan			QT Modeller		
	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
F1 Puanı	0,99	0,99	0,52	0,99	0,99	0,66	0,97	0,74	0,73
Ort. F1	0,83			0,88			0,81		



Şekil 5.14. Ticari yazılımlar ile sınıflandırılan Bergen 2018 test verisi 7 (a) LASTools (b) TerraScan (c) QT Modeller

5.1.2. DALES veri seti için sınıflandırma sonuçları

Çizelge 5.36-5.38’de DALES LiDAR test verisi 1 için 3x3, 5x5 ve 7x7 filtre boyutları için 1 m ve 0,5 m çözünürlükte hem SGD hem de Adam optimizasyon algoritmaları ile eğitilen modellerin sınıflandırma puanları verilmiştir.

Çizelge 5.36. DALES LiDAR test verisi 1 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,95	0,69	0,81	0,97	0,68	0,83
	Duyarlık	0,65	0,90	0,95	0,64	0,93	0,95
	F1 Puan	0,77	0,78	0,88	0,77	0,79	0,88
	Ort. F1	0,81			0,81		
	Doğruluk	0,80			0,81		
0,5 m	Kesinlik	0,91	0,69	0,85	0,92	0,72	0,90
	Duyarlık	0,68	0,91	0,89	0,74	0,92	0,91
	F1 Puan	0,78	0,78	0,87	0,82	0,81	0,90
	Ort. F1	0,81			0,84		
	Doğruluk	0,80			0,84		

Çizelge 5.37. DALES LiDAR test verisi 1 için 5x5 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,96	0,68	0,83	0,94	0,68	0,84
	Duyarlık	0,64	0,92	0,94	0,65	0,93	0,93
	F1 Puan	0,77	0,78	0,89	0,77	0,79	0,88
	Ort. F1	0,81			0,81		
	Doğruluk	0,80			0,81		
0,5 m	Kesinlik	0,96	0,72	0,87	0,95	0,71	0,86
	Duyarlık	0,72	0,93	0,94	0,70	0,92	0,94
	F1 Puan	0,82	0,81	0,91	0,81	0,80	0,90
	Ort. F1	0,85			0,84		
	Doğruluk	0,84			0,83		

Çizelge 5.38. DALES LiDAR test verisi 1 için 7x7 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,96	0,68	0,82	0,93	0,69	0,83
	Duyarlık	0,65	0,91	0,95	0,66	0,91	0,93
	F1 Puan	0,77	0,78	0,88	0,77	0,78	0,88
	Ort. F1	0,81			0,81		
	Doğruluk	0,80			0,80		
0,5 m	Kesinlik	0,95	0,74	0,78	0,88	0,75	0,89
	Duyarlık	0,69	0,89	0,96	0,77	0,88	0,89
	F1 Puan	0,80	0,81	0,86	0,82	0,81	0,89
	Ort. F1	0,82			0,84		
	Doğruluk	0,82			0,84		


Çizelge 5.37’de görüldüğü üzere model en iyi sınıflandırma performansını 5x5 filtre uygulanan 0,5 m çözünürlükte oluşturulan görüntülerde SGD optimizasyon algoritması ile elde etmiştir. En iyi model için DALES test verisi 1’in sınıflandırma hata matrisi Çizelge 5.39’da verilmiştir.

Çizelge 5.39. DALES LiDAR test verisi 1 için eğitilen en iyi modelin sınıflandırma hata matrisi


Gerçek Değer	Yer	3803180 (%72,19)	1184310 (%22,48)	278000 (%5,28)
	Bitki Örtüsü	141896 (%3,76)	3487002 (%92,40)	127195 (%3,37)
	Yapı	37277 (%1,26)	142883 (%4,83)	2779109 (%93,86)
		Yer	Bitki Örtüsü	Yapı
		Tahmin Edilen		

Şekil 5.15’te DALES test verisi 1 referans LiDAR nokta bulutu ve derin sinir ağının sınıflandırdığı LiDAR nokta bulutu verilmiştir. Yapı noktalarını %92,40’lık doğruluk oranı ile oldukça başarılı şekilde sınıflandırırken yer noktalarının %22,48’lik kısmını yanlış etiketleyerek bitki örtüsü sınıfına atamıştır. Yer noktalarını sınıflandırırken doğruluğu %72,19’da kalmıştır.

Şekil 5.16’da LASTools, TerraScan ve QT Modeller yazılımları ile sınıflandırılmış DALES test verisi 1 LiDAR nokta bulutunun görüntüleri gösterilmiştir. Çizelge 5.40’da ise bu yazılımların sınıflandırma puanları verilmiştir.



Şekil 5.15. (a) DALES test veri seti 1 için Referans nokta bulutu, (b) derin sinir ağının en iyi modeli ile sınıflandırılmış LiDAR nokta bulutu



Şekil 5.16. Ticari yazılımlar ile sınıflandırılan DALES test verisi 1 (a) LASTools (b) TerraScan (c) QT Modeller

Çizelge 5.40. DALES LiDAR test verisi 1 için ticari yazılımların sınıflandırma puanları

	LAStools			TerraScan			QT Modeller		
	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
F1 Puanı	0,93	0,84	0,82	0,95	0,92	0,90	0,53	0,04	0,27
Ort. F1	0,86			0,92			0,28		

Çizelge 5.41-5.43'te DALES LiDAR test verisi 2 için 3x3, 5x5 ve 7x7 filtre boyutları için 1 m ve 0,5 m çözünürlükte hem SGD hem de Adam optimizasyon algoritmaları ile eğitilen modellerin sınıflandırma puanları verilmiştir.

Çizelge 5.41. DALES LiDAR test verisi 2 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,94	0,70	0,83	0,97	0,68	0,83
	Duyarlık	0,78	0,88	0,92	0,64	0,93	0,95
	F1 Puan	0,85	0,78	0,87	0,77	0,79	0,88
	Ort. F1	0,83			0,81		
	Doğruluk	0,83			0,85		
0,5 m	Kesinlik	0,92	0,68	0,84	0,91	0,75	0,89
	Duyarlık	0,78	0,89	0,86	0,84	0,88	0,87
	F1 Puan	0,84	0,77	0,85	0,88	0,81	0,88
	Ort. F1	0,82			0,86		
	Doğruluk	0,82			0,86		

Çizelge 5.41 ve 5.43'te görüldüğü üzere model en iyi sınıflandırma performansını 0,5 m çözünürlükte oluşturulan görüntülerde 3x3 ve 7x7 filtre uygulanan sırasıyla ADAM ve SGD optimizasyon algoritmaları ile elde etmiştir. En iyi model için DALES test verisi 2'nin sınıflandırma hata matrisi Çizelge 5.44'te verilmiştir.

Çizelge 5.42. DALES LiDAR test verisi 2 için 5x5 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,94	0,68	0,84	0,93	0,70	0,85
	Duyarlık	0,76	0,89	0,91	0,78	0,89	0,91
	F1 Puan	0,84	0,77	0,88	0,85	0,78	0,88
	Ort. F1	0,83			0,84		
	Doğruluk	0,83			0,84		
0,5 m	Kesinlik	0,94	0,74	0,88	0,93	0,71	0,87
	Duyarlık	0,83	0,90	0,92	0,81	0,89	0,91
	F1 Puan	0,89	0,81	0,90	0,87	0,79	0,89
	Ort. F1	0,87			0,85		
	Doğruluk	0,87			0,85		

Çizelge 5.43. DALES LiDAR test verisi 2 için 7x7 filtre boyutları ile eğitilen modelin sınıflandırma puanları


Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,93	0,69	0,83	0,93	0,70	0,84
	Duyarlık	0,77	0,89	0,91	0,78	0,88	0,92
	F1 Puan	0,85	0,78	0,87	0,85	0,78	0,88
	Ort. F1	0,83			0,84		
	Doğruluk	0,83			0,84		
0,5 m	Kesinlik	0,94	0,76	0,82	0,90	0,76	0,89
	Duyarlık	0,82	0,88	0,94	0,86	0,86	0,85
	F1 Puan	0,88	0,81	0,88	0,88	0,81	0,87
	Ort. F1	0,86			0,85		
	Doğruluk	0,86			0,86		

Çizelge 5.44. DALES LiDAR test verisi 2 için eğitilen en iyi modelin sınıflandırma hata matrisi

Gerçek Değer	Yer	5144529 (%82,96)	831797 (%13,41)	222018 (%3,58)
	Bitki Örtüsü	237780 (%7,93)	2672886 (%89,14)	71670 (%2,39)
	Yapı	91325 (%3,99)	83218 (%3,64)	2110710 (%92,22)
		Yer	Bitki Örtüsü	Yapı
		Tahmin Edilen		

Şekil 5.17’de DALES test verisi 2 referans LiDAR nokta bulutu ve derin sinir ağının sınıflandırdığı LiDAR nokta bulutu verilmiştir. Yapı noktalarını %92,22’lik doğruluk oranı ile oldukça başarılı şekilde sınıflandırırken yer noktalarının %13,41’lik kısmını yanlış etiketleyerek bitki örtüsü sınıfına atamıştır. Yer noktalarını sınıflandırırken doğruluğu %82,96’da kalırken bitki örtüsü noktalarını belirleme doğruluğu %89,14 olmuştur.


Şekil 5.18’de LAsTools, TerraScan ve QT Modeller yazılımları ile sınıflandırılmış DALES test verisi 2 LiDAR nokta bulutunun görüntüleri gösterilmiştir. Çizelge 5.45’te ise bu yazılımların sınıflandırma puanları verilmiştir.




Şekil 5.17. (a) DALES test veri seti 2 için Referans nokta bulutu, (b) derin sinir ağının en iyi modeli ile sınıflandırılmış LiDAR nokta bulutu

Çizelge 5.45. DALES LiDAR test verisi 2 için ticari yazılımların sınıflandırma puanları


	LAStools			TerraScan			QT Modeller		
	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
F1 Puanı	0,95	0,88	0,84	0,86	0,91	0,89	0,63	0,04	0,20
Ort. F1	0,89			0,89			0,29		



(a) LAStools



(b) TerraScan



(c) QT Modeller

Şekil 5.18. Ticari yazılımlar ile sınıflandırılan DALES test verisi 2 (a) LAStools (b) TerraScan (c) QT Modeller

Çizelge 5.46-5.48’de DALES LiDAR test verisi 3 için 3x3, 5x5 ve 7x7 filtre boyutları için 1 m ve 0,5 m çözünürlükte hem SGD hem de Adam optimizasyon algoritmaları ile eğitilen modellerin sınıflandırma puanları verilmiştir.

