



Makale / Research Paper

Nokta Bulutu Verisi Kullanılarak Elma Bahçesinden Meyve Tespiti

Mehmet Akif GÜNEN^{1,2a}

¹Erciyes Üniversitesi Harita Mühendisliği Bölümü, Mühendislik Fakültesi, Kayseri, TÜRKİYE

²Gümüşhane Üniversitesi Harita Mühendisliği Bölümü, Mühendislik ve Doğa Bilimleri Fakültesi, Gümüşhane, TÜRKİYE

akif@erciyes.edu.tr

Received/Geliş: 04.07.2021

Accepted/Kabul: 24.11.2021

Öz: Meyvelerin gelişim süreci boyunca sağlığının izlenmesi, otomatik hasat edilmesi ve rekolte tahmini gibi tarımsal yönetim uygulamalarının gerçekleştirilebilmesi için meyvelerin mekânsal konumlarının tespit edilmesi hassas tarım uygulamaları açısından önemlidir. Meyvecilikte modern çözümler geliştirmek, meyve bahçelerinin karmaşık geometrisi nedeniyle zordur. Meyve tespiti konusunda gerçekleştirilen çoğu çalışma görüntü analizine dayanmaktadır. Bu çalışmada Fuji elma bahçesine ait fotogrametrik olarak üretilen nokta bulutu kullanılmıştır. Elmaların mekânsal konumlarının tespit edilmesi için yeni bir çerçeve önerilmiştir. Önerilen çerçevede en uygun komşuluğun belirlenmesi için Omnivaryans tabanlı bir yaklaşım kullanılmıştır. En uygun komşuluk sayısı belirlendikten sonra her bireysel noktadan 30 adet 2 boyutlu ve 3 boyutlu geometrik özellik çıkarılmıştır. Ardından, veri setini en iyi temsil eden özellikler Minimum artıklık maksimum ilgililik yöntemi kullanılarak seçilmiştir. Farklı özelliklerin elma belirleme üzerine etkisinin incelenmesi için ilgili özellikler ağırlık düzeyine göre altı farklı gruba ayrılarak istatistiksel ve görsel karşılaştırmaları gerçekleştirilmiştir. Destek vektör makine kullanılarak yapılan sınıflandırma işleminin sonuçlarına göre 25 özelliğin kullanılması (%95.81 doğruluk ve %93.20 kesinlik) en yüksek sınıflandırma performansını sağlamıştır. Bütün veya sınırlı sayıda özelliklerin kullanılması sınıflandırma performansını azalttığı belirlenmiştir. Ayrıca, 2 boyutlu özelliklerin 3 boyutlu özellikler kadar etkili olduğu görülmüştür.

Anahtar kelimeler: Elma belirleme, Nokta bulutu, özellik çıkarımı, özellik seçimi, sınıflandırma

Fruit Detection from Apple Orchard Using Point Cloud Data

Abstract: In precision agriculture applications, it is critical to determine the spatial location of fruits in order to perform agricultural management applications such as monitoring fruit health throughout the development process, automatic harvesting, and yield estimation. Due to the complex geometry of orchards, developing modern solutions in orchards is difficult. The majority of fruit detection research is based on image analysis. A photogrammetrically produced point cloud from a Fuji apple orchard was used in this study. To detect the spatial positions of apples, a new framework has been proposed. In the proposed framework, an Omnivariance-based approach was used to determine the most suitable neighborhood. After determining the most suitable size of neighborhoods, 30 2D and 3D geometric features were extracted from each individual point. Then, the features that best represent the data set were selected using the minimum redundancy maximum relevance method. In order to examine the effects of different features on apple detection, the related features were divided into six different groups according to their weight level and statistical and visual comparisons were made. According to the results of the classification process using a support vector machine, the use of 25 features (95.81% accuracy and 93.20% precision) provided the highest classification performance. It has been determined that the use of all or a limited number of features reduces the classification performance. In addition, 2D features were found to be as effective as 3D features.

Keywords: Apple detection, Point cloud, feature extraction, feature selection, classification

1. Giriş

Tarım; kısıtlamaları, özel çalışma koşulları ve yoğun iş gücü gerektiren bir sektördür. Dünya nüfusundaki artışla birlikte artan gıda ihtiyacı sürdürülebilir tarımın önemini gün geçtikçe

Bu makaleye atıf yapmak için

Günen, M. A., "Nokta Bulutu Verisi Kullanılarak Elma Bahçesinden Meyve Tespiti" El-Cezeri Fen ve Mühendislik Dergisi 2022, 9 (1); 253-265.

How to cite this article

Günen, M. A., "Fruit Detection from Apple Orchard Using Point Cloud Data" El-Cezeri Journal of Science and Engineering, 2022, 9 (1); 253-265

ORCID ID: "0000-0001-5164-375X"

artmasına neden olur. Özellikle kentsel nüfusun artmasına bağlı olarak kalifiyeli işçi oranının düşmesi ve girdi maliyetlerinin yükselmesi çiftçiler üzerine ek bir yük getirmektedir. Kırsal alanların azalmasına bağlı olarak tarım alanların dar alanlarda yapılıyor olması, iklimsel değişiklikler, artan gübre ve ilaç masrafı üretici girdi maliyetlerini yükselttiğinden dolayı birim alandan elde edilecek ürünün arttırılmasını zorunlu hale getirmektedir [1, 2]. Tüm bu nedenlerden dolayı tarımsal sürecin verimli, kaliteli ve hassas yönetilmesi için teknolojinin getirdiği yeni teknik ve yöntemlerin tarımsal alanlarda uygulanmasını kaçınılmaz hale getirmiştir. Hassas tarımın uygulama alanları öncelik olarak genellikle emtia bitkileri ile sınırlandırılmıştır. Ancak, meyvecilik için çözümler geliştirmek, diğer ürünlere kıyasla meyve bahçelerinin karmaşık geometrisi nedeniyle zorlu olmuştur. Otomasyon tekniklerini farklı tipteki mahsuller için genelleştirmek zor olduğundan, araştırmalar çoğu zaman mahsule özel sistemlere odaklanmışlardır [2, 3]. Bu amaçla geliştirilen robotik sistemler tarımsal ürünlerin hasat edilmesinde kullanımının yanı sıra rekolte haritalarının oluşturulması için kullanımı gün geçtikçe artmaktadır. Meyve yetiştiriciliğinde rekolte tahmini üreticilere verimi artırma noktasında faydalı bilgiler sağlamaktadır. Meyve ağaçlarında rekolte tahmini genellikle örneklem olarak seçilen bireysel ağaçlardan el ile sayım ile gerçekleştirilmektedir. Rekolte tahmininin doğru tahmin edilmesi, çiftçi, sanayici ve kamu kurumları açısından pazarlama, depolama ve lojistik ağlarının nitelikli kurulması açısından oldukça önemlidir. Tarımsal stratejilerin kurulmasında hasat öncesi rekolte tahmini iç ve dış piyasa fiyatının belirlenmesini sağlayarak ihracat/ithalat dengesinin oluşmasını sağlar. Meyvecilikte, meyvelerin hasta bölgelerinin, boyutlarının, şekillerinin ve sağlıklı olanların otomatik olarak tespit edilerek gübreleme, aşılama ve sulamanın etkili ve hızlı gerçekleştirilmesi için ürünlerin mekânsal konumlarının belirlenmesi önemlidir. Nitekim otomatik toplama ve paketlenme süreçlerinin gerçekleştirilmesinde robotik sistemler girdi olarak mekânsal meyve bilgileri kullanmaktadır. Mekânsal alanlarda elde edilen verilerin otomatik analizi, fotogrametri, uzaktan algılama, bilgisayarlı görü ve robotik uygulamalarda yoğun olarak çalışılan bir konu haline gelmiştir. [4-9].

