

**ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**EVRIŞİMLİ SINIR AĞLARI YÖNTEMLERİNİ KULLANARAK BİTKİ
TOHUM VE FİDELERİNİ SINIFLANDIRMA**

Kaan Çağhan ÖZAYDIN

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**ANKARA
2022**

Her hakkı saklıdır

ÖZET

Yüksek Lisans Tezi

EVİRİŞİMLİ SİNİR AĞLARI YÖNTEMLERİNİ KULLANARAK BİTKİ TOHUM ve FİDELERİNİ SINIFLANDIRMA

Kaan Çağhan ÖZAYDIN

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Recep ERYİĞİT

Dünyada artan nüfus ve sınırlı gıda kaynakları hakkında artan endişelerle birlikte, çağdaş bilgisayar teknolojisinin faydalarının tarım alanlarının verimliliğini artırmak için uygulanması kaçınılmazdır. Günümüzde CNN modelleri, özellikle görüntü sınıflandırma alanında, geleneksel makine öğrenimi yöntemlerinden daha iyi performans göstermektedir. Dolayısıyla, CNN modelleri günden güne daha yaygın olarak kullanılmaktadır. Bu çalışma, tarımsal faaliyetlere katkı sağlamanın yanı sıra, öne çıkan CNN modelleri kullanılarak bitki fide görüntülerinin sınıflandırılmasında en iyi yöntemin ortaya çıkarılması ve çiftçilerin tarım alanında çalışmalarını kolaylaştırmayı amaçlamaktadır. Çeşitli CNN modelleri kullanılarak, Kaggle sınıflandırılmış çevrimiçi veri bilimi platformundan bitki fidelerinin görüntüleri toplandı. Veri setinde 12 farklı bitki fide sınıfı ve 9 farklı tohum sınıfı bulunmakta ve toplam veri örneği sayısı sırasıyla 4750 ve 5285'tir. Modellerin performansını artırmak için hem veri ön işleme hem de veri büyütme uygulanmaktadır. Ayrıca, modellerde ince ayar yapmak için öğrenme oranı düzgün bir şekilde düşürüldü. Model performansını değerlendirmek için ortalama karekök hatası kullanıldı. Görüntülerin arka planlarının büyütülmesi ve kaldırılmasının modellerin performansını önemli ölçüde iyileştirdiği gözlemlenmiştir. Buna göre InceptionResNETv2 modelinin kullanılmasıyla doğruluk değeri yüzde 96,55 olarak elde edilmiştir. Bu sonuç, aynı veri seti üzerinde önceki çalışmalarla karşılaştırıldığında önemli bir gelişmedir. Sonuçlar, bu çalışmanın tarımsal faaliyetleri iyileştireceğini ve çiftçilerin bitki fide ve tohumlarını sınıflandırmasına yardımcı olacağını söylemek için cesaret verici olarak görülmektedir.

Haziran 2022, 66 sayfa

Anahtar Kelimeler: Derin Öğrenme, Evrişimli Sinir Ağları, Görüntü İşleme, Fide ve Tohum Sınıflandırma, Sınıf Aktivasyon Haritaları.

ABSTRACT

M. Sc. THESIS

PLANT SEEDS and SEEDLINGS CLASSIFICATION USING CONVOLUTIONAL NEURAL NETWORK METHODS

Kaan Çağhan ÖZAYDIN

Ankara University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

Supervisor: Doç. Dr. Recep ERYİĞİT

With growing concerns about the increasing population in the world and finite food resources, the application of the benefits of contemporary computing technology to improve the efficiency of agricultural fields is inevitable. CNN models today are outperforming traditional machine learning methods, especially in the image classification area. Consequently, CNN models are being used more and more prevalent day to day. This study, in addition to contributing to agricultural activities, it is aimed to reveal the best method in the classification of plant seedling images by using prominent CNN models and to facilitate the work of farmers in the agricultural field. Using various CNN models, plant seedlings and seeds' images were gathered from the online data science platform Kaggle classified. There are 12 different plant seedlings' classes and 9 different plant seeds' classes in the data set and the total number of data samples are respectively 4750 and 5285. Data preprocessing and data augmentation both are applied to improve the performance of the models. Furthermore, the learning rate was reduced properly to fine-tune the models. Root-mean-square error was used to evaluate the model performance. It is observed that augmentation and removing the backgrounds of the images significantly improved the performance of the models. Accordingly, With the use of the InceptionResNETv2 model, the accuracy value was obtained as 96.55 percent. This result is a significant improvement comparing the previous works on the same dataset. The results are encouraging to say that this work will improve agricultural activities and help farmers classify plant seedlings and plant seeds.

Haziran 2022, 66 sayfa

Key Words: Deep Learning, Convolutional Neural Networks (CNN), Image Processing, Fide ve Plant Seedlings and Seeds Classification, Class Activation Maps.

ÖNSÖZ ve TEŞEKKÜR

Çalışmalarında beni yönlendiren, yardımlarını esirgemeyen, bilgi ve tecrübelerine ihtiyacım olduğunda her daim değerleri zamanını ayıran ve beni aydınlatan danışman hocam sayın Doç. Dr. Recep Eryiğit'e teşekkürü bir borç biliyor ve şükranlarımı sunuyorum. Ayrıca yüksek lisans derslerimde bana çok değerli bilgiler veren ve benim bu projeye başlamam için gerekli temelleri atmamı sağlayan tüm Ankara üniversitesi bilgisayar mühendisliği ana bilim dalı hocalarıma sonsuz teşekkürler.

Kaan Çağhan ÖZAYDIN

Ankara, Haziran 2022

İÇİNDEKİLER

TEZ ONAY SAYFASI

ETİK.....	i
ÖZET.....	ii
ABSTRACT	iii
ÖNSÖZ ve TEŞEKKÜR.....	iv
KISALTMALAR DİZİNİ	vii
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ	x
1. GİRİŞ	1
2. KURAMSAL TEMELLER VE KAYNAK ÖZETLERİ	5
3. MATERYAL VE YÖNTEM	8
3.1 Veri Seti.....	8
3.2 CNN	12
3.2.1 Havuzlama (Pooling) katmanı	13
3.2.2 Aktivasyon katmanı	14
3.2.3 Tam bağlı katman	15
3.2.4 Zarar (Loss) fonksiyonu	15
3.3 Sınıflandırma Problemi	16
3.4 Veri Ön İşleme.....	16
3.5 Veri Temizleme.....	16
3.6 Veri Çoğaltma Yöntemi.....	18
3.7 Optimizasyon	18
3.8 Sonuç Değerlendirme Kriterleri	19
3.8.1 Hata matrisi	19
3.8.2 Doğruluk	20
3.8.3 Belirginlik	20
3.8.4 Hassasiyet.....	21
3.8.5 Duyarlılık	21
3.8.6 F1 skoru	21
3.9 CNN Mimarileri	22
3.9.1 ResNet50.....	22
3.9.2 GoogleNet.....	22

3.9.3 VGG-16	22
3.9.4 InceptionV3.....	23
3.9.5 DenseNet.....	23
3.9.6 MobileNetV2.....	23
3.9.7 NasNet	23
3.9.8 ResNet152V2.....	24
3.9.9 Xception	24
3.9.10 InceptionResNetV2	24
3.10 Hiper Parametreler	25
3.10.1 Yapay sinir ağıları ile bağlantılı parametreler	25
3.10.2 Öğrenme algoritmalarıyla ilgili parametreler.....	25
3.11 Çapraz Doğrulama.....	26
4. ARAŞTIRMA BULGULARI.....	27
4.1 Bitki Fidelerinin Sınıflandırılması.....	27
4.1.1 Xception modeli kullanılarak elde edilen bulgular	27
4.1.2 GoogleNet modeli kullanılarak elde edilen bulgular	29
4.1.3 MobileNetV2 modeli kullanılarak elde edilen bulgular	31
4.1.4 ResNet50 modeli kullanılarak elde edilen bulgular	32
4.1.5 NasNetLarge modeli kullanılarak elde edilen bulgular.....	34
4.1.6 ResNet152V2 modeli kullanılarak elde edilen bulgular	36
4.1.7 DenseNet201 modeli kullanılarak elde edilen bulgular	38
4.1.8 VGG16 modeli kullanılarak elde edilen bulgular	40
4.1.9 InceptionV3 modeli kullanılarak elde edilen bulgular	42
4.1.10 InceptionResNetV2 modeli kullanılarak elde edilen bulgular	44
4.2 Bitki Tohumlarının Sınıflandırılması.....	45
4.2.1 Xception modeli kullanılarak elde edilen bulgular	46
4.2.2 InceptionResNetV2 modeli kullanılarak elde edilen bulgular	47
4.2.3 InceptionV3 modeli kullanılarak elde edilen bulgular	49
5. TARTIŞMA VE SONUÇ	56
5.1 Tartışma	56
5.2 Sonuç	58
KAYNAKLAR	61
ÖZGEÇMİŞ.....	66

KISALTMALAR DİZİNİ

CAM	Sınıf Aktivasyon Haritası
CNN	Evrişimli Sinir Ağları
DL	Derin Öğrenme
FN	False Negative
FP	False Positive
GAP	Global Average Pooling
GMP	Global Max Pooling
HSV	Hue Saturation Value
ILSVRC	ImageNet Large Scale Visual Recognition Challenge
MM	Milimetre
ReLU	Düzeltilmiş Doğrusal Birim
ResNet	Residual Network
RGB	Kırmızı-Yeşil-Mavi
TN	True Negative
TP	True Positive
VGG	Visual Geometry Group

ŞEKİLLER DİZİNİ

Şekil 3.1	Bitki tohum ve fidelerini sınıflandırma yöntemi.....	8
Şekil 3.2	Matplot library kullanılarak verilerin incelenmesi (Bitki tohumları için)....	10
Şekil 3.3	Matplot library kullanılarak verilerin incelenmesi (Bitki fideleri için).....	10
Şekil 3.4	Bitki fidelerini içeren verilerin dağılım grafiği	11
Şekil 3.5	Bitki tohumlarını içeren verilerin dağılım grafiği	11
Şekil 3.6	Havuzlama örnekleri	14
Şekil 3.7	Aktivasyon fonksiyonları (Udofia, 2018).	14
Şekil 3.8	Bitki fide resimlerinin arka planını kaldırma aşamaları.....	17
Şekil 3.9	Bitki tohumlarını içeren veri setinden örnekler.....	17
Şekil 3.10	Bitki tohumlarının arka planlarının kaldırıldıktan sonraki durumları.....	18
Şekil 3.11	Hata Matrisi (Narkhede, 2018).....	19
Şekil 3.12	Inception Resnet V2 modelinin sıkıştırılmış görüntüsü (Elhamraoui, 2020).....	24
Şekil 4.1	Xception modeli ile yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir sayısına (epoch) göre değişimi	28
Şekil 4.2	GoogleNet modeli ile yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir sayısı (epoch) sayısına göre değişimi	29
Şekil 4.3	Xception modeli ile yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir (epoch) sayısına göre değişimi	31
Şekil 4.4	ResNet50 modeli ile yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir (epoch) sayısına göre değişimi	33
Şekil 4.5	NasNetLarge modeli ile yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir (epoch) sayısına göre değişimi	35
Şekil 4.6	ResNet152V2 modeli ile yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir (epoch) sayısına göre değişimi	37
Şekil 4.7	DenseNet201 modeli ile yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir (epoch) sayısına göre değişimi	39
Şekil 4.8	VGG16 modeli ile yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir (epoch) sayısına göre değişimi	41
Şekil 4.9	InceptionV3 modeli ile yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir (epoch) sayısına göre değişimi	43
Şekil 4.10	InceptionResNetV2 modeli ile yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir (epoch) sayısına göre değişimi	44

Şekil 4.11	Xception modeli ile bitki tohumları üzerinde yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir (epoch) sayısına göre değişimi	46
Şekil 4.12	InceptionResnetV2 modeli ile bitki tohumları üzerinde yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir (epoch) sayısına göre değişimi.....	48
Şekil 4.13	InceptionV3 modeli ile bitki tohumları üzerinde yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir (epoch) sayısına göre değişimi	50
Şekil 4.14	Bitki fidelerini sınıflandırma açısından en başarılı sonucu veren InceptionResNetV2 modeli için doğruluk matrisi	52
Şekil 4.15	Bitki tohumlarını sınıflandırma açısından en başarılı sonucu veren InceptionResNetV2 modeli için doğruluk matrisi	53
Şekil 4.16	Bitki tohumlarının sınıf aktivasyon haritaları	54
Şekil 4.17	Bitki fidelerinin sınıf aktivasyon haritaları	54
Şekil 4.18	Bitki fidelerinin sınıflandırılması	55

ÇİZELGELER DİZİNİ

Çizelge 3.1	Bitki fidelerini içeren veri seti	9
Çizelge 3.2	Bitki tohumlarını içeren veri seti	9
Çizelge 4.1	Xception modeli için bitki fide çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi	28
Çizelge 4.2	GoogleNet modeli için bitki fide çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi	30
Çizelge 4.3	MobileNetV2 modeli için bitki fide çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi	32
Çizelge 4.4	ResNet50 modeli için bitki fide çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi	34
Çizelge 4.5	NasNetLarge modeli için bitki fide çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi	36
Çizelge 4.6	ResNet152V2 modeli için bitki fide çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi	38
Çizelge 4.7	DenseNet201 modeli için bitki fide çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi	40
Çizelge 4.8	VGG16 modeli için bitki fide çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi	42
Çizelge 4.9	InceptionV3 modeli için bitki fide çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi	43
Çizelge 4.10	InceptionResNetV2 modeli için itki fide çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi	45
Çizelge 4.11	ResNet152V2 modeli için itki fide çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi	47
Çizelge 4.12	ResNet152V2 modeli için bitki tohum çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi	49

Çizelge 4.13 InceptionV3 modeli için bitki tohum çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi	51
Çizelge 5.1 Bitki fidelerinin CNN modelleriyle sınıflandırılmasından elde edilen bulgular	56
Çizelge 5.2 Bitki fidelerinin CNN modelleriyle sınıflandırılmasından elde edilen bulgular	58



1. GİRİŞ

Bitkiler, çok çeşitli canlı organizmalara besin ve oksijen sağlamaya devam ederken mısır, pirinç ve buğday gibi temel gıdalara erişim eksikliği nedeniyle her gün yaklaşık 700 milyon insan aç kalmaktadır (Anonymous, 2021). Bitki fidelerini ve tohumlarını sınıflandırmak, özellikle çok benzer görünen bitki fideleri ve tohumları için zaman alan ve yoğun çalışma gerektiren bir problemdir. Yabani otlar verim alınması beklenen arazilerde istenmeyen bitkilerdir. Topraktaki mineral ve su kaynaklarını tüketerek, verimliliği azaltmakta ve kaliteyi etkileyerek maddi zarara yol açmaktadır (Rahman vd., 2020). Bu sebeple yabani bitkilerin diğer bitkilerden ayıklanması oldukça önem arz etmektedir.

Tarım, insanın varlığını sürdürmesi için çok önemlidir ve dünya çapında, özellikle az gelişmiş ve gelişmekte olan ekonomilerde, birçok ekonominin temel itici gücü olmaya devam etmektedir (Belal vd., 2019). Tarımın günümüzde hızla büyüme gösteren bir alan olması nedeniyle, aynı cinse ait olan ve cinsler arası dönüşümün sonucu olarak ortaya çıkan ve bu sebeple birbirine oldukça benzeyen çok çeşitli tohumlar insanlığın kullanımına sunulmaktadır (Kaur vd., 2020). Yapacağımız çalışmada geçmişte deneyimlenmiş uygulamalardan da yararlanarak, bitkilerin fide ve tohumlarını evrişimli sinir ağları kullanarak sınıflandırıp yüksek doğruluk değerleri elde edilmeye çalışılacaktır. Bitki tohum ve fidelerinden elde edilen resimler evrişimli sinir ağları yardımıyla analiz edilecek, daha sonra doğruluk, özgüllük ve hassasiyet açısından değerlendirilecektir. Bu çalışma tarımsal üretimi hızlandıracak ve kolaylaştıracak bir yöntem ortaya koymayı esas almaktadır.