Çizelge 5.46. DALES LiDAR test verisi 3 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,90	0,69	0,92	0,98	0,71	0,92
	Duyarlık	0,79	0,90	0,88	0,78	0,95	0,98
	F1 Puan	0,84	0,78	0,90	0,87	0,81	0,95
	Ort. F1	0,84			0,88		
	Doğruluk	0,84			0,87		
0,5 m	Kesinlik	0,92	0,69	0,90	0,81	0,74	0,95
	Duyarlık	0,77	0,90	0,91	0,84	0,89	0,69
	F1 Puan	0,84	0,78	0,91	0,83	0,81	0,80
	Ort. F1	0,84			0,81		
	Doğruluk	0,84			0,82		

Çizelge 5.47. DALES LiDAR test verisi 3 için 5x5 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,93	0,68	0,93	0,91	0,70	0,93
	Duyarlık	0,78	0,90	0,94	0,79	0,90	0,92
	F1 Puan	0,85	0,78	0,94	0,85	0,79	0,93
	Ort. F1	0,86			0,86		
	Doğruluk	0,85			0,85		
0,5 m	Kesinlik	0,87	0,74	0,94	0,82	0,70	0,95
	Duyarlık	0,83	0,90	0,83	0,80	0,91	0,71
	F1 Puan	0,85	0,81	0,88	0,81	0,79	0,81
	Ort. F1	0,85			0,80		
	Doğruluk	0,85			0,81		

Çizelge 5.48. DALES LiDAR test verisi 3 için 7x7 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,91	0,68	0,92	0,90	0,70	0,92
	Duyarlık	0,77	0,90	0,90	0,78	0,89	0,89
	F1 Puan	0,84	0,78	0,91	0,84	0,78	0,90
	Ort. F1	0,84			0,84		
	Doğruluk	0,84			0,84		
0,5 m	Kesinlik	0,87	0,74	0,88	0,75	0,75	0,95
	Duyarlık	0,81	0,89	0,83	0,86	0,87	0,54
	F1 Puan	0,84	0,81	0,85	0,80	0,81	0,69
	Ort. F1	0,83			0,77		
	Doğruluk	0,83			0,78		

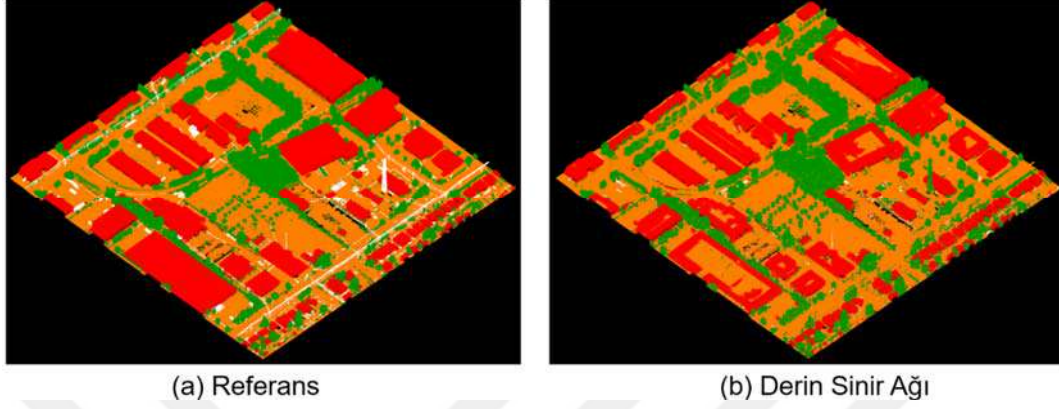
Çizelge 5.46’da görüldüğü üzere model en iyi sınıflandırma performansını 3x3 filtre uygulanan 1 m çözünürlükte oluşturulan görüntülerde ADAM optimizasyon algoritması ile elde etmiştir. En iyi model için DALES test verisi 3’ün sınıflandırma hata matrisi Çizelge 5.49’da verilmiştir.

Çizelge 5.49. DALES LiDAR test verisi 3 için eğitilen en iyi modelin sınıflandırma hata matrisi

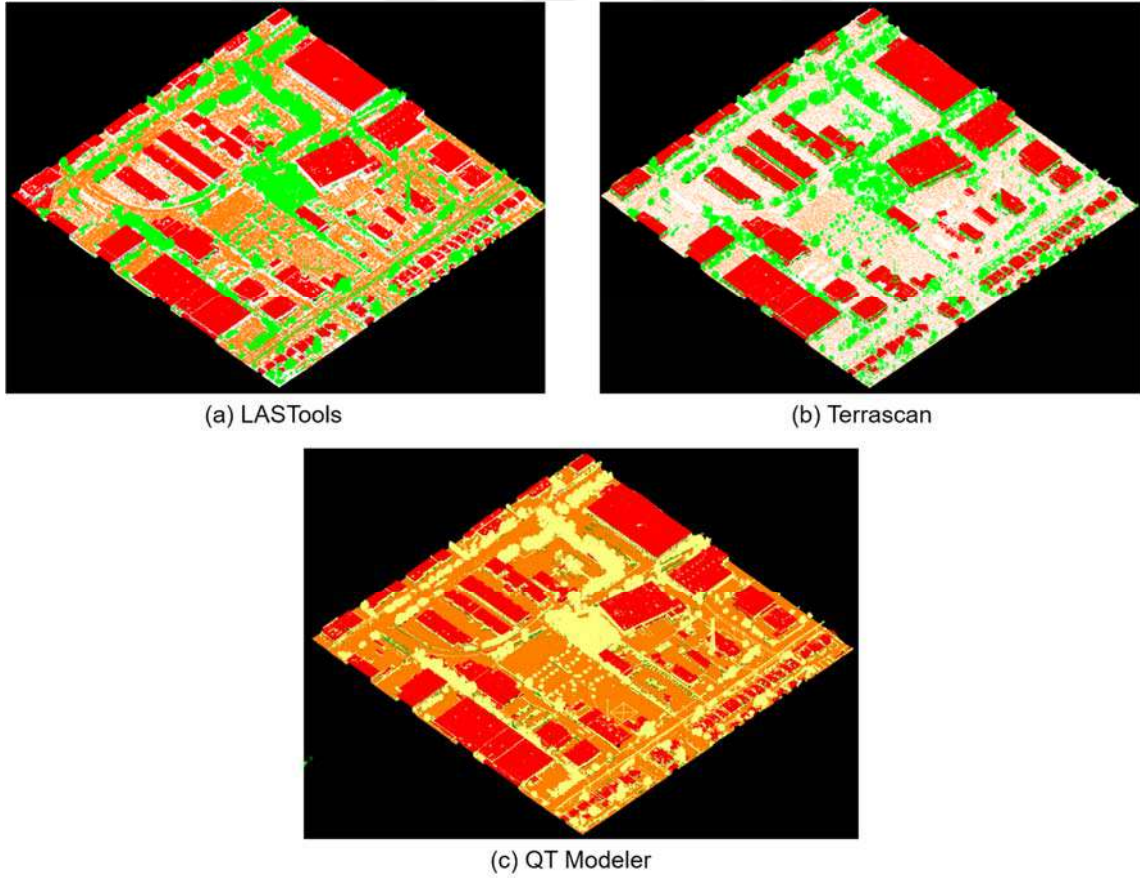
Gerçek Değer	Yer	4733702 (%83,84)	777634 (%13,77)	134183 (%2,38)
	Bitki Örtüsü	233020 (%8,29)	2519235 (%89,58)	55061 (%1,96)
	Yapı	246980 (%8,81)	34754 (%1,24)	2521348 (%89,9)
		Yer	Bitki Örtüsü	Yapı
		Tahmin Edilen		

Şekil 5.19’da DALES test verisi 3 referans LiDAR nokta bulutu ve derin sınır ağının sınıflandırdığı LiDAR nokta bulutu verilmiştir. Yer noktalarını %83,84’lük doğruluk oranı ile sınıflandırırken yer noktalarının %13,77’lik kısmını yanlış etiketleyerek bitki örtüsü sınıfına atamıştır. Bitki örtüsü noktalarını sınıflandırırken doğruluğu %89,58’de kalırken yapı noktalarını belirleme doğruluğu %89,9 olmuştur.

Şekil 5.20’de LAStools, TerraScan ve QT Modeller yazılımları ile sınıflandırılmış DALES test verisi 3 LiDAR nokta bulutunun görüntüleri gösterilmiştir. Çizelge 4.50’de ise bu yazılımların sınıflandırma puanları verilmiştir.



Şekil 5.19. (a) DALES test veri seti 3 için Referans nokta bulutu, (b) derin sinir ağının en iyi modeli ile sınıflandırılmış LiDAR nokta bulutu



Şekil 5.20. Ticari yazılımlar ile sınıflandırılan DALES test verisi 3 (a) LAStools (b) TerraScan (c) QT Modeller

Çizelge 5.50. DALES LiDAR test verisi 3 için ticari yazılımların sınıflandırma puanları

	LAStools			TerraScan			QT Modeller		
	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
F1 Puanı	0,94	0,92	0,89	0,88	0,93	0,94	0,58	0,05	0,27
Ort. F1	0,92			0,92			0,30		

Çizelge 5.51-5.44'te DALES LiDAR test verisi 4 için 3x3, 5x5 ve 7x7 filtre boyutları için 1 m ve 0,5 m çözünürlükte hem SGD hem de Adam optimizasyon algoritmaları ile eğitilen modellerin sınıflandırma puanları verilmiştir.

Çizelge 5.51. DALES LiDAR test verisi 4 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,93	0,68	0,83	0,98	0,70	0,83
	Duyarlık	0,78	0,88	0,90	0,78	0,94	0,94
	F1 Puan	0,85	0,77	0,86	0,87	0,80	0,88
	Ort. F1	0,83			0,85		
	Doğruluk	0,83			0,85		
0,5 m	Kesinlik	0,92	0,68	0,84	0,92	0,74	0,90
	Duyarlık	0,80	0,88	0,84	0,85	0,88	0,88
	F1 Puan	0,86	0,77	0,84	0,88	0,80	0,87
	Ort. F1	0,82			0,85		
	Doğruluk	0,83			0,86		

Çizelge 5.52. DALES LiDAR test verisi 4 için 5x5 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,94	0,67	0,84	0,92	0,69	0,84
	Duyarlık	0,77	0,89	0,90	0,79	0,89	0,86
	F1 Puan	0,85	0,76	0,87	0,85	0,78	0,85
	Ort. F1	0,83			0,83		
	Doğruluk	0,83			0,83		
0,5 m	Kesinlik	0,94	0,73	0,88	0,94	0,71	0,87
	Duyarlık	0,84	0,89	0,91	0,82	0,89	0,89
	F1 Puan	0,89	0,81	0,89	0,88	0,79	0,88
	Ort. F1	0,86			0,85		
	Doğruluk	0,86			0,85		

Çizelge 5.53. DALES LiDAR test verisi 4 için 7x7 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,93	0,68	0,83	0,92	0,69	0,83
	Duyarlık	0,78	0,89	0,90	0,79	0,88	0,88
	F1 Puan	0,85	0,77	0,86	0,85	0,78	0,85
	Ort. F1	0,83			0,83		
	Doğruluk	0,83			0,83		
0,5 m	Kesinlik	0,94	0,75	0,82	0,91	0,75	0,88
	Duyarlık	0,83	0,87	0,94	0,86	0,86	0,86
	F1 Puan	0,88	0,81	0,87	0,88	0,80	0,87
	Ort. F1	0,85			0,85		
	Doğruluk	0,86			0,86		


Çizelge 5.53'te görüldüğü üzere model en iyi sınıflandırma performansını 5x5 filtre uygulanan 0,5 m çözünürlükte oluşturulan görüntülerde SGD optimizasyon algoritması ile elde etmiştir. En iyi model için DALES test verisi 4'ün sınıflandırma hata matrisi Çizelge 5.54'te verilmiştir.

Çizelge 5.54. DALES LiDAR test verisi 4 için eğitilen en iyi modelin sınıflandırma hata matrisi

Gerçek Değer	Yer	5635071 (%83,56)	914564 (%13,56)	192938 (%2,86)
	Bitki Örtüsü	277960 (%8,9)	2783536 (%89,12)	71670 (%2,39)
	Yapı	75815 (%4)	96274 (%5,08)	1720361 (%90,7)
		Yer	Bitki Örtüsü	Yapı
		Tahmin Edilen		

Şekil 5.21’de DALES test verisi 4 referans LiDAR nokta bulutu ve derin sinir ağının sınıflandırdığı LiDAR nokta bulutu verilmiştir. Yapı noktalarını %90,7’lik doğruluk oranı ile sınıflandırırken bitki örtüsü noktalarını ise %89,12’lik oran ile tespit edebilmiştir. Yer noktalarını sınıflandırırken doğruluğu %83,56’da kalırken diğer test verilerinde olduğu gibi yer noktalarının %13,56’lık kısmını hatalı şekilde bitki örtüsü sınıfına dahil etmiştir.


Şekil 5.22’de LAStools, TerraScan ve QT Modeller yazılımları ile sınıflandırılmış DALES test verisi 4 LiDAR nokta bulutunun görüntüleri gösterilmiştir. Çizelge 5.55’te ise bu yazılımların sınıflandırma puanları verilmiştir.




