



ULUBORLU MESLEKİ BİLİMLER DERGİSİ (UMBD)

Uluborlu Journal of Vocational Sciences

<http://dergipark.gov.tr/umbd>

CEVİZ SÜRGÜN GÖRÜNTÜLERİ KULLANILARAK CEVİZ ÇEŞİTLERİNİN SINIFLANDIRILMASI

Ali Altınalan¹ , Kıyas KAYAALP^{2*} 

¹Isparta Uygulamalı Bilimler Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Isparta, Türkiye.

^{2*} Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, Isparta, Türkiye.

*Sorumlu Yazar: kiyaskayaalp@isparta.edu.tr

(Geliş/Received: 02.08.2023; Kabul/Accepted: 25.10.2023)

ÖZET: Ülkemizde ceviz, kabuklu yemişler arasında en çok tüketilen yemiş türleri arasındadır. Ancak ihtiyacı karşılayacak kadar ceviz üretimi yapılamamaktadır. Ceviz dikilirken toprağa ve uygun iklim koşullarına göre türlerinin seçilmesi gerekir. Cevizlerin sınıflandırılması için ceviz meyvesinden yararlanılmaktadır. Ceviz ağacının yetiştirilip meyve vermesi için en az 4-5 yıl geçmesi gerekir. Bu süre zarfından sonra ürüne göre gerçek sınıflandırma işlemi yapılabilir. Geçen süreyi kısaltabilmek için ceviz sürgün görüntüleri ile derin öğrenme modelleri kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Bunun için 10 farklı ceviz türüne ait 3552 ceviz sürgün görüntüsü kullanılmıştır. Görüntüler Isparta ili, Eğirdir ilçesinde yer alan Tarım ve Orman Bakanlığı Meyvecilik Araştırma Enstitüsü Müdürlüğü'ne ait, ceviz ağaçlarının yetiştiriciliğinin ve bakımının yapıldığı bahçeden elde edilmiştir. Gerçekleştirilen eğitim sonucunda en iyi sonuç %91,87 doğruluk oranı ile EfficientNetB0 derin öğrenme modelinden elde edilmiştir.

Anahtar Kelimeler: Ceviz Sürgünü, CNN, Derin Öğrenme, Sınıflandırma

CLASSIFICATION OF WALNUT VARIETIES USING WALNUT SHOOT IMAGES

ABSTRACT: In our country, walnuts are among the most consumed nuts among nuts. However, there is not enough walnut production to meet the need. When planting walnut, it is necessary to select the species according to the soil and suitable climatic conditions. Walnut fruit is used for classification. It takes at least 4-5 years for the walnut tree to grow and bear fruit. After this period of time, real classification can be made according to the product. In order to shorten the time, the classification process was carried out using deep learning models with walnut shoot images. For this, 3552 walnut shoot images of 10 different walnut species were used. The images were obtained from the garden of the Fruit Growing Research Institute Directorate of the Ministry of Agriculture and Forestry in Eğirdir district of Isparta province, where walnut trees are cultivated and maintained. As a result of the training, the best result was obtained from the EfficientNetB0 deep learning model with an accuracy rate of 91.87%.

Keywords: Classification, CNN, Deep Learning, Walnut Shoot.

1. GİRİŞ

Tarımsal ürün yetiştiriciliğinde verimi artırmak ve desteklemek için yapay zekâ ürünlerinden yararlanılması artık kaçınılmaz bir gerçek olmuştur [1]. Ceviz kuraklığa ve soğuğa dayanıklı olan ve çeşitli farklı iklim koşullarında yetişebilen bir türdür. Başta uzak doğu olmak üzere Türkiye, İran, Avrupa ve Amerika'da üretimi yapılmaktadır. Bahar aylarındaki erken ve geç donlar Şekil 1'de gösterilen sürgünlere zarar verebilmektedir. Ayrıca yüksek sıcaklıktan dolayı verim düşebilmektedir.



Şekil 1. Ceviz sürgün görüntüsü

Türkiye'de üretilen kabuklu yemişlerde fındıktan sonra en çok üretimi yapılan ikinci kabuklu yemiş türüdür. Türkiye'deki kişi başına düşen tüketim değerine göre en çok tüketilen kabuklu yemiş türü 4 kg ile cevizdir. Yeterlilik bakımından ise üretilen ceviz miktarının yeterli olduğu söylenemez. 2022 yılında üretimi yapılan ceviz miktarı yaklaşık 335 bin tondur. Bunun sadece 35 bin tonu ihraç edilmiş, buna karşılık yaklaşık 100 bin ton cevizde ithal edilmiştir [2]. Dünya üzerinde en büyük ceviz üreticisi Tablo 1'de gösterildiği gibi Çin'dir. Çin'i sırasıyla Amerika, İran ve Türkiye takip etmektedir [3].

