

T.C.
BİTLİS EREN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YANGIN TESPİTİNDE DERİN ÖĞRENME
ALGORİTMALARININ KARŞILAŞTIRMALI ANALİZİ

YÜKSEK LİSANS TEZİ

REMZİ GÖÇMEN

DANIŞMAN
DR. ÖĞR. ÜYESİ ERDAL AKIN

İKİNCİ DANIŞMAN
Doç. Dr. Musa ÇIBUK

EYLÜL 2023
BİTLİS

T.C.
BİTLİS EREN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YANGIN TESPİTİNDE DERİN ÖĞRENME
ALGORİTMALARININ KARŞILAŞTIRMALI ANALİZİ

YÜKSEK LİSANS TEZİ

REMZİ GÖÇMEN
ORCID: 0009-0004-3653-2831

DANIŞMAN
DR. ÖĞR. ÜYESİ ERDAL AKIN

İKİNCİ DANIŞMAN
Doç. Dr. Musa ÇIBUK

EYLÜL 2023
BİTLİS

T.C.
BİTLİS EREN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
YÜKSEK LİSANS TEZ ÇALIŞMASI
ETİK BEYANI

Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı Yüksek Lisans öğrencisiyim. Hazırlamış olduğum “**Yangın Tespitinde Derin Öğrenme Algoritmalarının Karşılaştırmalı Analizi**” başlıklı tezde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi; tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu; tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi; kullanılan verilerde herhangi bir değişiklik yapmadığımı; bu tezde sunduğum çalışmanın özgün olduğunu bildiririm, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim. 21/09/2023

İmza

Remzi GÖÇMEN

T.C.
BİTLİS EREN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
TEZ YAZIM KILAVUZU UYGUNLUK BEYANI

“Yangın Tespitinde Derin Öğrenme Algoritmalarının Karşılaştırmalı Analizi”
başlıklı yüksek lisans tezimin Bitlis Eren Üniversitesi Lisansüstü Eğitim Enstitüsü Tez
Yazım Kılavuzuna uygun olarak hazırlanmıştır. 21/09/2023

Tezi Hazırlayan

İmza

Remzi GÖÇMEN

Danışman

İmza

Dr. Öğr. Üyesi Erdal AKIN

İkinci Danışman

İmza

Doç. Dr. Musa ÇIBUK

Elektrik Elektronik Mühendisliği Anabilim Dalı Başkanı

İmza

Prof. Dr. Sabir RÜSTEMLİ

T.C.
BİTLİS EREN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
TEZ ONAY SAYFASI

Bitlis Eren Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı öğrencisi Remzi GÖÇMEN tarafından hazırlanan“Yangın Tespitinde Derin Öğrenme Algoritmalarının Karşılaştırmalı Analizi” adlı Yüksek Lisans Tezi ile ilgili tez savunma sınavı, 21/09/2023 tarihinde yapılmış ve tezin **oy birliği/ oy çokluğu** ile kabul/ ~~ret~~ edilmesine karar verilmiştir.

JÜRİ:

İMZA

Danışman:
(Bitlis Eren Üniversitesi)

.....

Üye: Prof. Dr. Sabir RÜSTEMLİ
(Bitlis Eren Üniversitesi)

.....

Üye:

.....

Bitlis Eren Üniversitesi Lisansüstü Eğitim Enstitüsü Yönetim Kurulunun
...../...../2023 tarih vesayılı kararıyla jüri tarafından kabul edilmiş bu
çalışmanın yüksek lisans / doktora tezi olarak kabulü onaylanmıştır.

...../...../2023

Doç. Dr. Mehmet Bakır ŞENGÜL

Enstitü Müdürü

T.C.
Bitlis Eren Üniversitesi Lisansüstü Eğitim Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı
YANGIN TESPİTİNDE DERİN ÖĞRENME ALGORİTMALARININ
KARŞILAŞTIRMALI ANALİZİ
Yüksek Lisans Tezi
Remzi GÖÇMEN
Danışman: Dr. Öğr. Üyesi Erdal AKIN
Eylül 2023
ÖZET

Baş döndürücü bir hızda ilerleyen teknolojiyle beraber, makine öğrenmesinin yöntemlerinden olan derin öğrenme uygulamaları, hayatımızın birçok alanında uygulanabilir olmuştur. Günlük hayatımızda plaka tanıma, optik karakter tanıma gibi uygulamalar artık yaşamımızın vazgeçilmezi haline gelmiştir. Günümüzde devam eden teknolojik gelişmelere paralel olarak, güvenlik kameralarından şüpheli durum tespiti veya otonom araçlar gibi yakın gelecekte hayatımızla iç içe olacak teknolojilerin gelişimi hissedilir şekilde artmaktadır. Bu teknolojinin başarımlar ve doğruluk oranlarının, yüksek değerlere ulaştığı görülmüştür. Bu çalışmada Kaggle’den elde edilmiş veri setlerinden, çoğunlukla orman yangınlarına ait görseller kullanarak orman yangınlarının yıkıcı sonuçlara ulaşmadan erken ve doğru tespit etmek amaçlanmış olup literatürdeki farklı derin öğrenme algoritmaları; MATLAB programı vasıtasıyla transfer öğrenme yoluyla eğitilmiştir. Böylece orman yangınlarını en kısa sürede ve en doğru olarak tespit eden, derin öğrenme algoritmasını veya algoritmalarını başarımlar oranları açısından mukayese etme imkânı elde edilmiştir. Geline nokta genel olarak %90’ların üzerinde yüksek başarımlar elde edilmiştir.

