

KMÜ Mühendislik ve Doğa Bilimleri Dergisi

<https://dergipark.org.tr/pub/kmuajens>

5(1), 67-84, (2023) © KMUJENS

e-ISSN: 2687-5071

<https://doi.org/10.55213/kmuajens.1291397>



Görüntü İşlemeye Dayalı Yapay Zekâ Teknikleri Kullanılarak Rekolte Tahmini: Elma Ağacı Uygulaması

The Yield Prediction Using Artificial Intelligence Techniques Based on Image Processing: Apple Tree Implementation

Şule Ataç¹, Ahmet Kayabaşı^{2,*}

^{1,2} Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi, Karamanoğlu
Mehmetbey Üniversitesi, Karaman, Türkiye

(Alındı: 2 Mayıs 2023; Kabul edildi: 24 Mayıs 2023)

Özet. Tarım sektörü, insanlığın ekonomik ve sosyal gelişiminde çok önemli görevler üstlenmiş ve bu görevini günümüze kadar sürdürmüştür. Tarımsal üretim doğa koşullarına bağlı olduğu için risk ve belirsizlik yüksektir. Günümüzde birçok alanda teknolojik gelişmeler yaşanmıştır. Özellikle tarım alanında yapay zekânın kullanımına yönelik büyük bir gelişme gösteren bilgisayar teknolojileri sayesinde, tarımda yaşanan bu risk ve belirsizliklere daha hızlı ve tutarlı çözümler üretmek mümkün hale gelmiştir. Tarımda yaşanan risk ve belirsizliklerden biri de rekolte tahminidir. Bu tahminlerde belirsizlik yüksek olduğu için yapay zekâdan faydalanmak doğruluk oranını arttıracaktır. Bu çalışmada elma ağaçlarındaki toplam rekoltenin tahmini için yapay zekâ ve görüntü işleme tekniklerinden faydalanılmıştır. Evrişimsel sinir ağları (ESA), doğrusal regresyon (DR) ve hazırlanan bir yapay sinir ağı (YSA) modeli ile tahmin çalışması yapılmıştır. Farklı yapay zekâ modelleri ile yapılan bu çalışmaların sonucunda doğrulukları kıyaslanarak % 85 'in üzerinde doğruluk oranları elde edilmiştir.

Sorumlu Yazar Email: ahmetkayabasi@kmu.edu.tr, orcid.org/0000-0002-9756-8756.

Anahtar Kelimeler: Tarım, elma rekoltesi, görüntü işleme, yapay zekâ, evrimsel sinir ağları.

Abstract. The agricultural sector has undertaken significant roles in the economic and social development of humanity and has continued this task until today. Risk and uncertainty are high as agricultural production depends on natural conditions. Today, there have been technological developments in many fields. Thanks to computer technologies, which have made great progress especially in the use of artificial intelligence in the field of agriculture, it has become possible to produce faster and more consistent solutions to these risks and uncertainties in agriculture. One of the risks and uncertainties experienced in agriculture is yield estimation. Since the uncertainty in these estimates is high, making use of artificial intelligence will increase the accuracy rate. In this study, artificial intelligence and image processing techniques were used to estimate the total yield of apple trees. Estimation study was carried out with convolutional neural networks (CNN), linear regression and a prepared artificial neural network (ANN) model. As a result of these studies with different artificial intelligence models, accuracy rates of over 85 % were obtained by comparing their accuracy.

Key words: Agriculture, apple harvest, image processing, artificial intelligence, convolutional neural networks.

1. Giriş

Elma, bir sonbahar meyvesidir ve genellikle eylül ayında hasat edilmeye başlanır. Elma fidanları yaklaşık 2-3 yaşında meyve vermeye başlamaktadır. Elma ılıman, özellikle soğuk ılıman iklim bitkisidir. Ülkemizde Elma birkaç bölge dışında hemen hemen her yerde yetiştirilebilir. Türkiye İstatistik Kurumu (TÜİK) verilerine göre Türkiye’de, 2022 yılında üretim miktarları önceki yıla göre artış gerçekleştirdiğini göstermiştir. Tahıl ürünlerinde ve diğer bitkisel ürünlerde (yem bitkileri hariç) 2021 yılına göre % 14,6 oranında artarak yaklaşık 70,2 milyon ton üretilmiştir. Meyveler, İçecek ve baharat bitkileri ise % 7,7 artış göstererek 26,8 milyon ton olarak üretilmiştir. Sebzeler % 0,5 azalma eğilimi göstermiştir. Meyveler içinde önemli bir yeri olan elmanın üretiminin ise

