

T.C.
BİLECİK ŐEH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĐİ ANABİLİM DALI

**DERİN EVRİŐİMLİ YAPAY SİNİR AĐI KULLANARAK MEYVE YAPRAĐI
HASTALIK TESPİTİ**

YÜKSEK LİSANS TEZİ

SENA NUR BENLİ

TEZ DANIŐMANI

DR. ÖĐR. ÜYESİ SALİM CEYHAN

BİLECİK, 2021

10422043

T.C.
BİLECİK ŐEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĐİ ANABİLİM DALI

**DERİN EVRİŐİMLİ YAPAY SİNİR AĐI KULLANARAK MEYVE YAPRAĐI
HASTALIK TESPİTİ**

YÜKSEK LİSANS TEZİ

SENA NUR BENLİ

TEZ DANIŐMANI

DR. ÖĐR. ÜYESİ SALİM CEYHAN

BİLECİK, 2021

10422043

BEYAN

Derin Evrişimli Yapay Sinir Ağı Kullanarak Meyve Yaprağı Hastalık Tespiti adlı yüksek lisans/doktora/sanatta yeterlik tezi/dönem projesinin hazırlık ve yazımı sırasında bilimsel araştırma ve etik kurallarına uyduğumu, başkalarının eserlerinden yararlandığım bölümlerde bilimsel kurallara uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, tezin herhangi bir kısmının Bilecik Şeyh Edebali Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunulmadığını, aksinin tespit edileceği muhtemel durumlarda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Bu çalışmanın, Bilimsel Araştırma Projeleri (BAP), TÜBİTAK veya benzeri kuruluşlarca desteklenmesi durumunda; projenin ve destekleyen kurumun adı proje numarası ile birlikte, ETİK KURUL onayı alınması durumunda ise ETİK KURUL tarih karar ve sayı bilgilerinin beyan edilmesi gerekmektedir.			
DESTEK ALINMIŞTIR		DESTEK ALINMAMIŞTIR	X
Destek alındı ise;			
Destekleyen kurum;			
Desteğin Türü		Proje Numarası	
1- BAP (Bilimsel Araştırma Projesi)			
2- TÜBİTAK			
Diğer;.....			
ETİK KURUL onayı var ise;			
ETİK KURUL karar tarih/sayı:	/.....	

Sena Nur BENLİ

.....

Tarih

.....

İmza

.....

ÖN SÖZ

Bu tez çalışmasının yazılmasında, çalışmamı sahiplenerek takip eden danışmanım Sayın Dr. Öğr. Üyesi Salim CEYHAN'a değerli katkı ve emekleri için teşekkürlerimi ve saygılarımı sunarım.

Savunma sınavı sırasında değerli jüri üyeleri Sayın Dr.Öğr.Üyesi Süleyman UZUN ve Dr.Öğr.Üyesi Alper YARGIÇ'a çalışmamın son haline gelmesindeki değerli katkıları adına teşekkürlerimi ve saygılarımı sunarım.

Son olarak bu günlere ulaşmamdaki emekleri adına değerli aileme teşekkür ederim.

Sena Nur BENLİ

2021

ÖZET

DERİN EVRİŞİMLİ YAPAY SİNİR AĞI KULLANARAK MEYVE YAPRAĞI HASTALIK TESPİTİ

Zirai üretimde bitki hastalıklarının hızlı bir şekilde tanınmasını sağlayacak ve kimyevi haşere ilaçlarının kullanımında karar verme sürecini hızlandıracak otonom bir tespit sistemi ortaya koymak önemlidir. Birçok ülke otonom sistemlerin araştırılması üzerine yatırım yapmakta ve pek çok AR-GE çalışmasını geliştirmektedir. Bu kapsamda ülkemizde de Tarımsal İzleme ve Bilgi Sistemi (TARBİL) kapsamında tarım eko-sisteminde verimlilik ve akıllı tarım uygulamaları desteklenmeye başlanmıştır.

Bu tezde açık bir kaynaktan alınan, görüntü çevirme, gama düzeltme, gürültü ekleme, PCA renk genişletme, döndürme ve ölçeklendirme olarak altı farklı veri genişletme tekniği ile oluşturulmuş, 14 farklı bitki yaprağına ait 38 çeşit hastalıklı ve sağlıklı “*New Plant Disease*” isimli yeni bir veri seti kullanılmıştır. Veri setindeki yaklaşık 83.107 görüntü için bitki yaprağı hastalık tespiti sınıflandırması yapan 6 katmanlı yeni bir Derin Evrişimsel Sinir Ağları (CNN) mimarisi oluşturulmuştur. Oluşturulan bu yeni modelle bitki yaprağı hastalığı sınıflandırma probleminin performansı iki şekilde incelenmiştir. Birinci olarak, veri setinde en yüksek sayıda veriye sahip 4 çeşit bitki yaprağına ait veriler ele alınıp modelin performansı incelenmiştir. İkinci olarak tüm veri seti için modelin performansı incelenmiştir. Elde edilen sonuçlar tezde verilmiştir. Ayrıca tüm veri seti için GoogLeNet, ResNet50, Vgg-19, Vgg-16, DenseNet gibi transfer öğrenme mimarileri kullanılmış ve performansları incelenerek sonuçları verilmiştir.

Anahtar Kelimeler: Yapay Zeka, Derin Evrişimli Sinir Ağları, Derin Öğrenme, Yaprak Hastalıklarının Tespiti, Transfer Öğrenme.

ABSTRACT

FRUIT LEAF DISEASE DETECTION USING DEEP CONVOLUTIONAL NEURAL NETWORK

It is important to establish an autonomous detection system that will enable rapid recognition of plant diseases in agricultural production and will accelerate decision-making in the use of chemical pest drugs. Many countries are investing in the research of autonomous systems and developing many R&D studies. In our country, efficiency and smart agricultural practices in the agricultural ecosystem have been started to be supported as part of the Agricultural Monitoring and Information System (TARBİL).

In this thesis, from an open source, image flipping, gamma correction, adding noise, PCA color expansion, A new dataset called "New Plant disease", 38 types of diseased and healthy, of 14 different plant leaves, was created with six different data expansion techniques as rotation and scaling. A 6-Layer Deep Convolutional Neural Network (CNN) architecture has been created for approximately 83.107 images in the dataset that detect plant leaf disease. With this new model, the performance of the plant leaf disease classification problem has been examined in two ways. First of all, the data set has 4 varieties of plant leaves with the highest number of data and examined the performance of the model. Secondly, the performance of the model has been reviewed for the entire dataset. The results obtained are given on the thesis. In addition, Transfer Learning architectures such as GoogLeNet, ResNet50, Vgg-19, Vgg-16, DenseNet have been used for the entire dataset and their performance has been reviewed.

Keywords: Artificial Intelligence, Deep Convolutional Neural Networks, Deep Learning, Detection of Leaf Diseases, Transfer Learning.

İÇİNDEKİLER

	Sayfa
ÖN SÖZ	i
ÖZET	ii
ABSTRACT	iii
TABLolar LİSTESİ	vi
ŞEKİLLER LİSTESİ	vii
KISALTMALAR VE SİMGELER LİSTESİ	ix
1. GİRİŞ	1
1.1. Çalışmanın Amacı	2
1.2. Literatür Taraması	3
2. MATERYAL VE METOD	8
2.1. Makine Öğrenmesi	8
2.2. Derin Öğrenme	9
2.2.1. Derin öğrenmenin tarihçesi	9
2.2.2. Derin öğrenme nedir?	10
2.2.3. Sinir ağları	11
2.2.4. Evrişimli sinir ağları (CNN)	11
2.2.4.1. Evrişim katmanı	13
2.2.4.2. Aktivasyon katmanı	14
2.2.4.3. Havuzlama katmanı	14
2.2.4.4. Tam bağlantı katmanı	15
2.2.4.5. Yığın normalleştirme	15
2.2.4.6. Bırakma katmanı	15
2.3. Transfer Öğrenme	16
2.3.1. Transfer öğrenme mimarileri	17
2.3.1.1. Vgg-19 ve Vgg-16	17

2.3.1.2. Resnet50	19
2.3.1.3. InceptionV3 ve GoogleNet	20
2.3.1.4. DenseNet	22
2.3.2. Transfer öğrenmede İnce Ayar (Fine-Tuning)	23
3. DENEYSEL ÇALIŞMALAR VE BULGULAR	24
3.1. Uygulamanın Amacı	24
3.2. Veri Seti	24
3.3. Ağ Yapısı	26
3.3.1. Katmanlı CNN mimarisi	28
3.3.2. Transfer öğrenme uygulamaları	33
4. SONUÇLAR VE ÖNERİLER	34
KAYNAKÇA	36

TABLULAR LİSTESİ

	Sayfa
Tablo 2.1. Aktivasyon çeşitleri	15
Tablo 3.1. Veri setine ait veri sayı tablosu	27
Tablo 3.2. “ <i>Yeni Bitki Yaprağı Hastalığı CNN Mimarisi</i> ” ile elde edilen değerler	31
Tablo 3.3. Eğitim dönemine göre elde edilen değerler	31
Tablo 3.4. CNN başlangıç parametreleri	32
Tablo 3.5. Doğruluk ve Kayıp fonksiyonu tablosu	35
Tablo 3.6. Transfer öğrenme mimarileri için elde edilen sonuçlar	36

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. Derin öğrenme venn şeması	8
Şekil 2.2. YSA tarihsel dalgalanması	9
Şekil 2.3. Tek bir sinir hücre yapısı	11
Şekil 2.4. Basit YSA gösterimi	12
Şekil 2.5. CNN yapısı	13
Şekil 2.6. 2D görselin 3D görsele dönüşümü	15
Şekil 2.7. Havuzlama çeşitleri	16
Şekil 2.8. Bırakma (Dropout) katmanı	17
Şekil 2.9. CNN mimarisi	17
Şekil 2.10. Transfer öğrenme mimarileri	18
Şekil 2.11. Vgg yapısı katman konfigürasyonları	20
Şekil 2.12. Ağa giren RGB görüntü	20
Şekil 2.13. ResNet50 modül	21
Şekil 2.14. ImageNet örnek ağ mimarisi	22
Şekil 2.15. Lineer ve Mlpconv katmanları	23
Şekil 2.16. Ağ içinde ağ modeli	24
Şekil 2.17. GoogLeNet mimarisi	24
Şekil 2.18. DenseNet grup ve evrişim katman görüntüsü	25
Şekil 2.19. DenseNet mimarisi	25
Şekil 3.1. Veri seti örneklem görüntüleri	27
Şekil 3.2. CNN akış diagramı	28
Şekil 3.3. X verisinin evrişim katmanı süreci	29
Şekil 3.4. X verisinin havuzlama katmanı işlem süreci	30
Şekil 3.5. 6 katmanlı CNN mimarisi	30
Şekil 3.6. Ağ içinde filtre görseli	32

Şekil 3.7. Tüm veri seti tahmin değerleri	33
Şekil 3.8. Vgg-19 mimarisi	34
Şekil 3.9. Vgg-19 mimarisi tahminleri	34

KISALTMALAR VE SİMGELER LİSTESİ

AI: Yapay Zeka

Batch Size : Yığın Boyutu

CNN: Derin Evrişimsel Sinir Ağları

HOG : Yönlendirilmiş Gradyanların Histogramı

ILSVRC: ImageNet Büyük Ölçekli Görsel Tanıma Yarışması

LBP : Yerel İkili Desenler

PCA : Temel bileşen analizi

R&D : Araştırma Geliştirme

RELU: Doğrultulmuş Doğrusal Birim

SIFT : Ölçek Değişmez Özellik Dönüşümü

SVM: Destek Vektör Makineleri

TARBİL : Tarımsal İzleme ve Bilgi Sistemi

WHO: Dünya Sağlık Örgütü

YSA: Yapay Sinir Ağları

1. GİRİŞ

İnsanođlu her zaman bir merak ve arařtırmaya olan alık duygusuyla yařamaktadır. Her keřfedilen bilginin anlamının ne olduđuyla ilgili yapılabilcek tđm teknolojik ve bilimsel alıřmalar sonucunda geliřen toplum kalkınır ve ilerler. Toplumların geliřen teknoloji ve bilime ayak uydurması ve izlemesi hayatı daha yařanabilir kılmaktadır. Bu karřılıklı iliřkiye “keřfet ve uygula” gibi bakarsak toplumların bu geliřime ayak uydurmaları iin sđrete aktif olmaları gerekmektedir. Yani bilgiye hızlı bir řekilde ulařarak bilgiyi kullanabilen ve aynı zamanda yeni bilgi uretebilen bireylerle toplumsal kalkınma sađlanır.

Veriler, teknoloji ađında yapılan, yapılmakta olan ve yapılabilcek her řeyin dijital anlamda karřılık geldiđi terimdir. Veriler ve verilerle yapılan her řey bir sđretir. Veriyi kullanarak bilgisayarla gđrđ ile dđnyayı anlama sđrecidir. Bu sđre aynı bir bebeđin dđnyaya geldikten sonra adım adım ۆđrenmesi gibidir. ocukların, dođumla bařlayan yařam serüvenleri basit ilkel yařamsal becerilerinden daha karmařık ve ileri dđzeydeki yařamsal becerilere dođru sistematik bir geliřim gđsterir ve bu geliřim, ‘*ۆđrenme*’ üzerine kurulmuřtur (Tuđrul, 2002: s.22). ۆđrenme, bireyin evresiyle etkileřime girmesiyle beyinde oluřan biyo-kimyasal deđiřiklikler sonucu meydana gelir (Keleř, vd., 2006:66-68). Beyindeki bu deđiřimlerle ilgilenen bilim insanları konuyu “*Nöroplastisite*”, adı altında inceleyerek ۆđrenmenin en basit anlamıyla beynin sđrekli kendisini yenileyebilme, yeni durumlara kendisini adapte edebilme, daha zengin ve daha iřlevsel sinir bađlantıları oluřturabilme kapasitesine dikkat ekmektedirler (Turhan, B, :58). Sinir ađlarının vđcudumuzdaki akıl almaz rolđ dđřünđlđnce bilim insanların dikkatini ekmesi kaınılmazdır. 1990’lı yıllardan beri bilgisayarların ۆđrenmesini sađlayan ‘*Yapay Sinir Ađları (YSA)*’ teknolojisinde olduka hızlı bir geliřme gđrđldđ. Bu teknoloji, kısa zamanda arařtırmacıların dikkatlerini üzerine eken bir bilim dalı olmayı bařardı ve alıřmalar laboratuvarlardan ıkararak gđnlük hayatın bir parası haline gelmeye bařladı (Öztemel, E. 2012).

“Derin ۆđrenme” bir ok aıdan ele alınmakta ve üzerinde alıřmalara bařlanmış olan bu yeni konu, insan dođasından gelen merak duygusunun sonularından oluřan makineler ve robotlar ۆđretilmek istenen konu üzerinde ۆđrenim sađlayabilir mi? tanıyabilir mi? tahmin yđrđtebilir mi? ve en ok merak edilenler arasında olan kendi kendine ۆđrenebilir mi? sorularına apaık bir řekilde cevap verebilmelerini gđrebilme řansı sunmaktadır. Derin ۆđrenme iinde bulundurduđu birok yaklařım ve algoritma ile kodlanabilmesi ve anlaşılrlık aısından zor gđrđnmesine karřın gđnümüzde en ok tercih edilen konulardan biridir. Burada en ۆnemli unsur verilerdir. Veriler, derin ۆđrenme yapısında bulunan yođun sinir ađlarından

geçerek öğrenmeyi ve test edilerek sonuçlar elde etmeyi sağlar. Bu sayede araştırmacılar, karmaşık ve yoğun verilerden bilgisayarlar aracılığıyla digital sonuçlar elde ederler.

