



# Kahramanmaraş Sütçü İmam University Journal of Engineering Sciences



Geliş Tarihi : 31.03.2022  
Kabul Tarihi : 20.05.2022

Received Date : 31.03.2022  
Accepted Date : 20.05.2022

## DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK BİTKİ YAPRAĞINDAKİ HASTALIKLARIN SINIFLANDIRILMASI

### CLASSIFICATION OF PLANT LEAF DISEASES USING DEEP LEARNING METHODS

*Ipek ATİK*<sup>1</sup> (ORCID: 0000-0002-9761-1347)

<sup>1</sup> Gaziantep İslam Bilim ve Teknoloji Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Gaziantep, Türkiye

\*Sorumlu Yazar / Corresponding Author: Ipek ATİK, [ipek.atik@gibtu.edu.tr](mailto:ipek.atik@gibtu.edu.tr),

#### ÖZET

Bitkilerin yetiştirilme süreci zahmetli ve uzun süren bir işlemdir. Bitki yetiştiriciliği ile uğraşan kişilerin en önemli sorunlarından biri bitki hastalığıdır. Hastalıkla mücadelede ilk olarak yapılması gereken hastalığın tanınmasıdır. Hastalıkla mücadelede hastalığın doğru bir şekilde tespit edip gereken önlemleri hızlı bir şekilde alabilmek oldukça önemlidir. Çalışmada domates yapraklarındaki hastalık belirlenmesinde derin öğrenme yöntemleri kullanılmıştır. Çalışmada kullanılan veri setinde 9 hastalıklı ve 1 sağlıklı sınıftan oluşan toplam 18.160 domates yaprağı görüntüsü bulunmaktadır. Görüntü hastalık sınıflandırmasında derin evrişimli sinir ağları (ESA) modellerden ön eğitilmiş ağlar olan GoogleNet, AlexNet, SqueezeNet, ShuffleNet ve ResNet-18 modelleri kullanılmıştır. Analizlerde veri seti %70 eğitim, %15 doğrulama ve %15 test verisi olarak ayrılmıştır. Eğitilmiş ağların test verisi ile performans ölçütleri doğruluk, kesinlik, özgüllük ve f-puanı değerleri hesaplanmıştır. Modellerin doğruluk oranları AlexNet, GoogleNet, ShuffleNet, SqueezeNet ve ResNet-18 için sırasıyla %93,93, %95,18, %94,82, %94,29 ve %81,79 olarak elde edilmiştir. Yapılan analizlere göre ön eğitilmiş ağların domates yaprağı hastalık sınıflandırma çalışmasında, en iyi performans gösteren modelin GoogleNet olduğu görülmüştür.

**Anahtar Kelimeler:** Derin Öğrenme, evrişimsel sinir ağları, görüntü sınıflandırma, domates bitkisi, hastalık

#### ABSTRACT

The process of growing plants is laborious and time-consuming. Plant diseases are one of the most significant problems facing people who deal with plant breeding. The first thing to do in the fight against the disease is to recognize the disease. It is essential to detect the disease quickly and take the necessary measures quickly. In the study, deep learning methods were applied to determine the disease in tomato leaves. The data set included 18,160 images of tomato leaves, which were divided into 10 classes. GoogleNet, AlexNet, SqueezeNet, ShuffleNet, and ResNet-18 networks, which are pre-trained deep convolutional neural networks (CNN) models, were used to classify images of diseases. In the models, 70% of the training dataset is used for training, 15% for validation, and 15% for testing. Based on the test data of the trained networks, accuracy, precision, specificity, and f-score values were calculated. For AlexNet, GoogleNet, ShuffleNet, SqueezeNet and ResNet-18, the accuracy rates were 93.93%, 95.18%, 94.82%, 94.29% and 81.79%, respectively. A study of pre-trained networks for the classification of tomato leaf diseases showed that GoogleNet was the highest performing model.

**Keywords:** Deep Learning, convolutional neural networks, image classification, tomato plant, disease

## GİRİŞ

Dünyada beş yüz bin den fazla bitki türü olduğu bilinmektedir. Her geçen gün yeni bitki türleri keşfedilirken bazı bitki türleri de yok olmaktadır (Arivazhagan, Shebiah, Ananthi, & Varthini, 2013). Bitki türlerinin korunup gelecek nesillere aktarılabilmesi ekolojik denge açısından oldukça önemlidir. Dünyada değişen iklim koşulları, hava kirliliği, yetiştirme aşamasında bakteri, mantar ve virüs saldırılarına maruz kalma gibi sebeplere bağlı olarak bitkilerde hastalıklar meydana gelmektedir. Günümüzde bitkilerdeki birçok hastalığın tespiti geleneksel yöntemler ile yapılmaktadır (Brahimi, Boukhalfa, & Moussaoui, 2017a). Hastalık belirlemede üretici hastalığı fark edebilir ama tanımlaması zahmetlidir. Bazı durumlarda hastalık tanımını doğru yapsa da hastalığı gidermek için uygulanması gereken yöntem hakkında bilgi sahibi olmayabilir (Ferentinos, 2018; Sannakki, Rajpurohit, Sumira, & Venkatesh, 2013).

Gelişen teknoloji ve yapay zekâ uygulamaları birçok alanda olduğu gibi tarım alanında hastalık tespiti ve bitki türü sınıflandırma çalışmalarında kullanılmaya başlanmıştır (Ferentinos, 2018). Yapay zeka yöntemleri hızlı ve yüksek güvenilirlikle sınıflandırma çalışmaları ile zaman ve iş gücü bakımından tasarruf sağlamaktadır (Arsenovic, Karanovic, Sladojevic, Anderla, & Stefanovic, 2019). Çalışmada domates bitkisinin yapraklarında görülen hastalık sınıflandırma çalışması yapılmıştır. Domates bitkisi subtropikal, tropikal ve ılıman bölgelerde yetişen zengin besin değeri olan bir sebzedir. Birçok kullanım alanı olduğu için geniş bir pazar payına sahiptir. Sağlıklı ve verimli üretim için bakım gerektiren bir sebzedir (Durmuş, Güneş, & Kırcı, 2017; H. Sabrol & K. Satish, 2016). Bu bağlamda veri setinde RGB renkte gerçek yaprak görüntülerinden oluşan 10 farklı sınıfta toplam 18160 görüntü bulunmaktadır (Kaggle, 2021). Çalışmada ön eğitilmiş ESA algoritmalarından GoogleNet, ShuffleNet, SqueezeNet, AlexNet ve ResNet-18 algoritmaları ile hastalık sınıfı belirleme çalışması yapılmıştır. Ön eğitilmiş modellerin başarı performansları değerlendirilmiştir.