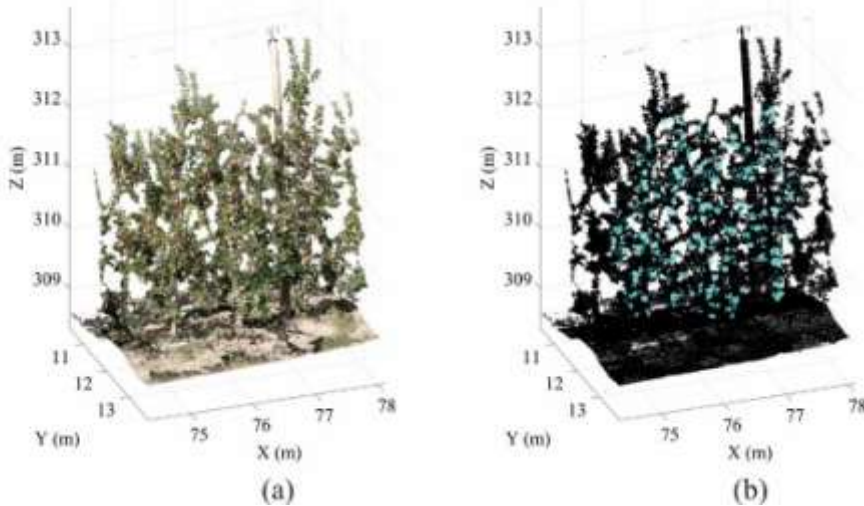
Tarım ürünlerine ait 2 boyutlu (2B) / 3B verilerin yakalanmasında farklı tipte sensörler (RGB, termal, multi-spektral, hiper-spektral, RGB-D kameralar veya LIDAR sensörler) kullanılmaktadır. Yakalanan veriler görüntü veya nokta bulutu tabanlı yaklaşımlarla işlenerek anlamlı veriler oluşturulmaktadır. Ancak, görüntü tabanlı yaklaşımlarda karmaşık aydınlatma ve değişken çevresel koşullar meyve tespitini zorlu bir görev haline getirmektedir. RGB sensörler ucuz ve erişimi nispeten kolay olduğu için elma belirleme çalışmalarında diğer görüntüleme sistemlerine göre daha fazla tercih edilmektedir. Wang, ResNet-50 derin öğrenme modelini değiştirerek, elmaların büyümelerini büyüme dönemi boyunca RGB kamera ve kalibrasyon topları ile izlemiştir [10]. Lawal yaptığı çalışmada RGB kamera ile elde edilen görüntülerle YOLOMuskmelon derin öğrenme modeli ile meyve tespitini gerçekleştirmiştir [11]. Gan ve arkadaşları gerçekleştirdikleri çalışmada termal kamera görüntüsünü kullanmışlardır. Narenciye meyvesinin tespit edilmesinde Faster R-CNN ve Single Shot Multibox Detector yöntemlerinin sonuca etkisini istatistiksel olarak karşılaştırmışlardır [12]. Termal görüntülerin kullanıldığı [13]'de portakal hasadı için meyve tespitini iyileştirmeye yönelik termal zamansal değişim üzerine bir çalışma sunulmuştur. Sa ve arkadaşları yaptıkları çalışmada multi-spektral görüntüler (RGB ve yakın kızılötesi) kullanarak kavun, tatlı biber ve elma gibi meyve/sebzeleri belirlemişlerdir [14]. Başka bir çalışmada 369–1042 nm aralığındaki hiper-spektral kameranın kullanılarak üç farklı narenciye çeşidinin meyveleri bölütleme yöntemi kullanılarak belirlenmiştir [15]. Stajenko ve arkadaşları RGB ve termal görüntülere kümeleme, Hough dönüşümü, renk eşikleme, şekil analizi, N-Cut algoritması ve yerel ikili modeller gibi görüntü işleme teknikleri uygulayarak meyveleri ve ağaç gövdesini birbirinden ayrılmış ve ağaçtaki toplam meyve sayısını belirlemişlerdir [16]. Son yıllarda, nesne yüzeylerinin ölçülen karşılığını temsil eden örneklenmiş 3 boyutlu (3B) nokta bulutları biçimindeki verilerin analizine özel bir önem verilmiştir. Teknolojik gelişmelere bağlı olarak bilgisayar sistemlerindeki grafik işlemcilerin güçlenmesi hızlı, etkili ve verimli sonuç ürünü elde etmenin önünü açmıştır. Yakalandığı sistemden bağımsız olmak üzere 3B veriler elde edildikten sonra, farklı sınıf etiketlerine göre otomatik veya el ile anlamlı nokta bulutu etiketlenmesinin gerçekleştirilmesi için

nokta bulutunun sınıflandırılması gerekir. İlgili sınıflandırma işlemi farklı uygulama çalışmalarında kullanılmaktadır. Xbox 360° Kinect RGB-D sensörünün kullanıldığı çalışmada kırmızı ve iki renkli elma türlerinin tespiti ve konumlandırılması gerçekleştirilmiştir [17]. Zhang ve arkadaşları RGB-D kamera kullanarak iki farklı elma çeşidine ait görüntüler kullanarak eğittikleri derin öğrenme modeli tabanlı elma algılama ve toplama robotu geliştirmişlerdir [18]. Tsoulas ve arkadaşları yaptıkları çalışmada yersel lazer tarayıcı ile elma bahçesinden üretilen nokta bulutundan geometrik ve radyometrik özellikler çıkartarak elma şekli tespiti yapmışlardır [19]. Ayrıca, hareketten yapıya tekniğini kullanarak oluşturulan yoğun nokta bulutu ile meyve tespiti günümüzde artık yaygın olarak kullanılmaktadır [20-23].

