



Determining the growth stages of sunflower plants using deep learning methods

Gülay Karahanlı^{1*}, Cem Taşkın²

¹Department of Information Technology, Tekirdağ Namık Kemal University, 59030, Tekirdağ, Türkiye

²Faculty of Engineering, Trakya University, Edirne, 22030, Türkiye

Highlights:

- Application of deep learning methods in precision agriculture applications
- Following the developmental stages of the sunflower plant for autonomous systems
- Comparison of the performance of convolutional neural network models in image classification

Keywords:

- Deep learning
- Convolutional neural networks
- Image classification
- Precision agriculture
- Transfer learning

Article Info:

Research Article

Received: 07.11.2022

Accepted: 09.08.2023

DOI:

10.17341/gazimmfd.1200615

Correspondence:

Author: Gülay Karahanlı

e-mail:

gulaykarahanli@nku.edu.tr

phone: +90 282 250 1211

Graphical/Tabular Abstract

It is foreseen that there may be problems in food supply in the future due to many reasons, especially the rapidly increasing population. In order to meet the increasing food needs, precision agriculture technologies are used, it is aimed to reduce production costs and increase product efficiency. In this way, many processes such as irrigation, fertilization, spraying, weeding and harvesting can be done by autonomous systems. Especially in some plant species such as sunflower, when to apply these processes is largely decided according to the developmental stage of the plant. In this study, 6465 images were taken from different angles and heights on 43 different days with the DJI Phantom 3 model drone from a 30-decare land. Since the images are high resolution (2250 x 4000 pixels), they were used by dividing them into 6 equal parts. Thus, both the variety of data and the number of images have increased. To be used in the training and testing of convolutional neural networks (CNN), a data set with 8 classes, 1600 in each class, and a total of 12800 images was created. An intermediate class test set was created with the remaining image fragments, whose stage could not be determined clearly. In this test set, there are 7 intermediate classes, 400 in each class, a total of 2800 images. The success rate in the 7-8 intermediate class was quite low, and some image processing techniques were applied to increase the success rate for this class. In addition, to test the accuracy of the trained models, a second test set was created from the images taken from a second field, with 200 images in each class and a total of 1600 images. The results obtained for three separate test sets were evaluated. The procedures performed are shown in Figure A.

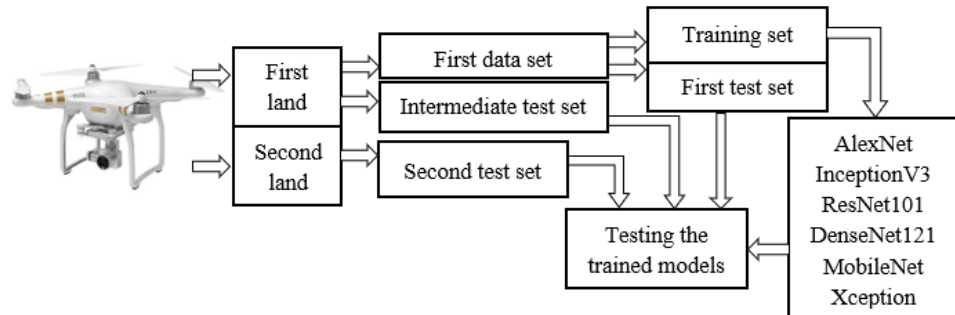


Figure A. Creating of datasets and testing the training model

Purpose:

Automatically detecting the stage of sunflower plants with deep learning methods.

Theory and Methods: With deep learning methods, solutions are offered to problems in many different branches of science. CNNs give the best results when it comes to image and video processing. CNNs are frequently used in processes such as image recognition and classification. In this study, six of the models frequently used in deep learning applications with transfer learning (AlexNet, InceptionV3, ResNet101, DenseNet121, MobileNet, Xception) were trained on the first dataset with three different optimization methods (Sdg, Adam, Rmsprop). Afterwards, the success rates on three different test sets were observed, and some filters were applied to increase the success rates.

Results: Thanks to the CNN models used, the developmental stage of sunflower can be determined quickly, easily and with high accuracy. At the last stage, the accuracy rate on the first test set was 100% with the InceptionV3 and Xception models, 91,50% with the ResNet101 model on the second data series, and 95,50% with the DenseNet121 model in the intermediate class test set.

Conclusion: High accuracy rates were obtained in the classification study carried out with six different deep learning methods. It is thought that it can be used with autonomous systems in the future.



Derin öğrenme yöntemleri kullanılarak ayçiçeği bitkisinin gelişim evrelerinin tespiti

Gülay Karahanlı^{1*}, Cem Taşkın²

¹Tekirdağ Namık Kemal Üniversitesi, Bilgi İşlem Daire Başkanlığı, 59030, Tekirdağ, Türkiye

²Trakya Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 22030, Edirne, Türkiye

Ö N E Ç I K A N L A R

- Hassas tarım uygulamalarında derin öğrenme yöntemlerinin uygulanması
- Otonom sistemler için ayçiçeği bitkisinin gelişim aşamalarının takip edilmesi
- Evrişimli sinir ağları modellerinin görüntü sınıflandırmadaki performanslarının karşılaştırılması

Makale Bilgileri

Araştırma Makalesi

Geliş: 07.11.2022

Kabul: 09.08.2023

DOI:

10.17341/gazimmfd.1200615

Anahtar Kelimeler:

Derin öğrenme,
evrişimli sinir ağları,
görüntü sınıflandırma,
hassas tarım,
transfer öğrenme

Ö Z

Son yıllarda gelişen hassas tarım teknolojileri sayesinde tarımsal ürünlerin sulanması, gübrenmesi, ilaçlanması, yabancı otların ayıklanması, hasat edilmesi gibi birçok işlem otonom sistemler tarafından yapılabilmektedir. Özellikle ayçiçeği gibi bazı bitki türlerinde bu işlemlerin ne zaman uygulanacağına, büyük ölçüde bitkinin içerisinde bulunduğu gelişim evresine göre karar verilmektedir. Bu çalışmada ayçiçeği bitkilerinin gelişim evrelerinin sınıflandırılabilmesi için derin öğrenme yöntemleri kullanılmıştır. Dron ile alınan görüntüler yüksek çözünürlüklü olduğundan her biri 6 eşit parçaya bölünmüş ve sonrasında 8 sınıf belirlenerek her sınıfa ait görüntüler ayıklanmıştır. Her sınıfta 1600 adet olmak üzere, toplamda 12800 adet görüntüden oluşan bir veri seti oluşturulmuştur. AlexNet, InceptionV3, ResNet101, DenseNet121, MobileNet ve Xception olmak üzere altı farklı derin öğrenme modeli, Sgd, Adam ve Rmsprop optimizasyon yöntemleriyle test edilerek performansları karşılaştırılmıştır. Modellerin başarılarının doğru değerlendirilebilmesi için eğitilen modeller farklı bir araziden alınan görüntüler ile oluşturulan ikinci bir veri seti üzerinde de test edilmiş ve yüksek başarı oranları elde edilmiştir. Ayrıca bitkinin hangi evrede olduğuna net karar verilemeyen görüntüler için 7 sınıflı bir test seti oluşturulmuş ve modellerin başarı oranları test edilmiştir. 7-8 ara sınıfında bulunan görüntüler için başarının çok düşük olduğu gözlemlenmiş, bu sınıf için de başarı oranını arttıracak resim işleme tekniklerinde kullanılan filtreler görüntülere uygulanarak modeller yeniden eğitilmiş ve sonuçları değerlendirilmiştir.

Determining the growth stages of sunflower plants using deep learning methods

H I G H L I G H T S

- Application of deep learning methods in precision agriculture applications
- Following the developmental stages of the sunflower plant for autonomous systems
- Comparison of the performance of convolutional neural network models in image classification

Article Info

Research Article

Received: 07.11.2022

Accepted: 09.08.2023

DOI:

10.17341/gazimmfd.1200615

Keywords:

Deep learning,
convolutional neural
networks,
image classification,
precision agriculture,
transfer learning

ABSTRACT

Thanks to the precision agriculture technologies developed in recent years, many processes such as irrigation, fertilization, spraying, weeding and harvesting of agricultural products can be done by autonomous systems. Especially in some plant species such as sunflower, when to apply these processes is largely decided according to the developmental stage of the plant. In this study, deep learning methods were used to classify the developmental stages of sunflower plants. Since the images taken with the drone are high resolution, each of them is divided into 6 equal parts, and then 8 classes are determined and the images belonging to each class are extracted. A data set consisting of 12800 images in total, 1600 in each class, was created. Six different deep learning models, namely AlexNet, InceptionV3, ResNet101, DenseNet121, MobileNet and Xception, were tested with Sgd, Adam and Rmsprop optimization methods and their performances were compared. In order to evaluate the success of the models correctly, the trained models were also tested on a second data set created with images taken from a different terrain and high success rates were obtained. In addition, a 7-class test set was created for images that could not be clearly determined at which stage the plant was in, and the success rates of the models were tested. It was observed that the success rate was very low for the images in the 7-8 intermediate class, and the filters used in the image processing techniques that would increase the success rate for this class were applied to the images, and the models were retrained and the results were evaluated.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : *karahanligulay@gmail.com, cemtaskin82@gmail.com / Tel: +90 530 701 0961

1. Giriş (Introduction)

Tüm canlılarda olduğu gibi insanların da hayatlarını devam ettirebilmeleri için gıdaya ihtiyaçları vardır. Hızlı artan nüfus, küresel ısınma, tahrip edilen tarım arazileri gibi birçok nedenden dolayı yeterli gıdanın üretilmesinde gelecekte ciddi sorunların yaşanabileceği öngörülmektedir [1]. Bu yüzden artan gıda ihtiyaçlarının karşılanmasında tarımın sürdürülebilir olması ve verimin artırılması büyük önem arz etmektedir. Hassas tarım teknolojilerini kullanarak, üretim maliyetlerinin düşürülmesi, ürün verimliliğinin artırılması hedeflenmektedir.

Yağlar, insanların beslenmesi için gerekli olan en temel besin maddelerindedir [2]. İnsanların beslenmek için ihtiyaç duyduğu yağların büyük kısmı bitkisel yağlardan karşılanmaktadır. Bitkisel yağların kaynağı, yağ, protein, karbonhidrat, mineral ve vitaminler bakımından zengin olan yağlı tohumlu bitkilerdir. Yağlı tohumlar deyince ilk aklı gelenler; ayçiçeği, soya, kanola (kolza), mısır, zeytin, pamuk çiğdi, palm çekirdeği, yer fıstığı, susam ve hindistan cevizidir [3]. Bu yağlı tohumlardan birçoğu ülkemizde üretilmekte olup, ekim alanı ve üretim miktarı bakımından birinci sırada ayçiçeği yer almaktadır [4].

Büyüme evreleri, bitki üzerinde çalışma yapan araştırmacılara ortak bir dil sağladığı için oldukça önemlidir. Bir ayçiçeği tarlasının büyüme aşaması belirlenirken, çok sayıda bitkinin ortalama gelişimi dikkate alınmalıdır [5]. Ayçiçeği gelişim evreleri vejetatif (vegetative stages) ve üreme (reproductive stages) olmak üzere iki kısımdan oluşur. Vejetatif evreler (V-n), VE (vegetative emergence) çıkış evresi olmak üzere, gövde sapı üzerinde 4 cm ve daha uzun yaprakların (gerçek yapraklar) sayısı ile isimlendirilen evrelerdir. Üreme evreleri (R-n) ise çiçek başının oluşmaya başladığı ve gelişimini tamamladığı tüm alt evreleri kapsar. Vejetatif ve üreme evrelerinin tüm alt evreleri Tablo 1'de detaylı olarak verilmiştir.