Tablo 1. Dünyada Ceviz Üretimi (ton) [3]

Ülkeler	2017	2018	2019	2020	2021
Çin	1.000.000	850.000	1.000.000	1.100.000	1.100.000
Amerika	571.530	615.980	594.206	716.680	657.710
İran	393.598	304.039	321.073	356.953	386.976
Türkiye	210.000	215.000	225.000	286.706	325.000
Meksika	147.198	159.535	171.367	164.651	135.946
Burkina Faso	107.000	127.000	128.000	128.000	137.267

Türkiye'de ceviz yetiştiriciliği arzı karşılayamamaktadır [4]. Yine TÜİK raporlarına göre 2022 yılında 8 bin ton civarı kayıp olmuştur, 15.327 ağaç ceviz meyvesi verirken 12.246 ağaç meyve vermemiştir [2]. Bu durum ceviz fidanı dikerken türünün tespitinin ne kadar önemli olduğunu göstermektedir. Var olan ağaçların verim olarak sadece %56'sından üretim elde edildiği tespit edilmiştir. Bu da ağaç başına düşen üretim kalitesinin düşük olduğunun bir göstergesidir.

Ceviz üretimi ve yetiştiriciliğinde en önemli sorunlardan birisi de ceviz türlerinin sınıflandırılmasıdır. Yetiştirici, ceviz fidanlarını bahçesine dikip 4-5 yıl geçtikten sonra ağaçlar meyve verdiklerinde, ceviz çeşidinin ne olduğunu anlayabilmektedir. Bazen bu süreç daha da uzayabilmektedir. Bu süre zarfında üretici bahçesindeki ağaçlar için sulama, gübreleme ve ilaçlama gibi işlemlere de hem zaman hem de para harcamaktadır. Bu süreci kısaltmak için sürgün görüntüleri kullanılarak ceviz çeşidinin sınıflandırma işlemini gerçekleştirebilmek oldukça önem arz etmektedir. Böylelikle üreticinin hem doğru ceviz çeşidi için yatırım yapması hem de verimi düşük olan ve bölgesinde yetişmeyecek ceviz türleri için emek harcamasının önüne geçilmesi hedeflenmiştir.

Bu çalışma literatürde yapılan araştırmalara göre ceviz sürgünleri kullanılarak CNN tabanlı derin öğrenme ile ceviz türlerinin sınıflandırılması için yapılan nadir çalışmalardan birisidir. Literatürde, ceviz sınıflandırma işlemleri için ceviz meyvesi kullanılmaktadır.

2. LİTERATÜR TARAMASI

Günümüzde görüntü sınıflandırma üzerinden yapılan çalışmaların sayısında oldukça büyük bir artış vardır. Temelde görüntü sınıflandırma nesne tanımadan hastalık tespitine kadar birçok disiplinde kullanılmaktadır. Eğitim [5], sağlık [6], ekonomi [7] ve tarım [8] sektörleri başta olmak üzere görüntü sınıflandırma artık gündelik hayatımızda da özellikle mobil uygulamaların geliştirilmesiyle birlikte artmıştır.

Ceviz sürgün görüntülerinin sınıflandırılmasında, Evrişimli Sinir Ağı (CNN) modelleri kullanılacaktır. Bilindiği gibi Evrişimli Sinir Ağları katmanlardan oluşur. Bu katmanlarda parametre değerleri kullanılır ve bu değerler değiştirilerek işlem sonucunda farklı sonuçlar alınabilir. Bu katmanlar evrişim, havuzlama ve tam bağlantı katmanlarıdır [9].

Yapılan literatür taramasında ceviz türlerinin sınıflandırılması için genelde ceviz meyvesi üzerinden sınıflandırma işlemi yapılmıştır [10]. Çin'in güney Sincan bölgesinde yetiştirilen üç ceviz türünün sınıflandırılması için YOLOv5 tabanlı tespit modeli kullanılmıştır. Xin2, Xinguang ve Wen185'in cevizlerinin sınıflandırılması için YOLOv5 modelinin ortalama doğruluğunun (mAP) sırasıyla %99,5, %98,4 ve %97,1 olduğunu tespit edilmiştir [11]. Yakın zamanda yapılan bir çalışmada 18 farklı ceviz çeşidine ait 1751 yaprak görüntüsü kullanarak kontrollü bir ortamda ceviz yapraklarından sınıflandırma işlemi yapılmıştır [12]. Bunların haricinde sınıflandırma işlemi için herhangi bir ceviz sürgün görüntüsü üzerinden çalışma yapılmadığı görülmüştür.

