



Bilgisayarlı Görü Teknikleri Kullanılarak Yapay Zeka Temelli Limon Ağacı Rekolte Tahmini

Artificial Intelligence Based Prediction of Lemon Tree Yield Using Computer Vision Technique

¹Yalçın IŞIK , ²Mücahit ÜNAY , ³Ahmet KAYABAŞI 

¹Selçuk Üniversitesi, Silifke-Taşucu Meslek Yüksekokulu, Silifke/Mersin, Türkiye

²MEB Silifke Atatürk Mesleki ve Teknik Anadolu Lisesi, Silifke/Mersin, Türkiye

³Karamanoğlu Mehmetbey Üniversitesi, Mühendislik Fakültesi, Karaman, Türkiye

¹isiky@selcuk.edu.tr, ²mucahitunay33@hotmail.com,

³ahmetkayabasi@kmu.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 20 March 2022

Accepted : 14 April 2022

Keywords:

Agriculture, Lemon Detection, Yield Prediction, Image Processing, Artificial Neural Network

ABSTRACT

Agriculture has always been one of the most important production sectors for people and has been in continuous technological development since the early times of human history. Computer vision techniques are also widely used in agriculture today. In the lemon groves, when the fruits on the trees are ripe and ready for sale, the total fruit yield is estimated by experienced people and the sales process takes place based on this forecast data. In this research, fruit yield estimation was made by using numerical data obtained by using computer vision techniques on fruit image taken from trees and transferred to computer environment and the artificial neural network in multilayer perceptron architecture. The designed system estimated the yield correctly by 72.8 % from the pictures taken while the lemons were on the tree and estimated the weights correctly 99.13% from the pictures taken while they collected.

© 2022 Bandırma Onyedü Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 20 Mart 2022

Kabul : 14 Nisan 2022

Anahtar Kelimeler:

Tarım, Limon Tespiti, Rekolte Tahmini, Görüntü İşleme, Yapay Sinir Ağı

ÖZET

Tarım, insanlar için her zaman en önemli üretim sektörlerinden birisi olmuş ve insanlık tarihinin ilk zamanlarından bu zamana kadar sürekli olarak teknolojik gelişim içinde olmuştur. Günümüzde tarım alanında bilgisayarlı görü teknikleri de yaygın olarak kullanılmaktadır. Limon bahçelerinde ağaçlar üzerindeki meyveler olgunlaşıp satışa hazır hale geldiğinde, toplam meyve rekoltesi bu konuda deneyimli insanlar tarafından tahmin edilir ve satış işlemi bu tahmin verisi üzerinden gerçekleşir. Bu araştırma ile, ağaçlardan alınan ve bilgisayar ortamına aktarılan meyve görüntüleri üzerinde bilgisayarlı görü tekniklerinin kullanılması ile elde edilen sayısal veriler ve çok katmanlı perseptron mimarisinde yapay sinir ağı kullanılarak meyve rekoltesi tahmini yapılmıştır. Tasarlanan sistem rekolteyi limonların ağaçtayken çekilen resimlerinden %72,8 oranında, toplanmış haldeyken çekilen resimlerinden ise ağırlıklarını % 99,13 oranında doğru tahmin etmiştir.

© 2022 Bandırma Onyedü Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayımlanmaktadır. Tüm Hakları Saklıdır.

ORCID ID: ¹0000-0001-9223-5381

²0000-0002-4265-2491

³0000-0002-9756-8756

1. GİRİŞ

Limon yıl boyunca yaprakları dökülmeyen, büyümesini sürdüren ve yapısında uçucu yağlar bulunan bir ağaç türüdür. Dünya turunçgiller üretiminin 2019/20 sezonunda %8'ini limon oluşturmaktadır. Bir yılda dünya genelinde 2,2 milyon ton ihracatı olan limonun, %25'i Türkiye tarafından yapılmaktadır. 2019 yılında Türkiye'de 4,3 milyon ton civarında gerçekleşen turunçgiller hasadının %22'sini 950 bin tonluk rekolte ile limon ve misket limonu oluşturmuştur [1]. Görüldüğü gibi limon Türkiye ekonomisinde önemli bir katkı payına sahiptir ve limonla ilgili yapılacak her türlü teknolojik çalışma ülkeye belirli bir katkı sağlayacaktır. Limonun çiftçi tarafından bahçede satışı genellikle kilogram olarak değil, bütün bahçedeki ürünün tamamı olarak satılmaktadır. Satış bedeli bütün bahçeden hasıl edilecek toplam limon miktarının uzman kişilerce kilogram olarak tahmin edilmesiyle belirlenmektedir. Tabii ki insan yanılgıları sonucunda tam tahmin yapılamayıp ürünün gerçek değerinde satılamaması sorunları olmaktadır. Bu sorunu ortadan kaldırmanın tek yolu, tahmini %100'e yakın değere yaklaştırmaktır ve bunun da insan gözüyle olması pek mümkün değildir. Pek çok alanda olduğu gibi bu alanda da görüntü işleme ve yapay sinir ağı yöntemleri kullanılarak daha doğru tahminler yapmak muhtemeldir. Başlangıçta %100 tahmin başarısı mümkün olmayabilir ama zaman içinde görüntüleme ve değerlendirme yöntemlerinde olacak gelişmelerle %100'e yaklaşmak mümkün olacaktır.