Dünya genelinde ayçiçeği üretiminde verim artışının nasıl sağlanabileceği konusunda çalışmalar yapılmaktadır. Örneğin nihai tane ağırlığının R-3 evresinin erken gelişim döneminde tohumluğun ağırlığı ile yakından ilişkili olduğu ve çiçek büyüme (tohumluk büyüme hızının) dinamiğinin ayçiçeğin potansiyel tane ağırlığını etkilediği görülmüştür [7]. Yapılan bir tez çalışmasında farklı gelişim evrelerinde uygulanan sulamaların (V-6 – V-10 evreleri arasında, R-1 evresi tabla oluşumu başlangıcında, R-5 evresi çiçeklenme başlangıcında, R-5,9 evresi tane dolumu tamamlandıktan sonra) ayçiçeği çeşitlerinin çiçeklenme tarihini, fizyolojik olgunlaşmasını, bitki boyunu, tabla çapını, hasat nemini, bin tane ağırlığını, kabuk oranını, bitkide tane verimini, hasat indeksini, dekara tane verimini, yağ oranını, protein oranını nasıl etkilediği araştırılmıştır [8].

Sulama işlemi, ürün verimini etkileyen en önemli faktörlerdendir. Ayçiçeği bitkisi en güçlü etkiyi erken büyüme evrelerindeki sulamaya karşı göstermektedir. En yüksek tanecik verimini elde etmek için vejetatif dönemde, tomurcuk döneminde ve tanecik oluşum döneminde sulama yapılmalıdır. Daha yüksek ekonomik getiri elde etmek için sulama-zamanlama etkilerinin daha fazla araştırılması gerekmektedir [9]. Eğer doğru büyüme evrelerinde sulama yapılırsa verim önemli derecede artmaktadır [10]. Ayçiçeği genellikle kurak şartlarda yetiştirilmekte olup, sulamaya önemli ölçüde yanıt vermektedir. Üç yıllık süreçte üç farklı gelişim evresinin (tomurcuk, çiçeklenme ve taneciklerde süt oluşum evreleri) on üç farklı kombinasyonu oluşturularak tam ve sınırlı sulama etkileri araştırılmış, en yüksek tohum ve yağ oranı bu üç evrede de tam sulama yapıldığında elde edilmiştir [11]. Tekirdağ koşullarında ayçiçeğinin erken vejetatif, geç vejetatif, toplam vejetatif, çiçeklenme ve tanecik oluşum dönemlerinde sulama etkileri araştırılmış, çiçeklenme dönemindeki su açığının diğer dönemlere göre daha hassas olduğu, bu dönemde toprakta yeterli suyun bulunması gerektiği belirtilmiştir [12]. Çukurova bölgesinde yaprak gübrelemesinin V-4, V-4 + R-3, V-4 + R-5,1, V-4 + R-5,5 evrelerinde uygulanmasının ayçiçeğinin

Tablo 1. Ayçiçeği bitkisinin gelişim evreleri [6] (Developmental stages of sunflower plant)

Evre İsmi	Alt Evre İsmi	Açıklama
Vejetatif Evreler	V-1, V-2, V-3, vb.	Kotiledon (ilk yapraklar) yapraklar hariç, 4 cm'den daha uzun yaprakların sayılarak belirlendiği evredir. Yaprak sayısı, çeşide göre değişmekle beraber genellikle 18-24 arasındadır.
Üreme Evreleri	R-1	Gövde sapının ucunda yaprak kümesi yerine çiçek başının görülmeye başladığı evredir. Üstten bakıldığında yıldız şeklinde genç bürgü yapraklarının oluştuğu gözlenir.
	R-2	Olgunlaşmamış çiçek tablası ile en yakın yaprak arasındaki mesafenin 0,5 cm-2 cm aralığında olduğu evredir. Tablanın arkasındaki küçük yapraklar dikkate alınmaz.
	R-3	Olgunlaşmamış çiçek tablası ile en yakın yaprak arasındaki mesafenin 2 cm'den yukarıya doğru uzaklaştığı evredir.
	R-4	Çiçek tablasının açılmaya başladığı evredir. Üstten bakıldığında sarı ışın çiçekler (yalancı çiçek, sarı iri dil çiçeği) görülmeye başlar.
	R-5	Çiçeklenmenin başlangıç evresidir. Tabla ortasındaki gerçek çiçekler görünmeye başlar. R-5,n şeklinde (R-5,1, R-5,2, R-5,3, ..., R-5,9) alt evreleri vardır. Noktadan sonraki numaralar, tabla üzerinde çiçeklenmiş alanın yüzdesini ifade eder.
	R-5,1	Tabla üzerindeki çiçeklenme oranının yüzde 10 olduğu evredir.
	R-5,5	Tabla üzerindeki çiçeklenme oranının yüzde 50 olduğu evredir.
	R-5,9	Tabla üzerindeki çiçeklenme oranının en az yüzde 90 olduğu evredir. Çiçeklenme işlemi tamamlanmış veya tamamlanmaya yakındır.
	R-6	Çiçeklenmenin tamamlandığı, sarı ışın çiçeklerin solduğu ve dökülmeye başladığı evredir.
R-7	Sarı ışın çiçeklerinin döküldüğü, tabla arkasının açık sarı renge döndüğü evredir.	
R-8	Tabla arkasının sarıya döndüğü, bürgü yapraklarının hala yeşil olduğu evredir.	
R-9	Fizyolojik olgunluğun tamamlandığı, tablanın tamamen sarardığı, bürgü yapraklarının sarı ve kahverengi olduğu evredir. Hasat edilebilir.	

verimi ve verim öğeleri üzerine etkileri araştırılmıştır. Farklı gelişme dönemlerinde uygulanan yaprak gübrelemesinin ayçiçeğinin bitki boyu, tabla çapı, tohum iç oranı, protein oranı üzerine etkisi istatistiksel açıdan önemli görülmüş, en yüksek tane verimi 4 yapraklı dönem (V4) + ilk tabla oluşumu (R3) uygulamasından elde edilmiştir [13].

Literatürde mahsullerin büyüme aşamalarının sürelerinin derin öğrenme yöntemleri ile tahmin edilebilmesi için yapılmış çalışmalar mevcuttur. Bu çalışmaların birçoğunda sıcaklık, yağış miktarı, rüzgâr hızı, güneşlenme süresi, basınç, nem gibi meteorolojik verilerden yararlanılmaktadır [14]. Ayrıca buğday ve arpa bitkilerinin görüntülerinden buğday için on iki ve arpa için on bir büyüme aşamasının tahmin edilmesi [15], altı çeşit bitkinin(buğday, arpa, mercimek, pamuk, biber, mısır) farklı fenolojik aşamalarının sınıflandırılması, yonca bitkisi için kotiledon oluşumundan ilk gerçek yaprağın gelişimine kadar olan erken fide gelişim aşamalarının (toprak, kotiledonun ilk görünümü, kotiledonun açılması, ilk yaprağın görünmesi) izlenmesi [16], mango bitkisinin salkım sayısı ve salkımların gelişim aşamasının tahmin edilmesi [17], uzaktan algılama görüntüleri üzerinden çeltik bitkilerinin beş farklı büyüme evresi (vegetatif, üreme, olgunlaşma, hasat ve hasat sonrası, çiftçilik) için sınıflandırılması [18], pirinç bitkisinin baş oluşturma zamanının tahmin edilmesi [19], tere bitkisinin dört çeşidi için büyüme modelinin çıkarılması [20], pamuk bitkisinin çiçeklenme zamanının ve çiçeklerin yerlerinin tespit edilmesi [21], üç farklı büyüme evresindeki buğday başaklarının yerlerinin tespit edilmesi ve sayılması [22] gibi çalışmalarda da derin öğrenme yöntemleri kullanılmıştır.

Tüm dünya için de stratejik öneme sahip olan ayçiçeği bitkisiyle ilgili yapılan çalışmalar incelendiğinde gelişim evrelerinin bilinmesinin zirai açıdan ne kadar önemli olduğu görülmektedir. Her bir evrede uygulanacak işlem (sulama, gübreleme, ilaçlama vb.) farklı farklı miktarlarda denemek en çok verimin nasıl elde edileceği araştırılmaktadır. Bu araştırmalar yapılırken evreler zirai alanda çalışan kişiler tarafından belirlenmekte ve işlemler buna göre uygulanmaktadır. Bu evrelerin bilgisayarlı görü sistemleriyle otomatik olarak tespit edilmesine yönelik bir çalışmaya ise rastlanmamıştır. Dolayısıyla böyle bir çalışmanın araştırmacılar için büyük kolaylık sağlayacağı düşünülmektedir. Aynı zamanda bu evrelerin bilinmesi bitkinin kültürü üzerine yapılan çalışmalarda ortak bir dil sağlayacaktır (Örneğin bir zararlı veya hastalığın ortaya çıktığı evreyi belirtmek, sulamanın veya gübrelemenin yapıldığı evreyi belirtmek vb.).

Bu çalışmada ayçiçeği tarlalarından elde edilen görüntüler üzerinde derin öğrenme teknikleri kullanılarak, bitkilerin hangi gelişim evresinde olduğu tespit edilmeye çalışılmıştır. İlk olarak ayçiçeği tarlalarından dron yardımıyla görüntüler elde edilmiş ve bazı ön işlemlerden geçirilerek 8 ayrı sınıf içeren bir veri seti oluşturulmuştur. Sonrasında bilimsel çalışmalarda özellikle sınıflandırmada sıklıkla kullanılan, başarıları kanıtlanmış altı farklı derin öğrenme modeli üç farklı optimizasyon yöntemi kullanılarak, bu veri setiyle eğitilmiş ve sonuçları değerlendirilmiştir.

2. Deneysel Metot (Experimental Method)

2.1. Evrimsel Sinir Ağları (Convolutional Neural Networks)

Derin öğrenme yöntemleri ile birçok farklı bilim dalındaki problemlere çözümler sunulmaktadır. Söz konusu görüntü ve video işleme alanı olduğunda en iyi sonuçları evrimsel sinir ağları (CNN) vermektedir. Özellikle görüntü tanıma ve sınıflandırma gibi işlemlerde CNN'ler sıklıkla kullanılmaktadırlar [23]. Derin öğrenmeyi anlamada ve geliştirmede önemli önemli yere sahip olan, literatürde yaygın olarak kullanılan birçok CNN modeli mevcuttur.

Bu modellerden bazıları ImageNet Large-Scale Visual Recognition Challenge (ILSVRC) yarışmasında yüksek başarılar elde etmişlerdir. Sonrasında bu modellerden esinlenilerek daha yüksek başarıların hedeflendiği birçok model tasarlanmıştır.