Bitki hastalıkları, gıda üretimini etkileyen ana faktörlerden biri olarak kabul edilir. Mahsul miktarını veya ekonomik verimliliği önemli ölçüde azaltan bir etkidir. (Altieri, M., 2018) 'e göre, üretim kayıplarını en aza indirmek ve mahsulün sürdürülebilirliğini korumak için bitki yaprağı hastalıklarının hızlı ve doğru teşhisi yapılarak sürekli olarak gözlemlenen mahsulün hastalık yönetimini ve kontrol önlemlerinin alınmasını sağlayacağı açıktır. Tarım için en büyük zorluk, mahsulü etkileyen başlıca hastalıkların semptomlarının doğru tanımlanmasıdır (Sharada, P.M., 2016,7:14-19). Geleneksel uygulamalar, geniş ekim alanlarını kapsayamayacağından ve karar verme süreçlerinde gereken erken bilgileri sağlayamayacağından karar verme sürecinde anlamlı bilgiler verecek şekilde bitkileri takip edebilen pratik, güvenilir ve ekonomik bir otonom sistem geliştirmek gereklidir. Gelişen teknolojiyle birlikte Bilgisayarla Görü ve özellikle Nesne Tanıma son birkaç yıldır muazzam bir ilerleme kaydetmiştir. Eski usul kullanılan nesne tanıma uygulamalarında saatler, hatta günler süren çalışmaların artık Derin Öğrenme uygulamaları ile çok hızlı, uçtan uca ve girdi olarak verilen görüntünün yüksek doğruluk düzeyiyle çıktı oranına eşlenmesi, konumuz olan bitki hastalıklarının teşhisi hakkında ciddi bir bilgi, birikim ve hızlanma sağlayacaktır.

1.1. Çalışmanın Amacı

Bitki hastalıklarının tespiti manuel, görsel, moleküler test veya mikroskopla gerçekleştirilir. Hastalık tespitinde makine öğrenmesi yöntemlerinin kullanılması, görsel değerlendirme, uzman yanlılığı ve hatalara yol açabilecek optik illüzyonlar yoluyla hastalıkları belirleme görevini üstlendiğinden daha güvenilirdir (Hanson A.M., 2017: 7, 3). Çiftçiler geniş ve uygun arazide meyve ve sebze mahsullerini seçmek için çeşitliliğe ihtiyaç duyarlar ancak optimum verim ve kaliteli ürün için bu ürünlerin yetiştirilmesi son derece teknik bir o kadar da tecrübe gerektirmektedir. Meyve bitkilerinin yönetimi, özellikle üretimi ve dolayısıyla hasat sonrası yaşamı önemli ölçüde etkileyebilecek hastalıkların yönetimi için yakından izlemeyi gerektirir. Bitki durumunda hastalık, bitkilerin normal fizyolojik fonksiyonlarında, karakteristik semptomlar üreten herhangi bir bozulma olarak tanımlanır. Semptom, bir şeye eşlik eden olgudur ve varlığının kanıtı olarak kabul edilir. Hastalığa neden olan herhangi bir ajan olan patojen sebeptir. Çoğu durumda bitkinin yapraklarında veya tanımlanması haşere, hastalıklar veya hastalık insidansının yüzdesi, semptomları, mahsullerin başarılı bir şekilde yetiştirilmesinde kilit bir rol oynar (Altieri, M., 2018).

Tarım için en büyük zorluk, mahsulü etkileyen başlıca hastalıkların semptomlarının doğru tanımlanmasıdır. Temelde var olan çevresel etkenler ve patojenik delillerin etkilerini insan gözlemlerinin hızlı sonuca varması ve teşhis konulması arasındaki zaman açığını ve oluşabilecek her türlü verimsizliği en aza indirmeyi planlayan bu sistemle; basit sinir ağı ile temellenmiş olup gelişmiş yapay zeka olarak bildiğimiz “Derin Öğrenme” yani derin evrişimli sinir ağı ile eğitilerek sonuçların değerlendirilmesi ve karar verme sürecinde anlamlı bilgiler verecek şekilde bitkileri takip edebilen pratik, güvenilir ve ekonomik bir otonom sistem geliştirilmesi, çözüme ulaşmaya yardımcı ve yol gösterici olması hedeflenmiştir.

Bu araştırmada, derin evrişimli sinir ağı modeli (makine öğrenme yöntemlerinin bir alt bölümü) oluşturularak ve transfer öğrenme yapılarak 14 farklı türde 38 hastalıklı ve sağlıklı bitki yaprağının yüksek doğrulukla teşhis edilmesi amaçlanmıştır. Bu kapsamda, tasarlanan yeni CNN mimarisi kullanılarak bitki yaprağı hastalıklarının hızlı ve yüksek doğrulukla tespitine yönelik otonom bir çözüm için temel oluşturmak hedeflenmiştir. Ayrıca oldukça karmaşık mimariler olan DenseNet, Vgg-16, Vgg-19, ResNet50, GoogleNet gibi popüler derin öğrenme algoritmalarının transfer öğrenme yöntemiyle tüm veri seti üzerindeki başarımları değerlendirilmiştir.

1.2. Literatür Çalışmaları

Kawasaki, Uga ve diğerleri 2015 yılındaki araştırmalarında yaprak görüntüleri kullanarak sağlıklı salatalıkları enfektelilerden ayırt etmek için derin CNN'i kullanmayı önerdiler. Bu çalışmada, iki zararlı viral enfeksiyonu teşhis etmek için ki bunlar: “*Kavun Sarı Nokta Virüsü ve Kabak Sarı Mozaik Virüsü*” CNN mimarisi kullanmışlardır. Çalışmada kullanılan veri seti 800 salatalık yaprağı görüntüsünden oluşmaktadır. Veri setinde; 300 Kavun Sarı Nokta Virüsü ile 200 Kabak Sarı Mozaik ve 300 sağlıklı veri bulunmaktadır. Veri setini genişletmek için görüntülerde döndürme dönüşümleri kullanılmıştır. Yazarlar sağlıklı ve sağlıklısız şekilde ikili sınıflandırma işlemi için üç evrişim katmanından, havuzlama katmanlarından ve yerel kontrast normalleştirme katmanlarından oluşan bir CNN mimarisi önermişlerdir. Bu ağda kullanılan aktivasyon fonksiyonu, doğrultulmuş doğrusal birim (ReLU) 'dir. Bu çalışmada elde edilen doğruluk, 4 katlı çapraz doğrulama stratejisi altında %94,9'dur (Kawasaki vd., 2015).

Mokhtar ve diğerlerinin 2015 yılında yaptıkları araştırmada **PlantVillage** adlı halka açık veri setini kullanarak 26 hastalık çeşidine sahip 14 çeşit bitki türü için 38 etiketli sınıf üzerinde 3 versiyon halinde çalışmışlardır. Birinci versiyon renkli görüntüler, ikincisi gri ölçekli görüntüler ve üçüncüsü de arka plan bilgisinin sınıflandırma üzerindeki etkisini

değerlendirmek için bölütlenmiş yaprakların görüntülerini içerir. CNN'nin performansını ölçmek için farklı eğitim-test dağılımları %80-20, %60-40, %50-50, %40-60 ve %20-80 kullanmışlardır. CNN'i eğitmek için iki eğitim stratejisi uygulamışlardır: sıfırdan eğitim ve transfer öğrenme. Bitki hastalıkları sınıflandırmasında derin CNN'nin doğruluğunu değerlendirmek için 60 deneysel konfigürasyon kullanmışlardır. Bunlar 2 CNN mimarisi, veri kümesinin 3 farklı versiyonu, 2 eğitim türü ve 5 eğitim-test dağılımıdır. Tüm konfigürasyonlarda en yüksek doğruluk %99,34'tür ve GoogLeNet transfer öğrenmesi ile renkli görüntüler üzerinde 80-20 veri seti dağılımı kullanılarak elde edilmiştir. Ancak bu çalışmada birkaç sınırlılandırma kullanılmıştır. İlk olarak, görüntülerin çoğu, basit bir arka plan kullanılarak kontrollü bir ortamda yakalanır. İkinci olarak, kontrolsüz bir ortamda çekilen görüntülere genelleme yapabilen bir sınıflandırıcı geliştirmek için görüntü sayısı yeterli değildir. Örneğin, yazarlar, doğruluğun önemli ölçüde %31'e düştüğünü gösteren farklı koşullardan alınan görüntüleri kullanarak eğitilmiş modelin bir değerlendirmesini elde etmişlerdir (Mokhtar ve diğerler, 2015).

Luaibi, Salman ve Miry 2020 yılında yaptıkları çalışmalarında ülkeleri Irak'ta 2019 yılında yapılan bir anketten yola çıkmıştır. Bu ankette ülkelerinde önemli yere sahip narenciyelerin özellikle; portakal, ekşi limon, tatlı limon, mandalina ve acı portakalın üretimindeki kayda değer düşüşün sebebinin bitkilerin yakalandıkları hastalıklar olduğunu görmüşlerdir. Yazarlar, özellikle en çok görülen 3 çeşit hastalık: Turunçgil Yaprak Güvesi, Element Yoksunluğu, Ölçek Böcek Hastalığının Derin CNN yaklaşımlarıyla tespitini amaçlamışlardır. Veri setinde her bir hastalıktan 50 hastalıklı ve 50 sağlıklı veri olmak üzere toplam 200 digital görüntü bulunmaktadır. Eğitim için verilerin %70'i, doğrulama için %20'si ve test için %10'unu şeklinde veri seti bölünmüştür. Veri sayısı yapay veri genişletme yaklaşımları ile (yeniden boyutlandırma, büyütme ve döndürme) orijinal veriler manipüle edilerek arttırılmıştır. AlexNet ve ResNet popüler mimarileri kullanılarak 10 dönem eğitilen veriler en hızlı ve en yüksek sonuca %97,92 doğrulukla AlexNet ve %95,73 doğrulukla ResNet ile ulaşmışlardır (Luaibi, Salman, Miry, 2020).

Yalcin ve Razavi 2016 yılında yaptıkları araştırmada insan yaşamında önemli yere sahip olan her türlü tüketim ve üretimde kullanılan bitkilerin hastalıklarının ve sağlıklı durumlarının stabil hale gelebilmesi ve gelişen teknoloji ile onların takibinin daha doğru yapılabilmesi ve oluşabilecek sıkıntıların önceden tahmin edilebilmesi amaçlanmıştır. En önemli problemi; "*Bitkilerin otomatik sınıflandırmalarının onların kendi buldukları türe göre yapılmasıdır.*" şeklinde tanımlamışlardır. Bitkileri otomatik olarak sınıflandırmak için CNN gibi yeni yapay zeka yöntemlerinden yararlanmak, tanıma doğruluğunun iyileştirilmesi

için hayati önem taşımaktadır. Sınıflandırma, bir eğitim veri kümesine dayalı olarak bir sınıf kümesine yeni bir gözlem atayan bir karar mekanizmasını içeren birçok uygulamada kullanılan örüntü tanımada aktif bir araştırma alanıdır. Türkiye de devlet teşviki ile oluşturulan Tarımsal İzleme ve Bilgi Sistemi (TARBIL)'den sağladıkları veriler ile çalışmışlardır. Buğday, arpa, mercimek, pamuk, biber, mısır, nar, kiraz, üzüm, antepfıstığı, domates, kayısı, ayçiçeği, mandalina, fasulye ve elma verileri ile deneme yapmışlardır. 16 sınıflı 4800 digital veri üzerinden veri setlerini Evrişimsel Sinir Ağlarına (CNN) ve SVM yapılarına uygulamışlar ve çeşitli ince ayarlar yapmışlardır. SVM, 2 çeşit olarak değerlendirilmiş; RBF Kernel ve Polynomial Kernel ve en yüksek doğruluk oranı %89 olmuştur. CNN yapısının doğruluk oranı ise %97,47 tir (Yalcin, Razavi, 2016:1-5).

Xiao ve diğerleri 2021'de yaptıkları çalışmalarında Çin Halk Cumhuriyeti'nde ve Tayvan'ın Miaoli eyaletinde yetişen çileklerin 2010 ve 2016 yılları arasında üretimindeki hızlı düşüşün sebebi olan çilek hastalıklarının CNN ile görüntü tanımayı geliştirmek için kullanılan güçlü bir derin öğrenme yaklaşımıyla hastalık tespitini hızlı bir şekilde yapmayı ve böylece ülke gelirinin 1.8 milyar dolarını kapsayan düşük bir kayıp ile üreticiyi korumayı amaçladılar. Başlıca çilek patojenleri şunlardır: Bakteri yaprak lekesi neden olan *Colletotrichum siamense*, Gri küfün nedensel ajanı olan *Botrytis sinereal*, *Neopestalotiopsis*; taç çürüklüğü, meyve çürüklüğü ve yaprak yanıklığının nedensel ajanı ve yaprak saplarını, yaprakları ve meyveleri çileğe özgü bir şekilde etkileyen küllenmeye neden olan diğer mantarlardır. Bu patojenler fotosenteze müdahale eder ve meyve kalitesini, büyümesini ve üretkenliğini olumsuz etkiler. 1306 görüntü ve 5 çeşit en çok karşılaşılan hastalık üzerinden önerilen teknikte ellerinde bulunan veri seti ile GoogLenet, Vgg-16 ve ResNet50 mimarileri kullanılmış ve veri setini %80 eğitim ve %20 doğrulama olarak ikiye bölünmüştür. 20 dönem eğitimden sonra %99,6 ile en yüksek değerlere sahip olan ResNet50 mimarisini önermektedirler (Xiao ve diğerleri, 2021).

Hanson ve diğerleri 2017 yılındaki çalışmalarında, Hindistan'da yetişen bitki türleri üzerinde oluşan hastalıkların tahminini geliştirecekleri mimarinin yeniliğe ayak uydurmasını istediklerini belirten Hanson Derin CNN mimarilerini kullanarak bitki hastalık tespiti yapmayı amaçladılar. Verileri, bitki görüntülerinin bulunduğu açık kaynaklı bir internet sitesinden indirmişlerdir. Çeşitli veri arttırma yöntemleri uygulayarak (döndürme, çevirme vb.) verileri çoğaltmışlardır. Daha iyi öznelik çıkarımı elde etmek amacıyla derin sinir ağı sınıflandırıcısı için veri seti olarak kullanılması amaçlanan nihai görüntüler, tutarlılık sağlamak amacıyla ön işleme tabi tutulmuştur. Görüntülerin ön işlenmesi genellikle düşük frekanslı arka plan gürültüsünün kaldırılmasını, tek tek parçacık görüntülerinin yoğunluğunun

normalleştirilmesini, yansımaların kaldırılmasını ve görüntülerin bölümlerinin maskelenmesini içerir. Sağlıklı ve hastalıklı olarak verileri etiketlendirdikten sonra eğitim, doğrulama ve test veri dizinlerini oluşturmuşlardır. Eğitim için 30.880 ve doğrulama için 2.589 görüntü içeren kendilerine özgü bir veri tabanı oluşturmuşlardır. Tanımladıkları evrişimli sinir ağları (CNN), çok sayıda katmanından oluşur. Bunlar, girdi görüntüsünün bölümlerini işleyen küçük nöron koleksiyonlarıdır. Bu koleksiyonların çıktıları daha sonra orijinal görüntünün daha yüksek çözünürlüklü bir temsilini elde etmek için giriş bölgeleri üst üste gelecek şekilde döşenir; bu işlem her katman için tekrarlanır. Evrişimli ağlar, nöron kümelerinin çıktılarını birleştiren yerel veya küresel havuz katmanlarını içerebilir. Ayrıca, her bir katmanın sonunda veya sonrasında uygulanan noktasal doğrusal olmayanlık ile evrişimli ve tam bağlantılı katmanların çeşitli kombinasyonlarından oluşurlar. Serbest parametre sayısını azaltmak için küçük giriş bölgelerinde bir evrişim işlemi başlattılar. Toplamda 100 dönem eğitime tabi tuttıkları verilerde ince ayar yapıldıktan sonra eğitilen modelin nihai doğruluğu %95 olmuştur (Hanson, 2017).