Literatürde değişik meyvelere ait görüntü işleme tekniklerinin kullanılmasına ilgili çalışmalar vardır. Linker vd., (ve diğerleri) doğal aydınlatma koşullarında elma bahçelerinde elde edilen RGB (Red Green Blue-Kırmızı Yeşil Mavi) görüntülerden yeşil elma sayısının belirlenmesine yönelik algoritma geliştirmiştir. Algoritma, dört ana adımı içermektedir. Renk ve pürüzsüzlük kullanarak, elmaya ait olma olasılığı yüksek olan piksellerin tespiti, elmalara ait olma olasılığı yüksek olan birleştirilmiş piksel kümeleri olan "tohum alanlarının" oluşumu ve genişlemesi, bu tohum alanlarının dış hatlarının yaylara ve bölümlere ayrılması, bu yayların birleştirilmesi ve elde edilen dairenin basit bir elma modeliyle karşılaştırılmasından oluşmaktadır. Algoritmanın performansı iki veri grubu kullanılarak incelenmiştir. İlk veri grubu, kameranın tam otomatik modunda ve çeşitli aydınlatma koşullarında kaydedilen görüntülerden oluşmaktadır. İkinci veri grubu, manuel olarak düşük pozlanmış ve çoğunlukla dağınık ışık altında (gün batımına yakın) kaydedilmiş görüntülerden oluşmaktadır. Algoritma ile görüntülerde görülebilen elmanın %85'inden fazlasını doğru tespit etmiştir. Çalışmada doğrudan aydınlatma ve renk doygunluğu, çok sayıda yanlış pozitif tespiti neden olmuştur. Bu tür görüntüler için doğru algılama oranı %95'e yakın, yanlış pozitif algılama oranı %5'ten az olarak sonuçlanmıştır [2]. Er vd., yapmış oldukları çalışmada, Akdeniz bölgesinde yer alan Isparta ve civarı illerde yetiştirilen elmaları görüntü işleme yöntemleri ile elmanın rengine, elmanın boyutuna ve elmanın ağırlığına göre ayırmaya yönelik çalışma gerçekleştirmişlerdir. Görüntü üzerinde elmayı bulma, boyutlandırma ve ağırlık tespiti resim üzerinde en küçük kareler yöntemi kullanılarak tahmin edilmeye çalışılmıştır. Yürüyen bant üzerindeki elmalar nitelik ve nicelik açısından %95,5 oranında doğru tespit edilmiştir. Tasarlanan sistemin bir elmayı tespit etme süresini 0,5 saniye olarak kayıt etmişlerdir [3]. Kurtulmuş vd., histogram eşitleme ve logaritma dönüşümü gibi bilgisayarlı görü yöntemlerinden faydalanarak normal şartlarda alınan şeftali meyvesinin görüntülerini aydınlatma açısından zenginleştirmişlerdir. Olgunlaşmamış şeftali meyvelerini tespit eden görüntü işleme algoritması oluşturmuşlardır. Çalışmada kullanılan görüntüleri 2048*1536 piksel çözünürlükte elde etmişlerdir. Meyve görüntüleri ile kamera arasında 50 cm mesafe bırakmışlardır. Görüntü işleme algoritmalarının geliştirilmesi ve test çalışmaları için görüntülerden rastgele 32 tanesi ile eğitim yapılmış, 64 tanesi ile test işlemi yapılmıştır. Kullanılan algoritma ile görüntülenen meyvelerin %75,3'ü doğru tespit edilmiştir [4]. Ören, yapmış olduğu çalışmada, salatalıklardaki bozulmanın etkisiyle meydana gelen boyut kaybı, nem oranındaki azalma, meyve renk değişimi ve dönüşümü ile küflenme ve berelenme oluşumunu Matlab programında görüntü işleme teknikleri ile tespit etmiştir [5]. Yaşar, Matlab programında görüntü işleme teknikleri kullanarak yaptığı çalışmada, portakal ağaçlarının doğal ortamda görüntülerini elde ederek ağacın meyve yükünü hesaplamıştır. Güneşin yoğun olduğu saatlerde yapılan resim çekimlerinde işlem yapmadan önce Matlab programı ile görüntüye karartma işlemi uygulamıştır. Yapılan çalışma neticesinde, portakal ağaçlarının meyve yükü %89,8 doğrulukla tahmin edilmiştir [6]. Tosun, görüntü işleme metodlarıyla yaprak alanı ölçüm sistemi adıyla yaptığı çalışmada, ARM mikrodenetleyici kullanarak tasarladığı yaprak alanı ölçme ünitesinde, ışığın yalıtıldığı bir kutu içerisinde görüntüsü alınan yaprağın alanını OpenCv kütüphanesi ile görüntü işleme teknikleri kullanarak tespit etmiştir. Python dili ile geliştirilen yazılımda arka plan temizleme, kenar bulma algoritması ve alan belirleme yöntemleri kullanılarak sonuca ulaşılmıştır. Çalışmanın %98,8 oranında doğruluk payı olduğu gözlemlenmiştir [7]. Akıncı, yaptığı çalışmada EmguCv görüntü işleme grafik kütüphanesi kullanarak aynı anda elde ettiği video görüntülerinden meyveleri ebatlarına göre sınıflandıran bir çalışma yapmıştır. Görüntülerin eşiklenme, düzleştirilme, yumuşatılma ve kenar bulma işlemlerinden sonra meyvenin görüntüsüne ait piksel koordinatları bulunarak meyvenin boyut bilgisine ulaşılmış, böylece meyveler boyutlarına göre ayrılmıştır [8]. Ergezer vd., yapay sinir ağları için örneklerle ilgili bilgiler toplayarak, genellemeler yapmakta ve sonra daha önce hiç karşılaşmadığı örneklerle karşılaştırılınca edindiği bilgilerden yararlanarak o örnekler için bir karar vermektedir. Yapay sinir ağları bu öğrenebilme ve genelleme yetenekleri sayesinde günümüzde pek çok bilim dalında oldukça sık kullanılmakta ve karmaşık görünen sorunları başarılı bir şekilde çözebilmektedirler [9]. Kav vd., yaptığı çalışmada tarımsal faaliyetin çok olduğu Karaman'da meteorolojik ölçümler yapmış ve elde edilen verileri kullanarak regresyon modeli ve yapay sinir ağları modeli ile en yüksek ve en düşük sıcaklık tahmini yapmış ve