% 7,2 oranında artış gösterdiği görülmektedir [11]. Elma üretiminde Karaman 9,2 milyon adet ile en fazla elma ağacına sahip il olarak ilk sırada yer almaktadır [12]. Verilen bilgiler incelenecek olursa elma üretimi ticari ve tarımsal faaliyet açısından Türkiye’de büyük önem arz etmektedir. Ülkemizde genellikle elmanın satışı elmanın toplandıktan sonra kilogram olarak satışından ziyade, elmalar daha toplanmamışken, yani daha ağaç dallarındayken bütün bahçedeki ürün olarak satılmaktadır. Bu durumda tüm ürünün miktarı net olarak belirlenemeyeceğinden tahmini bir fiyat verilerek satışı yapılmaktadır. Burada risk/belirsizlik yüksektir, yanlışlar ve hatalı tahminler yapılabilir. Bu durumda hata oranını düşürmek için yapay zekâdan yararlanmak doğruluk oranını arttıracaktır. Bir bilgisayarın tahmini, insan gözüne kıyasla daha yüksek doğrulukta sonuçlar verecektir. Bu konuyla ilgili literatürde bir çok farklı alanda, farklı teknikler kullanarak yapılmış çalışmalar mevcuttur.

Lozano vd. kümeler halinde olan bahçe bitkilerinin verimini hesaplamaya yönelik bir çalışma yürütmüşlerdir. Örnek olarak muz ve üzüm gibi bitkiler kümeler halinde ürün verirler. Muz ağacı üzerinde bir çalışma yaparak diğer benzer bitkilere öncülük eden bir derin öğrenme çalışması yapmışlardır. Maske bölgesi tabanlı evrimsel sinir ağları (MBESA) yöntemini kullanmışlardır. MBESA aynı anda segmentasyon maskeleri oluştururken bir görüntü içindeki nesnelere algılayarak görüntü tanımayaya yardımcı olur. MBESA ile bir görüntüdeki karmaşık muz meyvesinin tespiti, muz sınıfını tahmin ederken aynı zamanda meyveyi arka planından ayıran bir maske oluşturur. Muz burmalarına dayalı gerçek bir veri seti kullanmışlardır. Derin öğrenme modeliyle ortalama % 92,5 ile iyi bir doğruluk elde etmişlerdir. Muz katmanlarında başarıyla uygulanan bu derin öğrenme sınıflandırmasının diğer kümelenebilir bahçe bitkileri için de temel oluşturabilecektir [7]. Aggelopoulou vd. elma bahçelerinde ağaçların çiçeklenme döneminde belirlenen çiçek miktarına göre verim tahmini yapmaya çalışmışlardır. Amaçları bir elma bahçesindeki çiçek yoğunluğu değişkenliğini görüntü analizi kullanarak incelemek ve görüntü analizinden belirlenen çiçek yoğunluğu ile meyve verimi arasındaki ilişkiyi modellemektir. Araştırmalarını, Orta Yunanistan'daki ticari bir elma bahçesinde gerçekleştirmişlerdir. Nisan 2007'de, ağaçlar tam çiçek açarken, sistematik tekdüze rastgele örnekleme prosedürü izlenerek ağaçların fotoğraflarını çekmişler ve on ağaç