Literatürde yapılan çalışmalar incelendiğinde meyve tespiti çeşitli görüntü işleme teknikleri kullanılarak veya nokta bulutundan üretilen özelliklerin sınıflandırılmasıyla gerçekleştirildiği görülmektedir. Sınıflandırma işleminin gerçekleştirilmesi için genel olarak derin öğrenme tabanlı yaklaşımlar tercih edilmektedir ancak derin öğrenme tabanlı yaklaşımlar yüksek kapasiteli donanım gerektirmesi ve görece yavaş çalışmasından dolayı dezavantajlıdır. Ayrıca, doğrudan görüntülerin kullanıldığı çalışmalarda görüntü işleme sürecinde kullanılan eşik değer gibi kullanıcı tanımlı parametreler uzman deneyimi gerektirmektedir ve 3B elma konumunun belirlenmesine imkân sağlamamaktadır. Bu çalışmada Fuji elmalarının 3B konumlarının belirlenmesi için hareketten yapıya yöntemi ile elde edilen yoğun nokta bulutu kullanılmıştır. Gerçek veri seti kullanılarak gerçekleştirilen çalışmada adaptif en yakın komşu sayısı belirlemek için Omnivaryans metriği kullanılmıştır. Robotik hasat işleminde hareketten yapıya tekniği ile üretilen nokta bulutundan elma konumlarının belirlenmesinde adaptif komşu sayısı belirlenerek elde edilen en uygun komşu sayısına göre 3B/2B geometrik özellik çıkarımının gerçekleştirildiği ve bu özelliklerden sınıflandırma performansını arttıranların seçildiği çalışma sayısı oldukça kısıtlıdır. Literatürde yapılan çalışmalarda elma tespiti için Omnivaryans tabanlı komşu sayısı belirleme yönteminin kullanıldığı çalışma yoktur. Optimum komşu sayısı belirlendikten sonra ilgili en yakın noktalara dayalı 30 farklı 2B/3B öznitelik oluşturulmuştur. Farklı özniteliklerin elma belirleme problemine etkisinin incelenmesi için Minimum Artıklık Maksimum İlgililik (MAMI) yöntemi ile belirlenen ağırlıklarına göre sıralanmış ve en fazla ağırlığa sahip özelliklerden altı farklı öznitelik seti oluşturulmuştur. Daha sonra nokta bulutunu temsil eden her bir özellik seti destek vektör makineleri (DVM) ile sınıflandırılarak Fuji elmalarının konumları belirlenmiştir.

2. Veri Seti

Bu çalışmada Mola ve arkadaşları tarafından oluşturulan hareketten yapıya fotogrametrisi ile oluşturulan Fuji (*Malus domestica* Borkh. cv. Fuji) elma veri seti kullanılmıştır [20].



Şekil 1. a) Renkli nokta bulutu, b) Referans nokta bulutu

Bütün veri seti nokta bulutu ve görüntü işleme temelli elma belirlemeye yönelik veriler sunmaktadır ancak bu çalışmada de yalnızca 3B nokta bulutu verisi kullanılmıştır. Kullanılan veride, 582 ham görüntüden farklı bakış ve güzergâhtan yakalanan görüntüler ve 11 elma ağacının 3 boyutlu nokta bulutu yer almaktadır. Elde edilen nokta bulutu geo-referanslandırılmış ve .txt formatında kaydedilmiştir. Oluşturulan nokta bulutu 8 bit olarak 0-255 aralığında renkli olarak sunulmuştur (Şekil 1.a). Şekil 1.b.'da gösterilen referans veri seti el ile Cloud Compare yazılımı kullanılarak etiketlenmiştir. 11 ağacın 3 tanesi eğitim (433 adet), 8 tanesi (1022 adet) ise test için olmak üzere 1455 adet elmadan oluşmaktadır. Ancak nokta bulutu verisini işleme süreci daha sonraki bölümlerde anlatıldığı üzere iş yükü ve maliyet gerektirdiğinden bu çalışmada örneklenen eğitim veri seti yaklaşık %30 test ve %70 eğitim olarak ikiye ayrılarak kullanılmıştır. Şekil 1.a'da kullanılan renkli nokta bulutu Şekil 1.b'de ise referans veri seti vardır. Turkuaz ile gösterilen elma sınıfını temsil ederken, siyah ile gösterilen diğer sınıfları temsil etmektedir.

3. Metot

Çeşitli nesnelere arasında, özellikle ağaçlardaki meyvelerin mekânsal konumlarının belirlenmesi ekonomik, çevresel ve sağlık açısından önemli bir rol oynamaktadır. Bu çalışmada bireysel elmaları 3B nokta bulutundan belirlenmesi üzerine odaklanılmıştır. Önerilen çerçeve (Şekil 2) 1) adaptif komşu sayısı seçimi, 2) bireysel 3B noktalar için belirlenen en uygun komşu sayısına göre özellik çıkarımı, 3) elma sınıfını en iyi belirlemeyi sağlayan özelliklerin seçimi ve 4) danışmalı sınıflandırma aşamalarından oluşmaktadır. Uygulamalar Windows 7 işletim sistemi, Quadro K5000 ve Tesla k20 ekran kartı, 2.50 GHz ve 64 GB RAM'e sahip iş istasyonunda Matlab 2021a yazılımı kullanılarak gerçekleştirilmiştir



Şekil 2. Nokta bulutundan elma belirlemek için kullanılan çerçeve

3.1. En Uygun Komşu Sayısı Seçimi

Nesnelerin mekânsal bilgilerinin elde edilmesi, doğru ve kesin semantik nokta bulutu etiketlenmesi için önemlidir. Her 3B nokta için en uygun komşuluk boyutunu belirlemek nokta bulutundan geometrik özelliklerin çıkarılması için gereklidir, iyi bir komşuluk seçimi yerel geometriye ve dolayısıyla geometrik özelliklere dayanmalıdır. Farklı boyutlarda ve ölçeklerde olan benzer geometrik şekildeki nesnelere geometrik özelliklere dayanarak etkili şekilde belirlenebilmektedir. Hesaplama yükünü azaltmak ve anlamlı etiketlemeyi etkili kılmak için çeşitli optimum komşuluk sayısı seçim yöntemleri kullanılmaktadır. Bir 3B noktasının yerel komşuluğu, genellikle küresel [24] veya silindirik [25] bir komşuluk içindeki tüm 3B noktaları göz önünde bulundurarak tanımlanır. Komşuluk sayısı genellikle nesne veya veriler hakkında ön bilgiler dâhil edilerek tanımlanır. Ancak, sahnedeki farklı yapılar adaptif bir komşuluk sayısına göre belirlenmelidir [26, 27]. Bu bağlamda yüzey değişimine [28], eğrilik, nokta yoğunluğu ve normal tahmininin gürültüsüne [29, 30] ve öz-entropi tabanlı adaptif yöntemler sunulmuştur [26, 27]. Bu çalışmada ise

bireysel noktaların 3B şekilsel dağılımını tanımlamada kullanılan Omnivaryans komşuluk seçimi yöntemi literatüre kazandırılmıştır.

3.2. Özellik Çıkarımı

Makine öğrenmesi yöntemleri kullanılarak çözümü aranan problemlerde veriyi temsil eden özelliklerin çıkarılması gerekir [31]. Bazı problemlerde girdi olarak sunulan veriler her zaman makine öğrenmelerine girdi olarak verilememektedir. Nokta bulutu gibi karmaşık ve büyük verilerde, sınıflandırma işleminin doğruluğunu artırabilmek için nokta bulutuna ait özelliklerin çıkarılması ve ilgili özelliklerin sınıflandırıcıya giriş olarak verilmesi gerekmektedir. Nokta bulutundan özellik çıkarımının gerçekleşmesi için öncelikle uygun bir yerel komşuluk belirlenmelidir. Daha sonra bu yerel komşuluk içindeki ilgili 3B noktalar geometrik özellikleri çıkarmak için kullanılır.