sonuçları karşılaştırmıştır. Yaptığı çözümlenmelerde regresyon analizine göre yapay sinir ağlarının en yüksek ve en düşük hava sıcaklıklarını tahmin etmede daha iyi netice verdiğini tespit etmiştir [10]. Yapılan çalışmaların genellikle elma, şeftali ve portakal üzerine olduğu görülmektedir. Bu meyvelerin de tahmininin yapılması önem arz etmekle birlikte, limona göre algılama zorlukları farklı olabilmektedir. Limon ağacında yaprak arasında kalıp görünmeyen kısımlar genellikle daha fazla olup, portakalla kıyaslandığında da hacimsel olarak daha küçük olması algılama başarısını azaltmaktadır. Limondaki açık sarı renk algılamayı güçleştiren ışık parlamalarına daha yatkınlık oluşturmaktadır. Bu sebeple limon üzerine yapılacak başarılı bir çalışmanın önemli olduğu açıktır. Benzer çalışmalar yapılsa bile her çalışmadaki görüntüleme yöntem ve teknik farklılıkları, değerlendirme ve işleme yöntemleri, kullanılan yapay ağı modelleri ve eğitim yöntemleri sonucu etkileyebilmektedir. Yapılan bu çalışmada kullanılan yöntemlerle oldukça başarılı sonuçlar alınmakla birlikte, daha sonra denenecek farklı yöntem ve geliştirmelerle sonuçların daha da iyileştirilmesi mümkündür.

2. REKOLTE TAHMİN YÖNTEMİ

Bu çalışmada geliştirilen uygulama ile tarım alanında limon hasadına yönelik yeni bir yaklaşım oluşturma amaçlanmıştır. Meyve yüklü limon ağaçlarından elde edilen sayısal görüntüler bilgisayar ortamına aktarılarak, geliştirilen uygulama ile sayısal görüntüler üzerinde renk filtreleme yapıp, filtrelenen alanının piksel değerleri bulunmaktadır. Elde edilen değerlere göre oluşturulan yapay sinir ağı modeli rekolte tahmininde bulunmaktadır. Böylece günümüzde insan tahminine dayalı rekolte tahmini yerine bilgisayarlı görü ve yapay sinir ağı modeline dayalı bir rekolte tahmini yapılmaktadır. Limon bahçesindeki olgunlaşmış meyve yüklü bir ağaçtan elde edilen sayısal görüntülerden, OpenCv kütüphanesi kullanılarak veriler elde edilmekte, limonlardan elde edilen veriler ile yapay sinir ağı önce danışmanlı öğrenme modeli ile eğitilmektedir. Eğitimi tamamlanan yapay sinir ağı modeli sayısal görüntülerden elde edilen limon verileri ile rekolte tahmininde bulunmaktadır.

RGB kırmızı, yeşil ve mavi ana renklerinin oluşturduğu ve en yaygın kullanılan renk uzayıdır. RGB renk uzayında her renk kırmızı, yeşil ve mavi ana renklerin belirli oranlardaki sayısal bileşiminden oluşmaktadır. RGB renk uzayı ile farklı renk elde edilebilmektedir. RGB uzayında her bir renk 8 bit ile temsil edilir. Üç ana renkten $(2^8)^3=16.777.216$ hesabı ile farklı renk elde edilmektedir.

Yaygın kullanılan diğer bir renk uzayı da HSV'dir. HSV(Hue Saturation Value – Renk Tonu Doyum Değer) renk uzayı, renkleri sırayla renk özü, doygunluk ve parlaklık olarak tanımlar. Renk özü, rengin baskın dalga uzunluğu olarak ifade edilir. Renk özü yeşil, sarı, mavi, kırmızı vb. renkler için 0-100 aralığında değerler alabilir. Doygunluk rengin canlılığını belirler. Doygunluk 0-100 aralığında değerler alabilir, yüksek doygunluk değerleri canlı renkleri oluştururken düşük doygunluk değeri ise gri tonlamalı renkleri oluşturur. Parlaklık rengin aydınlığını ve içindeki beyaz değerini ifade eder. 0-100 aralığında değerler alabilir. Sayısal görüntü, piksellerden oluşan, her biri yoğunluğu için sonlu, farklı oranlarda sayısal gösterime veya gri alanı ile sırasıyla x-ekseni ve y-ekseni üzerinde belirtilen uzamsal koordinatlarla girdi olarak beslenen iki boyutlu işlevlerinden bir çıktı olan gri gösterimi olan görüntüdür [11].


