

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

KİVİ MEYVESİNİN LİDAR NOKTA BULUTU KULLANILARAK DESTEK
VEKTÖR MAKİNELERİ ALGORİTMASI İLE OTOMATİK TESPİTİ

YÜKSEK LİSANS TEZİ

Gültekin ERBAŞ

NİSAN 2025
TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

**KİVİ MEYVESİNİN LİDAR NOKTA BULUTU KULLANILARAK DESTEK
VEKTÖR MAKİNELERİ ALGORİTMASI İLE OTOMATİK TESPİTİ**

Gültekin ERBAŞ

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde

“HARİTA YÜKSEK MÜHENDİSİ”

Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 11 / 03 / 2025

Tezin Savunma Tarihi : 11 / 04 / 2025

Tez Danışmanı : Doç. Dr. Mustafa DİHKAN

Trabzon 2025

ÖNSÖZ

“Kivi Meyvesinin Lidar Nokta Bulutu Kullanılarak Destek Vektör Makineleri Algoritması İle Otomatik Tespiti” isimli bu tez Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Harita Mühendisliği Anabilim Dalı, Yüksek Lisans Programı’nda hazırlanmıştır.

Tez danışmanlığımı üstlenerek çalışma süresince değerli fikirleri ve öngörleriyle çalışmama yön veren ve emeklerini esirgemeyen değerli danışman hocam Doç. Dr. Mustafa DİHKAN’ a teşekkürlerimi sunarım.

Tez çalışmam boyunca kıymetli bilgileri ve tecrübesi ile çalışmama ışık tutan, her türlü desteği sağlayan değerli hocam Prof. Dr. Sayın Fevzi KARSLI’ ya teşekkürü bir borç bilirim.

Tez çalışması süresince matematiksel modelin geliştirilmesi konusunda değerli fikir ve önerileri ile manevi desteğini esirgemeyen saygı değer arkadaşım Harita Yüksek Mühendisi Feride Seçil YILDIRIM’ a teşekkürlerimi sunarım. Ayrıca, Ordu Büyükşehir Belediyesi’nde görevli Harita Mühendisi Sayın Volkan CEYLAN’ a harcadığı mesai ve teknik destekleri ile tezime yaptıkları büyük katkılarından ötürü teşekkür ederim.

Son olarak, her kararında yanımda olan, daimî destekleri ve fedakârlıkları ile bugüne ulaşabilmemde en büyük paya sahip olan annem Güner ERBAŞ’ a, babam Hasan ERBAŞ’ a, kıymetli eşim Hatice ERBAŞ’ a ve biricik oğlum Asil ERBAŞ’ a teşekkür eder ve minnettarlığımı sunarım.

Hazırladığım bu tez çalışmasının bundan sonra yapılacak bilimsel çalışmalara katkı sağlamasını ümit ve temenni ederim.

Gültekin ERBAŞ

Trabzon 2025

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “Kivi Meyvesinin Lidar Nokta Bulutu Kullanılarak Destek Vektör Makineleri Algoritması İle Otomatik Tespiti” başlıklı bu çalışmayı baştan sona kadar danışmanım Doç. Dr. Mustafa DİHKAN’ ın sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 11/04/2025

Gültekin ERBAŞ

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET.....	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ.....	IX
TABLolar DİZİNİ.....	X
SEMBOLLER VE KISALTMALAR DİZİNİ	XI
1. GENEL BİLGİLER	1
1.1. Giriş.....	1
1.2. Çalışmanın Motivasyonu.....	2
1.3. Tezin Ana Hattı	3
1.4. Çalışmanın Amacı	3
1.5. Literatür Araştırması	4
1.6. Temel Kavramlar.....	8
1.6.1. Nokta Bulutu Üretim Teknikleri	8
1.6.2. Lidar Algılayıcıları ve Özellikleri.....	10
1.6.3. Lidar Türleri	12
1.6.4. Lidar Nokta Bulutu Sınıflandırması.....	15
1.6.5. Yüzey Normali Hesabı.....	18
1.6.6. Veri Ölçekleme	19
1.6.7. Makine Öğrenimi Yöntemleri	21
1.6.8. Destek Vektör Makineleri	23
1.6.9. Grid-Search Optimizasyon Yöntemi.....	29
1.6.10. Doğruluk Değerlendirmesi.....	30
2. YAPILAN ÇALIŞMALAR.....	32
2.1. Çalışma Alanı	34
2.1.1. Veri Seti	35
2.1.2. Veri Seti Ön Hazırlık Aşaması.....	38
2.2. Destek Vektör Makinesi Eğitimi.....	42

2.3. Eğitilen Destek Vektör Makinesinin Testi	44
3. BULGULAR VE TARTIŞMA	46
3.1. Destek Vektör Makinesi ile Kivi Meyvesinin Tespitine Yönelik Sonuçların Değerlendirilmesi	46
4. SONUÇLAR	52
5. ÖNERİLER	53
6. KAYNAKLAR	54
ÖZGEÇMİŞ	



Yüksek Lisans Tezi

ÖZET

KİVİ MEYVESİNİN LİDAR NOKTA BULUTU KULLANILARAK DESTEK VEKTÖR MAKİNELERİ ALGORİTMASI İLE OTOMATİK TESPİTİ

Gültekin ERBAŞ

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Harita Mühendisliği Anabilim Dalı
Danışman: Doç. Dr. Mustafa DİHKAN
2025, 57 Sayfa

Tarımda otomasyonun gelişmesiyle birlikte meyvelerin sağlık durumunun gözlemlenmesi, rekolte tahmini ve otomatik bir şekilde hasat edilebilmesi gibi tarımsal uygulamaların yapılabilmesi için meyvelerin mekânsal konumlarının belirlenmesi hassas tarım açısından büyük önem taşımaktadır. Tez çalışmasında, bir kivi ağacına ait LiDAR nokta bulutu verileri kullanılarak, Destek Vektör Makinesi (DVM) algoritması ile kivi ağacına ait kivi-kivi dışı noktalarının segmentasyonu hedeflenmiş ve tarım sektöründe rekolte tahminine katkıda bulunmak için makine öğrenme yöntemlerinden faydalanılması amaçlanmıştır. LiDAR verisinden elde edilen kırmızı, yeşil ve mavi renk değerleri bilgileri ve her nokta için X, Y, Z yönlerinde hesaplanan yüzey normal vektörü değerleri DVM' ye girdi veri olarak sunulmuş ve sınıflandırma için eğitim işlemi gerçekleştirilmiştir. Çalışmada, yersel LİDAR tarayıcısı ile taranmış 1 adet kivi ağacına ait nokta bulutu kullanılmıştır. Nokta bulutu verisi 6 parçaya bölünmüş ve 2 tanesi DVM eğitim, 4 tanesi ise test işlemi için kullanılmıştır. DVM eğitiminde, ilgili veriye en uygun ayar parametrelerinin tespiti için Grid Search Optimizasyon algoritmasından faydalanılmış ve eğitim işlemi gerçekleştirilmiştir. Eğitim işlemi için doğruluk değerleri; Genel Doğruluk, Kesinlik, Geri Çağırma, F1-Skor ve Birleşimlerin Kesişimi doğruluk metrikleri için sırasıyla 0.95, 0.88, 0.86, 0.87 ve 0.79 olarak hesaplanmıştır. Test işlemi, kivi ağacına ait 4 parça nokta bulutu ile gerçekleştirilmiş olup, aynı doğruluk metrikleri için sırasıyla ortalama doğruluk değerleri; 0.95, 0.80, 0.86, 0.82 ve 0.73 olmak üzere hesaplanmıştır.

Anahtar Kelimeler: Destek Vektör Makinesi, Nokta Bulutu, Meyve Tespiti, Hassas Tarım

MSc. Thesis

SUMMARY

AUTOMATIC DETECTION OF KIWI FRUIT WITH SUPPORT VECTOR MACHINES USING LIDAR POINT CLOUD

Gültekin ERBAŞ

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Geomatics Engineering Graduate Program
Supervisor: Assoc. Prof. Mustafa DİHKAN
2025, 57 Pages

With the advancement of automation in agriculture, determining the spatial locations of fruits has become crucial for precision agriculture in order to enable agricultural applications such as monitoring fruit health, yield estimation, and automated harvesting. In this thesis study, LiDAR point cloud data of kiwi trees were used to segment kiwi and non-kiwi points on the tree using the Support Vector Machine (SVM) algorithm. The study aimed to contribute to yield estimation in the agricultural sector by utilizing machine learning methods. The red, green, and blue color values obtained from the LiDAR data, along with the surface normal vector values calculated in the X, Y, and Z directions for each point, were used as input data for the SVM, and a training process was conducted for classification. In this study, the point cloud of a single kiwi tree scanned with a terrestrial LiDAR scanner was used. The point cloud data was divided into six parts, with two used for SVM training and four for testing. During the SVM training process, the Grid Search Optimization algorithm was utilized to determine the most suitable hyperparameters for the given data, and the training was performed accordingly. The accuracy values for the training process were calculated as 0.95 for Overall Accuracy, 0.88 for Precision, 0.86 for Recall, 0.87 for F1-Score, and 0.79 for Intersection over Union (IoU). The testing process was conducted using four parts of the kiwi tree's point cloud, and the average accuracy values for the same metrics were calculated as 0.95, 0.80, 0.86, 0.82, and 0.73, respectively.

Key Words: Support Vector Machine, Point Cloud, Fruit Detection, Precision Agriculture

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Hava LİDAR sisteminin çalışma prensibi	12
Şekil 2. Yersel lazer tarayıcı	13
Şekil 3. Yersel lazer tarayıcı koordinat sistemi	14
Şekil 4. En yaygın kullanılan yapay zekâ yöntemlerinin birbirleriyle ilişkisi	21
Şekil 5. Makine öğrenimi çalışma prensibi	22
Şekil 6. Makine öğrenmesinin alt dalları içerisinde destek vektör makinesinin yeri.....	22
Şekil 7. Tahmin edilecek iki sınıfın her birine karşılık gelen destek vektörlerini maksimum düzeyde ayıran hiper düzlemin gösterimi	25
Şekil 8. Sert ve yumuşak marjin gösterimleri	26
Şekil 9. Eğri hiper düzlem gösterimi.....	27
Şekil 10. Çalışma iş akış şeması.....	33
Şekil 11. Çalışma alanı uydu görüntüsü.....	35
Şekil 12. Çalışmada kullanılan yersel lazer tarayıcı ve hedef noktası	37
Şekil 13. Kivi ağacına ait nokta bulutu	38
Şekil 14. Etiketleme işlemi.....	39
Şekil 15. Etiketleme esnasında kontrolsüz seçilen kivi dışı noktalar.....	40
Şekil 16. Etiketlenen nokta bulutu verisinin bölünmesi.....	41
Şekil 17. Eğitim işlemine ait nokta bulutu, etiket ve tahmin sonuçları.....	44
Şekil 18. 1 numaralı parça için kivi-kivi dışı noktaların tahmini.....	47
Şekil 19. 2 numaralı parça için kivi-kivi dışı noktaların tahmini.....	48
Şekil 20. 4 numaralı parça için kivi-kivi dışı noktaların tahmini.....	49
Şekil 21. 5 numaralı parça için kivi-kivi dışı noktaların tahmini.....	50

TABLÖLAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Faro Focus 3D X 130 teknik özellikleri	36
Tablo 2. Kivi ağacına ait nokta bulutu parçalarının içerdikleri nokta sayıları	42
Tablo 3. Grid Search optimizasyon algoritmasında kullanılan hiperparametreler	43
Tablo 4. Destek vektör makinesi eğitimi doğruluk değerleri	44
Tablo 5. Test verileri için destek vektör makinesi kivi-kivi dışı nokta tahmini doğruluk değerleri	46



SEMBOLLER VE KISALTMALAR DİZİNİ

LiDAR	: Işık Tespiti ve Ölçümü (Light Detection and Ranging)
DVM	: Destek Vektör Makinesi
2B	: İki Boyutlu
3B	: Üç Boyutlu
RGB	: Kırmızı-Yeşil-Mavi
HSV	: Ton, Doygunluk, Değer
FPFH	: Hızlı nokta Özellik Histogramı
KNN	: k-En Yakın Komşuluk
RBF	: Radyal Taban Fonksiyonu
SRC	: Seyrek Temsili Sınıflandırıcı
YSA	: Yapay Sinir Ağı
GLCM	: Gri Seviye- Eş Oluşum Matrisi
PCA	: Temel Bileşen Analizi
LDA	: Lineer Ayrım Analizi
BPNN	: Geri Yayılım Sinir Ağı
CBS	: Coğrafi Bilgi Sistemleri
RGB-D	: Kırmızı-Yeşil-Mavi-Derinlik
VR	: Sanal Gerçeklik
AR	: Artırılmış Gerçeklik
ToF	: Uçuş Süresi
GPS	: Global Konum Belirleme Sistemi (Global Positioning System)
IMU	: Atalet Ölçü Birimi (Inertial Measurement Unit)
İHA	: İnsansız Hava Aracı
YLT	: Yersel Lazer Tarayıcı
KSA	: Konvolüsyonel Sinir Ağları
RSA	: Rekürsif Sinir Ağları
OCR	: Optik Karakter Tanıma
ERM	: Ampirik Risk Minimizasyonu
KSA	: Yapısal Risk Minimizasyonu
R^2	: Korelasyon Katsayısı

μ : Sütun Ortalaması
 σ : Sütun Standart Sapması



1. GENEL BİLGİLER

1.1. Giriş

Tarım sektörü, dünya genelinde artan nüfus ve azalan doğal kaynaklar nedeniyle daha verimli üretim tekniklerine ihtiyaç duymakta olup, otomasyon, yapay zekâ ve ileri algılama teknolojilerinin hızla gelişmesiyle birlikte önemli bir dönüşüm sürecinden geçmektedir. Hassas tarım teknolojileri, tarımsal üretkenliği artırmak, kaynak kullanımını optimize etmek ve mahsul yönetimini daha verimli hale getirmek amacıyla giderek daha yaygın bir şekilde kullanılmaktadır. Bu bağlamda hassas tarım uygulamaları, bahsi geçen gereksinimleri karşılamak amacıyla çeşitli uzaktan algılama ve yapay zekâ yöntemlerini kullanarak tarımsal süreçlerin otomasyonunu sağlamaktadır. Tarım teknolojilerindeki gelişmeler, meyve tespiti ve verim tahmini gibi uygulamalarda LiDAR (Light Detection and Ranging) sistemlerinin kullanımını yaygınlaştırmıştır. Son yıllarda, LiDAR teknolojisi, tarımsal ürünlerin belirlenmesi, sınıflandırılması ve rekolte tahmini gibi alanlarda önemli bir yer edinmiştir. LiDAR, yüksek hassasiyetle üç boyutlu nokta bulutu verisi üreterek bitki örtüsünün, meyvelerin ve ağaç yapılarının detaylı bir şekilde modellenmesine olanak tanır.

Geleneksel görüntü işleme yöntemleri, ışık koşullarına duyarlı olup doğruluk açısından sınırlamalar içerirken, LiDAR tabanlı tespit sistemleri daha yüksek güvenilirlik sunmaktadır. LiDAR sensörlerinden elde edilen nokta bulutu verileri, tarımsal alanlarda detaylı analizler gerçekleştirilmesine olanak tanımaktadır. LiDAR teknolojisi, yüksek çözünürlüklü 3B veriler sunarak meyve tespiti, ağaç sağlığı analizi ve tarımsal planlama süreçlerinde önemli avantajlar sağlamaktadır. Bu bağlamda, LiDAR teknolojisi, yüksek hassasiyetli üç boyutlu görüntüleme kabiliyeti ile bitki ve meyve tespitinde önemli bir yer edinmiştir.

Meyve ağaçlarından elde edilen LiDAR nokta bulutları, geleneksel görüntüleme tekniklerine kıyasla daha doğru ve ayrıntılı bilgi sunarak tarımsal analizlerde avantaj sağlamaktadır. Ancak, bu verinin işlenmesi ve meyve tespiti gibi görevler için klasik, derin öğrenme ve makine öğrenmesi gibi yöntemlere ihtiyaç duyulmaktadır.

Bu tez çalışmasında, LiDAR nokta bulutu verileri kullanılarak kivi otomatik tespiti için destek vektör makineleri (DVM) yönteminden faydalanılmış ve kivi meyvesinin otomatik tespiti amaçlanmıştır.