### Çalışmanın Önemi;

- Bitki üretiminde verimi etkileyen en önemli faktörlerden biri hastalıktır. Hastalığın geleneksel yöntemlerle tespiti uzun, zaman alıcı, maliyetli ve ek iş gücü gerektiren bir işlemdir.
- Derin öğrenme yöntemleri hastalık tespiti hızlı ve doğru şekilde analiz edilebilmektedir.
- Hastalık tespitinde uzman kişilere ihtiyaç duyulmamaktadır.
- Çalışmada ön eğitilmiş evrişimli sinir ağlarının performans karşılaştırması detaylı olarak incelenmiştir.
- Domates bitkisinin yaprağında görülen hastalık konusunda birçok sınıflandırma çalışması yapılmıştır. Çalışma diğer modellerden yüksek performans göstermesi ve beş farklı ön eğitilmiş model sonuçlarının da kıyaslanması açısından literatüre katkı sağlayacaktır.

Çalışmada ilerleyen bölümlerde konu hakkında literatür araştırması yapılmış, yapılan çalışmalar hakkında araştırma sonuçlarına yer verilmiştir. Materyal ve metot başlığı altında önerilen derin öğrenme modeli, kullanılan veri seti açıklanmış, ön eğitilmiş evrişimsel sinir ağları, performans ölçütleri hakkında bilgi verilmiştir. Bulgular bölümünde çalışmada analizlerden elde edilen deneysel sonuçlara verilmiştir. Tartışma başlığı altında bitki yaprağı sınıflandırma çalışmaları ile yapılan çalışmalarla başarı performansları karşılaştırılmıştır. Ve son olarak sonuçlar bölümünde çalışmadan elde edilen çıkarımlar özetlenmiş ilerideki yapılacak çalışmalardan bahsedilmiştir.

### *Literatür İncelemesi*

Bitki hastalık sınıflandırması konusunda birçok çalışma yapılmıştır. Derin algoritma yöntemleri hızlı ve güvenilir performans göstermesi sebebi ile çalışmalarda tercih edilmektedir. Bitki hastalık sınıflandırma alanında yapılmış çalışmalar, çalışmada kullanılan model, veri seti ve doğruluk sonuçları bu bölümde özetlenmiştir.

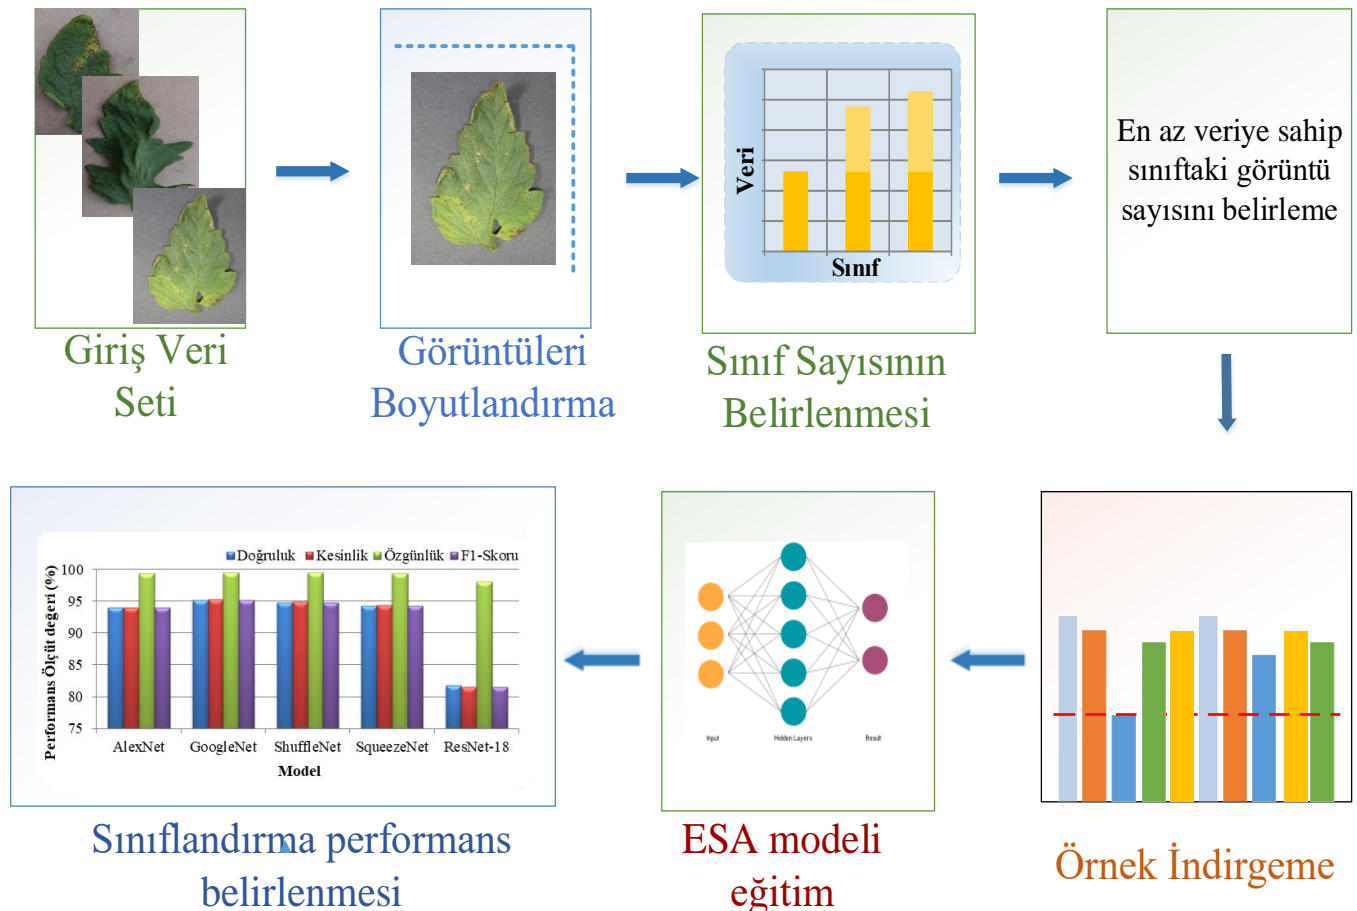
Liu ve diğ. (Liu, Tang, Zhou, Meng, & Dong, 2016) 13.689 görüntüden oluşan 4 sınıflı bir çalışma yapmıştır. Çalışmada AlexNet ve GoogleNet yöntemlerini kullanmış %97,92 doğruluk oranı elde etmiştir. Wang ve diğ. (Wang, Sun, & Wang, 2017) 2086 görüntüden oluşan 4 sınıf için sınıflandırma çalışması yapmıştır. Çalışmada VGG16, VGG19, Inception V3 ve ResNet50 yöntemlerini kullanmış ve %90,42 doğruluk oranı elde etmiştir. Ferentinos (Ferentinos, 2018) 87.848 görüntüden oluşan 58 sınıflı veri setini sınıflandırmıştır. Çalışmada VGGNet yöntemini kullanmış ve %99,53 doğruluk oranı elde etmiştir. Lu, Y. et al.(Liu et al., 2016) %95,48 başarı oranını AlexNet ile elde etmiştir. Çalışmada 500 görüntü ve 10 sınıftan oluşan veri seti kullanılmıştır. Mohanty ve diğ. (Mohanty, Hughes, & Salathé, 2016) AlexNet ve GoogleNet yöntemini kullanmış ve %99,34 başarı oranı elde etmiştir. Çalışmada 38 sınıflı 54.308 görüntüden oluşan veri seti kullanmıştır. Sladojevic ve diğ. (Sladojevic,