Beş evrişim ve üç tam bağlantılı katmandan oluşan AlexNet modeli 2012 yılında ILSVRC yarışmasında birinci olmuştur [24]. 2014 yılında ise diğer modellerdeki gibi arka arkaya gelen katmanlar yerine inception modülleri olarak isimlendirilen üst üste yığılmış katmanlardan oluşan Inception (GoogleNet) modeli yarışmanın kazananı olmuştur [25]. Havuzlama katmanları dahil toplamda 27 katman derinliğinde olan Inception modeli, toplamda doğrusal olarak yığılmış 9 inception modülünden oluşmaktadır. Böylece ağı, daha derinden daha geniş hale gelmektedir [26]. 2015 yılında daha önce kullanılan modellerden çok daha derin yapıya sahip modellerin eğitimini kolaylaştırmak için tasarlanan, kaybolan veya aşırı artan gradyanların ağı etkilemesini önlemek için geliştirilen ResNet modeli yarışmada birinci olmuştur [27]. Google tarafından Inception modelinden esinlenilerek geliştirilen Xception, artık (residual) bağlantıları olan, inception modülleri yerine derinlemesine ayrılabilir evrişim adımlarından oluşan evrişimli sinir ağı mimarisidir. Ağın öznelik çıkarma tabanını oluşturan 36 evrişimli katmana sahiptir. InceptionV3 ile aynı sayıda parametreye sahip olmasına rağmen önemli ölçüde daha iyi performans göstermektedir. Keras ve TensorFlow kullanan açık kaynaklı bir Xception uygulaması, Keras uygulamaları modülünün bir parçası olarak kullanılabilir [28]. Yine Google araştırmacıları tarafından tasarlanan, mobil ve gömülü görüntü uygulamaları için geliştirilen MobileNet, model boyutunu ve karmaşıklığını azaltmak için derinlemesine ayrılabilir evrişim blokları kullanır [29]. Bu bloklar girdiyi filtreleyen derinlemesine evrişim katmanı ve yeni özellikler oluşturmak için bu filtrelenmiş değerleri birleştiren 1x1 boyutunda evrişim katmanından (noktasal evrişim katmanı) oluşur [30]. Her katmanı diğer katmanlara ileri beslemeli bir şekilde bağlayan DenseNet mimarisinde, her katman için önceki tüm katmanların özellik haritaları girdi olarak kullanılır. Farklı katmanlar tarafından öğrenilen özellik haritalarının birleştirilmesi, sonraki katmanların girdisindeki farklılığı ve verimliliği artırır. Derin veya geniş mimariler yerine, ağın potansiyeli yeniden kullanılarak, eğitilmesi kolay ve son derece az parametresi olan yoğunlaştırılmış modeller ortaya çıkarılır. Inception, ResNet gibi ağlar ile karşılaştırıldığında daha basit ve daha verimli olduğu görülür [31].

CNN'lerin her bir katmanında optimize edilebilecek çok sayıda parametre bulunmaktadır. Örneğin evrişim katmanında filtre sayısı, filtre boyutu, adım aralığı (stride), piksel doldurma (padding), aktivasyon fonksiyonu; havuzlama katmanında filtre boyutu, adım aralığı, havuzlama yöntemi (max pooling, average pooling vb.); tam bağlantılı katmanda nöron sayısı gibi parametreler mevcuttur. Bunlar dışında öğrenme oranı (learning rate), optimizasyon yöntemi, seyreltme (dropout) miktarı ve ağırlık başlatıcı gibi ortak parametreler de optimize edilebilmektedir [32].

2.2. Veri Setinin Oluşturulması (Dataset Formation)

Bu çalışmada kullanılan görüntüler 30 Nisan 2020'de ekim yapılan ve 31 Ağustos 2020'de hasat edilen, Tekirdağ ilinin Köseilyas mevkiinde bulunan 30 dönümlük bir araziden DJI Phantom 3 model dron yardımıyla farklı açı ve yüksekliklerden alınmıştır. Ortalama 2-3 gün aralıklarla, günün farklı saatlerinde, 43 ayrı günde toplanan görüntüler ayrı ayrı dosyalanmıştır. Toplamda 2250 x 4000 çözünürlükte 6465 adet görüntü elde edilmiştir. Sonrasında farklı günlerde toplanan ve ayrı ayrı dosyalandıran tüm görüntüler çekildikleri gün sırasıyla tek bir klasörde birleştirilmiştir. Görüntüler incelendiğinde bitkilerin filizlenmesinden itibaren tüm gelişim süreci kolaylıkla gözlemlenmektedir. Orijinal görüntülerin boyutları oldukça yüksek (2250 x 4000 piksel) olup eğitim sırasında ağın girişine uygun olması

için yaklaşık onda bir oranında küçültüldüğünden çok fazla veri kaybı yaşanmaktadır. Ayrıca derin evrişimli sinir ağlarının başarısı çok miktarda veri olmasına bağlıdır. Veri sayısı arttıkça model parametrelerinin optimum seviyeye ulaşması daha etkin gerçekleşir [33]. Eğer yeterli veri yoksa ağ aşırı uyum (overfitting) gösterebilmekte, verileri öğrenmek yerine ezberleyebilmektedir [34]. Bu yüzden orijinal görüntülerin 6 eşit parçaya bölünerek kullanılmasının veri kaybını azaltacağı, aynı zamanda veri seti boyutunu da arttıracığı düşünülmüştür. Bunun yanında bölünen görüntüler perspektif farklılıklardan dolayı veri setindeki çeşitliliği de arttırmaktadır. 6 eşit parçaya bölünmüş görüntü örneği Şekil 1'de verilmiştir.

Test edilen arazi her ne kadar düzgün (homojen) bir yapıya sahip olsa da bazı bölgelerinde gelişim farklılıkları oluşmuştur. Özellikle ilk evrelerde ve çiçeklenme başlangıcında bu farklılıklar daha çok görülmektedir. Örneğin bölünmüş bir görüntünün bir parçasında bitkiler topraktan çıkmaya başlamışken bir parçasında henüz hiç bitki filizlenmemiş olabilmektedir. Veya benzer şekilde bölünmüş bir görüntünün bir parçasında henüz hiç çiçek görülmezken bir

parçasında çiçeklenme başlamış olabilmektedir. Bu yüzden özgün bir görüntünün tüm parçaları aynı sınıfa dahil edilmemiş ve veri setindeki her bir sınıf tek tek seçilen parçalardan oluşturulmuştur. Gelişim farklılıklarının olduğu örnek görüntüler Şekil 2'de verilmiştir.

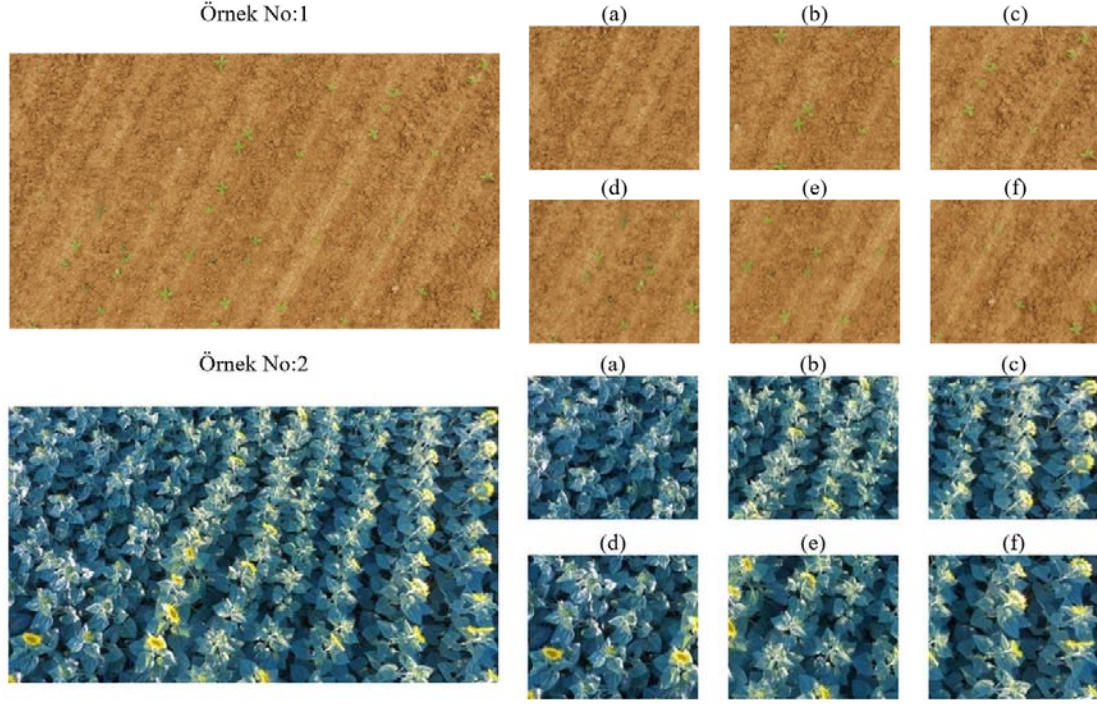
Şekil 2'de verilen örnek 1'in (a) parçası hariç diğerlerinde filizlenme başlamışken, (a) parçasında henüz hiç bitki bulunmamaktadır. Dolayısıyla bu parça veri setine dahil edilmemiştir. Benzer şekilde örnek 2'nin (a) parçasında hiç çiçek açmadığı görülmektedir. Dolayısıyla bu parça veri setine dahil edilmezken, onun dışındakiler 4. sınıf olarak sınıflandırılmıştır.

Tüm görüntüler 6 parçaya bölündüğünde 1333x1125 piksel boyutunda toplam 38790 adet görüntü elde edilmiştir. Bu görüntülerden göz ile net bir şekilde ayırt edilebilenler seçilerek 8 ayrı sınıf oluşturulmuş ve etiketlenmiştir. Etiketleme sonrası her sınıfın tanımı ve görüntü sayıları Tablo 2'de verilmiştir.

Tablo 2'den de görüldüğü gibi özellikle bazı evrelerin daha uzun sürmesinden kaynaklı olarak sınıflardaki görüntü sayıları arasında



Şekil 1. Özgün görüntü (üstte) ve 6 eşit parçaya bölünmüş görüntü parçaları
(The original image (above) and images divided into 6 equal parts)



Şekil 2. Gelişim farklılıklarının olduğu örnek görüntüler (Sample images with developmental differences)

Tablo 2. Etiketleme sonrası sınıflar ve görüntü sayıları (Post-labeling classes and image counts)

Sınıf No	Sınıf Tanımı	Görüntü Sayısı
1	İlk topraktan çıkış (kotiledon) ile 4-5 yaprak evresine kadar olan görüntüler alınmıştır.	1623
2	5-6 yaprak evresinden 10-11 yaprak evresine kadar olan görüntüler alınmıştır.	2458
3	Bitkiler arasında mesafeler azalmış, üst üste binmeler başlamıştır. Bitki sıraları belirgin olmaya başlamıştır.	3852
4	11-12 yaprak evresinden çiçek başının oluşmasına kadar olan görüntüler alınmıştır.	1774
5	Toprak zemin nerdeyse tamamen bitkilerle kaplanmıştır. Canlı yeşil tonlar hâkimdir.	2236
6	Çiçek tablaları açılmaya başlamıştır. Tabla ortasındaki çiçeklenme işlemi başlamıştır.	1612
7	Üstten bakıldığında sarı ışın çiçekler görülmeye başlamıştır. Çiçek başları diktir.	1630
8	Tabla üzerindeki çiçeklenme işlemi tamamlanmış veya tamamlanmaya yakındır.	1610
	Çiçek tablaları eğilmeye başlamıştır. Sarı ışın çiçekleri görülmeye devam etmektedir.	
	Çiçeklenme tamamlanmış, çiçek tablaları tamamen eğilmiştir. Sarı ışın çiçekleri neredeyse tamamen dökülmüştür. Yeşil yapraklar solmaya başlamıştır.	
	Tabla arkaları açık sarı renge dönmüştür. Bitkiler ayrı ayrı görülebilmektedir.	
	Yeşil yapraklar iyice solmuş, toprak zemin görülmeye başlamıştır.	
	Fizyolojik olgunluk tamamlanmıştır. Çiçek tablaları ve bürgü yaprakları kahverengiye dönmüştür. Hasat için uygundur.	


farklılıklar oluşmuştur. 1610 görüntünün olduğu 8. sınıf en az görüntünün olduğu sınıftır. Her sınıftan rastgele olmak üzere eşit sayıda (1600 adet) görüntü alınarak bir veri seti oluşturulmuştur. Bu durumda 12800 görüntünün olduğu dengeli bir veri seti elde edilmiştir. Veri setindeki görüntüler 1333x1125 piksel boyutlarında olmasına rağmen, ağırlık girişine uygun olması için 224 x 224 piksel boyutlarına getirilmiştir. Sonrasında yüzde 80'i eğitim, yüzde 20'si test (birinci test seti) olmak üzere rastgele ayrılmıştır. Bu durumda veri setindeki 12800 görüntünün 10240 tanesi eğitim, 2560 tanesi test (birinci test seti) için kullanılmıştır. Ayrıca eğitim görüntülerinin yüzde 20'si doğrulama işlemi için kullanılmıştır. Veri setindeki her bir sınıfa ait görüntülerden örnekler Şekil 3'te verilmiştir.