Lakshmi ve Sivakumar 2017 yılında yaptıkları araştırmalarında WHO 'dan aldıkları bilgilere göre Hindistan'da yaşayan insanların son 10 yılda diyabete yakalama oranlarının ikiye katlandığını öğrenmişlerdir. Buradan yola çıkarak dünya genelinde diyabet hastalığının artışı insanoğlunu şekere olan yaklaşımlarını vücuda aynı zararı vermediği düşünülen ama şeker tadı veren bitkilere ve diğer alanlarda şekere karşılık gelen maddelerin kullanılmasına itmiştir. Bitkiler üzerinde yaklaşımlar ele alındığında Stevia bitkisi açık ara öne çıkmaktadır. Fazla üretim beraberinde dikkat edilmesi gereken önemli konuları ortaya çıkarmaktaydı; iklim, toprak, gübreleme, hasat, yabancı ot kontrolü, su yönetimi vb. Stevia bitkisini etkileyen hastalılarda; *Alternaria alternata* (Mantar Hastalığı), *Sclerotinia sclerotiorum* (Beyaz Küf hastalığı), *Sclerotium rolfsii* (Mantar Kökenli Hastalık), *Septoria steviae* (Kahverengi Nokta Hastalığı), *Rhizoctonia* sp. (Kırmızı Leke Hastalığı), Red spider mites (Kırmızı Örümcek Hastalığı), Whiteflyis (Beyaz Sinek Hastalığı)'dır. Ellerinde bulunan görsel verilerle öncelikle görüntülere yeniden boyutlandırma yapmışlardır. Gri ölçeklendirme ile gri görüntüler ve renkli görüntüler üzerinde denemeler yapılmış olup, eğitim veri seti %80, %60 ve %40 arasında değişmektedir. CNN mimarisine giren veriler 5 çeşit sınıf içerisinde sınıflandırılarak sonuçlar elde edilmiştir. Kayıp fonksiyonunun en aza indirgenmesinde sinir ağının en iyi ağırlık ve bias'ını öğrenmek için önerilen çalışmalarında Stochastic Gradyan Descent algoritması kullanılmıştır. Yüksek doğruluk değerlerinin üzerinde önemli etkiye sahip olduklarını düşündükleri bu optimizasyon algoritmasıyla %80 eğitim ve %20 test verileri üzerinden çıktılarına bakıldığında; renkli veriler üzerinde doğruluk oranları %92 ve gri ölçekli

veriler üzerinde doğruluk oranları %90 'dır. Otonom araçlar, üretimin ve kalitenin korunabilmesi için sorunu en erken aşamada tanımaya yardımcı olduğunu belirtmişler ve makalelerinde Stevia'daki hastalıkları tanımlamak ve sınıflandırmak için derin evrişimli sinir ağına dayalı bir yöntem sunmuşlardır. Ana katkıları, Stevia alanındaki farklı hastalık türlerini tespit etmek için derin sinir ağları uygulamaktır (Lakshmi, Sivakumar, 2017).

Ashqar ve diğerleri 2020 yılında yaptıkları çalışmada bir fidenin tohumdan çimlenmesi ve gelişimini izlemişler ve fidelerin daha ayırt edilebilir hale gelmeden öncesi aşamalarında Derin CNN mimarisini kullanarak sınıflandırılmaya çalışılması amaçlanmıştır. Ayırt edici özellikler arasında tipik bir genç fidenin üç ana bölümden yararlanılmıştır. Bunlar; kök (embriyonik kök), hipokotil (embriyonik sürgün) ve kotiledonlar (tohum yaprakları) 'dır. Aarhus Üniversitesi Sinyal İşleme Grubu tarafından Güney Danimarka Üniversitesi ile işbirliği içinde sağlanan veri seti, çeşitli veri genişletme aşamalarında 12 türe ait yaklaşık 960 benzersiz bitkinin 5.608 görüntüsünü içerir. Verilerin herbiri birbirinden farklı özelliklere sahiptir ve veriler normalizasyon, yeniden boyutlandırma ve veri arttırımı şeklinde ön işleme tabi tutulmuştur. Vgg-16 isimli popüler CNN mimarisi ile çalışmış, ağ üzerinde 2 deney yaparak sonuçları paylaşılmıştır.

İlk deneyde, ince ayar yapılmış, görüntüleri 128x128 piksel olarak yeniden boyutlandırdıktan sonra 5.608 görüntüden oluşan orijinal bitki fidesi veri seti kullanılmıştır. Verileri eğitim %90, doğrulama %10 olarak ayrılmıştır. Eğitim doğruluğu %100 ve doğrulama doğruluğu %98,57 olarak bulunmuştur.

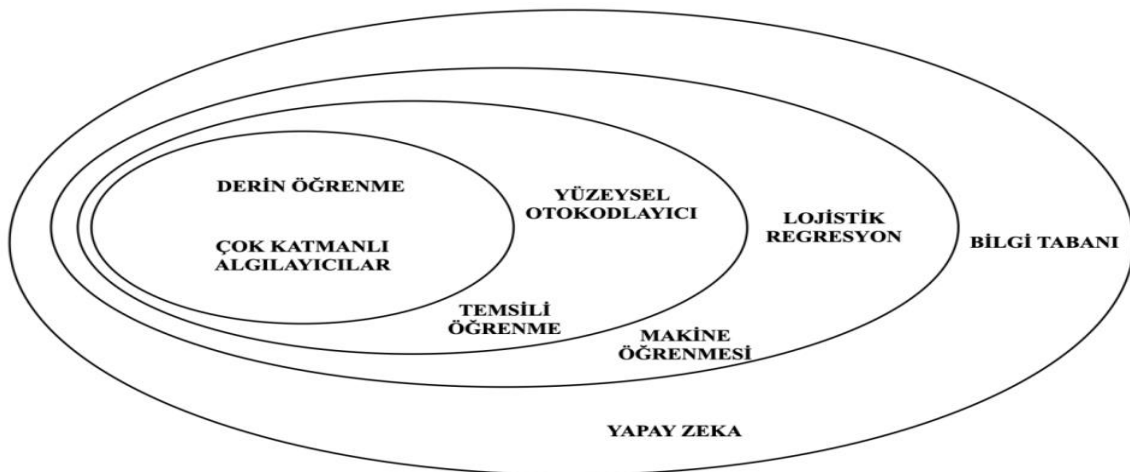
İkinci deneyde, görüntüleri 128x128 piksel olarak yeniden boyutlandırdıktan sonra 9527 görüntüden oluşan dengeli bitki fidesi veri setini kullanılmıştır. Verileri eğitim %90, doğrulama %10 olarak ayrılmıştır. Eğitim doğruluğu %100 ve doğrulama doğruluğu %99,48'dir. Sonuç olarak ne kadar çok görüntüye sahip olursak, sonuçların o kadar iyi olacağını ileri sürmüşlerdir (Ashgar,2020).

2. MATERYAL VE METOD

2.1. Makine Öğrenmesi

Makine Öğrenmesi, bilgisayarı verilerden öğrenebilmeleri için programlama sanatıdır. İstatistik, yapay zeka ve bilgisayar biliminin kesiştiği bir araştırma alanıdır ve aynı zamanda tahmine dayalı analiz veya istatistiksel öğrenme olarak da adlandırılır. Son yıllarda, makine öğrenmesi yöntemlerinin uygulanması günlük hayatta her yerde bulunur hale gelmiştir. “Hangi filmlerin izleneceğini, hangi yiyeceklerin sipariş edileceğini veya hangi ürünlerin satın alınacağını otomatik olarak önermekten, kişiselleştirilmiş çevrim içi yayınlara ve fotoğraflardaki arkadaşları belirlemeye kadar makine öğrenimi algoritmaları birçok modern web sitesinin ve cihazın merkezinde yer alır” (Müller Andreas C. Guido S., 2017:21).

Derin öğrenme, sırayla yapay zekanın (AI) bir alt alanı olan makine öğreniminin bir alt alanı Şekil 2.1’de gösterilmiştir. Yapay zekanın temel amacı, insanların sezgisel olarak ve neredeyse otomatik olarak gerçekleştirdiği, ancak bunun dışında bilgisayarlar için çok zorlayıcı olan problemleri çözmek için kullanılacak bir dizi algoritma ve teknik sağlamaktır. Böyle bir AI problem sınıfına harika bir örnek, bir görüntünün içeriğini yorumlamak ve anlamaktır. “Yapay zeka, otomatik makine muhakemesi (akıl yürütme, planlama, buluşsal yöntemler vb.) ile ilgili bir çok çalışma içermesine rağmen makine öğreniminin alt alanı genellikle örüntü tanıma ve verilerden öğrenmeye odaklanır. YSA, beynin yapısı ve işlevinden ilham alan, verilerden öğrenen ve örüntü tanımaya odaklanan bir tür makine öğrenme algoritmasıdır. Derin öğrenme YSA algoritmaları ailesine aittir ve çoğu durumda iki terim birbirinin yerine kullanılabilir” (Rosebrock, A., 2017:121-123).



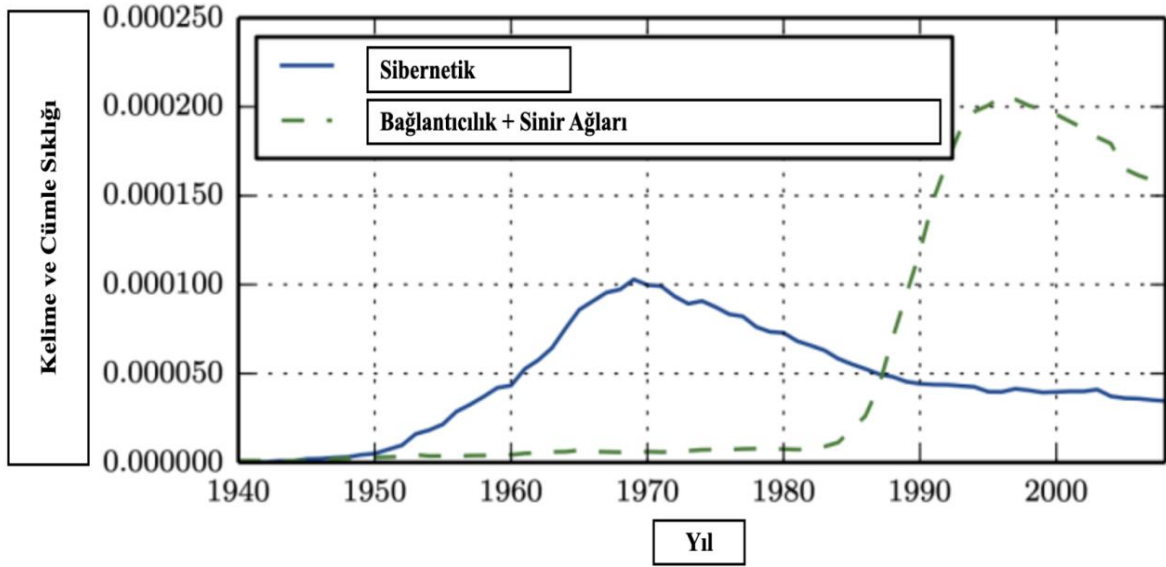
Şekil 2.1. Derin öğrenmeyi, yapay zekanın bir alt alanı olan makine öğreniminin bir alt alanı olarak tanımlayan bir Venn şeması

Kaynak: (Goodfellow vd., 2016:9).

2.2. Derin Öğrenme

2.2.1. Derin öğrenmenin tarihçesi

Yapay zeka, bilgisayarlar ve bilgisayar destekli makineler kullanılarak genellikle insana özgü nitelikler, çözüm bulma, anlama, anlamsal örnekler arasında akıl yürütme, genelleme ve geçmiş deneyimlerden öğrenme olarak sayılabilir. Daha yüksek mantıksal süreçlerle ilgili görevleri yerine getirme yeteneği olarak bilimsel çalışmalarda tanımlanmıştır (Nabiyev, 2012). Bazı temel bağlamlar, derin öğrenmeyi anlamak için yararlıdır. ‘Genel olarak üç gelişme dalgası olmuştur. 1940’lar ve 1960’lar da ‘sibernetik’ olarak bilinen derin öğrenme, 1980’ler ve 1990’lar da ‘bağlantıcılık’ olarak bilinen derin öğrenme ve 2006’da başlayan ‘derin öğrenme’ adı altında canlanmaya başlamıştır’ (Goodfellow vd., 2016:11-13). Bu nicel olarak Şekil 2.2.’de gösterilmiştir.



Şekil 2.2. Google Books'a göre ‘sibernetik’ ve ‘bağlantıcılık’ veya ‘sinir ağları’ ifadelerinin sıklığıyla ölçülen yapay sinir ağlarının üç tarihsel dalgasından ikisi

Kaynak: (Goodfellow vd., 2016).

Bugün tanıdığımız en eski öğrenme algoritmalarından bazıları biyolojik öğrenmenin hesaplamalı modelleri, yani öğrenmenin beyinde nasıl gerçekleştiğine veya olabileceğine dair modeller olarak tasarlanmıştır. Sonuç olarak bu araştırmacıları derin öğrenmenin geçtiği isimlerden olan YSA’yı tanımaya itmektedir. Derin öğrenme modellerine karşılık gelen bakış açısı, biyolojik beyinden ister insan beyninden isterse de bir hayvan beyninden esinlenen mühendislik sistemleri olmaktadır. “Makine öğrenimi için kullanılan sinir ağları türleri bazen beynin işlevini anlamak için kullanılmış olsalar da (Hinton ve Shallice, 1991:1), bunlar genellikle biyolojik işlevin gerçekçi modelleri olarak tasarlanmamıştır”.

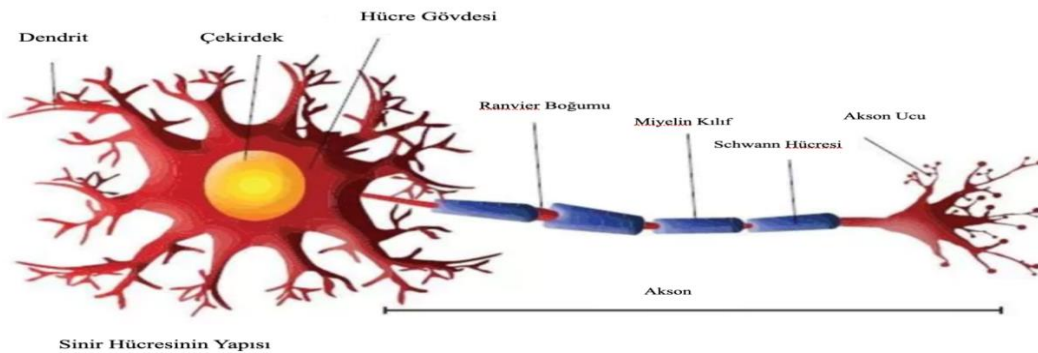
2.2.2. Derin öğrenme nedir?

Derin öğrenme geleneksel makine öğrenmesi işlemlerinden farklı olarak kodlanan komutların işlenmesi üzerine temellenmemiş olup görsel ve digital olarak kullanabileceği tüm kaynaklardan otomatik olarak öğrenmesiyle ayrılır. “*Derin öğrenme sinirsel bakış açısıyla iki ana fikir tarafından motive edilir. Birinci fikir, beynin akıllı davranışın mümkün olduğuna dair örnek bir kanıt sağlamasıdır ve zeka inşa etmenin matematiksel olarak basit bir yoludur. Beynin arkasındaki hesaplama ilkelerini tersine çevirmek ve işlevselliğini çoğaltmaktır*” (Goodfellow vd., 2016:20-25). Başka bir bakış açısı da beyni ve insan zekasının altında yatan ilkeleri anlamının çok ilginç olmasıdır. Bu nedenle bu temel bilimsel sorulara ışık tutan makine öğrenimi modelleri içerisinde derin öğrenme mühendislik uygulamalarını çözme yeteneklerinin yanı sıra yol göstericidir. Yapı taşını biyolojik sinir hücrelerine benzeterek YSA modellemesi ile daha derin bir öğrenim temelli bakış açısıdır. Beyin ve insan zekasının büyüleyiciliği bilim insanlarını, gelişen teknolojiyi kavramsal olarak ele alınabilir ve üretilebilirliğin son evresi gibi görülen ama sürekli gelişim halinde bulunan bilgisayarların kendi kendine tanınması ve karar vermesi mekanizması üzerine yoğunlaştırmaktadır.

Diğer öğrenme kuramlarında ele alınan verilerin yapısı, dokusu, şekli, yönü vb. durumlarında yaklaşımların bir sonraki adıma geçiş yapabilmeleri, algoritmalarla belirlenmediği sürece ileri adım atılamaması derin öğrenmenin farkını ortaya koymaktadır. Derin öğrenme özellikle Evrişimli Sinir Ağları (CNN) farklı bir yaklaşım benimsemektedir. “*Bir görüntüden özellikleri çıkarmak için bir dizi kural ve algoritmayı elle tanımlamak yerine, bu özellikler eğitim sürecinden otomatik olarak öğrenilir*” (Rosebrock, A., 2017:21-27).