Arsenovic, Anderla, Culibrk, & Stefanović, 2016) CaffeNet yöntemini kullanmış ve %96,30 başarı oranı elde etmiştir. Çalışmada 4483 görüntüden oluşan 15 sınıflık veri seti kullanmıştır. Brahimi, M. et al.(Brahimi, Boukhalfa, & Moussaoui, 2017b) AlexNet, DenseNet 169, Inception V3, ResNet 34, SqueezeNet 1.1 ve VGG 13 yöntemlerini kullanmıştır. Çalışmada %99,76 başarı oranı elde ettiği çalışmada 54,323 görüntüden oluşan 38 sınıflı veri setini kullanmıştır. Geetharamani ve diğ. (G & J, 2019) ESA yöntemini kullandığı 38 sınıftan oluşan 54.323 göründen oluşan veri setinde %99,76 doğruluk oranı elde etmiştir. Too ve diğ. (Too, Yujian, Njuki, & Yingchun, 2019) VGG16, Inception-v4, ResNet50, ResNet101, ResNet152 ve DenseNet121 yöntemlerini kullanmıştır. Çalışmada 38 sınıf ve 54.306 görüntüden oluşan veri seti kullanmış ve %99,75 doğruluk oranı elde etmiştir. Arsenovic ve diğ. (Arsenovic et al., 2019) AlexNet, VGG19, Inceptionv3, DenseNet201 ve ResNet152 yöntemlerini kullanmış ve %93,67 doğruluk oranı elde ettiği çalışmada 139.011 ve 42 sınıftan oluşan veri seti kullanmıştır.

Yapılan çalışmalardan incelendiğinde yapılan çalışmaların büyük veri setlerinde yüksek doğruluk oranıyla hastalık tespit ve sınıflandırma çalışması yapılabildiği görülmektedir. Bitkilerde hastalık sınıflandırma konusunda yüksek performans sağlamasından dolayı yapılan bu çalışmada da ön eğitilmiş ESA modelleri tercih edilmiştir.

## MATERYAL VE METOT

Bu çalışmada uygulanan sistemin genel aşamaları Şekil 1’de gösterilmektedir. Çalışmada domates yaprak görüntülerinin bulunduğu 10 sınıflık veri seti kullanılmıştır (Kaggle, 2021). Veri setindeki görüntüler ilk olarak ön işlem aşamasında yeniden boyutlandırılmıştır. Tüm görüntüler eğitim modelinin giriş boyutuna getirilmiştir. Veri etiketlerine göre sınıf sayısı belirlenmiştir. Veri setinde sınıf örneklerini en düşük elemanlı sınıfa göre eşitlemek örnek indirgeme (undersampling) yöntemi kullanılmıştır. Alınan görüntülerin %70’i eğitim, %15’i doğrulama ve %15’i test verisi olarak ayrılmıştır. Eğitim seti ile model eğitilip, modelin hiç görmediği test verileri ile test edilip sınıf etiketi belirlenmiştir.




Şekil 1. Önerilen Derin Öğrenme Metodunun Blok Diyagramı

## Veri Seti

Açık erişim veri tabanında alınan toplam 10 sınıf ve toplam 18.160 domates yaprak görüntüsü bulunmaktadır (Kaggle, 2021) . Veri setinde bulunan her bir sınıfa ait örnek görüntü ve toplam veri setinde her sınıfın yüzdelik oranı sırasıyla Şekil 2 ve Şekil 3'te verilmiştir. Ayrıca her sınıfa ait görüntü sayıları Tablo 1'de belirtilmiştir.



Şekil 2. Veri Setinde Bulunan Her Sınıf İçin Örnek Görüntüler (Kaggle, 2021)



Şekil 3. Veri seti sınıf verilerinin dağılımı (Kaggle, 2021)

Tablo 1. Veri Setinde Bulunan Sınıflara Ait Görüntü Sayısı (Kaggle, 2021)

Sınıf	Görüntü Sayısı	Sınıf	Görüntü Sayısı
Bakteri Lekesi	2127	Mozaik	373
Erken Yanıklık	1000	Septoria Yaprak Lekesi	1771
Sağlıklı	1591	Örümcek Akarları	1676
Geç Yanıklık	1909	Hedef Nokta	1404
Yaprak Kalıbı	952	Sarı Yaprak Kıvrılma	5357

Veri seti bakteri lekesi, mozaik, erken yanıklık, septoria yaprak lekesi, sağlıklı, örümcek akarları, geç yanıklık, hedef nokta, yaprak kalıbı ve sarı yaprak kıvrılma sınıfından oluşmaktadır. Veri setinde bulunan toplam 18160 görüntünün 2127 adeti bakteri lekesi, 1000 adeti erken yanıklık, 1591 adeti sağlıklı, 1909



adeti geç yanıklık, 952 adeti yaprak kalıbı, 373 adeti mozaik, 1771 adeti septoria yaprak lekesi, 1676 adeti örümcek akarı, 1404 adeti hedef nokta ve 5357 adeti sarı yaprak kıvrılma yaprak görüntülerinden oluşmaktadır. Veri setinde her görüntünün yüzdelik olarak dağılımı incelendiğinde en yüksek ondalık değere %29 ile sarı yaprak kıvrılma sınıfından oluşurken en az veriye sahip sınıf %2 ile mozaik sınıfıdır. Çalışmada dengeli veri seti yapabilmek için örnekleme indirgeme işlemi yapılmıştır.