Bu problemi çözmek için son yıllarda, bitki türlerinin tanınması, bitki segmentasyonu, tarlalarda su seviyesinin tespiti, tarlalarda yabancı ot tespiti gibi tarımsal faaliyetler için yararlı olabilecek yaklaşımların geliştirilmesinde önemli bir genişleme ve artış gözlemlenmektedir. Ancak, yanlış bir tespit tarımsal üretime çok zarar verebileceğinden önerilen algoritmaların çok hassas olması ve yöntemlerin hata payının minimuma indirilmesini gerekli hale getirmiştir. Tohumların uzman teknisyenler

tarafından sınıflandırılması günümüzde çok zaman almakta ve benzer tohumları ayırt ederken hatalar meydana gelmektedir (Keya vd., 2020).

Geleneksel makine öğrenimi ile karşılaştırıldığında, derin öğrenme büyük veri işleme için daha uygundur. Veri hacminin artmasıyla algoritma performansı artmaktadır. Geleneksel makine öğrenim algoritmalarının aksine, derin öğrenme modelleri özelliklerin yapay olarak belirlenmesine dayalı olmayıp, veri setleri üzerinde doğrudan daha yüksek seviyeli özellikler elde etmeye ve çok sayıda özellik dönüşümü yoluyla derin seviyeli bir makine öğrenimi modeli elde etmeye çalışmaktadır (Goodfellow vd., 2016). Bununla birlikte, CNN'lerin çekici özelliklerine rağmen, hala eksiklikleri olduğu bilinmektedir. Birincisi, çok fazla katman veya ağırlık olduğunda, hesaplama karmaşıklığı ve belleğe binen yük daha yüksektir (Gheisari vd., 2017). İkincisi, daha fazla parametre olduğunda, bırakma, büyütme gibi düzenleme yöntemleri kullanılarak önüne geçilmeye çalışılan bir aşırı uyum tehlikesi vardır. Üçüncüsü, ağ derin olduğunda, hata birçok katmana geri yayılması ile birlikte bozulmaları yok etme sorunu vardır (Ioffe ve Szegedy, 2015).

Son zamanlarda, bitki fide ve tohumların tanımlanması ve sınıflandırılması için klasik teknikler yaygın olarak kullanılmaktadır. Ayrıca, klasik yöntemlerin yerine DL algoritmaları kullanılmaya başlanmıştır. Özelliklerin manuel olarak seçilmesine dayalı olarak geliştirilen modası geçmiş makine öğrenme prosedürlerinin aksine, CNN bir mevcut verilerden kademeli olarak sofistike özellikleri hızlı bir şekilde belirleyebilir. Bu durum problemin daha hızlı ve kolay şekilde çözülmesi için büyük avantaj sağlamaktadır. Dolayısıyla, CNN modelleri daha yaygın olarak kullanılmakta ve birçok soruna yenilikçi çözümler sunmaktadır. Özellikle tarım alanında bitki ve tohum sınıflandırması gibi konularda oldukça başarılı sonuçlar vermektedir (Alimboyong vd., 2019).

Mevcut çalışmada python programlama dili kullanarak derin öğrenmenin bir alt dalı olan evrişimli sinir ağları (CNN) kullanılarak tohum sınıflandırması yapılmıştır. Veriler toplanırken Kaggle.com web sitesinden yararlanılmıştır ve danışman hocam sayın Doç. Dr. Recep ERYİĞİT'in toplamış olduğu verilerden yararlanılmıştır.

Derin öğrenmenin bir alt dalı olan evrimsel sinir ağı yöntemlerini kullanarak bitki tohumlarını sınıflandırmak ve yöntemleri karşılaştırarak en uygun modeli belirlemek amaçlanmaktadır. Daha önce uygulanan geleneksel ve yenilikçi yöntemleri inceleyerek tohum sınıflandırma problemi üzerinde test ederek karşılaştırmalı olarak incelenmesi hedeflenmektedir. Tarımsal alandaki araştırmalar ve teknolojik gelişmelerin ışığında tarımsal üretimin artırılması ve daha verimli hale gelmesini sağlamak hedeflenen unsurlar arasındadır. Bitki tohumlarının CNN modelleriyle sınıflandırılması ile tohum sınıflandırma sürecini hızlandırarak tarımsal faaliyetlerdeki iş yükünü azaltıp zaman tasarrufu sağlanması amaçlanmaktadır.

Kaggle.com'dan alınan bitki fidelerinden oluşan veri seti kaggle platformu tarafından dünya çapında araştırmacıların katıldığı bir sınıflandırma problemi ve meydan okumadır. Bu meydan okumanın amacı bu veri seti üzerinde çalışarak mümkün olan en yüksek doğruluk oranını yakalamaktır. Çalışmamızda bu meydan okuma üzerine yapılan daha önceki çalışmalar göz önünde bulundurularak daha iyi sonuçlar almak amaçlanmış ve bu doğrultuda ilerlenerek oldukça başarılı sonuçlar elde edilmiştir. Ayrıca, kendi oluşturduğumuz bitki tohumlarından oluşan veri seti üzerinde elde edilen başarı oranları tatmin edicidir.

10 ayrı öne çıkan CNN modeli bitki fide ve tohumlarını sınıflandırmak için kullanılacak ve elde edilen sonuçlar incelenip karşılaştırılarak bu problemi çözmek için en iyi model ortaya koyulmaya çalışılacaktır. Modeller karşılaştırılırken “Doğruluk değeri”, “Kayıp değeri”, “Hassasiyet”, “Duyarlılık” ve “F1-Skoru” dikkate alınacaktır. Çalışmamızda modellerden en iyi performans almak için veriler ön işleme tabi tutulmuş olup veri çoğaltma yöntemleri uygulanarak başarı oranları artırılmıştır.

Tezin kalan kısmı 4 ayrı bölümden oluşmaktadır. Giriş bölümünden sonra 2. Bölümde. Konu ile ilgili literatür taraması yapılmıştır. 3. Bölümde tezde bahsedilecek uygulamalarla ilgili temel kavramlar konu edilmiştir 4. Bölümde uygulamada yapılan CNN modellerinin doğruluk, hassasiyet, duyarlılık ve f1-skoru değerleri gösterilmektedir. 5. Bölümde elde edilen bulgular ve sonuçlar üzerinde tartışılacaktır.

Ayrıca, 5. bölümde çalışmanın sonucu ortaya koyulacak ve gelecekte yapılacak işlerden bahsedilecektir.



2. KURAMSAL TEMELLER VE KAYNAK ÖZETLERİ

Jones ve Ejeta (2016) tarım ve bitkilerin yaşamdaki önemini belirtmişlerdir. Özellikle sağlıklı yaşamak için bitkilerin gerekliliğinin altını çizmişlerdir ve çoğu diyetle çeşitliliğin birincil kaynakları olan bakliyat, meyve ve sebzelerin küresel arzının önerilen nüfus düzeyindeki alımları karşılamak için yetersizliğinden bahsetmişlerdir. Aynı zamanda, tarımın sadece insanlara gıda sağlamak için değil hayvan yemlerinde, biyoyakıtta ve endüstriyel bileşenlerde kullanımının çok yaygın olduğu belirtilmiştir.

Pei vd. (2021) yaptıkları çalışmada puslu görüntüler, bulanık görüntüler, balık gözü görüntüleri, sualtı görüntüleri, düşük çözünürlüklü görüntüler, tuz ve biberli görüntüler ve beyaz Gaussian görüntüler gibi çok çeşitli görüntüler üzerinde CNN kullanarak sınıflandırmalar yapmışlardır. Bu çalışmada ön eğitim, veri büyütme ve diğer stratejiler kullanılarak düşük kaliteli görüntü ve videoların tanıma performansının iyileştirilmesi için CNN tabanlı bir yöntem önerilmiştir.

Howard (2014) çalışmasında ImageNet tarafından düzenlenen CNN modelleri kullanılarak belli resimler üzerinde sınıflandırma yaparak mümkün olan en az hata oranının yakalanmasını amaçlayan yarışmayı dikkate almış ve mevcut yöntemlere ek olarak bazı iyileştirmeler ortaya koymuştur. Daha önceki yılda yapılan çalışma referans alınarak %20 iyileşme sağlanmıştır.

Smirnov vd, (2014) çalışmalarında DropOut regülarizasyon işleminin DropConnecte göre daha iyi sonuç verdiğini rapor etmiştir. Daha iyi teknikler kullanılarak ve ağ daha çok büyütülerek sonuçların iyileştirilebileceği ortaya konmuştur.

CNN modelleri günümüzde resim sınıflandırma konusunda en öne çıkan yöntemlerden biridir. Sosyal medya uygulamalarının arkadaş önerisi yapma mekanizması ya da Google'ın resim arama algoritmasının arkasında CNN mimarisi bulunmaktadır (Ergin, 2019). CNN, tıbbi görüntü tanıma (Li vd., 2014), yüz tanıma (Lawrence vd., 1997), kötü amaçlı yazılım algılama (Lo vd., 2019), görüntü sınıflandırma (Sharma, vd., 2018) gibi alanlarda birçok çalışmada kullanılmıştır. Bir evrişimli sinir ağının birincil ilkesi,

tümü ağıın daha önceki katmanlarından daha az soyut bilgilere dayanan kendi kendine öğrenilen özellikler hiyerarşisi geliştirmektir ve bu kendi kendine öğrenilen özellikler, evrişimli sinir ağıının doğal varyasyonlardan daha az etkilenmesini sağlar (Dyrmann vd., 2016). Konvolüsyonel Sinir Ağları, geleneksel makine öğrenme yöntemlerinin yanı sıra diğer derin öğrenme yöntemlerinden daha iyi performans gösterdiğinden, bitki fidelerini sınıflandırmak için en iyi seçeneklerden biri olduğu belirtilmiştir (Elnemr, 2019, Nkemelu vd., 2018, Rahman vd., 2020).

CNN ile resim sınıflandırma konusunda birçok çalışma yapılmıştır. CNN kullanılmasının çok yaygınlaşmasının en temel nedenleri arasında önemli özellikleri otomatik olarak çıkarması ve insan denetimine gerek duymaması olarak belirtilmiştir (Alzubaidi vd, 2021). Jmour vd (2018) yaptıkları çalışmada resimler üzerinden trafik işareti sınıflandırma ve benzeri problemler için en iyi yöntemin CNN olduğunu belirtmiştir.

Önceki çalışmalar, bizim çalışmamızda kullanacağımız veri seti üzerinde K-Nearest-Neighbour ve Support Vector Machine algoritmalarının sırasıyla 56.84 ve 64.47 doğruluğa sahip olduğunu bildirmiştir (Nkemelu vd., 2018). Ayrıca bu çalışma CNN yöntemlerini kullanarak %92,60 doğruluk değeri raporlamıştır. OpenCv kullanarak resimlerin arka planını kaldırarak ilk başta aldıkları %80,21 doğruluk oranını yaklaşık %12 arttırdıklarını belirtmişlerdir.

CNN kullanılarak gerçekleştirilmiş daha önceki çalışmalarda Elnemr, (2019) önerdiği CNN yöntemiyle aynı veri seti üzerinde %94,38 oranında doğruluk değeri rapor etmiştir. Resimleri 128x128 oranında ölçekleyerek sınıflandıran Elnemr (2019) modelde kullanılan filtrelerin tümünün yapısının, her aşamada her bir evrişim katmanı için sırasıyla 32, 64, 128, 256 ve 1024 filtre sayısı ile 3x3 çekirdek boyutunda olduğunu belirtmiştir.

Yalçın ve Razavi (2016) bitki fidelerini CNN kullanarak sınıflandırmıştır. Kendi oluşturdukları 16 ayrı bitki türünden oluşan bir veri seti üzerinde çalışmışlardır. Çalışmada 3 ayrı evrişimli katman kullanılmıştır. Girdi boyutları 227x227x3 olarak belirtilmiştir. Ayrıca, aktivasyon fonksiyonu olarak her bir evrişimli katmandan sonra RELU kullanılmıştır. Ayrıca 2 ayrı havuzlama kullanılmıştır. Başarı oranı %97,47 olarak rapor edilmiştir.


Rahman vd (2020) yaptıkları çalışmada farklı CNN modellerini karşılaştırmalı olarak incelemiştir. Yapılan analizlerde ResNet-50 %96,21, VGG-16 %95,47, DenseNet-121 %92,96 ve LeNet-5 %83,57 doğruluk değerine ulaştığı belirtilmiştir. Yapılan çalışmada veri setindeki resimlerin yeniden boyutlandırıldığı ve değerlerin normalize edildiği rapor edilmiştir. Ayrıca, verileri çoğaltma yöntemi uygulanarak doğruluk değerinin yükseltilmeye çalışıldığı belirtilmiştir.

Bir diğer çalışmada EfficientNetB0 modeli kullanılarak bitki fideleri sınıflandırılmış ve %96,52 doğruluk oranı elde edilmiştir (Makanapura, vd. 2022). Bu çalışmada veri seti eğitim için %70 validasyon ve test için %15 olarak alınmış olup 50 Epoch boyunca model eğitilip validasyonu yapılmıştır. Bu alanda yapılmış en güncel çalışmalardan biri olması sebebiyle elde edilen sonuç referans noktası olarak kabul edilebilir.

Loddo vd. (2021) yaptıkları çalışmada bitki tohumlarını içeren iki ayrı veri seti üzerinde CNN modellerini test etmişlerdir. AlexNet, ResNet18 ve ResNet50 %95'in üzerinde başarı oranlarıyla göze çarpmaktadır. Ayrıca, yapılan çalışmada önerilen ve seedNet olarak isimlendirilen metot yaklaşık %95 doğruluk değerine sahiptir. Diğer veri seti üzerinde en yüksek sonucu veren modeller %97 doğruluk oranıyla ResNet18 ve seedNet olarak raporlanmıştır.

3. MATERYAL VE YÖNTEM

En iyi sonuçları elde etmek için sınıflandırma sürecinde birçok iyileştirme yapıldı. İlk olarak, verileri ön işleme tabi tuttuk. Ardından resimlerden arka planı kaldırdık. Daha sonra veri seti üzerinde veri büyütme işlemi gerçekleştirilmiştir. Ayrıca, modellerin doğruluğunu artırmak için bir optimize edici algoritma seçilmiştir. Son olarak, modelimiz bitki tohum ve fidelerini sınıflandırılmaktadır.



Şekil 3.1 Bitki tohum ve fidelerini sınıflandırma yöntemi

Şekil 3.1’de bitki tohum ve fidelerini sınıflandırma aşamalarını özetlenmektedir. Bu aşamalar detaylı olarak incelenecektir.

3.1 Veri Seti

Eğitim aşamasından başlayarak performans değerlendirmesine kadar görüntü sınıflandırmasının tüm aşamaları için uygun veriler gereklidir. Veriler Kaggle web sitesinden alınmış olup, fide aşamasında olan 12 çeşit bitkiye ait 4.234 benzersiz bitkinin görüntülerinden oluşmaktadır. Mm’ye 10 piksel fiziksel çözünürlük oranına sahip RGB görüntüler içermektedir.