2.2.3. Sinir ağları

Beynimiz, her biri yaklaşık 10.000 diğer nörona bağlı yaklaşık 10 milyar nörondan oluşur ve temel birimleri genel olarak sinir hücreleri (nöronlar) ve bunların uzantılarının diğer sinir hücreleri ile oluşturduğu değme noktaları (sinaps) Şekil 2.3.’te gösterilemektedir .




Şekil 2.3. Tek bir sinir hücre yapısı

Kaynak: (Gorgodo, 2021).

Nöronlar dentritlerindeki diğer nöronlardan elektro-kimyasal girdiler alır. “*Bu elektro-kimyasal girdiler nöronu aktive etmek için yeterince güçlüyse, aktif nöron sinyali aksonu boyunca ileterek diğer nöronların dentritlerine iletir. Bu bağlı nöronlar da ateşlenebilir ve böylece mesajı iletme sürecini sürdürür*” (Korkmaz, 2007:93-100). “*Canlı vücudundaki hemen hemen tüm canlılık ve tepki verebilme özelliklerinde göstermektedir ki; Hücrelere gelen uyarılarla eş zamanlı olarak hücreler arasındaki mutlak sinaptik ilişkilerin değişimi veya hücreler arasında yeni sinaptik ilişkilerin kurulması ‘öğrenme’ sürecine karşılık gelir*” (Koç vd., 2004:74).

Sinir hücrelerindeki her bir süreç elemanının yapay olarak tanımlanabilmesi için modellenen YSA elemanlarına karşılık gelecek süreç elemanları tasarlanmıştır. Şekil 2.4’te tüm kaynakların ortak yaklaşımlarına göre oluşturulmuş özgün bir sinir ağı görüntüsü gösterilmektedir. Nöronlara gelen her bir bilgi girdi algılayıcılar ile tespit edilir alınan bilgilerin toplanma süreci ve birleştirilmesi ile elde edilen net sonuca karşılık gelecek sonuç hazırlanır. Aktive olmuş hücre içinde hazırlanan cevap bir başka nörona iletilmek üzere sinir hücresinden dentritler ile iletimi yapılır. Tüm bu biyolojik verileri göz önüne alarak çalışan YSA ortaya çıktığı tarihte inanılmaz sonuçlar ortaya koysa da ilerlemeler tek bir sinir ağının yapabilecekleri artık çağımızın gerisinde kalması sebebiyle aynı bir beyin de bulunduğu gibi binlerce hücreden oluşan Derin Öğrenme uygulamaları öne çıkmaktadır.



Şekil 2.4. Basit Yapay Sinir Ağı gösterimi¹.

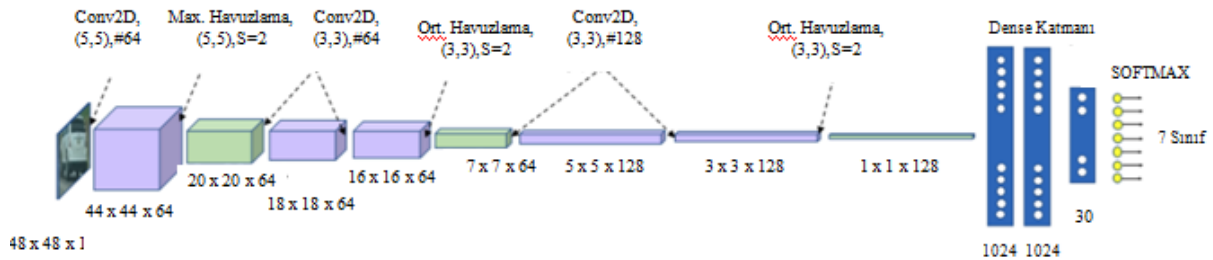
2.2.4. Evrişimli sinir ağları (CNN)

Son yıllarda biyolojik görsel sistemlerde bulunan alıcı alanlar kavramını taklit eden hesaplama teorileri, görüntü işleme alanında çığır açmaktadır. Bu durum çığır açıcı olayların kapısını açmakta Hubel ve Wiesel gibi bilim insanlarının yaptıkları deneyler ve sonuçları bulunmaktadır. Hubel ve Wiesel, daha genç yavru kedilerin beyin kabuğu anormallikler ve

¹Birçok çalışmadan elde edilen bilgiler ve veriler doğrultusunda özgün hazırlanmış basit yapay sinir ağı yapısı.

dolayısıyla körlük geliştirme riski altında olduğu sonucuna vardı. Araştırmacılar, üç yavru kedi içinde doğumda beyindeki elektriksel bağlantıları incelediler ve beyin kabuğu hücrelerinin görsel uyarılara yetişkin kedilerdekine benzer şekilde tepki verdiğini buldular (Hubel ve Wiesel, 1964) ve görsel korteksin üst üste binen alt bölgelerdeki ışığı algılayan alıcı alanlardan oluştuğunu keşfettiler. Bu CNN'leri modellemenin giriş noktasıdır (Hubel ve Wiesel, 1968). Her nöron, insan beyninin görsel korteksinde olduğu gibi sınırlı bir bölgede uyarılara tepki verir ve nöronların örtüşen bölgeleriyle birlikte tüm görsel alanı kaplar. “Sinir ağı denemelerinde iki çalışma prensinden oluşan beyni taklit ederek sinir ağı oluşturulmuştur. İlk prensip, sinir hücrelerinin görme bölgesi içinde kopyalanmış olmasını hedefleyerek çalışmaktadır. İkincisi prensip ise bilgiyi basit sinir hücrelerinden kopyalayan kompleks sinir hücrelerin bulunmasıdır” (Fukushima,1986:5-15). 1990 yılında LeCun elle yazılmış sayıları tanıması için bir CNN’i geri yayılım kullanarak eğitti. Genel ağırlık alanın uzay değişiminin öğrenme hızını arttırdığını el yazısı ile yazılan sayıların tanınmasında anlattığı makalesinde beş tane ağ yapısı hazırlayıp karşılaştırmıştır. Bunlar tek katmanlı, çift katmanlı, yerel olarak bağlantılı ve kısıtlı ağ ve kısıtlı ağ 2’dir. Kısıtlı ağ 2’de %100 eğitilmiş ağ üzerinde en yüksek bağlantılarla gizli katmanlarla %98.9 performans elde etmiştir (LeCun, 1989).

Bir CNN Şekil 2.5’te gösterildiği gibi temel olarak farklı katman türlerinden oluşur. Giriş katmanı, evrişimli doğrusal olmayan katman, havuzlama katmanı ve tam bağlı katmanlardır.

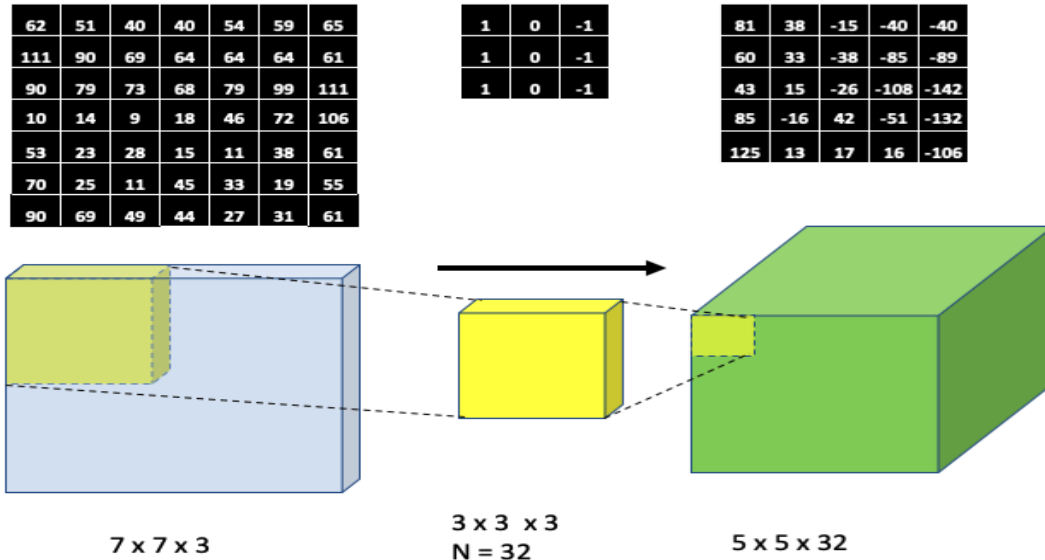


Şekil 2.5. Evrişim işlemi 44x44x64 çıktı şekli oluşturmak için 48 genişliğinde ve 48 yüksekliğinde gri tonlamalı bir görüntüye (5,5) boyutunda 64 filtre uygulanır. Maksimum havuzlama filtre boyutu (5,5) ve 44x44x64 görüntü formuna uygulanır ve çıktı şeklinin 20x20x64’e düşmesiyle sonuçlanır. İlk Conv2D işleminden sonra doğrusal olmayan bir RELU aktivasyonu uygulanır ve son yoğun katmana kadar her işlemten sonra devam eder.

Kaynak: (Kar, 2020:85).

2.2.4.1. Evrişim katmanı (Convolution Layer)

Evrişim, CNN mimarisinin ana yapı taşıdır. Bu dönüşümde filtreler 2x2, 3x3, 5x5 gibidir ve katmanın ayrılmaz bir parçası olmaktadır. Evrişim işlemi, filtrenin giriş görüntüsü üzerinde kaydırılmasıyla gerçekleştirilir. Her konumda, eleman bazında matris çarpımı yapılmaktadır. Ardından çarpım aralığında kümülatif bir toplam gelir. Her evrişim işleminden sonra, CNN görüntü hakkında biraz daha öğrenir. Kenarları öğrenerek başlar, ardından bir sonraki evrişimde şekilleri ve ardından görüntünün özelliklerini öğrenirse aktivasyon haritasını çıkarır. Evrişim işlemi sırasında, filtre boyutu ve filtre sayısı değişebilir. Aşağıdaki görsel Şekil 2.6'da gösterildiği üzere iki boyutlu görsel 3x3'lük bir filtre uygulandığında üç kanallı (RGB) ve üç boyutlu bir görüntünün evrişim işlemi kullanılarak 3x3'lük kenar filtresi kullanılarak nasıl dönüştüğü gösterilmektedir (Kar, 2020:87).



Şekil 2.6. 2D görselin 3D'ye dönüşümü

Kaynak: (Kar, 2020:87).

Buraya kadar bir dijital verinin ağa giriş aşamasındaki ilerleyişi açıklanmıştır. Bir çıktı hacminin boyutunu kontrol eden üç parametre: derinlik (depth), adım (stride) ve sıfır dolgu boyutu (zero-padding) 'dur.

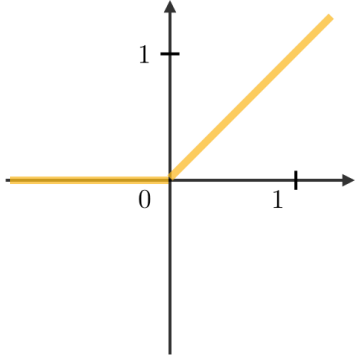
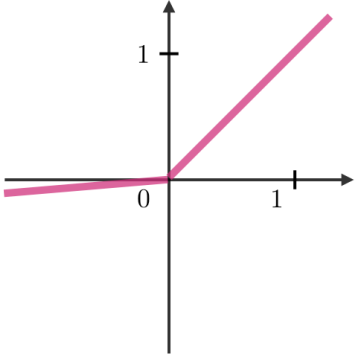
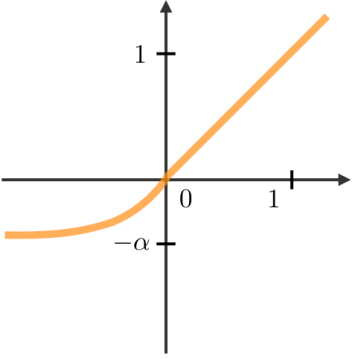
Derinlik: Bir çıktı hacminin derinliği, konvolüsyon katmanındaki giriş hacminin yerel bir bölgesine yerleşen filtrelerin sayısını kontrol eder. Her filtre, yönlendirilmiş kenarların veya lekelerin veya rengin varlığında 'etkinleşen' bir etkinleştirme haritası üretir. Belirli bir konvolüsyon katmanı için aktivasyon haritasının derinliği K veya sadece mevcut katmanda öğrenilen filtrelerin sayısı olacaktır. Girişin aynı (x, y) konumunu gösteren filtreler kümesine derinlik sütunu denir.

Adım: Sadece filtrenin boyutunu değiştirerek girdi hacimlerinin uzamsal boyutlarını azaltmak için evrişim katmanlarının nasıl kullanılabileceğini görebiliriz. Çıkış verisini ekileyen ve evrişim için ağırlık matrisi olan filtreyi görüntü üzerinde ayarlanmış alana piksellik adımlarla ya da daha büyük adımlarla kaydıracağının bilgisini verir.

Sıfır Dolgu Boyutu: Konvolüsyon katmanında verinin boyutu üzerinde üzerinde oluşan büyütülme işlemlerinden sonra uzaysal boyutunda oluşacak olan küçülmeyi önlemek amacıyla bu yerlere sıfır koyarak boyutu korumayı amaçlamaktadır.

2.2.4.2. Aktivasyon katmanı (Activation layer)

Aktivasyon katmanları teknik olarak 'katman' değildir. Bir aktivasyon katmanı içinde hiçbir parametre veya ağırlık öğrenilmemektedir. Konvolüsyon katmanından hemen sonra özellik haritası çıkardığı için ağ mimarilerinde gösterilmemektedir. Aktivasyon katmanı, bir girdiyi 3 boyutuyla kabul eder ve verilen aktivasyon fonksiyonunu uygular. Aktivasyon fonksiyonu eleman bazında uygulandığından, aktivasyon katmanının çıktısı her zaman girdi boyutu ile aynıdır. Bazı önemli aktivasyon fonksiyonları: *RELU*, *Sızıntılı RELU* ve *ELU* ve Tablo 2.1'de gösterilmektedir.

RELU	SIZINTILI RELU	ELU
$g(z) = \max(0, z)$	$g(z) = \max(\epsilon z, z),$ $\epsilon \ll 1$	$g(z) = \max(\alpha(e^z - 1)z),$ $\alpha \ll 1$
		

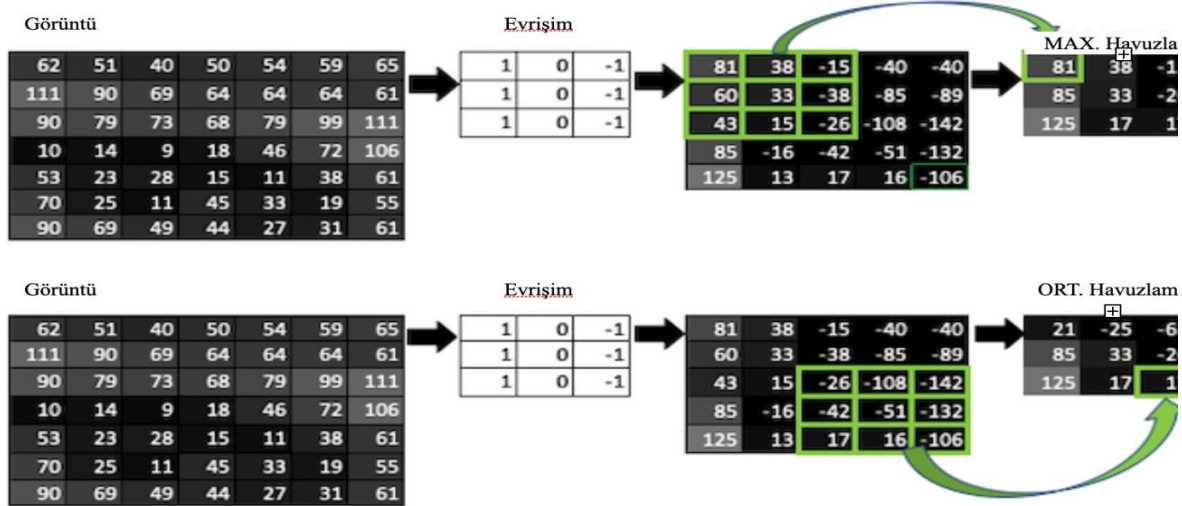
Tablo 2.1. Aktivasyon Fonksiyonları

Kaynak: (Amidi, 2020).