### Ön eğitilmiş ESA Modelleri

Ön eğitilmiş ESA'lar bir milyondan fazla sayıda görüntü üzerinde eğitilmiştir. Ön eğitilmiş ESA'lar yeni veri kümesini kullanarak eğitilip tipik bir sınıflandırma için uyarlanabilir ve ince ayar yapılabilir. Çalışmada AlexNet, GoogleNet, SqueezeNet, ShuffleNet ve ResNet-18 ön eğitilmiş ESA modelleri ile sınıflandırma çalışması yapılmıştır. Bu modellere ait derinlik, parametre sayısı ve giriş görüntü boyutu verileri Tablo 2'de özetlenmiştir (Krizhevsky, 2012; Szegedy, Ioffe, Vanhoucke, & Alemi, 2017; Ucar & Korkmaz, 2020; X. Zhang, Zhou, Lin, & Sun, 2018).

**Tablo 2.** Çalışmada Kullanılan Ön Eğitilmiş Modellere Ait Derinlik, Parametre Sayısı ve Giriş Görüntü Boyutu (Acikgoz, 2022; Atik, 2022a)

Model	Derinlik	Parametre sayısı (Milyon)	Giriş görüntü boyutu
SqueezeNet	18	1.24	227-by-227
GoogleNet	22	7.0	224-by-224
ResNet18	18	11.7	224-by-224
ShuffleNet	50	1.4	224-by-224
AlexNet	8	61.0	227-by-227

Öğrenme parametresinin artması modelin eğitim süresinin uzamasına sebep olur. Örneğin GoogleNet modeli Alexnet'ten 12 kat daha fazla parametre içerir. SqueezeNet mimarisi AlexNet mimarisinden yaklaşık 50 kat daha az parametre sahiptir. Veri setindeki görüntüler modelin giriş boyutuna getirilmelidir (Szegedy et al., 2017; Ucar & Korkmaz, 2020; X. Zhang et al., 2018).

### Performans Ölçüm Metrikleri

Ön eğitilmiş modeller ile eğitilen veri setlerinin doğru sınıflandırma oranını hesaplamak için doğru sınıfa atılan veri bilgisinin elde edilmesi gerekir. Şekil 4'deki gibi hata matrisi oluşturulur. Hata matrisinde tahmin ve gerçek değerlerin gerçek pozitif, gerçek negatif, yanlış negatif ve yanlış pozitif parametreleri verilir. Bu parametre değerlerine göre doğruluk, duyarlılık, kesinlik ve F-skor performans ölçüm metrikleri hesaplanır. Tablo 3'de bu metrikler ve eşitlikleri verilmiştir (Atik, 2022b; Öter, Aydoğan, Kıymık, & Tuncel, 2016; Öztürk & Paksoy, 2018; Ucar & Korkmaz, 2020).

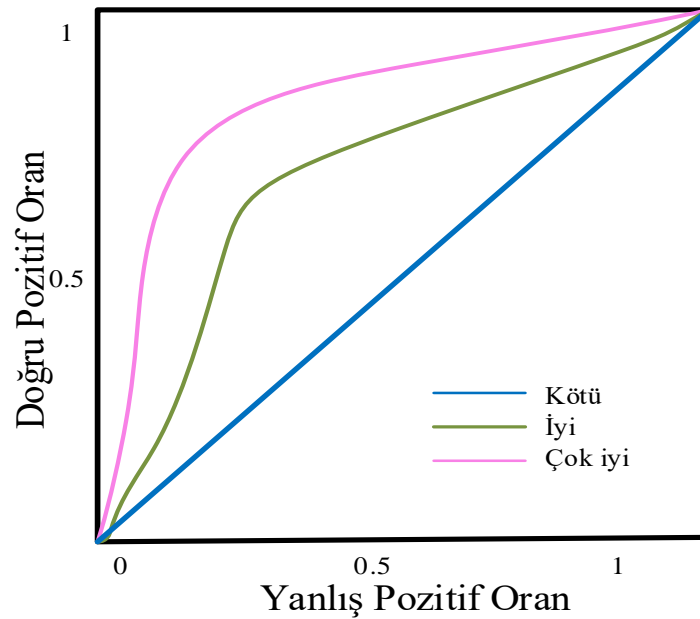
		Tahmin	
		Pozitif	Negatif
Gerçek	Pozitif	Gerçek pozitif (GP)	Yanlış negatif (YN)
	Negatif	Yanlış pozitif (YP)	Gerçek negatif (GN)

**Şekil 4.** Hata Matrisi (Atik, 2022a)

Modelin sınıflandırma performansını değerlendirirken kullanılan ifadelerden biri de ROC (Alıcı işlem karakteristikleri, Receiver Operating Characteristic) eğrisi yöntemidir. ROC eğrisi doğru pozitif oran (duyarlılık) ve yanlış pozitif oran (1-özgüllük) parametrelerinin oranının grafiğidir. ROC puanı 1 (bir) olduğunda, pozitifler negatiflerden mükemmel bir şekilde ayrılmıştır, ROC puanı 0 (sıfır) olduğunda ise herhangi bir pozitif bulunamadığı çıkarımı yapılır. Kötü, iyi ve çok iyi (mükemmel) performans gösteren testlere ait ROC eğrileri Şekil 5'de verilmiştir (Hoo, Candlish, & Teare, 2017).