Anahtar Kelimeler: Yangın Algılama, Görüntü İşleme, Derin Öğrenme, Evrişimli Sinir Ağları, Derin Öğrenme Algoritmaları

Republic of Türkiye
Bitlis Eren University Graduate School
Department of Electrical and Electronics Engineering
COMPARATIVE ANALYSIS OF DEEP LEARNING ALGORITHMS IN FIRE
DETECTION
Master's Thesis
Remzi GÖÇMEN
Supervisor: Asst. Prof. Dr. Erdal AKIN
September 2023
ABSTRACT

With technology advancing at a dizzying pace, deep learning applications, one of the methods of machine learning, have become applicable in many areas of our lives. Applications such as license plate recognition and optical character recognition have become indispensable in our daily lives. In parallel with the ongoing technological developments today, the development of technologies that will be intertwined with our lives in the near future, such as suspicious situation detection from security cameras or autonomous vehicles, is increasing noticeably. It has been observed that the performance and accuracy rates of this technology have reached high values. In this study, it is aimed to detect forest fires early and accurately before they reach devastating consequences, using mostly images of forest fires from data sets obtained from Kaggle. Different deep learning algorithms in the literature; Trained through transfer learning through the MATLAB program. Thus, it was possible to compare the deep learning algorithm or algorithms that detect forest fires in the shortest time and most accurately in terms of performance rates. At this point, generally high performances above 90% have been achieved.

Keywords: Fire Detection, Image Processing, Deep Learning, Convolutional Neural Networks, Deep Learning Algorithms

TEŞEKKÜR

Yoğun geçen tez çalışması sırasında, tez konusunun belirlenmesinden başlayarak son aşamaya kadar her türlü bilgi, teşvik ve deneyimlerini benden esirgemeyen danışman hocam sayın Dr. Öğr. Üyesi Erdal AKIN'a, Elektrik-Elektronik Mühendisliği Anabilim dalı başkanı sayın Prof. Dr. Sabir RÜSTEMLİ hocama şükranlarımı sunarım. Ayrıca Bilgisayar Mühendisliği Bölüm Başkanı Doç. Dr. Musa ÇIBUK'a yüksek lisans eğitimim boyunca yardımlarından dolayı minnettarım. Bu günlere gelmemde büyük emekleri olan başta ailem olmak üzere, çalışma temposu boyunca her daim bana destek olan eşime teşekkürlerimi sunarım.

Remzi GÖÇMEN

Bitlis-2023

İÇİNDEKİLER

ÖZET.....	I
ABSTRACT	II
TEŞEKKÜR	III
İÇİNDEKİLER	IV
ŞEKİLLER DİZİNİ	VII
ÇİZELGELER DİZİNİ	IX
KISALTMALAR	X
1. GİRİŞ.....	1
1.1. Tezin Amacı	2
1.2. Tez Özeti.....	2
1.3. Tez Organizasyonu.....	3
2. GENEL BİLGİLER	4
2.1. Tarihçe.....	5
2.2. Yapay Zekâ Nedir?	5
2.3. Makine Öğrenmesi	6
2.4. Farklı Makine Öğrenme Türleri.....	7
2.4.1. Denetimli Öğrenme	7
2.4.2. Takviyeli Öğrenme.....	8
2.4.3. Denetimsiz Öğrenme.....	8
2.4.4. Transfer Öğrenme	9
2.4.5. Derin Öğrenme.....	10
2.5. Derin Öğrenmenin Uygulandığı Bazı Alanlar	11
2.5.1. Sınıflandırma.....	11
2.5.2. Nesne Tespiti.....	11
2.5.3. Medikal	12
2.5.4. Görüntü/Video İşleme	12
2.6. Yapay Sinir Ağları	12

2.6.1. Evrişimsel Sinir Ağları	13
3. MATERYAL ve YÖNTEM.....	18
3.1. Kullanılan Derin Öğrenme Algoritma Tabanlı ESA'lar	18
3.1.1. AlexNet Mimarisi	19
3.1.2. VGG-16 Mimarisi	19
3.1.3. VGG-19 Mimarisi	20
3.1.4. GoogLeNET Mimarisi	21
3.1.5. Places-365.....	22
3.1.6. ResNET-18 Mimarisi	23
3.1.7. ResNET-50 Mimarisi	23
3.1.8. ResNET-101 Mimarisi	24
3.1.9. ShuffleNET Mimarisi	25
3.1.10. MobileNet Mimarisi	26
3.1.11. NASNET-Mobile Mimarisi	27
3.1.12. EfficientNET-B0 Mimarisi	27
3.1.13. Inception-v3 Mimarisi	28
3.1.14. DarkNet-19 Mimarisi.....	29
3.1.15. DarkNET-53 Mimarisi	29
3.1.16. Xception Mimarisi.....	30
3.1.17. Inception-Resnet Mimarisi	31
3.1.18. DenseNet-201 Mimarisi	32
3.1.19. SqueezeNET Mimarisi	33
3.1.20. NASNET-Large Mimarisi	33
3.2. Kullanılan Yangın Veri Seti	34
3.3. Transfer Öğrenme Yoluyla Yapay Sinir Ağlarının Eğitilmesi	37
3.3.1. Çapraz Doğrulama Tekniği	37