Şekil 5.21. (a) DALES test veri seti 4 için Referans nokta bulutu, (b) derin sinir ağının en iyi modeli ile sınıflandırılmış LiDAR nokta bulutu

Çizelge 5.55. DALES LiDAR test verisi 4 için ticari yazılımların sınıflandırma puanları


	LAStools			TerraScan			QT Modeller		
	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
F1 Puanı	0,95	0,90	0,71	0,89	0,93	0,88	0,66	0,03	0,16
Ort. F1	0,85			0,90			0,28		



(a) LAStools



(b) TerraScan



(c) QT Modeller

Şekil 5.22. Ticari yazılımlar ile sınıflandırılan DALES test verisi 4 (a) LAStools (b) TerraScan (c) QT Modeller

Çizelge 5.49-5.51’de DALES LiDAR test verisi 5 için 3x3, 5x5 ve 7x7 filtre boyutları için 1 m ve 0,5 m çözünürlükte hem SGD hem de Adam optimizasyon algoritmaları ile eğitilen modellerin sınıflandırma puanları verilmiştir.

Çizelge 5.56. DALES LiDAR test verisi 5 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,90	0,75	0,81	0,96	0,75	0,81
	Duyarlık	0,69	0,91	0,94	0,68	0,95	0,97
	F1 Puan	0,78	0,82	0,87	0,80	0,84	0,88
	Ort. F1	0,82			0,84		
	Doğruluk	0,81			0,83		
0,5 m	Kesinlik	0,90	0,75	0,74	0,88	0,78	0,89
	Duyarlık	0,67	0,91	0,90	0,77	0,90	0,90
	F1 Puan	0,77	0,82	0,82	0,82	0,84	0,90
	Ort. F1	0,80			0,85		
	Doğruluk	0,80			0,84		

Çizelge 5.57. DALES LiDAR test verisi 5 için 5x5 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,90	0,74	0,83	0,90	0,75	0,83
	Duyarlık	0,68	0,91	0,93	0,70	0,91	0,92
	F1 Puan	0,78	0,82	0,88	0,79	0,83	0,87
	Ort. F1	0,83			0,83		
	Doğruluk	0,81			0,82		
0,5 m	Kesinlik	0,91	0,78	0,81	0,90	0,77	0,87
	Duyarlık	0,73	0,92	0,94	0,74	0,91	0,92
	F1 Puan	0,81	0,84	0,87	0,81	0,83	0,89
	Ort. F1	0,84			0,84		
	Doğruluk	0,83			0,83		

Çizelge 5.58. DALES LiDAR test verisi 5 için 7x7 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,90	0,75	0,81	0,89	0,76	0,81
	Duyarlık	0,69	0,90	0,94	0,70	0,89	0,93
	F1 Puan	0,78	0,82	0,87	0,79	0,82	0,86
	Ort. F1	0,82			0,82		
	Doğruluk	0,81			0,81		
0,5 m	Kesinlik	0,92	0,78	0,78	0,87	0,80	0,85
	Duyarlık	0,73	0,91	0,95	0,78	0,88	0,91
	F1 Puan	0,81	0,84	0,86	0,82	0,83	0,88
	Ort. F1	0,84			0,84		
	Doğruluk	0,83			0,84		


Çizelge 5.49’da görüldüğü üzere model en iyi sınıflandırma performansını 3x3 filtre uygulanan 0,5 m çözünürlükte oluşturulan görüntülerde ADAM optimizasyon algoritması ile elde etmiştir. En iyi model için DALES test verisi 5’in sınıflandırma hata matrisi Çizelge 5.52’de verilmiştir.

Çizelge 5.59. DALES LiDAR test verisi 5 için eğitilen en iyi modelin sınıflandırma hata matrisi

Gerçek Değer	Yer	4812860 (%76,58)	1335035 (%21,24)	134375 (%2,14)
	Bitki Örtüsü	522150 (%9,19)	5097760 (%89,73)	51573 (%0,91)
	Yapı	104430 (%6,06)	62990 (%3,66)	1551497 (%90,05)
		Yer	Bitki Örtüsü	Yapı
		Tahmin Edilen		

Şekil 5.23’de DALES test verisi 5 referans LiDAR nokta bulutu ve derin sinir ağının sınıflandırdığı LiDAR nokta bulutu verilmiştir. Yer noktalarını sınıflandırma doğruluğu %76,58’de kalırken hatalı şekilde bitki örtüsü sınıfına dahil ettiği yer noktalarının oranı %21,24 olmuştur. Yapı noktalarını sınıflandırırken doğruluğu %90,05 olurken bitki örtüsü noktalarını da %89,73’lük oran ile doğru sınıfa atamıştır.

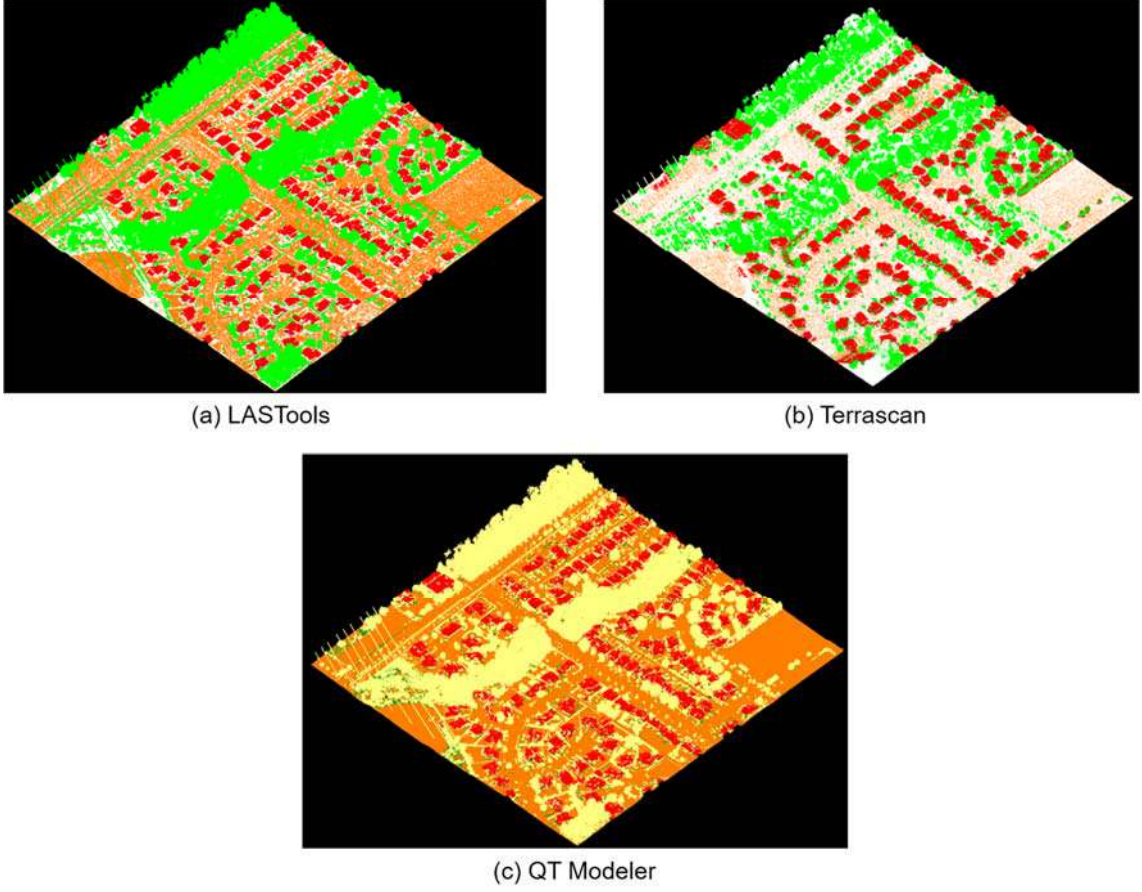
Şekil 5.24’de LAStools, TerraScan ve QT Modeller yazılımları ile sınıflandırılmış DALES test verisi 5 LiDAR nokta bulutunun görüntüleri gösterilmiştir. Çizelge 5.53’te ise bu yazılımların sınıflandırma puanları verilmiştir.



Şekil 5.23. (a) DALES test veri seti 5 için Referans nokta bulutu, (b) derin sinir ağının en iyi modeli ile sınıflandırılmış LiDAR nokta bulutu

Çizelge 5.60. DALES LiDAR test verisi 5 için ticari yazılımların sınıflandırma puanları

	LAStools			TerraScan			QT Modeller		
	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
F1 Puanı	0,80	0,84	0,59	0,84	0,94	0,86	0,58	0,08	0,14
Ort. F1	0,74			0,88			0,27		



Şekil 5.24. Ticari yazılımlar ile sınıflandırılan DALES test verisi 5 (a) LAStools (b) TerraScan (c) QT Modeler

Çizelge 5.54-5.56'da DALES LiDAR test verisi 6 için 3x3, 5x5 ve 7x7 filtre boyutları için 1 m ve 0,5 m çözünürlükte hem SGD hem de Adam optimizasyon algoritmaları ile eğitilen modellerin sınıflandırma puanları verilmiştir.

Çizelge 5.61. DALES LiDAR test verisi 6 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,96	0,74	0,84	0,98	0,74	0,84
	Duyarlık	0,76	0,93	0,95	0,76	0,95	0,97
	F1 Puan	0,85	0,82	0,89	0,85	0,83	0,90
	Ort. F1	0,85			0,86		
	Doğruluk	0,85			0,86		
0,5 m	Kesinlik	0,94	0,74	0,84	0,94	0,79	0,89
	Duyarlık	0,77	0,92	0,92	0,83	0,92	0,93
	F1 Puan	0,85	0,82	0,88	0,89	0,85	0,91
	Ort. F1	0,85			0,88		
	Doğruluk	0,85			0,88		

Çizelge 5.62. DALES LiDAR test verisi 6 için 5x5 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,96	0,72	0,85	0,96	0,74	0,85
	Duyarlık	0,75	0,94	0,95	0,77	0,93	0,95
	F1 Puan	0,84	0,81	0,90	0,85	0,83	0,90
	Ort. F1	0,85			0,86		
	Doğruluk	0,84			0,85		
0,5 m	Kesinlik	0,96	0,78	0,88	0,95	0,78	0,87
	Duyarlık	0,82	0,94	0,95	0,81	0,93	0,96
	F1 Puan	0,88	0,85	0,92	0,88	0,84	0,91
	Ort. F1	0,88			0,88		
	Doğruluk	0,88			0,87		

Çizelge 5.63. DALES LiDAR test verisi 6 için 7x7 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,96	0,74	0,84	0,95	0,75	0,84
	Duyarlık	0,77	0,93	0,95	0,77	0,92	0,96
	F1 Puan	0,85	0,83	0,89	0,85	0,83	0,89
	Ort. F1	0,86			0,86		
	Doğruluk	0,85			0,85		
0,5 m	Kesinlik	0,96	0,79	0,83	0,94	0,80	0,87
	Duyarlık	0,81	0,92	0,97	0,84	0,90	0,95
	F1 Puan	0,88	0,85	0,89	0,89	0,85	0,91
	Ort. F1	0,87			0,88		
	Doğruluk	0,87			0,88		

Çizelge 5.54-56'da görüldüğü üzere model en iyi sınıflandırma performansını her bir filtre boyutunun uygulandığı 0,5 m çözünürlükte oluşturulan görüntülerde ADAM optimizasyon algoritması ile elde etmiştir. En iyi model için DALES test verisi 6'nın sınıflandırma hata matrisi Çizelge 5.57'de verilmiştir.