Özellik çıkarmak için kovaryans temelli bir süreç işletilmiştir. 3B bireysel bir noktanın (P) adaptif komşuluk sayısına göre belirlenen komşu noktalarını oluşturan vektör $P'_i = [x_i, y_i, z_i]$ olmak üzere, P'_i 'yi oluşturan toplam m adet verinin komşu noktalarının ortalaması $\hat{P}^0 = \frac{1}{m} \sum_{i=1}^m P'_i$ olsun. Daha sonra kovaryans matrisini Eşitlik 1 ile tanımlanır.

$$\text{cov}(P') = \frac{1}{m} \sum_{i=1}^m (P'_i - \hat{P}^0) \times (P'_i - \hat{P}^0)^T \quad (1)$$

Kovaryans matrisi daha sonra tekil değerlerine ayrıştırılarak öz-değerler, $\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq 0$, elde edilmektedir. Öz-değerler matrisin en yüksek ortogonal varyansını temsil eder. İlgili öz-değerler ve 3B bireysel nokta konum bilgisi kullanılarak çeşitli geometrik özellikler üretilmektedir [19]. İlgili öz-değerler hesaplandıktan sonra bu çalışmada kullanılan 30 özellik çıkarılmıştır. Kullanılan 2B ve 3B özellikler:

$$\text{Lineerlik} = \frac{\lambda_1 - \lambda_2}{\lambda_1}, \quad \text{Düzlemsellik} = \frac{\lambda_2 - \lambda_3}{\lambda_1}, \quad \text{Saçılım} = \frac{\lambda_3}{\lambda_1}, \quad \text{Omnivaryans} = \sqrt[3]{\lambda_1 \times \lambda_2 \times \lambda_3},$$

$$\text{Anizotropi} = \frac{\lambda_1 - \lambda_3}{\lambda_1}, \quad \text{Özentropi} = -\sum_{n=1}^3 \lambda_n \ln(\lambda_n), \quad \text{Öz-değerler toplamı} = \lambda_1 + \lambda_2 + \lambda_3,$$

$$\text{Eğrilik değişim} = \frac{\lambda_3}{\lambda_1 + \lambda_2 + \lambda_3}, \quad \text{Z' değeri, k-en yakın nokta verisinin yarıçapı, Yoğunluk} =$$

$$\frac{k+1}{\frac{4}{3} \pi r_{k\text{-enyakin}}^3} \quad \text{Düşeylik} = 1 - n_z, \quad \text{k-en yakın nokta verisinin Z' koordinat değişimi, k-en yakın nokta}$$

verisinin Z' koordinat standart sapması, k-en yakın nokta verisinin yarıçapı (2B), 2B nokta ile tanımlanan dairesel komşuluktan; yoğunluk (2 boyut), toplam öz-entropi (2B), 2 adet öz-değer bileşeni ve öz-değerlerin oranı (2B) hesaplanmaktadır. Ayrıca, 2B izdüşümü düzlemini ayrıştırarak ve ikinci dereceden kutularla (bins) bir 2B birikim haritası türetilip; Frekans birikim haritası (2B), Z farkı (2B), Z değerlerinin standart sapması (2B). Bunlar dışında, 3B öz değer bileşenleri: $\lambda_1, \lambda_2, \lambda_3$,

$$\text{Şemsiye Eğriliği} = \sum_{n=1}^8 abs \left(\frac{P'_i - P}{|P'_i - P|} \times \text{normal}_p \right), \quad \text{Moment} = \frac{1}{k} \sum_{n=1}^k (P'_i - P)^2, \quad \text{Pürüzlülük} =$$

$$(P - \hat{P}^0) \times \frac{\text{normal}_p}{\|\text{normal}_p\|}, \quad \text{ortalama eğrilik} = \frac{\lambda_1 - \lambda_2}{2}, \quad \text{yüzey değişimi} = \frac{\lambda_1}{\lambda_1 + \lambda_2 + \lambda_3}, \quad \text{özellikleri}$$

kullanılmıştır. İlgili özelliklerde 2B Z koordinatı ile ilgili işlemler kutu içerisine denk gelen noktalardan hesaplanmaktadır.

3.3. Özellik Seçimi

Veri boyutu azaltma işlemi veri madenciliğinde önemli bir süreçtir. Özellik seçimi, özellik uzayından model oluşturmak için ölçülen özelliklerin alt kümesini seçerek verilerin boyutunu azaltmayı sağlar. Böylece veriyi tanımlayan en uygun alt kümeler seçilir. Özellik seçimi gerçekleştirildiğinde veri boyutu azaltıldığı için verinin daha sonraki süreçlerde işleme hızı artar, veriyi depolama maliyeti azalır, sınıflandırma işlemindeki model başarısı artar, veriyi tam olarak temsil edemeyen gürültülü veriler temizlenmiş olur, veri daha kolay yorumlanabilir ve görselleştirilebilir. Özellikle, örneklem sayısı az olan ve yüksek korelasyonlu öznelik içeren verilerde öznelik seçimi sınıflandırma işleminde yüksek performans sağlamaktadır [8, 32].

Öznelik seçimi genellikle filtreleme, sarmal ve gömülü olarak 3 kategoriye ayrılmaktadır. Filtreleme yöntemlerinde sınıflandırıcıdan bağımsız ölçüt kullanılırken, sarmal yöntemlerde ölçüt olarak sınıflandırıcı kullanılır. Gömülü yöntemlerde ise filtreleme ve sarmal yöntemler birlikte kullanılmaktadır. Bu çalışmada kullanılan Minimum Artıklık Maksimum İlgililik (MAMİ) filtreleme tabanlı yöntemi veriyi temsil eden en az boyutlu kümeyi ararken, öznelikler arasında en az artıklık / ortak bilgiyi içeren ve etiket değeri ile en fazla ilgili özneliğin seçimini sağlayan bir yöntemdir [33, 34]. MAMİ, hesaplama maliyetleri düşük, kolay ve hızlı bir yöntem olduğu için bu çalışmada kullanılmıştır. MAMİ algoritmasının detayları aşağıda verilmiştir.

$$I(X, Y) = \sum_{y \in Y} \sum_{x \in X} p(x, y) \log \left(\frac{p(x, y)}{p_1(x) p_2(y)} \right) \quad (2)$$

Burada ayrık rastlantı değişkeni olarak tanınan öznelikler (X ve Y) arasındaki ortak bilgi (I) elde edilmektedir. X ve Y'nin birleşik olasılık dağılım fonksiyonu $p(x, y)$ ile ifade edilirken $p_1(x)$ ve $p_2(y)$ sırasıyla X ve Y'nin olasılık dağılım fonksiyonunu ifade eder. K öznelikler arasından seçilecek öznelikleri belirten küme, $|K|$ ise toplam eleman sayısı olmak üzere minimizasyon işlemi Eşitlik 3 ile sağlanmaktadır.

$$\arg \min_L L = \frac{1}{|L|^2} \sum_{N_i, N_j \in K} I(N_i, N_j) \quad (3)$$

Eşitlik 3 minimum artıklık koşulunu sağlamak için kullanılmaktadır. Seçilecek kümenin ideal küme olmasını sağlamak için kullanılan diğer koşul ise maksimum ilişkiyi sağlamaktır (Eşitlik 4).

$$\arg \min_R R = \frac{1}{|L|} \sum_{N_i \in K} I(N_i, T) \quad (4)$$

Burada, N_i ayrık rastlantı değişkenini (özellik vektörleri), T ise sınıf etiket değerlerini temsil eden özellik vektörünü $I(N_i, N_j)$ i . ve j . özellikler arasındaki ortak bilgiyi, $I(N_i, T)$ ise i . ve etiket değerlerini ifade eden özellik arasındaki ortak bilgiyi elde etmek için kullanılır. Daha sonra ortak bilgi farkı veya ortak bilgi oranı yöntemlerinden birisini kullanarak ilgili özelliklere ait skorlar elde edilmektedir [33, 35].