3.3.2. Eğitim Parametreleri	38
4. BULGULAR VE TARTIŞMA	42
5. SONUÇ VE ÖNERİLER	49
KAYNAKLAR	50



ŞEKİLLER DİZİNİ

Şekil 2. 1. Semantik Yapay Zekâ Ağı	6
Şekil 2. 2. Makine Öğrenmesinin Çalışması.....	7
Şekil 2. 3. Denetimli Makine Öğrenme Süreci	7
Şekil 2. 4. Takviyeli Öğrenme Çalışma Modeli	8
Şekil 2. 5. Denetimsiz Makine Öğrenme Süreci.....	9
Şekil 2. 6. Geleneksel ve Transfer Öğrenimi arasındaki farklı öğrenme süreçleri	10
Şekil 2. 7. Yapay Zekânın kronolojik sıralaması.....	11
Şekil 2. 8. Yapay Sinir Ağı Katmanları	13
Şekil 2. 9. Evrimsel sinir ağı yapısının katmanları	14
Şekil 2. 10. Algılama ESA'larına dayalı yangın algılama algoritmalarının akış şeması	15
Şekil 2. 11. Farklı aktivasyon fonksiyonları	16
Şekil 3. 1. AlexNet modelinin genel yapısı	19
Şekil 3. 2. VGG-16 mimarisi	20
Şekil 3. 3. VGG-19 Ağının Yapısı	21
Şekil 3. 4. GoogLeNet ağı	22
Şekil 3. 5. ResNET-18 model mimarisi	23
Şekil 3. 6. ResNET-50 Mimarisi	24
Şekil 3. 7. ResNet-101 tabanlı derin özellik çıkarıcının yapısı	25
Şekil 3. 8. Yığılmış iki grup kıvrımı ile kanal karıştırma işlemi	26
Şekil 3. 10. NASNET-Mobile mimarisi	27
Şekil 3. 11. Efficientnet-B0 Mimari Görüntüsü	28
Şekil 3. 12. Inception-v3 modelinin mimarisi	28
Şekil 3. 13. DarkNet-19 mimarisi	29
Şekil 3. 14. DarkNet-53 mimarisi	30
Şekil 3. 15. Xception Mimarisi	31
Şekil 3. 16. Inception-Resnet	32
Şekil 3. 17. DenseNet-201 ağ yapısı	32
Şekil 3. 18. SqueezeNET yapılandırma detayları	33
Şekil 3. 19. NASNET-Large genel mimarisi	34
Şekil 3. 20. Veri Setinden Alınmış Örnek Yangın Görüntüleri.....	36
Şekil 3. 21. Veri Setinden Alınmış Örnek Yangın Olmayan Görüntüler	36
Şekil 3. 22. Transfer öğrenme yoluyla yapay sinir ağlarının eğitilmesi	37

Şekil 3. 23. 5 Kat Çapraz Doğrulama Tekniğinin Uygulanması	38
Şekil 3. 24. Karışıklık Matrisi(Confusion Matrix).....	40
Şekil 4. 1. Kullanılan Algoritmalarının Doğruluk-Zaman Balon Grafiği.....	48



ÇİZELGELER DİZİNİ

Çizelge 3.1. Tezde Kullanılan DÖA tabanlı ESA'lar	18
Çizelge 3.2. Tezde Kullanılan Veri Seti	35
Çizelge 3.3. Donanım Özellikleri	39
Çizelge 3.4. Çalışmada Kullanılan Eğitim ve Test Parametreleri	39
Çizelge 3.5. Modelin Oluşturduğu Kombinasyon Çeşitleri.....	40
Çizelge 3.6. Performans Karşılaştırma Metrikleri	41
Çizelge 4.1. Yapılan Eğitim Sonrası Elde Edilen Başarım Sonuçları	42
Çizelge 4.2. ESA'ların Transfer Öğrenme Süreleri	45



KISALTMALAR

DÖ	: Derin Öğrenme
DÖA	: Derin Öğrenme Algoritmaları
ESA	: Evrişimli Sinir Ağları
IBÖGTY	: ImageNet Büyük Ölçekli Görsel Tanıma Yarışması
MÖ	: Makine Öğrenmesi
PÖ	: Pekiştirmeli Öğrenme
YSA	: Yapay Sinir Ağları
YZ	: Yapay Zekâ



1. GİRİŞ

Ateş; bulunmasından bu yana, insanların gelişimine birçok alanda katkıda bulunmuştur. Fakat kontrolden çıkan bir yangın, ciddi zararlar verebilir. Bundan dolayı can ve mal kayıplarının önlenmesi kritik önemdedir [1]. Yangın, erken algılanması ve erken müdahale edilmesi halinde hasar miktarı ciddi ölçüde azaltılabilen bir afettir. Yangınla mücadelede, itfaiye kuvvetlerinin çabalarına rağmen; trafik, geç gelen ihbarlar, yangın alanının müdahale açısından elverişli konumda olmaması gibi sebepler nedeniyle, bazen yangına zamanında müdahale edilememektedir. Bu şekilde can ve mal kayıplarına neden olan trajik gerçek, araştırmacıları yangınla mücadele sistemlerini geliştirmeye ve iyileştirmeye teşvik etmiştir. Konu orman yangınları olduğunda ise trafik veya yangının bulunduğu konum gibi şehir yaşamının ürettiği engeller yerine, zaman darlığı aşılması gereken en önemli engeldir. Çünkü orman yangınları, en hızlı yayılan ve en geç fark edilen yangın türüdür.