**Tablo 3.** Sınıflandırma Çalışmasında Kullanılan Performans Ölçüm Metrikleri (Dyrmann, Karstoft, & Midtby, 2016; Krizhevsky, Sutskever, & Hinton, 2012)

Metrik	Eşitlik	Tanım
Doğruluk	$\frac{GP + GN}{GP + YP + YN + GN}$	Doğruluk değeri modelde doğru tahmin edilen değerlerin toplam veri kümesine oranıdır.
Kesinlik	$\frac{GP}{GP + YP}$	Pozitif olarak tahmin edilen değerlerin gerçekten kaç tanesinin pozitif olduğunu göstermektedir.
Duyarlılık	$\frac{GP}{GP + YN}$	Pozitif tahmin etmemiz gereken işlemlerin ne kadarını pozitif olarak tahmin ettiğimizi gösteren metriktir.
Özgüllük	$\frac{GN}{GN + YP}$	Modelin negatif durumları ne kadar iyi tahmin ettiğini gösteren metriktir.
F1-skor	$2 * \frac{Kesinlik * Duyarlılık}{Kesinlik + Duyarlılık}$	Kesinlik ve duyarlılık değerlerinin harmonik ortalamasını göstermektedir.



Şekil 5. Performanslarına Göre Temel ROC Eğrileri (Hoo Et Al., 2017)

ROC eğrisinde mükemmel olan analizde eğri (0,0), (0,1) ve (1,1) noktalarından geçer. Kötü bir olan ROC eğrisi (0,0) dan (1,1) e kadar uzanan köşegen biçimindedir. Analiz sonucu bu iki eğriye göre değerlendirilir (Hoo et al., 2017).

## BULGULAR

Çalışmada domates bitkisi yaprağındaki hastalık türlerinin sınıflandırma çalışması yapılmıştır. Veri tabanında bulunan 10 sınıf ve 18.160 adet yaprak görüntüsünden oluşan veri seri kullanılmıştır. Yaprak görüntülerinin boyutları 256 × 256 piksel iken ön eğitilmiş derin öğrenme algoritmalarında kullanılmak için 224 × 224 ve 227 × 227 boyutlarına getirilmiştir. Veri setinde homojen dağılım sağlanması için en az veriye sahip sınıf mozaik sınıfındaki veri adeti kadar diğer tüm sınıflardan da veri rastgele alınmıştır. Bu görüntülerin %70'i eğitim için %15'i doğrulama ve %15'i test için kullanılmıştır.

Eğitim aşamasında model her iterasyonda eğitilir ve test veri seti ile test edilerek başarı performansı belirlenir. Sürekli test veri seti ile test edilen modelde aşırı uyum (overfitting) durumu gerçekleşebilir. Eğitilen modelin test veri setine aşırı uyumunu engellemek için doğrulama veri seti kullanılmıştır (Atik, 2022a). Kullanılan bilgisayar sisteminde i7-10750 H CPU @2.60 GHz, NVIDIA Quadro P620 GPU, ve 16 GB RAM özelliklerine sahip donanım bulunmaktadır. Uygulama için Matlab R2020a da tanımlı ön eğitilmiş derin öğrenme algoritmaları AlexNet, GoogleNet, ShuffleNet and SqueezeNet ve ResNet-18 kullanılmıştır. ESA modelleri için hiperparametre değerleri Tablo 4’de verilmiştir.

**Tablo 4.** ESA Modellerinde Kullanılan Eğitim Hiperparametreleri

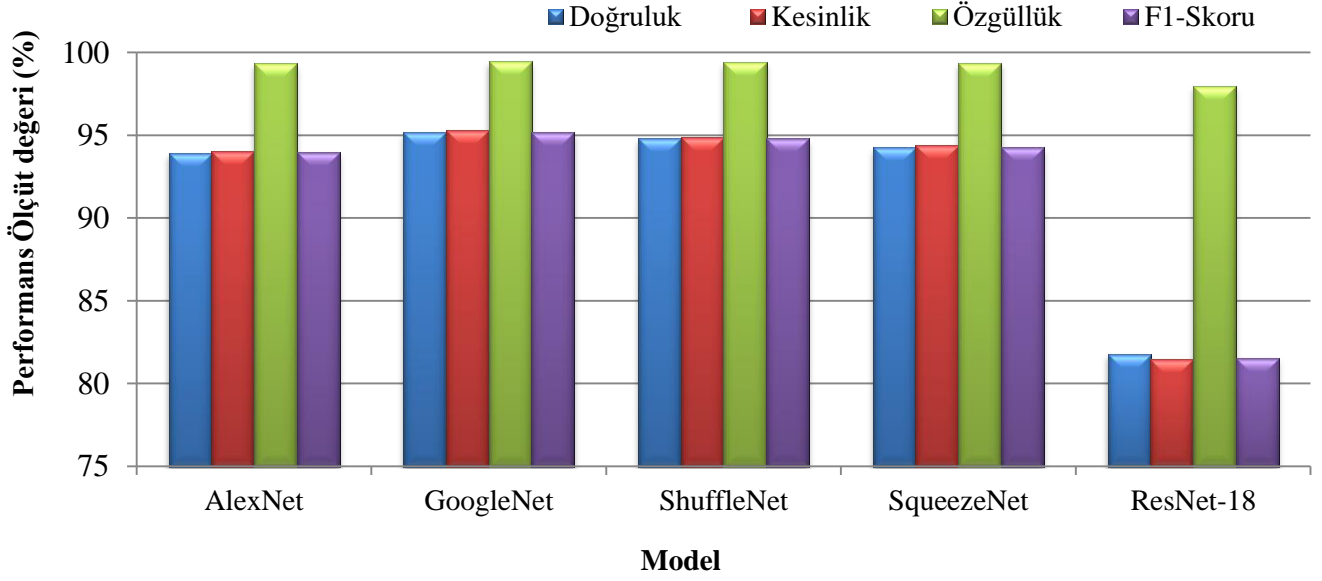
Hiperparametre	Değer
Mini topluluk boyutu	16
Maksimum epoch	50
Başlangıç öğrenme oranı	1e-4
Optimize yöntemi	SGDM

Veri seti ile eğitilen modeller test veri seti ile test edilmiştir. Test analizi sonuçlarına göre elde edilen ön eğitilmiş ESA modellerine ait doğruluk, kesinlik, özgüllük ve F-skor parametre değerleri Tablo 5’de verilmiştir. Her modelin kesinlik, özgüllük ve F-skor parametrelerinin karşılaştırması Şekil 6’da görülmektedir. Analiz sonuçlarına göre, AlexNet, GoogleNet, ShuffleNet, SqueezeNet ve ResNet-18 için doğruluk oranları sırasıyla %93,93, %95,18, %94,82, %94,29 ve %81,79 olarak hesaplanmıştır.