3. MATERYAL VE METOT

3.1. Görüntü Veri Seti

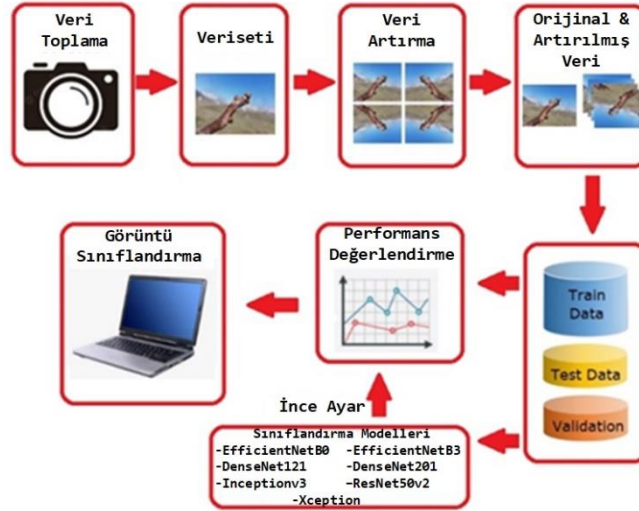
Bu çalışma için oluşturulan veri setindeki görüntüler; Mart-Nisan 2023 tarihleri arasında Isparta ili, Eğirdir ilçesinde yer alan Tarım ve Orman Bakanlığı Meyvecilik Araştırma Enstitüsü Müdürlüğü'ne ait, ceviz ağaçlarının yetiştiriciliğinin ve bakımının yapıldığı uygulama bahçesinden elde edilmiştir. Görüntüler; bahçede ağaçlar üzerinde kontrolsüz ortamda, Samsung S8(SM-950F) cep telefonu ile 4032×3024 piksel boyutlarında, 72 dpi yatay ve dikey çözünürlükte, 24 bit derinlikte RGB formatında elde edilmiştir. Oluşturulan veri setinde bulunan; Bilecik, Chandler, Fernette, Fernor, Franquette, Maraş12, Maraş18, Pedro, Şebin, Şen2 ceviz ağaçlarının sürgün görüntüleri Şekil 2'de gösterilmiştir.



Şekil 2. Veri setinde bulunan ceviz sürgün çeşitlerine ait görüntüler

3.2. Sınıflandırma Model Mimarisi

Derin öğrenme tabanlı ceviz sürgün görüntüleri kullanılarak ceviz çeşitlerinin sınıflandırılması için yapılan deneysel çalışmada; on farklı (Bilecik, Chandler, Fernette, Fernor, Franquette, Maraş12, Maraş18, Pedro, Şebin, Şen2) ceviz sürgün görüntülerinden bir veri seti oluşturuldu. Veri集中的 görüntülerden daha iyi bir sınıflandırma çalışması yapmak için görüntüler üzerinde farklı metotlarla veri artırma işlemi yapıldı. Bu süreçlerden sonra yedi farklı derin öğrenme algoritmasını uygulamak için veri seti eğitim, doğrulama ve test olmak üzere üç bölüme ayrıldı. Eğitim modellerinden elde edilen modellere, hiç görmedikleri ceviz sürgün görüntüleri verilerek modellerin sınıflandırma başarıları ölçüldü (Şekil 3).



Şekil 3. Çalışmada kullanılan sistem mimarisi

Veri集中的 görüntüler önışlem olarak 4032×3024 piksel boyutundan, $224 \times 224 \times 3$ boyutuna indirgenmiştir. Oluşturulan veri setindeki 3552 görüntünün %10'u doğrulama işlemi için rastgele seçildi. Kalan görüntülerin %80'i eğitim ve %20'si de test işlemi için ayrıldı. Modellerin eğitimlerinin daha fazla veri ile eğitilmesi amacıyla veri çoğaltımı yöntemi uygulanmıştır. Veri çoğaltımında beş farklı yöntem (zoom_range, horizontal_flip, rotation_range, width_shift_range, height_shift_range) kullanılarak, eğitim veri seti için toplam 10996 görüntü elde edilmiş ve bu görüntülerin 996 tanesi test ve doğrulama için kullanılmıştır. Çalışmada kullanılan orjinal ve veri artırılmış veri setindeki görüntülerin eğitim, doğrulama ve test sayıları Tablo 2'de gösterilmektedir.