başına verim ölçülerek ve on ağacın merkezinin konumu kaydedilerek verim haritalaması yapmışlardır. Bu verileri kullanarak, tam çiçek açan ağacın resmini analiz ederek ağaç verimini tahmin eden görüntü işleme tabanlı bir algoritma geliştirmişlerdir. 53 elma ağacı için değerlendirilen algoritma, tahmin edilen verimde % 18 hata göstermiştir [1]. Payne ve ekibi (2013) mango ağaçlarındaki meyve miktarını saymak için görüntü işleme dayalı bir yaklaşım sunmuşlardır. Ağaçların gündüz vakti görüntülerini elde ederek ağacın makina görüşüne dayalı verimini hesaplamaya çalışmışlardır. Belirledikleri mango ağacı tarlasında hasat zamanı gelmeden 3 hafta önce 3 günlük süre boyunca 15 ağacın her birinin meyvelerini tek tek saymışlar ve ağaçların dört bir taraftan görüntülerini almışlardır. Bu görüntüler için pikseller, renk segmentasyonu kullanılarak meyvenin piksellerini arka plan piksellerine bölmüştür. Görüntü işleme teknikleri ile meyvelerin görüntülerini resimden ayırarak sayma işlemi yapmışlar ve toplam 555 görüntüden oluşan veri seti kullanmışlardır. Sayma işleminden sonra bir ağaçtaki toplam mango ağırlığını hesaplayabilmek için her bir mangoya ortalama bir ağırlık verilmiş ve çıkan sayı ile çarpılmıştır. Bu şekilde yapmış oldukları çalışma ile meyve sayısı çok fazla değilken doğruluk oranı yüksek tahminler yapmışlardır. Fakat meyve sayısı arttıkça algoritmalarının etkinliğinin azaldığını fark etmişlerdir. Meyve yükü üzerinde aydınlatma konusunu da tartışmışlardır [10]. Nuske vd. görüntü işleme ile radial simetri kullanarak üzüm bağlarındaki toplam üzüm miktarını hesaplamaya yönelik bir çalışma yapmışlardır. Çalışmalarında iki farklı üzüm türü kullanmışlar, 224 asma olan bir bağ için bu çalışmayı yapmışlar ve % 9,8 hata ile ürün verimini ölçmüşlerdir. Görüntüleri yan tarafına bakan kameralara sahip küçük bir bağ aracı ile toplamışlardır. Mesafeyi de yaptıkları radyal simetri hesaplamalarında değerlendirmeye katmışlardır. Toplam üzümün hesaplama sonuçlarını gerçek olanlar ile kıyaslayarak doğruluğunu test etmişlerdir. % 9,8'luk bir hata payı belirlemişlerdir [9]. Baştürk ve arkadaşları görüntü işleme teknikleri kullanarak bir ağaçtaki elma sayısını belirlemeye çalışmışlardır. Yaptıkları çalışmada 20 farklı görüntü kullanmışlar ve bu görüntüler toplam 1360 meyve içermektedir. Meyvenin renk ve şekillerinden yola çıkarak görüntü işleme tekniklerini uygulamışlardır. Elde ettikleri görüntülerde farklı doğruluk oranlarına sahip sonuçlar bulmuşlardır. Hought dönüşümü tekniğinden faydalanmışlardır. % 80 den daha yüksek doğruluk oranına sahip sonuçlar elde etmişlerdir [2]. Cömert, Red Chief elma türü meyve ağaçlarında yapay zekaya dayalı

rekolte tahmini üzerine bir çalışma yapmıştır. Ağaçların görsellerini belirledikten sonra toplayarak gerçek değerlerle kıyaslama yapmışlardır. Matlab üzerinde bir çalışma hazırlamışlardır. Veri setlerinde 20 farklı ağaçtan görüntü işleme teknikleri ile elde ettikleri toplam piksellerden veri setleri oluşturmuşlardır. Böylece yapay zekâ kullanarak bir ağaçtan ne kadar verim alınabileceği tahmin ettirilmek istendiğinde tüm ağacın resmini çekmeleri ve analiz etmeleri gerekmektedir. Çalışmalarında 56,37 kg rekolteye sahip olan bir ağacın rekoltesi yapay zekâ ile 4,36 kg daha az tahmin edilmiştir [4]. Grilli ve arkadaşları, yaptıkları çalışmada bizlere tarladaki elma ağaçlarını incelemek, videolardan meyveleri otomatik olarak tespit etmek, büyüklüklerini ve sayılarını ölçmek için gelişmiş bir fotogrametrik çalışma sunmaktadır. Bu yaklaşım ile elma ölçümlerini daha objektif hale getirerek ve tarlada ölçülen elmaların daha kapsamlı bir şekilde toplanmasını sağlarken aynı zamanda hasat/elma toplama tarihlerini de tahmin ederek çiftçilerin ve ziraat mühendislerinin saha çalışmasını kolaylaştırması ve hızlandırmasını hedeflemişlerdir. Bunu hızlı ve otomatik olarak yapabilmek için akıllı telefon tabanlı videoları kullanan ve fotogrametri, derin öğrenme ve geometrik algoritmaları birleştiren bir sistem hazırlamaya çalışmışlardır. Aldıkları videodaki resim karelerini maskeleme aşamasında, K-ortalama ve MBESA derin öğrenme ağlarını kıyaslayarak BESA'nın daha verimli sonuçlar verdiği kanı getirmişlerdir. Yaptıkları çalışmada tamamen görünen elmaları tespit etmede % 100 başarı elde etmiş olsalar da kısmen görünen elmalar için % 82 kesinlik bildirmişlerdir [5]. İsik ve arkadaşları, yapmış olduğu çalışmada limon ağaçlarında toplam rekolteyi hesaplamaya yönelik yapay zekâdan yararlanan bir tahmin çalışması yapmıştır. Yaptığı çalışmada görsellerin yüklenebildiği bir arayüz hazırlanmıştır. Yüklenen görüntüye renge göre maskeleme işlemi uygulanmıştır. Limonlar sarı renkli olduklarından dolayı sarı renge yönelik maskeleme işlemi yapmıştır. Bu işlemden sonra otsu threshold yöntemiyle eşikleme yaparak resimleri siyah beyaza döndürme işlemi yaparak her bir konturu belirlemiştir. Konturların her birinin piksellerinden yola çıkarak yapay zekâyâ tahmin işlemi yaptırmaya çalışmıştır. Ağaç üzerinde yapmış olduğu denemelerde % 72,8 doğruluk oranını elde etmiştir. Toplanmış limon üzerinde % 99 değerine kadar doğruluk elde etmiştir [13].