Modellerin kesinlik değerleri incelendiğinde en yüksek performansı %95,29 ile GoogleNet modeli gösterirken en düşük performansı gösteren model %81,49 ile ResNet-18 modeli olmuştur. Özgüllük değerleri AlexNet, GoogleNet, ShuffleNet, SqueezeNet ve ResNet-18 için sırasıyla %99,33, %99,46, %99,42, %99,37 ve %97,98 olarak elde edilmiştir. Son olarak F1 puanı değerlerinde de benzer durum söz konusudur. Modellerin başarı performansına göre yüksekte düşüğe doğru sırasıyla GoogleNet, ShuffleNet, SqueezeNet, AlexNet ve ResNet-18’dir.

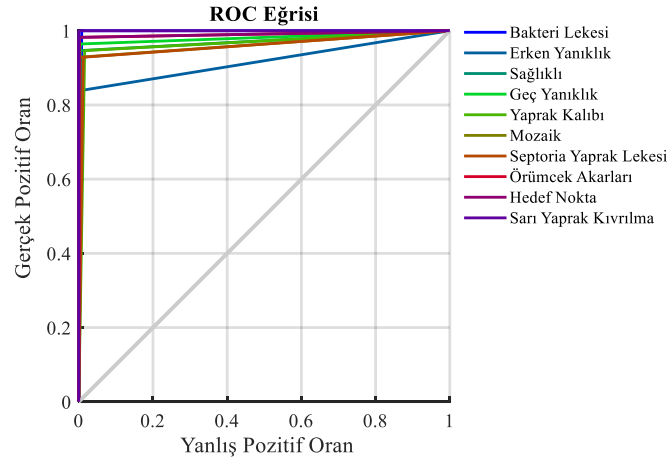
**Tablo 5.** ESA Modelleri Performans Ölçüt Değerleri (%)

Model	Doğruluk	Kesinlik	Özgüllük	F1-Puanı
AlexNet	93,93	94,03	99,33	93,95
GoogleNet	95,18	95,29	99,46	95,17
ShuffleNet	94,82	94,86	99,42	94,79
SqueezeNet	94,29	94,37	99,37	94,29
ResNet-18	81,79	81,49	97,98	81,55



Şekil 6. ESA Modelleri Performans Ölçüt Değerleri Karşılaştırma

Elde edilen sonuçlara göre GoogleNet modeli diğer tüm ESA modellerine göre daha yüksek bir başarı göstermiştir. En iyi performans gösteren model GoogleNet için her sınıfın belirtildiği ROC eğrisi de Şekil 7’de verildiği gibidir. Modelin performansı başarı ölçüt parametrelerinin belirttiği numerik değerlerin yanı sıra ROC eğrisinde de görüldüğü üzere 1’e yakın mükemmel değerlerdir.




Şekil 7. GoogleNet Modeli Analiz Değerleri ROC Eğrisi

Çalışmada en iyi performans gösteren model GoogleNet’in çalışmada kullanılan diğer ön eğitilmiş ESA modellerinden yüzde kaç oranında daha iyi sonuç elde ettiği de çalışmada incelenmiştir. Buna göre GoogleNet modelin performans ölçüt metrikleri doğruluk, kesinlik, özgüllük ve F1-puanı için diğer modellere göre iyileştirme değerleri hesaplanmış Tablo 6’da verilmiştir. Bu bağlamda analiz sonuçları iyileştirme yüzdelerinin karşılaştırması Şekil 8’de verildiği gibidir.




**Tablo 6.** GoogleNet Modelin Diğer ESA Modellere Göre İyileştirme Değerleri (%)

Model	Doğruluk	Kesinlik	Özgüllük	F1-Puanı
AlexNet	1,33	1,33	0,13	1,30
ShuffleNet	0,37	0,45	0,40	0,40
SqueezeNet	0,94	0,97	0,09	0,93
ResNet-18	16,37	16,93	1,51	16,70

**Şekil 8.** GoogleNet Modelin Diğer ESA Modellere Göre İyileştirme Değerleri (%)

Tablo 7'deki numerik değerler ve Şekil 8'deki görsel grafikten görüldüğü üzere başarı performansları iyileştirme değerleri karşılaştırmasında GoogleNet modelin doğruluk değeri AlexNet, ShuffleNet, SqueezeNet ve ResNet-18 için sırasıyla %1,33, %0,37, %0,94 ve %16,37 daha iyidir. Kesinlik değerleri kıyaslamasında GoogleNet modeli AlexNet, ShuffleNet, SqueezeNet ve ResNet-18 için sırasıyla %1,33, %0,45, %0,97 ve %16,93 daha iyi sonuç elde edilmiştir. Analizlerde üstün özellik gösteren GoogleNet mimarisi başlangıç modüllerinden dolayı karmaşık bir yapıya sahiptir. Bu model konvolüsyon ve havuzlama katmalarını üst üste istiflemekten uzaklaşan ilk evrişimli sinir ağı modellerindedir. Model bu sayede bellek kullanımı ve güç kullanımı yönünde avantaj sağlamaktadır. Analiz yapılan veri seti için en iyi sınıflandırma performansı gösteren GoogleNet mimarisi 22 derinlik değeri, 27MB boyut değeri, 7 milyon parametreye sahiptir. Çalışmada ikinci en yüksek performans gösteren ShuffleNet mimarisi 50 derinlik, 5.4MB boyut ve 1.4 milyon parametreye sahiptir. Bu modelin derinlik değeri GoogleNet'ten fazla olmakla beraber parametre sayısı GoogleNet'ten düşüktür. SqueezeNet mimarisi de öğrenme parametre sayısı bakımından GoogleNet'ten düşüktür. AlexNet mimarisinin parametre sayısı GoogleNet'ten fazla olmakla beraber derinlik değeri GoogleNet mimarisinden düşüktür. Modellerin analiz sonuçları her veri seti için farklılık gösterebilir. Modellerin performans karşılaştırmasında eğitim ve test süresi de özellikle büyük ölçekli çalışmalarda önemlidir. Çalışmada kullanılan modellere ait eğitim ve test süreleri Şekil 9'da verilmiştir.