Tablo 2. Orijinal ve artırılmış veri setindeki ceviz sürgün çeşitlerinin sayıları

No	Kategori	Orijinal			Veri Artırımı		
		Eğitim	Doğrulama	Test	Eğitim	Doğrulama	Test
1	Bilecik	279	39	70	1000	39	70
2	Chandler	221	30	55	1000	30	55
3	Fernette	226	31	56	1000	31	56
4	Fernor	284	40	71	1000	40	71
5	Franquette	264	37	66	1000	37	66
6	Maraş12	219	31	55	1000	31	55
7	Maraş18	241	34	61	1000	34	61
8	Pedro	296	41	74	1000	41	74
9	Şebin	272	38	68	1000	38	68
10	Şen2	254	35	64	1000	35	64
Toplam		2556	356	640	10000	356	640
		3552			10996		

3.3. Kullanılan Derin Öğrenme Modelleri

Günümüzde görüntü içinde nesne tespiti, tanıma ve sınıflandırma işlemleri için derin öğrenme mimarilerinin kullanımı artmıştır [13]. Oldukça yaygın olarak kullanılan derin öğrenme yöntemleri çok farklı alanlarda kullanılmaktadır. Artık sadece basit görüntü içerisinde nesne tespiti için kullanılmaktan daha fazlasını yaparak sağlık sektöründe MR görüntüleri üzerinde çeşitli hastalıkların tespiti için bile kullanılır hale gelmiştir [14]. Ayrıca tarımsal faaliyetlerde, hastalıkların tespiti [15], ürün rekoltesinin ölçülmesi [16], toplanan ürünlerin sınıflandırılması [17] gibi birçok alanda dikkate değer çalışmalarda yapılmıştır. Çalışmada kullanılan modeller, EfficientNetB0, EfficientNetB3, DenseNet121, DenseNet201, Inceptionv3, ResNet50v2, ve Xception derin öğrenme mimarileridir. Aşağıda çalışmada kullanılan CNN modelleri hakkında kısaca bilgiler verilmiştir.

3.3.1 EfficientNet

EfficientNet, hem imajenet hem de yaygın görüntü sınıflandırması, transfer öğrenme görevlerinde yüksek doğruluğa ulaşan en verimli modeller arasındadır [18]. EfficientNet, bir bileşik katsayı kullanarak tüm derinlik/genişlik/çözünürlük boyutlarını eşit şekilde ölçekleyen gelişmiş bir sinir ağı mimarisi ve ölçeklendirme yöntemidir.

3.3.2 DenseNet

DenseNet, katmanlarının diğer tüm katmanlara ileri beslemeli bir şekilde bağlar. Katmanlar kendinden önceki katmanlardan girdi değerleri alır ve kendi değerlerini de sonraki diğer katmanlara aktarır [19]. En önemlisi, ResNet'lerin aksine, özellikleri bir katmana geçmeden önce asla toplama yoluyla birleştirmez; bunun yerine özellikleri birleştirme işlemi yapar. Bu nedenle, herhangi bir katman, önceki tüm evrişimli blokların özellik haritalarından oluşan girdilere sahiptir.

3.3.3 InceptionV3

Inceptionv3, görüntü sınıflandırması için kullanılan evrişimli sinir ağlarına dayalı bir derin öğrenme modelidir. Inceptionv3, 2014 yılında GoogLeNet olarak tanıtılan temel model Inceptionv1'in üstün bir versiyonudur. Adından da anlaşılacağı gibi, Google'daki bir ekip tarafından geliştirilmiştir [20].

3.3.4 ResNet50v2

ResNet (Residual Network), 2015 yılında He ve arkadaşları tarafından derin öğrenme mimarilerinde eğitimi kolaylaştırmak için geliştirilmiştir [21]. ILSVRC ve COCO 2015 yarışmasında, nesne algılama, yerleştirme ve sınıflandırmasında birinci oldu. COCO nesne algılamada ResNet101, VGG16 ile değiştirildiğinde %28 başarıyı arttırmıştır.

3.3.5 Xception

Inception derin öğrenme mimarisinin bir uzantısı olarak 2017 yılında tanıtılmıştır [22]. Toplamda 71 katmandan oluşmaktadır. Katmanlar arasında ReLU aktivasyon fonksiyonunu kullanır. Ayrıca maksimum havuzlamam katmanları da kullanılır. Giriş boyutu temel olarak 299×299 pikseldir.

3.4. Derin Öğrenme Performans Değerlendirmesi

Çalışmada kullanılan yedi derin öğrenme modelinin performans değerlerini hesaplamak için Denklem 1-4’de verilen metrikler kullanılmıştır. Doğruluk (Accuracy), sınıflandırılan örnek veriler içinde doğru sınıflandırılmış örneklerin değeridir. Kesinlik (Precision), pozitif olarak sınıflandırılan örnek verilerin, gerçekte kaç adedinin pozitif olduğunun değeridir. Duyarlılık (Recall), pozitif olarak tahmin edilmesi gereken örnek verilerin, ne kadarının pozitif olarak sınıflandırıldığına değeridir. F1-Skor (F1-Score), kesinlik ve duyarlılık metriklerinin harmonik ortalamasıdır.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (2)$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (3)$$

$$F1 - \text{Skor} = 2 \times \left(\frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \right) \quad (4)$$

Denklemlerde kullanılan, True Positive (TP) doğru bir şekilde pozitif olarak sınıflandırılan örneklerin sayısını, True Negative (TN) doğru bir şekilde negatif olarak sınıflandırılan negatif örneklerin sayısıdır. False Negative (FN) yanlış bir şekilde pozitif olarak sınıflandırılan negatif örneklerin sayısını, False Positive (FP) yanlış bir şekilde negatif olarak sınıflandırılan pozitif örneklerin sayısını ifade etmektedir.