3.4. Sınıflandırma

Sınıflandırma, ham verilerin anlaşılır, anlamlı ve kullanılabilir bilgilere dönüşümünü sağlayan süreçtir [36]. Günümüze kadar araştırmacılar çok sayıda sınıflandırma yöntemi önermişlerdir. Ancak, birbirinden farklı nesnelere benzer karakterlere ve özelliklere sahip olması nedeniyle nokta bulutu sınıflandırması problemi tam olarak çözülememiştir. Bu nedenle, araştırmacılar yoğun olarak otomatik nokta bulutu sınıflandırma problemi üzerine çalışmalar gerçekleştirmektedir. Bu çalışmalar yol, bitki, zemin ve zemin olmayan yüzeylerin belirlenmesi, elektrik direklerinin belirlenmesi gibi çalışmalardır. Nokta bulutu sınıflandırma işleminde kontrollü ve kontrolsüz sınıflandırma [37, 38] yöntemleri kullanılmaktadır. Bu çalışmada 2B ve 3B özellikler, etkili ve yüksek sınıflandırma performansı sergilemesinden dolayı DVM yöntemi [39] ile sınıflandırılmıştır. Sınıflandırma ve örüntü tanıma probleminin çözümü için geliştirilen DVM son zamanlarda yoğun bir araştırma konusu haline gelmiştir. DVM orijinal olarak ikili sınıflandırma için geliştirilmiştir. Temel fikir, giriş örneklerinin maksimum marjını, yani, ayırıcı hiper-düzlemden en yakın sınıf örneklerine olan minimum mesafeyi belirlemektir. Bu çalışmada yüksek sınıflandırma başarısı gösterdiği için radyal tabanlı çekirdek fonksiyonu tercih edilmiştir. SVM algoritması Lagrange çarpanının üst sınır değerinin ifade eden ceza parametresi (C) olarak 25, kernel genişliği ise 0.1 olarak tanımlanmıştır. İlgili parametreler daha önce yapılan çalışmalar ve kullanıcı deneyimi göz önünde bulundurularak belirlenmiştir [40, 41].

3.5. İstatistiksel Değerlendirme

Veri setinden seçilen özelliklerin sınıflandırma performansına etkisinin değerlendirilmesi için doğruluk, keskinlik, duyarlılık, özgüllük, F-skor ve G-ortalama metrikleri kullanılmıştır. Doğruluk değerinin dengesiz veri setlerinde tek başına anlamlı sonuç sunamamasından dolayı diğer istatistiksel metriklerde hesaplanmıştır. Referans veri seti ile sınıflandırma sonucu tahmin edilen sınıfların karşılaştırması için hata matrisi kullanılmaktadır. Tablo 1’de satır hücreleri veri setindeki örneklerin gerçek sayılarını, kolon hücrelerinde ise tahmin edilen örneklerin sayısını göstermektedir.

Tablo 1. Hata matrisi parametreleri

		Tahmin Edilen Sınıf	
		Sınıf=1 (Elma)	Sınıf=0 (Diğer)
Doğru sınıf	Sınıf=1 (Elma)	Doğru Pozitif (DF)	Yanlış Negatif (YN)
	Sınıf=0 (Diğer)	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Tablo 1’de sunulan parametreler kullanılarak hesaplanan performans ölçü metrikleri aşağıda verilmiştir.


$$\text{Doğruluk} = \frac{DF + DN}{DF + YN + YP + DN}, \text{ Keskinlik} = \frac{DF}{DF + YP}, \text{ Duyarlılık} = \frac{DF}{DF + YN}, \text{ Özgüllük} = \frac{DN}{DN + YP}$$

$$, \text{ F-skor} = 2 \times \frac{\text{Duyarlılık} \times \text{Keskinlik}}{\text{Duyarlılık} + \text{Keskinlik}}, \text{ G-ortalama} = \sqrt{\text{Duyarlılık} \times \text{Özgüllük}}$$

4. Bulgular ve Tartışma

Fuji elma setine ait renkli nokta bulutunun kullanıldığı bu çalışmada en uygun nokta komşuluk sayısının belirlenmesi için Omnivaryans tabanlı yaklaşım kullanılmıştır. $P_i' = [x_i, y_i, z_i]$ veri setini oluşturmak için aranacak k-en yakın komşuluk için alt ve üst sınır belirlenmesi gerekmektedir. Bu

veri seti için bireysel her 3B noktanın kendisine en yakın 100 ile 3500 nokta arasından her 50. nokta için en uygun komşu sayısı arama işlemi gerçekleştirilmiştir. İlgili altmış dokuz farklı komşuluk bilgisinden faydalanılarak en yüksek Omnivaryans değerini üreten nokta kümesini sağlayan k-en yakın komşuluk sayısı optimum komşuluk sayısı olarak belirlenmiştir (Şekil 3). Sahneyi oluşturan aynı geometrik özelliğe sahip nesnelere farklı ölçeklerde olabileceği için (örneğin elmalar farklı boyutta olabilmektedir) adaptif komşu sayısı belirlemek önemlidir.