Kivi (*Actinidia deliciosa*), ticari açıdan önemli meyve türlerinden biri olup, özellikle hassas tarım uygulamalarında erken tespit ve hasat planlaması açısından büyük bir öneme sahiptir. Ancak, kivinin ağaçtaki dağılımı, yaprak örtüsünün yoğunluğu ve ışık yansımaları gibi faktörler, geleneksel görüntüleme yöntemleriyle tespitini zorlaştırmaktadır. Bu sebeple bu tez çalışmasında LiDAR nokta bulutu verileri kullanılarak kivinin otomatik tespiti için destek vektör makinelerinin (DVM) etkinliği araştırılmıştır. Çalışma, LiDAR nokta bulutlarından özellik çıkarımı, DVM tabanlı sınıflandırma süreçleri ve performans analizleri üzerine odaklanmaktadır.

Destek Vektör Makineleri, özellikle yüksek boyutlu verilerde etkili bir sınıflandırma ve regresyon algoritması olarak öne çıkmaktadır (Cortes & Vapnik, 1995). DVM, LiDAR nokta bulutlarından elde edilen yapısal ve spektral özellikleri değerlendirerek meyve tespiti ve ayrıştırılması için güçlü bir model sunmaktadır.

Çalışma, LiDAR nokta bulutlarından özellik çıkarımı, DVM tabanlı sınıflandırma süreçleri ve performans analizleri üzerine odaklanmaktadır. Yersel lazer tarayıcı cihazla taranmış 1 adet kivi ağacına ait nokta bulutu kullanılmıştır. Elde edilen nokta bulutu verisinden zemin noktaları ve gürültü noktaları elimine edilmesi gerekmektedir. Zemin ve gürültü noktaları temizlenen veri MATLAB yazılımının “Lidar Labeler” uygulamasında etiketlenerek referans veriseti oluşturulmuştur. Ardından kivi ağacına ait nokta bulutu 6 parçaya ayrılarak bunlardan 2 tanesi DVM eğitimi, 4 tanesi ise test işlemi için kullanılmıştır. DVM eğitimi işleminde ilgili veriye en uygun hiperparametrelerin tespiti için Grid Search optimizasyon algoritmasından faydalanılmış ve kivi ağacına ait 2 adet nokta bulutu parçası ile eğitim işlemi gerçekleştirilmiştir. Geri kalan 4 adet kivi ağacı parçası üzerinden de kivi tahmini işlemi gerçekleştirilmiştir.

1.2. Çalışmanın Motivasyonu

Tarımda otomasyonun artan önemi, özellikle meyve tespiti ile rekolte tahmini, hasat süreçlerinde verimliliği artırma ihtiyacı, bu çalışmanın temel motivasyonunu oluşturmuştur. Bu çalışmanın motivasyonu, tarımsal üretimde otomasyonu artırmak ve hassas tarım uygulamalarını geliştirmektir. Günümüzde, tarımsal üretimde verimliliği artırmak için hassas tarım teknolojileri giderek daha fazla kullanılmaktadır. Kivi gibi tırmanıcı bitkilerde meyve tespiti, geleneksel yöntemlerle oldukça zahmetli ve zaman alıcıdır. İnsan gözüyle yapılan meyve sayımı hatalara açık olup, iş gücü maliyetlerini

artırmaktadır. Literatürde, LiDAR ve Destek Vektör Makineleri tekniklerinin meyve tespitine yönelik çalışmaları bulunsa da, özellikle kivi için LiDAR verisi kullanılarak sınıflandırılması üzerine yapılan herhangi bir araştırma bulunmamaktadır. Bu bağlamda, çalışma hem teorik hem de uygulamalı olarak özgün değer taşımaktadır. Bu çalışma ile literatüre önemli bir katkı sağlanması amaçlanmaktadır.

1.3. Tezin Ana Hattı

Giriş kısmında yapılan çalışma hakkında genel ve ön bilgiler verildikten sonra çalışmanın motivasyonundan ve çalışmanın amacından bahsedilmiştir. Literatür araştırması bölümünde, tez çalışmasının konusuyla alakalı olarak ağaçlara ait nokta bulutlarından meyvelerin otomatik tespiti ile ilgili yapılan araştırma ve çalışmalara yer verilmiştir.

Temel kavramlar bölümünde; nokta bulutu üretim teknikleri, LiDAR algılayıcıları ve özellikleri, LiDAR nokta bulutu sınıflandırması, LiDAR türlerinden kısaca bahsedilmiştir. Ardından tez çalışmasında kullanılan yöntem ve kavramlar olan; yüzey normali matematiksel hesabı, veri ölçekleme, makine öğrenmesi yöntemleri, Destek Vektör Makinesi, Grid Search optimizasyon yöntemi ve yapılan uygulamanın performansını analiz etmek için kullanılan doğruluk metriklerinin anlatımı yapılmıştır. Yapılan çalışmalar bölümünde veri seti ve çalışma alanı, veri seti ön hazırlık aşaması, Destek Vektör Makinesi eğitimi ve eğitilen Destek Vektör Makinesinin testi işlemleri detaylı bir biçimde anlatılmıştır. Bulgular ve Tartışma bölümünde ise test verileri üzerinde eğitilen Destek Vektör Makinesinin kivi-kivi dışı olmak üzere gerçekleştirdiği segmentasyon sonuçları görsel ve doğruluk analizi metrikleri ile sayısal olarak sunulmuştur. Ayrıca gerçekleştirilen yöntemde bulunan negatif ve pozitif özellikler belirtilmiştir. Son olarak Sonuçlar ve Öneriler bölümlerinde ise yapılan çalışma kısaca özetlenerek, literatürde meyve tespitine yönelik yapılan çalışmalardan farklarından, özgün yönlerinden bahsedilmiştir. Bununla birlikte gerçekleştirilen tez çalışmasında karşılaşılan ve doğruluk oranlarını negatif bir biçimde etkilediği düşünülen durumlar açıklanarak bu durumlara çeşitli öneriler sunulmuştur.

1.4. Çalışmanın Amacı

Yapılan çalışmanın temel amacı; kivi meyvesinin LiDAR nokta bulutu verileri kullanılarak Destek Vektör Makinesi ile otomatik tespit edilmesini sağlamaktır. Tarımsal üretimde rekolte tahmini, işgücü maliyetlerini düşürmek ve hassas tarım tekniklerini

geliştirmek için uzaktan algılama teknolojilerinin kullanımı giderek daha fazla önem kazanmaktadır. Bu bağlamda son yıllarda, LiDAR teknolojisi, ilgili alanlarda önemli bir yer edinmiştir. LiDAR teknolojisi, yüksek doğrulukta üç boyutlu (3B) veriler sağlayarak bitkilerin, meyvelerin ve çevresel faktörlerin detaylı bir şekilde modellenmesine olanak tanımaktadır.

Bu çalışma, kivi ağacından elde edilen nokta bulutu verilerinin işlenmesi, özellik çıkarımı ve sınıflandırma süreçlerine odaklanmaktadır. Özellikle, LiDAR tarafından üretilen yoğun nokta bulutu verileri kullanılarak kivilerin ağaç yaprakları, dallar ve diğer çevresel unsurlar arasından ayrıştırılması hedeflenmektedir. Bu süreçte, nokta bulutu özellikleri (yükseklik, yoğunluk, eğrilik, yansıma değeri vb.) analiz edilerek DVM algoritması ile kivi meyvesinin otomatik olarak tespit edilmesi amaçlanmaktadır. Önerilen yöntem, kivi meyvelerinin yaprak ve dallardan ayrıştırılmasını sağlayarak hassas tarım uygulamalarına katkı sunmayı hedeflemektedir. DVM algoritması, nesne sınıflandırma ve segmentasyon için kullanılarak kivi meyvelerinin ağaç üzerindeki konumlarını belirlemek üzere eğitilmiştir. Çalışma, nokta bulutu işleme teknikleri ve DVM sınıflandırmasının entegrasyonunu içermektedir.

Çalışmanın bir diğer hedefi ise, önerilen yöntem ile farklı gelişim evrelerindeki kivilerin tespit doğruluğunu değerlendirmek ve geleneksel görüntü işleme yöntemlerine kıyasla LiDAR tabanlı yaklaşımların avantajlarını ortaya koymaktır. Çalışma kapsamında, saha verileri kullanılarak model eğitimi ve test aşamaları gerçekleştirilmiş, farklı parametre ayarları ve veri işleme stratejileri ile sistemin başarımı optimize edilmiştir. Elde edilen sonuçlar doğrultusunda, meyve tespitinin otomatikleştirilmesi için LiDAR nokta bulutu kullanılarak Destek Vektör Makinesi algoritması tabanlı yapay zekâ yönteminin tarım sektöründe uygulanabilirliği değerlendirilmiş ve gelecekteki hassas tarım uygulamalarına yönelik öneriler sunulmuştur. Böylece, tarımsal otomasyon sistemlerinin geliştirilmesine katkı sağlanarak, kivi hasadında daha hızlı, verimli ve düşük maliyetli bir çözüm sunulması hedeflenmektedir.

1.5. Literatür Araştırması

Tarım ve gıda endüstrisinde, meyvelerin doğru sınıflandırılması kârlılığı artırmak için çok önemlidir. Günümüzün teknolojik çağında, insan gücünü minimuma düşürecek otomatik veya robotik hasat teknikleri geliştirmek gereklidir. Bu da, hasat robotunun

robotik görüş sisteminde ürünlerin tanınması ve konumunun belirlenmesiyle mümkün olmaktadır. Böyle bir sınıflandırma için otomatik bir meyve sınıflandırma sistemine ihtiyaç vardır. Bu ihtiyacın giderilmesine yönelik literatürde yapılmış çalışmalar aşağıda özetlenerek listelenmiştir.

Wang vd. (2009), çalışmalarında elma hasat robotunun robot görüş sisteminde, elmayı tanımak ve konumunu belirlemek amacıyla yüksek hata oranı, aşırı hesaplama ve zaman kaybı gibi tanıma sorunlarını çözmek için yeni bir tanıma yöntemi olan Destek Vektör Makinesi uygulanarak tanıma doğruluğu ve verimliliği artırmayı hedeflemiştir. İlk olarak, elma meyvesinin renkli görüntülerindeki gürültüyü gidermek için vektör medyan filtresi kullanılmıştır. İkinci olarak, bölge büyütme yöntemi ve renk özelliklerine dayalı görüntü segmentasyonu gerçekleştirilmiştir. Daha sonra, renkli görüntünün renk ve şekil özellikleri çıkarılmış ve elma meyvesinin tanınması için DVM sınıflandırma yöntemi uygulanmıştır. Deneysel sonuçlar, destek vektör makinesinin sınıflandırma performansının sinir ağlarından daha iyi olduğunu göstermektedir. Renk ve şekil özelliklerine dayalı DVM ile elma meyvesinin tanınma oranı, yalnızca renk veya yalnızca şekil özelliklerini kullanmaya göre daha yüksek bulunmuştur.

Ge vd. (2021), çalışmalarında, Renk ve Şekil Çoklu-Özellik Füzyonu ve Destek Vektör Makinesi (DVM) tabanlı bir yöntem kullanarak 3B elma ağacı organlarının sınıflandırılması ve verim tahmini önermişlerdir. Önerilen yöntem, erken ve geç olgunluk dönemlerindeki bodur ve yoğun dikilmiş elma ağaçları için tasarlanmıştır. Öncelikle RGB (Kırmızı, Yeşil, Mavi), HSV (Ton, Doygunluk, Değer), Eğrilikler, Hızlı Nokta Özellik Histogramı (FPFH) ve Spin Görüntü özelliklerinden oluşan 196 boyutlu özellik vektörleri çıkarılmıştır. Daha sonra, doğrusal çekirdek fonksiyonuna sahip DVM eğitilmiş ve ardından eğitilmiş DVM, elma ağacı organlarını sınıflandırmak için kullanılmıştır. Sınıflandırılmış elma ağacı organlarının düzgünleştirilmesi için konum ağırlıklı düzgünleştirme algoritması uygulanmıştır. Daha sonra, birleştirici hiyerarşik kümeleme algoritması kullanılarak tekil elma meyveleri tanımlanmış ve verim tahmini yapılmıştır. Aynı eğitim ve test seti üzerinde yapılan deneysel sonuçlar, doğrusal çekirdek fonksiyonuna sahip DVM' nin, KNN (k- en yakın komşuluk) algoritması ve Ensemble algoritmasından daha iyi performans gösterdiğini ortaya koymuştur. Önerilen yöntemin verim tahmini için elde ettiği Duyarlılık (Recall), Kesinlik (Precision) ve F1 Skoru sırasıyla %93,75, %96,15 ve %94,93 olarak hesaplanmıştır.

Zhang vd. (2020), çalışmalarında, çoklu özellik füzyonu ve Destek Vektör Makinesi (DVM) tabanlı bir nar ağacı organ sınıflandırma ve meyve sayma yöntemi önermişlerdir. Yöntemlerinde; Nar ağaçlarının üç boyutlu nokta bulutları bir RGB-D kamera ile elde edilmiştir. Üç boyutlu nokta bulutları ön işleme tabi tutulduktan sonra DVM sınıflandırıcısını eğitmek için renk ve şekil özellikleri çıkarılmıştır. Sınıflandırma doğruluğunu artırmak için ağırlıklı Öklid mesafesine dayalı K-en yakın komşu (KNN) düzeltmesi uygulanmıştır. Nar meyvelerini saymak için birleşmeli-bölmeli hiyerarşik kümeleme yöntemi kullanılmıştır. Deney sonuçları, renk ve şekil özelliklerine dayalı DVM sınıflandırıcısının meyve için 0,75 ve meyve olmayan için 0,99 doğruluğa sahip olduğunu göstermiştir. Birleşmeli-bölmeli hiyerarşik kümeleme tabanlı meyve sayımının duyarlılığı %87,74 ve doğruluğu %78,15 olarak bulunmuştur. Sonuçları, önerilen yöntemin doğal ortamda nar ağaçlarındaki organ sınıflandırması ve verim tahmini için etkili ve uygulanabilir olduğunu göstermektedir.

Dorj vd. (2017), çalışmalarının amacını, görüntü işleme tekniklerini kullanarak ağaç üzerindeki turunçgilleri tespit edip sayabilen, verimi tahmin eden ve çeşitli yöntemlerle elde edilen verim tahmin sonuçlarını karşılaştıran etkili, basit ve uygun bir bilgisayarlı görüş algoritması geliştirmek olarak belirtmişlerdir. Yeni turunçgil tanıma ve sayma algoritması, turunçgil verimini tahmin etmek için renk özelliklerini (veya şemalarını) kullanmış ve ilgili modeller erken verim tahmini sağlamak amacıyla geliştirilmiştir. Turunçgil görüntüleri, Güney Kore'nin Jeju bölgesinde gündüz saatlerinde çekilmiş ve turunçgil tanıma ve sayma algoritması, 21 ağaçtan toplanan 84 görüntü üzerinde test edilmiştir.

Turunçgil sayma algoritması sırasıyla,

- RGB görüntüsünün HSV renk uzayına dönüştürülmesi,
- Eşikleme,
- Turuncu renk tespiti,
- Gürültü giderme,
- Watershed segmentasyonu,
- Sayma işlemi.

Adımlarından oluşmaktadır. Turunçgil meyvelerinde otomatik watershed segmentasyonu ile iyi sonuç elde etmek amacıyla mesafe dönüşümü ve işaretçi kontrollü watershed algoritmaları değerlendirilmiştir. Turunçgil sayma algoritması ile insan gözlemiyle yapılan sayım arasında 0.93 korelasyon katsayısı (R^2) elde edilmiştir. Önerilen algoritma, tekil turunçgil ağaçlarının verimini erken tahmin etmek için büyük bir potansiyel göstermiş ve diğer meyve mahsullerine uyarlanma olasılığı sunmuştur.