2.1. Görüntü İşleme Teknikleri

Görüntü işleme yöntemi insanların görme sistemi ile görüntüleri algılaması tanımlaması ve değerlendirmesi olayına benzemektedir. Görüntü işleme, sayısal görüntü alıcılar aracılığıyla görüntülerin alınarak bir takım işleme tabi tutulmasının ardından bilgisayarlarca tanımlanması ve istenilen amaca göre görüntünün yorumlanması olarak tanımlanabilir [12, 13]. Gürültü, sayısal görüntülerde oluşan istenmeyen verilerdir, görüntünün bozulmasına ve görüntüdeki detayların kaybolmasına sebep olabilir. Gürültüleri azaltmak için görüntü işleme algoritmalarından faydalanılır [14]. Filtreleme işlemi uzaysal ortamda ve frekans ortamında yapılabilir. Medyan filtreleme en az bulanıklaştırma işlemi ile çok büyük oranda gürültü azaltma amacı taşır [15]. Sayısal görüntünün siyah beyaz olarak tanımlanan ikili (binary) görüntüye çevrilmesi işleme eşikleme yöntemi denir. Görüntüdeki gürültülerin azaltılması ve nesne tespiti gibi amaçlar için kullanılır. Eşikleme, görüntü bölütleme amacıyla kullanılan en önemli yöntemlerdendir. Eşiklemede ana gaye, görüntüdeki nesnelere görüntü arka planından ayırmaktır. Genel olarak global ve optimal eşikleme teknikleri kullanılır. Nobuyuki Otsu tarafından 1979 yılında geliştirilen Otsu metodu ile eşik değerleri görüntü üstünden hesaplanmaktadır [16]. Otsu kavramı bir dizide (görüntü matrisinde) belirli bir eşik değeri altında olan kısımları 0, üstünde olan kısımları 1 yapmak suretiyle ikili (binary) bir görüntü oluşturmaya denir. Kenar, iki bölge arasındaki sınırda bulunan bir dizi bağlı pikseldir. Bir başka deyişle görüntünün herhangi bir bölümündeki parlaklık oranında meydana gelen keskin değişimdir. Görüntü üzerinde kenar tespiti ile o görüntüdeki nesnelere tespit edilebilir, sayısı çıkartılabilir ve özellikleri belirlenebilir. Kenar belirleme algoritmaları temel anlatımıyla, görüntü üzerindeki piksellerin renk değerlerinin birbirlerinden farklılaşması ile belirlenir. Görüntü işlemede kenar tespiti için çeşitli algoritmalar kullanılmaktadır. Bunlar; Sobel, Canny, Prewitt, Laplacian Zero-Cross vb. gibi kenar bulma algoritmalarıdır.

3. YAPAY SİNİR AĞLARI

Literatürde pek çok çalışmada kullanılan pek çok farklı tipte yapay sinir ağı modelleri vardır. En yaygın kullanılanlardan biri MLP (Multi Layer Perceptron - Çok Katmanlı Perceptron) yapısıdır. MLP giriş, gizli ve çıkış katmanlarına sahiptir ve birbirlerine ileri beslemeli olarak bağlıdır. Giriş katmanı girişi gizli katmandaki

nöronlara dağıtır. Nöronlarda kullanılan değişik aktivasyon fonksiyonları vardır. Nöronlar arasındaki ağırlıklar eğitim sürecinde değişik algoritmalarla istenilen çıkışı almak için ayarlanırlar [17]. Temel bir yapay sinir ağı yapısı Şekil 1'de görülmektedir.



Şekil 1. Yapay sinir ağı katmansal yapısı.

Yapay sinir ağlarının girdi verilerine göre çıkış verisi üretebilmesi için ağı öğrenmesi gerekmektedir. Öğrenme işlemi birkaç yöntem ile gerçekleştirilebilir. Danışmanlı eğitimde ağı öğrenmesi esnasında ağı, eğitim için giriş değerleri ile beraber çıkış değerleri de verilmektedir. Yapay sinir ağı, eğitim için verilen girdi değerleri göre istenen çıkış değerlerini elde edebilmek adına kendi ağırlık değerlerini (weight ve bias) günceller. Ağı elde ettiği sonuçlar ile bilinen sonuçlar arasındaki hata payı hesaplanır ve ağı yeni ağırlık değerleri bu hata payına göre yeniden oluşturulur. Hata payı bulunurken ağı tüm çıktı değerleri ile beklenen çıktı değerleri arasındaki fark hesaplanır ve bu fark ile her nörona düşen hata miktarı hesaplanır. Sonrasında nöronlar kendilerine iletilen ağırlık değerlerini yeniden oluştururlar [18].