Şekil 3. Optimum komşuluk sayısının dağılımı

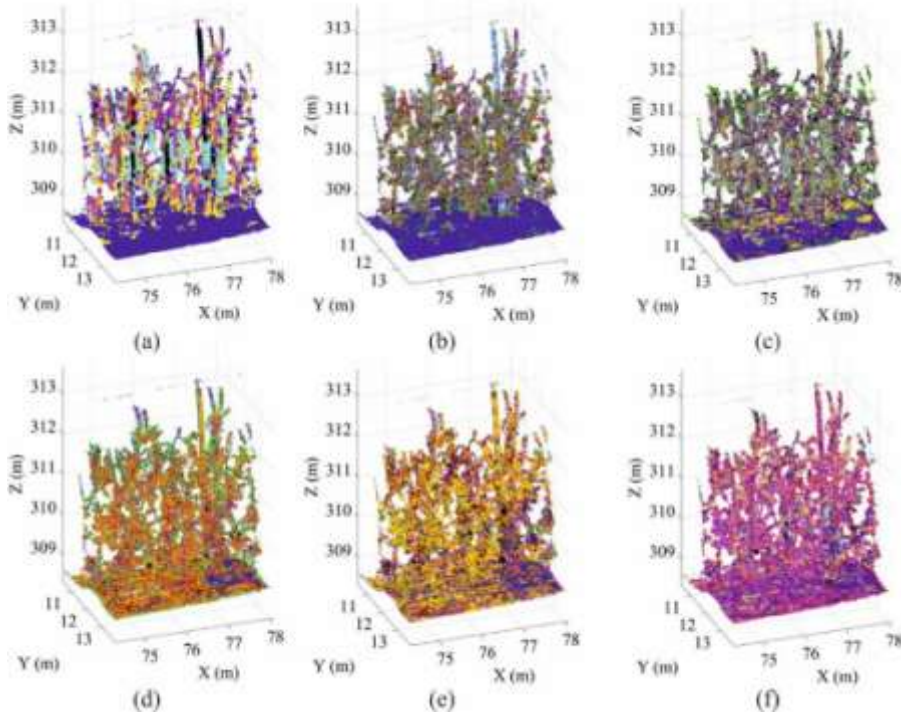
Optimum komşu sayısı seçimi için uygulanan yaklaşımlar ek hesaplama yüküne neden olsa da, bu süreci nokta bulutu sınıflandırma işlemine dâhil etmek 3B sahne analizi üzerinde önemli ölçüde olumlu bir etkiye sahiptir. Her bir 3B nokta için farklı olabilen optimum komşuluklardan yararlanarak, komşu noktalardan hesaplanan geometrik özelliklerin ayırt ediciliği artmaktadır. Çoklu görüntü yaklaşımı nedeniyle hareketten yapıya yöntemi kullanılarak nokta bulutu üretilmesi nesnelere yüksek hassasiyetle algılanmasını sağlar. Çünkü 3B nokta bulutunu oluşturmak için en az iki farklı görüntüde bir nesnenin algılanması gerekir ve aynı yanlış pozitifin iki farklı görüntüde algılanması pek olası değildir. Gerçekleştirilen uygulamada fotogrametrik olarak üretilen nokta bulutundan geometrik özellikler çıkartılarak sınıflandırma işlemi gerçekleştirilmiştir. Renk özelliği aydınlatma koşullarına ve atmosferik etkilere doğrudan bağlı olduğu için kullanılmamıştır. 3B nokta bulutu veri kümelerinin çoğu, yalnızca uzamsal 3B koordinatlarla bağlantılı geometrik bilgiler içerir. Her bireysel 3B noktanın optimum komşularıyla oluşturdukları veri kümesi kullanılarak özellik çıkarımı gerçekleştirilmiştir. 3B sahneyi temsil eden nesnelere genelde tam olarak rastgele bir nokta dağılımı sergilemezler. İlgili nesnelere, XY, YZ veya XZ düzlemlerine iz düşürülen 2B özellikler oluşturulmaktadır. Bu özellikler 3B özelliklerin tamamlayıcı bilgilerini içermektedir. Bu işlem gerçekleştirilirken 2B (9 adet) ve 3B (21 adet) toplam 30 farklı özellik çıkarılmıştır. Nokta bulutu XY düzlemine 0.30 kenar uzunluğuna sahip ikinci dereceden kutulara iz düşürülerek 2B özellikler çıkarılmıştır. 2B özellikler ağacı oluşturan dal, yaprak ve gövdeye göre daha düz alanlar içeren zemin sınıfının belirlenmesinde etkili olmuştur. Elde edilen 30 özellik MAMİ yöntemi kullanılarak analiz edilmişlerdir. Elde edilen analizler sonucunda ilgili özneliklere atanan skor/ağırlık değerleri Tablo 2’de sunulmuştur.

Özellik seçimi sonucunda en fazla ve en az ağırlık atanan üç özelliğin yakıştırma renkli nokta bulutları Şekil 4’de sunulmuştur. En fazla ağırlık atanan Şekil 4.a-c incelendiğinde zemin oldukça başarılı çıkarttığı gözlemlenmektedir. En az ağırlık atanan Şekil 4.d-f incelendiğinde ise çok fazla saçılım gerçekleştiği ve belirli bir sınıfın oluşmadığı görülmektedir. Ayrıca, k-en yakın nokta verisinin yarıçapı özelliğinin ise sınıflandırma üzerinde etkisinin çok fazla olmadığı çok saçımlı bir veri kümesi oluşturduğu belirlenmiştir (Şekil 4.f). Özellik çıkarımı ve seçimi işlemlerinin ardından verinin sınıflandırılması için DVM sınıflandırıcısı kullanılmıştır. Sınıflandırma işlemi en

fazla ağırlığa sahip 5, 10, 15, 20, 25 ve 30 özellik kullanılarak gerçekleştirilmiştir (Şekil 5). Sınıflandırma sonucunda referans veriyle aynı sınıfa atananlar doğru pozitif olarak, referans veride elma iken sınıflandırma sonucunda diğer sınıfa atananlar yanlış negatif olarak ve referans veride elma sınıfı değil iken sınıflandırma sonucunda elma olarak atananlar yanlış pozitif olarak isimlendirilmiştir.

Tablo 2. Özellik seçimi sonucunda elde edilen ağırlık değerleri


Öznitelik	Ağırlık	Öznitelik	Ağırlık	Öznitelik	Ağırlık
Lineerlik	0.0102	Yoğunluk	0.0184	Z değerlerinin standart sapması (2 boyut)	0.0213
Düzlemsellik	0.0144	Düşeylik	0.0484	Öz değer bileşenleri-1	0.0080
Saçılım	0.0147	k-en yakın nokta verisinin Z' koordinat aralığı	0.0150	Öz değer bileşenleri-2	0.0238
Omnivaryans	0.0410	k-en yakın nokta verisinin Z' koordinat standart sapması	0.0244	Öz değer bileşenleri-3	0.0150
Anizotropi	0.0114	k-en yakın nokta verisinin yarıçapı (2 boyut)	0.0100	Öz değer bileşenleri (2B)-1	0.0246
Özentropi	0.0225	Yoğunluk (2 boyut)	0.0445	Öz değer bileşenleri (2B)-2	0.0128
Özdeğerler toplamı	0.0125	Toplam öz entropi (2 boyut)	0.0281	Şemsiye eğriliği	0.0147
Eğrilik değişim	0.0108	Öz değerlerin oranı (2 boyut)	0.0147	Moment	0.0145
Z' değeri	0.0386	Frekans birikim haritası (2 boyut)	0.0530	Ortalama eğrilik	0.0128
k-en yakın nokta verisinin yarıçapı	0.0100	Z aralığı (2 boyut)	0.0246	Yüzey değişimi	0.0108



Şekil 4. En fazla ağırlık atanan özellikler a) Frekans birikim haritası (2B), b) Düşeylik, c) Yoğunluk (2B), en az ağırlık atanan özellikler d) Öz değer bileşenleri-1, e) k-en yakın nokta verisinin yarıçapı (2B) ve f) k-en yakın nokta verisinin yarıçapı

Sınıflandırma sonucunda hesaplanan istatistiksel metrik değerleri Tablo 3’de sunulmuştur. Tablo 3’de ilgili metriklerden en yüksek değere sahip olanlar koyu renk ile işaretlenmiştir. 25 özellik kullanılarak gerçekleştirilen sınıflandırma istatistiksel olarak diğer özelliklerin kullanılmasına göre daha başarılı sonuç üretmiştir.

5 özelliğin kullanılması yüksek doğruluk değeri sağlamış olsa da oldukça düşük duyarlılık sağlamaktadır. 30 özellik kullanılması düşük doğruluk sağlarken görece daha yüksek duyarlılık değeri sağlamıştır. İlgili farklılığın temel sebebi elma sınıfını oluşturan örneklem sayısının diğer sınıfları oluşturan örneklemelerden daha az olmasıdır. Doğru alt küme seçimi sınıflandırıcının hızını arttırmakta, aşırı öğrenmenin önüne geçmekte, tahmin edici modelin yorumlanmasını kolaylaştırmakta ve model karmaşıklığı azaltarak sınıflandırıcının sınıflandırma performansını arttırmaktadır. Bundan dolayı 30 özellik kullanılması sınıflandırıcı performansını olumsuz etkilemiştir.