Bhargava ve Bansal (2019), çalışmalarında meyvelerin türlerini ayırt etmek ve kalitesini daha hassas bir şekilde değerlendirmek amacıyla, dört farklı meyve türünü sınıflandıran ve meyvenin kalitesine dayalı olarak derecesini analiz eden bir sistem sunmaktadır. Öncelikle, algoritma görüntülerin kırmızı, yeşil ve mavi (RGB) değerlerini çıkarır ve ardından görüntülerin arka planı, böl-ve-birleştir algoritması kullanılarak kaldırılır. Sonrasında, renk, istatistiksel, dokusal ve geometrik olmak üzere toplamda 30 özellik çıkarılır. Meyve türünü ayırt etmek için yalnızca 12 geometrik özellik kullanılırken, diğer özellikler meyvenin kalite değerlendirmesinde kullanılmaktadır. Ayrıca, meyve kalitesini sınıflandırmak için dört farklı sınıflandırıcı kullanılmıştır: k-en yakın komşu (k-NN), destek vektör makinesi (DVM), seyrek temsili sınıflandırıcı (SRC) ve yapay sinir ağı (YSA). Sınıflandırıcılar, dört farklı meyve veritabanı üzerinde test edilmiştir:

- İlk veri kümesi, 4359 elma görüntüsü içermektedir ve bunların 2342'si çeşitli kusurlar içermektedir.
- İkinci veri kümesi, 918 avokado görüntüsünden oluşmakta olup, bunların 491'i çeşitli kusurlara sahiptir.
- Üçüncü veri kümesi, 3805 muz görüntüsünü içermekte olup, bunların 2224'ü çeşitli kusurlara sahiptir.
- Dördüncü veri kümesi ise 3050 portakal görüntüsünden oluşmakta olup, bunların 1590'ı çeşitli kusurlara sahiptir.

Sistemin performansı, k-katlı çapraz doğrulama yöntemi kullanılarak farklı k değerleri için doğrulanmıştır. Destek vektör makinesinin kalite değerlendirmede daha etkili olduğu görülmüştür.

Nosseir (2019), dört farklı meyve türünü (elma, mango, muz ve çilek) birbirinden ayırt eden ve çürümüş meyveleri tazelerinden ayırt eden bir sistem sunmaktadır. Kullanılan algoritmalar, meyve görüntülerinin renk ve doku özelliklerine dayanmaktadır. Algoritmalar, RGB değerlerini ve Gri Seviye Eş-Oluşum Matrisi (GLCM) değerlerinin birinci ve ikinci dereceden istatistiksel özelliklerini çıkarmaktadır. Meyve türlerini birbirinden ayırmak için İnce, Orta, Kalın, Kosinüs, Kübik ve Ağırlıklı K-En Yakın Komşu algoritmaları uygulanmıştır. Bu algoritmaların doğruluk oranları sırasıyla %96,3, %93,8, %25, %83,8, %90 ve %95 olarak elde edilmiştir. Bu adımlar, mevsimlik meyveler olan muz, elma ve çilekten oluşan ve mobil telefon ile çekilmiş 46 resim üzerinde test edilmiştir. Tüm meyve türleri doğru bir şekilde sınıflandırılmıştır. Çürümüş meyveleri taze olanlardan ayırmak için doğrusal ve ikinci dereceden Destek Vektör Makinesi (DVM) algoritmaları kullanılmıştır. Sınıflandırma, her bir meyve görüntüsünün renk segmentasyonu ve doku özellikleri temel

alınarak yapılmıştır. Doğrusal DVM' nin doğruluk oranı %96, ikinci dereceden DVM' nin doğruluk oranı ise %98 olarak elde edilmiştir.

Yang vd. (2019), çalışmalarında, kayısı çeşitlerini şekil özelliklerine dayalı makine öğrenmesi ile sınıflandırmanın potansiyelini araştırmayı amaçlamıştır. Dört farklı kayısı çeşidinin şekil özellikleri analiz edilmiştir. On üç şekil parametresi, farklı kayısı çeşitleri arasındaki şekil özelliklerinin farklılıklarını ve korelasyonlarını belirlemek için tek yönlü varyans analizi ve Pearson korelasyon analizi kullanılarak incelenmiştir. Özellikler arasındaki anlamlı ilişkilerin sınıflandırma üzerindeki etkisini azaltmak amacıyla, ardışık yansıtma algoritması ve temel bileşen analizi (PCA) kullanılarak özellik sayısı azaltılmıştır. Ayrıca, kayısı çeşitlerinin belirlenmesi için karar ağacı, k-en yakın komşu (K-NN), Naves Bayes, lineer ayırım analizi (LDA), destek vektör makinesi (DVM) ve geri yayılım sinir ağı (BPNN) olmak üzere altı farklı makine öğrenmesi yöntemi kullanılmıştır. Elde edilen sonuçlar, dört kayısı çeşidinin şekil özellikleri açısından önemli farklılıklar gösterdiğini ortaya koymuştur. Her bir özellik, diğerleriyle belirli düzeyde bir korelasyona sahiptir. Makine öğrenmesi ile yapılan sınıflandırma açısından, ardışık yansıtma algoritması ile destek vektör makinesi (DVM) en iyi sonucu vermiş ve test setinde %90.7 doğruluk oranına ulaşmıştır.

Literatür araştırmalı incelendiğinde kivi meyvesinin ağaç üzerindeki tespitine/segmentasyonuna yönelik yapılan herhangi bir çalışma bulunmadığı gözlemlenmiştir. Yapılan çalışmalar genellikle farklı meyve türlerinin makineye öğretilerek sınıflandırılmasına, çürük ve sağlam meyvelerin tanınmasına yöneliktir. Bu tez çalışmasında, literatürdeki çalışmalardan farklı olarak arka planda bulunan dal ve kurumuş yapraklar ile çok benzer renk değerlerine sahip olan kivi meyvesinin belirlenmesi konusuna odaklanılmıştır. Düzensiz bir veri yapısı olan nokta bulutlarından RGB değerlerinin alınması ve her bir noktanın yüzey normal vektörlerinin hesabı işlemleri gerçekleştirilerek DVM eğitilmiş ve segmentasyon sonuçları incelenmiştir.

1.6. Temel Kavramlar

1.6.1. Nokta Bulutu Üretim Teknikleri

Nokta bulutu, 3B nesnelerin uzamsal X,Y,Z koordinatlarından oluşan $N \times 3$ matrisler ve yüzey normları kullanılarak $N \times 6$ matrisler şeklinde basit bir temsili olup, en önemli 3B nesne gösterimlerinden biridir (Zhang vd. 2021). Nokta bulutu, bir nesnenin veya ortamın üç boyutlu (3B) koordinat verilerini içeren bir veri setidir. Nokta bulutu verileri, geniş bir

uygulama yelpazesine sahiptir ve birçok farklı sektörde kullanılmaktadır. Mimari ve mühendislik alanlarında, tarihi yapıların restorasyonu, bina bilgi modelleme ve inşaat süreçlerinin izlenmesi için yaygın olarak kullanılmaktadır (Rusu & Cousins, 2011). Coğrafi Bilgi Sistemleri (CBS) uygulamalarında, arazi modelleme, şehir planlama ve çevresel analizlerde de etkin bir şekilde kullanılmaktadır. Otonom sistemlerde, özellikle sürücüsüz araçlar ve robotik uygulamalarda, nokta bulutu verileri çevrenin algılanması ve haritalanması için kritik bir bileşendir. Bu veri seti, genellikle lidar tarayıcılar, fotogrametrik yöntemler ve RGB-D kameralar kullanılarak elde edilir. Lidar tarayıcılar, lazer darbeleri ile yüzeylere çarpıp geri dönen ışınları analiz ederek yüksek doğruluklu 3B veriler oluşturur. Bu teknoloji, lazer darbeleri kullanılarak mesafelerin ölçülmesi ve yüzeylerin detaylı bir şekilde modellenmesi prensibine dayanır. Lazer tarayıcılar, belirlenen bir frekansta ışınlar yayarak yüzeylere çarpmalarını ve geri dönme sürelerini hesaplar. Bu verileri, üç boyutlu (3B) koordinat noktaları olarak kaydedilir ve yüksek doğruluklu nokta bulutu verisi oluşturulur. LiDAR tabanlı sensörler, nesne tanıma ve yol takibi gibi görevlerde yaygın olarak kullanılmaktadır (Thrun, 2002). Medikal ve biyomedikal alanlarda ise, nokta bulutu teknikleri, ortopedik analizler, diş hekimliği uygulamaları ve cerrahi planlamada önemli bir rol oynamaktadır. Ayrıca, sanal ve artırılmış gerçeklik (VR/AR) uygulamalarında, gerçekçi dijital ortamların oluşturulması için nokta bulutu verileri kullanılmaktadır. Kültürel mirasın dijitalleştirilmesi, müzelerde ve arkeolojik alanlarda nesnelerin korunması ve incelenmesi amacıyla giderek daha fazla tercih edilmektedir (Remondino, 2011). Fotogrametrik yöntemler ise farklı açılardan çekilen görüntülerin işlenmesiyle 3B modelleme sağlar. Fotogrametrik yöntemler, çoklu 2B görüntülerden 3B nokta bulutu oluşturulmasını sağlamaktadır. Bu süreci farklı açılardan çekilen görüntülerin analiz edilerek üç boyutlu geometrik bilginin çıkarılması esasına dayanır. Geleneksel fotogrametrik yaklaşımlar, kamera kalibrasyonu ve stereoskopik görüntüleme tekniklerini kullanır (Remondino vd., 2011).

RGB-D kameralar ise renk ve derinlik bilgilerini birleştirerek hızlı bir şekilde nokta bulutu üretir. Bu yöntemler, nokta bulutunun doğruluğunu, yoğunluğunu ve uygulama alanlarını belirleyen temel tekniklerdir. Günümüzde robotik, uzaktan algılama ve otonom sürüş gibi çeşitli uygulamalarda, gerçek dünyadaki nesneleri temsil etmek için yaygın olarak kullanılmaktadır.

RGB-D kameralar, renk bilgisi (RGB) ve derinlik verisini (D) birleştirerek üç boyutlu veri elde etmeye olanak tanır. Bu cihazlar, aktif veya pasif derinlik algılama

yöntemlerini kullanarak sahnenin hem renk hem de derinlik bilgilerini eş zamanlı olarak yakalar. Microsoft Kinect, Intel RealSense ve Orbbec gibi cihazlar, bu teknolojiyi kullanarak oyun, hareket takibi, robotik ve artırılmış gerçeklik gibi alanlarda geniş uygulama olanakları sunmaktadır (Henry vd. 2012). RGB-D kameralar, derin öğrenme ve bilgisayarla görme algoritmaları ile desteklendiğinde, nesne tanıma, insan-robot etkileşimi ve iç mekân haritalama gibi gelişmiş görevlerde yüksek performans göstermektedir.

1.6.2. Lidar Algılayıcıları ve Özellikleri

LiDAR (Light Detection and Ranging), lazer darbeleri kullanarak nesnelerin mesafesini belirleyen bir uzaktan algılama teknolojisidir. Elektromanyetik spektrumun görünür ve kızılötesi bölgelerinde çalışan bu teknoloji, özellikle yüksek doğruluk gerektiren haritacılık, jeoloji, arkeoloji, otonom araçlar ve çevresel izleme gibi birçok alanda yaygın olarak kullanılmaktadır (Wehr & Lohr, 1999). LiDAR sistemleri, yüksek çözünürlüklü nokta bulutu verileri sağlayarak üç boyutlu yüzey modellemesi ve nesne tespiti gibi ileri düzey analizleri mümkün kılmaktadır (Vosselman & Maas, 2010).

LiDAR, elektromanyetik dalgalar kullanarak mesafe ölçümü yapan bir teknolojidir. Lazer ışınları hedef yüzeye yönlendirilir ve geri yansıyan sinyaller analiz edilerek hedefin uzaklığı hassas bir şekilde belirlenir. Bu işlem, time-of-flight (ToF) prensibine dayanır, yani lazer ışınının gönderildiği ve alındığı zaman arasındaki fark ölçülerek mesafe hesaplanır (Wehr & Lohr, 1999). LiDAR sistemleri, lazer kaynağı, sensör dedektörleri, GPS Atalet Ölçüm Birimi (IMU) ve veri işleme yazılımları olmak üzere dört temel bileşenden oluşur.

LiDAR sistemlerinde kullanılan lazer kaynağı, farklı dalga boylarında lazer ışınları üreterek hedef yüzeye yönlendirir. Kullanılan dalga boyu, sistemin uygulama alanına bağlı olarak değişir. Örneğin, 1550 nm dalga boyuna sahip lazerler insan gözü için daha güvenlidir ve uzun mesafelerde daha etkili olabilirken, 905 nm lazerler daha ekonomik ve yaygın olarak kullanılmaktadır. Lazer kaynağı, atım frekansı ve gücü gibi parametrelerle ölçüm doğruluğunu ve menzilini etkileyen önemli bir bileşendir. LiDAR cihazının ürettiği lazer darbeleri, genellikle kızılötesi veya görünür spektrumdaki belirli dalga boylarında çalışır. Örneğin, 1064 nm dalga boyu orman örtüsü analizi için daha uygunken, 1550 nm dalga boyundaki lazerler su yüzeyleri ve atmosfer analizlerinde daha etkilidir. Farklı dalga

boyları farklı uygulamalar için optimize edilmiştir ve bu seçim, algılama menzili, doğruluk ve çevresel koşullara bağlı olarak değişiklik gösterebilir (Baltsavias, 1999).

LiDAR sistemi; sensör dedektörleri, GPS ve Atalet Ölçüm Birimi (IMU), Veri işleme yazılımları bileşenlerinden oluşmaktadır. Bu bileşenlerin açıklamalarına aşağıda yer verilmiştir.

Sensör dedektörleri: Geri dönen lazer sinyallerini algılayan ve time-of-flight süresini hesaplayan optoelektronik bileşenlerdir. Dedektörlerin hassasiyeti ve algılama hızı, sistemin genel doğruluğunu belirler (Vosselman & Maas, 2010). LiDAR sistemlerinde kullanılan sensör dedektörleri, geri yansıyan sinyalleri algılayarak mesafe ölçümlerini hassas bir şekilde gerçekleştirir. Dedektörler, fotodiyotlar veya foton sayma teknolojileri gibi farklı algılama mekanizmalarına sahip olabilir. Bu sensörler, yansıyan sinyalin gücünü, dönüş süresini ve dalga boyunu analiz ederek çevredeki nesnelerin özelliklerini belirler. Ayrıca, gelişmiş dedektörler çoklu yansıma analizleri yaparak, özellikle ormanlık alanlarda veya karmaşık yüzeylerde daha ayrıntılı veri elde edilmesini sağlar.


GPS ve Atalet Ölçüm Birimi (IMU): LiDAR sistemlerinde konum ve yönelim bilgisi sağlamak için kullanılan temel bileşenlerdir. Hareketli LiDAR sistemlerinde konum ve yön belirlemek için kullanılır. GPS, global konum verisi sağlarken, IMU hareketin açısal hızını ve ivmesini ölçerek sistemin hassasiyetini artırır (Glennie, 2007). IMU, jiroskoplar, ivmeölçerler ve bazen manyetometrelerden oluşarak, özellikle yüksek dinamik hareket gerektiren uygulamalarda LiDAR ölçümlerinin doğruluğunu artırır. GPS ve IMU entegrasyonu, hava, kara ve deniz tabanlı LiDAR sistemlerinde veri bütünlüğünü sağlamak için kritik bir rol oynar.

Veri işleme yazılımları: LiDAR tarafından üretilen büyük hacimli nokta bulutu verilerinin analiz edilmesini ve sınıflandırılmasını sağlayan yazılımlar içerir. LiDAR sistemlerinden elde edilen ham veriler, özel yazılımlar aracılığıyla analiz edilir ve üç boyutlu (3B) modellemeye dönüştürülür. Bu yazılımlar, nokta bulutu verilerini filtreleme, sınıflandırma ve segmentasyon işlemlerini gerçekleştirerek detaylı yüzey modelleri oluşturur. Ayrıca, yoğunluk analizi, vektörleştirme, eğim hesaplamaları ve obje tanıma gibi ileri düzey analizler yapılarak, farklı endüstriyel ve bilimsel uygulamalar için optimize edilmiş sonuçlar elde edilir. Özellikle, makine öğrenmesi ve yapay zekâ destekli yazılımlar, verilerin otomatik olarak işlenmesini sağlayarak manuel müdahaleyi en aza indirir ve hata oranlarını düşürür.

1.6.3. Lidar Türleri

LiDAR sensörleri, kullanım alanlarına göre havadan, yersel ve mobil LiDAR olmak üzere üç türde sınıflandırılabilir.