Çizelge 5.64. DALES LiDAR test verisi 6 için eğitilen en iyi modelin sınıflandırma hata matrisi

Gerçek Değer	Yer	5223666 (%83,47)	841908 (%13,45)	191496 (%3,06)
	Bitki Örtüsü	236259 (%6,41)	3391284 (%92,08)	52392 (%1,42)
	Yapı	83157 (%3,73)	65927 (%2,96)	2078669 (%93,23)
		Yer	Bitki Örtüsü	Yapı
		Tahmin Edilen		

Şekil 5.25'de DALES test verisi 6 referans LiDAR nokta bulutu ve derin sınır ağının sınıflandırdığı LiDAR nokta bulutu verilmiştir. Yapı ve bitki örtüsü noktalarının tespitinde oldukça başarılı olan yöntem yer noktalarını sınıflandırmada aynı başarıyı yakalayamamıştır. Yer noktalarının %83,47'sini doğru tespit ederken hatalı şekilde bitki örtüsü sınıfına dahil ettiği yer noktalarının oranı %13,45 olmuştur. Yapı noktalarını

sınıflandırırken doğruluğu %93,23 olurken bitki örtüsü noktalarını da %92,08'lik oran ile doğru sınıfa atamıştır.


Şekil 5.26'da LAStools, TerraScan ve QT Modeller yazılımları ile sınıflandırılmış DALES test verisi 6 LiDAR nokta bulutunun görüntüleri gösterilmiştir. Çizelge 5.58'de ise bu yazılımların sınıflandırma puanları verilmiştir.



Şekil 5.25. (a) DALES test veri seti 6 için Referans nokta bulutu, (b) derin sinir ağının en iyi modeli ile sınıflandırılmış LiDAR nokta bulutu

Çizelge 5.65. DALES LiDAR test verisi 6 için ticari yazılımların sınıflandırma puanları

	LAStools			TerraScan			QT Modeller		
	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
F1 Puanı	0,74	0,81	0,54	0,86	0,92	0,87	0,99	0,50	0,98
Ort. F1	0,70			0,88			0,82		



Şekil 5.26. Ticari yazılımlar ile sınıflandırılan DALES test verisi 6 (a) LAStools (b) TerraScan (c) QT Modeller

Çizelge 5.59-5.61’de DALES LiDAR test verisi 7 için 3x3, 5x5 ve 7x7 filtre boyutları için 1 m ve 0,5 m çözünürlükte hem SGD hem de Adam optimizasyon algoritmaları ile eğitilen modellerin sınıflandırma puanları verilmiştir.

Çizelge 5.66. DALES LiDAR test verisi 7 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,90	0,78	0,68	0,96	0,78	0,66
	Duyarlık	0,73	0,92	0,89	0,73	0,97	0,96
	F1 Puan	0,81	0,84	0,77	0,83	0,87	0,78
	Ort. F1	0,81			0,83		
	Doğruluk	0,82			0,85		
0,5 m	Kesinlik	0,92	0,78	0,81	0,90	0,80	0,87
	Duyarlık	0,75	0,93	0,85	0,79	0,91	0,86
	F1 Puan	0,83	0,85	0,83	0,84	0,85	0,87
	Ort. F1	0,84			0,85		
	Doğruluk	0,84			0,85		

Çizelge 5.67. DALES LiDAR test verisi 7 için 5x5 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,88	0,77	0,68	0,90	0,78	0,82
	Duyarlık	0,74	0,89	0,87	0,76	0,91	0,86
	F1 Puan	0,80	0,83	0,77	0,82	0,84	0,84
	Ort. F1	0,80			0,83		
	Doğruluk	0,81			0,83		
0,5 m	Kesinlik	0,92	0,80	0,86	0,91	0,79	0,82
	Duyarlık	0,78	0,93	0,91	0,77	0,92	0,87
	F1 Puan	0,85	0,86	0,88	0,84	0,85	0,84
	Ort. F1	0,86			0,84		
	Doğruluk	0,85			0,84		

Çizelge 5.68. DALES LiDAR test verisi 7 için 7x7 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,89	0,78	0,80	0,88	0,78	0,76
	Duyarlık	0,76	0,90	0,86	0,76	0,89	0,88
	F1 Puan	0,82	0,84	0,83	0,82	0,83	0,82
	Ort. F1	0,83			0,82		
	Doğruluk	0,83			0,83		
0,5 m	Kesinlik	0,93	0,78	0,83	0,91	0,80	0,79
	Duyarlık	0,76	0,94	0,90	0,79	0,91	0,87
	F1 Puan	0,83	0,85	0,86	0,84	0,85	0,83
	Ort. F1	0,85			0,84		
	Doğruluk	0,84			0,85		

Çizelge 5.60’da görüldüğü üzere model en iyi sınıflandırma performansını her bir filtre boyutunun uygulandığı 0,5 m çözünürlükte oluşturulan görüntülerde SGD optimizasyon algoritması ile elde etmiştir. En iyi model için DALES test verisi 7’nin sınıflandırma hata matrisi Çizelge 5.62’de verilmiştir.

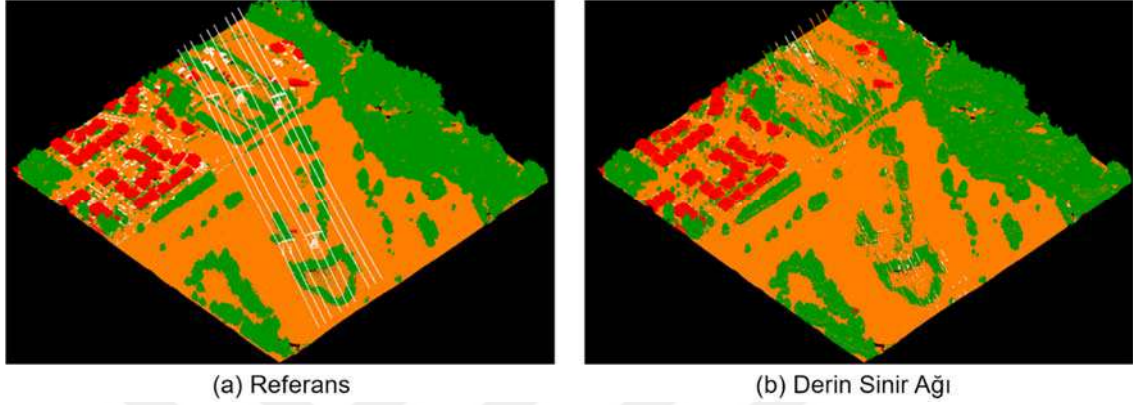
Çizelge 5.69. DALES LiDAR test verisi 7 için eğitilen en iyi modelin sınıflandırma hata matrisi

Gerçek Değer	Yer	5453082 (%77,62)	1507851 (%21,46)	54901 (%0,78)
	Bitki Örtüsü	409371 (%6,39)	5952008 (%92,93)	24667 (%0,39)
	Yapı	33116 (%6,14)	15501 (%2,87)	488457 (%90,52)
		Yer	Bitki Örtüsü	Yapı
		Tahmin Edilen		


Şekil 5.27’de DALES test verisi 7 referans LiDAR nokta bulutu ve derin sinir ağının sınıflandırdığı LiDAR nokta bulutu verilmiştir. Yer noktalarının %77,62’sini doğru tespit ederken hatalı şekilde bitki örtüsü sınıfına dahil ettiği yer noktalarının oranı %21,46 olmuştur. Yapı noktalarını sınıflandırırken doğruluğu %90,52 olurken bitki örtüsü noktalarını da %92,93’lük oran ile doğru sınıfa atamıştır. Yapı ve bitki örtüsü

noktalarının tespitinde oldukça başarılı olan yöntem yer noktalarını sınıflandırmada aynı başarıyı yakalayamamıştır.

Şekil 5.28’de LASTools, TerraScan ve QT Modeler yazılımları ile sınıflandırılmış DALES test verisi 7 LiDAR nokta bulutunun görüntüleri gösterilmiştir. Çizelge 5.63’te ise bu yazılımların sınıflandırma puanları verilmiştir.



Şekil 5.27. (a) DALES test veri seti 7 için Referans nokta bulutu, (b) derin sinir ağının en iyi modeli ile sınıflandırılmış LiDAR nokta bulutu



Şekil 5.28. Ticari yazılımlar ile sınıflandırılan DALES test verisi 7 (a) LASTools (b) TerraScan (c) QT Modeler

Çizelge 5.70. DALES LiDAR test verisi 7 için ticari yazılımların sınıflandırma puanları

	LAStools			TerraScan			QT Modeller		
	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
F1 Puanı	0,79	0,93	0,27	0,88	0,95	0,76	0,97	0,60	0,96
Ort. F1	0,66			0,86			0,84		

Çizelge 5.64-5.66'da DALES LiDAR test verisi 8 için 3x3, 5x5 ve 7x7 filtre boyutları için 1 m ve 0,5 m çözünürlükte hem SGD hem de Adam optimizasyon algoritmaları ile eğitilen modellerin sınıflandırma puanları verilmiştir.

Çizelge 5.71. DALES LiDAR test verisi 8 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,97	0,65	0,80	0,98	0,67	0,82
	Duyarlık	0,70	0,92	0,94	0,72	0,94	0,96
	F1 Puan	0,81	0,76	0,87	0,83	0,78	0,88
	Ort. F1	0,81			0,83		
	Doğruluk	0,81			0,82		
0,5 m	Kesinlik	0,96	0,65	0,80	0,91	0,70	0,86
	Duyarlık	0,71	0,91	0,92	0,79	0,90	0,84
	F1 Puan	0,82	0,76	0,85	0,85	0,79	0,85
	Ort. F1	0,81			0,83		
	Doğruluk	0,81			0,83		

Çizelge 5.72. DALES LiDAR test verisi 8 için 5x5 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,97	0,65	0,81	0,93	0,66	0,84
	Duyarlık	0,70	0,92	0,93	0,73	0,91	0,87
	F1 Puan	0,81	0,76	0,86	0,82	0,77	0,85
	Ort. F1	0,81			0,81		
	Doğruluk	0,81			0,81		
0,5 m	Kesinlik	0,95	0,69	0,85	0,94	0,68	0,83
	Duyarlık	0,77	0,92	0,89	0,76	0,91	0,88
	F1 Puan	0,85	0,79	0,87	0,84	0,78	0,86
	Ort. F1	0,84			0,83		
	Doğruluk	0,83			0,82		

Çizelge 5.73. DALES LiDAR test verisi 8 için 7x7 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,96	0,65	0,79	0,95	0,66	0,83
	Duyarlık	0,70	0,92	0,92	0,73	0,91	0,91
	F1 Puan	0,81	0,76	0,85	0,82	0,76	0,87
	Ort. F1	0,81			0,82		
	Doğruluk	0,80			0,81		
0,5 m	Kesinlik	0,95	0,70	0,79	0,91	0,71	0,81
	Duyarlık	0,75	0,90	0,92	0,79	0,86	0,85
	F1 Puan	0,84	0,79	0,85	0,84	0,78	0,83
	Ort. F1	0,83			0,82		
	Doğruluk	0,83			0,82		


Çizelge 5.72’de görüldüğü üzere model en iyi sınıflandırma performansını her bir filtre boyutunun uygulandığı 0,5 m çözünürlükte oluşturulan görüntülerde SGD optimizasyon algoritması ile elde etmiştir. En iyi model için DALES test verisi 8’in sınıflandırma hata matrisi Çizelge 5.74’te verilmiştir.