4. BULGULAR

4.1. Deneysel Prosedür

Çalışma için Intel Core i7-6700HQ 2.60GHz işlemci, 24 GB Ram, 128 GB NVMe M.2 (PCIe) SSD, 1 TB Sata sabitdisk, Nvidia GeForce GTX965M 4GB grafik kartı donanımına sahip bilgisayar kullanılmıştır. Çalışma Anaconda platformunda, Python programlama dili ile Jupyter Notebook kullanılarak gerçekleştirilmiştir.

Eğitim aşamasında, ön eğitilmiş modellerin temel katmanları dondurulmuştur. Baz modelin üzerine Fine-tuning işlemi ile global_average_pooling, dropout, dense, batch_normalization katmanları ilave edilmiştir. Aktivasyon fonksiyonu softmax olarak ayarlanmıştır. Ara katmanlarda ise ReLU aktivasyon fonksiyonu kullanılmıştır. Optimizer için Adamax, loss function için Categorical Cross Entropy, metrik olarak Accuracy, Epoch ise 50 değerleri kullanılarak eğitimler gerçekleştirilmiştir (Tablo 3). Öğrenme oranının (lr) güncellenmesi ve aşırı öğrenmeden kaçınmak için modele reduce_lr_loss, early_stop ve model_check_point kontrolleri eklenmiştir. Modellerin eğitilerek eğitim ve doğrulama doğrulukları elde edilmiş ve test verileri ile sınıflandırma performansını elde etmek için karışıklık matrisi kullanılmıştır. Karışıklık matrisine dayalı olarak Kesinlik, Duyarlılık ve F1-Skor metrikleri elde edilmiştir.


Tablo 3. Eğitim hiperparametleri

Parametre	Değer
Image size	224×224×3
Optimizer	Adamax
Loss function	Categorical Cross Entropy
Epochs	50
Output Activation	Softmax
Learning rate	min. 0.00001


4.2. Derin Öğrenme Modellerinin Performanslarının Karşılaştırılması

Çalışmada EfficientNetB0, EfficientNetB3, DenseNet121, DenseNet201, ResNet50v2, Inceptionv3 ve Xception ön öğrenmeli derin öğrenme modelleri kullanılarak eğitim gerçekleştirilmiştir. Eğitim sonucunda elde edilen kayıp ve doğruluk grafikleri Şekil 4'de verilmiştir. Derin öğrenme modellerinin hepsi 50 epoch değeri için ayarlanarak eğitilmiştir.


Modellerin en düşük doğrulama kaybı; EfficientNetB0 ile 0,4083, EfficientNetB3 ile 0,4525, DenseNet121 ile 0,4653, DenseNet201 ile 0,4931, ResNet50v2 ile 0,8960, Inceptionv3 ile 1,0960, Xception ile 0,7564 değerleri elde edilmiştir. Modellerin eğitiminde en yüksek doğrulama doğruluğu; EfficientNetB0 ile 0,9326, EfficientNetB3 ile 0,9242, DenseNet121 ile 0,9157, DenseNet201 ile 0,9185, ResNet50v2 ile 0,8567, Inceptionv3 ile 0,8539, Xception ile 0,8343 değerleri elde edilmiştir.