2.2.4.3. Havuzlama katmanı (Pooling layer)

Havuzlama, evrişimden sonraki işlemdir. Ağdaki parametre ve hesaplama miktarını azaltmak için gösterimin uzamsal boyutunu aşamalı olarak azaltmak ve dolayısıyla fazla uydurmayı da kontrol etmektir. Havuzlama Katmanı, girdinin her derinlik diliminde bağımsız olarak çalışır ve işlemlerini kullanarak onu uzamsal olarak yeniden boyutlandırır (Standford,

2020). En yaygın iki havuzlama türü şunlardır: Maksimum havuzlama ve Ortalama havuzlamadır. Maksimum havuzlamayla, pencereyi özellik haritasının üzerine kaydırıp pencerenin maksimum değerini alırken, ortalama havuzlamayla, penceredeki ortalama değeri alınır. Evrişim ve havuz katmanları birlikte, özellik çıkarma görevini yerine getirir. Şekil 2.7’de maksimum ve ortalama havuzlama işlemlerini gösterilmektedir (Kar, 2020:90).



Şekil 2.7. 7x7’lik filtreler ile havuzlama çeşitlerinin gösterimi

Kaynak: (Kar, 2020:90).

2.2.4.4. Tam bağlı katman (Fully connected layer)

Yoğun katmanlar olarak da adlandırılan tam bağlantılı katmanlar, ağırlık ve bias uygulayarak mevcut katmandan bağlı nöronu önceki katmandan her bir nörona bağlar. Ağırlık ve sapma vektörü olarak adlandırılır ve aşağıdaki denklemle temsil edilebilir:

$$\begin{bmatrix} w_{11} & w_{12} & w_{13} \\ w_{21} & w_{22} & w_{23} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} + \begin{bmatrix} b_1 \\ b_2 \end{bmatrix} = \begin{bmatrix} y_1 \\ y_2 \end{bmatrix} \quad (2.1)$$


2.2.4.5. Yığın normalleştirme (Batch normalization)

“Yığın normalleştirme derin sinir ağlarındaki yeniden merkezleme ve yeniden ölçeklendirme yoluyla katmanların girdilerinin normalleştirilmesi yoluyla yapay sinir ağlarını daha hızlı ve daha kararlı hale getirmek için kullanılan bir yöntemdir“ (Musaev, M. vd., 2019:1-9). Derin öğrenme gibi yoğun sinir ağlarına sahip yapılarda çok tercih edilen bir işlemdir. Herhangi bir katmana 0’a ortalanmış ve 1 ile 0 arasında değerlere sahip veriler vermemizi sağlar (Ioffe S. vd., 2015:3-7).

2.2.4.6. Bırakma katmanı (Dropout layer)

Büyük verilerle eğitim işlemi yapıldığı zamanlarda ağ içinde zamanla ezberleme meydana gelir. Ağın ezberlemesinin önüne geçmek için bırakma katman kullanılır (Srivastava

vd., 2014:1930-1933). Temel mantığı Şekil 2.8'te gösterildiği gibi ağda bulunan bazı nöronların kaldırılması işlemidir.




Şekil2.8.² Sol: Bir sinir ağının herhangi bir kesinti olmaksızın tam bağlı iki katmanı.

Sağ: Bağlantıların %50'sini düşürdükten sonra aynı iki katman.

2.3 Transfer Öğrenme

Bir CNN mimarisi, içerisindeki her evrişim katmanından sonra RELU katmanı takip eder ardından havuzlama katmanı ve böyle devam eden katmanlardan oluşmaktadır. Dijital görüntüler ağda ilerledikçe boyut olarak küçülerek ilerler ancak aynı zamanda da katmanlarda ilerledikçe CNN ağının derinliği artmaktadır. Böylece özellik haritasında ki ayrıntılar arttıkça özellik haritasında özelleşmektedir. Tam bağlantılı katmanlardan oluşan düzenli bir ileri beslemeli sinir ağı eklenir ve son katmanda SOFTMAX katmanı ile ağın tahmini çıktısı elde edilir ve Şekil 2.9 'daki gibi bir ağ oluşur.



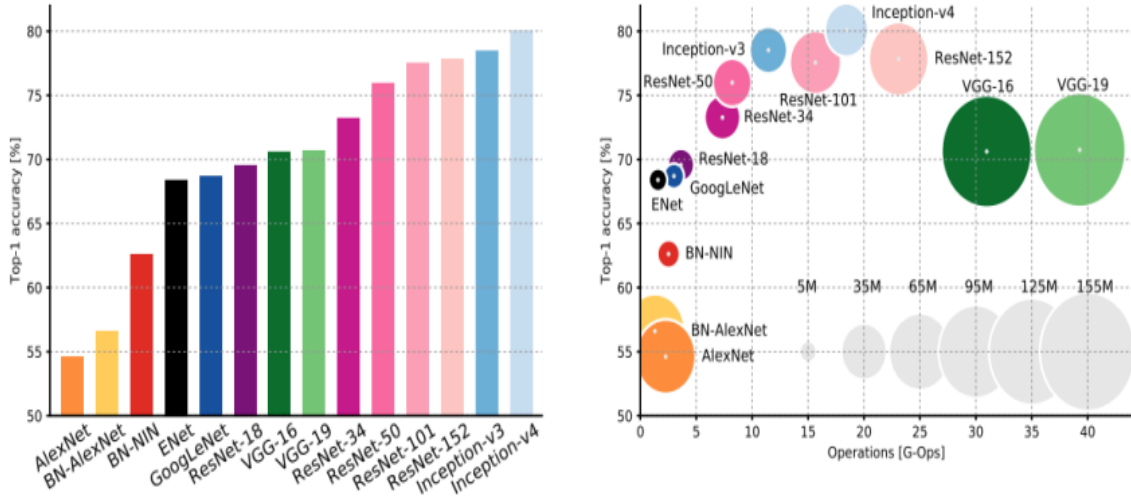
Şekil 2.9. CNN Mimarisi

Kaynak: (Kar, 2020:174).

Transfer öğrenimi problem çözmede elde edilen bilgiyi korumaya ve bunu diğer ilgili problemleri uygulamaya odaklanan bir makine öğrenimi araştırma alanıdır. Örneğin bir gemi tanımayı öğrenene dek elde edilen bilgiler sandal tanımaya uygulanabilir. Bu alandaki çalışmaların öğrenmede anlamasına ilişkin uzun psikolojik literatür tarihi ile bir ilgisi vardır, ancak ikisi arasındaki resmi ilişki sınırlıdır. Transfer öğrenimi ve alan uyarlaması, bir ortamda

²Birçok çalışmadan edilen bilgiler ve veriler doğrultusunda özgün hazırlanmış 'Bırakma Katmanı' hakkında görsel yaklaşım.

öğrenilenlerin başka bir ortamda genellemeyi geliştirmek için kullanıldığı durumu ifade eder (Goodfellow vd., 2016:526). Transfer öğrenimi içerisinde birçok popüler mimari barındırmaktadır. Bunlar Şekil 2.10 'da gösterilmektedir.



Şekil 2.10. Transfer Öğrenme Mimarileri % 'lik başarımları

Kaynak: (Canziani vd., 2016:2).

Tezde verilen çalışmada bitki yapraklarından bitki hastalıkları tanıma problemi için transfer öğrenimi kullanmak diğer bir inceleme konusu olarak verilmiştir. Çalışmada kullanılan transfer öğrenme mimarileri Vgg-19, Vgg-16, ResNet50, DenseNet, Inception V3, GoogLeNet'tir.

2.3.1. Transfer öğrenme mimarileri

2.3.1.1. Vgg-19 ve Vgg-16

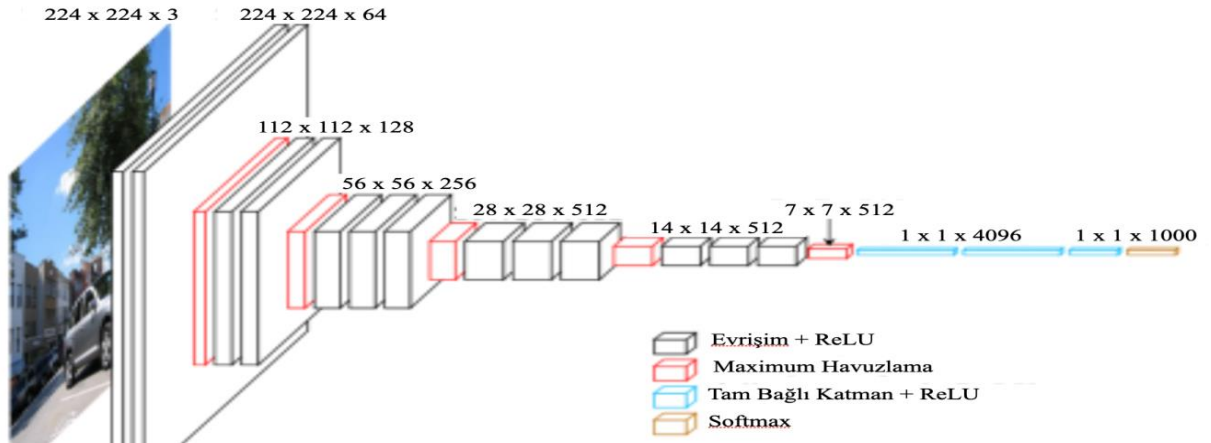
K. Simonyan ve A. Zisserman tarafından Oxford üniversitesinde “*Görsel Geometri Klubü*” tarafından yayımlanmış olan “*Very Deep Convolutional Networks for Large-Scale Image Recognition*” adlı araştırma makalesinde 14 Milyon görüntüden ve 1000 sınıflandırmadan oluşan veri setinde ImageNet 'in yaptığı yarışmada test değerleriyle ilk beş model arasına girerek %92 ilk bir doğruluk oranı sağlamışlardır (Simonyan ve A. Zisserman, 2015). CNN mimarisi katman konfigürasyonlarını, Ciresan ve diğerlerinden esinlenerek aynı prensipler kullanılarak tasarlamışlardır (Krizhevsky vd., 2012). Şekil 2.11'de gösterildiği gibi Vgg mimarisinde kullanılan giriş görüntüleri 224×224 RGB 'dir. Toplam 47 katmandan oluşmaktadır. Modelin ilerleyişi yapılan tek ön işleme, her görsel verinin eğitim setinde hesaplanan ortalama RGB değerinden yani her pikselden çıkarılmaktadır. Görüntü 3×3 boyutlu filtrelerle kullanılarak evrişim katmanlarından geçirilir. Uzamsal havuzlama, dönüşümlerin bir kısmını takip eden beş maksimum havuzlama katmanı tarafından gerçekleştirilir. Katmanlar içerisinde tüm evrişim katmanlarını maksimum havuzlama

katmanı izlememektedir. Maksimum havuzlama, 2x2 piksellik bir pencere üzerinde gerçekleştirilir. 3 tam bağlantılı katmandan sonra Softmax katmanı ile sınıflandırma sonuçları elde edilmektedir. Model konfigürasyon görüntüsü Şekil 2.12’de gösterilmektedir (Simonyan ve A. Zisserman, 2015:2-5). Vgg mimarisinin Vgg-16 ve Vgg-19 versiyonları mimari üzerinde değişikliklerle sağlanmaktadır. Küçük boyutlu filtreler, Ciresan ve arkadaşları tarafından 2011 yılında kullanılsa da ağ derinlikleri Vgg kadar derin olsa da ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ILSVRC) veri setleri üzerinde denenmemiştir. Aynı zamanda GoodFellow ve arkadaşlarının 2014 yılında yaptıkları 11 katmanlı sokak numaraları tanıma çalışmasında da CNN’de derinliğin arttıkça performansın artacağını söylemişlerdir (GoodFellow vd., 2014). “Ağ topolojileri Vgg den daha karmaşıktır ve özellik haritalarının uzamsal çözünürlüğü, hesaplama miktarını azaltmak için ilk katmanlarda daha agresif bir şekilde azaltılmaktadır” (Simonyan ve A. Zisserman, 2015:3-6).

ConvNet Yapılandırma					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
Veri Girişi (224 x 224 RGB Görüntü)					
conv3-64	conv3-64 LRN	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
Maximum Havuzlama					
conv3-128	conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
Maximum Havuzlama					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 conv1-256	conv3-256 conv3-256 conv3-256	conv3-256 conv3-256 conv3-256 conv3-256
Maximum Havuzlama					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
Maximum Havuzlama					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
Maximum Havuzlama					
FC- 4096					
FC- 4096					
FC- 1000					
Softmax					

Şekil 2.11. Konfigürasyonların derinliği, daha fazla katman eklendikçe soldan (A) sağa (E) doğru artar.

Kaynak: (Simonyanve A. Zisserman, 2015:3).



Şekil 2.12. 224x224 RGB Görüntünün ağ içine girişi

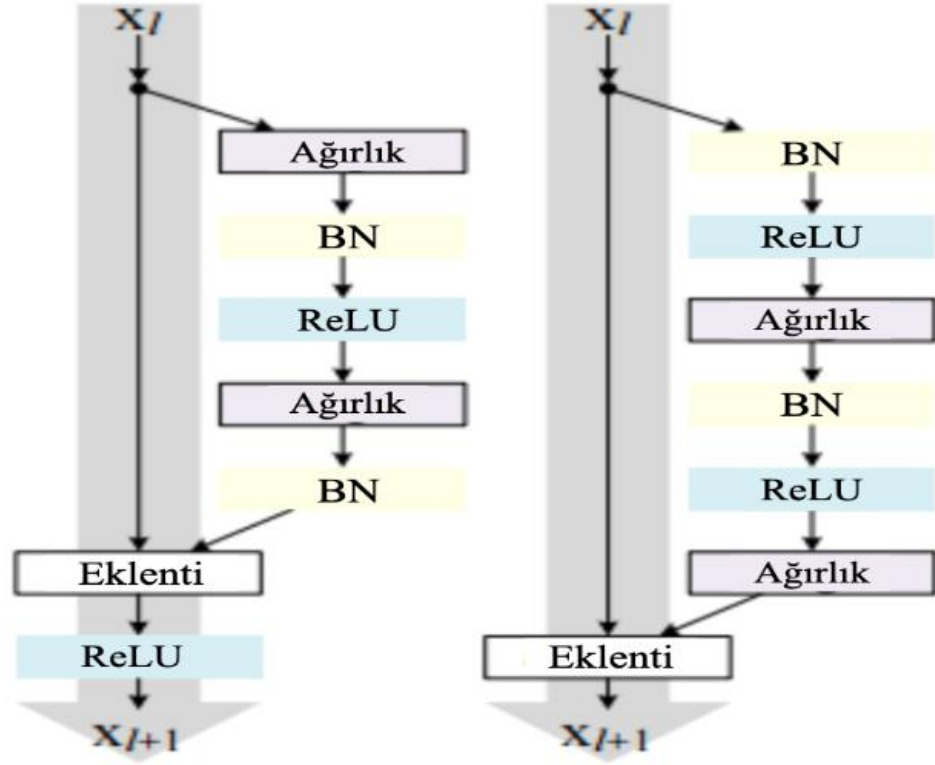
Kaynak: (ichi.pro, 2021).