2.3. Görüntülerin Sınıflandırılması ve Sonuçların Değerlendirilmesi (Classification of Images and Evaluation of Results)

CNN modellerinin eğitimi ve testi için sunduğu GPU desteği sayesinde büyük veriler üzerinde çok hızlı işlem yapılabilmesine

olanak sağlayan Google Colab bulut sistemi kullanılmıştır. Tüm kodlar OpenCV, Keras ve Tensorflow kütüphaneleri kullanılarak Python yazılım dilinde yazılmıştır. 12800 görüntünün olduğu veri seti altı farklı derin öğrenme modeli (AlexNet, InceptionV3, ResNet101, DenseNet121, MobileNet, Xception), 16 yığın boyutu, üç farklı optimizasyon yöntemi (Adam, Sgd, Rmsprop) ile 50 devir (epoch) eğitilmiştir. Veriler analiz edilirken en doğru modelin hangisi olduğuna karar vermek için kullanılan bazı ölçütler vardır. Bunlardan en sık kullanılanları doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1 skorudur [35]. Bu ölçütler karmaşıklık matrisi (confusion matrix) üzerinden hesaplanabilmektedir.

Doğruluk ölçütü, doğru tahmin edilen örneklerin sayısının tüm örnek sayısına bölünmesiyle bulunur. Eğer veri seti dengeli ise, yani her sınıfta eşit sayıda veri varsa doğruluk ölçütünün kullanılması mantıklıdır. Aksi takdirde bu ölçütün kullanılması yanıltıcı sonuçlar verecektir. Bu çalışmada kullanılan veri setleri dengeli olup, eğitim sonucu elde edilen doğruluk ve kayıp değerleri Tablo 3'te verilmiştir.



Şekil 3. Her bir ayçiçeği evresi için veri setinden örnek görüntüler
(Sample images from the dataset for each sunflower stage)

Tablo 3. Çalışmada kullanılan modellere ait kayıp ve doğruluk sonuçları (Loss and accuracy results of the models used in the study)

Modeller		Optimizasyon Yöntemleri		
		Adam	Sgd	Rmsprop
AlexNet	Kayıp	0,0229	0,0785	0,0012
	Doğruluk	99,414	97,500	99,960
InceptionV3	Kayıp	0,5943	0,0006	0,0274
	Doğruluk	89,062	100	99,492
ResNet101	Kayıp	0,0025	0,0060	0,0269
	Doğruluk	99,921	99,726	99,609
DenseNet121	Kayıp	0,0883	0,0061	0,0026
	Doğruluk	97,500	99,804	99,921
MobileNet	Kayıp	0,5368	0,0027	0,0065
	Doğruluk	88,593	99,921	99,765
Xception	Kayıp	0,0666	0,0016	0,0077
	Doğruluk	98,164	99,960	99,687

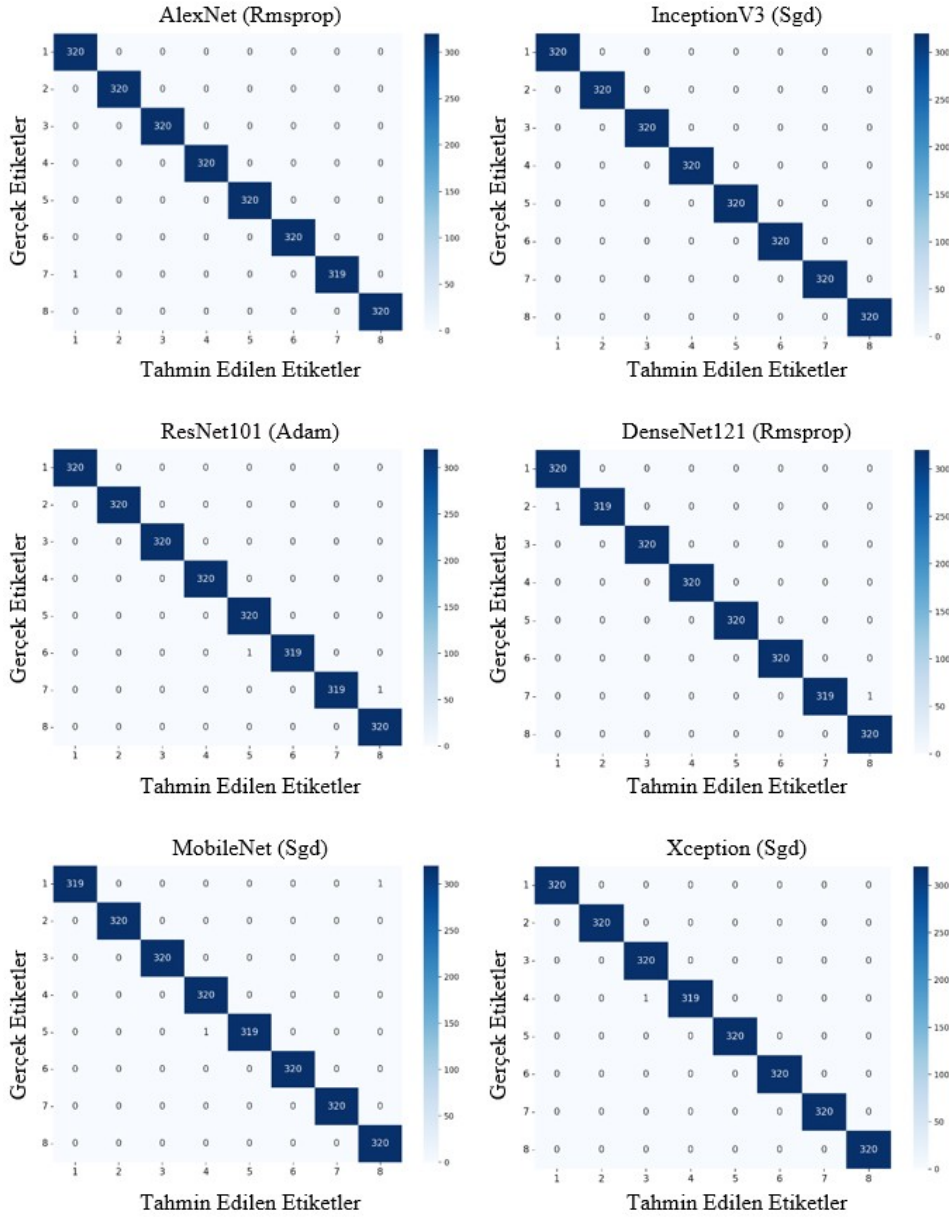
Tablo 3 incelendiğinde InceptionV3 ve MobileNet modelleri hariç, diğer modellerde optimizasyon yöntemlerinin başarı oranlarını çok değiştirmedikleri görülmektedir. ResNet101 modeli için Adam, AlexNet ve DenseNet121 modelleri için Rmsprop, InceptionV3, MobileNet ve Xception modelleri için Sgd optimizasyon yöntemi en yüksek başarı oranlarını vermiştir. Bu aşamadan sonra ki çalışmalar bu optimizasyon yöntemleriyle devam etmiştir.

Karmaşıklık matrisi, tahminlerin doğruluğu hakkında bilgi veren, gerçek değerlerin bilindiği test verileri üzerinde sınıflandırma modelinin performansını tanımlamak için kullanılan tablodur. Karmaşıklık matrisleri sınıf bazında kesinlik ve duyarlılık bilgilerinin resimli bir temsili verir [36]. Her bir sınıf için yapılan tahminlerin ne kadarının doğru ne kadarının yanlış veya hangi sınıfta ne kadar hatalı tahmin yapıldığını görmek için kullanılır. Bu çalışmada test edilen altı farklı model için, en yüksek doğruluk oranlarının elde edildiği optimizasyon yöntemlerine ait karmaşıklık matrisleri Şekil 4'te verilmiştir. Karmaşıklık matrisleri incelendiğinde yanlış tahminlerin genellikle bir önceki sınıf veya bir sonraki sınıf olarak tahmin edildiği söylenebilir. Buradan da özellikle sınıflar arası

geçişlerde görüntülerin doğru tahmin edilmesinde zorluklar yaşanabileceği sonucuna varabiliriz. Her bir modelin en yüksek doğruluk elde edildiği optimizasyon yöntemi için doğruluk grafiği Şekil 5'te verilmiştir.

Her model için doğruluk grafikleri incelendiğinde AlexNet modeli yaklaşık 40 devirde, InceptionV3 modeli yaklaşık 30 devirde en yüksek doğruluğa erişirken diğer modeller yaklaşık 20 devir civarında en yüksek doğruluğa erişmiş ve bu şekilde devam etmiştir. Bu durumda AlexNet modelinin diğer modellere göre daha yavaş bir şekilde yüksek performans elde ettiği söylenebilir. Her bir modelin en yüksek doğruluk elde edildiği optimizasyon yöntemi için hata (kayıp) grafiği Şekil 6'da verilmiştir.

Kesinlik ölçütü, pozitif olarak tahmin edilen örneklerin gerçekte kaç tanesinin pozitif olduğunu ifade eder. Duyarlılık ölçütü ise, doğru sınıflandırılmış pozitif örnek sayısının, toplam pozitif örnek sayısına oranını verir. Kesinlik ve duyarlılık ölçütleri tek başlarına anlamlı bir karşılaştırma sonucu vermede yeterli olmadığından, bu iki ölçütün beraber değerlendirildiği F1 skor ölçütü tanımlanmıştır. Bu ölçüt,



Şekil 4. Altı model için en yüksek başarımın elde edildiği test sonuçlarına ait karmaşıklık matrisleri
(The confusion matrices of the test results with the highest success for the six models)

kesinlik ve duyarlık değerlerinin harmonik ortalamasının alınmasıyla hesaplanır. Daha çok dengesiz veri setlerinde yapılan tahminlerin doğruluğunun karşılaştırılmasında kullanılır [37]. Bu çalışmada birinci test seti için pozitif olarak tahmin edilen örneklerin tümü pozitif olduğundan tüm modeller için kesinlik değeri 1'dir. Benzer şekilde doğru sınıflandırılmış pozitif örneklerin sayısı toplam pozitif örnek sayısına eşit olduğundan tüm modeller için duyarlılık değeri 1'dir. Dolayısıyla F1 skor değerleri de 1 olarak hesaplanmaktadır.


Daha objektif bir değerlendirme yapılabilmesi için, eğitilen modeller farklı bir araziden alınan görüntüler ile oluşturulan ikinci bir veri seti (ikinci test seti) üzerinde de test edilmiştir. Bu veri setinde her sınıf için 200 olmak üzere toplamda 1600 adet görüntü mevcuttur. İkinci test setinden örnek görüntüler Şekil 7'de verilmiştir.