Yapılan çalışmalar incelendiğinde ışığın gelme açısı, meyvenin rengi, kamera kalitesi, kullanılan yapay zekâ tahmin modeli, kullanılan görüntü işleme tekniği, hazırlanan veri setleri gibi durumların tahmin sonuçları üzerinde olumlu veya olumsuz etkileri olmuştur. Uygun yöntemlerin kullanılması ile alınan sonuçlar daha yüksek olabilecektir.

2. Materyal ve Yöntem


2.1. Materyal

Bu çalışmada bilgisayar ile görüntü işleme teknikleri uygulanarak elde edilen elma ağacı görüntüsü piksellerinden yapay zekâ yardımı ile rekolte tahmini yapılmaya çalışılmıştır. Yapay zekânın eğitilmesi için kullanılan veri seti bilgileri Karaman'da mevcut olan elma bahçelerinden toplanmıştır. 272 adet görüntüye ait piksel hesaplanarak veri setine eklenmiştir. Her bir görüntünün pikseli için resmin bütününe oranı, ağaca olan mesafesi teker teker hesaplanıp veri setine eklenmiştir. Çalışmada Python dili kullanılmış ve OpenCv kütüphanesinden yararlanılmıştır. Veri seti Python dilinde hazırlanmış olan görüntü işleme teknikleriyle elde edilmiş piksel bilgilerini içermektedir. Bu çalışma için görüntülerin telefon üzerinden toplanabileceği bir Android uygulama tasarlanmış ve uygulama yazılan bir API ile haberleşmektedir. API için Python Flask kütüphanesinden yararlanılmıştır.

2.2. Yöntem

Çalışmada elma rekoltesinin hesabının yapılabilmesi için toplanan görüntülerin farklı aşamalardan geçmesi gerekmektedir. İlk aşama olarak yapay zekâ için veri seti hazırlanmıştır. Veri seti toplanan elmaların belli mesafelerde çekilmiş görsellerinden faydalanarak ayarlanmıştır. Bu işlemten sonra yapay zekâ eğitim modelinin belirlenip eğitilmesi gerekmektedir. Model belirlendikten sonra tahmin işlemi için görüntülerin bir dizi işlemten geçerek tahmine hazır hale getirilmesi gereklidir. Bunun için görüntü işleme tekniklerinden faydalanılmıştır. Çalışmada görüntüler 6944 x 9280 çözünürlüğe sahip kamerası olan bir telefon tarafından toplanmıştır. Bu çalışma kullanıcıya yönelik olarak hazırlandığı için kullanıcıların kullanabilmesi adına bir telefon uygulaması da hazırlanmıştır. Çalışmada ilk uygulanan yöntem yapay zekâyı eğitmeye kullanılacak olan

veri setinin toplanmasıdır. Bu işlem için ilk olarak elma bahçelerinden toplanmış olan elmaların belli mesafelerden çekilmiş görüntüleri gerekmektedir. Bu çalışma için 0,5 metre, 1 metre, 1,5 metre, 2 metre, 2,5 metre, 3 metre, 3,5 metre, 4 metre mesafelerden arka planı beyaz olan düz bir zemine yerleştirilen elmaların resimleri çekilmiştir. Şekil 1(a) ve Şekil 1(b)'de 1 ve 1,5 metre mesafeden alınmış, toplanan elma görüntüleri görülmektedir.



Şekil 1. (a) 1 metre mesafeden elmaların görüntüsü. (b) 1,5 metre mesafeden elmaların görüntüsü.

Farklı mesafelerden çekilme sebebi, rekoltesi hesaplanacak olan görsellerin kullanıcı tarafından belirlenecek olmasıdır. Kullanıcının ağaca olan mesafesi değişkenlik gösterebilir. Bu sebeple mesafe doğru tahmin için önemli bir kriterdir. Her bir elmanın ağırlığı Şekil 2'de görüldüğü gibi hassas tartı kullanılarak hesaplanmış ve veri setine eklenmiştir.