EfficientNetB0



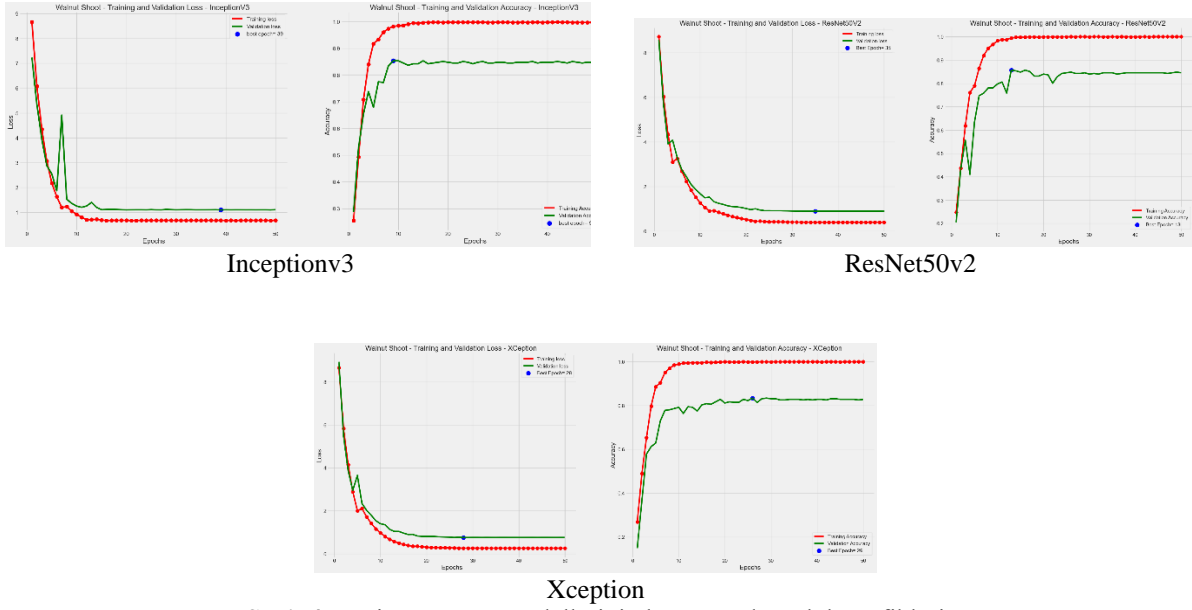
EfficientNetB3



DenseNet121



DenseNet201



Şekil 4. Derin öğrenme modellerinin kayıp ve doğruluk grafikleri

En iyi performansı gösteren modelin tespit edilmesi amacıyla test sonuçlarından elde edilen Kesinlik, Duyarlılık ve F1-Skor metrikleri sırasıyla Tablo 4, Tablo 5 ve Tablo 6'da sunulmuştur. Modellerin test sonuçlarından elde edilen Kesinlik değerlerini gösteren Tablo 4'e bakıldığında, tüm ceviz çeşitlerinin sınıflandırılmasında en iyi değerleri EfficientNetB0 ve EfficientNetB3 modellerinin verdiği görülmektedir. DenseNet121 modeli de bu öğrenme modellerini takip etmiştir.

Tablo 4. Test sonuçlarının Kesinlik değerleri

Modeller	Bilecik	Chandler	Feritite	Fernor	Franquette	Maraş12	Maraş18	Pedro	Şebın	Şen2
EfficientNetB0	0.88	0.88	0.92	0.95	0.91	0.91	0.89	0.93	0.90	0.97
EfficientNetB3	0.85	0.90	0.89	0.93	0.94	0.88	0.96	0.94	0.91	0.98
DenseNet121	0.82	0.86	0.88	0.95	0.90	0.95	0.92	0.95	0.92	0.91
DenseNet201	0.85	0.84	0.79	0.97	0.85	0.94	0.92	0.93	0.88	0.94
Inceptionv3	0.78	0.76	0.79	0.85	0.82	0.87	0.86	0.89	0.88	0.87
ResNet50v2	0.77	0.67	0.76	0.90	0.68	0.83	0.87	0.89	0.89	0.86
Xception	0.79	0.76	0.74	0.88	0.66	0.81	0.87	0.88	0.92	0.78

Tablo 5'de ise duyarlılık metriğine göre yine tüm ceviz çeşitlerinin sınıflandırılmasında en iyi değerleri EfficientNetB0 modellenin verdiği görülmektedir. EfficientNetB3 ve DenseNet121 modeli de bu öğrenme modelini takip etmiştir.

Tablo 5. Test sonuçlarının Duyarlılık değerleri

Modeller	Bilecik	Chandler	Fernte	Fernor	Franquette	Maraş12	Maraş18	Pedro	Şebın	Şen2
EfficientNetB0	0.94	0.94	0.84	1.00	0.91	0.89	0.89	0.95	0.88	0.97
EfficientNetB3	0.91	0.80	0.89	0.95	0.91	0.92	0.91	0.95	0.91	0.98
DenseNet121	0.93	0.80	0.77	0.97	0.86	0.95	0.97	0.95	0.90	0.94
DenseNet201	0.86	0.67	0.80	0.96	0.91	0.93	0.97	0.96	0.88	0.92
Inceptionv3	0.87	0.69	0.68	0.94	0.80	0.95	0.80	0.92	0.78	0.92
ResNet50v2	0.86	0.65	0.63	0.90	0.76	0.73	0.89	0.91	0.81	0.94
Xception	0.84	0.56	0.70	0.96	0.71	0.78	0.85	0.88	0.84	0.90

F1-Skorlarının bulunduğu Tablo 6’da ise tüm ceviz çeşitlerinin sınıflandırılmasında en iyi değerleri EfficientNetB0 ve EfficientNetB3 modellerinin verdiği görülmektedir. DenseNet121 ve DenseNet201 modelleri de bu öğrenme modellerini takip etmiştir.