İkinci test setindeki görüntüler incelendiğinde, gelişim aşamalarının düzensiz ve yabancı otların çok fazla olduğu görülmektedir. Bunlara

rağmen elde edilen doğruluk oranları oldukça yüksektir. İkinci test seti üzerinde yapılan testler sonucu elde edilen kayıp, doğruluk oranları, kesinlik, duyarlılık ve F1 skor değerleri Tablo 4'te verilmiştir. En yüksek doğruluk değeri ResNet101 modeli ve Adam optimizasyon yöntemiyle %87,81 olarak elde edilmiştir.

Gerçek hayatta bitkiler için evreler her zaman net değildir. Bazı durumlarda gözle bile karar vermek zor olabilmektedir. Bu durumda olan görüntüler ara sınıflar olarak sınıflandırılmış ve test edilmiştir. Bunun için 8 sınıf arasında geçiş aşamasında bulunan 400 görüntü alınarak bir ara sınıf test seti oluşturulmuştur. Toplamda 7 ara sınıf ve 2800 adet görüntüden oluşan ara sınıf test setinden örnek görüntüler Şekil 8'de verilmiştir.

Örneğin Şekil 8'de verilen ara sınıf test seti görüntülerinden 2-3 ara sınıfına ait (a) örneği incelendiğinde, bu görüntü için kesinlikle 3. sınıfta demek yanlış olacaktır, çünkü toprak zemin ve sıra araları hala



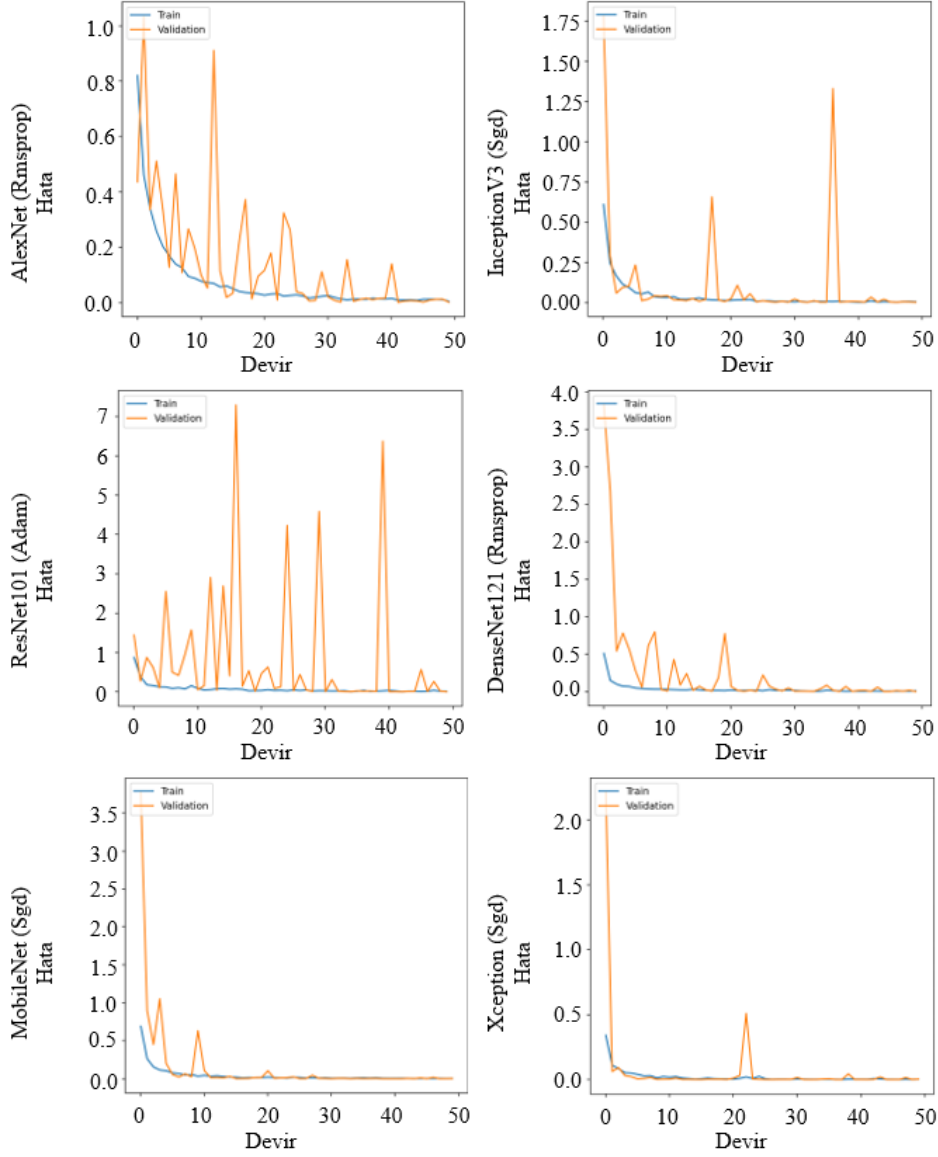
Şekil 5. Altı model için en yüksek başarımın elde edildiği eğitim işlemine ait doğruluk grafikleri
(Accuracy graphs of the training process with the highest success for six models)

görülebilmektedir. Benzer şekilde kesinlikle 2. sınıfta demek de yanlış olacaktır, çünkü bitkiler oldukça gelişmiş, üst üste binmiş ve toprak zemin neredeyse tamamen kaplanmak üzeredir. Bu görüntü InceptionV3 modeli ile test edildiğinde %42 olasılıkla 2. sınıfa, %57 olasılıkla 3. sınıfa ait olduğu sonucu çıkmaktadır. Benzer olarak 2-3 ara sınıfına ait (b) örneği DenseNet121 modeliyle test edildiğinde %51 olasılıkla 2. sınıfa, %48 olasılıkla 3. sınıfa ait olduğu sonucu çıkmaktadır. Bu yüzden hangi sınıfta olduğuna tam olarak karar verilemeyen görüntüler için olasılık hangi sınıfa daha yakın ise o evrede sınıflandırmak yanlış olmayacaktır.

Ara sınıf test setinde her sınıfta 400 adet görüntü bulunmaktadır. Her bir ara sınıf her bir model ile ayrı ayrı test edilmiş ve sonuçları Tablo 5'te verilmiştir. Bu tabloya göre örneğin 1-2 ara sınıfına ait tüm görüntüler 1. veya 2. sınıfa dahil edilmiş, dolayısıyla doğruluk oranı tüm modeller için %100 olarak elde edilmiştir. 2-3 ara sınıfı için AlexNet modeliyle 400 görüntüden 317 tanesi 2. sınıfa, 72 tanesi 3.

sınıfa, 9 tanesi 6. sınıfa, 2 tanesi 7. sınıfa dahil edilmiş ve doğruluk oranı %97,25 olarak hesaplanmıştır. Yine benzer şekilde Xception modeliyle 3-4 ara sınıfına ait görüntülerin 149 tanesi 3. sınıfa, 228 tanesi 4. sınıfa, 23 tanesi 6. sınıfa dahil edilmiş ve %94,25 doğruluk oranı elde edilmiştir. Sınıf bazında kaç adet görüntünün hangi sınıfta tahmin edildiği ve elde edilen doğruluk değerleri Tablo 5'te verilmiştir.


Tablo 5'ten görüldüğü gibi 7-8 ara sınıfı hariç tüm ara sınıfların sınıflandırılmasında yüksek başarılar elde edilirken, 7-8 ara sınıfı için doğruluk oranları çok düşük seviyelerde kalmıştır. Bu da genel başarı oranının düşmesine sebep olmuştur. Karmaşıklık matrisleri incelendiğinde 7-8 ara sınıfında hatalı olarak sınıflandırılan görüntülerin birçoğunun 1 sınıfta sınıflandırıldığı görülmektedir. Bunun sebebinin 1 ve 8 numaralı sınıflarda toprak zeminin daha çok görünmesi ve iki sınıfta da bir miktar yeşil yaprakların bulunması olduğu düşünülmektedir. Bu yüzden 1 ve 8 sınıfları arasındaki



Şekil 6. Altı model için en yüksek başarımın elde edildiği eğitim işlemine ait hata grafikleri
(Loss graphs of the training process with the highest success for six models)

farklılıkları arttırabilmek için görüntüler üzerinde yüksek geçiren filtreler (high pass filters) uygulanmış ve modeller tekrar eğitilmiştir. Özellikle 7-8 ara sınıfında ayçiçeği saplarının daha belirgin olabilmesi için yüksek geçiren filtreler ile denemeler yapılmıştır. Yüksek geçiren filtreler, görüntü üzerindeki yüksek frekansları vurgulayan ve düşük frekansları bastıran filtrelerdir. Bir görüntünün kontrast değeri arttığında frekans değeri de artar. Yüksek geçiren filtreler ile yüksek frekansların olduğu bölgeler tespit edilebilir [38]. Açık ve koyu tonlu detaylar arasındaki farkları belirginleştirmek, küçük detayları keskinleştirmek ve mümkün olduğu kadar çok detayı ortaya çıkarmak için kullanılırlar. Ancak bu işlem sırasında istenmeyen gürültüler de ortaya çıkmaktadır. Gürültülerin ortadan kaldırılması veya azaltılması için de birçok filtre tasarlanmıştır. Medyan filtresi bunlardan biridir. Medyan filtresi doğrusal olmayan bir yaklaşım olup, kenar algılama ve nesne çıkarma gibi işlemlerden önce, bozulmuş görüntünün kalitesini artırmak için kullanılan bir ön işleme tekniğidir [39]. Dolayısıyla yüksek geçiren filtre uygulanan ayçiçeği görüntüleri üzerinde sonuçlar incelenmiş, yüksek geçiren filtrelerin tek başlarına

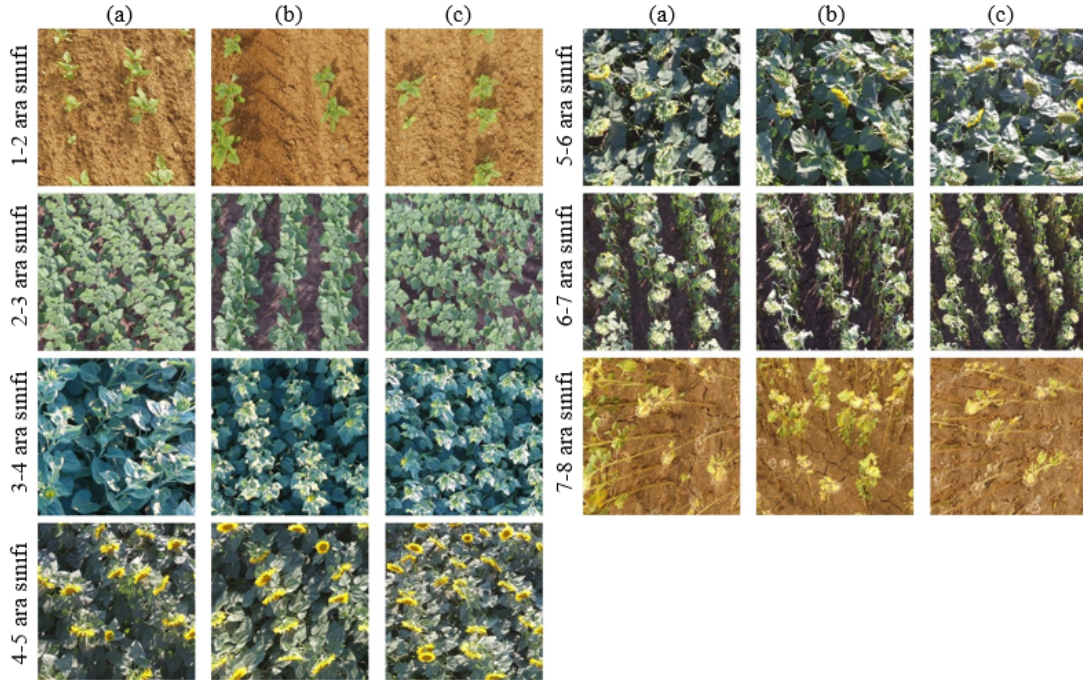
çok iyi sonuçlar vermediği görülmüştür. Sonrasında medyan filtresi de uygulanarak testler tekrar yapılmıştır. Tablo 6'da verilen 3x3 boyutunda yüksek geçiren filtresinden sonra, 3x3 ve 7x7 boyutunda medyan filtreleri uygulanarak sonuçlar karşılaştırılmıştır. Medyan filtresinin uygulanmasından önce ve sonra elde edilen sonuçlar Tablo 6'da verilmiştir. Tablo 6 incelendiğinde başarımın çok düşük olduğu 7-8 ara sınıfı için yüksek geçiren ve medyan filtreleri uygulandıktan sonra başarımın oldukça yükseldiği görülmektedir. Yüksek geçiren filtresinden sonra 3x3 boyutunda medyan filtresi uygulandığında 7-8 ara sınıfı için en yüksek doğruluk oranı DenseNet121 modeliyle %85,75 olarak elde edilmiştir. 7x7 boyutunda medyan filtresi uygulandığında ise en yüksek doğruluk oranı %80 olarak yine DenseNet121 modeliyle alınmıştır. Ortalama doğruluk oranları karşılaştırıldığında ise 3x3 medyan filtresiyle en yüksek başarı oranı %95,50 olarak DenseNet121 modeliyle, 7x7 medyan filtresiyle %92,32 olarak MobileNet modeliyle elde edilmiştir. Medyan filtresi öncesi ve sonrası tüm test setleri için genel doğruluk değerleri Tablo 7'de verilmiştir.