Şekil 5. a) 5 özellik, b) 10 özellik, c) 15 özellik, d) 20 özellik, e) 25 özellik ve f) 30 özellik kullanılarak belirlenen elmalar

20 özellik ve 25 özellik kullanılarak elde edilen görsel ve istatistiksel metrik değerlerinin yakın olduğu görülmektedir. Sınıflandırma sonuçlarının istatistiksel anlamlılık testleri ile karşılaştırılması objektif değerlendirme açısından önemlidir.

Tablo 3. Farklı özellik setlerinden elde edilen istatistiksel metrikler

	5 özellik	10 özellik	15 özellik	20 özellik	25 özellik	30 özellik
Doğruluk	0.8925	0.9300	0.9485	0.9566	0.9581	0.8027
Kesinlik	0.7340	0.8642	0.9002	0.9258	0.9320	0.3343
Duyarlılık	0.1004	0.4633	0.6208	0.6766	0.6852	0.7234
Özgüllük	0.9953	0.9905	0.9911	0.9930	0.9935	0.8130
F-skor	0.1767	0.6032	0.7349	0.7818	0.7898	0.4573
G-ortalama	0.3161	0.6775	0.7844	0.8197	0.8251	0.7669

Farklı özellik setleri kullanılarak elde edilen sonuçlar arasındaki farkın anlamlı olup olmadığının belirlenebilmesi için McNemar testi kullanılmıştır. İki farklı özellik seti kullanılarak elde edilen sınıflandırma sonuçlarının %5 önem seviyesinde, gerçek sınıf etiketlerini tahmin etmek için aynı sınıflandırma performansa olan sıfır hipotezi reddedilmiştir ($p = 1.2218e-113$). Sonuç olarak iki özellik seti ile elde edilen sonuçlar arasındaki fark istatistiksel olarak anlamlıdır. Hareketten yapıya yöntemi ile üretilen nokta bulutu ile gerçek zamanlı robotik hasadın gerçekleştirilmesi günümüz teknolojik şartlarında mümkün değildir. Ancak, bilgisayar donanımsal alt yapısının gelişmesi ve yazılımların evrilmesiyle birlikte, gelecekte bu sınırlamanın üstesinden gelinecektir. 3B verilerin nitel ve nicel analizinden, önerilen yaklaşımın elma konumunun yüksek hassasiyetle belirlenmesinde kullanılabileceği görülmüştür.

5. Sonuçlar

Bu makalede Fuji elmalarının mekânsal konumlarının belirlenmesi için bir çerçeve önerilmiştir. Önerilen çerçevenin farklı boyut ve tipteki elmaların tespit edilmesinde oldukça etkili olduğu nitel ve nicel incelemeler sonucunda belirlenmiştir. Önerilen yaklaşımda ilk önce k-en yakın komşuluk yöntemi kullanılarak nokta bulutunu oluşturan her bireysel noktanın farklı sayıdaki k en yakın komşuluğunu içeren veri seti oluşturulmuştur. İlgili veri setindeki her bireysel noktanın en uygun komşuluk sayısını belirlemek için en düşük Omnivaryans değerini sağlayan k-en yakın nokta sayısı optimum olarak belirlenmiş. Daha sonra 30 adet 3B ve 2B geometrik özellik çıkarımı optimum k en yakın komşuluk sayısına bağlı olarak gerçekleştirilmiştir. İlgili özelliklerden veri setini en iyi temsil edecek özelliklerin belirlenmesi için MAMİ özellik seçimi yöntemi kullanılmıştır. İlgili özellikler en fazla ağırlığa sahip olandan en aza olana göre sıralanarak 6 farklı veri seti oluşturulmuştur. Daha sonra bu veri setleri DVM ile sınıflandırma işlemi gerçekleştirilmiştir. Elde edilen sonuçlara göre 25 özellik kullanımı en yüksek sınıflandırma performansını (%95.81 doğruluk ve %93.20 kesinlik) sağlamıştır. 2B özelliklerin en az 3B özellikler kadar öneme sahip olduğu belirlenmiştir. Gerçekleştirilen uygulamaların yüksek kapasiteli iş istasyonlarına ihtiyaç duyması her ne kadar zayıf yönü olsa da elde edilen sonuçların başarısı oldukça yüksektir. Kullanılan yaklaşımın ile elma boyutlarının belirlenerek ağaçtaki elmaların ağırlıklarının belirlenme potansiyeli oldukça yüksektir. Gelecek çalışmalarda elma boyutunun belirlenmesi için farklı sınıflandırıcıların boyut belirleme performanslarının karşılaştırmalı analizi gerçekleştirilecektir.

Yazarların Katkıları

Yöntemin geliştirilmesini, analizlerin ve istatistiksel değerlendirmenin yapılmasını ve makalenin yazımını Mehmet Akif GÜNEN gerçekleştirmiştir.

Çıkar Çatışması

Bu çalışmada herhangi bir çıkar çatışması yoktur

Kaynaklar

- [1]. Burunkaya, M., Hassas tarım uygulamaları için yeni nesil damla sulama sistemi tasarımı ve gerçekleştirilmesi. *Politeknik Dergisi*, 2019. **22**(3): 785-792.
- [2]. Nowak, B., Precision Agriculture: Where do We Stand? A Review of the Adoption of Precision Agriculture Technologies on Field Crops Farms in Developed Countries. *Agricultural Research*, 2021: 1-8.
- [3]. Hâni, N., Roy, P., ve Isler, V., A comparative study of fruit detection and counting methods for yield mapping in apple orchards. *Journal of Field Robotics*, 2020. **37**(2): 263-282.