Havadan LiDAR, uçaklar, helikopterler ve insansız hava araçları (İHA' lar) ile geniş alanların hızlı ve yüksek doğrulukla haritalanmasını sağlayan bir uzaktan algılama yöntemidir. Havadan LiDAR sistemleri, yüksek çözünürlüklü topografik haritaların oluşturulması, orman örtüsünün analiz edilmesi, kentsel planlama ve altyapı çalışmaları gibi çeşitli alanlarda yaygın olarak kullanılır. Bu sistemler, gelişmiş GPS ve IMU sensörleri ile entegre edilerek, hassas konum verileri sağlar. Özellikle, yoğun bitki örtüsüne sahip bölgelerde ve ulaşılması zor alanlarda detaylı yüzey modelleri oluşturulmasını mümkün kılar. Ayrıca, deniz seviyesinin yükselmesi gibi çevresel değişikliklerin izlenmesinde önemli bir rol oynar. Havadan Lidar sisteminin bileşenleri Şekil 1'de gösterilmiştir.



Şekil 1. Hava LiDAR sisteminin çalışma prensibi (URL-1)

Yersel LiDAR ise genellikle araçlara veya tripodlara monte edilerek kullanılan kara bazlı LiDAR sistemleri, bina cepheleri, yol yüzeyleri ve arazi analizleri gibi detaylı yüzey modellemeleri için tercih edilir. Statik veya hareketli olarak çalışabilen bu sistemler, şehir planlama, altyapı projeleri ve tarihi yapıların dijital haritalanması gibi uygulamalarda

yüksek hassasiyet sağlar. Yüksek çözünürlüklü nokta bulutu verileri elde ederek, nesnelerin geometrik özelliklerini ayrıntılı bir şekilde analiz etmeye olanak tanır. Ayrıca, kısa menzilli yüksek doğruluklu taramalar yaparak, iç mekân haritalama ve yapısal analizlerde de etkin bir şekilde kullanılır. Yersel lazer tarama, geleneksel ölçüm yöntemlerine kıyasla 3B nokta verilerinin çok daha hızlı bir şekilde elde edilmesini sağlar. Ölçme alanındaki 3B nokta verileri, nokta dizileri olarak yüksek hassasiyetle ölçülebilir. Yersel lazer tarayıcılar, birçok ölçüm uygulamasında, özellikle tarihi yapıların röleve çalışmalarında çokça tercih edilmektedir. Şekil 2’ de yersel lazer tarayıcı (YLT) gösterilmektedir.



Şekil 2. Yersel lazer tarayıcı


Yersel lazer ölçümlerindeki ana parametre, alet ile ölçüm yapılan nokta arasındaki uzaklıktır. Yersel lazer tarayıcılar, lazer ışınının bir hedefe gönderilmesi ve yansıyan sinyalin dönüş süresinin veya faz farkının ölçülmesi prensibine dayanır (Shan & Toth, 2018). Temel olarak üç farklı lazer tarama yöntemi bulunmaktadır:

- Uçuş süresi (yansıma süresi) (Time-of-Flight - ToF): Lazer ışını bir nesneye çarpar ve geri döner. Işığın gidiş-dönüş süresi ölçülerek mesafe hesaplanır.
- Faz Kaydırma (Phase-Shift - PS): Sürekli dalga lazer sinyali kullanılarak faz kayması hesaplanır, bu sayede daha yüksek doğruluk sağlanır.
- Üçgenleme (Triangulation): Kamera ve lazer kaynağı arasındaki açısal fark kullanılarak mesafe hesaplanır. Kısa mesafelerde yüksek hassasiyet sunar.

Yersel lazer tarayıcılarda, lazer pulslarının kısa zaman dilimlerinde gönderilip ölçülmesine dayanan puls yöntemi kullanılmaktadır (Lichti & Gordon 2004).

Sensör teknolojisi ve ona bağlı yazılım araçlarındaki hızlı gelişim; mühendislik projeleri, tarihi ve kültürel varlıkların belgelenmesi ile kentsel alanların 3B modellenmesi, madencilik faaliyetleri, deformasyon analizi ve orman alanlarının ölçümü gibi çeşitli alanlarda geometrik verilerin elde edilmesinde yersel lazer taramayı önemli bir teknik haline getirmiştir. Yersel lazer tarama yöntemi, 3B modelleme, obje sınıflandırma ve sanal gerçeklik uygulamaları için yeni imkanlar sunmuştur.

Yersel lazer tarama tekniği mevcut diğer ölçüm yöntemleriyle beraber kullanılabilir ve ölçümler diğer ölçüm verileriyle birleştirilebilir. Yersel lazer tarama sistemi koordinat sistemi aşağıda gösterilmiştir (Şekil 3).



Şekil 3. Yersel lazer tarayıcı koordinat sistemi (Altuntaş ve Yıldız, 2008)

- x, y, z : Nokta bulutu koordinatları,
- ρ : Tarayıcı ile obje arasındaki eğik mesafe,
- α : Işın doğrultusunun x eksenini yatay düzlemde yaptığı açı,
- θ : Işın doğrultusunun yatay düzlemle yaptığı eğim açısı,
- O_1 : Tarayıcı koordinat sistemi merkezi,
- O_2 : Yer koordinat sistemi merkezidir.

3B koordinatlar (x,y,z), Denklem 1'deki gibidir (Elkhrachy & Niemeir 2006; Scaioni 2005; Lichti & Gordon 2004).

$$\begin{bmatrix} x \\ y \\ z \end{bmatrix} = \rho \begin{bmatrix} \cos\theta\cos\alpha \\ \cos\theta\sin\alpha \\ \sin\theta \end{bmatrix} \quad (1)$$

Mobil LiDAR sistemi de bir aracın üzerine yerleştirilen ve çeşitli harita çıkarma, analiz ve modelleme işlevlerini yerine getiren lazer tarama teknolojisini kullanarak dinamik ortamlarda 3B veriler toplayan bir sistemdir. Bu tür sistemler, genellikle otomobiller, kamyonlar veya diğer mobil platformlar üzerine montelenmiş sensörler ve GPS alıcıları ile çalışır.

1.6.4. Lidar Nokta Bulutu Sınıflandırması

LiDAR nesnelerin 3B koordinatlarını doğrudan ölçerek yoğun nokta bulutları elde eder (Vosselman, 2009). Nokta bulutları, arazi (zemin), bitki örtüsü, binalar vb. gibi araziye ve arazi dışındaki nesnelere ait noktaları içerir ve lazer tarama işlemi sırasında kaydedilir (Hao vd., 2009). LiDAR nokta bulutları, genellikle nesne çıkarımı, Dijital Arazi Modeli (DTM) oluşturma, 3B bina modelleme ve değişim tespiti gibi uygulamalarda kullanılır (Vosselman, 2000; Rottensteiner, 2003; Brenner, 2005; Hommel, 2009; Champion vd., 2009). Her bir LiDAR noktası, LiDAR verisinin özelliklerine dayanarak anlamlı kategorilere ayrılır.

LiDAR, yüksek hassasiyetli 3B veri elde etme teknolojisi olarak, uzaktan algılama ve coğrafi bilgi sistemlerinde önemli bir yer tutmaktadır. LiDAR verileri, milyonlarca noktadan oluşan yoğun bir bulut şeklinde elde edilir ve bu verilerin anlamlandırılması için nokta bulutu sınıflandırması gereklidir. LiDAR verilerinin sınıflandırılması, nokta bulutundaki her bir noktanın belirli bir sınıfa atanmasını içerir. Bu süreç, nesnelerin otomatik olarak tanımlanmasına olanak tanır. Sınıflandırma işlemi, belirli kurallar ve algoritmalar kullanılarak gerçekleştirilir ve genellikle aşağıdaki temel adımları içerir:

- **Ön İşleme:** Gürültü temizleme, hatalı veya eksik verilerin düzeltilmesi gibi işlemler gerçekleştirilir.
- **Öznitelik Çıkarımı:** Her bir noktanın yükseklik, yansıtıcılık, yoğunluk ve geometrik ilişkileri analiz edilir.

- **Özellik Tabanlı Gruplama:** Noktalar, belirli mekânsal ve spektral özelliklere göre kümeler ayrılır.
- **Makine Öğrenmesi ve Derin Öğrenme Kullanımı:** Verilerin otomatik sınıflandırılması için çeşitli algoritmalar (örneğin; DVM, YSA) uygulanır.
- **Sonuç Değerlendirmesi ve Doğruluk Analizi:** Elde edilen sınıflandırma sonuçlarının doğruluğu istatistiksel yöntemler ile analiz edilir.

Bu süreç, sınıflandırma doğruluğunu artırmak için çeşitli optimizasyon ve ince ayarlamalar gerektirir. Özellikle büyük ölçekli LiDAR verilerinde veri yönetimi ve işlem süresi önemli bir zorluk teşkil etmektedir.

Nokta bulutu sınıflandırma sürecinde geleneksel, makine öğrenmesi tabanlı ve derin öğrenme tabanlı yöntemler kullanılmaktadır:

Geleneksel sınıflandırma yöntemleri, kural tabanlı yaklaşımlar ve temel istatistiksel analizler kullanarak LiDAR nokta bulutu verilerini sınıflandırmayı amaçlar. Bu yöntemler, nispeten düşük hesaplama gereksinimleri ve kolay uygulanabilirlikleri nedeniyle yaygın olarak kullanılmıştır. Ancak, karmaşık çevresel koşullarda ve büyük veri kümelerinde sınırlı doğruluk sunabilirler. Geleneksel yöntemler genellikle aşağıdaki teknikleri içerir:

- **Eşikleme (Thresholding):** Nokta bulutundaki belirli bir özelliğin (örneğin yükseklik veya yoğunluk) belirlenen bir eşik değeri ile karşılaştırılması yoluyla veri sınıflandırılması yapılır. Özellikle arazi modeli oluşturma ve bina tespiti gibi uygulamalarda kullanılır.
- **Kurallara Dayalı Yaklaşımlar:** Belirli özniteliklere dayalı olarak geliştirilen algoritmalar, manuel olarak belirlenen kurallar çerçevesinde sınıflandırma işlemi gerçekleştirir. Örneğin, belirli bir yükseklik aralığında bulunan noktalar ağaç olarak etiketlenebilir.
- **Yoğunluk Tabanlı Kümeleme:** Nokta yoğunluğuna bağlı olarak gruplama yapılır. DBSCAN gibi yöntemler, belirli yoğunluk eşiğine sahip noktaları belirleyerek nesne tespiti yapılabilir.
- **Spektral ve Geometrik Özelliklerin Kullanımı:** Nokta bulutundaki farklı yüzey türleri, yansıtıcılık, eğim ve kıvrım gibi geometrik özellikler yardımıyla ayrıştırılabilir.

Bu yöntemler, günümüzde modern makine öğrenmesi ve derin öğrenme teknikleriyle desteklenerek daha yüksek doğrulukta sınıflandırma işlemleri gerçekleştirmek için temel oluşturabilir.

Makine öğrenmesi tabanlı yöntemler, LiDAR nokta bulutu sınıflandırmasında yaygın olarak kullanılan güçlü tekniklerdir. Bu yöntemler, belirli özelliklere dayalı olarak eğitim verilerinden öğrenme yaparak sınıflandırma süreçlerini otomatik hale getirir. Geleneksel yöntemlere kıyasla daha esnek ve yüksek doğruluk oranlarına sahiptirler. Makine öğrenmesi yöntemleri genellikle denetimli, yarı denetimli ve denetimsiz öğrenme yaklaşımlarını içerir.

Destek Vektör Makineleri (DVM): Sınıflandırma için yüksek boyutlu bir hiperdüzlem oluşturarak verileri ayıran güçlü bir algoritmadır. LiDAR nokta bulutu verilerinde, yüzeylerin ayrıştırılması, nesnelerin belirlenmesi ve arazi sınıflandırması gibi uygulamalarda sıkça kullanılmaktadır. DVM, doğrusal ve doğrusal olmayan sınıflandırma yapabilen çekirdek fonksiyonları ile geniş bir uygulama alanına sahiptir.

Karar Ağaçları ve Random Forest: Karar ağaçları, veri setindeki farklı öznitelikleri kullanarak sınıflandırma yaparken, Random Forest yöntemi birden fazla karar ağacını birleştirerek daha yüksek doğruluk elde eder.

K-En Yakın Komşu (KNN): Her noktanın en yakın komşularına göre sınıflandırılmasını sağlar. Özellikle belirli nesnelerin yoğun olarak bulunduğu alanlarda etkili bir yöntemdir.

Gaussian Mixture Model (GMM): Nokta bulutundaki farklı dağılımları modelleyerek nesneleri ayırt edebilen bir olasılık tabanlı yaklaşımdır.

Makine öğrenmesi tabanlı yöntemler, LiDAR nokta bulutu sınıflandırmasında büyük ölçekli veri kümelerini verimli bir şekilde işleyerek, arazi modeli oluşturma, şehir planlaması, otonom sürüş sistemleri ve orman yönetimi gibi alanlarda önemli avantajlar sağlamaktadır.

Derin Öğrenme Tabanlı Yöntemler;

- **Yapay Sinir Ağları (YSA):** Katmanlı sinir ağları aracılığıyla veri içerisindeki karmaşık ilişkileri öğrenerek sınıflandırma yapar.
- **Konvolüsyonel Sinir Ağları (KSA):** Nokta bulutu verilerinin görüntü benzeri formatlara dönüştürülerek işlenmesini sağlar.
- **Rekürsif Sinir Ağları (RSA):** Nokta bulutu verilerini sekanslar halinde işleyerek sınıflandırma yapar.

1.6.5. Yüzey Normali Hesabı

Günümüzde 3B modelleme, bilgisayar görüşü ve robotik alanlarında nokta bulutları yaygın olarak kullanılmaktadır. Nokta bulutları üzerinde yüzey normali hesaplama, yüzeyin geometrik yapısını anlamak ve ilgili analizleri gerçekleştirmek için önemlidir.

Yüzey normali, bir yüzeyin herhangi bir noktasında ona dik olan birim vektördür ve yüzeyin eğimi hakkında bilgi sağlar (Besl & Jain, 1988).

3B uzayda bir nokta bulutu $P = \{p_1, p_2, \dots, p_n\}$ şeklinde tanımlandığında, herhangi bir p_i noktasının yüzey normali n_i , komşu noktaları temel alarak belirlenebilir.

Matematiksel olarak, yüzey normali hesaplama süreci en iyi uygun düzlemi bulmaya dayanır. Bu düzlem, noktanın en yakın komşularının dağılımını analiz ederek belirlenir. Düzlem denklemi Denklem 2' de yer almaktadır.

$$ax + by + cz + d = 0 \quad (2)$$

Burada (a, b, c) vektörü yüzeyin normal yönünü temsil eder.

En uygun düzlemin belirlenmesi için, noktanın en yakın k komşusunun kovaryans matrisi Denklem 3' teki gibi hesaplanır (Mitra vd., 2004).

$$C = \frac{1}{k} \sum_{i=1}^k (p_i - \bar{p})(p_i - \bar{p})^T \quad (3)$$

Denklem 3'te $\bar{p}$ komşu noktaların ortalama noktasıdır. Kovaryans matrisinin en küçük özdeğerine karşılık gelen özvektör, noktanın yüzey normalini verir. Bu yöntem, özellikle düzensiz veya gürültülü nokta bulutları üzerinde yüzey yapısını anlamak için kullanışlıdır. En küçük özdeğer ve buna karşılık gelen özvektör hesaplanarak, yüzeyin en iyi uygun düzlemi belirlenir ve böylece her nokta için yüzey normali yönlendirilmiş olur.

Yüzey normali hesabı, bilgisayarla görme, fotogrametri, LiDAR veri analizi ve bilgisayar grafikleri gibi birçok alanda kritik bir rol oynar. Yüzey normallerini hesaplamak için çeşitli algoritmalar geliştirilmiştir. En yaygın kullanılan bazı yöntemler:

- En küçük kareler (Least Squares) metodu
- PCA Temel bileşen analizi (Principal Component Analysis)
- Nokta üçlülere (Triangular Mesh Normal Estimation)
- Ortalama ağırlıklı normaller (Weighted Averaging of Normals)

- Varyasyonel metotlar (Variational Methods)
- RANSAC (Random Sample Consensus) yaklaşımı
- Moving Least Squares (MLS) yöntemi

Bu yöntemler, yüzey normali hesabında yaygın olarak kullanılan tekniklerdir ve uygulamaya bağlı olarak farklı avantajlara sahiptirler. Özellikle PCA ve en küçük kareler yöntemleri, nokta bulutlarıyla çalışırken en sık kullanılan ve dengeli sonuçlar veren yöntemlerdir.