4. MATERYAL VE YÖNTEM

4.1. Yöntem

Bilgisayarlı görü teknikleri ile gerçekleştirilen limon ağacı meyve rekoltesi tahmini uygulaması Microsoft Visual Studio Code programında Python dili ile OpenCv kütüphanesi ve Keras kütüphanesi kullanılarak kodlanmıştır. Uygulama ile limon ağaçlarındaki meyveler tespit edilmiş, tespit edilen limonlara ait piksel bilgileri, limonun kapladığı alanın resme oranı gibi veriler kullanılarak modellenen yapay sinir ağı eğitilmiş, uygulamanın limon ağacındaki limonları tespit etmesi ve rekolte tahmininde bulunması sağlanmıştır. Geliştirilen uygulamanın test edilmesi için ağaç üzerindeki limonlara ait görüntüler 2021 yılının şubat ayı içerisinde çekilmiş ve uygulama test edilmiştir. Ayrıca kullanıcının daha rahat kullanımı için bir ara yüz tasarımı da yapılmıştır.

4.2. Bilgisayarlı Görü Teknikleri ile Sayısal Görüntüde Limon Tespiti


Telefondan alınan görüntüler 3840x5120 piksel boyutlarında (20 mega piksel çözünürlük) olup, görüntü işleme için hız bağlamında yavaşlamaya sebebiyet vermektedir. Yavaşlamanın önlenmesi için resmin boyutları 800x600 piksel olarak küçültülmüştür. Sayısal görüntünün varsayılan renk uzayı RGB'dir. RGB renk uzayı renkleri, ana renklerin sayısal bir karışımı olarak ifade eder. Herhangi bir bilgisayarlı görme uygulamasında belirli renkteki bir nesneyi ayırt etmek istediğimizde HSV renk uzayını kullanmak daha elverişlidir. Çünkü RGB'nin aksine sadece renk tonu (hue) değerini kullanarak ve bu renk tonu değerine eşik değer uygulamak suretiyle renkleri daha net ayırt edebiliriz. Şekil 2'de RGB renk uzayından HSV renk uzayına dönüştürülmüş bir resim görülmektedir.

Uygulamamızda resimdeki limonların tespiti için HSV renk uzayında sarı renge göre filtreleme işlemi yapılmıştır. Bundan dolayı sayısal görüntü RGB renk uzayından HSV renk uzayına çevrilmiştir. Filtreleme için sarı rengin en düşük renk tonu değeri ile en yüksek renk tonu değeri aralık olarak belirlenmiştir. Belirlenen aralıktaki renk tonu değerine göre filtreleme yapıldığında limonlar resim üzerinde tespit edilmiştir.


Olgunlaşan limonlar sarı renkte oldukları için uygulamamızda sarı renge göre maskeleyme işlemi gerçekleştirilmektedir. RGB renk uzayından HSV renk uzayına dönüştürülen görüntü, HSV uzayında sarı renge göre belirlenen filtre değerleriyle maskeleyme işlemine tabii tutulmaktadır. Maskeleyme işlemi neticesinde görüntü üzerindeki sarı renk dışında kalan tüm renkler siyah olarak gösterilmektedir. Şekil 3'te sarı renge göre maskelenmiş bir resim görülmektedir.

Gürültü, sayısal görüntülerde oluşan istenmeyen verilerdir, görüntünün bozulmasına ve görüntüdeki detayların kaybolmasına sebep olabilir. Gürültüler, görüntüde benekli bir görünüm oluştururlar. Sayısal görüntüdeki


gürültüyü azaltmak için filtreler uygulanmaktadır. Geliştirdiğimiz uygulamada OpenCv kütüphanesinin medyan filtreleme fonksiyonu kullanılmıştır. Medyan filtre uygulanarak gürültüsü azaltılmış ve kenarları daha belirginleştirilmiş görüntü Şekil 4'te gösterilmiştir.



Şekil 2. RGB renk uzayından HSV renk uzayına çevrilmiş görüntü.




Şekil 3. Maskelenmiş resim.



Şekil 4. Medyan filtre uygulanmış resim.

Sayısal görüntü üzerinde eşikleme işlemi görüntüdeki gürültülerin azaltılması ve nesne tespiti gibi amaçla için kullanılır. Eşiklemenin amacı, görüntüdeki nesnelere görüntü arka planından ayırmaktır. OpenCv kütüphanesi içerisinde yer alan Otsu tarafından geliştirilen threshold fonksiyonu bu işlemi yapmaktadır. Şekil 5'de otsu eşikleme uygulanmış bir resim görülmektedir.



Şekil 5. Otsu eşikleme uygulanmış resim.

Renk uzayı dönüşümü yapılan, maske uygulanan, filtreleme ve otsu eşikleme işleminden geçen resim görüntü işleme için uygun hale gelmiş olur. OpenCv'nin findContours fonksiyonu ile resimdeki filtrelenen alanlar tespit edilebilir, alanların piksel bilgilerine ulaşılabilir. Uygulamamızda limonlara ait alanların resim arka planından ayrılması ve bu alanlara ait piksellerin bulunması ile limon tespiti yapılabilmektedir. Her bir limona ait piksel bilgileri ve limonların resmin geneline yüzdesel oran bilgileri yapay sinir ağımızın rekolte tahmini yapabilmeleri için giriş (input) verisi olarak kullanılmaktadır.