Şekil 2. Hassas tartı ile elma ağırlık ölçümü.


Veri setine eklenen bir diğer kritik parametre ise her bir görüntü için elde ettiğimiz piksel değeridir. Bunu hesaplaması için görüntü işleme tekniklerinden faydalanılmıştır. Toplam 278 görüntü, veri setine yapay zekâ eğitiminde kullanılmak üzere eklenmiştir.

2.3. Görüntü İşleme Teknikleri


Görüntü işleme, bir görüntüde görünmeyen veya görünmesi zor olan nesnelerin bulunması, görüntüde nesnelere ayırt etme veya algılama, orijinal görüntüden daha net ve gelişmiş bir görüntü oluşturma, görüntüdeki nesnelerin etrafındaki çeşitli desenleri ölçme ve algılama, orijinal görüntüye benzer büyük bir dijital görüntü veri tabanından görüntülere göz atma ve bu görüntülerde arama yapma gibi amaçlarla kullanılır [6]. Bu çalışmada bir çok görüntü işleme tekniğinden yararlanılmıştır. Bunları sıralayacak olursak resmi yeniden boyutlandırma, RGB resmi HSV formatına dönüştürme, renge göre maskeleme, erezyon ve genişleme morfolojik işlemleri, eşikleme ve konturları saydırma şeklinde olacaktır. Şekil 3’de kırmızı elma ağacının HSV formatına dönüştürülmüş hali görülmektedir. Şekil 4 ise aynı ağacın HSV formatındaki ağaç görselinin renge göre maskelenmiş halidir. Ağacın Morfolojik işlemlere tabi tutulmasından sonraki hali ise Şekil 5’te görülmektedir.



Şekil 3. RGB resmin HSV formatına dönüştürülmesi.



Şekil 4. HSV formatında olan resme, renge göre maskeleye uygulanması.



Şekil 5. Renge göre maskelenmiş resme erezyon, genişleme ve otsu threshold yöntemi uygulanması.


Bir elma ağacının çekilmiş olan resmine sırasıyla Şekil 3, 4 ve 5 teki gibi görüntü işleme adımları uygulandıktan sonra kontur saydırma işlemi yaptırılır. Belirlenen her bir elmanın pikseli saydırılır ve veri seti listesine kaydedilir. Python'da OpenCv kütüphanesinde kontur saydırma için hazır bir fonksiyon mevcuttur. Bu fonksiyondan yararlanarak kontur hesaplaması yapılmıştır.

2.4. Yapay Zekâ Tahmin Modelleri ve Rekolte Tahminleri

Yapay Zekâ, insan yeteneklerini hem taklit edecek hem de ötesine geçecek şekilde davranabilen bilgisayarlar ve robotlar geliştirme alanıdır diyebiliriz. Yapay zekâ özellikli programlar, bilgi sağlamak veya insan müdahalesi olmadan eylemleri otomatik olarak tetiklemek için verileri analiz edebilirler. Bu çalışmada yapay sinir ağı (YSA) modeli, doğrusal regresyon (DR) yöntemi ve evrimsel sinir ağları (ESA) olmak üzere üç farklı yapay zekâ modeli kullanılmıştır.

2.4.1. YSA Modeli


YSA, belki de en kullanışlı sinir ağı türündendir ve genellikle tek katmanlı sinir ağları veya çok katmanlı algılayıcılar olarak adlandırılır. YSA'nın yapı taşları yapay nöronlardır. Şekil 6'da görüldüğü gibi nöronlar, ağırlıklı giriş sinyallerine sahip olan ve bir aktivasyon fonksiyonu kullanarak bir çıkış sinyali üreten basit hesaplama birimleridir. Nöronlar, nöron ağları halinde düzenlenmiştir. Bir dizi nöron katman olarak adlandırılır ve bir ağ birden çok katmana sahip olabilir. Ağdaki nöronların mimarisine genellikle ağ topolojisi denir. Son gizli katman, çıktı katmanı olarak adlandırılır ve problem için gereken formata karşılık gelen bir değer veya değerler vektörünün çıktısından sorumludur. Çıktı katmanındaki aktivasyon fonksiyonunun seçimi, modellediğiniz problemin türü tarafından büyük ölçüde kısıtlanmıştır. Mesela, Bir regresyon probleminde tek çıkış nöronu olabilir ve nöronun aktivasyon fonksiyonu olmayabilir [3].