Üzerinde bulunduğumuz coğrafyada, sıklıkla meydana gelen orman yangınlarının geç tespit edilmesi ve bu yangınlara geç müdahalelerde bulunulması gibi nedenler, ülkemizdeki yeşil alanları gün geçtikçe daraltmaktadır. Bu daralmayla sera gazı yayılımının artmasıyla birlikte; küresel ısınmanın hızlanması, iklim değişikliği, çevre kirliliği, kuraklık gibi istenmeyen olumsuz durumlar, özelde ülkemizi ve genelde de dünyayı daha yaşanılmaz bir hale getirmektedir.

Günümüzde yangınla mücadele birimleri tarafından aktif olarak kullanılan bilgisayarlı yangın tespit sistemleri vardır. Fakat etkili biçimde müdahalede bulunmak mümkün olamamaktadır. Ormanlık arazilerin fiziksel yapısı ve orman yangınlarının yayılma hızı göz önünde bulundurulunca; yangının erken ve doğru tespiti, yangınlara zamanında müdahale edilmesini sağlayarak, büyük zararların önüne geçme veya azaltmada muhakkak etkili olacaktır. Bilgisayarlı görü ve yapay zekâ sistemleri ile yangın ihbarlarının hayata geçirilmeden önce teyit edilmesi, yanlış ihbarların da önüne geçerek kazanç sağlayacaktır.

Bazı nokta tipi termal ve duman algılayıcılardan yaygın olarak istifade edilebilmektedir. Fakat bu tür algılayıcıların yangın bölgesine yakınlığı ve bu yangın ortamından kolayca etkilenip arızalanması veya hasarı söz konusudur. Bilgisayarlı görüntü işlemenin ilerlemesiyle video ve resim tabanlı yangın algılama, geleneksel yöntemlere göre hızlı tepki ve geniş algılama alanı gibi avantajlara sahiptir [2]. Yangın

kayıplarını azaltmak için yüksek hassasiyet, doğru ve erken algılama ile alarm gereklidir. Bununla birlikte, duman ve ısı algılayıcıları gibi geleneksel yangın algılama teknolojileri; geniş alanlar, karmaşık binalar veya birçok dezavantajlı alan için uygun değildir. Yukarıda saydığımız algılama teknolojilerinin sınırlamaları nedeniyle; kaçırılan algılamalar, yanlış alarmlar, algılama gecikmeleri ve diğer sorunlar sıklıkla ortaya çıkmaktadır. Bu da erken yangın uyarılarının alınmasını daha da zorlaştırır [3]. Son zamanlarda görüntülü yangın algılama, popüler bir araştırma konusu haline geldi. Bu teknik; erken yangın algılama, yüksek doğruluk, esnek sistem kurulumu ve geniş alanlarda yangınları etkin bir şekilde algılama yeteneği gibi birçok üstünlüğü barındırmaktadır [4]. Derin öğrenme algoritmaları(DÖA); kameradan gelen görüntü verilerini analiz ederek, yangın veya yangın riskinin varlığını belirlemek için çalışır. Bu nedenle algılama algoritması bu teknolojinin özüdür ve görüntülü yangın algılayıcılarının performansını doğrudan etkilemektedir.

1.1. Tezin Amacı

Bu çalışmanın temel hedefi; özü itibariyle Yapay Sinir Ağları(YSA) olan, Derin Öğrenme Algoritmalarını kullanarak farklı veri setlerinden alınmış, çoğunlukla orman yangını görüntüleri üzerinden bu algoritmaları karşılaştırarak bir performans değerlendirmesi amaçlanmaktadır. Böylece kullanılan DÖA'nın; yangını algılama doğruluğu, yangını tespit süresinin hızı ve hassasiyeti bakımından karşılaştırma imkânı elde edilebilecektir.

1.2. Tez Özeti

Bu tez çalışmasında öncelikle Evrişimsel Sinir Ağları(ESA) sistemlerinin yapısı, işlevi ve çalışma prensibi incelenmiştir. Daha sonra bu sistemin yangın tanıma sistemlerindeki kullanımı hakkında detaylı bir literatür taraması yapılarak, benzer çalışmalar araştırılmıştır. Ayrıca yangın tanıma sistemlerinde kullanılan veri setlerini kullanan ESA'ların tanıma işlemlerinde nasıl kullanıldığı araştırılarak, derin öğrenme algoritmaları ayrıntılı incelenmiştir.

Bu işlemlerde ve kullanılan algoritmalar için, kodlamada ve görüntü işlemede birçok kolaylık sunan MATLAB [5] programı kullanılmıştır. Aynı zamanda bu programdan; veri setlerinin eğitilmesi ve test edilmesinin yanında sonuçları karşılaştırmak için de faydalanılmıştır. Bu çalışmada doğrulama için 5 kat çapraz doğrulama (five fold cross validation) yöntemi uygulanmıştır. Yani veri kümesinin

%20'lik kısmı test verisi için kullanılırken, geriye kalan % 80'lik kısmı ise eğitim verisi olarak değerlendirilmiştir.

1.3. Tez Organizasyonu

Bölüm 1'de tez çalışması konusunun önemi ile ilgili giriş bilgilerine, Bölüm 2'de literatür taramasına yer verilmiştir. Yapay Zekânın(YZ) tanımı, alt dalları ve alanları ile ilgili genel bilgilere yer verilmiştir. Ayrıca yapay sinir ağları, evrimsel sinir ağları, nesne tespiti için kullanılan bazı evrimsel sinir ağları modellerinden bahsedilmiştir. Yangın algılama ve tanıma için kullanılan derin öğrenme modelleri, yangın görüntülerinin yararlanıldığı veri setleri ve uygulama ile ilgili bilgilere değinilmiştir. Bölüm 3'te tezde kullanılan derin öğrenme modelleri, test için kullanılan yöntem ve eğitim parametrelerine değinilmiştir. Bölüm 4'te eğitimde kullanılan algoritmalara ait sonuçların detayları ile tablo grafiği ve doğruluk-zaman balon grafiği verilmiştir. Bölüm 5 yani sonuç kısmında yangını algılama süresi en hızlı ve doğruluk oranı hassasiyeti en iyi olan ESA mimari ağını tespit ederek, algoritma hakkında yorumlara yer verilmiştir.