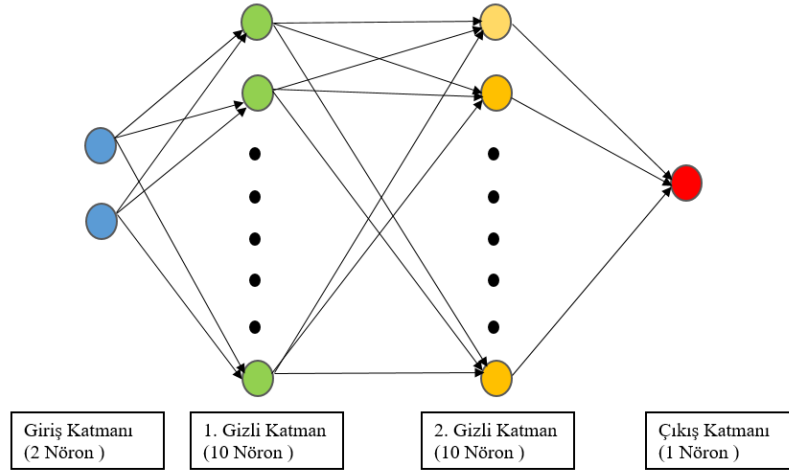
4.3. Yapay Sinir Ağı ile Rekolte Tahmini

Bilgisayarlı görü teknikleri ile elde edilen resim üzerindeki limonlara ait bilgiler yapay sinir ağının giriş verisi olarak kullanılmıştır. Yapay sinir ağının giriş verisi olarak iki adet veri kullanılmakta ve çıkış verisi tek bir tahmin sonucu olacağı için çıkış verisi tek olacak şekilde yapay sinir ağı tasarlanmıştır.

Uygulamamızdaki yapay sinir ağı modeli Python dili ile Keras kütüphanesi kullanılarak kodlanmıştır. Multi Layer Perceptron (MLP) ağ mimarisine sahip ardışık bir ağ tasarlanmıştır. Yapay sinir ağı (YSA) katmanlarda bulunan her bir nöron kendinden sonra gelen katmanlardaki her bir nörona bağlı olacak şekilde tasarlanmıştır.

YSA modelimizde bir adet giriş (input layer) katmanı, iki adet gizli (hidden layer) katman ve bir adet çıkış (output layer) katmanı bulunmaktadır. Giriş katmanında iki adet nöron, görüntüde tespit edilen her bir limonun piksel bilgisi ile limonun pikselinin resmin toplam pikseline oranı bilgisi için giriş sağlamaktadır. Gizli katmanların her birisinde 10'ar adet nöron bulunmaktadır. Buradaki her bir nöron kendinden sonraki her bir nörona bağlantılıdır. Çıkış katmanında ise tek bir tahmin sonucu üretileceği için bir adet nöron vardır. Tasarlanan model Şekil 6'da görülmektedir. YSA modelimizde gizli katmanlarda aktivasyon fonksiyonu olarak sigmoid fonksiyonu, çıkış katmanında relu aktivasyon fonksiyonu kullanılmıştır. Overfitting (ölü nöron) oluşmasını engellemek için Dropout metodundan faydalanılmıştır. Dropout metodu nöronların weight değerlerini 0,2 oranında azaltır ve böylece nöronların weight değerleri sürekli güncellenerek ölü nöronlar oluşmasının önüne geçilir.

Tasarlanan model Keras kütüphanesinin compile metodu ile derlenir. Derleme işleminde loss fonksiyonu, tahmin edilen değer, gerçek değerinden ne kadar uzak olduğunu hesaplar. Amacımız bu değeri sıfıra yaklaştırmaktır. Ardından optimizasyon ile model kendini günceller. Modelimizde loss fonksiyonu olarak MSE (Mean Squared Error - Ortalama Kareysel Hata) fonksiyonu kullanılmıştır.



Şekil 6. Uygulama için tasarlanan yapay sinir ağı modeli.

4.4. Yapay Sinir Ağının Eğitilmesi

Uygulamamız için tasarlanan YSA modelimiz danışmanlı öğrenme algoritması ile öğrenmeyi gerçekleştirmektedir. Danışmanlı öğrenmede giriş verilerine göre beklenen bir çıkış verisi sisteme verilmektedir. Sistem bu çıkış verilerine göre weight (ağırlık) ve bias değerlerini MSE'den faydalanarak güncelleyecek ve en yakın sonucu bulana kadar bu işlemi eğitim sayısınca devam ettirecektir. Eğitimde aynı anda 4 veri eğitimi seçeneği (batch_size=4) seçilmiş olup, "adam" algoritmasıyla optimizasyon yapmak suretiyle 10.000 epoch iterasyon yapılmıştır.

Danışmanlı öğrenmenin gerçekleşmesi için ağaçlardan çeşitli büyüklüklerde 63 adet limon kullanılmıştır. Zemine belirli aralıklara yerleştirilen limonlar 0,5 metre, 1 metre, 2 metre, 2,5 metre gibi uzaklıklardan fotoğraflanmıştır. Çeşitli uzaklıklardan elde edilen bu limon resimlerinden, görüntü işleme teknikleri ile her bir limonun resimdeki piksel bilgilerine ve her bir limonun resmin toplam piksel büyüklüğüne oranı bilgisine ulaşılmıştır. Bu bilgiler Python'ın NumPy (Numeric Python) kütüphanesi aracılığı ile matris olarak oluşturulmuştur. Bu matris verisi YSA modelimiz için giriş verisi olarak kullanılmıştır. Resimlerde tespit edilen her bir limon terazi ile tartılmış ve bu veriler yine NumPy kütüphanesi aracılığı ile çıkış verisi olarak kullanılmak üzere matris olarak oluşturulmuştur. Şekil 7'de uygulamamızın eğitim veri seti oluşturulurken resim üzerinde tespit edilmiş limonlar ve bu limonlara ait bilgiler görülmektedir.