1.6.6. Veri Ölçekleme

Makine öğrenmesi ve istatistiksel analiz süreçlerinde veri ön işleme önemli bir aşamadır. Veri ölçekleme, modelin performansını artırmak ve farklı değişkenlerin aynı önem seviyesinde değerlendirilmesini sağlamak için uygulanır.

Veri ölçekleme, veri setindeki değişkenlerin farklı büyüklük ve ölçü birimlerine sahip olması nedeniyle ortaya çıkan analiz ve modelleme sorunlarını gidermek için kullanılan bir tekniktir. Ölçekleme, özellikle uzaklık tabanlı algoritmalarda (örneğin, K-En Yakın Komşu (KNN) ve Destek Vektör Makineleri (DVM)) model performansını artırır. Bunun yanı sıra, yapay sinir ağları ve doğrusal regresyon gibi yöntemlerde de modelin daha hızlı ve kararlı bir şekilde eğitilmesine yardımcı olmaktadır. Ölçeklenmiş veriler, optimizasyon süreçlerinde daha iyi sonuçlar elde edilmesini sağlar ve modelin genelleme yeteneğini artırır. Bu bağlamda, veri ölçekleme veri analizinde önemli bir ön işleme aşamasıdır.

Veri ölçekleme, makine öğrenmesi modellerinin performansını artırmak, modelin farklı büyüklüklere sahip değişkenler üzerinde daha sağlıklı çalışmasını sağlamak amacıyla kullanılan önemli bir ön işleme yöntemidir. Özellikle derin öğrenme, kümeleme ve regresyon analizlerinde veri ölçekleme, modelin daha hızlı ve daha doğru sonuçlar üretmesine yardımcı olmaktadır. Makine öğrenmesi uygulamalarında kullanılan temel veri ölçekleme yöntemleri şunlardır:

Min-Max Scaler (Min-Maks Ölçekleme): Veriyi belirlenen bir aralıkta (genellikle $[0,1]$ veya $[-1,1]$) ölçeklendirir. Bu yöntem, özellikle sinir ağları ve regresyon modellerinde sıkça kullanılmaktadır. Min-Max Scaler, veri setindeki minimum değeri 0'a, maksimum değeri 1'e çekerek diğer değerleri bu aralıkta normalize eder. Ancak, aykırı değerlere karşı duyarlıdır ve verinin dağılımı değiştiğinde yeniden hesaplanması gerekebilir.

RobustScaler (Sağlam Ölçekleyici): Medyan ve inter-kuartil aralığı (IQR) kullanarak aykırı değerlere karşı dayanıklı bir ölçekleme sağlar. Bu yöntem, özellikle aykırı değerlerin yoğun olduğu veri setlerinde etkin çalışır ve merkezi eğilim ölçütlerini kullanarak verinin istikrarlı bir şekilde ölçeklenmesini sağlar. RobustScaler, veriyi ortanca (medyan) etrafında ölçekleyerek aşırı uç değerlerin etkisini minimize eder. Bu nedenle, lojistik regresyon, DVM ve kümeleme algoritmaları gibi modellerde sıklıkla tercih edilir.

MaxAbsScaler (Maksimum Mutlak Ölçekleyici): Veriyi maksimum mutlak değeri 1 olacak şekilde normalize eder. Bu yöntem, özellikle pozitif ve negatif değerlere sahip verilerde kullanılır ve orijinal veri dağılımını korur. MaxAbsScaler, özellikle seyrek veri kümeleriyle çalışırken avantaj sağlar ve doğrusal modeller ile kümeleme algoritmalarında yaygın olarak tercih edilir. Ancak, aykırı değerlere karşı Min-Max Scaler kadar hassas değildir ve büyük ölçekli verilerde etkinliği azalabilir.

Logaritmik Dönüşüm: Veri dağılımını normalleştirmek için kullanılan bir yöntemdir. Özellikle pozitif yönde çarpık dağılıma sahip verilerde etkilidir ve değişkenlerin varyansını azaltarak istatistiksel analizlerde daha güvenilir sonuçlar elde edilmesini sağlar. Ayrıca, lojistik regresyon, zaman serisi analizi ve makine öğrenmesi modellerinde hata oranlarını düşürmeye yardımcı olur. Ancak, sıfır veya negatif değerlere sahip verilerde uygulanabilmesi için ön işleme adımları gerektirebilir.

StandardScaler (Standartlaştırma): StandardScaler veriyi ortalaması 0 standart sapması 1 olacak şekilde ölçekler (Pedregosa vd., 2011). Bu, şu anlama gelir:

- Her bir özelliğin (feature) ortalaması 0 olur
- Her bir özelliğin standart sapması 1 olur.
- Veriler yaklaşık olarak $[-3,3]$ aralığında dağıtılır (URL-2, 2025).

StandardScaler işlem adımları şu şekildedir:

- Her bir sütunun ortalaması hesaplanır (Denklem 4).

$$\mu = \frac{1}{n} \sum_{i=1}^n X_i \quad (4)$$

- Her bir sütunun standart sapması hesaplanır (Denklem 5).

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2} \quad (5)$$


- Her bir değer, ortalamadan çıkarılıp standart sapmaya bölünerek ölçeklenir (Denklem 6), (Pedregosa vd., 2011; URL-2, 2025).

$$X_{scaled} = \frac{X - \mu}{\sigma} \quad (6)$$

1.6.7. Makine Öğrenimi Yöntemleri

Günümüzde istatistiksel olarak büyük miktarda verinin dağınık bir şekilde bulunduğunu görebiliriz ve bu veriler tekrar toplanarak bilgi elde edilir. Bu bilgilerin düzenlenmesi ve kategorize edilmesi gerekmektedir. İşte bu noktada sınıflandırma (classification) ve regresyon (regression) kavramları devreye girer.


Makine öğrenmesi, makinelerin öğrenme yeteneğidir: Belirli algoritmalar kullanılarak oluşturulan bir makinenin kendi kararlarını almasını ve kullanıcılara sonuçlar sunmasını sağlar. Temel olarak, makine öğrenmesi yapay zekânın bir alt dalı olarak kabul edilir (Şekil 4).



Şekil 4. En yaygın kullanılan yapay zekâ yöntemlerinin birbirleriyle ilişkisi (Sotoudeh vd. 2019)


Günümüzde makine öğrenmesi, karmaşık veri sınıflandırma ve karar verme süreçlerinde kullanılmaktadır (Kulkarni & Shinde, 2013). Basit bir ifadeyle, makine öğrenmesi, bir sistemin öğrenmesini ve gerekli kararları almasını sağlayan algoritmaların geliştirilmesidir. Makine öğrenmesi, yöntemler, teoriler ve uygulama alanları sağlayan

matematiksel optimizasyon ile güçlü bir bağa sahiptir. Aynı zamanda, açıkça programlanması veya algoritmalarının tasarlanması zor olan çeşitli bilişim görevlerinde kullanılmaktadır. Makine öğrenimi çalışma prensibi çalışma prensibi Şekil 5'teki gibidir.



Şekil 5. Makine öğrenimi çalışma prensibi (URL-1, 2025)

Makine öğrenmesine bazı örnek uygulamalar arasında spam filtreleme, optik karakter tanıma (OCR), arama motorları ve bilgisayarla görme (Computer Vision) yer almaktadır. Makine öğrenmesi yöntemleri ve DVM' nin makine öğrenmesindeki yeri Şekil 6' da gösterilmiştir.



Şekil 6. Makine öğrenmesinin alt dalları içerisinde destek vektör makinesinin yeri (Wang vd., 2020; Xue vd., 2019)

Makine öğrenmesi yöntemleri ve görevleri genellikle denetimli öğrenme (supervised learning), denetimsiz öğrenme (unsupervised learning) ve pekiştirmeli öğrenme (reinforcement learning) olmak üzere üçe ayrılır.

Denetimli öğrenme; bu tür öğrenmede sisteme örnek girişler sağlanır ve bunlar çıktılarla eşleştirilir. Her örnek, bir giriş nesnesi (genellikle bir vektör) ve istenen çıktı değeri (denetleyici sinyal) içeren bir çift olarak sunulur. Denetimli öğrenme algoritması, eğitim verilerini analiz eder ve inceler, ardından yeni örnekleri eşleştirmek için kullanılacak bir tahmin fonksiyonu üretir. En iyi senaryoda, algoritma daha önce görülmemiş örneklerin sınıf etiketlerini doğru bir şekilde belirleyebilir. Öğrenme algoritmasının, eğitim verilerinden genelleme yaparak daha önce karşılaşılmamış durumlara “makul” bir şekilde uyum sağlaması beklenir.

Denetimsiz Öğrenme; bu tür öğrenmede sisteme bazı örnek girişler sağlanır, ancak herhangi bir çıktı bulunmaz. Burada istenen bir çıktı olmadığı için, algoritmanın veri kümelerini doğru şekilde ayırt edebilmesi amacıyla kategorilendirme yapılır.

Denetimsiz öğrenme, etiketlenmemiş verilerden gizli yapıyı tanımlayacak bir fonksiyon belirleme işlemidir. Öğreniciye verilen örnekler veya eğitim setleri etiketlenmemiş olduğundan, olası bir çözümü değerlendirecek bir hata veya ödül sinyali bulunmaz. Bu yönüyle denetimsiz öğrenme, denetimli öğrenme ve pekiştirmeli öğrenmeden farklıdır. Aynı zamanda yoğunluk tahmini (Density Estimation) ve istatistik problemleriyle yakından ilişkilidir (Jakkula, 2013).

Pekiştirmeli öğrenme, davranışçı psikolojiden ilham alan ve makine öğrenmesinin bir alt dalı olan bir yaklaşımdır. Bu öğrenme yöntemi, yazılım ajanlarının bir ortamda nasıl hareket etmeleri gerektiğini belirleyerek toplam ödülü maksimize etmelerini amaçlar.

Pekiştirmeli öğrenme, oyun teorisi, kontrol teorisi, yöneylem araştırması, bilgi teorisi, sürü zekâsı, istatistik ve genetik algoritmalar gibi birçok teori kapsamında incelenmekte ve kullanılmaktadır (Jakkula, 2013).

1.6.8. Destek Vektör Makineleri


Destek Vektör Makinesi (DVM) ilk olarak 1992 yılında duyulmuş olup, Boser, Guyon ve Vapnik tarafından tanıtılmıştır. Destek Vektör Makineleri, sınıflandırma ve regresyon için kullanılan bir dizi denetimli öğrenme yöntemidir. Bunlar, genelleştirilmiş doğrusal sınıflandırıcılar ailesine aittir. Başka bir deyişle, Destek Vektör Makinesi, makine öğrenimi

teorisini kullanarak tahmin doğruluğunu en üst düzeye çıkarırken veriye aşırı uyumu (overfitting) otomatik olarak önleyen bir sınıflandırma ve regresyon tahmin aracıdır.

DVM günümüzde el yazısı analizi, yüz analizi gibi birçok uygulamada, özellikle desen sınıflandırma ve regresyona dayalı uygulamalarda yaygın olarak kullanılmaktadır. Destek Vektör Makinelerinin temelleri Vapnik tarafından geliştirilmiş olup, üstün ampirik performans gibi birçok umut verici özelliği sayesinde popülerlik kazanmıştır. DVM’ nin formülasyonu, geleneksel sinir ağları tarafından kullanılan Ampirik Risk Minimizasyonu (ERM) ilkesine göre daha üstün olduğu kanıtlanmış Yapısal Risk Minimizasyonu (SRM) ilkesini kullanır. SRM, beklenen riskin üst sınırını en aza indirirken, ERM eğitim verileri üzerindeki hatayı minimuma indirir. Bu fark, DVM’ yi daha iyi genelleştirme yeteneğiyle donatarak istatistiksel öğrenimde asıl hedef olan genelleme kapasitesini artırır.

Bir DVM karar fonksiyonu, gözlemleri bir sınıftan diğerine ayırmak (sınıflandırmak) için kullanılan, “hiper düzlem” olarak adlandırılan optimal bir ayırım yüzeyidir. Bu hiper düzlem, daha sonra görülmemiş veriler için en olası etiketi belirlemek amacıyla kullanılabilir. Hiper düzlemin çıkarılmasında kullanılan özellikler genellikle ham veriler değildir; aksine, çoğunlukla özellik seçimi aşamasında yapılan bir tür enterpolasyon sonucu elde edilen türevsel verilerdir. Özellikler, birbirleriyle olan ilişkilerine dayalı koordinatlar ile ifade edilir ve destek vektörlerini oluşturur. Diğer makine öğrenimi yöntemlerinde olduğu gibi, DVM ile çalışırken iki tamamlayıcı hedefi dengelemek gerekmektedir. Bunlardan ilki sınıflandırıcının yeni örneklerle doğru etiketler atama yüzdesini en üst düzeye çıkarmak (doğruluğunu optimize etmek) ve diğeri sınıflandırıcının yeni verilere genelleştirilebilir olmasını (yeniden üretilebilirliğini optimize etmek) sağlamaktır. İlk hedef, kullanılan özelliklerin bilgilendiriciliğiyle (özellik önem derecesi) sınırlıyken, ikinci hedef modelin eğitilmesi için kullanılan benzersiz örneklerin sayısıyla belirlenir.

Bir DVM karar fonksiyonunu eğitme süreci, her iki sınıf etiketinin destek vektörleri arasındaki mesafeyi (marjı) en üst düzeye çıkaran yeniden üretilebilir bir hiper düzlem belirlemeye dayanır (Şekil 7). Dolayısıyla, en uygun hiper düzlem, sınıflar arasındaki marjı maksimize eden düzlemdir. Bir DVM doğrusal veya doğrusal olmayan olabilir ancak en yaygın olanı doğrusal DVM’ dir. Doğrusal DVM problemlerinin karmaşıklığı, kullanılan özelliklerin sayısına bağlı olarak değişir. Örneğin, iki özellik boyutunun olduğu varsayımsal bir durumda, hiper düzlem basitçe bir doğruya karşılık gelirken, üç özellik kullanıldığında hiper düzlem iki boyutlu bir düzleme karşılık gelir.




Şekil 7. Tahmin edilecek iki sınıfın her birine karşılık gelen destek vektörlerini maksimum düzeyde ayıran hiper düzlemin gösterimi (Schnyer vd., 2017)

DVM' nin karmaşıklık düzeyi yani boyutsallığı ne olursa olsun, sınıflandırma problemleri çoğunlukla doğrusaldır, çünkü kullanılan hiper düzlem eğrisel değil, düzdür. Eğer DVM için kullanılan özelliklerin bu şekilde doğrusal olarak ayrılabilir olduğu varsayılırsa, özelliklerin grafiği üzerinde sınıflandırılan iki etiketi ayıran düz bir hiper düzlem (doğrusal sınıflandırıcı olarak adlandırılır) çizilebilir.

Buna bağlı olarak, doğrusal bir DVM için en üst düzeye çıkarılması gereken teknik olarak iki tür marj vardır. Sert marj (hard margin) durumunda, hiçbir eğitim hatasına izin verilmez. Sert marj en basit ve en az hesaplama gerektiren yaklaşım olmasına rağmen, pratikte özelliklerin doğrusal olarak tamamen ayrılabilir olması nadiren mümkündür. Bu nedenle, sınıflandırıcının bazı hatalar yapmasına izin vererek, yeni verilere daha iyi genelleme yapabilen daha büyük bir marj elde etmek genellikle mümkündür. Bu tür yanlış sınıflandırmalara izin vermek, yumuşak marj (soft margin) olarak adlandırılan bir yöntemle sağlanır. Bu değişkenlerin arasında değişen sıfırdan farklı değerler alabilmesi, eğitim verisindeki aykırı değerlerin hiper düzlemin hata yapmasına ve dolayısıyla yanlış

sınıflandırmaya yol açmasına izin verir (Şekil 8). Bu bağlamda, sert marj, gevşeme değişkeninin sıfıra eşit olduğu yumuşak marjın özel bir durumu olarak düşünülebilir.