2. GENEL BİLGİLER

Yangın tespiti için kullanılan sistemleri(sensörler, dedektörler gibi) direkt orman yangınlarında kullanmak, bazen yetersiz kalabilmektedir. Bundan dolayı derin öğrenme tabanlı, görüntü işleme sistemlerinden faydalanmak oldukça makul ve mantıklı bir çözüm yaklaşımı olabilmektedir. Teknolojinin süratle ilerlediği günümüzde, uzaktan algılama çalışmaları da hayatımızın birçok noktasında kendini göstermektedir. Uzaktan algılama yapmak için kullanılan yöntemlerin başında gelen YZ tabanlı derin öğrenme yöntemleri birçok alanda kullanılmaktadır. Bu alanlardan bazıları; yüz tanıma, nesne algılama, ses tanıma, tıbbi teşhisler, otonom araçlar, yangın tespiti ile bunun gibi daha birçok alanda kullanımı yaygın olup, başarı oranı kayda değer yüksek sonuçlar elde edilmektedir [6].

DÖA ve bunları kullanan ESA'lar yukarıda sayılan alanlardan olan yangını algılayarak, kısa sürede tespit ederek erken müdahale edilebilmesi için uygun bir yöntem olarak karşımıza çıkmaktadır. Görüntülü yangın algılama, görüntülerin algoritmik(zaman ve doğru tespit gibi) çözümlemesine dayanır. Bunun yanı sıra, görüntü özelliklerini manuel veya makinenin otomatik olarak çıkarması da dâhil olmak üzere; yaygın algılama algoritmaları daha düşük bir doğruluk, gecikmeli algılama ve büyük miktarda hesaplama yapmaktadır [3]. Bu çalışmada, sınıflandırma yapan(AlexNet, GoogLeNet, NASNET-Large, ResNET-18 gibi) ESA'lar ile gelişmiş algılama algoritmaları önerilmektedir. ESA'lara dayalı yangın algılama yaklaşımlarının doğrulama açısından diğer algoritmalara oranla daha yüksek olduğunu ortaya koymaktadır. Görsel sahnelerden etkili bir duman algılama, büyük ölçekli yangınlardan korunabilmek için çok önemlidir. Ancak renk, doku ve şekillerdeki büyük varyasyonlar nedeni ile halen çok zordur. Duman algılama doğruluğunu iyileştirmek için, ham piksel değerlerinden sınıf çıktılarına kadar uçtan uca eğitilebilen ve görüntülerden otomatik olarak öznitelikler çıkarabilen ESA'ya dayalı yeni bir yaklaşım önerilmiştir. Deneyler de alınan sonuçlar, bu yöntemin mevcut geleneksel yöntemlere göre daha iyi performans ve büyük veri kümesinde % 0,44 yanlış alarm oranlarıyla, %99,40 doğru algılama oranlarına ulaştığını göstermektedir [2].


2.1. Tarihçe

Akıllı davranışı ve eleştirel düşüncüyü simüle etmek için bilgisayar kullanma kavramı ilk olarak 1950’de Alan TURING tarafından tanımlanmıştır [7]. Altı yıl sonra John MCCARTHY, YZ terimini, "akıllı makineler yapma bilimi ve mühendisliği" olarak tanımladı [8]. YZ, 1950’lerin ortalarında bir bilgisayar bilimi disiplini olarak ortaya çıktı. O zamandan beri; çoğunlukla mühendislikte olmak üzere, normalde insan zekâsı gerektiren, zor sorunları çözmek için pratik kullanıma sahip bir dizi güçlü araç üretildi [9]. YZ; bir bilgisayarın ya da bilgisayarın yönettiği bir cihazın, insana ait özellikler olduğu varsayılan; muhakeme yürütme, genelleme yapma ve deneyimlerden öğrenme gibi bilişsel süreçlere ilişkin görevleri yerine getirme becerisi” olarak ifade edilmiştir [10]. İnsanoğlu yüzyıllardır cansız varlıkları canlandırmayı ve harekete geçirmeyi düşünmüştür. 4000 yıl önceden başlayan veri depolama isteği ile beraber, YZ ve YSA’ da asıl gelişme ise son elli yılda gerçekleşmiştir [11]. Modern YZ’nin başlangıcının izlerini klasik filozofların insan düşünce sistematiğini simgesel sistem olarak, tanımlama girişiminde görebiliriz. Fakat yapay zekâ alanı 1956’ya kadar resmi olarak oluşturulamamıştır. 1956’da Hannover, New Hampshire, Dartmouth College’da yapılan bir konferansta “yapay zekâ” terimi ilk defa ortaya atılmıştır [12].