Şekil 7. İkinci test setinden örnek görüntüler (Sample images from the second test set)

Tablo 4. İkinci test setinden elde edilen kayıp, doğruluk, kesinlik, duyarlılık ve F1 skor değerleri
(Loss, accuracy, precision, sensitivity and F1 score values obtained from the second test set)

Modeller (Opimizasyon yöntemi)	Kayıp	Doğruluk	Kesinlik	Duyarlılık	F1 Skor
AlexNet (Rmsprop)	0,8876	85,81	0,88	0,86	0,84
InceptionV3 (Sgd)	0,9481	85,25	0,89	0,85	0,82
ResNet101 (Adam)	0,8494	87,81	0,90	0,88	0,86
DenseNet121 (Rmsprop)	1,9661	80,87	0,86	0,81	0,79
MobileNet (Sgd)	0,8378	81,37	0,85	0,81	0,79
Xception (Sgd)	0,6809	86,43	0,88	0,86	0,84



Şekil 8. Ara sınıf test setinden örnek görüntüler (Sample images from the intermediate class test set)

Tablo 5. Ara sınıf test setinden elde edilen sınıf bazında doğru örnek sayıları ve doğruluk oranları
(Accurate sample counts and accuracy rates by class obtained from the intermediate class test set)

Ara sınıf	Modeller	Sınıflar								Doğruluk oranı
		1	2	3	4	5	6	7	8	
1-2	AlexNet	309	91	0	0	0	0	0	0	100
	InceptionV3	327	73	0	0	0	0	0	0	100
	ResNet101	292	108	0	0	0	0	0	0	100
	DenseNet121	332	68	0	0	0	0	0	0	100
	MobileNet	326	74	0	0	0	0	0	0	100
	Xception	315	85	0	0	0	0	0	0	100
2-3	AlexNet	0	317	72	0	0	9	2	0	97,25
	InceptionV3	0	314	73	0	0	9	4	0	96,75
	ResNet101	0	298	80	0	0	14	8	0	94,50
	DenseNet121	0	293	105	0	0	2	0	0	99,50
	MobileNet	0	259	81	0	0	6	54	0	85,00
	Xception	0	264	130	0	0	4	2	0	98,50
3-4	AlexNet	0	0	32	349	0	19	0	0	95,25
	InceptionV3	0	0	142	246	2	10	0	0	97,00
	ResNet101	0	0	80	290	0	30	0	0	92,50
	DenseNet121	0	0	160	216	0	24	0	0	94,00
	MobileNet	0	0	44	335	6	15	0	0	94,75
	Xception	0	0	149	228	0	23	0	0	94,25
4-5	AlexNet	0	0	0	33	361	0	2	4	98,50
	InceptionV3	0	0	0	3	386	0	4	7	97,25
	ResNet101	0	0	0	20	366	0	1	13	96,50
	DenseNet121	0	0	0	11	362	0	6	21	93,25
	MobileNet	0	0	0	59	338	0	3	0	99,25
	Xception	0	0	0	32	352	2	0	14	96,00
5-6	AlexNet	0	0	0	0	95	305	0	0	100
	InceptionV3	0	0	0	0	83	317	0	0	100
	ResNet101	0	0	0	0	114	286	0	0	100
	DenseNet121	0	0	0	0	106	253	41	0	89,75
	MobileNet	0	0	0	0	141	257	1	1	99,50
	Xception	0	0	0	0	35	365	0	0	100
6-7	AlexNet	0	1	0	0	0	316	83	0	99,75
	InceptionV3	0	0	0	0	0	267	133	0	100
	ResNet101	0	0	0	0	0	305	95	0	100
	DenseNet121	0	0	0	0	0	217	183	0	100
	MobileNet	0	0	0	0	0	262	138	0	100
	Xception	0	0	0	0	0	346	54	0	100
7-8	AlexNet	314	0	0	0	0	0	68	18	21,50
	InceptionV3	299	0	0	0	0	0	37	64	25,25
	ResNet101	172	0	0	0	0	0	49	179	57,00
	DenseNet121	125	0	0	91	0	0	23	161	46,00
	MobileNet	286	0	0	0	0	0	84	30	28,50
	Xception	312	0	0	0	0	0	37	51	22,00
Ortalama doğruluk oranı	AlexNet									87,46
	InceptionV3									88,03
	ResNet101									91,50
	DenseNet121									88,92
	MobileNet									86,71
	Xception									87,25

Tablo 6. Filtre uygulandıktan sonra ara sınıflar için sınıf bazında elde edilen doğruluk oranları
(Class-based accuracy rates for intermediate phases after filtering)

Uygulanan filtre	Modeller	Ara sınıflar							Doğruluk oranı									
		1-2	2-3	3-4	4-5	5-6	6-7	7-8										
<table border="1"> <tr><td>0</td><td>0</td><td>0</td></tr> <tr><td>-1</td><td>3</td><td>-1</td></tr> <tr><td>0</td><td>0</td><td>0</td></tr> </table>	0	0	0	-1	3	-1	0	0	0	AlexNet	99,75	75,25	49,75	98,50	100	100	18,75	77,42
	0	0	0															
	-1	3	-1															
	0	0	0															
	InceptionV3	100	90,25	84,25	99,00	100	100	24,25	85,39									
	ResNet101	99,50	75,75	96,25	96,25	55,25	57,25	95,25	82,21									
	DenseNet121	100	94,00	96,75	99,25	98,75	99,50	24,25	87,50									
MobileNet	99,75	95,50	99,25	96,00	96,25	97,50	37,50	88,82										
Xception	100	95,25	98,25	96,00	100	100	26,25	87,96										
<table border="1"> <tr><td>0</td><td>0</td><td>0</td></tr> <tr><td>-1</td><td>3</td><td>-1</td></tr> <tr><td>0</td><td>0</td><td>0</td></tr> </table> + Medyan(3x3)	0	0	0	-1	3	-1	0	0	0	AlexNet	73,00	99,75	99,75	95,75	98,25	95,00	81,00	91,78
	0	0	0															
	-1	3	-1															
	0	0	0															
	InceptionV3	100	93,00	94,00	96,00	100	100	37,00	88,57									
	ResNet101	100	89,75	87,25	89,25	99,25	99,75	71,25	90,92									
	DenseNet121	100	99,50	92,25	94,25	96,75	100	85,75	95,50									
MobileNet	99,75	93,50	95,75	97,25	100	100	25,25	87,35										
Xception	100	96,00	95,50	99,75	100	100	24,50	87,96										
<table border="1"> <tr><td>0</td><td>0</td><td>0</td></tr> <tr><td>-1</td><td>3</td><td>-1</td></tr> <tr><td>0</td><td>0</td><td>0</td></tr> </table> + Medyan(7x7)	0	0	0	-1	3	-1	0	0	0	AlexNet	100	77,25	87,00	84,50	99,25	97,75	36,75	70,91
	0	0	0															
	-1	3	-1															
	0	0	0															
	InceptionV3	100	82,00	94,50	99,00	95,50	100	36,75	86,82									
	ResNet101	100	93,75	86,75	97,25	98,50	100	41,00	88,17									
	DenseNet121	100	96,25	67,75	94,00	99,50	100	80,00	91,07									
MobileNet	98,75	91,50	96,75	99,00	99,50	99,75	61,00	92,32										
Xception	100	94,50	91,25	97,00	100	100	40,00	88,96										

Tablo 7. Medyan filtre öncesi ve sonrası test setleri için doğruluk oranları
(Accuracy rates for test sets before and after median filter)

Uygulanan filtre	Modeller	Doğruluk oranı (Birinci test seti)	Doğruluk oranı (İkinci test seti)	Doğruluk oranı (Ara sınıf test seti)									
<table border="1"> <tr><td>0</td><td>0</td><td>0</td></tr> <tr><td>-1</td><td>3</td><td>-1</td></tr> <tr><td>0</td><td>0</td><td>0</td></tr> </table>	0	0	0	-1	3	-1	0	0	0	AlexNet	93,24	76,94	77,42
	0	0	0										
	-1	3	-1										
	0	0	0										
	InceptionV3	99,76	83,19	85,39									
	ResNet101	92,53	78,69	82,21									
	DenseNet121	99,88	86,25	87,50									
MobileNet	99,80	80,56	88,82										
Xception	100	87,19	87,96										
<table border="1"> <tr><td>0</td><td>0</td><td>0</td></tr> <tr><td>-1</td><td>3</td><td>-1</td></tr> <tr><td>0</td><td>0</td><td>0</td></tr> </table> + Medyan(3x3)	0	0	0	-1	3	-1	0	0	0	AlexNet	87,77	76,74	91,78
	0	0	0										
	-1	3	-1										
	0	0	0										
	InceptionV3	100	86,25	88,57									
	ResNet101	99,53	91,50	90,92									
	DenseNet121	99,92	81,87	95,50									
MobileNet	99,76	80,43	87,35										
Xception	100	87,74	87,96										
<table border="1"> <tr><td>0</td><td>0</td><td>0</td></tr> <tr><td>-1</td><td>3</td><td>-1</td></tr> <tr><td>0</td><td>0</td><td>0</td></tr> </table> + Medyan(7x7)	0	0	0	-1	3	-1	0	0	0	AlexNet	99,10	83,68	70,91
	0	0	0										
	-1	3	-1										
	0	0	0										
	InceptionV3	99,60	82,49	86,82									
	ResNet101	99,60	87,18	88,17									
	DenseNet121	99,14	80,43	91,07									
MobileNet	97,25	85,62	92,32										
Xception	99,49	87,56	88,96										

Her bir test seti dikkate alındığında, 3x3 boyutundaki medyan filtresinin 7x7 boyutuna göre daha iyi sonuçlar verdiği söylenebilir. Bunun nedeni filtre boyutu arttıkça etkilenen piksel sayısının da artması ve buna bağlı olarak bazı detayların ortadan kalkmasıdır. Genel doğruluğun en yüksek elde edildiği 3x3 yüksek geçiren ve 3x3 medyan filtresi için ara sınıf test seti karmaşıklık matrisleri Tablo 8’de verilmiştir.