Çizelge 5.74. DALES LiDAR test verisi 8 için eğitilen en iyi modelin sınıflandırma hata matrisi

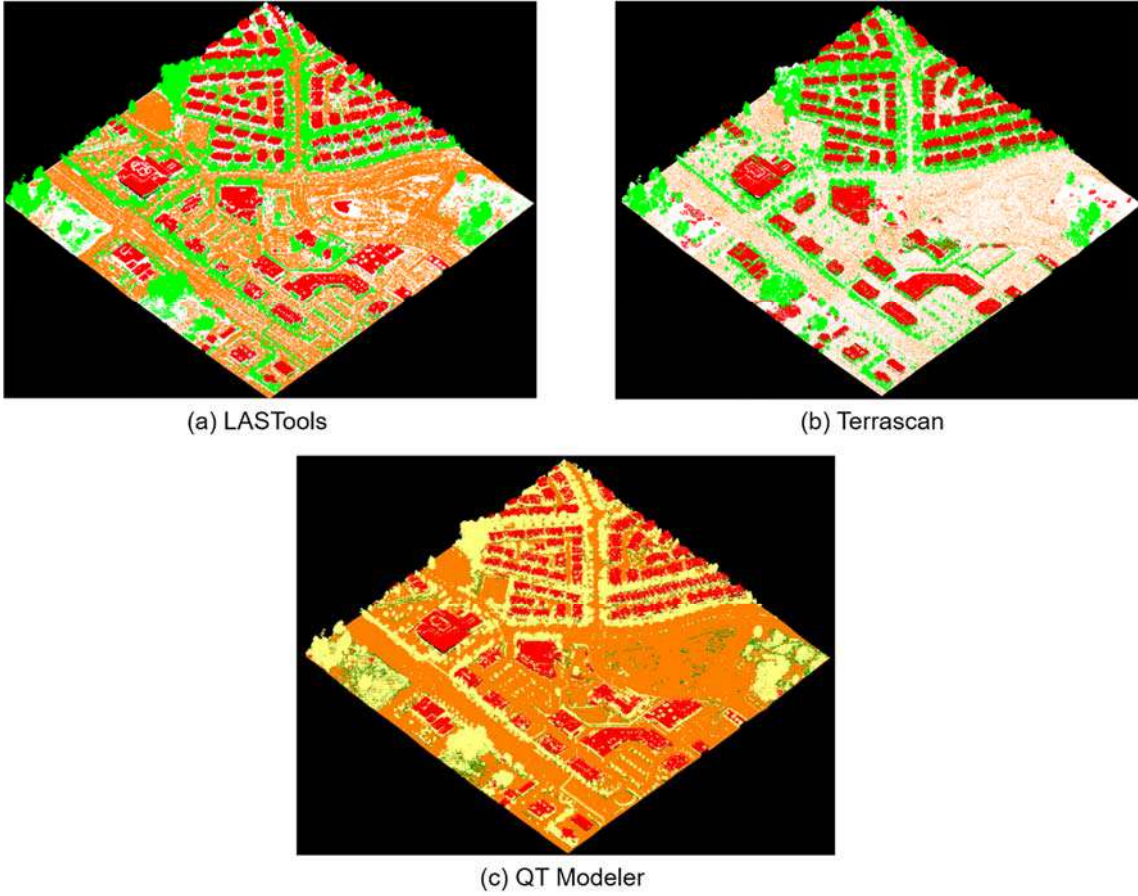
Gerçek Değer	Yer	4879721 (%76,76)	1225679 (%19,28)	245408 (%3,86)
	Bitki Örtüsü	172497 (%5,2)	3035844 (%91,48)	102316 (%3,08)
	Yapı	108868 (%5,02)	131479 (%6,07)	1921576 (%88,55)
		Yer	Bitki Örtüsü	Yapı
		Tahmin Edilen		

Şekil 5.29’te DALES test verisi 8 referans LiDAR nokta bulutu ve derin sinir ağının sınıflandırdığı LiDAR nokta bulutu verilmiştir. Yapı noktalarını %88,55’lik doğruluk oranı ile sınıflandırırken bitki örtüsü noktalarını ise %91,48’lik oran ile tespit edebilmiştir. Yer noktalarını sınıflandırırken doğruluğu %76,76’da kalırken diğer test verilerinde olduğu gibi yer noktalarının %19,28’lik kısmını hatalı şekilde bitki örtüsü sınıfına dahil etmiştir.

Şekil 5.30’de LAsTools, TerraScan ve QT Modeller yazılımları ile sınıflandırılmış DALES test verisi 8 LiDAR nokta bulutunun görüntüleri gösterilmiştir. Çizelge 5.75’te ise bu yazılımların sınıflandırma puanları verilmiştir.



Şekil 5.29. (a) DALES test veri seti 8 için Referans nokta bulutu, (b) derin sinir ağının en iyi modeli ile sınıflandırılmış LiDAR nokta bulutu



Şekil 5.30. Ticari yazılımlar ile sınıflandırılan DALES test verisi 8 (a) LAStools (b) TerraScan (c) QT Modeller

Çizelge 5.75. DALES LiDAR test verisi 8 için ticari yazılımların sınıflandırma puanları

	LAStools			TerraScan			QT Modeller		
	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
F1 Puanı	0,79	0,80	0,59	0,84	0,86	0,88	0,98	0,67	0,99
Ort. F1	0,73			0,86			0,88		

Çizelge 5.76-5.78’de DALES LiDAR test verisi 9 için 3x3, 5x5 ve 7x7 filtre boyutları için 1 m ve 0,5 m çözünürlükte hem SGD hem de Adam optimizasyon algoritmaları ile eğitilen modellerin sınıflandırma puanları verilmiştir.

Çizelge 5.76. DALES LiDAR test verisi 9 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,94	0,73	0,87	0,98	0,72	0,86
	Duyarlık	0,79	0,88	0,96	0,77	0,93	0,98
	F1 Puan	0,86	0,80	0,91	0,86	0,81	0,91
	Ort. F1	0,86			0,86		
	Doğruluk	0,85			0,86		
0,5 m	Kesinlik	0,93	0,72	0,84	0,91	0,77	0,93
	Duyarlık	0,78	0,88	0,94	0,85	0,88	0,91
	F1 Puan	0,85	0,80	0,89	0,88	0,82	0,92
	Ort. F1	0,85			0,87		
	Doğruluk	0,84			0,87		

Çizelge 5.77. DALES LiDAR test verisi 9 için 5x5 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,94	0,72	0,88	0,94	0,73	0,88
	Duyarlık	0,79	0,89	0,96	0,80	0,89	0,96
	F1 Puan	0,86	0,80	0,92	0,86	0,80	0,92
	Ort. F1	0,86			0,86		
	Doğruluk	0,85			0,86		
0,5 m	Kesinlik	0,94	0,77	0,91	0,94	0,76	0,90
	Duyarlık	0,84	0,90	0,96	0,83	0,89	0,96
	F1 Puan	0,89	0,83	0,93	0,88	0,82	0,93
	Ort. F1	0,88			0,88		
	Doğruluk	0,88			0,87		

Çizelge 5.78. DALES LiDAR test verisi 9 için 7x7 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,94	0,72	0,87	0,94	0,73	0,87
	Duyarlık	0,79	0,88	0,96	0,80	0,88	0,96
	F1 Puan	0,86	0,80	0,91	0,86	0,80	0,92
	Ort. F1	0,86			0,86		
	Doğruluk	0,85			0,86		
0,5 m	Kesinlik	0,94	0,77	0,85	0,87	0,79	0,91
	Duyarlık	0,82	0,88	0,97	0,87	0,86	0,83
	F1 Puan	0,88	0,82	0,91	0,87	0,82	0,87
	Ort. F1	0,87			0,85		
	Doğruluk	0,87			0,86		


Çizelge 5.77’de görüldüğü üzere model en iyi sınıflandırma performansını her bir filtre boyutunun uygulandığı 0,5 m çözünürlükte oluşturulan görüntülerde SGD optimizasyon algoritması ile elde etmiştir. En iyi model için DALES test verisi 9’un sınıflandırma hata matrisi Çizelge 5.79’da verilmiştir.

Çizelge 5.79. DALES LiDAR test verisi 9 için eğitilen en iyi modelin sınıflandırma hata matrisi


Gerçek Değer	Yer	5056752 (%83,97)	787400 (%13,08)	171100 (%2,84)
	Bitki Örtüsü	244829 (%7,81)	2801651 (%89,36)	68414 (%2,18)
	Yapı	50728 (%2,05)	48426 (%1,96)	2367548 (%95,89)
		Yer	Bitki Örtüsü	Yapı
		Tahmin Edilen		

Şekil 5.31’de DALES test verisi 9 referans LiDAR nokta bulutu ve derin sinir ağının sınıflandırdığı LiDAR nokta bulutu verilmiştir. Yapı noktalarını %95,89’luk doğruluk oranı ile oldukça başarılı şekilde sınıflandırırken yer noktalarının %13,08’lik kısmını yanlış etiketleyerek bitki örtüsü sınıfına atamıştır. Yer noktalarını sınıflandırırken doğruluğu %83,97’de kalmıştır. Bitki örtüsü noktalarını ise %89,36’lık oran ile tespit edebilmiştir.

Şekil 5.32’de LAsTools, TerraScan ve QT Modeller yazılımları ile sınıflandırılmış DALES test verisi 9 LiDAR nokta bulutunun görüntüleri gösterilmiştir. Çizelge 5.80’de ise bu yazılımların sınıflandırma puanları verilmiştir.



Şekil 5.31. (a) DALES test veri seti 9 için Referans nokta bulutu, (b) derin sinir ağının en iyi modeli ile sınıflandırılmış LiDAR nokta bulutu



Şekil 5.32. Ticari yazılımlar ile sınıflandırılan DALES test verisi 9 (a) LAsTools (b) TerraScan (c) QT Modeller

Çizelge 5.80. DALES LiDAR test verisi 9 için ticari yazılımların sınıflandırma puanları

	LAStools			TerraScan			QT Modeller		
	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
F1 Puanı	0,92	0,86	0,83	0,86	0,91	0,90	0,98	0,54	0,98
Ort. F1	0,87			0,89			0,83		

Çizelge 5.81-5.83'te DALES LiDAR test verisi 10 için 3x3, 5x5 ve 7x7 filtre boyutları için 1 m ve 0,5 m çözünürlükte hem SGD hem de Adam optimizasyon algoritmaları ile eğitilen modellerin sınıflandırma puanları verilmiştir.

Çizelge 5.81. DALES LiDAR test verisi 10 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,96	0,69	0,85	0,98	0,71	0,85
	Duyarlık	0,77	0,92	0,96	0,77	0,96	0,97
	F1 Puan	0,85	0,79	0,90	0,86	0,81	0,91
	Ort. F1	0,85			0,86		
	Doğruluk	0,84			0,85		
0,5 m	Kesinlik	0,94	0,71	0,83	0,94	0,75	0,90
	Duyarlık	0,79	0,91	0,91	0,84	0,90	0,93
	F1 Puan	0,86	0,80	0,87	0,89	0,82	0,92
	Ort. F1	0,84			0,88		
	Doğruluk	0,84			0,87		

Çizelge 5.82. DALES LiDAR test verisi 10 için 5x5 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,96	0,69	0,86	0,95	0,70	0,85
	Duyarlık	0,76	0,92	0,95	0,78	0,92	0,93
	F1 Puan	0,85	0,79	0,90	0,85	0,80	0,89
	Ort. F1	0,85			0,85		
	Doğruluk	0,84			0,84		
0,5 m	Kesinlik	0,96	0,74	0,85	0,95	0,72	0,88
	Duyarlık	0,81	0,92	0,96	0,81	0,92	0,95
	F1 Puan	0,88	0,82	0,90	0,87	0,81	0,92
	Ort. F1	0,87			0,87		
	Doğruluk	0,86			0,86		

Çizelge 5.83. DALES LiDAR test verisi 10 için 7x7 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,96	0,69	0,85	0,94	0,70	0,84
	Duyarlık	0,76	0,92	0,95	0,78	0,91	0,92
	F1 Puan	0,85	0,79	0,90	0,85	0,79	0,87
	Ort. F1	0,85			0,84		
	Doğruluk	0,84			0,84		
0,5 m	Kesinlik	0,96	0,75	0,84	0,93	0,76	0,89
	Duyarlık	0,81	0,91	0,98	0,84	0,89	0,93
	F1 Puan	0,88	0,82	0,90	0,89	0,82	0,91
	Ort. F1	0,87			0,87		
	Doğruluk	0,86			0,87		


Çizelge 5.81’de görüldüğü üzere model en iyi sınıflandırma performansını 3x3 filtre uygulanan 0,5 m çözünürlükte oluşturulan görüntülerde ADAM optimizasyon algoritması ile elde etmiştir. En iyi model için DALES test verisi 10’un sınıflandırma hata matrisi Çizelge 5.84’te verilmiştir.