2.2. Yapay Zekâ Nedir?

1956 yılından önceki dönem, YZ’nin kuluçka dönemi olarak kabul edilir. O zamana kadar bilim adamları ve mühendisler zihinsel işlerinin bir kısmını makinelerle değiştirmeye çalıştılar [13]. YZ açık insan rehberliği olmadan sorunları çözebilen ve görevleri gerçekleştirebilen, bir teknolojiler koleksiyonunu tanımlamak için kullanılan geniş bir terimdir [14]. Bunlardan bazıları şunlardır; makine öğrenimi, bilgisayar görüşü, doğal dil işleme, robotik ve derin öğrenme gibi. Genel amaçlı bir teknoloji olan YZ, sorunları otonom olarak çözmek ve insan rehberliği olmadan görevleri gerçekleştirmek için veriye dayalı algoritmalar kullanır [8]. YZ; esasında sezgisel programlama olan bir yaklaşımdır [15]. YZ; insanların yapabildiklerini bilgisayarlara yaptırabilme uğraşıdır [11]. YZ akıllı davranış üzerine bir çalışmadır. Asıl gaye, tabiatı ki varlıkların akıllı davranışlarını suni olarak üretmeyi, kuram olarak meydana getirmektir [16]. YZ, insanoğlunun yapabileceği bazı işleri daha çok veriyle daha süratle yapılabilmesine olanak sağlayarak yaşantımızı kolaylaştırmaktadır. Bu nedenle; dil çevirileri, sesli asistanlar, sağlık hizmetleri, öneri sistemleri, navigasyon(yönelim), siber güvenlik, savunma sanayi, e-ticaret ile robotik

uygulamaları da benzer bir şekilde, kendisine sunulan veri kümelerini özümseyerek yapılması istenen görevi öğrenir [20]. Şekil 2. 2’de makine öğrenmesinin çalışma mantığına ait görsel yer almaktadır.




Şekil 2. 2. Makine Öğrenmesinin Çalışması

2.4. Farklı Makine Öğrenme Türleri

2.4.1. Denetimli Öğrenme


Denetimli makine öğrenimi teknikleri, sahip olduklarından yararlanır. Etiketlerin yardımıyla önceki ve şimdiki verilerden edinilen bilgi ve olayları tahmin etmek için kullanılır [21]. Sisteme test veri setinin ve eğitim veri setinin yüklenmesi, veri setinde de tüm veri için lazım olan etiketlenmenin yapılarak, girdi veri seti ile çıktı veri seti arasında alakanın kurulması esasına dayanır. Asıl hedef sonuçları bilinen veri setinden yapılan gruplandırmadan yola çıkarak, sonuçları bilinmeyen veri setine ait tahmin yapabilmektir [22]. Şekil 2. 3’de denetimli makine öğrenme sürecinin nasıl çalıştığı ile ilgili görsele yer verilmiştir.



Şekil 2. 3. Denetimli Makine Öğrenme Süreci

2.4.2. Takviyeli Öğrenme


Takviyeli öğrenme eğitim olmadan, deneme yanılma yoluyla en iyi sonucu bulmak için, belirli bir ortamla etkileşime giren bir algoritmaya sahiptir. Makine belirli kararlar vermek üzere eğitilmiştir. Geçmiş deneyimlerden öğrenir ve doğru kararlar vermek için mümkün olan en iyi bilgiyi yakalamaya çalışır[20]. Şekil 2. 4'te temsili bir takviyeli öğrenme modelinin çalışma prensibine ait görsel yer almaktadır.



Şekil 2. 4. Takviyeli Öğrenme Çalışma Modeli

2.4.3. Denetimsiz Öğrenme


Denetimsiz öğrenmede bir çıkış bilgisi verilmeksizin giriş görüntüleri ağın girişine uygulanır. Ağdaki katmanlarda sonuç verisi oluşturulur. Buna göre oluşan çıkışlarda benzer değerlere sahip olan sonuçlar, bir kümeye alınır. Oluşan her bir küme bir sınıfı temsil eder [23]. Bu tür MÖ'de, algoritmalar kendi yapılarını oluşturur. Denetimsiz öğrenme, bir sonuç bilinmediğinde veya önceden belirlenmediğinde kalıpları keşfetmek ve tespit etmek için kullanılır. Yeterince büyük veri setleriyle, denetimsiz öğrenme algoritmalarının davranış kalıplarını veya daha önce bilinmeyen diğer durumları tanımlaması mümkündür. Şekil 2. 5'te denetimsiz makine öğrenme ait gerçekleşme süreci verilmiştir.



Şekil 2. 5. Denetimsiz Makine Öğrenme Süreci

2.4.4. Transfer Öğrenme


Geleneksel veri madenciliği ve makine öğrenimi algoritmaları, önceden toplanmış etiketli veya etiketsiz eğitim verileri üzerinden eğitilmiş istatistiksel modelleri kullanarak, gelecekteki veriler hakkında tahminler yapar [24]. Yarı denetimli sınıflandırmada çok az miktarda etiketlenmiş veri ve çok fazla miktarda etiketlenmemiş veri bulunur. İyi bir sınıflandırıcı oluşturmak için etiketli verilerin çok az olabileceği sorunun ele alır. Buna rağmen, çoğu etiketli ve etiketsiz verilerin dağılımlarının aynı olduğunu varsaymaktadır. Transfer öğrenimi; bunun aksine, eğitim ve testte kullanılan alanların, görevlerin ve dağıtımların farklı olmasına izin verir [25]. Belirli senaryolarda, test verilerinin özellik alanı ve tahmin edilen veri dağıtım özellikleriyle eşleşen eğitim verilerinin elde edilmesi, zor ve pahalı olabilir. Bu nedenle, ilgili bir kaynak alandan eğitilen bir hedef alan için yüksek performanslı bir öğrenen oluşturmaya ihtiyaç vardır. Transfer öğrenimi için motivasyon budur [26]. Şekil 2. 6'da geleneksel öğrenme ve transfer öğrenme arasındaki farklı öğrenme süreçleri gösterilmiştir.