- [4]. Weinmann, M., Urban, S., Hinz, S., Jutzi, B., ve Mallet, C., Distinctive 2D and 3D features for automated large-scale scene analysis in urban areas. *Computers Graphics*, 2015. **49**: 47-57.
- [5]. Vanegas, C.A., Aliaga, D.G., ve Benes, B., Automatic extraction of Manhattan-world building masses from 3D laser range scans. *IEEE transactions on visualization computer graphics*, 2012. **18**(10): 1627-1637.
- [6]. Boyko, A. ve Funkhouser, T., Extracting roads from dense point clouds in large scale urban environment. *ISPRS Journal of Photogrammetry Remote Sensing*, 2011. **66**(6): S2-S12.
- [7]. Gorte, B., Elberink, S.O., Sirmacek, B., ve Wang, J., IQPC 2015 Track: Tree separation and classification in mobile mapping lidar data, in *The International Archives of Photogrammetry, Remote Sensing Spatial Information Sciences*. 2015. p. 607.
- [8]. Günen, M.A., Atasever, U.H., ve Beşdok, E., Analyzing the contribution of training algorithms on deep neural networks for hyperspectral image classification. *Photogrammetric Engineering Remote Sensing*, 2020. **86**(9): 581-588.
- [9]. Kurban, T. ve Beşdok, E. 3 Dimensional Point Cloud Filtering Using Differential Evolution Algorithm. in *2019 IEEE Jordan International Joint Conference on Electrical Engineering and Information Technology (JEEIT)*. 2019. IEEE.
- [10]. Wang, D., Li, C., Song, H., Xiong, H., Liu, C., ve He, D., Deep learning approach for apple edge detection to remotely monitor apple growth in orchards. *IEEE Access*, 2020. **8**: 26911-26925.
- [11]. Lawal, O.M., YOLOMuskmelon: quest for fruit detection speed and accuracy using deep learning. *IEEE Access*, 2021. **9**: 15221-15227.
- [12]. Gan, H., Lee, W.S., Alchanatis, V., ve Abd-Elrahman, A., Active thermal imaging for immature citrus fruit detection. *Biosystems Engineering*, 2020. **198**: 291-303.
- [13]. Bulanon, D., Burks, T., ve Alchanatis, V., Study on temporal variation in citrus canopy using thermal imaging for citrus fruit detection. *Biosystems Engineering*, 2008. **101**(2): 161-171.
- [14]. Sa, I., Ge, Z., Dayoub, F., Upcroft, B., Perez, T., ve McCool, C., Deepfruits: A fruit detection system using deep neural networks. *Sensors*, 2016. **16**(8): 1222.
- [15]. Okamoto, H. ve Lee, W.S., Green citrus detection using hyperspectral imaging. *Computers electronics in agriculture*, 2009. **66**(2): 201-208.
- [16]. Stajanko, D., Lakota, M., ve Hočevár, M., Estimation of number and diameter of apple fruits in an orchard during the growing season by thermal imaging. *Computers Electronics in Agriculture*, 2004. **42**(1): 31-42.
- [17]. Nguyen, T.T., Vandevoorde, K., Wouters, N., Kayacan, E., De Baerdemaeker, J.G., ve Saeys, W., Detection of red and bicoloured apples on tree with an RGB-D camera. *Biosystems Engineering*, 2016. **146**: 33-44.
- [18]. Zhang, K., Lammers, K., Chu, P., Li, Z., ve Lu, R., System design and control of an apple harvesting robot. *Mechatronics*, 2021. **79**: 102644.
- [19]. Tsoulas, N., Paraforos, D.S., Xanthopoulos, G., ve Zude-Sasse, M., Apple shape detection based on geometric and radiometric features using a LiDAR laser scanner. *Remote Sensing*, 2020. **12**(15): 2481.
- [20]. Gené-Mola, J., Sanz-Cortiella, R., Rosell-Polo, J.R., Morros, J.-R., Ruiz-Hidalgo, J., Vilaplana, V., ve Gregorio, E., Fruit detection and 3D location using instance segmentation neural networks and structure-from-motion photogrammetry. *Computers Electronics in Agriculture*, 2020. **169**: 105165.
- [21]. Zine-El-Abidine, M., Dutagaci, H., Galopin, G., ve Rousseau, D., Assigning apples to individual trees in dense orchards using 3D colour point clouds. *Biosystems Engineering*, 2021. **209**: 30-52.
- [22]. Gongal, A., Silwal, A., Amatya, S., Karkee, M., Zhang, Q., ve Lewis, K., Apple crop-load estimation with over-the-row machine vision system. *Computers Electronics in Agriculture*, 2016. **120**: 26-35.

- [23]. Liu, X., Chen, S.W., Aditya, S., Sivakumar, N., Dcunha, S., Qu, C., Taylor, C.J., Das, J., ve Kumar, V. Robust fruit counting: Combining deep learning, tracking, and structure from motion. in IEEE International Conference on Intelligent Robots and Systems. 2018.
- [24]. Lee, I. ve Schenk, T.J., Perceptual organization of 3D surface points, in International Archives of Photogrammetry Remote Sensing Spatial Information Sciences. 2002. p. 193-198.
- [25]. Filin, S. ve Pfeifer, N., Neighborhood systems for airborne laser data. Photogrammetric Engineering Remote Sensing, 2005. **71**(6): 743-755.
- [26]. Weinmann, M., Reconstruction and analysis of 3D scenes. 2016: Springer.
- [27]. Weinmann, M., Jutzi, B., Hinz, S., ve Mallet, C., Semantic point cloud interpretation based on optimal neighborhoods, relevant features and efficient classifiers. ISPRS Journal of Photogrammetry Remote Sensing, 2015. **105**: 286-304.
- [28]. Pauly, M., Keiser, R., ve Gross, M. Multi-scale feature extraction on point-sampled surfaces. in Computer graphics forum. 2003. Wiley Online Library.
- [29]. Lalonde, J.-F., Unnikrishnan, R., Vandapel, N., ve Hebert, M. Scale selection for classification of point-sampled 3D surfaces. in Fifth International Conference on 3-D Digital Imaging and Modeling (3DIM'05). 2005. IEEE.
- [30]. Mitra, N.J. ve Nguyen, A. Estimating surface normals in noisy point cloud data. in Proceedings of the nineteenth annual symposium on Computational geometry. 2003.
- [31]. Keskenler, M.F., Dal, D., ve Aydın, T., Yapay Zeka Destekli ÇOKS Yöntemi ile Kredi Kartı Sahtekarlığının Tespiti. El-Cezerî Fen ve Mühendislik Dergisi, 2021. **8**(2): 1007-1023.
- [32]. Yargı, V. ve Postalciöğlü, S., EEG İşareti Kullanılarak Bağımlılığa Yatkınlığın Makine Öğrenmesi Teknikleri ile Analizi. El-Cezerî Fen ve Mühendislik Dergisi, 2021. **8**(1): 142-154.
- [33]. Gulgezen, G., Cataltepe, Z., ve Yu, L. Stable feature selection using MRMR algorithm. in 2009 IEEE 17th Signal Processing and Communications Applications Conference. 2009. Ieee.
- [34]. Kurşun, O., Şakar, C.O., Favorov, O., Aydın, N., ve Gürgen, S.F., Using covariates for improving the minimum redundancy maximum relevance feature selection method. Turkish journal of electrical engineering computer sciences, 2010. **18**(6): 975-989.
- [35]. Ding, C. ve Peng, H., Minimum redundancy feature selection from microarray gene expression data. Journal of bioinformatics computational biology, 2005. **3**(02): 185-205.
- [36]. Mountrakis, G., Im, J., ve Ogole, C., Support vector machines in remote sensing: A review. ISPRS Journal of Photogrammetry Remote Sensing, 2011. **66**(3): 247-259.
- [37]. Haala, N. ve Brenner, C., Extraction of buildings and trees in urban environments. ISPRS journal of photogrammetry remote sensing, 1999. **54**(2-3): 130-137.
- [38]. Vosselman, G., Slope based filtering of laser altimetry data, in International archives of photogrammetry remote sensing. 2000. p. 935-942.
- [39]. Cortes, C. ve Vapnik, V., Support-vector networks. Machine learning, 1995. **20**(3): 273-297.
- [40]. Laube, P., Franz, M.O., ve Umlauf, G. Evaluation of features for SVM-based classification of geometric primitives in point clouds. in 2017 Fifteenth IAPR International Conference on Machine Vision Applications (MVA). 2017. IEEE.
- [41]. Mallet, C., Bretar, F., Roux, M., Soergel, U., ve Heipke, C., Relevance assessment of full-waveform lidar data for urban area classification. ISPRS journal of photogrammetry remote sensing, 2011. **66**(6): S71-S84.