Çizelge 5.84. DALES LiDAR test verisi 10 için eğitilen en iyi modelin sınıflandırma hata matrisi

Gerçek Değer	Yer	5722724 (%83,72)	970534 (%14,20)	141957 (%2,08)
	Bitki Örtüsü	296670 (%8,64)	3104521 (%90,42)	31871 (%0,93)
	Yapı	68670 (%3,86)	58151 (%3,27)	1650127 (%92,82)
		Yer	Bitki Örtüsü	Yapı
		Tahmin Edilen		

Şekil 5.33'te DALES test verisi 10 referans LiDAR nokta bulutu ve derin sinir ağının sınıflandırdığı LiDAR nokta bulutu verilmiştir. Yer noktalarını sınıflandırma doğruluğu %83,72'de kalırken hatalı şekilde bitki örtüsü sınıfına dahil ettiği yer noktalarının oranı %14,20 olmuştur. Yapı noktalarını sınıflandırırken doğruluğu %92,82 olurken bitki örtüsü noktalarını da %90,42'lik oran ile doğru sınıfa atamıştır.


Şekil 5.34'te LAsTools, TerraScan ve QT Modeller yazılımları ile sınıflandırılmış DALES test verisi 10 LiDAR nokta bulutunun görüntüleri gösterilmiştir. Çizelge 5.85'te ise bu yazılımların sınıflandırma puanları verilmiştir.




Şekil 5.33. (a) DALES test veri seti 10 için Referans nokta bulutu, (b) derin sinir ağının en iyi modeli ile sınıflandırılmış LiDAR nokta bulutu

Çizelge 5.85. DALES LiDAR test verisi 10 için ticari yazılımların sınıflandırma puanları


	LAStools			TerraScan			QT Modeller		
	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
F1 Puanı	0,84	0,82	0,58	0,87	0,90	0,87	0,98	0,55	0,99
Ort. F1	0,75			0,88			0,84		



(a) LAStools



(b) Terrascan



(c) QT Modeller

Şekil 5.34. Ticari yazılımlar ile sınıflandırılan DALES test verisi 10 (a) LAStools (b) TerraScan (c) QT Modeller

Çizelge 5.86-5.88’de DALES LiDAR test verisi 11 için 3x3, 5x5 ve 7x7 filtre boyutları için 1 m ve 0,5 m çözünürlükte hem SGD hem de Adam optimizasyon algoritmaları ile eğitilen modellerin sınıflandırma puanları verilmiştir.

Çizelge 5.86. DALES LiDAR test verisi 11 için 3x3 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,92	0,63	0,83	0,97	0,64	0,84
	Duyarlık	0,71	0,86	0,93	0,69	0,92	0,96
	F1 Puan	0,80	0,73	0,88	0,81	0,75	0,90
	Ort. F1	0,80			0,82		
	Doğruluk	0,80			0,81		
0,5 m	Kesinlik	0,91	0,63	0,83	0,89	0,68	0,89
	Duyarlık	0,72	0,85	0,90	0,78	0,84	0,90
	F1 Puan	0,80	0,73	0,87	0,84	0,75	0,90
	Ort. F1	0,80			0,83		
	Doğruluk	0,79			0,82		

Çizelge 5.87. DALES LiDAR test verisi 11 için 5x5 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,92	0,62	0,82	0,91	0,63	0,85
	Duyarlık	0,69	0,87	0,92	0,71	0,87	0,91
	F1 Puan	0,79	0,72	0,87	0,80	0,73	0,88
	Ort. F1	0,79			0,80		
	Doğruluk	0,79			0,80		
0,5 m	Kesinlik	0,91	0,67	0,87	0,91	0,65	0,87
	Duyarlık	0,77	0,86	0,93	0,75	0,86	0,92
	F1 Puan	0,83	0,75	0,90	0,82	0,74	0,90
	Ort. F1	0,83			0,82		
	Doğruluk	0,83			0,81		

Çizelge 5.88. DALES LiDAR test verisi 11 için 7x7 filtre boyutları ile eğitilen modelin sınıflandırma puanları

Çözünürlük		SGD			ADAM		
		Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
1 m	Kesinlik	0,91	0,63	0,83	0,92	0,63	0,84
	Duyarlık	0,71	0,86	0,92	0,71	0,86	0,93
	F1 Puan	0,80	0,73	0,88	0,80	0,73	0,88
	Ort. F1	0,80			0,80		
	Doğruluk	0,80			0,80		
0,5 m	Kesinlik	0,91	0,68	0,81	0,88	0,70	0,88
	Duyarlık	0,75	0,83	0,94	0,81	0,80	0,90
	F1 Puan	0,83	0,75	0,87	0,84	0,75	0,89
	Ort. F1	0,82			0,83		
	Doğruluk	0,81			0,83		

Çizelge 5.87’de görüldüğü üzere model en iyi sınıflandırma performansını 5x5 filtre uygulanan 0,5 m çözünürlükte oluşturulan görüntülerde SGD optimizasyon algoritması ile elde etmiştir. En iyi model için DALES test verisi 11’in sınıflandırma hata matrisi Çizelge 5.89’da verilmiştir.

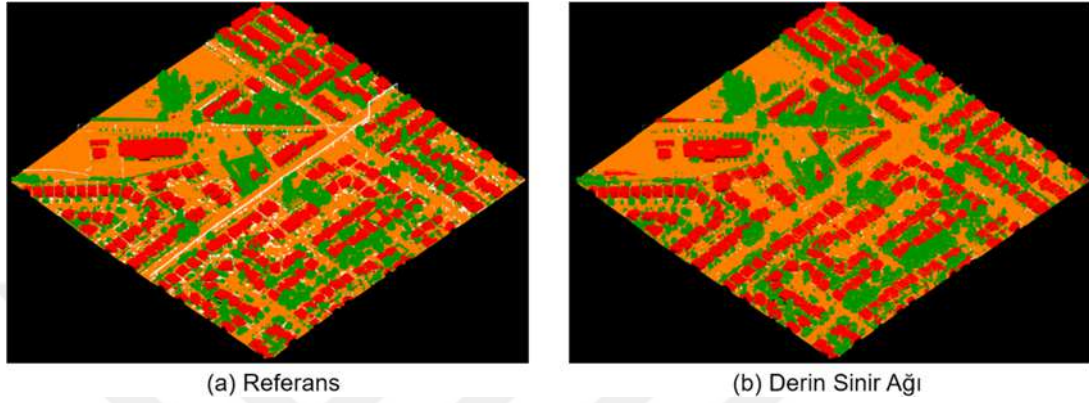
Çizelge 5.89. DALES LiDAR test verisi 11 için eğitilen en iyi modelin sınıflandırma hata matrisi

Gerçek Değer	Yer	4778806 (%76,72)	1195324 (%19,19)	251928 (%4,04)
	Bitki Örtüsü	347902 (%11,23)	2637225 (%85,1)	97513 (%3,15)
	Yapı	105934 (%4,08)	86157 (%3,32)	2396535 (%92,38)
		Yer	Bitki Örtüsü	Yapı
		Tahmin Edilen		


Şekil 5.35’te DALES test verisi 11 referans LiDAR nokta bulutu ve derin sınır ağının sınıflandırdığı LiDAR nokta bulutu verilmiştir. Yapı noktalarını %92,38’lik doğruluk oranı ile oldukça başarılı şekilde sınıflandırırken yer noktalarının %19,19’luk kısmını yanlış etiketleyerek bitki örtüsü sınıfına atamıştır. Yer noktalarını sınıflandırırken

doğruluğu %76,72’de kalırken bitki örtüsü noktalarını belirleme doğruluğu %85,1 olmuştur.

Şekil 5.36’da LASTools, TerraScan ve QT Modeller yazılımları ile sınıflandırılmış DALES test verisi 11 LiDAR nokta bulutunun görüntüleri gösterilmiştir. Çizelge 5.90’da ise bu yazılımların sınıflandırma puanları verilmiştir.



Şekil 5.35. (a) DALES test veri seti 11 için Referans nokta bulutu, (b) derin sinir ağının en iyi modeli ile sınıflandırılmış LiDAR nokta bulutu




Şekil 5.36. Ticari yazılımlar ile sınıflandırılan DALES test verisi 11 (a) LASTools (b) TerraScan (c) QT Modeller

Çizelge 5.90. DALES LiDAR test verisi 11 için ticari yazılımların sınıflandırma puanları

	LAStools			TerraScan			QT Modeller		
	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı	Yer	Bitki Ört.	Yapı
F1 Puanı	0,92	0,87	0,81	0,84	0,89	0,88	0,98	0,51	0,98
Ort. F1	0,87			0,87			0,82		

5.2. Sınıflandırma Sonuçlarının Yorumlanması

Hava LiDAR nokta bulutu verilerinin düzensiz yapıda olması karelaja ayırma ve görüntüye dönüşüm işlemlerinde sınıflandırma performansına etki eden önemli bir dezavantaja sahiptir, şöyle ki bitki örtüsünün sık olduğu bölgelerde piksel sınıflandırma aşamasında bitkilerin bulunduğu katmanın altındaki yer yüzüne ait noktaları doğru sınıfa atayamamasıdır. Tez çalışmasında önerilen yöntem her ne kadar karelajlara ayrılan nokta bulutunda her bir pikselde ki en düşük ve en yüksek kota sahip noktaları kullanarak sınıflandırma işlemini gerçekleştirirse de orman örtüsünün bulunduğu veri setlerinde yer noktalarını tespit etmekte kısmen başarılı olamamıştır (Şekil 5.37).




Şekil 5.37. Bergen test verisinde yer noktalarının hatalı olarak bitki sınıfına dahil edilmesi (a) Referans (b) Derin sinir ağı

Topoğrafyası dağlık ve sık orman örtüsü içeren Bergen LiDAR nokta bulutu test verileri için hatalı olarak bitki örtüsü sınıfına atanan yer noktalarının ortalama oranı %32 iken kısmen daha az bitki katmanını içeren DALES test verileri için bu değer %17'de kalmıştır. Sınıflandırma başarısı kriterlerinden birisi olan F1 puanına da direkt etki eden unsurlardan olmuştur. Bergen veri setinde yer sınıfı için ürettiği ortalama F1 puanı 0,79

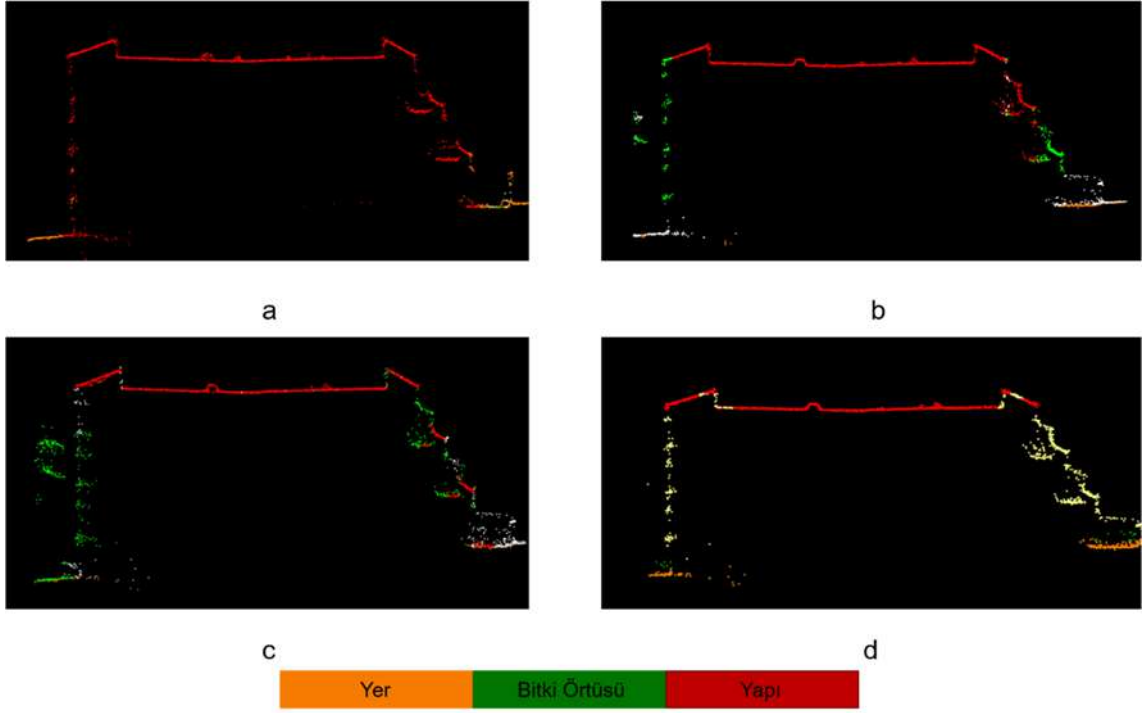
da kalırken DALES veri setinde 0,87 olmuştur. Bitki örtüsüne ait noktalar için ürettiği ortalama F1 puanı ise Bergen veri seti için 0,89 iken DALES veri seti için 0,82 olmuştur.