2.3.1.2. ResNet50

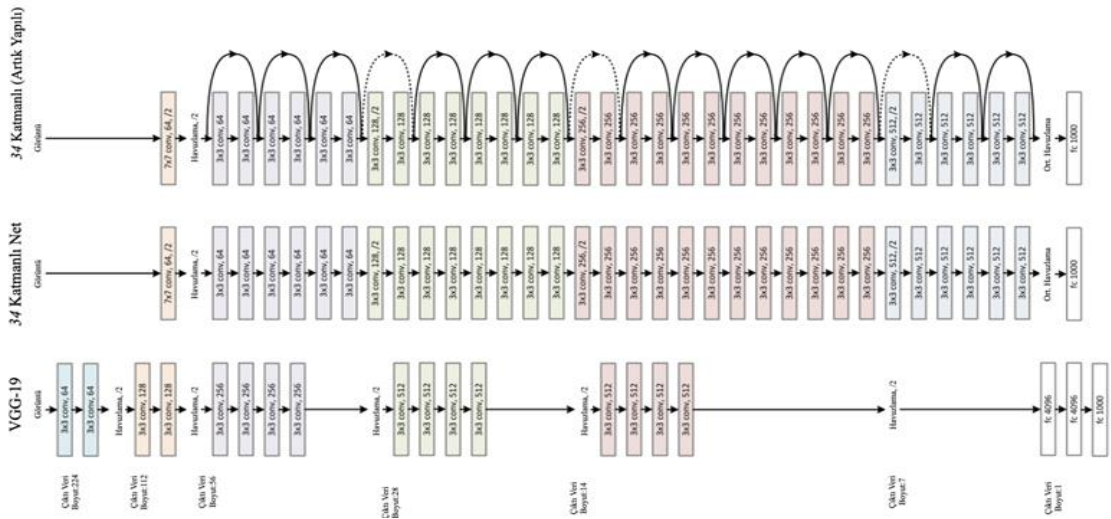
Artık Ağ anlamına gelen “Residual Neural Network” ismini almaktadır. Vgg-19 mimarisinden esinlenerek hazırlanmıştır. Microsoft Research Asia 'dan diğerleri tarafından önerilen bir ağ yapısıdır ve ILSVRC-2015 sınıflandırma görevinde birinci olmuştur. Evrişimli katmanlar çoğunlukla 3x3 filtreye sahiptir ve iki basit tasarım kuralı izler:

- Aynı çıktı özelliği eşleme boyutu için katmanlar aynı sayıda filtreye sahiptir
- Özellik eşleme boyutu yarıya indirilirse, katman başına zaman karmaşıklığını korumak için filtre sayısı iki katına çıkar (He ve diğerleri, 2016:770-773).

ResNet50 mimarisi ise 50 ağırlık katmanında oluşmaktadır. ResNet, hem Vgg-16 hem de Vgg-19'dan çok daha derin olsa da, ResNet50 için model boyutunu 102 MB'a indiren tam bağlantılı katmanlar yerine global ortalama havuz kullanımı nedeniyle model boyutu aslında önemli ölçüde daha küçüktür (Rosebrock, 2017:279). Teoride CNN ağına katmanlar istiflendikçe hata oranının azalması beklenmektedir (Goodfellow vd., 2014:527). Fakat katman sayısının artması pratik olarak gerçekleştirildiğinde eğitimde hata oranının artmak yerine azaldığı deneyimlenmiştir. Burdan yola çıkan ResNet artık bloklardan oluşturuldu ve yapı taşı kabul edildi. Artık blok'ta, x girişi doğrudan ağın çıkışına eklenir, yani $F(x) + x$ ve bu yol atlama bağlantısı veya kısayol olarak bilinir Şekil 2.13'te gösterilmiştir. Şekil 2.14'te ImageNet tarafından Vgg-19 ve artık modül bloklarının kullanılarak hazırlanan ağ yapısı gösterilmektedir.



Şekil 2.13. Sol: Orijinal Artık Modülü, Sağ: Ön Aktivasyonlu Orijinal Artık Modülü
Kaynak: (Rosebrock, 2017:279).




Şekil 2.14. ImageNet için örnek mimari. Sol: Referans olarak Vgg-19 modeli Orta: 34 parametre katmanına sahip düz bir ağ.Sağda: 34 parametre katmanına sahip artık bir ağ.

Kaynak: (He vd., 2016:773).

2.3.1.3. Inception V3 ve GoogleNet

Lin ve diğerleri 2013'te "Network in Network" yani Ağ içinde Ağ yaklaşımını ortaya atmışlardır. İçerisinde yüksek sayıda evrişim katmanları bulunan bu yapıda doğrusal olan


filtrelere doğrusal olmayan aktivasyon fonksiyonları kullanarak oluşturulan yeni bir yaklaşım olarak öne sürülmüştür (Lin vd., 2013:2). Bu yaklaşımda normal konvolüsyon ağlarının da ve havuzlama katmanların değişikliğe giderek yeni bir model sunulmuştur. Eğitime giren verilerin ağ üzerinde ki ilk adımlarında ağ bilgiye sahip olmamaktadır. “İki yaklaşım geliştirilmektedir. Birincisi radyal tabanlı ve çok katmanlı algılayıcıdan oluşan fonksiyon tahminleyicisidir. İkincisi de özniteliğin kullanımını çok katmanlı algılayıcı ile daha derin bir model oluşturmaktır” (Lin ve diğerleri 2013:2-4). Lineer konvolüsyon katmanı ile Mlpconv katmanı Şekil 2.15 ve 2.16 ’da gösterilmektedir.



Şekil 2.15. a. Lineer Konvolüsyon Katmanı, b. Mlpconv Katmanı

Kaynak: (Lin vd., 2014:2).


Ağ içinde Ağ modelin de sunulan yaklaşımın mlpconv katmanlarının ağ içerisinde kullanımı Şekil 3.14’te gösterilmektedir.



Şekil 2.16. Kümelenmiş üç Mlpconv katmanı ve bir küresel ortalama havuzlama katmanı

Kaynak: (Lin vd., 2014:3).

Inception modüllerinden oluşan Googlenet mimarisi'nin göze çarpan özelliği, seyreklik ve çok ölçekli bilgileri tek bir blokta tanıtan bir başlangıç katmanıdır. İşlevsel olarak büyük bir ağ içindeki küçük bir ağa eşdeğerdir. GoogLeNet'in filtreleri ve ağırlıkları, hata geri yayılımı yoluyla yinelemeli olarak tanımlanır. Hata geri yayılım yaklaşımı, son katmanı



Şekil 2.19. DenseNet mimarisi içerisinde Yoğun Blok ve Geçiş Blokları

Kaynak: (Ruiz P, 2021).

2.3.2. Transfer öğrenmede İnce Ayar (Fine-Tuning)

Standart bir makine öğrenimi sınıflandırıcısı olan Ölçek Değişmez Özellik Dönüşümü (SIFT), Yönlendirilmiş Gradyanların Histogramı (HOG), Yerel İkili Desenler (LBP) vb. gibi öğrenmeyi aktarmaya yönelik yaklaşımlarla özellik çıkarımı yapmaktadırlar. Bununla birlikte, özellik çıkarma yönteminden gerçekten daha iyi performans gösterebilen başka bir transfer öğrenme türü daha vardır. Bu yöntemine ince ayar (fine-tuning) denir ve ağ üzerinde çeşitli ayarlamalar yapılarak oluşturulur.

İnce ayar uygulamak, başlangıçta eğitilmemiş sınıfları ağın tanınması için önceden eğitilmiş ağları kullanmamıza olanak tanır. Bu yöntem kullanılarak, özellik çıkarımı yoluyla transfer öğrenme yönteminden daha yüksek doğruluklu sonuçlar elde edilir. Önceden eğitilmiş bir CNN mimarisinde örneğin Vgg transfer öğrenme mimarisinde tam bağlı katmanların tahmin bölümü yapan katmanı kısıtlanarak ağın özellik çıkarma için kullanılan ağırlıkları yeni veriler için eğitilmiş olur. “Kısıtlanan ağın altındaki katmanlarda ağırlıklar güncellenemez ve dondurulmuş olurlar. Böylece ağ çok küçük bir öğrenme oranı kullanarak eğitilir ve yeni tam bağlı katmanların ağda ince ayar kullanılarak öğrenilen evrişim katmanlarından kalıpları öğrenilebilir hale gelmesi sağlanır” (Rosebrock A., 2017:186-190). Ağ içinde eğitilememiş olan parametrelerin eğitilebilir hale getirilmesine olanak tanır.

3. DENEYSEL ÇALIŞMALAR VE BULGULAR

Çalışmada bitki hastalıkları teşhisi üzerine derin öğrenme uygulaması iki aşamadan oluşmaktadır. Birinci aşamada veri setini araştırılması ve uygulanacak çalışma ortamların belirlenmesidir. İkinci aşamada ise veri setini çeşitli hazırlık aşamalarının ayarlanması ve çeşitli programlama dilleri için etkileşimli bir ortam sağlayan açık kaynak kodlu bir program olan Jupyter Notebook çalışma ortamında verilerin Python yazılım dili ve Tensorflow ve Keras kütüphaneleri kullanılarak işlenmesine dayanmaktadır.









Bu bölümde sırasıyla uygulamanın amacı, veri seti, veri dönüştürme, model oluşturma ve çeşitlendirme ve model seçimleri hakkında bilgiler verilecektir.

3.1. Uygulamanın Amacı

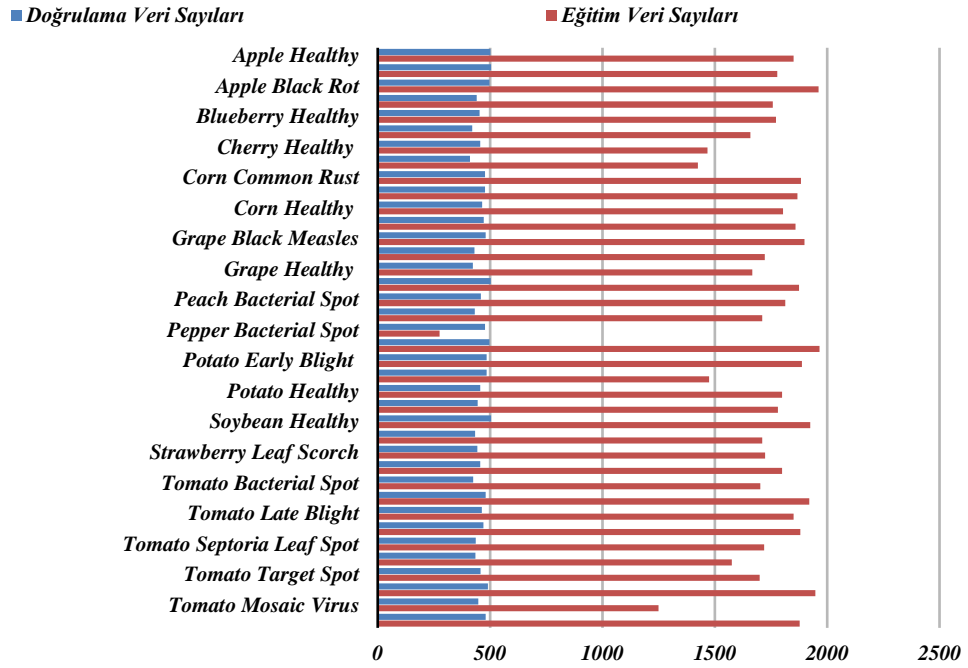
Toplumumuzda ve dünyada insan sağlığı açısından önemli olan vücudun ihtiyacı olan besin öğelerini karşılanmasında bitkiler önemli bir yer teşkil etmektedir. Ziraî üretimde bitki hastalıklarının hızlı bir şekilde tanınmasını sağlayacak ve kimyevi haşere ilaçlarının kullanımında karar verme sürecini hızlandıracak otonom bir tespit sistemi ortaya koymak önemlidir. Bu çalışmada, makine öğrenmesi yöntemlerinin bir alt bölümü olan derin evrişimli sinir ağı modeli oluşturma çalışması ve transfer öğrenme yapılarak yüksek doğruluklu 14 farklı tür ve 38 çeşit hastalıklı veya sağlıklı bitki yaprağının teşhisi amaçlanmıştır.

3.2. Veri Seti

Bu New Plant Disease adlı veri seti “Veri Bilimi Eviniz” sloganıyla ortaya çıkmış bir platform olan Kaggle sitesinden alınmıştır. Kullanılan veri seti 14 farklı bitki yaprağına ait bunlar; yaban mersini, vişne, mısır, üzüm, portakal, şeftali, biber, patates, çilek, soya, domates, ahududu, kabak ve elma ve içerisinde 38 çeşitli hastalık dosyalarıyla beraber sağlıklı dosyaları da bulunmaktadır. Görüntüler 256x256 boyutlarında ve toplam 83.107 JPG görüntüden oluşmaktadır. Veri setinde test, eğitim ve doğrulama dosyaları ayrı dizinlerde bulunmaktadır. Eğitim dosyasında 65.535, doğrulama dosyasında 17.572 ve tahminleme yapılması amacıyla 33 test verisi bulunmaktadır. Veri setine ait 8 görsel Şekil 3.1 ve Tablo 3.1’de gösterilmektedir.

			
a. Elma sedir-elma pası mantar patojeni	b. Mısır koma pası mantar patojeni	c. Domates erken yanıklık mantar patojeni	d. Patates erken yanıklık mantar patojeni
			
e. Yaban mersini sağlıklı yaprak	f. Şeftali bakteriyel leke patojeni	g. Portakal bakteri patojeni (CitrusHuanglongbing)	h. Üzüm Kara Çürük Mantar patojeni

Şekil 3.1. Veri setine ait 8 görsel

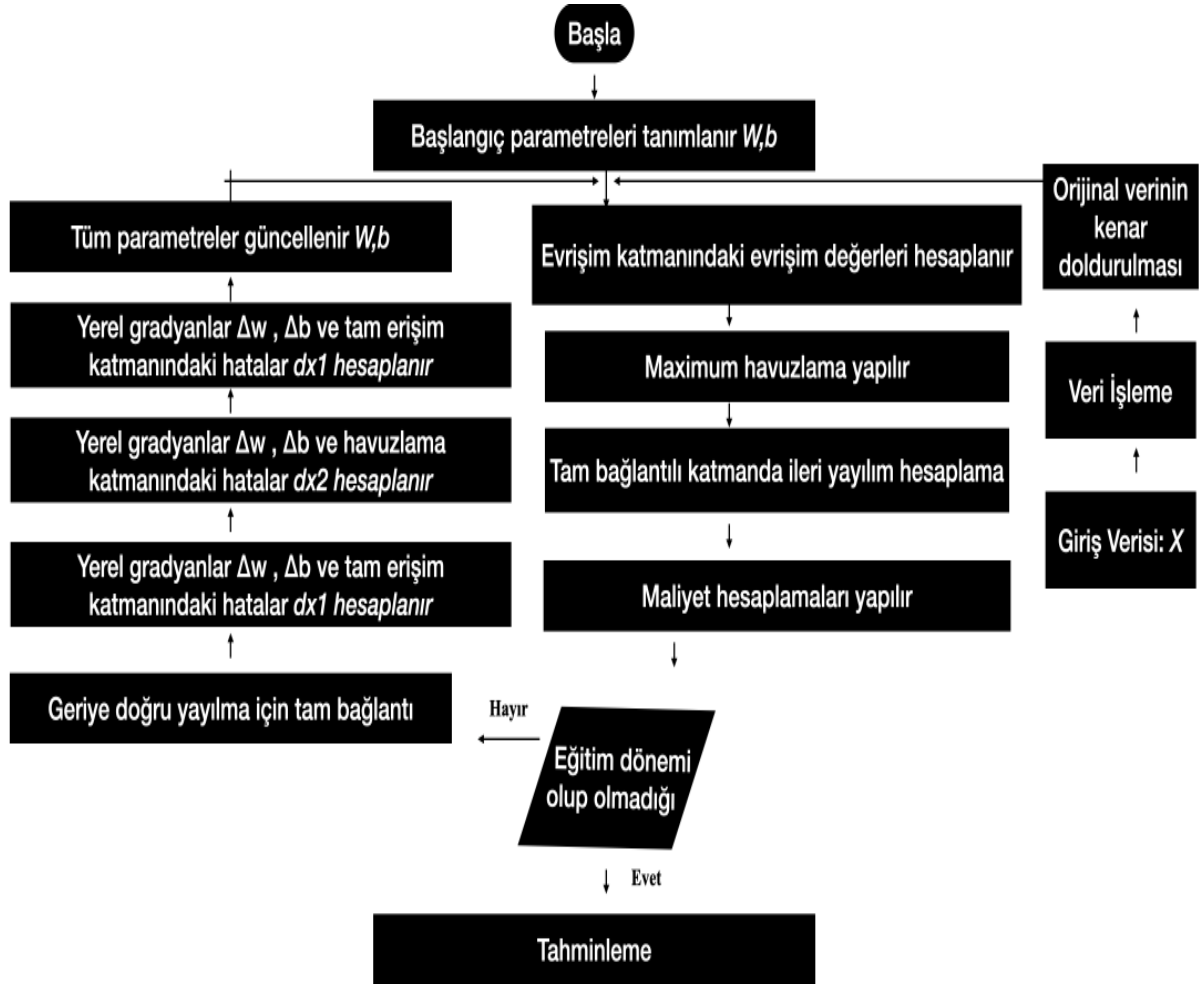


Tablo 3.1. Veri setine ait veri sayıları grafiği

3.3 Ağ Yapısı

CNN, insan sesi tanıma üzerine doğal dil işleme, insan sesi tanıma ile konuşma tanıma, bilgisayarların insan gibi görmesi prensibiyle nesne ve yüz tanıma gibi birçok alanda ilerlemelere neden olan bir algoritmadır. Çalışmada bitki hastalıkları teşhisi üzerine CNN mimari yapısı kullanarak nesne tanıma yapılmıştır. CNN yapımız oluşturulurken dikkat ettiğimiz ağ yapısı özelliklerinden bahsedilecektir.