Şekil 6. Nöron yapısı.

Bu çalışmada, YSA'nın eğitimini için Python Keras kütüphanesinden yararlanılmıştır. İlk model denemesi olarak hazırlanan çok katmanlı mimariye sahip bir sinir ağından faydalanılmıştır. 74 adet elmanın belli mesafelerden pikselleri ölçülmüş ve bu piksel verileri YSA eğitimine dâhil edilmiştir. Model hazırlanırken ardışık metodu ile ardışık

katmanların oluşturulması sağlanmıştır. Giriş katmanında 3 adet input girdisi ve 128 adet nöron kullanılmıştır. Ara katmanda tek katman mevcut olup 64 nöron kullanılmıştır. Aktivasyon fonksiyonu olarak relu tercih edilmiştir. Çıkış katmanında tek bir çıkışımız olacağı için 1 adet nöron ve aktivasyon yöntemi olarak da linear tercih edilmiştir. Araya dropout fonksiyonu da koyulmuştur. Bu fonksiyon verilen oranda nöronların ağırlık değerlerini değiştirir. Böylece ölü nöronların oluşması önlenmiştir. Verisetinde kullanılan elma görüntüleri Şekil 7’de ve verisetindeki yerleri Tablo 1’de görülmektedir. YSA ile verisetindeki herbir elmanın pikseli, resme göre oranı ve kamera mesafesine göre tahminleme yapılmıştır.



Şekil 7. Veri seti oluşturabilmek için tespit edilen elmalar örneği

Tablo 1. Veri seti bilgileri örneği.

#	Elma Pikselleri	Resme Oranı	Yakınlık (Metre)	Ağırlık (gram)
1	1079px	0.0017	0,5m	42g
2	1267px	0.002	0,5m	96g

3	1995px	0.0031	0,5m	122g
4	779px	0.0012	0,5m	56g
5	1003px	0.0016	0,5m	64g
6	1448px	0.0022	0,5m	111g
7	502px	0.0008	0,5m	28g
8	372px	0.0006	0,5m	44g
9	1522px	0.0024	0,5m	93g
10	2015px	0.0031	0,5m	123g

2.4.2. DR Yöntemi

DR, tahmin edilen çıktının sürekli olduğu ve sabit bir eğime sahip olduğu denetimli bir makine öğrenimi algoritmasıdır. Değerleri, kategoriler halinde (örneğin kedi, köpek) sınıflandırmaya çalışmak yerine, sürekli bir aralık (örneğin satış, fiyat) içinde tahmin etmek için kullanılır. Keras kütüphanesinde DR için hazır fonksiyon mevcuttur ve bu çalışmada bu fonksiyondan yararlanılarak tahmin işlemi yapılmıştır. Tahmin işlemi için girdi/hedef bilgilerini belirtilmiş ve normalize edilmiştir. Hassas ölçümler için normalize önemli bir aşamadır. Eğitim verilerini X_egitim ve buna karşılık gelen hedef ağırlıkları Y_egitim olarak adlandırılmıştır. Eğitim için için scikit-learn kütüphanesinden LinearRegression sınıfına ihtiyaç duyulur. Bu sebeple kütüphaneyi indirilip sınıf nesnesi oluşturulmuştur. Son olarak fit() metodu kullanılarak modelin eğitimi gerçekleştirilmiştir. Böylece model oluşturmuş ve eğitilmiştir. Eğitim sonucunda ortalama mutlak hata (OMH) değeri % 21,61 olarak belirlenmiştir.

2.4.3. ESA Tahmin Modeli

ESA derin öğrenmede kullanılan en popüler sinir ağlarından birisidir. ESA modelleri, birden çok katmandan oluşur ve çoğunlukla görüntü işleme ve nesne algılama için

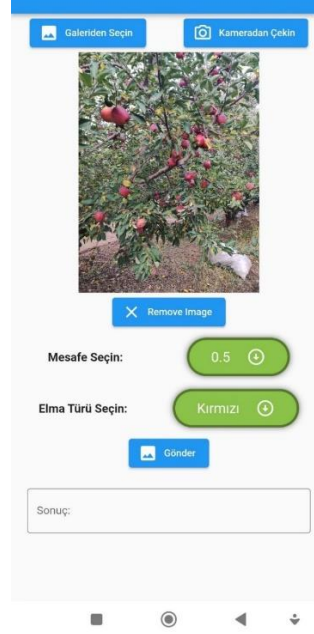
kullanılırlar [8]. ESA bir derin öğrenme modeli türüdür ve evrişim katmanlarından oluşur. Verilen girdinin boyutlarına göre tahmin modeli oluşturur. Bu çalışmada ESA ile tek boyutlu sinir ağları kullanılmıştır. Çalışmada 3 girdi ve bir çıktı vardır. Ara katmanda 64 adet nöron kullanılmıştır. Önceki çalışmalarda olduğu gibi drop out ile ölü nöron oluşturulması önlenmiştir. Model eğitimde kullanılan veriler % 80 eğitim ve % 20 test olacak şekilde ayarlanmış ve eğitim işleminde Python Keras kütüphanesi kullanılmıştır.