Şekil 8. Sert ve yumuşak marjin gösterimleri (Mahmoudi vd., 2012)

Şekil 8'deki grafiklerde soldaki çizim, hiçbir eğitim hatasına (yanlış sınıflandırılmış destek vektörlerine) izin verilmeyen sert kenarlıklı bir hiper düzlemi göstermektedir. Sağdaki çizim ise ξ gevşek değişkenlerinin kullanımı yoluyla bir dereceye kadar eğitim hatasına izin veren yumuşak marjlı bir hiper düzlemi göstermektedir. Her iki çizimde de w marjı, b sınıflar arasındaki kesişimi ve $x^{(i)}$ yeşil (baskı versiyonunda gri) ve kırmızı (baskı versiyonunda koyu gri) ile gösterilen sınıf etiketlerini göstermektedir.

Yumuşak marj yaklaşımı ayrıca C adı verilen bir ceza faktörü (yumuşak marj sabiti) içerir. Bu parametre, hiper düzlemin karmaşıklığı ile eğitim hataları arasındaki dengeyi kontrol etmek (yani düzenleme, regularization) ve aşırı öğrenmeyi (overfitting) önlemek için kullanılır. Aşırı öğrenme, sınıflandırıcının eğitim verisinde en yüksek doğruluğu sağlayacak şekilde aşırı uyarlanması sonucunda modelin yeni verilere genelleme yapamaması durumudur.

Daha zor sınıflandırma problemlerinde, en uygun çözümleri doğrudan eğri hiper düzlemler (yani doğrusal olmayan karar sınırları) gerektirebilir (Şekil 9). Bir sınıflandırıcının karar sınırı verilerle doğrusal olmayan bir şekilde ilişkili olduğunda yani yalnızca birkaç aykırı değer içeren yumuşak marj durumunun ötesinde, bu sınıflandırıcı doğrusal olmayan (nonlinear) olarak adlandırılır.



Şekil 9. Eğri hiper düzlem gösterimi (Derek vd., 2020)

Şekil 9’ daki grafik, destek vektörleri ayıran eğri bir hiperdüzlem ile doğrusal olmayan bir sınıflandırma problemini göstermektedir.

Bu tür durumlarda, destek vektörlerini daha yüksek boyutlu bir giriş uzayına dönüştürmek için genellikle bir tür çekirdek (kernel) yöntemi gereklidir. Başka bir deyişle, bu ek adım, doğrusal olarak ayrılamayan bir özellik kümesini doğrusal olarak ayrılabilir bir hale dönüştürmeye hizmet eder. Çekirdek yöntemleri genellikle doğrusal DVM için bir tür boyut azaltma yöntemi olarak da kullanılmaktadır.

Kernel fonksiyonları, DVM modellerinde veri noktalarını yüksek boyutlu bir uzaya dönüştürerek daha iyi ayırım yapmayı sağlar (Schölkopf & Smola, 2002). Bu dönüşüm, özellikle doğrusal olarak ayrıştırılamayan veri setlerinde daha güçlü bir sınıflandırma performansı elde edilmesini sağlar. Kernel fonksiyonları, farklı veri yapıları için uygun olacak şekilde çeşitlenmiştir ve modelin doğruluğunu artırmada kritik bir rol oynar. Grid Search kullanarak optimal kernel fonksiyonunu belirlemek mümkün hale gelir. Bu seçim, modelin genelleme başarısını doğrudan etkileyerek overfitting (aşırı uyum) veya underfitting (eksik uyum) gibi problemlerin önüne geçilmesine yardımcı olabilir. Bu bağlamda, kernel fonksiyonlarının doğru belirlenmesi, modelin başarımını artırmak için önemli bir adımdır.

Destek Vektör Makinesinde kullanılan literatürde mevcut kernel fonksiyonları ve diğer parametreler aşağıda özetlenerek sıralanmıştır.

Linear Kernel: Verilerin doğrusal olarak ayrılabilir olduğu durumlarda tercih edilir. Linear kernel, özellikle yüksek boyutlu veri setlerinde hesaplama açısından daha verimli olup, fazla parametre gerektirmeden etkili sonuçlar elde edilmesini sağlar. Ayrıca, büyük veri kümelerinde daha az hesaplama maliyetine sahip olduğu için genellikle tercih edilir (Schölkopf & Smola, 2002).

RBF (Radial Basis Function) Kernel: En yaygın kullanılan kernel türüdür. Verilerin doğrusal olarak ayrılamadığı durumlarda önerilir (Burges, 1998). RBF kernel, verileri daha yüksek boyutlu bir uzaya haritalayarak doğrusal ayrıştırılabilir hale getirmeye yardımcı olur. Bu özellik, karmaşık veri setlerinde daha iyi sınıflandırma performansı elde edilmesini sağlar. RBF kernel, gamma parametresi ile doğrudan ilişkilidir; küçük gamma değerleri geniş bir etki alanına sahip karar sınırları oluştururken, büyük gamma değerleri daha dar ve spesifik karar sınırları oluşturur. Bu nedenle, gamma ve C parametreleri ile birlikte optimize edilerek modelin genelleme yeteneği artırılabilir.

Sigmoid Kernel: Sigmoid kernel, yapay sinir ağlarındaki aktivasyon fonksiyonlarına benzerlik gösterir ve özellikle iki sınıf arasındaki ayrımı modellemek için kullanılır. Kernel fonksiyonu, verileri dönüştürerek doğrusal olmayan karar sınırları oluşturur. Sigmoid kernel, genellikle nöral ağlarla ilişkili olan tanh fonksiyonunu temel alır ve belirli hiperparametre kombinasyonları ile esnek karar sınırları sağlayabilir. Ancak, Sigmoid kernel her durumda iyi performans göstermeyebilir ve belirli veri setlerinde aşırı uyum sorununa neden olabilir (Schölkopf & Smola, 2002).

Polynomial Kernel: Doğrusal olmayan karar sınırları oluşturmak için kullanılır (Cristianini & Shawe-Taylor, 2000). Polynomial kernel, verileri belirli bir dereceden polinom fonksiyonları kullanarak yüksek boyutlu uzaya projelendirir. Bu yaklaşım, özellikle doğrusal olmayan ilişkiler içeren veri kümelerinde etkili olabilir. Kernel fonksiyonunun derecesi (degree), modelin esnekliğini ve öğrenme kapasitesini belirler. Düşük derece değerleri daha basit karar sınırları oluştururken, yüksek derece değerleri daha karmaşık desenleri yakalayabilir. Ancak, derece çok yüksek seçildiğinde model aşırı uyuma (overfitting) meyilli hale gelebilir. Polynomial kernelin etkili kullanımı için Grid Search ile derece, C ve gamma parametrelerinin optimize edilmesi önemlidir.

C Parametresi: C parametresi, modelin esnekliğini belirleyen kritik bir hiperparametredir. Büyük C değerleri, modelin daha az hata kabul etmesini sağlayarak veriye daha sıkı uyum göstermesine neden olur. Bu durum, eğitim verisi üzerinde yüksek doğruluk sağlarken, test verisine genelleme yapma konusunda zorluk çıkarabilir ve aşırı

uyum (overfitting) riskini artırabilir (Cortes & Vapnik, 1995). Öte yandan, küçük C değerleri modelin daha fazla hataya izin vermesine olanak tanır ve karar sınırlarını daha genel hale getirerek genelleme yeteneğini artırabilir. Bu nedenle, C parametresi için doğru dengeyi bulmak, modelin başarımı açısından oldukça önemlidir. Grid Search yöntemi, çapraz doğrulama kullanarak farklı C değerlerini değerlendirerek en uygun değerin belirlenmesine yardımcı olabilir.

Gamma Parametresi: Gamma, bir veri noktasının ne kadar etkili olacağını belirler. Yüksek gamma değerleri, karar sınırlarını daraltarak modele daha fazla esneklik kazandırabilir, ancak aşırı uyum riski doğurabilir (Keerthi & Lin, 2003).

DVM veriye uydurulduğunda w ve b gibi temel parametrelerin ayarlanması otomatik olarak gerçekleştirilse de, sınıflandırıcının doğruluğu büyük ölçüde hiperparametre seçiminden de etkilenebilir. Hiperparametreler, karar fonksiyonunun uyumunu etkileyen ve öğrenme (eğitim) başlamadan önce belirlenen değişkenlerdir. DVM genellikle diğer makine öğrenimi algoritmalarına (örneğin, yapay sinir ağları) kıyasla daha az hiperparametreye sahip olsa da, özellik seçimi sonucu ortaya çıkan herhangi bir “serbest” parametre (örneğin, k -en iyi özellik sayısı, yumuşak marjin sabiti C vb.) genellikle ayarlanması gereken hiperparametreler olarak ele alınır (Ben-Hur & Weston, 2010).

1.6.9. Grid-Search Optimizasyon Yöntemi

Makine öğrenmesi modellerinin performansı, doğru hiperparametre seçimi ile yakından ilgilidir. Hiperparametreler, modelin öğrenme kapasitesini ve genelleme yeteneğini belirleyen kritik unsurlardır. Hiperparametre optimizasyonu, makine öğrenmesi modellerinin performansını artırmak için hiperparametrelerin en uygun kombinasyonlarını belirleme sürecidir. Hiperparametreler, modelin öğrenme sürecini ve genel performansını doğrudan etkileyen ayar değerleridir. Bu optimizasyon süreci çeşitli yöntemlerle gerçekleştirilebilir:

- Izgara arama (Grid Search)
- Rastgele arama (Random Search)
- Bayesçi optimizasyon (Bayesian Optimization)
- Tree-structured Parzen Estimator (TPE)
- Genetik Algoritmalar (Genetic Algorithms)
- Parçacık sürü optimizasyonu (Particle Swarm Optimization)

- Hyperband
- BOHB (Bayesian Optimization and Hyperband)

Kullanılacak yöntem, problemin doğasına, veri büyüklüğüne ve hesaplama kaynaklarına bağlı olarak değişir. En uygun yöntemi seçmek için veri seti ve modelin karmaşıklığı dikkate alınmalıdır.

Grid Search, en uygun hiperparametre kombinasyonunu belirlemek için yaygın olarak kullanılan bir optimizasyon yöntemidir. Bu yöntem, belirlenen hiperparametre aralıklarında sistematik bir arama yaparak, en iyi performans sağlayan kombinasyonu belirlemeye yardımcı olur.

Grid Search, belirli hiperparametrelerin önceden belirlenen değerlerini sistematik olarak dener ve en iyi performans gösteren kombinasyonu belirler (Bergstra & Bengio, 2012). Bu yöntem, hiperparametre uzayının tümünü sistematik olarak tarayarak, belirli bir modelin en iyi performans göstereceği değerleri belirler (Hsu, vd., 2003). Grid Search yöntemi, belirli bir değerlendirme metriği (örneğin doğruluk, F1 skoru veya hata oranı) kullanılarak hiperparametre kombinasyonlarının çapraz doğrulama ile değerlendirilmesine dayanır. Genellikle belirlenen hiperparametre aralıklarında tüm olası kombinasyonlar test edilir ve en yüksek başarıyı sağlayan parametreler seçilir. Ancak, hesaplama maliyeti açısından Grid Search optimizasyonunun büyük veri kümeleri ve geniş hiperparametre aralıklarında yüksek zaman karmaşıklığına sahip olduğu da göz önünde bulundurulmalıdır.

1.6.10. Doğruluk Değerlendirmesi

Doğruluk analizi, sınıflandırma işlemlerinden sonra oluşan sınıfların doğruluklarını belirlemek için yapılan bir işlemdir. Doğruluk analizi yöntemlerinin uygulanabilmesi için ilk gereklilik, üzerinde doğruluk metriklerinin hesaplanacağı sınıflandırılmış çıktı veriye karşılık gelen, eşit boyutlarda bir referans verinin bulunmasıdır. Sonuç ve referans verileri arasında tam bir karşılaştırma yapılmalıdır. Bu karşılaştırma ile tahmin edilen verideki her bir birime (piksel veya nokta) Doğru Pozitif (DP), Doğru Negatif (DN), Yanlış Pozitif (YP) ve Yanlış Negatif (YN) isimli dört etiket verilmektedir. DP, veri içerisinde bir nesnenin türü ve yerinin doğru tespit edilmesi durumunda kullanılan bir etikettir. DN ise nesne içermeyen bir alanın doğru tahmin edilmesi durumunu ifade etmektedir. YP, nesne bulunmayan bir alanda hatalı olarak nesne tespit etme durumunu ifade ederken, YN nesne bulunan bir alanda nesneyi tespit edememe durumudur.

Literatürde Genel Doğruluk (Overall Accuracy/OA), Kesinlik (Correctness/Cr), Duyarlılık (Completeness/Cp), F1-Puanı (F1-Score), Birleşimlerin Kesişimi (Intersection Over Union/IoU) ve Kalite (Quality/Q) doğruluk metrikleri mevcuttur (Denklem 7-12).

Genel Doğruluk: Genel doğruluk oranı, modelin doğru tahmin ettiği örneklerin tüm örneklere oranıdır.

$$OA = \frac{DP + DN}{DP + YP + DN + YN} \quad (7)$$

Kesinlik: Modelin pozitif olarak sınıflandırdığı örneklerin gerçekten doğru olup olmadığını gösterir.

$$Cr = \frac{DP}{DP + YP} \quad (8)$$

Duyarlılık: Modelin, tüm gerçek pozitifleri doğru bir şekilde yakalayıp yakalayamadığını ölçer.

$$Cp = \frac{DP}{DP + YN} \quad (9)$$

Birleşimlerin Kesişimi:

$$IoU = \frac{DP}{DP + YP + YN} \quad (10)$$

Kalite:

$$Q = \frac{DP}{DP + YP + YN} \quad (11)$$


F1 Skoru: Kesinlik ve duyarlılık arasında bir denge sağlayan ölçümdür.

$$F1 = 2 \times \frac{Cr \times Cp}{Cr + Cp} \quad (12)$$

2. YAPILAN ÇALIŞMALAR

Bu tez çalışmasında, kivi ağacına ait yersel LiDAR nokta bulutlarından destek vektör makineleri algoritması kullanılarak kivi meyvesinin otomatik tespiti işlemi gerçekleştirilmiştir. Yapılan çalışma; veri temini, veri seti ön hazırlık aşaması, özellik çıkarımı, DVM eğitimi ve eğitilen DVM' nin testi aşamalarından oluşmaktadır (Şekil 10).





Şekil 10. Çalışma iş akış şeması

Arazide yersel lazer tarayıcı ile elde edilen kivi ağacına ait nokta bulutu verisi öncelikle veri seti ön hazırlık aşamasından geçirilmiştir. Bu aşamada kivi ağacına ait yer noktaları ve gürültü noktaları veri setinden elimine edilmiştir. Bu sayede, parametre yoğunluğunun azaltılmasıyla, bellek kullanımı, iş gücü ve işlem süresi açısından tasarruf sağlanmıştır. Gürültü ve yer noktalarından ayrılan kivi ağacı nokta bulutundaki her bir kivi noktası 1, arka plan ise 2 rakamları ile etiketlenmiştir. Ardından veri seti ön hazırlık aşamasının devamı niteliğindeki bir adım olan, kivi ağacına ait nokta bulutu verisinin 6 parçaya bölünmesi işlemi gerçekleştirilmiştir. Bu işlemin esas amacı eğitim ve test veri setlerinin oluşturulmasıdır. Elde edilen 6 parça nokta bulutundan 2 tanesi DVM eğitimi, geriye kalan 4 tanesi ise eğitilen modelin test işleminde kullanılmak üzere hazır hale getirilmiştir. Eğitim ve test için ayrılan nokta bulutlarının barındırdığı her bir noktanın X, Y ve Z yönlerine ait yüzey normal vektörleri (en yakın 50 komşuya göre) ve RGB (kırmızı, yeşil ve mavi) renk değerleri DVM eğitim ve test aşamasında algoritmaya girdi veri olarak sunulmuştur. Eğitim ve test işlemleri ile 4 adet test kivi ağacı parçasında bulunan kivi meyvelerinin otomatik segmentasyon sonuçları hazır hale gelmiştir. Yüzey normal vektörleri ve RGB renk değerlerinin girdi veri olarak sunulduğu DVM algoritmasının kivi segmentasyonu işlemindeki performansı doğruluk metriklerinden elde edilen sayısal sonuçlar ile belirlenmiştir.