Çizelge 3.1 Bitki fidelerini içeren veri seti


Fide Türü	Veri Sayısı
Siyah Çim	263
Yabani hardal	390
Yoğurt Otu	287
Kuş Otu	611
Buğday	211
Yaban Pazısı	475
Yaygın rüzgâr çimi	654
Mısır	221
Kuru Beybunik	516
Çobançantası	231
Küçük Çiçekli Turnagagası	496
Şeker Pancarı	385
Toplam	4,234

Çizelge 3.1’de bitki fidelerinin türlere göre veri sayısı ve toplam veri adedi gösterilmektedir. Veri seti 12 adet bitki türünden oluşmaktadır. En fazla veriye sahip bitki türü 654 veri ile “Yaygın rüzgâr çimi” olarak görünmektedir. En az veriye sahip bitki türü ise 211 veri ile “Buğday” bitkisidir. Toplam bitki sayısı 4,234’tür. Verilerin %70’i eğitim için kullanılmış olup %15’i validasyon ve %15’i test için kullanılmıştır.

Çizelge 3.2 Bitki tohumlarını içeren veri seti


Tohum Türü	Veri Sayısı
Biber	416
Chenopodium	133
Helianthus Annuus	565
Lepidium Draba	534
Osmancık	1039
Phaseolus Vulgaris	509
Pisum Sativum	564
Vicia Poannica	603
Vicia Villosa	922
Toplam	5,285

Çizelge 3.2’de bitki tohumlarının türlere göre veri sayısı ve toplam veri adedi gösterilmektedir. Veri seti 9 adet bitki türünden oluşmaktadır. En fazla veriye sahip bitki türü 1039 veri ile “Osmancık” olarak görünmektedir. En az veriye sahip bitki türü ise 133 veri ile “Chenepodium” bitkisidir. Toplam bitki sayısı 5,285’tir. Verilerin %70’i eğitim için kullanılmış olup %15’i validasyon ve %15’i test için kullanılmıştır.




Şekil 3.2 Matplot library kullanılarak verilerin incelenmesi (Bitki tohumları için)

Şekil 3.2’de Matplot kütüphanesi kullanılarak bitki tohumlarını içeren veri setinden 4 adet örnek resimin boyutlarını göstermektedir. Verilerin boyutları daha sonrasında modellerin yapısına göre değiştirilmiştir ve bu raporda detaylı bir şekilde belirtilmektedir.




Şekil 3.3 Matplot library kullanılarak verilerin incelenmesi (Bitki fideleri için)

Şekil 3.3’te Matplot kütüphanesi kullanılarak bitki fidelerini içeren veri setinden 4 adet örnek resmin boyutlarını göstermektedir. Resim boyutları her bir model için güncellenmektedir.



Şekil 3.4 Bitki fidelerini içeren verilerin dağılım grafiği

Yukarıdaki 3.4’te veri setinin dağılım grafiği gösterilmiştir. 12 ayrı çeşidin veri setinde eşit dağılmadığı gözlemlenmiştir. Verileri test ederken ve test sonuçlarını yorumlarken verilerin dağılımını göz önünde bulundurmak gerekebileceğinden bu grafik önem arz etmektedir.



Şekil 3.5 Bitki tohumlarını içeren verilerin dağılım grafiği

Şekilde kendi çalışmalarımızla elde ettiğimiz bitki tohumlarını içeren veri setinin bitki türlerine göre dağılımı gösterilmektedir. Veri seti 9 farklı bitki çeşidi içermektedir. En fazla veriyi “Osmancık” isimli bitki tohumundan elde etmekteyiz ve en az veri “chenepodium” isimli bitki türünden gelmektedir. Veri setinin eşit dağılmaması ve birbirinden oldukça farklılık göstermesi verilerin ön işleme ve temizleme aşamalarının önemini daha da arttırmaktadır.

3.2 CNN

Evrişimli sinir ağı, evrişim hesaplama yöntemini içeren ve derin bir yapıya sahip, ileri beslemeli bir sinir ağıdır. Ayrıca, en yaygın kullanılan derin öğrenme algoritmaları arasındadır. Evrişimli sinir ağları görüntü tanıma ve sınıflandırma alanında öne çıkan bir araştırma konusudur. Yerel sensör alanı, ağırlık paylaşımı ve havuzlama katmanı evrişimli sinir ağının temel yapısını oluşturmaktadır (Krizhevsky vd., n.d.). DL, genellikle çok büyük ve çoğu durumda etiketlenmemiş veri setini içeren sinir ağlarını eğitmek için kullanılır. Bununla birlikte, bilgisayarla görme işleri için, derin öğrenmenin bir alt dalı olan CNN (Konvolüsyon sinir ağı), görüntülerin sınıflandırılması için etkili bir yöntem olarak kabul edilir (Andrea vd., 2018).

CNN mimarisi, genel olarak beyin işlevini taklit eden çok katmanlı basit modüller yığıdır. Bu çok katmanlı yapı verileri alır, hesaplar ve sonuçları bir sonraki katmana yönlendirir (Rahman vd., 2020). Görüntü tanıma ve işleme sürecinde, özellik farklılaşması evrişim katmanı aracılığıyla simüle edilir ve görüntü özelliği çıkarma ve verinin yeniden yapılandırmasının karmaşıklığını azaltmak için ağırlık paylaşımı ve havuzlamanın ağ yapısı aracılığıyla ağırlık sayısı azaltılır.

CNN yapısının temel kısmı evrişim katmanıdır (dönüştürme katmanı). Doğada, görüntüler genellikle statiktir. Yani, resmin bir bileşeninin oluşumu, diğer herhangi bir parçanın oluşumu ile aynıdır. CNN yapısı bunun üzerine kuruludur yani bir bölgede öğrenilen bir özellik, başka bir bölgede öğrenilen bir modelle eşleşebilir. Bir resimden küçük bir kesit alınarak resimdeki tüm noktalar bu kesitle karşılaştırmalı olarak taranmaktadır. Herhangi bir konumdan (Çıkış) geçerken alınan kesit tek bir konumda yoğunlaştırılır. Filtreler, bir resmin daha büyük bir resimden (Kernel) geçen küçük bölümleridir. Geri yayılım yaklaşımı daha sonra filtreleri yapılandırmak için kullanılır.

CNN'ler tarımda eşzamanlı olarak esas olarak tanıma ve sınıflandırma görevleri için kullanılır (Kamilaris ve Prenafeta-Boldú, 2018) ve üstün sonuçlar sağladığı kanıtlanmıştır. En yaygın olarak kullanılan Derin öğrenme temelli sinir ağları, Evrişimli Sinir Ağları, Tekrarlayan Sinir Ağları ve Q-öğrenme olarak belirtilebilir ve en popüler

olanı, evrişimli sinir ağıları (CNN veya ConvNet)'dir. Başlangıçta 1980'lerde Kunihiro Fukushima tarafından önerilen CNN, Lecun vd. (2015)'in eserlerinde belirtildiği gibi normalize edilmiş görüntülerle sinir ağına doğrudan girerek özellik çıkarma sürecini dışlamak için geniş bir şekilde tasarlanmış olan ileri beslemeli yapay sinir ağılarıdır. Salido ve Ruiz (2018)'in eserlerinde anlatıldığı gibi derin evrişimli sinir ağıları, ILSVRC-2012'nin büyük ölçekli görüntü sınıflandırma görevinde üstün performans göstermiştir (Russakovsky vd., 2014). CNN modelleri özellik çıkarma yöntemi olarak da kullanılmaktadır. AlexNet, bir görüntü sınıflandırıcısını eğitmek için özellik çıkarıcı olarak önceden eğitilmiş CNN kullanır (Barbedo, 2016).

Bu çalışmada bitki tohum ve fidelerini geleneksel makine öğrenim yöntemlerinden daha iyi sonuç verdiği gözlemlendiği için CNN yöntemleri kullanılarak sınıflandırılmış ve kullanılan CNN yöntemlerinden hangi yöntemin daha iyi sonuç verdiği ortaya konulmuştur.


3.2.1 Havuzlama (Pooling) katmanı

Havuzlama katmanı, yüksek boyutlu girdilerin boyutlarını azaltmak için kullanılan bir katmandır. Karmaşıklığı azaltarak daha sade bir yapı elde etmemizi sağlar. Bu katman kayan pencereler kullanarak verileri sadeleştirir. Havuzlama katlaması modelin öğrenmesi gereken parametre sayısını azaltarak zaman ve kaynak tasarrufu sağlamaktadır. İki çeşit havuzlama katmanı mevcuttur:

Max Pooling: Bu katman, filtre tarafından kapsanan özellik haritasının bölgesinden maksimum öğeyi seçen bir havuzlama işlemidir (GeeksforGeeks, 2022).

Average Pooling: Genel havuzlama, özellik haritasındaki her kanalı tek bir değere indirger.

Her iki havuzlamaya yönelik örnek şekilde gösterilmiştir.



Şekil 3.6 Havuzlama örnekleri

Şekilde görüldüğü gibi alanlardaki en yüksek değerlerin seçilmesi en yüksek havuzlamayı temsil ederken ortalamaların alınarak çerçevelenmesi ortalama havuzlamayı temsil etmektedir.


3.2.2 Aktivasyon katmanı

Aktivasyon fonksiyonu, sinir ağlarının sonuna veya arasına yerleştirilen bir düğümdür. Nöronun ateşlenip ateşlenmeyeceğine karar vermeye yardımcı olurlar.

Activation Functions


Sigmoid

$$\sigma(x) = \frac{1}{1+e^{-x}}$$




tanh

$$\tanh(x)$$




ReLU

$$\max(0, x)$$



Leaky ReLU

$$\max(0.1x, x)$$




Maxout

$$\max(w_1^T x + b_1, w_2^T x + b_2)$$

ELU

$$\begin{cases} x & x \geq 0 \\ \alpha(e^x - 1) & x < 0 \end{cases}$$



Şekil 3.7 Aktivasyon fonksiyonları (Udofia, 2018).

Şekil 3.7’de birçok aktivasyon katmanının mevcut olduğu görülmektedir.

Sigmoid Aktivasyon Fonksiyonu: CNN modelleri kullanılarak yapılan sınıflandırmalarda sıklıkla kullanılmaktadır. Şekil üzerinde görüldüğü gibi girdileri 0 ile 1 arasında çıktılarına çevirir. Derinliği yüksek modellerle yapılan sınıflandırmalarda yeterince iyi sonuç vermemektedir.

Tanjant Hiperbolik Aktivasyon Fonksiyonu: Bu fonksiyon gelen girdileri -1 ile 1 arasında çıktılarına dönüştürür. Sigmoid'e oranla derinliği yüksek modellerde daha iyi sonuçlar verdiği için daha yaygındır ancak şekil üzerinde görülebileceği gibi kaybolan eğim problemi ortaya çıkmaktadır.

ReLU Fonksiyonu: ReLU fonksiyonu aktivasyon fonksiyonları arasında en yaygın olarak kullanılan fonksiyonların başında gelmektedir. Tüm nöronları aynı anda aktifleştirmemesi diğer fonksiyonlara göre avantajlı bir durumdur. Tüm negatif girdileri sıfıra çevirirken nöron aktifleşmez bu sayede işlemlerin daha hızlı gerçekleşmesi sağlanmaktadır. ReLU sonuca tanh ve sigmoid fonksiyonlarına kıyasla sonuca 6 kat daha çok yakınsamaktadır (Udofia, 2018.). ReLU fonksiyonu girdileri 0 ve sonsuz arasındaki çıktılarına çevirmesi sebebiyle doyuma ulaşmayan bir fonksiyon olarak tanımlanır.

3.2.3 Tam bağlı katman

Tam bağlı katman (FC), herbir girdinin tüm nöronlara bağlı olduğu bir yapı üzerinde çalışır. FC yapı katmanları genellikle CNN mimarisinin sonuna doğru bulunur ve sınıf skorları gibi hedefleri optimize etmek için kullanılabilir (A. Amidi ve S. Amidi, 2018.). FC yapı katmanlarına sahip modellerin görüntü sınıflandırmada daha iyi doğruluk ve performans değerleri almayı sağlayacağı belirtilmiştir (Zhang, Luo, Wei ve Wu, 2018).

3.2.4 Zarar (Loss) fonksiyonu

Zarar fonksiyonu yapay sinir ağlarının önemli bileşenlerinden biri olarak öne çıkmaktadır. CNN modelleri tarafından yapılan tahmin için oluşan kayıpları hesaplayan fonksiyon zarar fonksiyonu olarak isimlendirilmektedir. Kayıp değeri gradyanı hesaplamak için kullanılır.

3.3 Sınıflandırma Problemi


Eğitilmiş Öğrenme Yöntemleri genel olarak iki alt kategoriden oluşur. Bunlar; Sınıflandırma (Classification) ve Regresyon (Regression) problemleridir (Büber, 2018). Sınıflandırma yapılmadan önce veri setindeki örnekler ayrı ayrı sınıf bilgileriyle etiketlenmişlerdir. Algoritmanın amacı ise çıktının hangi sınıfa ait olduğu tespit edebilmektir. Elimizdeki veriler sayısal ve veri setindeki örnekler birbirinden farklı sınıflara etiketleniyorsa bu durumda regresyon yöntemleri kullanılır. Bizim çalışmamız bitki tohum ve fidelerini birbirinden ayırt etmek üzerine kurulu olduğu için bir sınıflandırma problemidir.

3.4 Veri Ön İşleme

Resimler her model için ayrı ayrı yeniden boyutlandırıldı. CNN modelleri farklı girdi boyutlarıyla çalıştığı için her model için farklı boyutlandırmalar yapılmıştır. Veriler sınıflarına göre etiketlenerek normalizasyona tabi tutulmuştur.


3.5 Veri Temizleme

Şekil 3.3'te, bitki fidelerinin çok küçük bir tam görüntü ölçeğini kapsadığı ve bu durumun CNN modelleri için görüntüleri sınıflandırmada bazı sorunlara neden olduğu açıkça görülmektedir. Bu sorunu çözmek için görüntülerin arka planları kaldırıldı. Bu yöntemle modellerin doğruluk değerlerinde önemli artışlar gözlemledik.




Şekil 3.8 Bitki fide resimlerinin arka planını kaldırma aşamaları

Şekil 3.8’de resmin arka planını kaldırma süreci adım adım gösterilmiştir. Orijinal resim belli oranlarda bulanıklaştırıldıktan sonra renk, doygunluk ve açıklık değerleri ayarlandı. Sonrasında maskelenerek arka plan ortadan kaldırılmaktadır.



Şekil 3.9 Bitki tohumlarını içeren veri setinden örnekler

Şekil 3.9’da bitki tohumlarını içeren veri setinden örnekler gösterilmektedir. Bazı tohum türleri birbirine oldukça benzerlik göstermekte olup bunların insan gözüyle ayırt edilmesi hata payını arttırmaktadır.



Şekil 3.10 Bitki tohumlarının arka planlarının kaldırıldıktan sonraki durumları

Şekil 3.10’da arka planı kaldırılmış bitki tohumlarının resimleri görünmektedir. Bu aşamada farklı renk ve çeşitlerde bitkiler için farklı arka plan kaldırma işlemleri uygulanmıştır. Böylece modelin gereksiz detaylara odaklanması önlenmiştir.

3.6 Veri Çoğaltma Yöntemi

Modellerin daha fazla öğrenmesine yardımcı olmak ve modellerin doğruluğunu artırmak için veri arttırma yöntemleri uygulandı. Veri büyütme için çeşitli yöntemler uyguladık. Rastgele seçilen eğitim görüntüleri rastgele 180 derece döndürüldü, genişliğin yüzde onu kadar rastgele yakınlıştırıldı, yüksekliğin yüzde onu kadar dikey olarak rastgele kaydırıldı ve dikey ve yatay olarak rastgele çevrildi. Böylece veri havuzu arttırıldı. Hem validasyon doğruluk oranları hemde test doğruluk oranları modeller arası değişkenlik göstermekle birlikte artış gösterdi.