Sıra No	Limon Pixel	Limon Yüzde	Ağırlık	Uzaklık
1	688	0.14	54	1m
2	873	0.18	80	1m
3	2008	0.42	250	1m
4	1738	0.36	210	1m
5	1743	0.36	198	1m
6	1497	0.31	148	1m
7	1230	0.26	111	1m
8	766	0.16	64	1m
9	952	0.2	87	1m
10	593	0.12	68	1m
11	1162	0.24	112	1m
12	1511	0.31	159	1m
13	2131	0.44	249	1m
14	2500	0.52	273	1m
15	886	0.18	121	1m
16	1306	0.27	134	1m
17	916	0.19	88	1m
18	981	0.2	89	1m
19	2027	0.42	218	1m
20	1322	0.28	135	1m

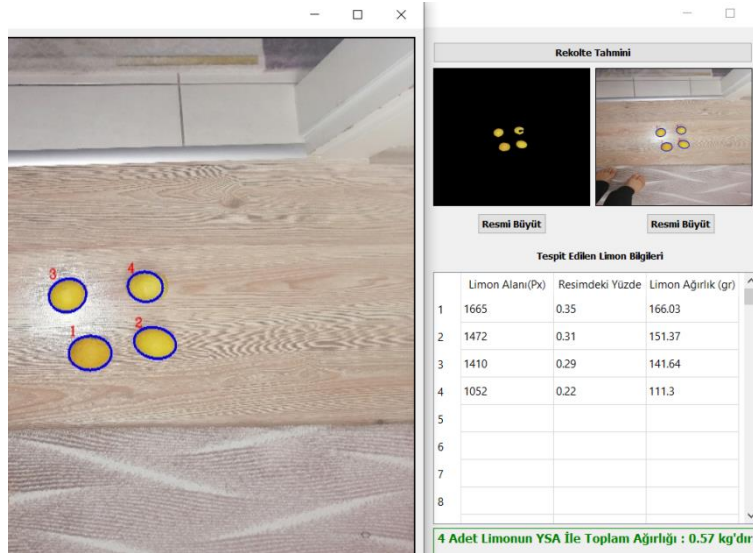
Şekil 7. Veri seti oluşturmak için tespit edilen limonlar ve limonların bilgileri.

5. ARAŞTIRMA BULGULARI VE TARTIŞMA

Şekil 8'de görüldüğü gibi bir limon ağacının önden ve arkadan olacak şekilde iki adet resmi çekilmiştir. Resimler bilgisayara aktarılmış ve geliştirilen uygulamada kullanılmıştır. Resim Yükle butonu ile resimler sırasıyla uygulamaya yüklenmiş ve resimlerdeki limonlar önce tespit edilmiş, bilgileri çıkartılmış ve YSA'na giriş verisi olarak verilmiştir. YSA bu bilgiler ışığında rekolte tahmininde bulunmuştur. Ağacın ön tarafından çekilen resimde uygulamamız 65 adet limon tespit etmiş olup 6,9 kg rekolte tahmini yapmıştır. Ağaçtan toplanan limonlar terazi ile tartılmış ve gerçek ağırlığın 9,72 kg olduğu görülmüştür. Tasarlanan model bu resim için %70,99 doğrulukla rekolte tahmini yapmıştır. Ağacın arka tarafından çekilen resimde uygulamamız 46 adet limon tespit etmiş ve 5,76 kg rekolte tahmini yapmıştır. Ağaçtaki limonlar toplanıp tartılmış ve gerçek ağırlık 7,67 kg olarak tespit edilmiştir. Modelimiz burada %75,1 doğrulukla tahmin yapmıştır. Sonuç olarak ağacın ön ve arka tarafından elde edilen resimlerde uygulamamız 12,66 kg rekolte tahmini yapmış olup bu limonların gerçek ağırlığının 17,39 kg olduğu görülmüştür. Tasarladığımız sistem rekolteyi %72,8 oranında doğru tahmin etmiştir. Oranın bu şekilde çıkmasında, resim çekilirken ortamdaki ışık miktarı, büyük kısmı yaprak arkasında kalan limonlar, ışığın yansımından kaynaklı olarak belirlediğimiz sarı renk filtre aralığı dışında renge sahip olan limonlar etkili olmuştur.

Tasarlanan sistem ağaçtan toplanmış ve bir zemine yerleştirilmiş olan limon görüntüleri üzerinde de test edilmiştir. Resimde tespit edilen 4 adet limon için uygulamamız 570 gr ağırlık tahmininde bulunmuştur. Bu durum Şekil 9'da görülmektedir. Limonlar terazi ile tartıldığında gerçek ağırlığın 575 gr olduğu Şekil 10'da gösterildiği gibi görülmüştür. Uygulamamız bu resimdeki limonların ağırlığını % 99,13 oranında doğru tahmin etmiştir.

Şekil 8. Limon ağacı rekolte tahmini.



Şekil 9. Zemindeki limonlara ait ağırlık tahmini.



Şekil 10. Zemindeki limonların terazi ile tartılması.