2.4.4. Python API Hazırlanması

Çalışmada hazırlanacak olan mobil uygulama ile haberleşmeyi sağlamak için bir API yazılmasına ihtiyaç duyulmuştur. API olarak REST API türünden yararlanılmıştır. REST API hizmetleri, yalnızca HTTP istekleri yaparak veri tabanı ile etkileşim kurmanıza olanak tanır. Bu çalışmada, Flask kullanarak bir REST sunucusu yazılmıştır. Bunun için Python Flask kütüphanesinden yararlanılmıştır. Flask bir web framework aracıdır ve web uygulamalarını kolayca geliştirmenizi sağlayan bir Python modülüdür. Bu kütüphane ile birkaç satır kod yazarak basit bir uygulama hazırlamak mümkündür. Bu sebeple API yazarken tercih sebebi olmuştur. Bir sunucu ayarlanarak API dışarıdan ulaşılabilir hale getirilmiştir.

2.4.5. Mobil uygulama tasarımı

Mobil uygulama kullanıcı arayüzü için Android studio ortamında Flutter ile hazırlanmıştır. Uygulama hazırlanan API ve sunucu ile haberleşerek topladığı görüntüleri iletme işlemini yapmaktadır. Uygulamada iki adet görüntü almaya yarayan buton bulunmaktadır. Bunlardan ilki direkt kameradan görüntüyü almayı sağlar ve diğeri de kullanıcının galerisinde mevcut olan görsel varsa onu seçmesini sağlar. Şekil 8’de görüldüğü gibi kullanıcının mesafeyi ve elmanın türünü seçmesi gereklidir.



Şekil 8. Mobil uygulama görüntüsü.

3. Sonuç ve Öneriler

Çalışma Karaman’da bulunan elma bahçelerinde gerçekleştirilmiştir. Karaman’da elma üretimi tüm ülke bazında önem arz etmektedir. Araştırmalara göre ülkenin en çok elma ağacına sahip olan şehridir. Yaklaşık 1300 tane elma üreticisi olduğu belirlenmiştir. Buradan yola çıkarak bu projenin yapılması üreticiler açısından da faydalı olacaktır. Çalışmada iki farklı tür ağaç üzerinde ve toplanmış elmalar üzerinde tahmin çalışması yapılmıştır. Kırmızı türde elmaya sahip olan Starking elma ve sarı elma olarak bilinen Golden cinsidir. Farklı ağaçlar oldukları için her birisine ayrı olarak renge göre görüntü işleme teknikleri uygulanmıştır. Şekil 9’da üzerinde çalışma yapılmış olan Starking elma ağacı, Şekil 10’da üzerinde çalışma yapılmış olan Golden cinsi elma ağacı ve Şekil 11’de çalışmalarda kullanılmış olan toplanmış Starking elmalar görülmektedir.



Şekil 9. Starking elma ağacı.



Şekil 10. Golden cinsi elma ağacı.



Şekil 11. Toplanmış starking elmalar.

Ağaç ile yapılan çalışmalarda YSA, DR ve ESA ile yapılmış olan tahminlerdeki doğruluk oranı sonuçları aşağıdaki çizelgelerde belirtilmiştir. YSA ile yapılmış olan tahminlerdeki doğruluk oranı Tablo 2’de görülmektedir. Tablo 3, DR tahmin sonuçlarını ve Tablo 4, ESA tahmin sonuçlarını göstermektedir.