3.7 Optimizasyon

Validasyon doğruluğunu artırmak için bir optimize edici olarak öğrenme hızı azaltma yöntemi uygulandı. Sabır (patience) değeri 3 olarak tanımlandı, böylece 3 epoch için validasyon doğruluğunda herhangi bir iyileştirme olmadığında öğrenme oranı düşürüldü. Öğrenme oranını düşürmenin modelin doğruluğunu önemli ölçüde arttırdığını gözlemledik.

3.8 Sonuç Değerlendirme Kriterleri

Veriler sınıflandırıldıktan sonra modelin ne kadar başarılı olduğunu test etmek için çeşitli yöntem ve kriterler bulunmaktadır. Bu yöntem ve kriterler kullanılarak modeller birbirleriyle kıyaslanabilmekte ve ne kadar başarılı oldukları detaylı analiz edilebilmektedir.

3.8.1 Hata matrisi

Hata matrisi diğer adıyla karışıklık matrisi sınıflandırma problemleri için geliştirilen ML algoritmalarının başarısının görselleştirilebilmesi için kullanılan bir ölçümdür. Bu matris verilerin gerçek durumları ile modelin tahminlerini karşılaştırmamızı sağlayan bir tablo sunmaktadır. Hata matrislerinin satırları gerçek durumları temsil ederken sütunlar ise tahmin edilen değerlere karşılık gelmektedir.

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

Şekil 3.11 Hata Matrisi (Narkhede, 2018).

Hata matrisini oluştururken kullanılan bazı kavramlar vardır:

Doğru pozitif (DP): Modelin doğru tahmin ettiği pozitif verileri ifade etmektedir.

Doğru negatif (DN): Modelin doğru tahmin ettiği negatif verileri ifade etmektedir.

Yanlış pozitif (YP): Gerçekte negatif olan bir verinin model tarafından pozitif olarak tahmin edildiğini belirtmektedir. Böylece negatif örnek yanlış sınıflandırılmış olur.

Yanlış negatif (YN): Gerçekte pozitif olan bir verinin model tarafından negatif olarak tahmin edildiğini belirtmektedir. Böylece pozitif örnek yanlış sınıflandırılmış olur.

3.8.2 Doğruluk

Doğruluk oranını hesaplamak için model tarafından başarılı şekilde sınıflandırılmış örnek sayısı tüm örnek sayısına bölünür. Doğruluk oranı veri setinin dengesiz olduğu durumlarda güvenilirliğini yitirebilmektedir. Örneğin, bir nesnenin kedi olup olmadığını algılayan bir çalışma düşünelim. Eğer gösterilen nesnelerin çoğunluğu kedi değilse o zaman kedi olmadığına yönelik yapılan tahminler çok yüksek bir yüzdeyle doğru çıkacaktır. Dolayısıyla buradaki yüksek doğruluk oranı yüksek başarı anlamına gelmeyecektir.

$$\frac{DP + DN}{DP + DN + YP + YN}$$

3.8.3 Belirginlik

Belirginlik, modelin negatif örnekleri sınıflandırma başarısını temsil etmektedir. Doğru negatif değerinin doğru negatif ve yanlış pozitif değerlerinin toplamına bölünmesiyle elde edilmektedir.

$$\frac{DN}{DN + YP}$$

3.8.4 Hassasiyet

Hassasiyet, doğru pozitif değerin doğru negatif ve yanlış pozitif değerlerinin toplamına bölünmesiyle elde edilmektedir.

$$\frac{DP}{DP + YP}$$

3.8.5 Duyarlılık

Doğru tahmin edilen pozitif örneklerin toplam pozitif örneklere bölünmesiyle hesaplanmaktadır. Modelin pozitif örnekleri sınıflandırma başarısını temsil etmektedir.

$$\frac{DP}{DP + YN}$$

3.8.6 F1 skoru

$$F1 \text{ Skoru} = 2 \times \frac{\text{Hassasiyet} \times \text{Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}}$$

F1 Skoru, hassasiyet ve duyarlılık değerlerinin çarpımlarının toplamına oranının iki katı formülüyle hesaplanmaktadır. Bir başka ifadeyle hassasiyet ve duyarlılık değerlerinin harmonik ortalaması alınarak hesaplanmaktadır.

F1 Skoru formülde görüldüğü gibi hassasiyet ve duyarlılık değerlerinin bir arada değerlendirilmesini sağlamaktadır ve modelleri birbirleriyle karşılaştırmanın en tutarlı yöntemlerinden biridir.

3.9 CNN Mimarileri

3.9.1 ResNet50

Bu mimari, ağa daha fazla karmaşıklık katmayan, aksine basitleştiren kısayol bağlantılarından yararlanır (Rahman vd., 2020). VGGNet'ten esinlenen ResNet (Simonyan ve Zisserman, 2014), Microsoft ekibi tarafından geliştirilmiştir (He vd., 2016) ve ILSVRC 2015'in kazananıdır (Russakovsky vd., 2014b). ResNet50 mimarisinin diğer mimarilere tercih edilmesinin ve ILSVRC 2015'i kazanmasının sebebi daha küçük parametre boyutunu sahip olması ve bunun bir sonucu olarak modelin ve ağırlıkların yüklenmesini ve modelin öğrenme sürecini çok hızlandırmasıdır (Zahisham, Lee ve Lim, 2020). Bu mimariye dair daha ayrıntılı bir genel bakış (He vd., 2016) 'de bulunabilir.

3.9.2 GoogleNet

GoogLeNet Mimarisi, ağ hesaplama kaynaklarının daha iyi kullanılmasına yardımcı olur. İyi hazırlanmış mimarisi, tutarlı bir bilgi işlem bütçesini korurken daha fazla ağ derinliği ve genişliği sağlar (Almawas vd., 2020). GoogLeNet Google Szegedy liderliğindeki ekip tarafından tasarlanmıştır ve ILSVRC 2014'ün galibi olmuştur. GoogLeNet, 22 katmandan oluşan çok daha derin bir ağa sahiptir, ancak AlexNet'ten 12 kat daha az parametre kullanır (Salido ve Ruiz, 2018).

3.9.3 VGG-16

On üç evrişim katmanı, beş havuz katmanı ve üç tamamen bağlantılı katman, bu basit ama etkili mimariyi oluşturur (Rahman vd., 2020). AlexNet mimarisini temel alarak VGG Grup tarafından geliştirilmiştir. Bu model AlexNet'ten farklı olarak çekirdek

boyutlarını sabit tutmaktadır. Bunun yapılmasındaki temel düşünce 11'e 11 ve 5'e 5 boyutndaki çekirdeklerin birden çok 3'e 3'lük çekirdeklerle değiştirilebilmesiydi (Bıçakçı, 2020). VGG Grup tarafından benzer ancak katman sayısı farklı olan VGG19 modeli daha sonra güncelleme olarak ortaya konulmuştur.

3.9.4 InceptionV3

Inception-v3 ağ modeli, düşük yapılandırılmalı bir bilgisayarda eğitilmesi zor olan derin bir sinir ağıdır; eğitilmesi en az birkaç gün sürer ve bu modeldeki son katmandaki çıktı düğümlerinin sayısı, veri kümesindeki kategorilerin sayısına eşittir (Thakallapelli vd., 2016).

3.9.5 DenseNet

DenseNet sistemi, yoğun bloklardan oluşur. Her katmanın girdi olarak önceki seviyelerden bir özellik haritası alması ve sonraki tüm katmanlara girdi olarak kendi özellik haritalarını kullanması gibi benzersiz bir özelliği vardır (Rahman vd., 2020).

3.9.6 MobileNetV2

MobileNetV2, mobil cihazlar için bir CNN mimarisidir (Lawrence ve diğerleri, 1997). MobileNetV2'nin mimarisi, 32 filtreli tamamen evrişimli bir katman ve ardından 19 artık darboğaz katmanı içerir (Sandler, vd., 2018).

3.9.7 NasNet

Nasnet, pekiştirmeli öğrenme yoluyla ince ayarlanmış temel yapı taşlarından (hücreler) oluşan ölçeklenebilir bir CNN mimarisidir (sinir mimarisi araması kullanılarak oluşturulmuştur).

3.9.8 ResNet152V2

ResNet152V2, 83.878.529'u eğitilebilir parametre ve 143.744'ü eğitilemez parametre olmak üzere toplam 84.022.273 parametreye sahiptir (Elshennawy ve Ibrahim, 2020).


3.9.9 Xception

Xception, CNN özellik haritaları içinde tamamen ayrıştırılabilen çapraz kanal ve uzamsal korelasyonlar sağlayan Inception modülüne dayanan bir hipotezdir (Jinsakul vd., 2019).

3.9.10 InceptionResNetV2

55,9 milyon parametreden oluşan bu model, görüntü sınıflandırmasında tatmin edici sonuçlar veren en yeni modellerden biridir.

Inception Resnet V2 Network



Şekil 3.12 Inception Resnet V2 modelinin sıkıştırılmış görüntüsü (Elhamraoui, 2020)

Şekilde Inception ResNet V2 modelinin sıkıştırılmış yapısı görünmektedir. Modelde her katmanda kullanılan fonksiyonlar renklerle birbirinden ayrılarak belirtilmiştir.

3.10 Hiper Parametreler

Hiper parametreler sınırlı hesaplama kaynaklarına sahip olduğumuz için modeli veri seti üzerinde uygularken oldukça kritik bir öneme sahiptir. Hiper parametreler yapay sinir ağlarının yapısını belirleyen değişkenler olup aynı zamanda sinir ağının nasıl eğitilmesi gerektiğini belirlemektedir. Hiper parametreler ağırlık ve bias değerlerini iyileştirmeden önce belirlenmektedir.

3.10.1 Yapay sinir ağları ile bağlantılı parametreler

Regülasyon teknikleri ile gizli katmanlardaki birim sayısı arttıkça doğruluk değerine olumlu katkı sağlayabilmektedir. Katmanlardaki nöron sayılarının az olması yetersiz uyuma (underfitting) sebep olmaktadır. Bırakma (Dropout), aşırı uyumu önlemek ve böylece genelleme gücünü artırmak amacıyla uygulanan bir regülasyon tekniğidir.

3.10.2 Öğrenme algoritmalarıyla ilgili parametreler

Öğrenme Oranı:

Öğrenme oranı bir CNN modelinin parametrelerini ne kadar hızlı değiştireceğini belirtir. Öğrenme oranı ne kadar düşük olursa model o kadar yakınsar ama öğrenme yavaşlar. Öğrenme oranı büyüdükçe, öğrenme hızlanırken yakınsama azalmaktadır (Radhakrishnan, 2017).

Devir (Epoch) Sayısı:

Devir (Epoch) sayısı, eğitim sırasında tüm eğitim verilerinin ağa gösterilme sayısıdır. Eğitim setindeki doğruluk oranı artarken aynı zamanda validasyon setindeki doğruluk oranı artıyorsa devir sayısı arttırılır. Öğrenme oranı artarken validasyon değeri artmadığında devir sayısı daha fazla arttırılmamalıdır. Çalışmamız da kullandığımız devir sayısı 50'dir. Model kararlı hale gelene kadar 20 devir süresince eğitilmektedir ve

daha sonra 30 devir boyunca veriler arttırılarak öğrenme oranı azaltma yöntemi kullanılarak eğitilmektedir.

Küme Büyüklüğü (Batch Size):

Küme büyüklüğü, parametre güncellemesinin gerçekleşmesinden sonra ağı verilen alt numunelerin sayısıdır. Modelin eğitildiği ortamdaki hesaplama gücü ve ram boyutuna bağlıdır. Küme büyüklüğünün artması model üzerinde olumlu etki yaparken hesaplama gücü açısından zorluklar çıkarmaktadır. Çalışmada küme büyüklüğünü 64 olarak tanımlanmaktadır.

3.11 Çapraz Doğrulama

Çapraz doğrulama doğrulama kullanılan modelin bağımsız bir veri seti üzerinde yapılan sınamalar ile nasıl bir sonuç vereceğini ortaya koyan tekniktir. Bu yöntem eğitim ve test veri setlerini birbirlerini tamamlayacak şekilde iki ayrı kümeye ayırır. Kümelerin birisinde analiz yapılarak model oluşturulurken diğesinde model test edilir. Çaprazlanan veriler kullanılarak yapılan test sonuçları birleştirilir ve modelin genel performansı ölçülür. Yaptığımız çalışmada modelimizi test ederken çapraz doğrulama tekniğini kullandık.

4. ARAŞTIRMA BULGULARI

Derin öğrenme kullanılarak 2 ayrı veri seti üzerinde yapılan çalışmalar sonucunda yüksek bir başarı oranıyla tohumlar sınıflandırıldı. Sonuçları incelemek için birçok yöntem kullanıldı. Aşırı uyum gösterme (Overfitting) ya da yetersiz uyum (Underfitting) problemlerinin olup olmadığı birçok farklı yöntemle test edildi. Modelin doğruluk oranı ve kayıp oranı ayrı ayrı gözlemlendi. Tüm veri kümesini bir sinir ağından geçirmek yeterli değildir ve tam veri kümesini aynı sinir ağına birçok kez geçirmemiz gerekiyor. Ancak, sınırlı bir veri kümesi kullandığımızı ve yinelemeli bir süreç olan Gradient Descent kullandığımız öğrenmeyi ve grafiği optimize etmek için kullandığımızı unutmayın. Bu nedenle, ağırlıkların tek geçiş veya bir devir (epoch) ile güncellenmesi yeterli olmamaktadır.


Araştırma sonuçları göstermektedir ki devir (epoch) sayısı arttıkça başarı oranında ciddi bir artış gözlemleniyor. Model kayıp değeri de devir (epoch) sayısı arttıkça düşüyor. Eğitim ve test çizgilerinin birbirine yakın seyretmesi modelin Aşırı uyum (overfitting) göstermediğini gösteriyor.

4.1 Bitki Fidelerinin Sınıflandırılması

Bitki fidelerini sınıflandırmak için CNN modelleri kullanılmıştır. 10 farklı CNN modeli ile sınıflandırma yapılmıştır. Modellerin birbirinden farklı alanlarda avantajları ve dezavantajları tablo ve grafiklerle sunulacaktır.

4.1.1 Xception modeli kullanılarak elde edilen bulgular

Xception modeli kullanılarak yaptığımız sınıflandırmada eğitim doğruluğu %99,94 olarak hesaplanmıştır. Validasyon doğruluğu ise %95,71 olarak bulunmuştur. Test verileri üzerinde ise doğruluk değeri %95,11 olarak göze çarpmaktadır.



Şekil 4.1 Xception modeli ile yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir sayısına (epoch) göre değişimi

Şekil 4.1’de modelin kararlı hale geldikten sonraki eğitim ve validasyon doğruluk ve kayıp değerlerinin devir sayısı (epoch) arttıkça gösterdiği değişim gösterilmektedir. Eğitim doğruluğu arttıkça validasyon doğruluğu da ona yaklaşmaktadır. Kayıp değeri de eğitim veri seti üzerinde azaldıkça validasyon veri seti üzerinde de azalarak kararlı hale gelmektedir.