6. SONUÇLAR

Limon ağaçlarından resim elde edilirken ortamın ışık miktarı, limonların yaprak arkasında kalıp çok az bir kısmının resimde görünmesi, uygulamamızda yansıyan ışıktan dolayı limonun sarı renk dışında bir renkte algılanıp yok sayılması ağaç üzerindeki limonların tespitini olumsuz etkilemektedir. Ayrıca bazı limonların piksel değerlerinin çok küçük olup YSA tarafından ağırlık tahmininde 0 gr ağırlık olarak tahmin edilmesi de uygulamanın doğruluk oranını düşürmektedir (ortalama %72,8). Ancak çalışma, onlarca farklı ağaç için gerçekleştirilip, yaprak arkasında kalan kısımlar için genel bir düzeltme katsayısı oluşturularak bahçenin tamamı için daha doğru bir sonuç çıkarılabilir.

Ağaçtan bağımsız olarak çekilen limon resimlerinde uygulamamız %99,13 oranında doğru tahminde bulunmuştur. Bu durum tasarladığımız yapay sinir ağının tahmin gücünü göstermektedir. Rekolte tahmininde bulunulacak ağacın resmi elde edilirken ortamdaki güneş ışığı miktarı uygun olup, daha az yapraklı ağaçlar ile daha doğru sonuçlara ulaşılabilir. Resimler daha kaliteli fotoğraf makineleri ile çekilirse resimdeki limon tespiti oranı daha da artabilir. Ayrıca YSA eğitilirken veri seti için kullanılan resimler bizim çektiğimiz uzaklıklar (0,5 metre, 1 metre, 2 metre, 2,5 metre) dışındaki mesafelerden de çekilerek eğitimin kalitesi artırılabilir.

Yazar Katkıları

Her bir yazar da çalışmaya eşit miktarda katkıda bulunmuştur.

Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

KAYNAKÇA

[1] Tarım ve Orman Bakanlığı, "Tarım Ürünleri Piyasa Raporu-Limon", Temmuz 2020.

[2] R. Linker, O. Cohen, and A. Naor, "Determination of the number of green apples in RGB images

- recorded in orchards”, Computers and Electronics in Agriculture, vol. 81, pp. 45-57, 2012.
- [3] O. Er, B. Çetişli, M. M. Sofu, ve M. C. Kayacan, “Gerçek zamanlı otomatik elma tasnifleme”, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, vol. 17, no. 2, pp. 31-38, 2013.
- [4] F. Kurtulmuş, “Olgunlaşmamış Şeftali Meyvesini Doğal Bahçe Koşullarında Alınmış Görüntülerde Görüntü İşleme Teknikleri Ve Yapay Sınıflandırıcılarla Saptayarak Sayan Algoritmaların Geliştirilmesi”, Uludağ Üniversitesi Fen Bilimleri Enstitüsü Doktora Tezi, 2013.
- [5] Ören, S. , “Görüntü İşleme Yöntemi ile Salatalık Kalite Değişiminin Sayısal Analizi”, Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi, 2012.
- [6] G. H. Yaşar, “Görüntü İşleme İle Ağaç Meyve Yükünün Hesaplanması”, Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Yüksek Lisans Tezi, 2019.
- [7] O. Tosun, “Görüntü İşleme İle Yaprak Alanı Ölçüm Sistemi Tasarımı”, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi, 2015.
- [8] İ. B. Akıncı, “Gerçek Zamanlı Olarak Meyveleri Görüntü İşleme İle Sınıflandıran Otomasyon Sistemi”, Karabük Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi, 2017.
- [9] H. Ergezer, M. Dikmen, ve E. Özdemir, “Yapay Sinir Ağları Ve Tanıma Sistemleri”, Pivolka, vol. 2, no. 6, pp. 14-17, 2003.
- [10] R. Kav, “Meteorolojik Parametrelerden Minimum ve Maksimum Hava Sıcaklığının Regresyon ve Yapay Sinir Ağları Yöntemi ile Tahmini”, Selçuk Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi, 2019.
- [11] R. C. Gonzales, R. E. Woods, “Digital Image Processing”, 4. Edition, 2018.
- [12] G. Çankaya, M. H. Arslan, ve M. Ceylan, “Görüntü işleme ve yapay sinir ağları yöntemleri ile betonun basınç dayanımının belirlenmesi”, Selçuk Üniversitesi Mühendislik Fakültesi Bilim ve Teknoloji Dergisi, 2013.
- [13] B. Jahne, “Practical handbook on image processing for scientific and technical applications”, CRC press, (Chapter 1), 2014.
- [14] C. Küpeli, F. Bulut, “Görüntüdeki Tuz Biber ve Gauss Gürültülerine Karşı Filtrelerin Performans Analizleri”, Halıç Üniversitesi Fen Bilimleri Dergisi, vol. 3, no. 2, pp. 211-239, 2020.
- [15] Y. Zhu, C. Huang, “An Improved Median Filtering Algorithm for Image Noise Reduction”, Physics Procedia, vol. 25, pp. 609-616, 2012.
- [16] N Otsu - IEEE transactions on systems, man, and cybernetics, 1979.
- [17] E. Öztemel, “Yapay Sinir Ağları”, Papatya Yayıncılık Eğitim, İstanbul, 2003.
- [18] M. F. Keskenler, E. F. Keskenler, “Geçmişten Günümüze Yapay Sinir Ağları ve Tarihi”, Takvim-i Vekayi, vol. 5, no. 2, pp. 8-18, 2017.