**Şekil 9.** Modellere ait analiz süresi

Şekil 9'dan görüldüğü üzere analiz süreleri AlexNet, SqueezeNet, ShuffleNet, GoogLeNet ve ResNet-18 için sırasıyla 24 dk, 25 dk, 49 dk, 72 dk ve 150 dk olmuştur. Veri setinin boyutu, modellerin derinlik, parametre değerleri, ve analiz yapılan bilgisayarın özelliklerine göre birçok etkene bağlı olarak analiz süresi değişkenlik göstermektedir.

## TARTIŞMA

Çalışmanın bu bölümünde görüntü sınıflandırma alanında yapılan çalışmalar ile önerilen çalışmanın performans karşılaştırmasına yer verilmiştir. Bu bağlamda, bu çalışmalara ait, veri setindeki örnek sayıları, kullanılan veri seti, sınıf sayıları, sınıflandırma başarı oranları göz önüne alınarak bir Tablo 7'de sunulmuştur.

**Tablo 7.** Domates Yaprağı Hastalık Sınıflandırması İle İlgili Yapılan Çalışmalar Ve Başarı Performans Değerleri

Referans	Model/Algoritma	Veri seti	Kullanılan Veri	Başarı performans ölçütü ve elde edilen değer
(Yamamoto, Togami, & Yamaguchi, 2017)	Super-Resolution Convolutional Neural Network (SCRNN)	PlantVillage	Domates yaprağı	Doğruluk değeri yaklaşık ~%90 olarak elde edilmiştir.
(Durmuş et al., 2017)	AlexNet and SqueezeNet v1.1	PlantVillage	Domates yaprağı	Sınıflandırma Doğruluk değeri, AlexNet modeli ile %95,65 olarak elde edilmiştir.
(Fuentes, Yoon, Kim, & Park, 2017)	AlexNet, GoogleNet, VGG-16, ResNet-50,101, ResNetXt-101, Faster RCNN, SSD, R-FCN, ZFNet	Image taken in real fields	Domates yaprağı	Kesinlik değeri ResNet-50 ve Region based Fully Convolutional Network (R-FCN) modeli ile %85,98 olarak elde edilmiştir.
Yapılan çalışma	AlexNet, GoogleNet, ShuffleNet, SqueezeNet ve ResNet-18	PlantVillage	Domates yaprağı	En iyi doğruluk değeri GoogleNet modeli %95,18 olarak elde edilmiştir.

Tabloda domates yaprağı hastalık sınıflandırma çalışmalarının ile bu çalışmada elde edilen başarı performans değeri karşılaştırması verilmiştir. Tablodan da görüldüğü üzere Yamamoto ve ark. SCRNN modeli ile doğruluk değerini yaklaşık %90 olarak elde etmiştir. Durmuş ve ark. Ön eğitilmiş modellerden sadece AlexNet ve SqueezeNet modellerini kullanmıştır. En yüksek doğruluk değerini AlexNet mimarisi ile %95,65 olarak hesaplamıştır. Fuentes ve ark. R-FCN modeli ile doğruluk değeri %85,98 olarak elde edilmiştir. Domates yaprağı sınıflandırma çalışmaları için analizlerde bu çalışmada elde edilen doğruluk değerinin (%95,18) diğer çalışmalardan daha yüksek olduğu görülmektedir. Ayrıca bu çalışmada ön eğitilmiş beş farklı model için analiz karşılaştırma sonuçlarına yer verilmesi daha geniş kıyaslama imkânı sunmaktadır.

## SONUÇLAR

Bu çalışmada, domates yaprağı hastalık görüntülerinin sınıflandırılması için çeşitli derin öğrenme tabanlı sınıflandırma yaklaşımları kullanılmıştır. Çalışmada toplam 10 sınıf ve toplam 18.160 domates yaprak görüntüsü bulunan veri seti kullanılmıştır. Analizlerde ön eğitilmiş derin öğrenme algoritmalarından GoogleNet, ShuffleNet, AlexNet, GoogleNet ve ResNet-18 modelleri kullanılmıştır. Kullanılan modeller içinde en yüksek performans değerine GoogleNet mimarisi ile ulaşılmıştır. GoogleNet modeli ile yapılan sınıflandırma çalışmasında doğruluk, kesinlik, özgüllük ve F1-puanı değerleri sırasıyla %95,18, %95,29, %99,46 ve %95,17 olarak elde edilmiştir. Çalışmada kullanılan diğer modeller içinde ikinci en yüksek başarı gösteren model ShuffleNet modeli olmuştur. ShuffleNet modeli için doğruluk, kesinlik, özgüllük ve F1-puanı değerleri sırasıyla %94,82, %94,86, %99,42 ve %94,79 olarak elde edilmiştir. GoogleNet ve ShuffleNet modellerinden sonra en performans değerleri en yüksekte doğru sırasıyla SqueezeNet, AlexNet ve ResNet-18'dir. Bu modellere ait doğruluk değerleri SqueezeNet için %94,29, AlexNet için %93,93 iken ResNet-18 için %81,79 olarak elde edilmiştir. Model performanslarında görüldüğü üzere en başarılı model GoogleNet iken, en düşük performans gösteren model ResNet-18 modeli olmuştur. İlerleyen çalışmalarda; Yapılan çalışma hastalık tespit çalışmalarının geliştirilmesi bu alandaki en büyük sorunlardan olan verim kaybını önleyecektir. Hastalıkların daha hızlı ve daha kolay şekilde tespit edilmesi zaman ve işgücü bakımından özellikle bu alanda çalışan kişilere büyük kolaylık sağlayacaktır. Sınıflandırma alanında yeni ve az parametreye sahip modellerin geliştirilmesi için çalışmalar yapılacaktır.