Önerilen yöntemin başarılı olduğu konu ise yapı sınıfına ait noktaları yüksek doğrulukta tespit edebilmesidir (Şekil 5.38). Tez kapsamında performans kıyaslaması yaptığımız ticari yazılımlar ile karşılaştırdığımızda yapı noktalarını Bergen veri seti için ortalama %88 ve DALES veri seti için ortalama %92’lik bir oranda doğru sınıfa atamıştır. Diğer yazılımlar bina cephesine ait noktaları çoğunlukla bitki örtüsü sınıfına yanlış atamıştır. Özellikle girinti veya çıkıntı olmayan düz cepheleri bitki örtüsü sınıfına dahil etmiştir (Şekil 5.39). Önerilen yöntemin bina cephelerini tespit etmedeki başarısı bölüm 4.4.1’de anlatılan yer noktalarının belirtilen eşik değerin altında kabul edilmesi ve eşik değerin üstündeki tüm noktaların ilgili pikselin en yüksek noktasına göre sınıflandırılmasına dayanmaktadır.



Şekil 5.38. DALES test verisinden bir binanın sınıflandırılması (a) Derin sinir ağı (b) LAStools (c) TerraScan (d) QT Modeler (QT Modeler yazılımı bitki örtüsünü sarı renk ile göstermiştir.)

Özellikle bina cephe noktalarının tespitinde diğer algoritmalara kıyasla oldukça başarılı bir performans ortaya koymuştur. Derin sinir ağı yönteminin ve karşılaştırma yapılan algoritmaların ürettiği ortalama F1 puanları Bergen ve DALES veri setleri için sırasıyla Çizelge 5.91 ve 5.92’de verilmiştir.



Şekil 5.39. Binanın profil görüntüsü (a) Derin sinir ağı (b) LAStools (c) TerraScan (d) QT Modeller (QT Modeller yazılımı bitki örtüsünü sarı renk ile göstermiştir.)

Çizelge 5.91. Bergen LiDAR test veri seti için derin sinir ağı ve algoritmaların ortalama F1 puanı

F1 puanı	Derin sinir ağı	Terrascan	LAStools	QTM Modeller
Yer	0,79	0,98	0,99	0,97
Bitki Örtüsü	0,89	0,98	0,98	0,71
Yapı	0,91	0,89	0,85	0,88

Çizelge 5.92. DALES LiDAR test veri seti için derin sinir ağı ve algoritmaların ortalama F1 puanı

F1 puanı	Derin sinir ağı	Terrascan	LAStools	QTM Modeller
Yer	0,87	0,87	0,87	0,81
Bitki Örtüsü	0,82	0,91	0,86	0,33
Yapı	0,90	0,88	0,68	0,63

6. SONUÇLAR VE ÖNERİLER

6.1. Sonuçlar

Bu tez çalışmasında son yıllarda araştırmacılar arasında popülerliği giderek artan makine öğrenmesi tekniklerinden derin öğrenme ile hava LiDAR nokta bulutlarının sınıflandırılmasını sağlayan bir yöntem önerilmiştir. Sınıflandırma işlemi LiDAR nokta bulutunun yer, yapı ve bitki örtüsü noktalarını ait oldukları sınıfa atama işlemi olarak kabul edilebilir. Sınıflandırma performansını ölçmek için ortalama doğruluk ve F1 puanı kullanılmıştır. F1 puanı, eğitim verisinde ki sınıflar arası dengesizliğin olduğu durumlar için daha uygun bir kıyas yöntemidir (Wen vd., 2020). Klasik sınıflandırma algoritmalarını kullanan farklı yazılımlar ile sonuçları kıyaslandığında, önerilen yöntemin verimli ve dezavantajlı olduğu kısımlar şöyle sıralanabilir;

- Nispeten daha düz arazi tiplerinde yer noktalarını tespit etme doğruluğu klasik algoritmalara kıyasla daha yüksek olmuştur. Buna karşın engebeli arazi yapısı fazla olan bölgelerde aynı başarıyı gösterememiştir.
- Bitki örtüsünün daha sık olduğu bölgelerde doğruluğu daha seyrek ve az olan bölgelere kıyasla daha yüksek olmuştur. Yöntemin dezavantajlarından biri ise bitki örtüsü altında kalan yer noktalarını hatalı şekilde bitki örtüsü sınıfına dahil etmesidir (Şekil 5.37). Bu nedenle bitki örtüsü sınıfına ait kesinlik (*precision*) ve yer sınıfına ait duyarlık (*recall*) puanları daha düşük gelmiştir.
- Önerilen yöntem yapı noktalarını klasik algoritmalara göre daha başarılı şekilde sınıflandırırken bunun en büyük sebebi binaların cephelerini daha doğru şekilde tespit edebilmesidir (Şekil 5.38). Özellikle binaların yoğun olduğu DALES test veri setlerinde LASTools ve QT Modeller yazılımlarına kıyasla yapı sınıfı için ürettiği F1 puanı sırasıyla %22 ve %27 daha fazla olmuştur. F1 puanı, yine yapı sınıfı için TerraScan yazılımından ise %2 daha fazla gelmiştir.

Tez kapsamında LiDAR nokta bulutlarını sınıflandırmak amacıyla oluşturulan derin sinir ağı U-net ağ mimarisini temel alan bir TESA'dır. Bir TESA ağının girdi verisi görüntü olduğu için ilk işlem adımı olarak bölüm 3.4.1'de bahsedilen teknik ile 3B LiDAR nokta bulutları 2B gri görüntüye dönüştürülmüştür. Bu adımda ki işlem süresi

nokta bulutunun kapladığı alan ve nokta yoğunluğuna göre değişmektedir. Görüntüye dönüşüm aşamasında seçilen parametreler ağın nihai sınıflandırma performansını direkt etkilediği için bunlar değiştirilebilir veya arttırılabilirler. Bölüm 4.2.1’de bu parametrelerden bahsedilmiştir.

TESA’nın eğitiminde seçilen SGD ve ADAM optimizasyon algoritmalarının eğitim sürelerine etkisi de tez kapsamında değerlendirilmiş ve sonuçlar Çizelge 6.1’de verilmiştir. ADAM algoritması, SGD algoritmasının daha hızlı hesap kabiliyetine sahip olması için zaman içerisinde çeşitli versiyonları türetilerek geliştirilmiştir. Tez çalışmasında da eğitim süreleri kıyaslandığında ADAM optimizasyon algoritmasının SGD’ye göre yaklaşık beş kat daha hızlı eğitimi tamamlayabildiği ortaya koyulmuştur.

Çizelge 6.1. Bergen 2018 veri seti için filtre boyutlarına göre eğitim süreleri

Filtre Boyutu	SGD	ADAM
3 x 3	818 sn.	159 sn.
5 x 5	1125 sn.	246 sn.
7 x 7	1838 sn.	364 sn.

6.2. Öneriler

Derin sinir ağlarının eğitimini doğrudan etkileyen unsurlar eğitim verisinin büyüklüğü ve sınıflandırma doğruluğudur. Hava LiDAR nokta bulutlarının araziden elde edilmesinde birçok farklı lazer sensörü kullanılmakla beraber toplanan bu verilerin sınıflandırılması hem operatörler tarafından hem de algoritmalar aracılığı ile gerçekleştirilerek iki aşama sonucunda tamamlanmaktadır. Sağlam ve güvenilir veri seti elde etmenin bir başka yolu ise yapay nokta bulutu üretebilen simülasyonlardır. Bunlardan birisi Winiwarter vd. tarafından geliştirilen HELIOS++ 3B topoğrafik lazer tarama simülasyonudur (Winiwarter vd., 2022). Uçak, İHA veya yersel lazer tarayıcılar aracılığıyla belirli bir maliyet ile üretilen LiDAR nokta bulutlarını araziye 3B haliyle hassas ve doğru şekilde üretebilen bir sanal lazer tarayıcı ile elde etmek araştırmacılar için hem maliyet hem de zaman açısından oldukça büyük bir kazanç olacaktır.

7. KAYNAKLAR

- ASPRS, Las Format., 2019. <https://www.asprs.org/committee-general/laser-las-file-format-exchange-activities.html> [Ziyaret Tarihi: 15 Aralık 2021].
- Axelsson, P. (1999). Processing of laser scanner data—algorithms and applications. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54, 138–147. doi:10.1016/S0924-2716(99)00008-8
- Axelsson, P. (2000). DEM Generation from Laser Scanner Data Using adaptive TIN Models. *International Archives of Photogrammetry and Remote Sensing*, 23(B4), 110–117. doi:10.1016/j.isprs.2005.10.005
- Badrinarayanan, V., Kendall, A. ve Cipolla, R. (2017). Segnet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE transactions on pattern analysis and machine intelligence*, 39(12), 2481–2495.
- Boulch, A., Guerry, J., Le Saux, B. ve Audebert, N. (2017). SnapNet: 3D point cloud semantic labeling with 2D deep segmentation networks. *Computers & Graphics*. doi:10.1016/j.cag.2017.11.010
- Brzank, A. ve Heipke, C. (2005). Classification of lidar data into water and land points in coastal areas. *ISPRS Archives – Volume XXXVI Part 3, 2006 Symposium of ISPRS Commission III Photogrammetric Computer Vision PCV '06*. http://www.isprs.org/proceedings/XXXVI/part3/singlepapers/P_19.pdf adresinden erişildi.
- Canaz, S. ve Habib, A. (2013). Photogrammetric features for the registration of terrestrial laser scans with minimum overlap. *Journal of Geodesy and Geoinformation*, 2(1), 1–8. doi:10.9733/jgg.250913.2
- Chen, Q., Gong, P., Baldocchi, D. ve Xie, G. (2007). Filtering Airborne Laser Scanning Data with Morphological Methods. *Photogrammetric Engineering & Remote Sensing*, 73(2), 175–185. doi:10.14358/PERS.73.2.175
- Chen, Y., Liu, G., Xu, Y., Pan, P. ve Xing, Y. (2021). PointNet++ network architecture with individual point level and global features on centroid for als point cloud classification. *Remote Sensing*, 13(3), 1–17. doi:10.3390/rs13030472
- Cheng, P., Hui, Z., Xia, Y., Ziggah, Y. Y., Hu, Y. ve Wu, J. (2019). An Improved Skewness Balancing Filtering Algorithm Based on Thin Plate Spline Interpolation. *Applied Sciences*, 9(1), 203. doi:10.3390/app9010203
- Evans, J. S. ve Hudak, A. T. (2007). A multiscale curvature algorithm for classifying discrete return LiDAR in forested environments. *IEEE Transactions on Geoscience and Remote Sensing*, 45(4), 1029–1038. doi:10.1109/TGRS.2006.890412
- Fernandez-Diaz, J. C. (2011). Lifting the Canopy Veil - Airborne LiDAR for Archeology of Forested Areas. *Imaging Notes*, 26(2).
- Habib, A. F. (2018). LiDAR Mapping Principles.
- Hinton, G. E., Osindero, S. ve Teh, Y. W. (2006). A Fast Learning Algorithm for Deep Belief Nets. *Neural computation*, 18(7), 1527–54. doi:10.1162/neco.2006.18.7.1527
- Hu, X. ve Yuan, Y. (2016). Deep-learning-based classification for DTM extraction from ALS point cloud. *Remote Sensing*, 8(9), 1–16. doi:10.3390/rs8090730
- Huang, R., Xu, Y., Hong, D., Yao, W., Ghamisi, P. ve Stilla, U. (2020). Deep point embedding for urban classification using ALS point clouds: A new perspective from local to global. *ISPRS Journal of Photogrammetry and Remote Sensing*, 163(February), 62–81. doi:10.1016/j.isprs.2020.02.020