Çizelge 4.1 Xception modeli için bitki fide çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi

Bitki Çeşidi	Hassasiyet	Duyarlılık	F1 Skoru	Destek
Siyah Çim	0.71	0.66	0.68	59
Yabani hardal	1.00	0.99	0.99	94
Yoğurt Otu	0.96	0.98	0.97	66
Kuş Otu	0.99	0.99	0.99	150
Buğday	0.77	0.98	0.86	55
Yaban Pazısı	1.00	0.99	1.00	123
Yaygın Rüzgâr Çimi	0.90	0.87	0.89	158
Mısır	0.96	1.00	0.98	52
Kuru Beybunik	0.99	0.96	0.98	142
Çobançantası	0.97	0.98	0.97	58
Küçük Çiçekli Turnagagası	1.00	0.97	0.98	130
Şeker Pancarı	0.98	0.98	0.98	101
Makro Ortalama	0.94	0.95	0.94	1188
Ağırlıklı Ortalama	0.95	0.95	0.95	1188

Çizelge 4.1’de bitki fidelerinden oluşan veri seti üzerinde her bir bitki çeşidi için test verilerinin hassasiyet, hatırlatma, F1 Skoru değerlerinin oranları verilmektedir. Tablonun en alt kısmında ise bitki türlerinin ağırlıklarına göre yapılan ortalama değerler ve ağırlıkları dikkate alınmadan verilen ortalama değerler hesaplanmıştır. Siyah çim en çok hatalı sınıflandırılan bitki fidesi olarak göze çarpmaktadır. Yabani hardal ise en başarılı sınıflandırılan bitki türü olarak öne çıkmaktadır.

4.1.2 GoogleNet modeli kullanılarak elde edilen bulgular

GoogleNet’in en temel modeli kullanılarak elde edilen sonuçlara göre eğitim veri setinde %76,33 doğruluk değeri elde edilmiştir. Validasyon veri seti üzerinde ise %69,95 oranında doğruluk değeri elde edilmiştir. Test veri setinde ise %75,84 değerinde bir doğruluk ortaya çıkmaktadır.



Şekil 4.2 GoogleNet modeli ile yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir sayısı (epoch) sayısına göre değişimi

Şekil 4.2’de görüleceği üzere model kararlı hale geldikten sonra yapılan gözlemlerde devir sayısı (epoch) sayısı arttıkça eğitim ve validasyon doğruluk değerleri birlikte artış göstermektedir. Bunun yanısıra, kayıp değerlerini incelediğimizde eğitim veri seti üzerindeki kayıp değerleri azalırken validasyon verileri üzerindeki kayıp değerleri de benzer şekilde azalma eğilimindedir.


Çizelge 4.2 GoogleNet modeli için bitki fide çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi

Bitki Çeşidi	Hassasiyet	Duyarlılık	F1 Skoru	Destek
Siyah Çim	0.30	0.08	0.13	36
Yabani hardal	0.77	0.98	0.86	52
Yoğurt Otu	1.00	0.78	0.88	36
Kuş Otu	0.83	0.95	0.88	95
Buğday	0.89	0.57	0.70	28
Yaban Pazısı	0.95	0.71	0.81	78
Yaygın Rüzgâr Çimi	0.61	0.95	0.74	94
Mısır	0.88	0.81	0.84	36
Kuru Beybunik	0.69	0.74	0.71	81
Çobançantası	0.95	0.49	0.64	39
Küçük Çiçekli Turnagagası	0.91	0.98	0.94	81
Şeker Pancarı	0.92	0.84	0.88	57
Makro Ortalama	0.81	0.74	0.75	713
Ağırlıklı Ortalama	0.80	0.80	0.78	713

Çizelge 4.2’de görüldüğü gibi “Siyah Çim” bitkisi GoogleNet modeliyle sınıflandırılırken oldukça düşük hassasiyet, hatırlatma ve F1 skoru değerlerine sahiptir. Hassasiyet değerlerinde en başarılı olduğu bitki “Yoğurt Otu” olarak göze çarpmaktadır. Hatırlatma değerleri açısından en başarılı sınıflandırılan bitkiler “Küçük Çiçekli Turnagagası” ve “Yabani Hardal” olarak öne çıkmaktadır. F1 skoru açısından değerlendirdiğimizde en başarılı sınıflandırılan bitki türü “Küçük Çiçekli Turnagagası” olarak öne çıkmaktadır.

4.1.3 MobileNetV2 modeli kullanılarak elde edilen bulgular

MobileNetV2 modeli kullanılarak yapılan sınıflandırma sonucunda eğitim veri seti üzerindeki doğruluk değeri %99,49 olarak gözlemlenmektedir. Validasyon veri seti üzerindeki en yüksek doğruluk değeri ise %93,10 olarak elde edilmiştir. Test verileri üzerinde yapılan sınıflandırmada ise doğruluk değeri %90,15 olarak hesaplanmıştır.



Şekil 4.3 Xception modeli ile yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir (epoch) sayısına göre değişimi

Şekil 4.3'te görüleceği gibi model kararlı hale geldikten sonra MobileNetV2 modeli eğitim veri seti üzerinde çok yüksek doğruluk verilerine ulaşmaktadır. Ancak, validasyon doğruluğu eğitim doğruluğuna oranla çok daha az artmaktadır. Kayıp değerleri içinde benzer bir durum söz konusudur. Eğitim veri setinde kayıp kararlı hale geldikten sonra 0'a yakinken validasyon verileri üzerinde yavaşça azalım göstermektedir.


Çizelge 4.3 MobileNetV2 modeli için bitki fide çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi

Bitki Çeşidi	Hassasiyet	Duyarlılık	F1 Skoru	Destek
Siyah Çim	0.53	0.61	0.57	59
Yabani hardal	0.88	0.99	0.93	94
Yoğurt Otu	0.82	0.95	0.88	66
Kuş Otu	1.00	0.89	0.94	150
Buğday	0.76	0.98	0.86	55
Yaban Pazısı	0.98	1.00	0.99	123
Yaygın Rüzgâr Çimi	0.90	0.78	0.83	158
Mısır	0.93	0.96	0.94	52
Kuru Beybunik	0.98	0.87	0.92	142
Çobançantası	0.96	0.84	0.90	58
Küçük Çiçekli Turnagagası	1.00	0.97	0.98	130
Şeker Pancarı	0.86	0.97	0.91	101
Makro Ortalama	0.88	0.90	0.89	1188
Ağırlıklı Ortalama	0.91	0.90	0.90	1188

Çizelge 4.3'te gözlemlendiği üzere en düşük Hassasiyet, Duyarlılık ve F1 Skoru değerine sahip bitki “Siyah Çim” olarak tespit edilmektedir. “Yaban Pazısı”, “Küçük Çiçekli Turnagagası” bitkileri en başarılı sınıflandırılan bitkiler olarak gözlemlenmektedir.

4.1.4 ResNet50 modeli kullanılarak elde edilen bulgular

ResNet50 modeli kullanılarak yapılan sınıflandırmada eğitim veri seti üzerinde %99,49 oranında doğruluk değeri elde edilmiştir. Validasyon verileri üzerinde yapılan sınıflandırmada ise doğruluk değeri %93,52 olarak gözlemlenmektedir. Test veri seti kullanılarak yapılan sınıflandırmada doğruluk değeri %91,83 olarak gözlemlenmektedir.



Şekil 4.4 ResNet50 modeli ile yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir (epoch) sayısına göre değişimi

Şekilde 4.4'te görülebileceği gibi eğitim doğruluğu arttıkça validasyon doğruluğu da artmaktadır ve bir noktada hem eğitim hem de validasyon doğruluğu sabitlenmektedir. Benzer durum kayıp değerleri içinde gözlemlenmektedir. Eğitim verilerini sınıflandırırken kayıp değeri devir sayısı (epoch) arttıkça azalım gösterirken validasyon verilerini sınıflandırırken ki kayıp değerleri de inişli çıkışlı bazı aralıklar dışında azalım göstermektedir.


Çizelge 4.4 ResNet50 modeli için bitki fide çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi

Bitki Çeşidi	Hassasiyet	Duyarlılık	F1 Skoru	Destek
Siyah Çim	0.51	0.51	0.51	59
Yabani hardal	0.98	0.98	0.98	94
Yoğurt Otu	0.88	1.00	0.94	66
Kuş Otu	0.97	0.97	0.97	150
Buğday	0.81	0.98	0.89	55
Yaban Pazısı	0.99	0.98	0.98	123
Yaygın Rüzgâr Çimi	0.85	0.82	0.84	158
Mısır	0.89	0.98	0.94	52
Kuru Beybunik	0.99	0.89	0.94	142
Çobançantası	0.96	0.91	0.94	58
Küçük Çiçekli Turnagagası	0.99	0.96	0.98	130
Şeker Pancarı	0.95	0.98	0.97	101
Makro Ortalama	0.90	0.91	0.90	1188
Ağırlıklı Ortalama	0.92	0.92	0.92	1188

Çizelge 4.4’te görüleceği üzere ResNet50 modeli ile sınıflandırılan bitki fideleri arasında en başarılı sınıflandırılan bitkiler “Yabani Hardal”, “Küçük Çiçekli Turnagagası” ve “Yaban Pazısı” olarak öne çıkmaktadır. “Siyah Çim” bitkisi ise en başarısız sınıflandırılan bitki olarak gözlemlenmektedir.

4.1.5 NasNetLarge modeli kullanılarak elde edilen bulgular

NasNetLarge modeli kullanılarak yapılan sınıflandırmada eğitim veri seti üzerinde %98,34 oranında doğruluk değeri elde edilmiştir. Validasyon verileri üzerinde yapılan sınıflandırmada ise doğruluk değeri %91,33 olarak gözlemlenmektedir. Test veri seti kullanılarak yapılan sınıflandırmada doğruluk değeri %90,15 olarak gözlemlenmektedir.



Şekil 4.5 NasNetLarge modeli ile yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir (epoch) sayısına göre değişimi

NasNetLarge modeli ile sınıflandırma yaparken model kararlı hale geldikten sonra eğitim doğruluğunun çok hızlı artış gösterdiği gözlemlenmekteyken validasyon doğruluğu inişli çıkışlı bir seyir izlemektedir ancak yavaş yavaş artış gözlemlenmektedir. Kayıp değerlerinin devir (epoch) sayısına göre değişimini gördüğümüz diğer grafikte de yine eğitim verileri üzerinde kayıp çok hızlı düşerek 0 yaklaşırken validasyon aşamasındaki kayıp oranları yavaş yavaş azalmaktadır.


Çizelge 4.5 NasNetLarge modeli için bitki fide çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi

Bitki Çeşidi	Hassasiyet	Duyarlılık	F1 Skoru	Destek
Siyah Çim	0.61	0.32	0.42	59
Yabani hardal	0.90	0.96	0.93	94
Yoğurt Otu	0.90	0.86	0.88	66
Kuş Otu	0.95	0.95	0.95	150
Buğday	0.87	0.96	0.91	55
Yaban Pazısı	0.90	0.98	0.94	123
Yaygın Rüzgâr Çimi	0.82	0.93	0.87	158
Mısır	0.82	0.94	0.87	52
Kuru Beybunik	0.98	0.95	0.96	142
Çobançantası	1.00	0.76	0.86	58
Küçük Çiçekli Turnagagası	1.00	0.89	0.94	130
Şeker Pancarı	0.89	0.96	0.92	101
Makro Ortalama	0.89	0.87	0.87	1188
Ağırlıklı Ortalama	0.90	0.90	0.90	1188

Çizelge 4.5’te görüleceği üzere NasNetLarge modeli ile sınıflandırılan bitki fideleri arasında en başarılı sınıflandırılan bitkiler “Yabani Hardal”, “Küçük Çiçekli Turnagagası” ve “Yaban Pazısı” olarak öne çıkmaktadır. “Siyah Çim” bitkisi ise en başarısız sınıflandırılan bitki olarak gözlemlenmektedir.

4.1.6 ResNet152V2 modeli kullanılarak elde edilen bulgular

ResNet152V2 modeli kullanılarak yapılan sınıflandırmada eğitim veri seti üzerinde %99,63 oranında doğruluk değeri elde edilmiştir. Validasyon verileri üzerinde yapılan sınıflandırmada ise doğruluk değeri %94,44 olarak gözlemlenmektedir. Test veri seti kullanılarak yapılan sınıflandırmada doğruluk değeri %90,99 olarak gözlemlenmektedir.



Şekil 4.6 ResNet152V2 modeli ile yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir (epoch) sayısına göre değişimi

ResNet152V2 modeli ile sınıflandırma yaparken model kararlı hale geldikten sonra eğitim doğruluğunu artış gösterdikçe validasyon doğruluğu inişli çıkışlı bir seyir izlemektedir ancak yavaş yavaş artarak eğitim doğruluğuna yaklaşmaktadır. Kayıp değerlerinin devir (epoch) sayısına göre değişimini gördüğümüz diğer grafikte de yine eğitim verileri üzerinde kayıp çok hızlı düşerek 0 yaklaşırken validasyon aşamasındaki kayıp oranları yavaş yavaş azalmaktadır.


Çizelge 4.6 ResNet152V2 modeli için bitki fide çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi

Bitki Çeşidi	Hassasiyet	Duyarlılık	F1 Skoru	Destek
Siyah Çim	0.47	0.68	0.55	59
Yabani hardal	0.97	0.98	0.97	94
Yoğurt Otu	0.93	0.97	0.95	66
Kuş Otu	0.90	0.99	0.94	150
Buğday	0.84	0.89	0.87	55
Yaban Pazısı	1.00	0.95	0.97	123
Yaygın Rüzgâr Çimi	0.88	0.75	0.81	158
Mısır	0.94	0.96	0.95	52
Kuru Beybunik	0.99	0.88	0.93	142
Çobançantası	0.95	0.91	0.93	58
Küçük Çiçekli Turnagagası	0.99	0.97	0.98	130
Şeker Pancarı	0.97	0.97	0.97	101
Makro Ortalama	0.90	0.91	0.90	1188
Ağırlıklı Ortalama	0.92	0.91	0.91	1188

Çizelge 4.6’da görüleceği üzere ResNet152V2 modeli ile sınıflandırılan bitki fideleri arasında en başarılı sınıflandırılan bitkiler “Yabani Hardal”, “Küçük Çiçekli Turnagagası”, “Yaban Pazısı” ve “Şeker Pancarı” olarak öne çıkmaktadır. “Siyah Çim” bitkisi ise en başarısız sınıflandırılan bitki olarak gözlemlenmektedir. Makro ortalama değerleri “Hassasiyet” açısından %90, “Duyarlılık” açısından %91 ve “F1 Skoru” %90 olarak gözlemlenmektedir. Ağırlıklı ortalama değerleri “Hassasiyet” için %92, “Hatırlatma” için %91 ve “F1 Skoru” %91 olarak gözlemlenmektedir.

4.1.7 DenseNet201 modeli kullanılarak elde edilen bulgular

DenseNet201 modeli kullanılarak yapılan sınıflandırmada eğitim veri seti üzerinde %99,97 oranında doğruluk değeri elde edilmiştir. Validasyon verileri üzerinde yapılan sınıflandırmada ise doğruluk değeri %95,20 olarak gözlemlenmektedir. Test veri seti kullanılarak yapılan sınıflandırmada doğruluk değeri %90,99 olarak gözlemlenmektedir.



Şekil 4.7 DenseNet201 modeli ile yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir (epoch) sayısına göre değişimi

Şekilde gözlemlenebileceği gibi DenseNet201 modeli ile sınıflandırma yaparken model kararlı hale geldikten sonra eğitim doğruluğunu artış gösterdikçe validasyon doğruluğu inişli çıkışlı bir seyir izlemektedir ancak yavaş yavaş artarak eğitim doğruluğuna yaklaşmaktadır. Kayıp değerlerinin devir (epoch) sayısına göre değişimini gördüğümüz diğer grafikte de yine eğitim verileri üzerinde kayıp çok hızlı düşerek 0 yaklaşırken validasyon aşamasındaki kayıp oranları hızlı bir azalma gösterdikten sonra yavaş yavaş azalmaya devam ederek kararlı hale gelmektedir.