CNN yapısı özellik çıkarımı için evrişim ve havuzlama katmanlarından oluşur. Tam bağlı katmanlar sınıflandırıcı olarak işlevlenmiştir. Geri Beslemeli sinir ağları esas olarak özellikleri ağ üzerinden belirli değerlere eşlerken, evrişimli sinir ağları önce sinyalleri özelliklere dönüştürür ve ardından özellikleri belirli bir hedef değere eşler. Ağ yapısının akış diyagramı Şekil 3.2’de gösterilmektedir.



Şekil 3.2. CNN Algoritması Akış Diyagramı

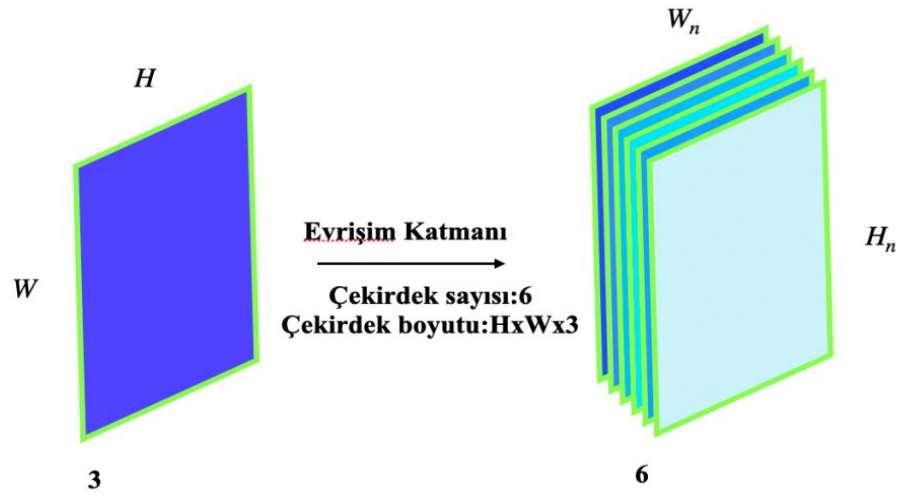
Evrişim Katmanı: Ağa giren verinin RGB değerler taşıyan bir veri olduğu dikkate alındığı zaman RGB verilerin altı erişim çekirdeği olduğu varsayılmaktadır (LeCun ve diğerleri, 2015). Ağa giren veri 3 boyutlu bir matristir. Matris içerisinde yükseklik (W),

genişlik (H) ve 3 değerini barındırır. Her bir evrişim çekirdeği, evrişim katmanı ile ilişkili olup içerisinde üç boyutlu matrisi barındırmaktadır. Bu katmanlar eşik değeri olarak b bulundurulur. Her bir katman için özellik çıkarımı yapıldıktan sonra giriş verisi olan resme ait boyutlar değişmektedir. Giriş verisi X olarak kabul edildiği zaman bu değişimlerin denklemleri aşağı da gösterilmektedir. Şekil 3.3'te giriş verisinin erişim katmanları süreci gösterilmektedir.

$$X_n = X \times W = \sum_{k=1}^3 (X_k \times W_k) + b \quad (3.1)$$

$$H_n = (H - h + 2 \times P)/S + 1 \quad (3.2)$$

$$W_n = (W - w + 2 \times P + 1)/S \quad (3.3)$$



Şekil 3.3. Giriş verisi X 'in evrişim katmanları süreci

Havuzlama Katmanı: Evrişim katmanından geçen veri havuzlama katmanına gelir. Giriş tensörü sıkıştırılarak giriş verilerinin boyutunu küçültülür. Maksimum havuzlama, bu işleme girmiş eleman değeri olarak karşılık gelen $n \times n$ alanının maksimum değeri almasına dayanır. Bu işlemin dayandığı fonksiyonel denklem 3.4, 3.5, 3.6 'da gösterilmektedir. İşlem süreci Şekil 3.4'te gösterilmiştir.

$$W_p = (W - f)/s + 1 \quad (3.4)$$

$$H_p = (H - f)/s + 1 \quad (3.5)$$

$$D_p = D \quad (3.6)$$




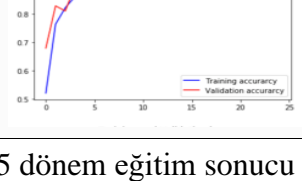
değerler Tablo 3.2 ve 3.3'te ve kullanılan parametre değerleri de Tablo 3.4 'de gösterilmektedir. Bitki yapraklarının ağ içine girdiğinde filtrelerden geçerken ki örnek görseli Şekil 3.6'da gösterilmektedir.

Bitki Yaprak Türü	Çeşit Sayısı	Eğitim Görüntü Sayısı (%80)	Test Görüntü Sayısı (%20)	Toplam Görüntü Sayısı	Doğruluk Oranı
Elma	4	7771	1943	9714	%99.53
Mısır	4	7316	1829	9145	%97.97
Üzüm	4	7222	1805	9027	%99.44
Domates	10	18345	4585	22930	%96.88

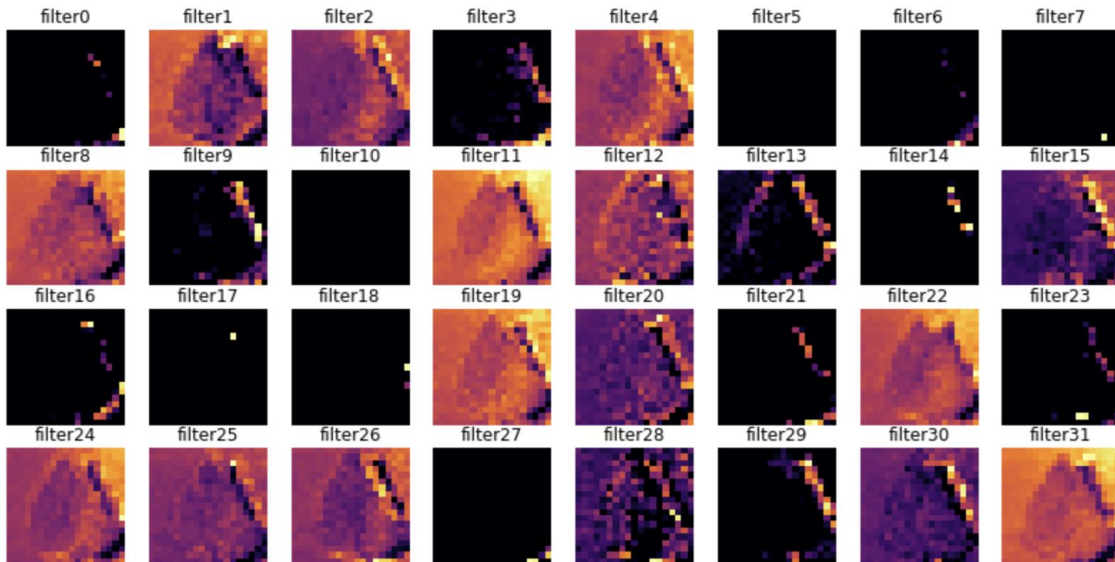
Tablo 3.2. Yüksek sayıda veri içeren tek çeşide ait hastalıklı ve sağlıklı yaprak türleri ve 'Yeni Bitki Yaprığı Hastalığı CNN Mimarisi' ile elde edilen değerler.

PARAMETRELER	DEĞERLER
BATCH SİZE	32
OPTİMİZASYON	ADAM OPT.
DÖNEM	25
EGİTİLEBİLİR PARAMETRELER	1.163.978

Tablo 3.3. 'Yeni Bitki Yaprığı Hastalığı CNN Mimarisi' ile kullanılan başlangıç parametreleri ve atanmış değerler.

BİTKİ YAPRAĞI	5 DÖNEM Doğruluğu	15 DÖNEM Doğruluğu	25 DÖNEM Doğruluğu	Doğruluk Grafikleri
ELMA	0.9844	0.9688	0.9911	
MISIR	0.9441	0.9567	0.9797	
ÜZÜM	0.9704	0.9922	0.9944	
DOMATES	0.8601	0.9480	0.9688	

Tablo 3.4. Elma, Mısır, Uzüm ve Domates yaprakları 5,10,15 dönem eğitim sonucu ve görsel grafikleri.



Şekil 3.6. Örnek giriş sağlıklı domates yaprağı verisi için filtrelerden geçerken oluşan görüntüleri

Yeni Bitki Yaprağı Hastalığı CNN Mimarisi” tüm veri setine uygulanması veri setimizdeki dört büyük yaprak çeşidi için oluşturulan yeni CNN mimarisi, tüm verisetine uygulandığında elde edilen sonuç yaklaşık %92 civarında olmuştur. Doğrulukta bu azalma sonuçlandırılmak istenirse varılan sonuçlardan biri ele alınan veri setindeki yaprak türü ve hastalık çeşitliliği arttıkça modelin doğruluğu düşmektedir. Şekil 3.7’de elde edilen 6 katmanlı CNN yapısının %92’lik eğitim sonucu veri setinden rastgele seçilmiş hastalıklı ve sağlıklı elma, mısır, patates, domates yaprakları tahmin sonuçları bulunmaktadır.

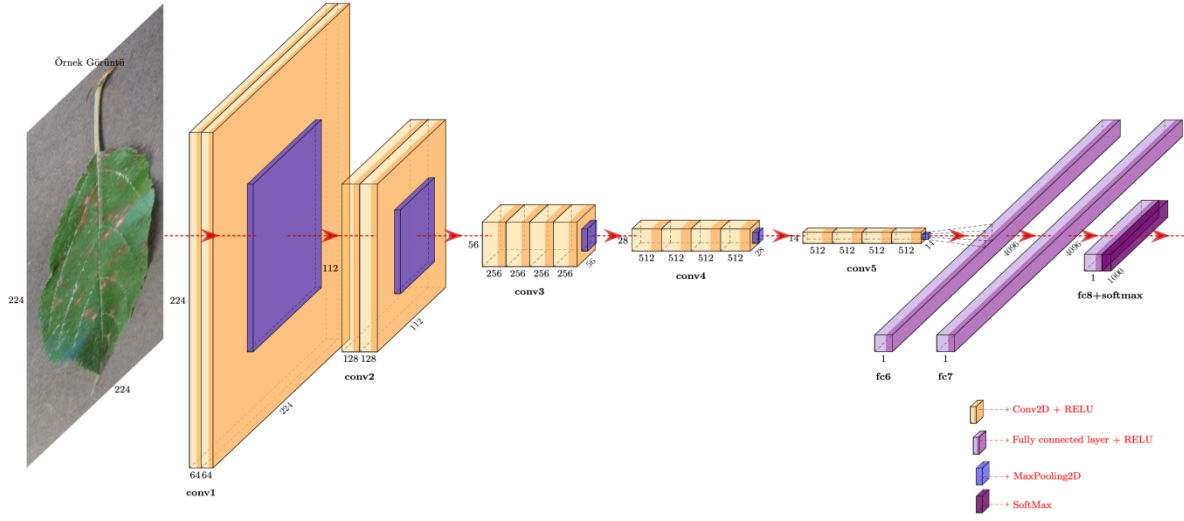
```
Tüm veriseti Modeli'nin Tahmin Sonuçları:  
Prediction: Apple__Cedar_apple_rust (%99.99)  
Prediction: Corn_(maize)__Cercospora_leaf_spot Gray_leaf_spot (%95.72)  
Prediction: Apple__healthy (%92.39)  
Prediction: Potato__healthy (%95.32)  
Prediction: Tomato__Early_blight (%99.43)  
Prediction: Potato__Early_blight (%100.00)  
Prediction: Potato__Early_blight (%92.54)  
Prediction: Tomato__Tomato_Yellow_Leaf_Curl_Virus (%98.15)  
Prediction: Tomato__healthy (%97.86)  
Prediction: Apple__Apple_scab (%40.69)  
Prediction: Corn_(maize)__Common_rust_ (%99.88)
```

Şekil 3.7. ‘Yeni Bitki Yaprağı Hastalığı CNN Mimarisi’ ile tüm veri seti için tahminleme sonuçları

Tüm veri setinin eğitimi çalışmalarından elde edilen doğruluk değerlerinin tatmin edici düzeyde olmaması sonucunda, çalışmada iki yol izlenmiştir. Birincisi önceden eğitilmiş bir mimari olan Vgg-19 modeli kullanılarak transfer öğrenme yöntemini kullanmak olmuştur. Biliyoruz ki sıfırdan bir sınıflandırıcı model oluşturmak, en azından süreci ve parametre değerlerini belirleyebilmek için transfer öğrenme yöntemi çalışmamızda çıkış yolu gösterecek eylemler arasına girmiştir.

Bu sonuçtan yola çıkarak popüler transfer öğrenme mimarisi olan ve tüm veri seti ile çalışması için Vgg-19 ağında denemeler yapılmıştır. Vgg-19 ağına giriş yapan görüntü boyutlarınının 224x224x3 olup 45 dönem eğitilen veri setimiz 0.8722 ile başladığı doğrulama değerleri ağı parametrelerinde ince ayar yapıldıktan sonra 0.9470 doğrulama oranına sahip olmakla beraber eğitim kümesinde öğrenme oranını 0.61’den 1.00’e (%100) yükselmiş olduğunu gözlemlenmiştir. Kullanılan mimari yapı Şekil 3.8’de gösterilmektedir.

VGG-19 Mimarisi



Şekil 3.8. Bitki yaprağı'nın Vgg-19 Mimarisi

VGG-19 transfer öğrenme mimarisinde 224x224 RGB görüntülerin bütün veri seti ile 45 dönem eğitilen bitki yaprağı hastalık verileri tahmin sonuçlarının görsel verileri Tomato_late_blight için, Tomato_healthy, Tomato_Tomato_yellow_curl_virus, Corn_(maize)_Common_rust_ için elde edilen veriler: %100, %100, %100, %100'dür. Bu değerler transfer öğrenme mimarilerinin doğru çalışma yöntemi kullanılarak çalıştırıldığında ki elde edilen en kayda değer sonuçlar olmakla beraber umut vericidir. Şekil 3.9. 'da ve Tablo 3.5. 'de doğruluk (accuracy) ve kayıp (loss) çalışmanın görsel sonuçları gösterilmiştir.