Tablo 2. YSA tahmin sonuçları

Tür	Gerçek Rekolte Değeri (kg)	Tahmin Edilen Rekolte Değeri (kg)	Doğruluk Oranı
Golden Elma Ağacı	200,73	203,97	% 98,38
Starking Elma Ağacı	27	29,3	% 91,49
Toplanmış Starking Elma	0,372	0,36	% 96,77

Tablo 3. DR tahmin sonuçları

Tür	Gerçek Rekolte Değeri (kg)	Tahmin Edilen Rekolte Değeri (kg)	Doğruluk Oranı
Golden Elma Ağacı	200,73	230,88	% 85
Starking Elma Ağacı	27	29	% 92,6
Toplanmış Starking Elma	0,372	0,38	% 97,85

Tablo 4. ESA tahmin sonuçları

Tür	Gerçek Rekolte Değeri (kg)	Tahmin Edilen Rekolte Değeri (kg)	Doğruluk Oranı
Golden Elma Ağacı	200,73	195	% 97,2
Starking Elma Ağacı	27	25,27	% 91,6
Toplanmış Starking Elma	0,372	0,38	% 97,85

Toplanmış elmaların tahmininde % 95'in üzerinde doğruluk oranı tespit edilirken ağaç üzerinde yapılan tahmin oranı daha düşüktür. Çekilen fotoğrafın durumuna göre değişkenlik göstermektedir. Üzerinde denemeler yapılan ağaçlarda % 85'in üzerinde doğruluk tespit edilmiştir. En başarılı yöntemin ESA ve hazırlanan yapay sinir ağına olduğunu gözlemleyebiliriz. Ağaçlardan toplanan görsellerde rekolte tahmini için uygulama üzerinden doğru mesafenin girilmesi önemlidir. Çalışmada tahmin doğruluğunu etkileyen birçok olumsuz durumla karşılaşmıştır. Kameranın kalitesi, güneş ışınlarının elma meyvelerinin üzerine düşme açısı, ağaç yapraklarının elma meyvelerinin üzerini kapatması sonuçları olumsuz yönde etkilemiştir. Dış etkenlerden kaynaklı olumsuz durumları azaltarak ve yapay zekâ eğitiminde bazı değişiklikler yaparak doğruluk oranını arttırabilecektir.

KAYNAKÇA

- [1] Aggelopoulou AD., Bochtis D., Fountas S., Swain KC., Gemtos TA., Nanos GD., Yield prediction in apple orchards based on image processing, Precision Agriculture 12(3), 448-456, (2010).
- [2] Baştürk MÖ., Turgut K., Hocaoglu AK., Görüntü İşleme Tabanlı Elma Ağacında Rekolte Tahmini, URSI-TÜRKİYE 2021 X. Bilimsel Kongresi, (2021).
- [3] Brownlee J., Crash Course on Multi-Layer Perceptron Neural Networks, from <https://machinelearningmastery.com/neural-networks-crash-course/>, (2016).
- [4] Cömert O., Sayısal Görüntüleme Destekli Red Chief Elma Rekolte Tahmini, Gaziosmanpaşa Üniversitesi, (2013).
- [5] Grilli E., Battisti R., Remondino F., An Advanced Photogrammetric Solution to Measure Apples, Remote Sensing, 13(19), (2021).
- [6] Kaymak AM., Örnek MN., Kahramanlı H., Görüntü İşleme Teknolojilerinin Elma Bahçelerine Yönelik Kullanım Örneği, Uluborlu Mesleki Bilimler Dergisi, 2(1), 17-26, (2019).

- [7] Le TT., Lin CY., Piedad Jr. E., Deep learning for noninvasive classification of clustered horticultural crops – A case for banana fruit tiers, *Postharvest Biology and Technology*, 156, (2019).
- [8] Mandal M., Introduction to Convolutional Neural Networks (CNN), from <https://www.analyticsvidhya.com/blog/2021/05/convolutional-neural-networks-cnn/>, (2021).
- [9] Nuske S., Achar S., Bates T., Narasimhan S., Singh S., Yield estimation in vineyards by visual grape detection, 2011 IEEE/RSJ International Conference on Intelligent Robots and Systems, IEEE, (2011).
- [10] Payne AB., et al., Estimation of mango crop yield using image analysis–segmentation method, *Computers and electronics in agriculture*, 91, 57-64, (2013).
- [11] Türkiye İstatistik Kurumu 2022, Bitkisel Üretim İstatistikleri,2022. <https://data.tuik.gov.tr/Bulten/Index?p=Bitkisel-Uretim-Istatistikleri-2022-45504> [Ziyaret Tarihi: 10 Mayıs 2023].
- [12] Tob, T. O. B., Elma, Ocak-2021, Tarım Ürünleri Piyasaları, Tarım ve Orman Bakanlığı / TOB: 1-4, (2021).
- [13] Yalçın I., Mücahit Ü., Kayabaşı A., Bilgisayarlı Görü Teknikleri Kullanılarak Yapay Zekâ Temelli Limon Ağacı Rekolte Tahmini, *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 4(1), 80-88, (2022).