2.1. Çalışma Alanı

Ülkemizde kivi yetiştiriciliğinin en fazla olduğu illerden birisi olan Ordu ili veri temini için uygun görülmüştür. Çalışma alanı olarak Ordu İli Altınordu İlçesi Kökenli Mahallesi'nde bulunan kivi bahçesi çalışma alanı olarak belirlenmiştir (ITRF 3° koordinat sisteminde Y1:402538.99, X1:4530966.58; Y2:402520,95, X2:4530998.03; Y3: 402528.87, X3: 4530999.69; Y4: 402531.02, X4: 4530963.97) (Şekil 11).



Şekil 11. Çalışma alanı uydu görüntüsü

2.1.1. Veri Seti

Tez çalışmasında kullanılan LiDAR nokta bulutları Faro Focus 3D X 130 lazer tarayıcısı ile elde edilmiştir. Tablo 1’de Faro Focus 3D X 130’un teknik özellikleri gösterilmiştir.

Tablo 1. Faro Focus 3D X 130 teknik özellikler (Günen, 2017)

Ölçüm mesafesi	%90 yansıtıcı yüzeylerde iç ve dış ortamlarda 0.6m-130m arası ölçüm
Ölçme hızı (nokta sayısı/saniye)	122000 / 244000 / 488000 / 976000
Ölçüm hatası	±2mm
Çözünürlük	70 mp üstü renk
Düşey/Yatay Ölçüm Açısı	300°/360°
Düşey/Yatay Step size	0.009° (40,960-3D-piksel 360°)
Max düşey ölçüm hızı	5.820 rpm veya 97 Hz
Lazer Sınıfı	Lazer Sınıfı 1
Dalga Boyu	1550 nm
Çıkıştaki Işın Çapı	2.25 mm (1/e)
Tarayıcı Kontrol	Dokunmatik ekran ve WLAN
İki Yönlü Kompensatör	Hassasiyet: 0.015°
	Mesafe: ± 5°
Yükseklik Sensoru	Elektronik Barometre sayesinde rölatif olarak hesaplanan yükseklik taramalara eklenir
GPS	Entegre edilmiş GPS alıcısı
Batarya Ömrü	4.5 saat
Ağırlık	5.2 kg
Boyut	240 x 200 x 100 mm

Tarama sırasında kivi ağacının 360° taranabilmesi için 3 farklı yere hedef noktaları konulmuş ve 2 ayrı noktaya cihaz kurularak ölçüm yapılmıştır (Şekil 12). Ölçüm hassasiyeti 2.3 mm olup toplamda 3904491 nokta elde edilmiştir.



Şekil 12. Çalışmada kullanılan yersel lazer tarayıcı ve hedef noktası


Arazide ölçüm işlemlerinden sonra taranan nokta bulutları “Scene” yazılımında *.las formatında üretilmiştir. Oturumda oluşturulan nokta bulutlarının birbirleriyle örtüşmesi için taranan dosyalar bu hedef noktaları referans alınarak bindirmeli şekilde oluşturulmuştur. Bu işlemler sonucunda 3 boyutlu nokta bulutu elde edilmiştir (Şekil 13).




Şekil 13. Kivi ağacına ait nokta bulutu

2.1.2. Veri Seti Ön Hazırlık Aşaması

Çalışma kapsamında girdi olarak kullanılan nokta bulutları öncelikle *.las formatlı olarak MATLAB yazılımının “Lidar Labeler” uygulamasında görselleştirilmiş ve kivi meyvesi ile kivi dışı objelere (ağaç, dal, yaprak) ait noktaların, kivi (1) ve arka plan (2) olmak üzere etiketleme işlemi gerçekleştirilmiştir.



(a)




(b)


Şekil 14. Etiketleme işlemi

Şekil 14a’ da kiviye ait noktalar, Şekil 14b’de de kivi noktalarının etiketlenmiş hali görülmektedir.

Etiketleme işlemi esnasında perspektife bağlı olarak kivinin arkasında kalan fakat kiviye ait olmayan noktaların kivi olarak etiketlenme sorunu ortaya çıkmıştır. Bu problemin ortadan kaldırılması hususunda etiketleme işleminin yapıldığı “Lidar Labeler” uygulamasında nokta bulutu, *rotate* komutuyla döndürülerek etiketlenen objeye ait olmayan noktalar bulunup *erase* komutuyla temizlenebilmiştir. Şekil 15’ te de görselleştirildiği üzere kivi meyvesinin arkasında bulunan ağaç dalına ait noktalar da kivi noktalarıyla aynı bölgede bulundukları için etiketleme aracı dala ait noktaları da kontrolsüz bir şekilde kivi meyvesi olarak etiketlemiştir.



(a)




(b)

Şekil 15. Etiketleme esnasında kontrolsüz seçilen kivi dışı noktalar

Nokta bulutunda kiviye ait ve kivi-dışı istenmeyen noktaların kontrolsüz şekilde etiketlenmiş hali Şekil 15b’de sunulmuştur.

Zemin noktaları elimine edilen ve manuel olarak kivi (1) - kivi dışı (2) olmak üzere tüm noktaları etiketlenen kivi ağacı Destek Vektör Makinesi eğitiminde etkin bir biçimde kullanılmak üzere “Cloud Compare” programının kullanımıyla 6 parçaya ayrılmıştır (Şekil 16).



Şekil 16. Etiketlenen nokta bulutu verisinin bölünmesi

Şekil 16(a)'da RGB renkleriyle ve 16(b)' de etiketleriyle (mavi renk kivileri, yeşil renk ise kivi dışı noktaları temsil etmektedir) birlikte sunulan kivi ağacı parçaları mevcut son halleri ile DVM eğitime ve test işlemine hazır hale getirilmişlerdir. Kivi ağacının parçalara ayrılması ile elde edilen 3 ve 6 numaralı parçalar DVM eğitiminde, 1,2,4 ve 5 numaralı parçalar ise eğitilen DVM' nin testinde kullanılmak üzere seçilmişlerdir.

Eğitim ve test işleminde kullanılacak kivi ağacı parça nokta bulutlarının bilgileri Tablo 2'de detaylı bir biçimde listelenmiştir.

Tablo 2. Kivi ağacına ait nokta bulutu parçalarının içerdikleri nokta sayıları

Numara	Nokta sayısı	Kivi nokta sayısı	Kivi dışı nokta sayısı
Parça 1 (Test)	558.101	80.060	478.041
Parça 2 (Test)	1.055.475	79.421	976.054
Parça 3 (Eğitim)	357.517	43.331	314.186
Parça 4 (Test)	664.861	8.388	656.473
Parça 5 (Test)	977.795	42.756	935.039
Parça 6 (Eğitim)	185.900	19.027	166.873

2.2. Destek Vektör Makinesi Eğitimi

Destek vektör makinesi eğitiminde kullanılmak üzere nokta bulutlarından direkt olarak elde edilen ve hesaplama vasıtasıyla dolaylı bir şekilde elde edilen parametreler kullanılmıştır. Eğitim işleminde kullanılan parametrelerin seçimi sırasında, çeşitli parametreler ile eğitim işlemi gerçekleştirilmiştir. Bu denemeler sonucunda mevcut veri için en yüksek doğruluklu kivi segmentasyonu işleminin gerçekleştirilmesine olanak tanıyan parametreler seçilmiştir. Bu parametreler; nokta bulutlarında bulunan her bir noktaya ait kırmızı, yeşil, mavi (RGB) renk değerleri ve yine her bir noktanın X, Y, Z koordinat değerlerinden hesaplanan 3 yönlü yüzey normal vektörleridir.

Radyometrik çözünürlüğü 64 bit olan kırmızı, yeşil ve mavi renk değerleri ham nokta bulutunda sunulmuş olup, nokta bulutu verisi içerisinden direkt olarak alınmıştır. Yüzey normal vektörlerinin hesabı ise aşağıdaki işlem adımlarıyla gerçekleştirilmiştir.

- 1) Python' da bulunan Open3D kütüphanesini kullanılarak boş bir Nokta Bulutu nesnesi oluşturulmuştur.
- 2) Numpy formatında yüklenen nokta koordinatları, gerekli fonksiyonların kullanımıyla Vector3dVector fonksiyonu, Open3D formatına dönüştürülerek, daha önce oluşturulan boş Open3D nokta bulutu nesnesine aktarılır. (Bu işlemin yapılma sebebi Open3D kütüphanesinin Numpy formatını desteklemiyor oluşudur.)

- 3) Ardından Open3D kütüphanesinde mevcut KD-Tree algoritması kullanılarak noktaların en yakınındaki 50 komşu nokta yardımıyla her noktanın yüzey normalleri hesaplanmıştır.

Normal vektörleri, yüzeylerin eğimi ve yönelimi hakkında bilgi sağladıkları için bu çalışmada kivi ve kivi dışı nesnelerin yapısını belirlemek adına kullanılmıştır. İlgili parametrelerin DVM' ye girdi veri olarak sunulması ile DVM' nin kivi segmentasyonu işlemi için sınıflandırma performansı göstermesi sağlanmıştır. Özetle eğitim ve test işlemi için Şekil 16' da gösterilen nokta bulutu parçalarındaki her bir noktanın kırmızı, yeşil, mavi renk değerleri ile X, Y ve Z eksenlerindeki yüzey normalleri olmak üzere toplamda 6 parametre sunulmuştur.

Seçimi tamamlanan parametrelerin kullanımıyla, 3 ve 6 numaralı nokta bulutu parçaları birleştirilerek *Standart Scaler (Scikit-learn)* aracılığıyla $[-3,3]$ aralığında ölçeklendirilmiş ve DVM eğitiminin maksimum verim ile tamamlanabilmesi amacıyla en uygun hiperparametrelerin (ayar parametreleri) belirlenmesi hususunda Grid Search optimizasyon algoritması kullanılmıştır. Grid Search yöntemi ile en uygun hiperparametrelerin belirlenmesi adımı algoritmada kullanılması için sunulan parametreler Tablo 3' te listelenmiştir.

Tablo 3. Grid Search optimizasyon algoritmasında kullanılan hiperparametreler


Düzenleme Parametresi (C)	Kernel Ölçeklendirme Parametresi (gamma)	Çekirdek Fonksiyonu (Kernel)
0.1	0.001	linear
1	0.01	rbf
10	0.1	poly
100	1	Sigmoid

Tablo 3'te sunulan parametreler ile Grid Search optimizasyon algoritmasının çalıştırılması sonucu çalışmada kullanılan veri için en uygun hiperparametrelerin C, gamma ve Kernel değerlerinin sırasıyla; 10, 0.1 ve rbf olarak seçilmesi kararına varılmıştır.

Seçimi tamamlanan hiperparametreler kullanılarak veri seti içerisindeki 3 ve 6 numaralı parça nokta bulutlarının kullanımıyla DVM eğitimi gerçekleştirilmiştir. Eğitim sonucu elde edilen doğruluk oranları Tablo 4'te ve görsel sonuçlar ise Şekil 17'de sunulmuştur.

Tablo 4. Destek vektör makinesi eğitimi doğruluk değerleri

Genel Doğruluk	Kesinlik	Geri Çağırma	F1-Skor	Birleşimlerin Kesişimi
0.9520	0.8856	0.8678	0.8761	0.7929



Şekil 17. Eğitim işlemine ait nokta bulutu, etiket ve tahmin sonuçları

2.3. Eğitilen Destek Vektör Makinesinin Testi

Kivi ağacına ait nokta bulutu parçaları (3 ve 6) ile eğitilip kaydedilen DVM modelinin test işlemi 1, 2, 4 ve 5 numaralı parçalar olmak üzere toplamda 4 nokta bulutu parçası ile test edilmiştir. Her bir parçanın test işlemi ayrı ayrı gerçekleştirilmiştir. İlk olarak 1 numaralı parçanın içerisindeki tüm noktalara ait kırmızı, yeşil, mavi renk değerleri ve X, Y, Z yönlerindeki yüzey normalleri, eğitilen DVM modeline girdi olarak sunulmuş ve bu parametreler üzerinden kivi-kivi olmayan noktaların tahminlerinin yapılması sağlanmıştır. Bu işlem tüm test verileri için sırasıyla tekrarlanmıştır.

Elde edilen sonuçlar, manuel olarak etiketleme işlemi yapılan referans veriler ile karşılaştırılarak, Genel Doğruluk, Kesinlik, Geri Çağırma, F1-Skor ve birleşimlerin kesişimi metrikleri, dört adet test verisi için hesaplanmış ve metriklerin sayısal değerleri Bulgular bölümünde sunulmuştur.



3. BULGULAR VE TARTIŞMA

Bu bölümde, yersel LiDAR sistemi ile elde edilen kivi ağacına ait nokta bulutundan DVM yöntemi ile kivi meyvesinin tespiti gerçekleştirilmesine yönelik yapılan tüm uygulamaların sonuçları irdelenip gerekli karşılaştırmalar yapılmıştır.

Tez çalışmasında gerçekleştirilen tüm işlemler, 24 GB RAM ve 1 TB SSD'li, Intel(R) Core (TM) i7-7700HQ CPU 2.80GHz işlemcili bilgisayar ortamında Matlab & Python yazılımları vasıtasıyla gerçekleştirilmiştir.


3.1. Destek Vektör Makinesi ile Kivi Meyvesinin Tespitine Yönelik Sonuçların Değerlendirilmesi

Yersel LiDAR sistemi ile elde edilen kivi ağacı nokta bulutu verisi daha önceki aşamalarda çeşitli veri seti ön hazırlık adımlarından geçirilerek DVM eğitimi ve test işlemleri gerçekleştirilmiştir. Kivi ağacı nokta bulutuna ait RGB değerleri, her bir nokta için hesaplanan X,Y ve Z yönlerindeki yüzey normal vektörlerinin, Destek Vektör Makinesine parametre olarak sunulmasının kivi meyvesinin tespitine yönelik performans incelemesi bu başlık altında yapılmıştır.

Test işlemi sonucunda elde edilen tahminlerin doğruluk oranları ve görsel sonuçları Tablo 5 ve Şekil 18,19,20 ve 21'de sunulmaktadır.


Tablo 5. Test verileri için destek vektör makinesi kivi-kivi dışı nokta tahmini doğruluk değerleri

Doğruluk Metriği	Parça 1	Parça 2	Parça 4	Parça 5
Genel Doğruluk	0.9211	0.9401	0.9810	0.9797
Kesinlik	0.8580	0.7786	0.6938	0.8768
Geri Çağırma	0.8013	0.8583	0.9347	0.8829
F1-Skor	0.8259	0.8120	0.7656	0.8798
Birleşimlerin Kesişimi	0.7242	0.7127	0.6757	0.8027



Şekil 18. 1 numaralı parça için kivi-kivi dışı noktaların tahmini


Şekil 18’ de 1 numaralı parçanın referans verisi ile DVM ile elde edilen kivi-kivi dışı segmentasyon sonucu karşılaştırmalı olarak sunulmuştur. Sonuç görsel incelendiğinde eğitilen DVM algoritmasının kivi yoğunluğu olan bölgeleri doğru bir şekilde sınıflandırdığı gözlemlenmiştir. Fakat dal ve yapraklara ait bazı bölgelerin, seyrek gürültü noktası biçiminde, kivi olarak sınıflandırıldığı gözlemlenmektedir. Genel hatları ile yorumlandığında RGB renkleri ve yüzey normal vektörleri ile eğitilen DVM’ nin 1 numaralı parça için başarılı bir kivi-kivi dışı segmentasyonu işlemi gerçekleştirdiği gözlemlenmektedir.



Şekil 19. 2 numaralı parça için kivi-kivi dışı noktaların tahmini

Şekil 19 'da 2 numaralı referans verisi ve DVM sınıflandırma sonucu görülmektedir. Orta kısımda işaretli, kivi nokta yoğunluğu fazla olan kivi topluluğunda, kiviler net bir şekilde göz ile ayırt edilememesine rağmen eğitilen DVM algoritmasının bu kivileri başarılı bir şekilde sınıflandırdığı gözlemlenmektedir. Parça 2 için yapılan kivi-kivi dışı noktaların segmentasyonunda da yaprakların kurumuş kısımlarının ve dalların bazı bölgelerinin DVM tarafından kivi noktası olarak sınıflandırdığı gözlemlenmektedir. Orijinal renkli görsel incelendiğinde bu negatif durumun; dal, yaprak ve kivi meyvelerinin


birbirlerine çok benzer RGB renk değerlerine sahip olmasının sebep olduğu yorumu yapılabilmektedir.