224*224-> Toplam 45 epochs'un Tahmin Sonuçları

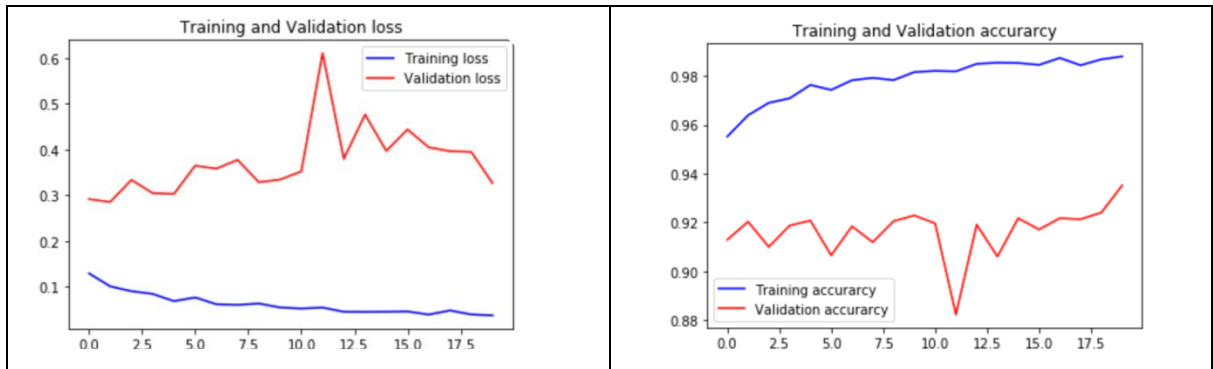
Prediction: Tomato__Late_blight (%100.00)

Prediction: Tomato__healthy (%100.00)

Prediction: Tomato__Tomato_Yellow_Leaf_Curl_Virus (%100.00)

Prediction: Corn_(maize)__Common_rust_ (%100.00)

Şekil 3.9. Vgg-19 Mimarisinde 45 dönem koşturulan verilerin doğruluk tahminleri görseli



Tablo 3.5. Vgg-19 Mimarisinde 45 dönem koşturulan verilerin doğruluk ve kayıp fonksiyon değer görseli

3.3.2. Transfer öğrenme uygulamaları

Transfer öğrenme varolan bir problemin denenen başka yollardan çözüm elde edilerek yaklaşım geliştirme ve çeşitlenmesine sebep olmaktadır. Bitki yaprağı hastalıkları teşhisinde farklı katman ve özelliklere sahip transfer öğrenme mimarileri tüm veri setine uygulaması amaçlanmıştır. Eğitim ve test görüntüleri sabit değerlere sahip olup katman sayısı farklı olan beş derin öğrenme mimarisi üzerinde çalışılmaktadır bunlar; GoogLeNet, 144 katmanlı, Vgg-16, 41 katmanlı, Vgg-19, 47 katmanlı, ResNet50, 177 katmanlı ve DenseNet, 121 katmanlıdır. Her mimarinin kendine ait ince ayarları bulunmaktadır. Bu ince ayarlar yapıldıktan sonra elde edilen sonuçlar Tablo 3.6'da gösterilmektedir.

Kullanılan Algoritma	Katman Sayısı	Girdi Şekli	Eğitim Sayısı (%80)	Test Sayısı (%20)	Toplam Sayısı	Doğruluk Oranı
GoogLeNet	144	224x224x3	66487	16621	83107	%70~
Vgg-16	41	224x224x3	66487	16621	83107	%80
Vgg-19	47	224x224x3	66487	16621	83107	%95
ResNet50	177	224x224x3	66487	16621	83107	%50
DenseNet	121	224x224x3	66487	16621	83107	%43~

Tablo 3.6. Transfer öğrenme mimarileri için elde edilen sonuçlar

4. SONUÇLAR VE ÖNERİLER

Bu çalışmada açık kaynaktan alınan “*New Plant Disease*” isimli yaklaşık 83.107 görüntü içeren veri seti için oluşturduğumuz ‘**Yeni Bitki Yaprağı Hastalığı CNN Mimarisi**’ isimli 6 katmanlı yeni bir CNN mimarisi kullanılarak bitki yaprağı hastalık sınıflandırmasına derin öğrenme yaklaşımı önerilmiştir. Tasarlanan mimarinin katman yapısının hazırlanması kayıp (Loss) fonksiyonu, kategorizasyon bölümlerinde yapılan ayarlar ve bir çok çalışmanın incelenmesi sonucu bu mimariye hızlı ve verimli bir yapı kazandırılmıştır. Yeni CNN mimarisi öncelikle 4 büyük veri kapasitesine sahip alt dizin içerisinde bulunan veri dosyalarında denenmiş ve %96,88 üzerinde başarılar elde edilmiştir. Tüm veri setine uygulandığında ise %92 gibi bir sonuç elde edilmiştir ki bu konuda yapılan diğer çalışmalarla karşılaştırıldığında ciddi bir başarımlı olduğu görüşündeyiz. Tezde yeni bir model mimarisinin oluşturulması, görüntülerin ağa girişindeki vakit kaybının en aza indirilmesi ve CNN ağlarında özellik çıkarımı sırasında ön işlemeye gerek kalmaması gibi kazanımların bu konuya yapılan önemli katkılar olarak görülebilir. Ayrıca çeşitli transfer öğrenme mimarileri kullanılarak elde edilen deneysel çalışmalarının performansları incelenmiştir.

Bitki yaprağı hastalıklarının tespiti, artan veri sayısı ve oluşturulan yeni modeller göz önüne alındığında geliştirilebilir ve sürekli bir çalışma alanıdır. Bu çalışmada öncelikle, ele alınan 14 farklı bitki yaprağına ait 38 çeşit hastalıklı ve sağlıklı bitki yaprağı veri seti sınıflandırma problemi için sıfırdan yeni bir model oluşturmak yerine görüntüler üzerinde çalışılan mimarilerden biri olan Vgg-19 mimarisi kullanılarak transfer öğrenme gerçekleştirilmiştir. Transfer öğrenme yöntemi ile elde edilen ön sonuca ince ayar yapılarak, ADAM optimizasyon yöntemiyle 45 dönem eğitilen veri setinin doğruluğunun %95 civarında olduğu görülmüştür. Daha sonra tüm veri kümesi yerine alt kümeleri üzerinde hızlı sonuç alınabilmesi açısından yeni bir model oluşturulma ve modele ait parametrelerin belirlenmesi çalışmaları yapılmıştır. Çalışmamızda çok farklı denemelerle oluşturulan yeni model ve parametreler kullanılarak veri setindeki yüksek sayıda çeşide sahip elma, mısır, üzüm ve domates yaprağı verileri için ADAM optimizasyon yöntemi ve 25 dönem eğitim ile elde edilen doğruluklar, sırasıyla, %99.53, %97.97, %99.44 ve %96.88 ‘dir. Bu sonuçlar oluşturulan yeni CNN mimarisinin yüksek doğruluklarla ve kısa dönemli eğitimle sonuca ulaştığını açıkça göstermektedir. Daha sonra, bu yeni model kullanılarak 14 farklı bitki yaprağına ait 38 çeşit hastalıklı ve sağlıklı yaprak türü (tüm veri seti) için yapılan eğitimde elde edilen doğruluğun yaklaşık %92 civarında olduğu görülmüştür. Yapılan incelemeler göz önüne alındığında ele alınan veri setindeki yaprak türü ve hastalık çeşitliliği arttıkça

oluřturulan modelin dođruluđu dűřmektedir. Diđer önemli bir sonuç ise özellik çıkarımı için derin evriřimli sinir ađlarında verilere herhangi bir ön iřlem yapılmasına gerek olmamasıdır. Veri seti ham, dođal yapısında ve renkli görüntüler kullanıldıđında bařarım sonuçlarında herhangi bir azalma eđilimi olmadığı görűlműřtür. Dolayısıyla bu konuda yapılacak çalıřmalarda ön iřleme adımlarında kaybedilen zaman yerine veri seti arttırımı ve model mimarisi üzerinde çalıřmaların daha önemli olduđu görűřűndeeyiz.

Transfer öğrenme mimarileri hazır ađlıklara sahip ađ içinde bulunan verinin eđitilmesine dayanmakta ve çeřitli çalıřmalar tarafından önerilmektedir. Bu çalıřmada öncelikle ele alınan Vgg-19 mimarisi haricinde, çalıřma süreç iřlemlerine, mimari türlerine ve katmanlarına göre farklılıklar gösteren Vgg-16, ResNet50, GoogleNet ve DenseNet gibi tranfer öğrenme mimarileri de ele alınmıřtır. Bu mimarilerin ince ayara yapılmaksızın tüm veri seti üzerindeki bařarımlarının ADAM optimizasyonu, *SparseCategoricalCrossEntropy* kayıp fonksiyonu ve 25 dönem eđitimle, sırasıyla, %80, %50, %70, %43 olduđu görűlműřtür. Sonuçlar göstermiřtir ki; Vgg mimarilerinden Vgg-19 sınıflandırmada en iyi sonuç olan %90 dođruluk deđerine sahip iken hemen ardından diđer bir Vgg mimarisi Vgg-16'nın, %80 dođruluk deđerine sahip olduđu görűlműřtür.

Sunulan çalıřma Intel(R) Core (TM) i5-5200U CPU @ 2.20GHz 2.19GHz, 8 GB RAM, 512 GB SSD bellek ve x64 tabanlı kiřisel bilgisayar kullanılarak gerçekteřtirilmiřtir.

KAYNAKÇA

- Altieri, M.,** (2018). *Agroecology: The Science of Sustainable Agriculture*. CRC Press, Endereço.
- Collis J.** *Glossary of Deep Learning: Batch Normalisation*. medium.com. 24 April 2018.
- Goodfellow, I. J., Bulatov, Y., Ibarz, J., Arnoud, S., & Shet, V.** Multi-digit number recognition from street view imagery using deep convolutional neural networks. *In Proc. ICLR*, 2014.
- Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y.** (2016). *Deep learning* (Vol. 1, No.2). Cambridge: MIT press.
- Kar, K.** (2020). *Deep Learning on Images*. *In mastering computer vision with tensorflow: Vol. first* (pp. 83–119). Packt Publishing.
- Müller Andreas C. Guido S.,** (2017). *Intoduction to machine learning with python (1st ed., Vol. 1)*. Oreilly.
- Nabiyev, V. V.** (2012). *Yapay Zekâ: İnsan-Bilgisayar Etkileşimi*. Seçkin Yayıncılık.
- Öztemel, E.** *Yapay Sinir Ağları*. Papatya Yayıncılık Eğitim, 2012.
- Rosebrock, A.** (2017). *Deep Learning for Computer Vision with Python Starter Bundle (1sted., Vol. 1)*. PyimageSearch.
- Turhan, B., & Özbay, Y.** Erken Çocukluk Eğitimi ve Nöroplastisite. *Early Childhood Education and Neuroplasticity*. 58.
- Ashqar, B. A., Abu-Nasser, B. S., & Abu-Naser, S. S.** (2019). Plant seedlings classification using deep learning. *International Journal of Academic Information Systems Research (IJASIR)*. Vol. 3 Issue 1, January – 2019, Pages: 7-14.
- Canziani, A., Paszke, A., & Culurciello, E.** (2016). An analysis of deep neural network models for practical applications. *arXiv preprint arXiv:1605.07678*.
- Fukushima, K.** (1986). A neural network model for selective attention in visual pattern recognition. *Biological Cybernetics*, 55(1), 5-15.
- Hanson, A. M. G. J., Joel, M. G., Joy, A., & Francis, J.** (2017). Plant leaf disease detection using deep learning and convolutional neural network. *International Journal of Engineering Science*, 5324, 2-4.

- Hinton, G. E., & Shallice, T.** (1991). Lesioning an attractor network: Investigations of acquired dyslexia. *Psychological review*, 98(1), 74.
- He, K., Zhang, X., Ren, S., & Sun, J.** (2016). Deep residual learning for image recognition. *In Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- Huang, G., Liu, S., Van der Maaten, L., & Weinberger, K. Q.** (2018). Condensenet: An efficient densenet using learned group convolutions. *In Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2752-2761).
- Hubel, David H., & Torsten N. Wiesel.** (1964). Effects of monocular deprivation in kittens. *Naunyn-Schmiedebergs Archiv for Experimentelle Pathologie und Pharmakologie* 248:492–7.
- Hanson, A.M., Annette, J., Jerin, F.,** (2017). Plant Leaf Disease Detection using Deep Learning and Convolutional Neural Network. *IJESC* Vol.:7, Issue No:3.
- Ioffe, S., & Szegedy, C.** (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. *In International conference on machine learning*. 448-456. PMLR.
- KawasakiY, Uga H, Kagiwada S, Iyatomi H.** (2015). Basic Study of Automated Diagnosis of Viral Plant Diseases Using Convolutional Neural Networks. *Advances in Visual Computing: 11th International Symposium, ISVC 2015, Proceedings, Part II* pp 638–645
- Korkmaz, Ö., & Mahiroğlu, A.** (2007). Beyin, bellek ve öğrenme. *Kastamonu Eğitim Dergisi*, 15(1), 93-104.
- Koç, M. L., Balas, C. E., & Arslan, A.** (2004). Taş dolgu dalgakıranların yapay sinir ağları ile ön tasarımı. *Teknik Dergi*, 15(74).
- Luaibi, A. R., Salman, T. M., & Miry, A. H.** (2021). Detection of citrus leaf diseases using a deeplearning technique. *International Journal of Electrical and Computer Engineering*, 11(2), 1719.
- Lakshmi, S., & Sivakumar, R.** (2017). Advanced Stevia Disease Detection Using Deep Learning. *Deep Learning for Image Processing Applications*, 31, 94.
- LeCun, Y.** (1989). Generalization and network design strategies. *Connectionism in perspective*, 19, 143-155.
- Lin, M., Chen, Q., & Yan, S.** (2013). Network in network. *arXiv preprint arXiv:1312.4400*.

- LeCun Y, Bengio Y, Hinton G.** (2015). Deep learning. *Nature*, 521(7553): 436.
- Mokhtar, U., El-Bendary, N., Hassenian, A.E., Emary, E., Mahmoud, M.A., Hefny, H., & Tolba, M.F.** (2014). SVM-Based Detection of Tomato Leaves Diseases. *IEEE Conf. on Intelligent Systems*.
- Musaev, M., Khujayorov, I., & Ochilov, M.** (2019). Image approach to speech recognition on CNN. In *Proceedings of the 2019 3rd International Symposium on Computer Science and Intelligent Control* (pp. 1-6).
- Rende, F. Ş., Bütün, G., Karahan, Ş., & TÜBİTAK BİLGEM, G.** (2016). Derin Öğrenme Algoritmalarında Model Testleri: *Derin Testler*.
- Sharada, P.M., David, P.H., Marcel, S.,** (2016). Using deep learning for image-based plant disease detection, *Frontiers in Plant Science*, 7:1419.
- Srivastava, N., G. E. Hinton, A. Krizhevsky, I. Sutskever & R. Salakhutdinov** (2014). Dropout: a simple way to prevent neural networks from overfitting. *Journal of machine learning research*, 15(1): 1929-1958.
- Simonyan, K., & Zisserman, A.** (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., & Rabinovich, A.** (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9).
- Szegedy, C., W. Liu, Y. Q. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke & A. Rabinovich** (2015). Going Deeper with Convolutions. *IEEE Conference on Computer Vision and Pattern Recognition (Cvpr)*: 1-9.
- Tuğrul, B.** (2002). Erken çocukluk döneminde öğrenmeyi ve öğretimi kolaylaştıran özellikler. *Hacettepe Üniversitesi Eğitim Fakültesi Dergisi*, 22(22).
- Keleş, E., & Çepni, S.** (2006). Beyin ve öğrenme. *Journal of Turkish Science Education*, 3(2), 66-82.
- Yalcin, H., & Razavi, S.** (2016). Plant classification using convolutional neural networks. In *Fifth International Conference on Agro-Geoinformatics (Agro-Geoinformatics)* (pp. 1-5).
- Xiao, J. R., Chung, P. C., Wu, H. Y., Phan, Q. H., Yeh, J. L. A., & Hou, M. T. K.** (2021). Detection of Strawberry Diseases Using a Convolutional Neural Network. *Plants*, 10(1), 31.

Amidi A. (2020). *Evrişimli Sinir Ağları el kitabı*. [Erişim: 14.06.2021, <https://stanford.edu/~shervine/1/tr/teaching/cs-230/cheatsheet-convolutional-neural-networks>]

Ruiz P. (2018). DenseNet on CIFAR10. [Erişim : 14.08.2021, <https://towardsdatascience.com/densenet-on-cifar10-d5651294a1a8>]

Açık kaynaklı web sitesinden alınmıştır. *Sinir Hücresi (Nöron)*. [Erişim: 14.06.2021, <https://www.gorgoda.com/sinir-hucresi-noron.html>]

Açık kaynaklı web sitesinden alınmıştır. *CS231n: Convolutional Neural Networks for Visual Recognition*. [Erişim: 09.06.2021, <https://cs231n.github.io/>]

Açık kaynaklı web sitesinden alınmıştır. *VGG16 ve VGG19 CNN Modellerinde Unsurları Çıkarın, Filtreleri Görselleştirin ve Özellik Haritalarını Oluşturun*. [Erişim: 14.06.2021, <https://ichi.pro/tr/vgg16-ve-vgg19-cnn-modellerinde-unsurlari-cikarin-filtreleri-gorsellestirin-ve-ozellik-haritalarini-olusturun-231835409051088>]