- Hui, Z., Hu, Y., Yevenyo, Y. Z. ve Yu, X. (2016). An improved morphological algorithm for filtering airborne LiDAR point cloud based on multi-level kriging interpolation. *Remote Sensing*, 8(1). doi:10.3390/rs8010035
- İnik, Ö. ve Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi (GBAD)*, 6(3), 85–104.
- Jacobsen, K. ve Lohmann, P. (2003). Segmented Filtering of Laser Scanner Dsms. *WG III/3 3-D reconstruction from airborne laserscanner and InSAR data, XXXIV*, 6. http://www.isprs.org/proceedings/xxxiv/3-w13/papers/jacobsen_alsdd2003.pdf adresinden erişildi.
- Jing Huang ve Suya You. (2016). Point cloud labeling using 3D Convolutional Neural Network. *23rd International Conference on Pattern Recognition (ICPR)*, 2670–2675. doi:10.1109/ICPR.2016.7900038
- Karpathy, A. vd., 2015, *CS231n Convolutional Neural Networks for Visual Recognition* [online], <https://cs231n.github.io>, <https://cs231n.github.io/neural-networks-3/> [Ziyaret Tarihi: 22 Şubat 2021]
- Kızırcak, M. A., 2019, *Derin Öğrenme İçin Aktivasyon Fonksiyonlarının Karşılaştırılması* [online], Medium.com, <https://ayyucekizrak.medium.com/derin-ogrenme-icin-aktivasyon-fonksiyonlarinin-karsilastirilmasi-cee17fd1d9cd> [Ziyaret Tarihi: 15 Aralık 2021].
- Kraus, K. ve Pfeifer, N. (1998). Determination of terrain models in wooded areas with airborne laser scanner data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 53(4), 193–203. doi:10.1016/S0924-2716(98)00009-4
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, (25), 1097–1105. <https://dl.acm.org/doi/10.1145/3065386> adresinden erişildi.
- Kurt, F. (2018). *Evrişimli Sinir Ağlarında Hiper Parametrelerin Etkisinin İncelenmesi*. Hacettepe Üniversitesi Lisansüstü.
- Lawin, F. J., Danelljan, M., Tosteberg, P., Bhat, G., Khan, F. S. ve Felsberg, M. (2017). Deep projective 3D semantic segmentation. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 10424 LNCS, 95–107. doi:10.1007/978-3-319-64689-3_8
- Lecun, Y., Bengio, Y. ve Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. doi:10.1038/nature14539
- Li, B. ve Jan, C. V. (2017). 3D Fully Convolutional Network for Vehicle Detection in Point Cloud, 1513–1518.
- Liu, Y., Piramanayagam, S., Monteiro, S. T. ve Saber, E. (2017). Dense Semantic Labeling of Very-High-Resolution Aerial Imagery and LiDAR with Fully-Convolutional Neural Networks and Higher-Order CRFs. *2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)* içinde (C. 18, ss. 1561–1570). IEEE. doi:10.1109/CVPRW.2017.200
- Lohmann, P., Koch, A. ve Schaeffer, M. (2000). Approaches to the filtering of laser scanner data. *International Archives of Photogrammetry and Remote Sensing*, 33(B3/1; PART 3), 540–547.
- Long, J., Shelhamer, E. ve Darrell, T. (2015). Fully Convolutional Networks for Semantic Segmentation. *Computer Vision and Pattern Recognition*, 39(4), 3431–3440. <http://arxiv.org/abs/1411.4038> adresinden erişildi.
- Maturana, D. ve Scherer, S. (2015). VoxNet: A 3D Convolutional Neural Network for

- real-time object recognition. *2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)* içinde (C. 2, ss. 922–928). IEEE. doi:10.1109/IROS.2015.7353481
- McCulloch, W. S. ve Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133. doi:10.1007/BF02478259
- Meng, X., Wang, L., Silván-Cárdenas, J. L. ve Currit, N. (2009). A multi-directional ground filtering algorithm for airborne LIDAR. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(1), 117–124. doi:10.1016/j.isprsjprs.2008.09.001
- Qi, C. R., Su, H., Niessner, M., Dai, A., Yan, M. ve Guibas, L. J. (2016). Volumetric and Multi-View CNNs for Object Classification on 3D Data. doi:10.1109/CVPR.2016.609
- Qin, N., Hu, X., Dai, H. ve Hu, X. (2018). Deep fusion of multi-view and multimodal representation of ALS point cloud for 3D terrain scene recognition. *ISPRS Journal of Photogrammetry and Remote Sensing*, 143, 205–212. doi:10.1016/j.isprsjprs.2018.03.011
- Rizaldy, A., Persello, C., Gevaert, C. M. ve Oude Elberink, S. J. (2018). Fully Convolutional Networks For Ground Classification From Lidar Point Clouds. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, IV–2(June), 231–238. doi:10.5194/isprs-annals-IV-2-231-2018
- Rizaldy, Aldino, Persello, C., Gevaert, C., Oude Elberink, S. ve Vosselman, G. (2018). Ground and Multi-Class Classification of Airborne Laser Scanner Point Clouds Using Fully Convolutional Networks. *Remote Sensing*, 10(11), 1723. doi:10.3390/rs10111723
- Ronneberger, O., Fischer, P. ve Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9351, 234–241. doi:10.1007/978-3-319-24574-4_28
- Rumelhart, D. E. ve McClelland, J. L. (1986). *Parallel Distributed Processing. Readings in Cognitive Science: A Perspective from Psychology and Artificial Intelligence*. The MIT Press. doi:10.7551/mitpress/5236.001.0001
- Serna, A. ve Marcotegui, B. (2014). Detection, segmentation and classification of 3D urban objects using mathematical morphology and supervised learning. *ISPRS Journal of Photogrammetry and Remote Sensing*, 93, 243–255. doi:10.1016/j.isprsjprs.2014.03.015
- Sithole, G. ve Vosselman, G. (2004). Experimental comparison of filter algorithms for bare-Earth extraction from airborne laser scanning point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing*, 59(1–2), 85–101. doi:10.1016/j.isprsjprs.2004.05.004
- Sithole, G. ve Vosselman, G. (2005). Filtering of airborne laser scanner data based on segmented point clouds. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 36, 66–71.
- Su, H., Maji, S., Kalogerakis, E. ve Learned-Miller, E. (2015). Multi-view convolutional neural networks for 3D shape recognition. *Proceedings of the IEEE International Conference on Computer Vision, 2015 Inter*, 945–953. doi:10.1109/ICCV.2015.114
- Susaki, J. (2012). Adaptive slope filtering of airborne lidar data in urban areas for Digital Terrain Model (DTM) generation. *Remote Sensing*, 4(6), 1804–1819. doi:10.3390/rs4061804
- Tóvári, D. ve Pfeifer, N. (2005). Segmentation based robust interpolation - A

- new approach to laser data filtering. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 36, 79–84.
- Tran, T. H. G., Ressel, C. ve Pfeifer, N. (2018). Integrated change detection and classification in urban areas based on airborne laser scanning point clouds. *Sensors (Switzerland)*, 18(2). doi:10.3390/s18020448
- Uray, F. (2016). Hava Lidar Nokta Bulutu Verileri Filtreleme Algoritmalarının Geliştirilmesi Ve Performanslarının Karşılaştırılması. <https://tez.yok.gov.tr/UlusalTezMerkezi/TezGoster?key=cbOXH84ZayrLjc0tI-QXKkgwmORv36UAM6QJSB0M41vQ25hnsbIekjlkxvb3WeeA> adresinden erişildi.
- Varney, N., Asari, V. K. ve Graehling, Q. (2020). DALES: A large-scale aerial LiDAR data set for semantic segmentation. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops, 2020-June*, 717–726. doi:10.1109/CVPRW50498.2020.00101
- Vosselman, G. (2000). Slope based filtering of laser altimetry data. *International Archives of Photogrammetry and Remote Sensing, Vol. 33, Part B3/2*, 33(Part B3/2), 678–684. doi:10.1016/S0924-2716(98)00009-4
- Wallace, L., Lucieer, A., Malenovsky, Z., Turner, D. ve Vopěnka, P. (2016). Assessment of forest structure using two UAV techniques: A comparison of airborne laser scanning and structure from motion (SfM) point clouds. *Forests*, 7(3), 1–16. doi:10.3390/f7030062
- Wang, D., Wang, J., Scaioni, M. ve Si, Q. (2019). Coarse-to-Fine Classification of Road Infrastructure Elements from Mobile Point Clouds Using Symmetric Ensemble Point Network and Euclidean Cluster Extraction. *Sensors*, 20(1), 225. doi:10.3390/s20010225
- Wang, L., Xu, Y. ve Li, Y. (2018). A Voxel-Based 3D Building Detection Algorithm for Airborne LIDAR Point Clouds. *Journal of the Indian Society of Remote Sensing*, 47(February), 349–358. doi:10.1007/s12524-018-0893-9
- Wen, C., Yang, L., Li, X., Peng, L. ve Chi, T. (2020). Directionally constrained fully convolutional neural network for airborne LiDAR point cloud classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 162, 50–62. doi:10.1016/j.isprsjprs.2020.02.004
- Winiwarter, L. (2018). *Thesis-Classification of 3D Point Clouds using Deep Neural Networks*. Vienna University of Technology.
- Winiwarter, L., Esmoris Pena, A. M., Weiser, H., Anders, K., Martínez Sánchez, J., Searle, M. ve Höfle, B. (2022). Virtual laser scanning with HELIOS++: A novel take on ray tracing-based simulation of topographic full-waveform 3D laser scanning. *Remote Sensing of Environment*, 269(October 2021), 112772. doi:10.1016/j.rse.2021.112772
- Wu, Z., Song, S., Khosla, A., Yu, F., Zhang, L., Tang, X. ve Xiao, J. (2015). 3D ShapeNets: A deep representation for volumetric shapes. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 07-12-June*, 1912–1920. doi:10.1109/CVPR.2015.7298801
- Yousefhussien, M., Kelbe, D. J., Ientilucci, E. J. ve Salvaggio, C. (2018). A multi-scale fully convolutional network for semantic labeling of 3D point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing*, 143, 191–204. doi:10.1016/j.isprsjprs.2018.03.018
- Zhang, K., Chen, S. C., Whitman, D., Shyu, M. L., Yan, J. ve Zhang, C. (2003). A progressive morphological filter for removing nonground measurements from airborne LIDAR data. *IEEE Transactions on Geoscience and Remote Sensing*,

- 41(4 PART I), 872–882. doi:10.1109/TGRS.2003.810682
- Zhang, K. ve Whitman, D. (2005). Comparison of Three Algorithms for Filtering Airborne Lidar Data. *Photogrammetric Engineering Remote Sensing*, 71(3), 313–324. doi:10.14358/PERS.71.3.313
- Zhao, X., Guo, Q., Su, Y. ve Xue, B. (2016). Improved progressive TIN densification filtering algorithm for airborne LiDAR data in forested areas. *ISPRS Journal of Photogrammetry and Remote Sensing*, 117(July), 79–91. doi:10.1016/j.isprsjprs.2016.03.016