Çizelge 4.7 DenseNet201 modeli için bitki fide çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi

Bitki Çeşidi	Hassasiyet	Duyarlılık	F1 Skoru	Destek
Siyah Çim	0.44	0.75	0.55	59
Yabani hardal	0.97	1.00	0.98	94
Yoğurt Otu	0.97	0.95	0.96	66
Kuş Otu	0.95	0.99	0.97	150
Buğday	0.79	0.96	0.87	55
Yaban Pazısı	0.99	0.98	0.99	123
Yaygın Rüzgâr Çimi	0.92	0.65	0.76	158
Mısır	0.89	0.98	0.94	52
Kuru Beybunik	0.96	0.91	0.93	142
Çobançantası	0.98	0.86	0.92	58
Küçük Çiçekli Turnagagası	1.00	0.97	0.98	130
Şeker Pancarı	0.98	0.98	0.98	101
Makro Ortalama	0.90	0.92	0.90	1188
Ağırlıklı Ortalama	0.93	0.91	0.91	1188

Çizelge 4.7’de görüleceği üzere DenseNet201 modeli ile sınıflandırılan bitki fideleri arasında en başarılı sınıflandırılan bitkiler “Yabani Hardal”, “Küçük Çiçekli Turnagagası”, “Yaban Pazısı” ve “Yabani Hardal” olarak öne çıkmaktadır. “Siyah Çim” bitkisi ise en başarısız sınıflandırılan bitki olarak gözlemlenmektedir. Makro ortalama değerleri “Hassasiyet” açısından %90, “Duyarlılık” açısından %92 ve “F1 Skoru” %90 olarak gözlemlenmektedir. Ağırlıklı ortalama değerleri “Hassasiyet” için %93, “Hatırlatma” için %91 ve “F1 Skoru” %91 olarak gözlemlenmektedir.

4.1.8 VGG16 modeli kullanılarak elde edilen bulgular

VGG16 modeli kullanılarak yapılan sınıflandırmada eğitim veri seti üzerinde %97,15 oranında doğruluk değeri elde edilmiştir. Validasyon verileri üzerinde yapılan sınıflandırmada ise doğruluk değeri %88,64 olarak gözlemlenmektedir. Test veri seti kullanılarak yapılan sınıflandırmada doğruluk değeri %88,63 olarak gözlemlenmektedir.



Şekil 4.8 VGG16 modeli ile yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir (epoch) sayısına göre değişimi

Şekil 4.8’de gözlemlenebileceği gibi VGG16 modeli ile sınıflandırma yaparken model kararlı hale geldikten sonra eğitim doğruluğu ve validasyon doğruluğu birbirine yakın oranlarla artış göstermektedir. Kayıp değerlerinin devir (epoch) sayısına göre değişimini gördüğümüz diğer grafikte 7. Ve 11. Epoch’lar arasında validasyon kaybı dalgalanarak yükselmektedir. Daha sonra tekrar azalarak eğitim kaybı ve validasyon kaybı yakın seyretmektedir.


Çizelge 4.8 VGG16 modeli için bitki fide çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi

Bitki Çeşidi	Hassasiyet	Duyarlılık	F1 Skoru	Destek
Siyah Çim	0.46	0.31	0.37	59
Yabani hardal	0.89	0.96	0.92	94
Yoğurt Otu	0.97	0.94	0.96	69
Kuş Otu	0.95	0.97	0.96	150
Buğday	0.84	0.81	0.82	57
Yaban Pazısı	0.95	0.90	0.92	125
Yaygın Rüzgâr Çimi	0.78	0.89	0.83	168
Mısır	0.91	0.94	0.92	52
Kuru Beybunik	0.90	0.86	0.88	131
Çobançantası	0.88	0.97	0.93	71
Küçük Çiçekli Turnagagası	0.98	0.96	0.97	122
Şeker Pancarı	0.92	0.88	0.90	90
Makro Ortalama	0.87	0.87	0.87	1188
Ağırlıklı Ortalama	0.88	0.89	0.88	1188

Çizelge 4.8’de görüleceği üzere DenseNet201 modeli ile sınıflandırılan bitki fideleri arasında en başarılı sınıflandırılan bitkiler “Yoğurt Otu”, “Küçük Çiçekli Turnagagası”, ve “Kuş Otu” olarak öne çıkmaktadır. “Siyah Çim” bitkisi ise en başarısız sınıflandırılan bitki olarak gözlemlenmektedir. Makro ortalama değerleri “Hassasiyet” açısından %87, “Duyarlılık” açısından %87 ve “F1 Skoru” %87 olarak gözlemlenmektedir. Ağırlıklı ortalama değerleri “Hassasiyet” için %88, “Hatırlatma” için %89 ve “F1 Skoru” %88 olarak gözlemlenmektedir.

4.1.9 InceptionV3 modeli kullanılarak elde edilen bulgular

InceptionV3 modeli kullanılarak yapılan sınıflandırmada eğitim veri seti üzerinde %99,60 oranında doğruluk değeri elde edilmiştir. Validasyon verileri üzerinde yapılan sınıflandırmada ise doğruluk değeri %94,70 olarak gözlemlenmektedir. Test veri seti kullanılarak yapılan sınıflandırmada doğruluk değeri %94,61 olarak gözlemlenmektedir.



Şekil 4.9 InceptionV3 modeli ile yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir (epoch) sayısına göre değişimi

Şekil 4.9’da gözlemlenebileceği gibi InceptionV3 modeli ile sınıflandırma yaparken model kararlı hale geldikten sonra eğitim doğruluğunu artış gösterdikçe validasyon doğruluğu inişli çıkışlı bir seyir izlemektedir ancak yavaş yavaş artarak eğitim doğruluğuna yaklaşmaktadır. Kayıp değerlerinin devir (epoch) sayısına göre değişimini gördüğümüz diğer grafikte de yine eğitim verileri üzerinde kayıp çok hızlı düşerek 0 yaklaşıırken validasyon aşamasındaki kayıp oranları 5. ve 10. devir sayısı (epoch) değerleri arasında büyük bir dalgalanma gösterdikten sonra yavaş yavaş azalmaya devam ederek kararlı hale gelmektedir.


Çizelge 4.9 InceptionV3 modeli için bitki fide çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi

Bitki Çeşidi	Hassasiyet	Duyarlılık	F1 Skoru	Destek
Siyah Çim	0.58	0.64	0.61	59
Yabani hardal	0.98	1.00	0.99	94
Yoğurt Otu	0.97	0.98	0.98	66
Kuş otu	0.99	0.99	0.99	150
Buğday	0.83	0.91	0.87	55
Yaban pazısı	0.99	1.00	1.00	123
Yaygın rüzgâr çimi	0.90	0.85	0.87	158
Mısır	0.96	0.98	0.97	52
Kuru Beybunik	0.99	0.98	0.98	142
Çobançantası	1.00	0.93	0.96	58
Küçük Çiçekli Turnagagası	1.00	0.99	1.00	130
Şeker Pancarı	0.99	0.98	0.99	101
Makro Ortalama	0.93	0.94	0.93	1188
Ağırlıklı Ortalama	0.95	0.95	0.95	1188

Çizelge 4.9’da görüleceği üzere InceptionV3 modeli ile sınıflandırılan bitki fideleri arasında en başarılı sınıflandırılan bitkiler “Yaban Pazısı”, “Yabani Hardal”, ve “Küçük Çiçekli Turnagagası” olarak öne çıkmaktadır. “Siyah Çim” bitkisi ise en başarısız sınıflandırılan bitki olarak gözlemlenmektedir. Makro ortalama değerleri “Hassasiyet” açısından %93, “Duyarlılık” açısından %94 ve “F1 Skoru” %93 olarak gözlemlenmektedir. Ağırlıklı ortalama değerleri “Hassasiyet” için %95, “Hatırlatma” için %95 ve “F1 Skoru” %95 olarak gözlemlenmektedir.

4.1.10 InceptionResNetV2 modeli kullanılarak elde edilen bulgular

InceptionResNetV2 modeli kullanılarak yapılan sınıflandırmada eğitim veri seti üzerinde %99,80 oranında doğruluk değeri elde edilmiştir. Validasyon verileri üzerinde yapılan sınıflandırmada ise doğruluk değeri %96,55 olarak gözlemlenmektedir. Test veri seti kullanılarak yapılan sınıflandırmada doğruluk değeri %96,54 olarak gözlemlenmektedir.



Şekil 4.10 InceptionResNetV2 modeli ile yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir (epoch) sayısına göre değişimi

Şekil 4.10’da gözlemlenebileceği gibi InceptionResNetV2 modeli ile sınıflandırma yaparken model kararlı hale geldikten sonra eğitim ve validasyon doğruluğu paralel bir seyir izlemektedir. Kayıp değerlerinin devir (epoch) sayısına göre değişimini gördüğümüz diğer grafikte de yine eğitim verileri üzerinde kayıp çok hızlı düşerek 0 yaklaşırken validasyon kayıp değeride hızla düşerek 0’a yaklaşmaktadır.

Çizelge 4.10 InceptionResNetV2 modeli için itki fide çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi

Bitki Çeşidi	Hassasiyet	Duyarlılık	F1 Skoru	Destek
Siyah Çim	0.86	0.61	0.71	59
Yabani hardal	1.00	0.98	0.99	94
Yoğurt Otu	1.00	1.00	1.00	66
Kuş otu	0.99	0.99	0.99	150
Buğday	0.86	1.00	0.92	55
Yaban pazısı	1.00	1.00	1.00	123
Yaygın rüzgâr çimi	0.90	0.96	0.93	158
Mısır	0.95	1.00	0.97	52
Kuru Beybunik	0.96	0.99	0.97	142
Çobançantası	1.00	0.95	0.97	58
Küçük Çiçekli Turnagagası	1.00	0.99	1.00	130
Şeker Pancarı	1.00	0.98	0.99	101
Makro Ortalama	0.96	0.95	0.95	1188
Ağırlıklı Ortalama	0.97	0.97	0.96	1188

Çizelge 4.10’da görüleceği üzere InceptionV3 modeli ile sınıflandırılan bitki fideleri arasında en başarılı sınıflandırılan bitkiler “Yaban Pazısı”, “Yabani Hardal”, ve “Küçük Çiçekli Turnagagası” olarak öne çıkmaktadır. “Siyah Çim” bitkisi ise en başarısız sınıflandırılan bitki olarak gözlemlenmektedir. Makro ortalama değerleri “Hassasiyet” açısından %93, “Duyarlılık” açısından %94 ve “F1 Skoru” %93 olarak gözlemlenmektedir. Ağırlıklı ortalama değerleri “Hassasiyet” için %95, “Hatırlatma” için %95 ve “F1 Skoru” %95 olarak gözlemlenmektedir.


4.2 Bitki Tohumlarının Sınıflandırılması

Bitki tohumlarını sınıflandırmak için CNN modelleri kullanılmıştır. Bitki fidelerini sınıflandırırken kullandığımız 10 farklı CNN modelinden önce çıkan 3 modeli bitki tohumlarını içeren veri setimiz için temel olarak kullandık. InceptionResNetV2, Xception ve InceptionV3 modelleri fideleri sınıflandırırken en iyi sonuçları verdikleri için tohum sınıflandırmasında kullanacağımız 3 model olarak seçilmiştir. Modellerin

birbirinden farklı alanlarda avantajları ve dezavantajları tablo ve grafiklerle sunulacaktır ve tartışma bölümünde değerlendirilecektir.

4.2.1 Xception modeli kullanılarak elde edilen bulgular

Xception modeli kullanılarak yapılan sınıflandırmada eğitim veri seti üzerinde %99,89 oranında doğruluk değeri elde edilmiştir. Validasyon verileri üzerinde yapılan sınıflandırmada ise doğruluk değeri %98,16 olarak gözlemlenmektedir. Test veri seti kullanılarak yapılan sınıflandırmada doğruluk değeri %97,22 olarak gözlemlenmektedir.



Şekil 4.11 Xception modeli ile bitki tohumları üzerinde yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir (epoch) sayısına göre değişimi

Şekil 4.11’de gözlemlenebileceği gibi Xception modeli ile sınıflandırma yaparken model kararlı hale geldikten sonra eğitim doğruluğu %100’e yakın olarak gözlemlenmektedir ve devir (epoch) sayısı arttıkça artış gösterdikçe daha da yaklaşmaktadır. Validasyon doğruluğu ise inişli çıkışlı bir seyir izlemektedir ancak yavaş yavaş artarak eğitim doğruluğuna yaklaşmakta ve kararlı hale gelmektedir. Kayıp değerlerinin devir (epoch) sayısına göre değişimini gördüğümüz diğer grafikte de yine eğitim verileri üzerinde kayıp çok hızlı düşerek 0 yaklaşıırken validasyon aşamasındaki kayıp oranları hızlı bir azalma gösterdikten sonra bazı aralıklarda dalgalanmaktadır ancak daha sonra yavaş yavaş azalmaya devam ederek kararlı hale gelmektedir.


Çizelge 4.11 ResNet152V2 modeli için itki fide çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi

Bitki Çeşidi	Hassasiyet	Duyarlılık	F1 Skoru	Destek
Biber	1.00	1.00	1.00	128
HelianthusAnnuus	0.99	0.99	0.99	155
LepidiumDraba	1.00	1.00	1.00	150
PhaseolusVulgaris	0.99	0.99	0.99	169
PisumSativum	1.00	1.00	1.00	170
ViciaPoannnica	0.99	0.75	0.85	161
VicioVillosa	0.88	1.00	0.93	296
chenepodium	1.00	1.00	1.00	37
Osmancık	1.00	1.00	1.00	320
Makro Ortalama	0.98	0.97	0.97	1586
Ağırlıklı Ortalama	0.98	0.97	0.97	1586

Çizelge 4.11’de görüleceği üzere Xception modeli ile sınıflandırılan bitki tohumları arasında en başarılı sınıflandırılan bitkiler “Biber”, “LepidiumDraba”, ve “PisumSativum” olarak öne çıkmaktadır. “VicioVillosa” bitkisi ise en başarısız sınıflandırılan bitki olarak gözlemlenmektedir. Makro ortalama değerleri “Hassasiyet” açısından %87, “Duyarlılık” açısından %87 ve “F1 Skoru” %87 olarak gözlemlenmektedir. Ağırlıklı ortalama değerleri “Hassasiyet” için %88, “Hatırlatma” için %89 ve “F1 Skoru” %88 olarak gözlemlenmektedir.

4.2.2 InceptionResNetV2 modeli kullanılarak elde edilen bulgular

InceptionResNetV2 modeli kullanılarak yapılan sınıflandırmada eğitim veri seti üzerinde %99,66 oranında doğruluk değeri elde edilmiştir. Validasyon verileri üzerinde yapılan sınıflandırmada ise doğruluk değeri %97,46 olarak gözlemlenmektedir. Test veri seti kullanılarak yapılan sınıflandırmada doğruluk değeri %97,54 olarak gözlemlenmektedir.



Şekil 4.12 InceptionResnetV2 modeli ile bitki tohumları üzerinde yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir (epoch) sayısına göre değişimi

Şekil 4.12’de gözlemlenebileceği gibi InceptionResNetV2 modeli ile sınıflandırma yaparken model kararlı hale geldikten sonra eğitim doğruluğu %100’e yakın olarak gözlemlenmektedir ve devir (epoch) sayısı arttıkça artış gösterdikçe küçük dalgalanmalar yaşansa da kararlı hale gelmektedir. Validasyon doğruluğu ise inişli çıkışlı bir seyir izlemektedir ancak yavaş yavaş artarak eğitim doğruluğuna yaklaşmakta ve kararlı hale gelmektedir. Kayıp değerlerinin devir (epoch) sayısına göre değişimini gördüğümüz diğer grafikte de yine eğitim verileri üzerinde kayıp çok hızlı düşerek 0’a yaklaşırken validasyon aşamasındaki kayıp değerleri ilk 10 devir (epoch) boyunca büyük dalgalanmalar göstermektedir. Daha sonraki aşamalarda 0’a yaklaşarak eğitim kayıp değerine yaklaşmaktadır.