Tablo 6. Test sonuçlarının F1-Skor değerleri

Modeller	Bilecik	Chandler	Fernte	Fernor	Franquette	Maraş12	Maraş18	Pedro	Şebın	Şen2
EfficientNetB0	0.91	0.86	0.88	0.97	0.91	0.90	0.89	0.94	0.89	0.97
EfficientNetB3	0.88	0.85	0.89	0.95	0.91	0.92	0.91	0.95	0.91	0.98
DenseNet121	0.87	0.83	0.82	0.96	0.88	0.95	0.94	0.95	0.91	0.92
DenseNet201	0.87	0.75	0.80	0.96	0.88	0.94	0.94	0.95	0.88	0.93
Inceptionv3	0.82	0.73	0.73	0.89	0.81	0.90	0.83	0.91	0.83	0.89
ResNet50v2	0.81	0.66	0.69	0.90	0.71	0.78	0.88	0.90	0.85	0.90
Xception	0.81	0.65	0.72	0.92	0.69	0.80	0.86	0.88	0.88	0.84

Modellerin Eğitim, Doğrulama ve Test Doğruluk değerlerini içeren Tablo 7 incelendiğinde ceviz türlerinin sürgün görüntülerine göre sınıflandırılmasında en yüksek başarımların değerleri %91,87 değeri ile EfficientNetB0 derin öğrenme modeli ulaşmıştır. Onu sırasıyla %91,41 değeri ile EfficientNetB0 ve %90,62 değeri ile DenseNet121 elde etmiştir.

Tablo 7. Modellerin Eğitim, Doğrulama ve Test Doğruluk değerleri

Doğruluk (%)	EfficientNetB0	EfficientNetB3	DenseNet121	DenseNet201	Inception V3	ResNet150V2	Xception	Average
Eğitim	99.92	99.89	99.94	99.99	98.29	99.42	99.97	99.63
Doğrulama	93.26	92.42	91.57	91.85	85.39	85.67	83.43	89.08
Test	91.87	91.41	90.62	89.38	84.06	81.41	81.09	87.98

Karışıklık matrisinde ana köşegen doğru tahmin edilen görüntüleri, diğerleri ise yanlış tahmin edilen görüntüleri ifade etmektedir. Şekil 5’de verilen EfficientNetB0 modelinin karışıklık matrisi incelendiğinde Şen2, Pedro, Fernor ve Maraş18 ceviz sürgün görüntülerinin sadece iki hatalı görüntü sınıflandırma yaptığı görülmektedir. Chandler ceviz sürgün görüntülerinde ise onbir hatalı görüntü sınıflandırması yapmıştır.

Ceviz Sürgünlerinin Karışıklık Matris Değerleri - (EfficientNetB0)

Gerçek Sınıf	Bilecik	Chandler	Fernette	Femor	Franquette	Maraş12	Maraş18	Pedro	Şebın	Şen2
Bilecik	64	0	0	1	2	0	0	0	3	0
Chandler	0	44	5	0	1	3	0	2	0	0
Fernette	1	1	50	2	0	0	1	1	0	0
Femor	1	0	0	69	0	0	0	1	0	0
Franquette	2	3	0	0	59	2	0	0	0	0
Maraş12	0	1	0	0	1	53	0	0	0	0
Maraş18	1	0	0	0	0	2	53	1	3	1
Pedro	0	0	0	2	0	0	0	72	0	0
Şebın	5	0	1	0	0	0	0	0	62	0
Şen2	1	0	0	0	0	0	1	0	0	62
Tahmin Edilen Sınıf	Bilecik	Chandler	Fernette	Femor	Franquette	Maraş12	Maraş18	Pedro	Şebın	Şen2

Şekil 5. EfficientNetB0 modelinin karışıklık matrisi

5. SONUÇ

Ceviz sürgün görüntüleri kullanılarak derin öğrenme yöntemleri ile ceviz türlerinin sınıflandırılabilirliği yapılan çalışma ile gösterilmiştir. 10 farklı ceviz türü için 3552 sürgün görüntülerinden oluşan bir veri seti oluşturulmuştur. Veri artırma ile görüntüler her tür için 1000 görüntü olacak şekilde çoğaltılmıştır. Bu görüntüler EfficientNetB0, EfficientNetB3, DenseNet121, DenseNet201, ResNet50v2, Inceptionv3 ve Xception ön öğrenmeli derin öğrenme modelleri ile eğitilmiştir.