## KAYNAKLAR

- Acikgoz, H. (2022). A novel approach based on integration of convolutional neural networks and deep feature selection for short-term solar radiation forecasting. *Applied Energy*, (305). doi:https://doi.org/10.1016/j.apenergy.2021.117912.
- Arivazhagan, S., Shebiah, R. N., Ananthi, S. N., & Varthini, S. V. (2013). Detection of unhealthy region of plant leaves and classification of plant leaf diseases using texture features. *Agricultural Engineering International: The CIGR Journal*, 15, 211–217.
- Arsenovic, M., Karanovic, M., Sladojevic, S., Anderla, A., & Stefanovic, D. (2019). Solving Current Limitations of Deep Learning Based Approaches for Plant Disease Detection. *Symmetry*, 11(7). doi:10.3390/sym11070939
- Atik, I. (2022a). Classification of Electronic Components Based on Convolutional Neural Network Architecture. *Energies*, 15(7). doi:10.3390/en15072347
- Atik, I. (2022b). Performance Comparison of Pre-Trained Convolutional Neural Networks in Flower Image Classification. *Avrupa Bilim ve Teknoloji Dergisi*, (35), 315–321. doi:10.31590/ejosat.1082023
- Brahimi, M., Boukhalfa, K., & Moussaoui, A. (2017a). Deep Learning for Tomato Diseases: Classification and Symptoms Visualization. *Applied Artificial Intelligence*, 31(4), 299–315. doi:10.1080/08839514.2017.1315516
- Durmuş, H., Güneş, E. O., & Kırcı, M. (2017). Disease detection on the leaves of the tomato plants by using deep learning. In *2017 6th International Conference on Agro-Geoinformatics* (pp. 1–5). doi:10.1109/Agro-Geoinformatics.2017.8047016
- Dyrmann, M., Karstoft, H., & Midtby, H. S. (2016). Plant species classification using deep convolutional neural network. *Biosystems Engineering*, 151, 72–80. doi:10.1016/j.biosystemseng.2016.08.024
- Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311–318. doi:https://doi.org/10.1016/j.compag.2018.01.009
- Fuentes, A., Yoon, S., Kim, S. C., & Park, D. S. (2017). A Robust Deep-Learning-Based Detector for Real-Time Tomato Plant Diseases and Pests Recognition. *Sensors*, 17(9). doi:10.3390/s17092022
- G, G., & J, A. P. (2019). Identification of plant leaf diseases using a nine-layer deep convolutional neural network. *Computers & Electrical Engineering*, 76, 323–338. doi:https://doi.org/10.1016/j.compeleceng.2019.04.011
- H. Sabrol, & K. Satish. (2016). Tomato plant disease classification in digital images using classification tree (pp. 1242–1246). Presented at the 2016 International Conference on Communication and Signal Processing (ICCSP). doi:10.1109/ICCSP.2016.7754351
- Hoo, Z. H., Candlish, J., & Teare, D. (2017). What is an ROC curve? *Emergency Medicine Journal*, 34(6), 357–359. doi:10.1136/emermed-2017-206735
- Kaggle. (2021, December 6). Kaggle. *Kaggle data set*. dataset. Retrieved from https://www.kaggle.com/datasets (Erişim tarihi:15.01.2022)
- Krizhevsky, A. (2012). *Convolutional Deep Belief Networks on CIFAR-10*. https://www.cs.toronto.edu/~kriz/conv-cifar10-aug2010.pdf
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25, 1097–1105.
- Liu, Y., Tang, F., Zhou, D., Meng, Y., & Dong, W. (2016). Flower classification via convolutional neural network. In *2016 IEEE International Conference on Functional-Structural Plant Growth Modeling, Simulation, Visualization and Applications (FSPMA)* (pp. 110–116). doi:10.1109/FSPMA.2016.7818296
- Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using Deep Learning for Image-Based Plant Disease Detection. *Frontiers in Plant Science*, 7.
- Öter, A., Aydoğan, O., Kıymık, M., & Tuncel, D. (2016). Tıkayıcı Uyku Apnesinin Yapay Sinir Ağları ve Morfolojik Filtreler kullanılarak Sınıflandırılması İçin Yeni Yöntem. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 19, 52. doi:10.17780/ksujes.74055

- Öztürk, M., & Paksoy, T. (2018). Buğday Tipi Sınıflandırma için Yapay Sinir Ağı Uygulaması: Yeni Bir Yapay Zeka Eğitimi Yazılımı. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 21, 246–257. doi:10.17780/ksujes.332770
- Sannakki, S., Rajpurohit, V. S., Sumira, F., & Venkatesh, H. (2013). A neural network approach for disease forecasting in grapes using weather parameters. In *2013 Fourth International Conference on Computing, Communications and Networking Technologies (ICCCNT)* (pp. 1–5). doi:10.1109/ICCCNT.2013.6726613
- Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D., & Stefanović, D. (2016). Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification. *Computational Intelligence and Neuroscience*, 2016.
- Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. (2017). Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning. *Proceedings of the AAAI Conference on Artificial Intelligence*, 31(1). Retrieved from <https://ojs.aaai.org/index.php/AAAI/article/view/11231>
- Too, E. C., Yujian, L., Njuki, S., & Yingchun, L. (2019). A comparative study of fine-tuning deep learning models for plant disease identification. *Comput. Electron. Agric.*, 161, 272–279.
- Ucar, F., & Korkmaz, D. (2020). COVIDiagnosis-Net: Deep Bayes-SqueezeNet based diagnosis of the coronavirus disease 2019 (COVID-19) from X-ray images. *Medical Hypotheses*, 140, 109761–109761. doi:10.1016/j.mehy.2020.109761
- Wang, G., Sun, Y., & Wang, J. (2017). Automatic Image-Based Plant Disease Severity Estimation Using Deep Learning. *Computational Intelligence and Neuroscience*, 2017, 1–8. doi:10.1155/2017/2917536
- Yamamoto, K., Togami, T., & Yamaguchi, N. (2017). Super-Resolution of Plant Disease Images for the Acceleration of Image-based Phenotyping and Vigor Diagnosis in Agriculture. *Sensors*, 17(11). doi:10.3390/s17112557
- Zhang, S., Huang, W., & Zhng, C. (2019). Three-channel convolutional neural networks for vegetable leaf disease recognition. *Cognitive Systems Research*, 53, 31–41.
- Zhang, X., Zhou, X., Lin, M., & Sun, J. (2018). Shufflenet: An extremely efficient convolutional neural network for mobile devices (pp. 6848–6856). Presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.