3. Sonuçlar ve Tartışmalar (Results and Discussions)

Bu çalışmada, derin öğrenme yöntemleri kullanılarak ayçiçeklerinin hangi gelişim evresinde olduğu başarılı bir şekilde tespit edilebilmiştir. Altı farklı derin öğrenme modeli ile gerçekleştirilen sınıflandırma çalışmasında yüksek doğruluk oranları elde edilmiştir. Kullanılan CNN modelleri sayesinde ayçiçeğinin gelişim evresi hızlı,

Tablo 8. Filtre uygulandıktan sonra ara sınıf test seti için karmaşıklık matrisleri
(Confusion matrices for intermediate class test set after filtering)

Ara sınıf	Modeller	Sınıflar								Doğruluk oranı
		1	2	3	4	5	6	7	8	
1-2	AlexNet	176	116	0	0	0	0	0	108	73,00
	InceptionV3	311	89	0	0	0	0	0	0	100
	ResNet101	321	79	0	0	0	0	0	0	100
	DenseNet121	309	91	0	0	0	0	0	0	100
	MobileNet	318	81	0	0	0	0	1	0	99,75
	Xception	332	68	0	0	0	0	0	0	100
2-3	AlexNet	0	392	7	0	1	0	0	0	99,75
	InceptionV3	0	284	88	0	0	23	5	0	93,00
	ResNet101	0	313	46	0	0	40	1	0	89,75
	DenseNet121	0	353	45	0	0	1	1	0	99,50
	MobileNet	1	226	148	0	0	2	23	0	93,50
	Xception	0	250	134	0	0	14	2	0	96,00
3-4	AlexNet	0	0	8	391	1	0	0	0	99,75
	InceptionV3	0	0	32	344	1	23	0	0	94,00
	ResNet101	0	0	8	341	0	51	0	0	87,25
	DenseNet121	0	0	23	346	0	31	0	0	92,25
	MobileNet	0	0	75	308	0	17	0	0	95,75
	Xception	0	0	106	276	0	18	0	0	95,50
4-5	AlexNet	0	0	0	24	359	0	0	17	95,75
	InceptionV3	0	0	0	1	383	0	0	16	96,00
	ResNet101	0	0	0	29	328	0	10	33	89,25
	DenseNet121	0	0	0	17	360	0	23	0	94,25
	MobileNet	0	0	0	15	374	0	0	11	97,25
	Xception	0	0	0	0	399	0	0	1	99,75
5-6	AlexNet	0	0	0	5	277	116	2	0	98,25
	InceptionV3	0	0	0	0	63	337	0	0	100
	ResNet101	0	0	0	0	115	282	3	0	99,25
	DenseNet121	0	0	0	0	81	306	13	0	96,75
	MobileNet	0	0	0	0	70	330	0	0	100
	Xception	0	0	0	0	68	332	0	0	100
6-7	AlexNet	0	2	0	1	17	36	344	0	95,00
	InceptionV3	0	0	0	0	0	295	105	0	100
	ResNet101	0	0	0	0	1	302	97	0	99,75
	DenseNet121	0	0	0	0	0	176	224	0	100
	MobileNet	0	0	0	0	0	218	182	0	100
	Xception	0	0	0	0	0	304	96	0	100
7-8	AlexNet	43	24	0	9	0	0	85	239	81,00
	InceptionV3	252	0	0	0	0	0	60	88	37,00
	ResNet101	115	0	0	0	0	0	22	263	71,25
	DenseNet121	54	0	0	3	0	0	124	219	85,75
	MobileNet	299	0	0	0	0	0	41	60	25,25
	Xception	302	0	0	0	0	0	48	50	24,50

kolay ve yüksek doğrulukla tespit edilebilmektedir. Birinci veri seti üzerinde üç farklı optimizasyon yöntemiyle eğitilen modellerin, birinci test seti ve farklı bir araziden alınan ikinci test seti üzerindeki doğrulukları Tablo 9'da verilmiştir.

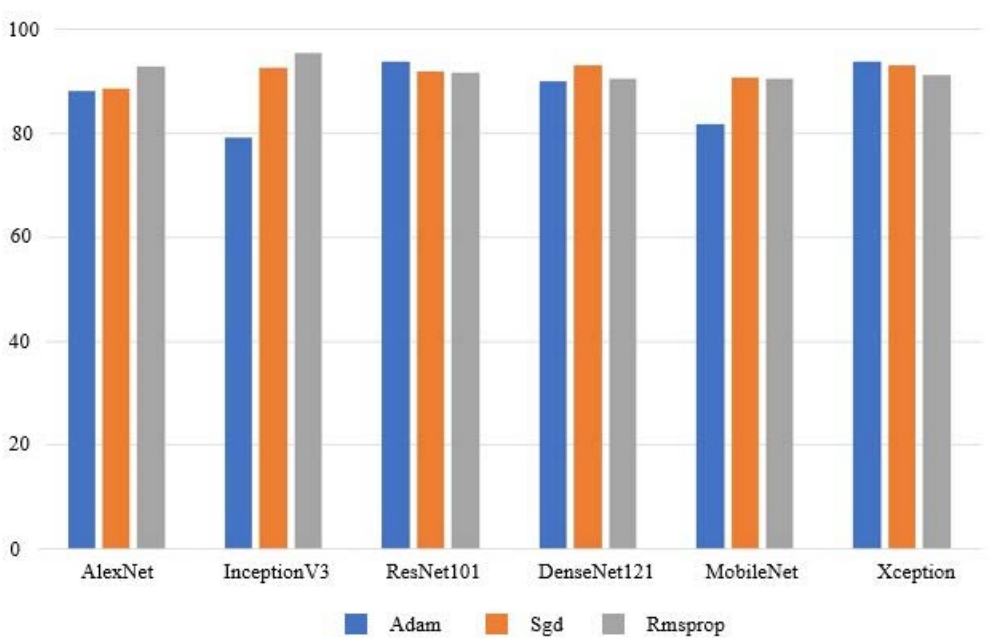
Tablo 9'dan görüldüğü gibi birinci test seti üzerinde en yüksek doğruluk InceptionV3 modeli ve Sgd optimizasyon yöntemiyle %100 olarak elde edilmiştir. Ancak Rmsprop optimizasyon yöntemiyle de %99,49 gibi çok yüksek bir doğruluk oranı elde edilmiştir. İkinci test seti üzerinde ise en yüksek doğruluk oranı, yine InceptionV3 modeliyle ancak Rmsprop optimizasyon yöntemiyle %91,18 olarak elde edilmiştir. Ortalama doğruluk oranları dikkate alındığında, en yüksek başarı InceptionV3 modeli ve Rmsprop optimizasyon yöntemiyle sağlanmış olup, %95,33 olarak hesaplanmıştır. Her bir model ve optimizasyon yöntemi için, ortalama doğruluk oranlarını gösteren grafik Şekil 9'da verilmiştir. Eğitilen modeller, gelişim

aşamasına tam karar verilemeyen, iki sınıfa da dahil edilebilecek görüntülerden oluşan 7 sınıflı ara sınıf test seti üzerinde de test edilmiştir. Her bir model için, ara sınıf bazında doğruluk oranları ve ortalama doğruluk oranları Tablo 10'da verilmiştir.

Tablo 10'da 7-8 ara sınıfına ait görüntülerin tahmin edilmesinde başarı oranının çok düşük olduğu, bu durumun ortalama doğruluk oranını da düşürdüğü görülmektedir. 7-8 ara sınıfı için en yüksek başarı ResNet101 modeliyle %57, ortalama başarı oranı ise yine ResNet101 modeliyle %91,50 olarak elde edilmiştir. 7-8 ara sınıfında da başarı oranını arttırabilmek için bazı yüksek geçiren filtreler ile testler tekrar yapılmıştır. Bu filtreler ile oluşan gürültüleri bastırmak için de 3x3 ve 7x7 boyutunda medyan filtreleri uygulanmıştır. En iyi sonuçların elde edildiği yüksek geçiren filtre, sonrasında 3x3 ve 7x7 boyutlarında medyan uygulandıktan sonra elde edilen doğruluk oranları, her bir test seti için Tablo 11'de verilmiştir.

Tablo 9. Birinci ve ikinci test seti için doğruluk oranları (Accuracy rates for the first and second test set)

Modeller	Birinci test seti doğruluk oranları			İkinci test seti doğruluk oranları			Ortalama doğruluk oranları		
	Adam	Sgd	Rmsprop	Adam	Sgd	Rmsprop	Adam	Sgd	Rmsprop
AlexNet	99,41	97,50	99,96	76,74	79,93	85,81	88,08	88,71	92,88
InceptionV3	89,06	100	99,49	69,49	85,25	91,18	79,28	92,62	95,33
ResNet101	99,92	99,72	99,60	87,81	83,99	83,62	93,86	91,86	91,61
DenseNet121	97,50	99,80	99,92	82,68	86,25	80,87	90,09	93,02	90,39
MobileNet	88,59	99,92	99,76	75,00	81,37	81,12	81,79	90,64	90,44
Xception	98,16	99,96	99,68	89,49	86,43	82,81	93,83	93,19	91,24



Şekil 9. Her bir model ve optimizasyon yöntemine ait ortalama doğruluk oranları (Average accuracy rates for each model and optimization method)

Tablo 10. Ara sınıf test seti için sınıf bazında ve ortalama doğruluk oranları (Class-based and average accuracy rates for the intermediate class test set)

Modeller	Ara sınıflar							Ortalama doğruluk oranları
	1-2	2-3	3-4	4-5	5-6	6-7	7-8	
AlexNet	100	97,25	95,25	98,50	100	99,75	21,50	87,46
InceptionV3	100	96,75	97,00	97,25	100	100	25,25	88,03
ResNet101	100	94,50	92,50	96,50	100	100	57,00	91,50
DenseNet121	100	99,50	94,00	93,25	89,75	100	46,00	88,92
MobileNet	100	85,00	94,75	99,25	99,50	100	28,50	86,71
Xception	100	98,50	94,25	96,00	100	100	22,00	87,25


Ortalama doğruluk oranları dikkate alındığında 3x3 medyan filtresinin 7x7 medyan filtresine göre daha iyi sonuçlar verdiği görülmektedir. Veri setindeki görüntülerin 224x224 piksel boyutlarında olmasından ve filtre boyutu arttıkça detayların daha fazla kaybolmasından dolayı 3x3 filtrelerin daha iyi sonuçlar verdiği söylenebilir. Tablo 11'e göre en iyi sonuçlar ResNet101 modeliyle

%93,98 olarak elde edilmiştir. Filtresiz ve filtreli sonuçların ortalama doğruluk oranlarını gösteren grafik Şekil 10'da verilmiştir.