Çizelge 4.12 ResNet152V2 modeli için bitki tohum çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi

Bitki Çeşidi	Hassasiyet	Duyarlılık	F1 Skoru	Destek
Biber	0.92	1.00	0.96	128
HelianthusAnnuus	0.97	0.99	0.98	155
LepidiumDraba	0.99	1.00	1.00	150
PhaseolusVulgaris	1.00	0.97	0.98	169
PisumSativum	0.99	1.00	1.00	170
ViciaPoannnica	0.94	0.92	0.93	161
VicioVillosa	0.96	0.93	0.95	296
chenepodium	1.00	1.00	1.00	37
Osmancık	1.00	1.00	1.00	320
Makro Ortalama	0.98	0.98	0.98	1586
Ağırlıklı Ortalama	0.98	0.98	0.98	1586

Çizelge 4.12 görüleceği üzere InceptionResNetV2 modeli ile sınıflandırılan bitki tohumları arasında en başarılı sınıflandırılan bitkiler “Chenepodium”, ve “Osmancık” olarak öne çıkmaktadır. “VicioVillosa” ve “ViciaPoannnica” bitkileri ise en başarısız sınıflandırılan bitkiler olarak gözlemlenmektedir. Makro ortalama değerleri “Hassasiyet” açısından %98, “Duyarlılık” açısından %98 ve “F1 Skoru” %98 olarak gözlemlenmektedir. Ağırlıklı ortalama değerleri “Hassasiyet” için %98, “Hatırlatma” için %98 ve “F1 Skoru” %98 olarak gözlemlenmektedir.

4.2.3 InceptionV3 modeli kullanılarak elde edilen bulgular

Xception modeli kullanılarak yapılan sınıflandırmada eğitim veri seti üzerinde %100 oranında doğruluk değeri elde edilmiştir. Validasyon verileri üzerinde yapılan sınıflandırmada ise doğruluk değeri %98,05 olarak gözlemlenmektedir. Test veri seti kullanılarak yapılan sınıflandırmada doğruluk değeri %95,96 olarak gözlemlenmektedir




Şekil 4.13 InceptionV3 modeli ile bitki tohumları üzerinde yapılan sınıflandırma için eğitim ve validasyon doğruluğu ve kayıp değerlerinin devir (epoch) sayısına göre değişimi

Şekil 4.13'te gözlemlenebileceği gibi InceptionV3 modeli ile sınıflandırma yaparken model kararlı hale geldikten sonra eğitim doğruluğu yavaş yavaş artarak %100'e yaklaşmaktadır. Validasyon doğruluğu devir (epoch) sayısı arttıkça ilk 5 devir (epoch) boyunca dalgalanmalar yaşansa da daha sonra istikrarlı bir artış göstermektedir. Kayıp değerlerinin devir (epoch) sayısına göre değişimini gördüğümüz diğer grafikte de yine eğitim verileri üzerinde kayıp çok hızlı düşerek 0'a yaklaşırken validasyon aşamasındaki kayıp değerleri 4. ve 6. Epoch'lar arasında büyük dalgalanmalar göstermektedir. Daha sonraki aşamalarda 0'a yaklaşarak eğitim kayıp değerine yaklaşmaktadır.

Çizelge 4.13 InceptionV3 modeli için bitki tohum çeşitlerine göre hassasiyet, duyarlılık ve f1 skoru değerleri ile makro ve ağırlıklı ortalama değerlerinin gösterimi


Bitki Çeşidi	Hassasiyet	Duyarlılık	F1 Skoru	Destek
Biber	1.00	0.99	1.00	128
HelianthusAnnuus	0.88	0.99	0.93	155
LepidiumDraba	1.00	1.00	1.00	150
PhaseolusVulgaris	1.00	0.82	0.90	169
PisumSativum	0.95	1.00	0.97	170
ViciaPoannnica	0.92	0.88	0.90	161
VicioVillosa	0.93	0.96	0.94	296
chenepodium	1.00	1.00	1.00	37
Osmancık	1.00	1.00	1.00	320
Makro Ortalama	0.96	0.96	0.96	1586
Ağırlıklı Ortalama	0.96	0.96	0.96	1586

Çizelge 4.13'te görüleceği üzere InceptionResNetV2 modeli ile sınıflandırılan bitki tohumları arasında en başarılı sınıflandırılan bitkiler “Chenepodium”, “Osmancık” ve LepidiumDraba olarak öne çıkmaktadır. “VicioVillosa” ve “ViciaPoannnica” bitkileri ise en başarısız sınıflandırılan bitkiler olarak gözlemlenmektedir. Makro ortalama değerleri “Hassasiyet” açısından %96, “Duyarlılık” açısından %96 ve “F1 Skoru” %96 olarak gözlemlenmektedir. Ağırlıklı ortalama değerleri “Hassasiyet” için %96, “Hatırlatma” için %96 ve “F1 Skoru” %96 olarak gözlemlenmektedir.



Şekil 4.14 Bitki fidelerini sınıflandırma açısından en başarılı sonucu veren InceptionResNetV2 modeli için doğruluk matrisi

2. veri seti için yapılan uygulama da ortaya çıkan karışıklık matrisi Şekil 4.13'teki gibi ortaya çıkmaktadır. Matrisin diyagonali boyunca doğru sınıflanan yani tahmin edilen değerle gerçek değerin kesiştiği ve denk olduğu veri sayılarını bitki türlerine göre gözlemliyoruz. InceptionResNetV2 sınıflandırmada bir hayli başarılı görünmektedir.




Şekil 4.15 Bitki tohumlarını sınıflandırma açısından en başarılı sonucu veren InceptionResNetV2 modeli için doğruluk matrisi

Şekilde 4.15'te 9 adet bitki tohumunu InceptionResNetV2 modeliyle sınıflandırdıktan sonra oluşan doğruluk matrisi gösterilmektedir. Bitki tohumları çok yüksek başarı oranlarıyla sınıflandırıldığı için diyagonal dışında kalan çok az veri görünmektedir.

CAM (Class Activation Map):


CNN'lerde küresel ortalama havuzlamayı (GAP) kullanarak sınıf aktivasyon haritaları oluşturmak için çeşitli teknikler bulunmaktadır. Belirli bir kategori için bir sınıf etkinleştirme haritası, CNN tarafından o kategoriyi tanımlamak için kullanılan ayırmacı görüntü bölgelerini gösterir. Global Ortalama Havuzlama katmanı (GAP), Oquab ve benzerlerinde kullanılan Global MaxPooling Katmanı (GMP) yerine tercih edilir, çünkü GAP katmanları, nesnenin tam bir boyutunu tanımlayan GMP katmanı ile karşılaştırıldığında tam kapsamını belirlemeye yardımcı olmaktadır. Bunun nedeni, GAP'ta, tüm ayırt edici bölgeleri bulmaya yardımcı olan tüm aktivasyon boyunca bir

ortalama alırken, GMP katmanı sadece en ayırıcı bölgeyi dikkate almaktadır. Sınıf aktivasyon haritaları, CNN tarafından verilen tahmin kararını yorumlamak için kullanılabilir.



Şekil 4.16 Bitki tohumlarının sınıf aktivasyon haritaları


Uygulama sonuçlarını test için yapılan bir diğer testte sınıf aktivasyon haritasının çıkarılmasıdır. Şekil 4.16'da görülebileceği üzere uygulama oldukça başarılı görünmektedir. Sınıf aktivasyon haritalarını incelediğimizde resmin doğru kısımlarını işaretlediğini gözlemlemekteyiz.



Şekil 4.17 Bitki fidelerinin sınıf aktivasyon haritaları

Şekil 4.17, InceptionResNetV2 ve ResNet-50 ile görüntülerdeki yaklaşım açısından farkı göstermektedir. Şekil 4.17'de gösterilen sınıf aktivasyon haritaları, modellerin son evrişim katmanlarından alınmıştır. Kırmızı renk tonunun baskın olduğu kısımlar

modelin daha sık odaklandığı kısımlar olarak gösterilirken, mavi tonlu kısımlar en az odaklanılan kısımlar olarak karşımıza çıkmaktadır.



Şekil 4.18 Bitki fidelerinin sınıflandırılması

Şekil 4.18’te görüldüğü gibi modelin yaptığı tahminlere göre bitki fideleri etiketlenmiştir ve örnek olarak resimde gösterilen bitki fidelerinin tamamı doğru sınıflandırılmıştır. En iyi sonucu veren model olan InceptionResNetV2 ile yapılan tahminler oldukça başarılı görünmektedir.

5. TARTIŞMA VE SONUÇ

5.1 Tartışma

Önerilen sistemin performansını değerlendirmek için aşağıdaki metrikler kullanılır: ortalama doğruluk, ortalama hassasiyet, ortalama geri çağırma ve ortalama F1 puanı.

Çizelge 5.1 Bitki fidelerinin CNN modelleriyle sınıflandırılmasından elde edilen bulgular

Model	Kesinlik	Duyarlılık	F1-Skoru	Test Doğruluğu	Validasyon Doğruluğu	Eğitim Doğruluğu
ResNET-50	0.92	0.92	0.92	0.9183	0.9352	0.9949
GoogleNet Naive	0.80	0.80	0.78	0.7584	0.6995	0.7633
InceptionResNETV2	0.97	0.97	0.96	0.9654	0.9655	0.9980
VGG-16	0.88	0.89	0.88	0.8863	0.8864	0.9715
InceptionV3	0.95	0.95	0.95	0.9461	0.9470	0.9969
DenseNET	0.93	0.91	0.91	0.9099	0.9520	0.9997
MobileNETV2	0.91	0.90	0.90	0.9015	0.9310	0.9980
NasNETLarge	0.90	0.90	0.90	0.9015	0.9133	0.9834
ResNET152V2	0.92	0.91	0.91	0.9099	0.9444	0.9963
Xception	0.95	0.95	0.95	0.9511	0.9571	0.9994

On farklı Evrişimli Sinir Ağı modeli uygulandı. InceptionResNetV2, tüm modeller arasında en iyi sonuçları vermektedir ve GoogleNet Naive, Çizelge 5.1'de görülebileceği gibi en düşük doğruluk, hassasiyet, duyarlılık ve fl puanı değerlerine sahiptir.

Çizelge 5.1, InceptionResnetV2 modelinin bu problem özelinde diğer CNN modellerinden daha iyi performans gösterdiğini ortaya çıkarmaktadır. Hem doğrulama verilerinde hem de test verilerinde daha iyi performans göstermektedir. İkinci en iyi model, doğruluk, hassasiyet, duyarlılık ve fl puanı açısından Xception olarak görünmektedir. VGG-16, DenseNet, ResNET152V2 ve ResNET-50 modellerinin eğitim verilerini hızlı öğrendiği ve eğitim doğruluğu açısından son derece başarılı olduğu gözlemlenmiştir. Ancak bu modeller, Xception, InceptionResNETV2 ve InceptionV3

ile karşılaştırıldığında test veri kümesinde doğruluk değerleri açısından zayıf kalmaktadır.

Inception ResNET V2 modeli, eğitim veri setinde hızlı öğrenme göstermesinin yanı sıra doğrulama setinde giderek daha kararlı hale gelmektedir. Öğrenme sürecinde elde edilen maksimum doğruluk değeri %96,55 olmuştur. Model maksimum %96,55 değerine ulaştığında modelin en iyi durumu kaydedilmiştir ve modelin bu durumu test veri setinde kullanılmıştır. Model kaybı eğitim için sıfıra çok yakın olarak gözlenmektedir ve doğrulama için Şekil 4.12'de görüldüğü gibi süreç boyunca azalma eğilimindedir.

Çizelge 4.10'da siyah çim türündeki bitkinin diğer bitkilere oranla çok daha az yüzdeyle doğru sınıflandırıldığı gözlemlenmektedir. Bu, doğruluğun nasıl geliştirileceğine dair açık bir ipucudur. Daha iyi bir doğruluk değeri elde etmek için bu spesifik bitki türleri üzerinde daha fazla çalışma yapılması gerekmektedir. Diğer bitkiler, Çizelge 4.10'a göre çok iyi bir doğruluk yüzdesi ile sınıflandırılmıştır. Şekilde 4.14'te karışıklık matrisi, diğerleri kadar fazla veriye sahip olmayan sınıfların bile sıklıkla doğru bir şekilde sınıflandırıldığını gösterir. Bu nokta, önerilen yöntemin performansını kanıtlamaktadır. Görüntü arka planlarının kaldırılmasının ve veri büyütmenin, modelin doğruluğunu artırmak için önemli bir rol oynaması dikkat çekicidir.

Şekil 4.17'de InceptionResNetV2'nin görüntünün büyük bir ölçeğine odaklandığını görüyoruz ve bu da görüntülerin arka planını kaldırmamıza neden olmaktadır. Bu nedenle, model sadece görüntülerin önemli kısımlarına odaklanabildiği için arka planları çıkardıktan sonra çok daha iyi doğruluk değerleri elde ediyoruz.

Çizelge 5.2 Bitki fidelerinin CNN modelleriyle sınıflandırılmasından elde edilen bulgular

Model	Kesinlik	Duyarlılık	F1-Skoru	Test Doğruluğu	Validasyon Doğruluğu	Eğitim Doğruluğu
InceptionResNETV2	0.98	0.98	0.98	0.9754	0,9746	0.9966
InceptionV3	0.96	0.96	0.96	0.9596	0.9805	1.000
Xception	0.98	0.97	0.97	9722	0.9816	0.9989

Çizelge 5.2’de bitki fidelerini sınıflandırmada başarısıyla öne çıkan 3 model kullanılarak bitki fidelerinin sınıflandırılması işleminin “Kesinlik”, “Duyarlılık”, “F1-Skoru”, “Test”, “Validasyon” ve “Eğitim” Doğruluk değerleri bulunmaktadır. InceptionResNetV2 modeli bitki fidelerinde olduğu gibi bitki tohumlarının sınıflandırılmasında da en iyi model olarak öne çıkmaktadır. Eğitim doğruluğu hariç tüm kriterlerde diğer modellerden daha iyi performans göstermektedir. Her üç modelde de “Kesinlik”, “Duyarlılık”, “F1-Skoru”, “Test”, “Validasyon” ve “Eğitim” Doğruluk değerlerinin %95 ve üzeri olması bitki tohumlarının sınıflandırılmasının oldukça başarılı bir şekilde gerçekleştiğini göstermektedir.

Elde ettiğimiz sonuçlar literatürde bulunan geleneksel yöntemlerle Kaggle.com’dan alınan aynı veri seti üzerinde yapılan tüm çalışmalardan daha üstündür. Derin öğrenme ve CNN kullanılarak yapılan çalışmaların çoğundan daha başarılı olarak görünmektedir. Literatür taraması boyunca yapılan çalışmaların başarı oranlarına bakılırsa InceptionResNetV2 modeli ile yaptığımız sınıflandırma literatürdeki çalışmalara oranla daha iyi performans göstermektedir.

5.2 Sonuç

Bu yazıda, erken büyüme aşamalarındaki bitki fidelerini ve tohumlarını sınıflandırmak için yeni bir yöntem olan derin öğrenme temelli Evrişimli sinir ağları kullanılarak raporlanmıştır. 10 farklı CNN modeli karşılaştırmalı olarak incelenmiş ve en başarılı ve başarısız olan modeller gösterilmektedir. Verilerin toplanması, ön işlenmesi,

temizlenmesi, hiper parametrelerin belirlenmesi gibi aşamalar tamamlanmış mümkün olan en iyi sonucu alabilmek için farklı yöntemler denenerek doğruluk oranı arttırılırken kayıp değerleri azaltılmıştır. Her bir model için hassasiyet, duyarlılık ve F1 skorları birbirleriyle karşılaştırmalı biçimde incelenmiş ve modellerin bu problem üzerinde birbirlerine üstün ve zayıf yönleri ortaya çıkarılmıştır.