Şekil 2. 6. Geleneksel ve Transfer Öğrenimi arasındaki farklı öğrenme süreçleri

2.4.5. Derin Öğrenme

Derin öğrenme(DÖ) bir makine öğrenmesi sınıfıdır. DÖ; özellik çıkarma ve dönüştürme için, birçok doğrusal olmayan işlem birimi katmanını kullanır. Her ardışık katman, önceki katmandaki çıktıyı girdi olarak alır [27]. Algoritmalar denetimli (sınıflandırma gibi) veya denetimsiz (desen analizi gibi) olabilir. DÖ’de, verilerin birden fazla özellik seviyesinin veya temsillerinin öğrenilmesine dayanan bir yapı söz konusudur. Üst düzey özellikler, alt düzey özelliklerden türetilerek hiyerarşik bir temsil oluşturur. Bu temsil, soyutlamanın farklı seviyelerine karşılık gelen birden çok temsil seviyesini öğrenmektedir [28]. DÖ, temel olarak verinin temsilden öğrenmeye dayalıdır. Bir görsel için temsilden söz edildiğinde; piksel başına yoğunluk değerlerinin veya kenar kümelerinin, özel şekillerin vb. bir vektörü düşünülebilir. Bu özelliklerden bazıları verileri daha iyi temsil eder. Bu aşamada yine bir avantaj olarak; derin öğrenme yöntemleri elle çıkarılan özellikler yerine, veriyi en iyi temsil eden hiyerarşik özellik çıkarımı için etkin algoritmalar kullanmaktadır [29]. YSA ile ilişkilendirilen bu makine öğrenimi türü, insan beynindeki nöronların bağlantı kurma biçiminden ilham almıştır. Verileri modellemek ve çıkarımlar yapmak için etkileşime giren çok sayıda algoritma katmanına sahiptir. Bir problemin parçalarını etkili bir şekilde çözmek ve daha büyük bir çözüm elde etmek için daha yüksek seviyelerdeki YSA’lara bu kısmi çözümleri sağlamak için daha düşük soyutlama seviyelerinde, birden fazla YSA vardır [30]. Yapay zekânın tarihsel süreç içinde ki değişimi Şekil 2. 7’de kronolojik olarak verilmiştir.



Şekil 2. 7. Yapay Zekânın kronolojik sıralaması

2.5. Derin Öğrenmenin Uygulandığı Bazı Alanlar

DÖ; günümüzde görüntü analizi, ses analizi, robotik, otonom araçlar, gen analizleri, kanser teşhisleri ve sanal gerçeklik gibi birçok yerde kullanılmaya başlandı. Bu kadar yaygın alanda kullanılmasının temelinde, problemlerin çözümünde elde ettiği yüksek doğruluk oranlarıdır. Hatta ses tanımlama, görüntü tanımlama gibi bazı problemlerde insan performansının üzerine çıkmıştır [31].

2.5.1. Sınıflandırma

Görüntü sınıflandırma alanında yapılan birçok çok çalışma vardır. Kullanılan ayrı ayrı yöntemler, sınıflandırma başarısına katkı sağlamıştır [32]. DÖ ile trafik işaretlerinin sınıflandırılması [33], uydu görüntülerinin sınıflandırılması [34], yüz tanıma sınıflandırılması [35], üç boyutlu görüntülerin sınıflandırılması, kolon kanseri görüntülerinin sınıflandırılması [36], toprak örtüsü sınıflandırılması, mahsul türlerinin sınıflandırılması [37], zararlı yazılımların sınıflandırılması [38], video sınıflandırma [39] gibi birçok sınıflandırma çalışmaları yapılmıştır [40].

2.5.2. Nesne Tespiti

Görüntü tabanlı otomatik nesne türlerinin sınıflandırma görevlerinde geleneksel makine öğrenimi yöntemlerinin kullanımı için öncelikle özellik kümesinin çıkarılması gerekir [41]. Görüntü sınıflandırma ve nesne tespiti benzer özellikler gösterse de birbirinden farklıdır. Nesne tespitinde bir görüntü içerisinde bir nesne aranır. Sınıflandırmada ise elde bulunan etiketlere göre görüntüler bir sınıfa alınır. Bu nesnenin görüntü içerisinde nerede olduğu tahmin edilmeye çalışılır [42]. Temel bilgisayar görme

problemlerinden biri olan nesne algılama, görüntülerin ve videoların anlamsal olarak anlaşılması için değerli bilgiler sağlayabilir. Görüntü sınıflandırma insan davranış analizi dâhil olmak üzere birçok uygulama(yüz tanıma ve otonom sürüş vb.) ile ilgilidir. Ancak bakış açıları, pozlar ve aydınlatma koşullarındaki büyük farklılıklar nedeniyle, ek bir nesne konumlandırma göreviyle, nesne algılamayı kusursuz bir şekilde gerçekleştirmek zordur. Nesne algılamanın problem tanımı; nesnelerin belirli bir görüntüde nerede bulunduğunu ve her bir nesnenin hangi kategoriye ait olduğunu belirlemektir [43].