Şekil 20. 4 numaralı parça için kivi-kivi dışı noktaların tahmini

Şekil 20’ de bulunan 4 numaralı parçada kivi noktalarının diğer parçalara göre daha az bulunduğu gözlemlenmektedir. Ağaca ait parçada mevcut kivilerin yoğun olduğu bölgelerin DVM ile doğru bir şekilde sınıflandırıldığı gözlemlenmektedir. Fakat diğer

parçalarda da olduğu gibi kivi dışı noktaların gürültü şeklinde kivi noktası olarak hatalı bir biçimde sınıflandırıldığı gözlemlenmektedir.



Şekil 21. 5 numaralı parça için kivi-kivi dışı noktaların tahmini

Şekil 21’ de gösterilen 5 numaralı parçanın kivi-kivi dışı noktalarının yoğun olduğu gözlemlenmektedir. Orijinal renkli nokta bulutu görseli incelendiğinde kivi, kurumuş yaprak ve dalların RGB renk değerlerinin birbirine çok yakın olduğu gözlemlenmektedir. Fakat buna rağmen eğitilen DVM algoritması kivileri başarılı bir şekilde segmente etmiştir. Hatalı olarak sınıflandırılan noktalar göz ardı edilebilecek kadar azdır. Ortaya çıkan hatalı

tahminlerin, referans veriler için yapılan manuel etiketleme aşamasında yapılan hatalı etiketleme işlemlerinin de sebep olduğu düşünülmektedir.

Genel olarak test için kullanılan nokta bulutu parçaları ile ortaya çıkarılan sonuçlar; RGB renk değerleri ve yüzey normal vektörleri ile eğitilen DVM' nin kivi meyvelerinin tespitinde gözle görülür düzeyde başarı sağladığını ortaya çıkarmaktadır.



4. SONUÇLAR

Yüksek lisans tez çalışması kapsamında Yersel LiDAR sistemi ile arazi ortamında alımı gerçekleştirilen kivi ağacı üzerinden Destek Vektör Makinesi yöntemi ile kivi meyvelerinin tespiti işlemi gerçekleştirilmiştir. Yapılan çalışmada sentetik veri kullanılmaksızın, belirlenen çalışma alanı kapsamında gerçek arazi ortamından elde edilen verilerin kullanılması yapılan çalışma için bir özgün değer sağlamaktadır. Ayrıca literatürde kivi meyvesinin tespitine yönelik yapılmış bir çalışma bulunmaması, bu tez çalışmasının ağaç üzerinden kivi meyvesinin tespitine yönelik yapılan ilk çalışma olması sebebiyle literatüre önemli bir katkı sağlayacaktır.

Tez çalışmasında, çalışma bölgesinden elde edilen kivi ağacı nokta bulutunun eğitim ve test veri setlerine ayrılarak Destek Vektör Makinesinin ağaç üzerinde bulunan kivi meyvelerinin tespitine yönelik performansı değerlendirilmiştir. Destek Vektör Makinesine girdi parametre olarak nokta bulutundaki noktaların RGB değerleri ve her bir noktanın X,Y,Z yönlü yüzey normal vektörleri sunulmuştur. Eğitim işlemi için seçilen 2 parça nokta bulutu verisinin girdi parametreleri ve Grid Search optimizasyon algoritması yardımıyla elde edilen hiperparametreler vasıtasıyla DVM' nin eğitimi; Genel Doğruluk, Kesinlik, Geri Çağırma, F1-Skor ve Birleşimlerin Kesişimi için sırasıyla 0.95, 0.88, 0.86, 0.87 ve 0.79 doğruluk oranları ile tamamlanmıştır. Eğitilen DVM ile 4 parça nokta bulutu üzerinden kivi-kivi dışı objelerin tahmin işlemi gerçekleştirilmiştir. İlgili test işlemi için ortalama Genel Doğruluk, Kesinlik, Geri Çağırma, F1-Skor ve Birleşimlerin Kesişimi doğruluk değerleri; 0.95, 0.80, 0.86, 0.82 ve 0.73 olmak üzere hesaplanmıştır.

Elde edilen görsel ve sayısal sonuçlar üzerine RGB değerleri ve X,Y,Z yönlü yüzey normal vektörlerinden oluşan 6 parametre ile eğitilen Destek Vektör Makinesinin kivi meyvesi tespitindeki başarısı ortaya konulmuştur. Sonuç olarak gerçekleştirilen çalışma, tarımda otomasyonun gelişmesi ve rekolte tahmini gibi tarımsal uygulamaların gerçekleştirilmesi adına büyük önem taşımaktadır.

5. ÖNERİLER

Yersel LiDAR sistemi ile arazi ortamında alımı gerçekleştirilen kivi ağacı üzerinden Destek Vektör Makinesi yöntemi ile kivi meyvelerinin tespiti işlemi büyük oranda başarılı bir biçimde gerçekleştirilmiştir. Fakat yapılan çalışmada kivi meyve noktalarının tespiti yapılırken gürültü şeklinde hatalı olarak tahmin edilen kivi noktaları ve kivi dışı noktalar ortaya çıkmıştır. Bu durumu düzeltebilmek ve daha verimli, doğru sonuçlar alabilmek adına gürültü noktaları şeklinde etiketlenen hatalı noktaların etiketleri giderilmelidir. Bu işlem gerçekleştirilirken bir bölgede hangi etiketin çoğunlukta olduğu durumu dikkate alınmalıdır.

Ayrıca yapılan çalışmanın genelleştirilebilirlik düzeyinin artırılması hususunda farklı bölgelerden, farklı boyutlarda yetişen kivilere sahip, ağaçların nokta bulutlarının elde edilmesi ve eğitim ve test veri setlerine eklenmesi önem arz etmektedir.

Gerçekleştirilen tez çalışmanın gelişime açık bir diğer yönü ise Destek Vektör Makinesi eğitiminde kullanılan parametrelerdir. Bu çalışmada RGB renk değerleri ve X,Y,Z yönlü yüzey normal vektörleri olmak üzere 6 parametre kullanılmıştır. Parametre sayısına doğru parametreler ile katkı sağlanması çalışmanın doğruluk ve genelleştirilebilirlik düzeyine katkı sağlayacaktır.

Yapılan gözlemler ve araştırmalar sonucunda elde edilen tecrübeler ile oluşturulan önerilerin sağlanması durumunda düzensiz bir veri yapısı olan ağaç nokta bulutlarından makine öğrenme yöntemleri ile meyvelerin çıkarılması hususunda istenilen başarı ve hedeflenen amaçların ulaşılabilirliği sağlanacaktır.

6. KAYNAKLAR

- Altuntaş, C. & Yıldız, F. (2008). Yersel Lazer Tarayıcı Ölçme Prensipleri ve Nokta Bulutlarının Birleştirilmesi, *Jeodezi, Jeoinformasyon ve Arazi Yönetimi Dergisi*, 98, 20-27.
- Baltsavias, E. P. (1999). Airborne laser scanning: Basic relations and formulas. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54(2-3), 199-214.
- Ben-Hur, A., & Weston, J. (2010). A user's guide to support vector machines. *Methods in Molecular Biology*, 609, 223-239
- Bergstra, J. & Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 13, 281-305.
- Besl, P. J. & Jain, R. C. (1988). Segmentation through variable-order surface fitting. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 10(2), 167-192.
- Bhargava, A. & Bansal, A. (2019). Automatic detection and grading of multiple fruits by machine learning. *Food Anal Methods*, 13, 751–761.
- Brenner, C. (2005). Building Reconstruction From Images and Laser Scanning. *International Journal of Applied Earth Observation and Geoinformation*, 6, 187-198.
- Burges, C. J. C. (1998). A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, 2(2), 121-167.
- Champion, N., Rottensteiner, F., Matikainen, L., Liang, X., Hyypä, J. & Olsen, B. P. (2009). A Test of Automatic Building Change Detection Approaches. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 38, 145-150.
- Cortes, C. & Vapnik, V. (1995). Support vector networks. *Machine Learning*, 20(3), 273-297.
- Cristianini, N. & Shawe-Taylor, J. (2000). *An introduction to support vector machines and other kernel-based learning methods*. Cambridge: Cambridge University Press.
- Dorj, U.O., Lee, M. & Yun, S., 2017. An yield estimation in citrus orchards via fruit detection and counting using image processing. *Computers and Electronics in Agriculture*, 140, 103–112.
- Elkhrachy, I. & Niemeier, W. (2006). Optimization And Strength Aspects For Geo-Referencing Data With Terrestrial Laser Scanner Systems, *3rd IAG/12th FIG Symposium*, Baden.

- Ge, L., Zou, K., Zhou, H., Yu, X., Tan, Y., Zhang, C., & Li, W. (2021). Three dimensional apple tree organs classification and yield estimation algorithm based on multifeatures fusion and support vector machine. *Information Processing in Agriculture*, 9, 431-442.
- Glennie, C. L. (2007). Rigorous 3D error analysis of kinematic scanning LIDAR systems. *Journal of Applied Geodesy*, 1(3), 147-157.
- Günen, M.A. (2017). *Nokta Bulutu Filtreleme Algoritmalarının Karşılaştırılması*, E.R.Ü., Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Kayseri.
- Hao, Z., Zhang, Y., Liu, J. & Ji, S., (2009). Automatic Building Detection Using Airborne LiDAR Data. *International Forum on Information Technology and Applications*, 3, 668-671.
- Henry, P., Krainin, M., Herbst, E., Ren, X., & Fox, D. (2012). *RGB-D mapping: Using depth cameras for dense 3D modeling of indoor environments*. *International Journal of Robotics Research*, 31(5), 647-663.
- Hommel, M. (2009). Verification of A Building Damage Analyses and Extension To Surroundings of Reference Buildings. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 38(3), 18- 23.
- Hsu, C.W., Chang, C.C.& Lin, C.J. (2003). A Practical Guide to Support Vector Classification. *Technical Report; Department of Computer Science and Information Engineering, University of National Taiwan*, s. 1396–1400.
- Jakkula V. (2013). Tutorial on Support Vector Machine (SVM). *Washington State University*, 1–13
- Keerthi, S. S., & Lin, C. J. (2003). Asymptotic behaviors of support vector machines with Gaussian kernel. *Neural Computation*, 15(7), 1667-1689.
- Kulkarni, U.V. & Shinde, S.V. (2013). Neuro-fuzzy classifier based on the Gaussian membership function. *4th International Conference on Computing, Communications and Networking Technologies*, s. 1–7. Tiruchengode.
- Lichti, D.D. & Gordon, S.J. (2004). Error Propagation in Directly Georeferenced Terrestrial Laser Scanner Point Clouds for Cultural Heritage Recording, *Proceedings of FIG Working Week*, Athens.
- Mahmoudi, A., Takerkart, S., Regragui, F., Boussaoud, D., & Brovelli, A. (2012). Multivoxel pattern analysis for fMRI data: A review. *Computational and Mathematical Methods in Medicine*. 1-14.
- Mitra, N. J., Nguyen, A. & Guibas, L. (2004). Estimating surface normals in noisy point cloud data. *International Journal of Computational Geometry & Applications*, 14, 261-276.

- Nosseir, A. & Ahmed S.E.A. (2019). Automatic Classification for Fruits Types and Identification of Rotten Ones using k-NN and SVM. *International Journal of Online and Biomedical Engineering (iJOE)*, 3, 47–61
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O. & Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825-2830.
- Pisner, D.A. & Schnyer, D.M. (2020). Support vector machine. *Academic Press: Cambridge*, 6, 101–121.
- Remondino, F. (2011). Heritage recording and 3D modeling with photogrammetry and 3D scanning. *Remote Sensing*, 3(6), 1104-1138.
- Rottensteiner, F. (2003). Automatic Generation of High-Quality Building Models From LiDAR Data. *IEEE Computer Graphics and Applications*, 23(6), 42-50.
- Rusu, R. B. & Cousins, S. (2011). 3D is here: Point cloud library (PCL). *IEEE International Conference on Robotics and Automation (ICRA)*, s. 1-4. Shanghai.
- Schnyer, D. M., Clasen, P. C., Gonzalez, C., & Beevers, C. G. (2017). Evaluating the diagnostic utility of applying a machine learning algorithm to diffusion tensor MRI measures in individuals with major depressive disorder. *Psychiatry research. Neuroimaging*, 264, 1-9.
- Schölkopf, B., & Smola, A. J. (2002). *Learning with kernels: Support vector machines, regularization, optimization, and beyond*. Cambridge: MIT Press.
- Shan, J., & Toth, C. K. (Eds.). (2018). *Topographic laser ranging and scanning: Principles and processing*. Boca Raton: CRC press.
- Somvanshi, M., Chavan, P., Tambade, S. & Shinde, S.V. (2016). A review of machine learning techniques using decision tree and support vector machine. *International Conference on Computing Communication Control and Automation (ICCUBE)*, s. 1–7. Pune.
- Sotoudeh, H., Shafaat, O., Bernstock, J. D., Brooks, M. D., Elsayed, G. A., Chen, J. A., Szerip, P., Chagoya, G., Gessler, F., Sotoudeh, E., Shafaat, A., & Friedman, G. K. (2019). Artificial intelligence in the management of glioma: Era of personalized medicine. *Frontiers in Oncology*, 9(768), 1-11.
- Thrun, S. (2002). Robotic mapping: A survey. *Exploring Artificial Intelligence in the New Millennium*, 1-35.
- URL-1. (2025, Şubat 10). Makine Öğrenimi Çalışma Prensibi:
<https://www.turhost.com/blog/deep-learning-nedir/#serp> adresinden alınmıştır.
- URL-2. (2025, Şubat 12). Standart Ölçekleyici:
<https://scikitlearn.org/stable/modules/generated/sklearn.preprocessing.StandardScaler.html> adresinden alınmıştır.

- V. Vapnik (1995). *The Nature of Statistical Learning Theory*. New York: Springer
- Vosselman, G. & Maas, H. G. (2010). *Airborne and terrestrial laser scanning*. Boca Raton: CRC Press.
- Vosselman, G. (2000). Slope Based Filtering of Laser Altimetry Data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 33, 935-942.
- Vosselman, G. (2009). *Advanced Point Cloud Processing*. D.Fritsch (Ed.), *Photogrammetric Week*, s. 137-146. Heidelberg.
- Wang, G., Pu, P., & Shen, T. (2020). An efficient gene bigdata analysis using machine learning algorithms. *Multimedia Tools and Applications*, 79(15-16), 9847–9870.
- Wang, J. J., Zhao, D., Ji, W., Tu, J. J., & Zhang, Y. (2009). Application of Support Vector Machine to Apple Recognition using in Apple Harvesting Robot. *International Conference on Information and Automation, Proceedings of the 2009 IEEE*, s. 1110-1115. Zhuhai.
- Wehr, A. & Lohr, U. (1999). Airborne laser scanning an introduction and overview. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54(2-3), 68-82.
- Xue, H., Sun, S., Venkataramani, G., & Lan, T. (2019). Machine Learning-Based Analysis of Program Binaries: A Comprehensive Study. *IEEE Access*, s. 65889–65912.
- Yang, X., Zhang, R., Zhai, Z., Pang, Y. & Jin, Z. (2019). Machine learning for cultivar classification of apricots (*Prunus armeniaca* L.) based on shape features. *Scientia Horticulturae*, 256.
- Zhang, C., Zhang, K., Ge, L., Zou, K., Wang, S., Zhang, J., & Li, W. (2021). A method for organs classification and fruit counting on pomegranate trees based on multi-features fusion and support vector machine by 3D point cloud. *Scientia Horticulture*, 278.
- Zhang, Y., Wang, H., Lin, G., Nicholas, V.C.H., Shen, Z., Miao, C. (2021). StarNet: Style-Aware 3D Point Cloud Generation. *Journal of Latex Class Files*, 14(8), 1-10.

ÖZGEÇMİŞ

Gültekin Erbaş ilk, orta ve lise öğretimini Giresun’ da tamamladı. 2009 yılında Karadeniz Teknik Üniversitesi Mühendislik Fakültesi Harita Mühendisliği bölümünde lisans eğitimine başladı. 2014 yılında aynı bölümden mezun oldu. Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim dalında tezli yüksek lisans programına başladı. 2016 yılında Giresun Belediyesi’ nde Harita Mühendisi olarak çalışmaya başladı. Halen görevine devam etmektedir. Evli ve bir çocuk babasıdır.