Şekil 10'da verilen grafikte dört ayrı durum için sonuçlar gösterilmiştir. Filtre yok: Herhangi bir yüksek geçiren veya medyan filtresi uygulanmamıştır. 1.Durum: Sadece 3x3 boyutunda yüksek

Tablo 11. Filtresiz, yüksek geçiren filtreli, 3x3 ve 7x7 medyan filtre uygulanmış görüntüler için test sonuçları (Test results for unfiltered, high-pass filtered, 3x3 and 7x7 median filtered images)

Kullanılan Filtreler	Modeller	Birinci test seti doğruluk oranları	İkinci test seti doğruluk oranları	Ara sınıf test seti doğruluk oranları	Ortalama doğruluk oranları									
Filtre yok	AlexNet	99,96	85,81	87,46	91,07									
	InceptionV3	100	85,25	88,03	91,09									
	ResNet101	99,92	87,81	91,50	93,07									
	DenseNet121	99,92	80,87	88,92	89,90									
	MobileNet	99,92	81,37	86,71	89,33									
	Xception	99,96	86,43	87,25	91,21									
<table border="1" style="display: inline-table; vertical-align: middle;"> <tr><td>0</td><td>0</td><td>0</td></tr> <tr><td>-1</td><td>3</td><td>-1</td></tr> <tr><td>0</td><td>0</td><td>0</td></tr> </table>	0	0	0	-1	3	-1	0	0	0	AlexNet	93,24	76,94	77,42	82,53
	0	0	0											
	-1	3	-1											
	0	0	0											
	InceptionV3	99,76	83,19	85,39	89,44									
	ResNet101	92,53	78,69	82,21	84,47									
DenseNet121	99,88	86,25	87,50	91,21										
MobileNet	99,80	80,56	88,82	89,72										
Xception	100	87,19	87,96	91,71										
<table border="1" style="display: inline-table; vertical-align: middle;"> <tr><td>0</td><td>0</td><td>0</td></tr> <tr><td>-1</td><td>3</td><td>-1</td></tr> <tr><td>0</td><td>0</td><td>0</td></tr> </table> + 3x3 medyan	0	0	0	-1	3	-1	0	0	0	AlexNet	87,77	76,74	91,78	85,43
	0	0	0											
	-1	3	-1											
	0	0	0											
	InceptionV3	100	86,25	88,57	91,60									
	ResNet101	99,53	91,50	90,92	93,98									
DenseNet121	99,92	81,87	95,50	92,43										
MobileNet	99,76	80,43	87,35	89,18										
Xception	100	87,74	87,96	91,90										
<table border="1" style="display: inline-table; vertical-align: middle;"> <tr><td>0</td><td>0</td><td>0</td></tr> <tr><td>-1</td><td>3</td><td>-1</td></tr> <tr><td>0</td><td>0</td><td>0</td></tr> </table> + 7x7 medyan	0	0	0	-1	3	-1	0	0	0	AlexNet	99,10	83,68	70,91	84,56
	0	0	0											
	-1	3	-1											
	0	0	0											
	InceptionV3	99,60	82,49	86,82	89,63									
	ResNet101	99,60	87,18	88,17	91,65									
DenseNet121	99,14	80,43	91,07	90,21										
MobileNet	97,25	85,62	92,32	91,73										
Xception	99,49	87,56	88,96	92,00										



Şekil 10. Filtresiz ve filtreli sonuçların ortalama doğruluk oranları (Average accuracy of unfiltered and filtered results)

geçiren filtre uygulanmıştır. 2.Durum: 3x3 boyutunda yüksek geçiren ve sonrasında 3x3 boyutunda median filtre uygulanmıştır. 3.Durum: 3x3 boyutunda yüksek geçiren ve sonrasında 7x7 boyutunda median filtre uygulanmıştır. Grafikten de görüldüğü gibi en iyi sonuç ResNet101 modeliyle 2.durumda, yani yüksek geçiren filtre sonrası 3x3 boyutunda median filtresinin uygulanmasıyla alınmıştır.

Kaynaklar (References)

- Gökırmaklı Ç., Bayram M., Gıda için gelecek öngörülere: Yıl 2050, Akademik Gıda, 16 (3), 351-360, 2018.
- Bayraktar N., Kolsarıcı Ö., İşler N., Mert M., Arslan B., Yağlı tohumlu bitkilerin tüketim projeksiyonları ve üretim hedefleri, Türkiye Ziraat Mühendisliği IV. Teknik Kongresi, Ankara-Türkiye, 467-483, 9-13 Ocak, 1995.
- Onat B., Arıoğlu H., Güllüoğlu L., Kurt C., Bakal H., Dünya ve Türkiye'de yağlı tohum ve ham yağ üretimine bir bakış, Kahramanmaraş Sütçü İmam Üniversitesi Tarım ve Doğa Dergisi, 20, 149-153, 2017.
- Erem Kaya T., Sezgin A., Küllekiç M., Kumbasaroğlu H., Dünyada ve Türkiye'de ayçiçeği üretimi ve dış ticaretindeki gelişmeler, Alinteri Journal of Agriculture Science, 18 (1), 28-33, 2010.
- Berglund D.R., Sunflower Production, North Dakota Agricultural Experiment Station and North Dakota State University Extension Service Extension Publication A-1331 (EB-25 Revised), North Dakota State University, Fargo, 2007.
- Schneider A.A., Miller J.F., Description of sunflower growth stages, Crop Science, 21 (6), 901-903, 1981.
- Castillo F.M., Calderini D., Vásquez S., Does the pre-flowering period determine the potential grain weight of sunflower?, Field Crops Research, 212, 23-33, 2017.
- Kaya M.D., Farklı gelişme dönemlerinde uygulanan sulamaların ayçiçeği (*Helianthus annuus* L.)'nde verim ve verim öğelerine etkileri, Doktora Tezi, Ankara Üniversitesi, Fen Bilimleri Enstitüsü, 2006.
- Amjed A., Noorka I.R., Differential growth and development response of sunflower hybrid in contrasting irrigation regimes, American Journal of Plant Sciences, 4 (5), 1060-1065, 2013.
- Ghani A., Hussain M., Qureshi M.S., Effect of different irrigation regimens on the growth and yield of sunflower, International Journal Of Agriculture & Biology, 2 (4), 334-335, 2000.
- Göksoy A.T., Demir A.O., Turan Z.M., Dağüstü N., Responses of sunflower (*Helianthus annuus* L.) to full and limited irrigation at different growth stages, Field Crops Research, 87 (2-3), 167-178, 2004.
- Erdem T., Delibaş L., Yield response of sunflower to water stress under Tekirdağ conditions, Helia, 26 (38), 149-158, 2003.
- Özdemir U., Sinan N.S., Çukurova'da kuru koşullarda ayçiçeğinin (*Helianthus Annuus* L.) farklı gelişme dönemlerinde uygulanan yaprak gübresinin verim ve verim öğeleri üzerine etkileri, Ç.Ü Fen ve Mühendislik Bilimleri Dergisi, 39 (5), 2020.
- Yue Y., Li J.H., Fan L.F., Zhang L.L., Zhao P.F., Zhou Q., Wang N., Wang Z.Y., Huang L., Dong X.H., Prediction of maize growth stages based on deep learning, Computers and Electronics in Agriculture, 172 (105351), 2020.
- Rasti S., Bleakley C.J., Silvestre G. C. M., Holden N. M., Langton D., O'Hare G. M. P., Crop growth stage estimation prior to canopy closure using deep learning algorithms, Neural Computing and Applications, 33, 1733-1743, 2021.
- Samiei S., Rasti P., Ly Vu J., Buitink J., Rousseau D., Deep learning-based detection of seedling development, Plant Methods, 16 (1), 2020.
- Koirala A., Walsh K.B., Wang Z., Anderson N., Deep Learning for mango (*Mangifera indica*) panicle stage classification, Agronomy, 10 (1), 2020.
- Ikasari I.H., Ayumi V., Fanany M.I., Mulyono S., Multiple regularizations deep learning for paddy growth stages classification from LANDSAT-8, 2016 International Conference on Advanced Computer Science and Information Systems (ICACSIS), Malang-Indonesia, 512-517, 15-16 October, 2016.
- Desai S.V., Balasubramanian V.N., Fukatsu T., Ninomiya S., Guo W., Automatic estimation of heading date of paddy rice using deep learning, Plant Methods, 15 (76), 2019.
- Namin S.T., Esmacilzadeh M., Najafi M., Brown T.B., Borevitz J.O., Deep phenotyping: deep learning for temporal phenotype/genotype classification, Plant Methods, 14 (66), 2018.
- Jiang Y., Li C., Xu R., Sun S., Robertson J.S., Paterson A.H., DeepFlower: a deep learning-based approach to characterize flowering patterns of cotton plants in the field, Plant Methods, 16 (1), 2020.
- Hasan M.M., Chopin J.P., Laga H., Miklavcic S.J., Detection and analysis of wheat spikes using Convolutional Neural Networks, Plant Methods, 14 (1), 2018.
- Döş M.E., Uysal M., Uzaktan algılama verilerinin derin öğrenme algoritmaları ile sınıflandırılması, Türkiye Uzaktan Algılama Dergisi, 1 (1), 28-34, 2019.
- Alex K., Sutskever I., Geoffrey E., Imagenet classification with deep convolutional neural networks, Communications of the ACM, 60 (6), 84-90, 2017.
- Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D., Erhan D., Vanhoucke V., Rabinovich A., Going deeper with convolutions, 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston-USA, 1-9, 7-12 June, 2015.
- Fırat H., Hanbay D., Comparison of 3D CNN based deep learning architectures using hyperspectral images, Journal of the Faculty of Engineering and Architecture of Gazi University, 38 (1), 521-534, 2023.
- He K., Zhang X., Ren S., Sun J., Deep residual learning for image recognition, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas-USA, 770-778, 27-30 June, 2016.
- Chollet F., Xception: Deep learning with depthwise separable convolutions, 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu-USA, 1800-1807, 21-26 July, 2017.
- Şafak E., Doğru İ., Barışçı N., Toklu S., IoT based mobile driver drowsiness detection using deep learning, Journal of the Faculty of Engineering and Architecture of Gazi University, 37 (4), 1869-1882, 2022.
- Howard A.G., Zhu M., Chen B., Kalenichenko D., Mobilenets: Efficient convolutional neural networks for mobile vision applications, arXiv preprint arXiv:1704.04861, 2017.
- Huang G., Liu Z., Maaten L.V.D., Weinberger K.Q., Densely connected convolutional networks, 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu-USA, 2261-2269, 21-26 July, 2017.
- Gülcü A., Kuş Z., Konvolüsyonel sinir ağlarında hiper-parametre optimizasyonu yöntemlerinin incelenmesi, Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji, 7 (2), 503-522, 2019.
- Ecemiş İ.N., İlhan H.O., The performance comparison of pre-trained networks with the proposed lightweight convolutional neural network for disease detection in tomato leaves, Journal of the Faculty of Engineering and Architecture of Gazi University, 38 (2), 693-705, 2023.
- Shorten C., Khoshgoftaar T.M., A survey on image data augmentation for deep learning, Journal of Big Data, 6 (1), 1-48, 2019.
- Uslu O., Özmen Akyol S., Türkçe Haber Metinlerinin Makine Öğrenmesi Yöntemleri Kullanılarak Sınıflandırılması, Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi, 2 (1), 15-20, 2021.
- Theckedath D., Sedamkar R.R., Detecting affect states using VGG16, ResNet50 and SE ResNet50 Networks, SN Computer Science, 1, 1-7, 2020.
- Karasulu B., Yücalar F., Borandağ E., A hybrid approach based on deep learning for gender recognition using human ear images, Journal of the Faculty of Engineering and Architecture of Gazi University, 37 (3), 1579-1594, 2022.
- Akbulut H., Aslantaş V., Multi-exposure image fusion using convolutional neural network, Journal of the Faculty of Engineering and Architecture of Gazi University, 38 (3), 1439-1451, 2023.
- Shah A., Bangash J., Khan A.W., Ahmed I., Khan A., Khan A., Khan A., Comparative analysis of median filter and its variants for removal of impulse noise from gray scale images, Journal of King Saud University - Computer and Information Sciences, 34 (3), 505-519, 2022.