Eğitimin sonucunda en iyi test performansını %91,87 ile EfficientNetB0 derin öğrenme modeli vermiştir. En düşük test değeri ise %81,09 ile Xception derin öğrenme modeli vermiştir. Ceviz türlerinin sınıflandırılması için yapılan bu çalışmada, ceviz sürgün görüntülerinin derin öğrenme yöntemleriyle başarılı bir şekilde sınıflandırılabilirliği gösterilmiştir. Bununla birlikte ceviz sürgün görüntülerinden oluşan yeni bir veri seti oluşturulmuştur. Daha fazla türe ait görüntülerin eklenmesiyle veri seti genişletilebilir.

6. KAYNAKLAR

- [1] Güzel, B., & Okatan, E. (2022). Tarım ve Yapay Zeka. In M. Bilen (Ed.), Yapay Zekanın Değiştirdiği Dinamikler (pp. 199–224). Eğitim Yayınevi.
- [2] TÜİK. (2023). Türkiye İstatistik Kurumu Bitkisel Üretim İstatistikleri. TÜİK.
- [3] FAO. (2023). Food and Agriculture Organization of the United Nations (FAO) Walnuts Production Statistics. FAO. <http://www.fao.org/faostat/en/#data/QC>.
- [4] Güvenç, İ., & Kazankaya, A. (2019). Türkiye’de ceviz üretimi, dış ticareti ve rekabet gücü. Yuzuncu Yıl University Journal of Agricultural Sciences, 29(3), 418–424.
- [5] Özkan, M., & Kar, G. (2022). Türkçe Dilinde Yazılan Bilimsel Metinlerin Derin Öğrenme Tekniği Uygulanarak Çoklu Sınıflandırılması. Mühendislik Bilimleri ve Tasarım Dergisi, 10(2), 504–519.
- [6] Öztürk, T., & Katar, O. (2022). A Deep Learning Model Collaborates with an Expert Radiologist to Classify Brain Tumors from MR Images. Turkish Journal of Science and Technology, 17(2), 203–210.
- [7] Dalkıran, İ., & Ozan, M. (2022). Derin Öğrenme Teknikleri Kullanılarak Borsadaki Hisse Değerlerinin Tahmin Edilmesi. Avrupa Bilim ve Teknoloji Dergisi, 39, 143–148.

- [8] Kayaalp, K., & Metlek, S. (2020). Classification of robust and rotten apples by deep learning algorithm. *Sakarya University Journal of Computer and Information Sciences*, 3(2), 112–120.
- [9] Metlek, S., & Kayaalp, K. (2021). Detection of bee diseases with a hybrid deep learning method. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36(3), 1715–1731.
- [10] Jun, L. U., Han, X. Z., & Wang, K. J. (2017). Classification of Collection Walnut Based on GLCM and SVM. *2nd International Conference on Test, Measurement and Computational Method (TMCM 2017)*, 276–281.
- [11] Sanlin, Z., Liping, Z., Weiqiang, Z., Zhuang, G., & Ziqiang, F. (2022). Identification and localization of walnut varieties based on YOLOv5. *Journal of Chinese Agricultural Mechanization*, 43(7), 167
- [12] Karadeniz, A. T., Çelik, Y., & Başaran, E. (2023). Classification of walnut varieties obtained from walnut leaf images by the recommended residual block based CNN model. *European Food Research and Technology*, 249(3), 727–738.
- [13] Deng, L., & Yu, D. (2014). Deep learning: methods and applications. *Foundations and Trends® in Signal Processing*, 7(3–4), 197–387.
- [14] Altun, S., & Alkan, A. (2022). MR Spektroskopi kullanılarak beyin tümörü tespitinde LSTM tabanlı derin öğrenme uygulaması. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 38(2), 1193–1202. <https://doi.org/10.17341/gazimmfd.1069632>.
- [15] Dikici, B., Bekçioğulları, M. F., Açıkgöz, H., & Korkmaz, D. (2022). Zeytin Yaprağındaki Hastalıkların Sınıflandırılmasında Ön Eğitimli Evrişimli Sınır Ağlarının Performanslarının İncelenmesi. *Konya Journal of Engineering Sciences*, 10(3), 535–547.
- [16] Shi, R., Li, T., & Yamaguchi, Y. (2020). An attribution-based pruning method for real-time mango detection with YOLO network. *Computers and Electronics in Agriculture*, 169, 105214. <https://doi.org/10.1016/j.compag.2020.105214>.
- [17] Aktaş, H. (2022). Antep fıstığının derin öğrenme ile dış kabuk rengine göre sınıflandırılması. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 1.
- [18] Tan, M., & Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. *International Conference on Machine Learning*, 6105–6114.
- [19] Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 4700–4708.
- [20] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2818–2826.
- [21] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770–778.
- [22] Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1251–1258.