Çalışma sonucunda gözlemlenen önemli noktalardan biri eğitim örnekleri ne kadar küçük olursa, eğitim aşaması boyunca fazla uyum olasılığı o kadar yüksek olmaktadır. Aşırı uyum olasılığını azaltmak için, eğitim verilerini güçlendirme yoluyla yüz binlerce hatta milyonlarca eğitim verisine ihtiyaç bulunmaktadır. Çalışmamızda verileri çoğaltma yöntemleri kullanılarak bu sorun minimuma indirilmeye çalışılmış ve ciddi başarı elde edilmiştir. Bitki fidelerini içeren veri setinde “Siyah Çim” türü bitkinin yapısı gereği ayırt etmesi oldukça zor bir türdür. Sonuçlar göstermektedir ki bu bitki türü özelinde çalıştırılan 10 farklı CNN modeli de diğer bitkilere oranla sınıflandırmada daha çok zorlanmaktadır. Çalışmamızda resimlerin arka planları kaldırılarak sorun mümkün olduğunca çözülmeye çalışılmıştır ancak bazı spesifik bitki türleri için daha fazla çalışma yapmanın gerekliliği ortaya çıkmaktadır. Diğer bir problem, CNN'nin yüksek donanım talepleri gerektirmesi ve modelin eğitimi için büyük miktarda bellek gerektirmesidir. Kendi bilgisayar kaynaklarımıza bağlı kalarak yaptığımız bu çalışmanın ilerisi için web servisler ve bulut platformlarının güçlü işlemci ve bellek gücü kullanılarak otomasyon özelliğine sahip bir uygulama üretilmesi planlanmaktadır.

Kaggle.com’da araştırmacılar için bir meydan okuma olarak başlatılan 12 adet bitki fidesini sınıflandırma problemini geleneksel makine öğrenmesi yöntemlerinden çok daha iyi bir yöntem olan CNN kullanarak çözülmüştür. InceptionResNetV2 modeliyle elde ettiğimiz %96,54 doğruluk oranı sadece geleneksel yöntemleri geride bırakmakla kalmamış aynı zamanda literatürdeki birçok Derin Öğrenme ve CNN kullanılarak aynı veri seti üzerindeki uygulamalarından daha üstün görünmektedir. Bunun yanında kendi oluşturduğumuz tohum veri setinde yine InceptionResNetV2 modeli kullanılarak elde ettiğimiz %97,54 doğruluk oranı çalışmanın önemini pekiştirmektedir.

Gelecekte uygulama mobil platformlara entegre edilerek çiftçilere ve tarım ile ilgilenen kişilere büyük bir destek sağlamak planlanmaktadır. Ayrıca, en başarılı sınıflandırma yapan CNN modelleri birleştirilerek yeni bir model oluşturulup daha iyi sonuçlar alınması planlanmaktadır.



KAYNAKLAR

- Alimboyong, C. R., Hernandez, A. A. ve Medina, R. P. (2019). Classification of Plant Seedling Images Using Deep Learning. IEEE Region 10 Annual International Conference, Proceedings/TENCON, 2018-October, 1839–1844. doi:10.1109/TENCON.2018.8650178
- Almawas, L., Alotaibi, A. ve Kurdi, H. (2020). Comparative performance study of classification models for image-splicing detection. Procedia Computer Science içinde (C. 175, ss. 278–285). Elsevier B.V. doi:10.1016/j.procs.2020.07.041
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., ... Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. Journal of Big Data, 8(1), 1–74. doi:10.1186/s40537-021-00444-8
- Amidi, A. ve Shervine, A. (n.d.). CS 230 - Evrişimli Sinir Ağları El Kitabı. <https://stanford.edu/~shervine/l/tr/teaching/cs-230/cheatsheet-convolutional-neural-networks> adresinden erişildi.
- Andrea, C. C., Mauricio Daniel, B. ve Jose Misael, J. B. (2018). Precise weed and maize classification through convolutional neuronal networks. 2017 IEEE 2nd Ecuador Technical Chapters Meeting, ETCM 2017, 2017-January, 1–6. doi:10.1109/ETCM.2017.8247469
- Anonymous. (2021). Mapped: Food Production Around the World. 13 Mart 2022 tarihinde <https://www.visualcapitalist.com/cp/mapped-food-production-around-the-world/> adresinden erişildi.
- Barbedo, J. G. A. (2016). A review on the main challenges in automatic plant disease identification based on visible range images. Biosystems Engineering, 144, 52–60. doi:10.1016/J.BIOSYSTEMSENG.2016.01.017
- Belal A.M. Ashqar, Bassem S. Abu-Nasser, S. S. A.-N. (2019). Plant Seedlings Classification Using Deep Learning. International Journal of Academic Information Systems Research (IJASIR), 46(3), 745–749. <http://dstore.alazhar.edu.ps/xmlui/handle/123456789/279> adresinden erişildi.
- Bıçakçı, K. (2020). AlexNet, VGGNet, Inception ve ResNet Nedir? 7 Haziran 2022 tarihinde <https://frightera.medium.com/alexnet-vggnet-inception-ve-resnet-nedir-bddc7482918b> adresinden erişildi.
- Büber, E. (2018). Makine Öğrenmesi Üzerine Teknik İnceleme | by Ebubekir Büber | Medium. 30 Mayıs 2022 tarihinde <https://medium.com/@EbubekirBbr/makine-ogrenmesi-uzerine-teknik-inceleme-1a124af61ef4> adresinden erişildi.
- Convolutional Neural Network (ConvNet yada CNN) nedir, nasıl çalışır? | by Tuncer Ergin | Medium. (n.d.). 23 Mayıs 2022 tarihinde <https://medium.com/@tuncerergin/convolutional-neural-network-convnet-yada-cnn-nedir-nasil-calisir-97a0f5d34cad> adresinden erişildi.

- Courville, I. G. and Y. B. and A. (2016). Deep learning. *Nature*, 29(7553), 1–73. <http://deeplearning.net/> adresinden erişildi.
- Dyrmann, M., Karstoft, H. ve 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
- Elhamraoui, Z. (2020, 16 Mayıs). InceptionResNetV2 Simple Introduction. Medium. 9 Haziran 2022 tarihinde <https://medium.com/@zahraelhamraoui1997/inceptionresnetv2-simple-introduction-9a2000edcdb6> adresinden erişildi.
- Elnemr, H. A. (2019). Convolutional neural network architecture for plant seedling classification. *International Journal of Advanced Computer Science and Applications*, 10(8), 319–325. doi:10.14569/ijacsa.2019.0100841
- Elshennawy, N. M. ve Ibrahim, D. M. (2020). Deep-Pneumonia Framework Using Deep Learning Models Based on Chest X-Ray Images. *Diagnostics* 2020, Vol. 10, Page 649, 10(9), 649. doi:10.3390/DIAGNOSTICS10090649
- GeeksforGeeks. (2022). CNN | Introduction to Pooling Layer. <https://www.geeksforgeeks.org/cnn-introduction-to-pooling-layer/>. 29 Mayıs 2022 tarihinde <https://www.geeksforgeeks.org/cnn-introduction-to-pooling-layer/> adresinden erişildi.
- Gheisari, M., Wang, G. ve Bhuiyan, M. Z. A. (2017). A Survey on Deep Learning in Big Data. *Proceedings - 2017 IEEE International Conference on Computational Science and Engineering and IEEE/IFIP International Conference on Embedded and Ubiquitous Computing, CSE and EUC 2017*, 2, 173–180. doi:10.1109/CSE-EUC.2017.215
- He, K., Zhang, X., Ren, S. ve Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016-December, 770–778. doi:10.1109/CVPR.2016.90
- Howard, A. G. (2014). Some improvements on deep convolutional neural network based image classification. *2nd International Conference on Learning Representations, ICLR 2014 - Conference Track Proceedings* içinde . <http://code.google.com/p/cuda-convnet> adresinden erişildi.
- Ioffe, S. ve Szegedy, C. (2015). Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. *32nd International Conference on Machine Learning, ICML 2015*, 1, 448–456. doi:10.48550/arxiv.1502.03167
- Jinsakul, N., Tsai, C. F., Tsai, C. E. ve Wu, P. (2019). Enhancement of deep learning in image classification performance using Xception with the swish activation function for colorectal polyp preliminary screening. *Mathematics*, 7(12), 1170. doi:10.3390/MATH7121170

- Jmour, N., Zayen, S. ve Abdelkrim, A. (2018). Convolutional neural networks for image classification. 2018 International Conference on Advanced Systems and Electric Technologies, IC_ASET 2018, 397–402. doi:10.1109/ASET.2018.8379889
- Jones, A. D. ve Ejeta, G. (2016). A new global agenda for nutrition and health: the importance of agriculture and food systems. Bulletin of the World Health Organization, 94(3), 228. doi:10.2471/BLT.15.164509
- Kamilaris, A. ve Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. Computers and Electronics in Agriculture, 147, 70–90. doi:10.1016/J.COMPAG.2018.02.016
- Kaur, A., Singh, S., Nayyar, A. ve Singh, P. (2020). Classification of Wheat Seeds Using Image Processing and Fuzzy Clustered Random Forest. International Journal of Agricultural Resources, Governance and Ecology, 16(2), 1. doi:10.1504/ijarge.2020.10030235
- Keya, M., Majumdar, B. ve Islam, M. S. (2020). A Robust Deep Learning Segmentation and Identification Approach of Different Bangladeshi Plant Seeds Using CNN. 2020 11th International Conference on Computing, Communication and Networking Technologies, ICCCNT 2020 içinde . Institute of Electrical and Electronics Engineers Inc. doi:10.1109/ICCCNT49239.2020.9225677
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E. (n.d.). ImageNet Classification with Deep Convolutional Neural Networks. <http://code.google.com/p/cuda-convnet/> adresinden erişildi.
- Lawrence, S., Giles, C. L., Tsoi, A. C. ve Back, A. D. (1997). Face recognition: A convolutional neural-network approach. IEEE Transactions on Neural Networks, 8(1), 98–113. doi:10.1109/72.554195
- Lecun, Y., Bengio, Y. ve Hinton, G. (2015). Deep learning. Nature, 521(7553), 436–444. doi:10.1038/NATURE14539
- Li, Q., Cai, W., Wang, X., Zhou, Y., Feng, D. D. ve Chen, M. (2014). Medical image classification with convolutional neural network. 2014 13th International Conference on Control Automation Robotics and Vision, ICARCV 2014, 844–848. doi:10.1109/ICARCV.2014.7064414
- Lo, W. W., Yang, X. ve Wang, Y. (2019). An xception convolutional neural network for malware classification with transfer learning. 2019 10th IFIP International Conference on New Technologies, Mobility and Security, NTMS 2019 - Proceedings and Workshop içinde . Institute of Electrical and Electronics Engineers Inc. doi:10.1109/NTMS.2019.8763852
- Loddo, A., Loddo, M. ve di Ruberto, C. (2021). A novel deep learning based approach for seed image classification and retrieval. Computers and Electronics in Agriculture, 187, 106269. doi:10.1016/J.COMPAG.2021.106269

- Makanapura, N., Sujatha, C., Patil, P. R. ve Desai, P. (2022). Classification of plant seedlings using deep convolutional neural network architectures. *Journal of Physics: Conference Series* içinde (C. 2161, s. 12006). IOP Publishing. doi:10.1088/1742-6596/2161/1/012006
- Narkhede, S. (2018). Understanding Confusion Matrix. *Towards Data Science*. 30 Mayıs 2022 tarihinde <https://towardsdatascience.com/understanding-confusion-matrix-a9ad42dcfd62> adresinden erişildi.
- Nkemelu, D. K., Omeiza, D. ve Lubalo, N. (2018). Deep Convolutional Neural Network for Plant Seedlings Classification. <http://arxiv.org/abs/1811.08404> adresinden erişildi.
- Pei, Y., Huang, Y., Zou, Q., Zhang, X. ve Wang, S. (2021). Effects of Image Degradation and Degradation Removal to CNN-Based Image Classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 43(4), 1239–1253. doi:10.1109/TPAMI.2019.2950923
- Radhakrishnan, P. (2017, 9 Ağustos). What are Hyperparameters ? and How to tune the Hyperparameters in a Deep Neural Network? | by Pranoy Radhakrishnan | *Towards Data Science*. 30 Mayıs 2022 tarihinde <https://towardsdatascience.com/what-are-hyperparameters-and-how-to-tune-the-hyperparameters-in-a-deep-neural-network-d0604917584a> adresinden erişildi.
- Rahman, N. R., Hasan, M. A. M. ve Shin, J. (2020). Performance comparison of different convolutional neural network architectures for plant seedling classification. 2020 2nd International Conference on Advanced Information and Communication Technology, ICAICT 2020, 146–150. doi:10.1109/ICAICT51780.2020.9333468
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., ... Fei-Fei, L. (2014a). ImageNet Large Scale Visual Recognition Challenge. <http://arxiv.org/abs/1409.0575> adresinden erişildi.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., ... Fei-Fei, L. (2014b). ImageNet Large Scale Visual Recognition Challenge. <http://arxiv.org/abs/1409.0575> adresinden erişildi.
- Salido, J. A. A. ve Ruiz, C. (2018). Using deep learning for melanoma detection in dermoscopy images. *International Journal of Machine Learning and Computing*, 8(1), 61–68. doi:10.18178/ijmlc.2018.8.1.664
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A. ve Chen, L. C. (2018). MobileNetV2: Inverted Residuals and Linear Bottlenecks. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition* içinde (ss. 4510–4520). doi:10.1109/CVPR.2018.00474

- Sharma, N., Jain, V. ve Mishra, A. (2018). An Analysis of Convolutional Neural Networks for Image Classification. *Procedia Computer Science* içinde (C. 132, ss. 377–384). Elsevier. doi:10.1016/j.procs.2018.05.198
- Simonyan, K. ve Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. 3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings. doi:10.48550/arxiv.1409.1556
- Smirnov, E. A., Timoshenko, D. M. ve Andrianov, S. N. (2014). Comparison of Regularization Methods for ImageNet Classification with Deep Convolutional Neural Networks. *AASRI Procedia*, 6, 89–94. doi:10.1016/J.AASRI.2014.05.013
- Thakallapelli, A., Ghosh, S. ve Kamalasadan, S. (2016). Real-time frequency based reduced order modeling of large power grid. *IEEE Power and Energy Society General Meeting* içinde (C. 2016-Novem). doi:10.1109/PESGM.2016.7741877
- Udofia, U. (2018). Basic Overview of Convolutional Neural Network (CNN) | by Udeme Udofia | DataSeries | Medium. Medium. 29 Mayıs 2022 tarihinde <https://medium.com/dataseries/basic-overview-of-convolutional-neural-network-cnn-4fcc7dbb4f17> adresinden erişildi.
- Yalcin, H. ve Razavi, S. (2016). Plant classification using convolutional neural networks. 2016 5th International Conference on Agro-Geoinformatics, Agro-Geoinformatics 2016 içinde . Institute of Electrical and Electronics Engineers Inc. doi:10.1109/Agro-Geoinformatics.2016.7577698
- Zahisham, Z., Lee, C. P. ve Lim, K. M. (2020). Food Recognition with ResNet-50. *IEEE International Conference on Artificial Intelligence in Engineering and Technology, IICAIET 2020*. doi:10.1109/IICAIET49801.2020.9257825
- Zhang, C. L., Luo, J. H., Wei, X. S. ve Wu, J. (2018). In defense of fully connected layers in visual representation transfer. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* içinde (C. 10736 LNCS, ss. 807–817). Springer, Cham. doi:10.1007/978-3-319-77383-4_79