2.5.3. Medikal

Bilgisayar destekli teşhis, radyomik ve tıbbi görüntü analizi dâhil olmak üzere tıbbi görüntüleme alanında MÖ'nün kullanımı hızla artıyor. 2012 sonlarında, bir ESA'ya dayalı bir DÖ'nün yaklaşımının dünya çapında en iyi bilinen bilgisayarla görme yarışması ImageNet Classification'da ezici bir zafer kazanmasıyla başladı. O zamandan beri, tıbbi görüntüleme de dâhil olmak üzere, neredeyse tüm alanlardaki araştırmacılar, hızla büyüyen DÖ alanına aktif olarak katılmaya başladılar [45–47].

2.5.4. Görüntü/Video İşleme

Görüntü işlemede genel olarak, değerlendirme yapabilmek için veri setlerinden yararlanılmaktadır. Örneğin bu çalışmada kullanılan veri setinin, %20'lik kısmı test verisi olarak, geriye kalan % 80'lik kısmı ise eğitim verisi olarak kullanılmıştır.


Bir görüntü işleme sisteminin çeşitli bileşenleri bulunmakta ancak en önemli ana bileşen üç boyutlu bir nesnenin görüntülerini yakalayan bir kameradır. Görüntü işlemede alanında görüntü ve video sıkıştırma etkin bir rol oynamaktadır. Görüntü ve video için sıkıştırma teknolojilerinin geliştirilmesi sayesinde multimedya iletişimi ve uygulamaları da ilerleme kaydedilmektedir. Depolama maliyeti son zamanlarda büyük oranda azalmış olsa da görüntü ve video sıkıştırma ihtiyacı büyümektedir [47].

2.6. Yapay Sinir Ağları

İnsan beyninin öğrenme yolunu taklit ederek beynin öğrenme, hatırlama, genelleme yapma yolu ile topladığı verilerden, yeni veri üretebilme gibi temel işlevlerin gerçekleştirildiği bilgisayar yazılımlarıdır. YSA, insan beyninden esinlenerek, öğrenme sürecinin matematiksel olarak modellenmesi uğraşı sonucu ortaya çıkmıştır [11]. YSA birbirine bağlı çok sayıda basit işlemciye sahip büyük ölçüde paralel sistemlerden meydana gelir [48]. YSA'lar, geleneksel algoritmaların çok az başarılı olduğu görevleri

gerçekleştirmek için insan beyninin mimarisini kullanma girişimi olarak başladı. Kısa süre sonra deneysel sonuçları iyileştirmeye yöneldiler ve çoğunlukla biyolojik öncüllerine sadık kalma girişimlerini terk ettiler. Nöronlar, bazı nöronların çıktısının diğerlerinin girdisi olmasına izin vermek için çeşitli modellerde birbirine bağlanır. Ağ, yönlendirilmiş ağırlıklı bir grafik oluşturur [49]. Örüntü sınıflandırma, kümeleme, fonksiyon modelleme en uygun şekilde sokma, tahmin etme, ilişkilendirme ve kontrol konularıyla alakalı sorunların çözümünde öteki hesaplama vasıtalarından daha iyi neticeler elde edilmektedir [50].

YSA birkaç katmandan meydana gelmektedir. Aralarında hiyerarşik bir bağlantı vardır. Yani bir katmanda ki sinir hücreleri bir sonra ki katmandaki sinir hücresiyle bağlantılıdır. Birinci katman girdi katmanıyken, en son katman çıktı katmanı olarak isimlendirilmektedir. YSA'nın tamamında bu katmanlar mevcuttur. Giriş ve çıkış katmanları arasında birçok katman olabilmektedir. Farklı katmanlar arasında, sinir hücrelerini birbirine bağlayan bağlar vardır. Katmanda ki sinir hücresi çıktıyı alarak sonraki katmanda bulunan hücreye girdi olacak şekilde birbirine bağlanmaktadır. Bu bağlantıların önemine istinaden bambaşka ağırlıkları vardır. YSA'nın eğitiminde hedefi; bu ağırlıkları, sistemin tahminleri doğru olarak yapması için revize etmektir. Şekil 2. 8'de yapay sinir ağlarına ait görsele yer verilmiştir.




Şekil 2. 8. Yapay Sinir Ağı Katmanları

2.6.1. Evrimsel Sinir Ağları

ESA derin öğrenmenin temel mimarisi olarak bilinir. ESA canlıların doğal görsel algılama mekanizmasından ilham alan, tanınmış bir derin öğrenme mimarisidir [51]. “Evrimsel sinir ağı”, sinir ağının evrim adı verilen bir matematik işlemi kullandığını gösterir. Evrim (konvolüsyon) özel bir doğrusal işlem çeşididir [52]. ESA, tipik olarak

üç tür katmandan oluşan matematiksel bir yapıdır; evrişim(convulation), havuzlama(pooling) ve tamamen bağlı(fully connected) katmanlar. İlk iki katman olan, evrişim ve havuzlama katmanları özellik çıkarımı yapar. Tamamen bağlantılı bir katman olan üçüncü katman, çıkarılan özellikleri sınıflandırma gibi nihai çıktıya eşler [53]. ESA, katmanlarından en az birinde genel matris çarpımı yerine evrişimi kullanan basit sinir ağlarıdır. ESA derin öğrenme alanındaki en önemli ağlardan biridir. ESA, bilgisayar görüşü ve doğal dil işleme dâhil, ancak bunlarla sınırlı olmamak üzere birçok alanda etkileyici başarılı sonuçlar elde etmiştir. ESA'nın ortaya çıkışı YSA'dan ayrılmaz [54]. 1943'te McCulloch ve Pitts biyolojik nöronların karmaşık hesaplamaları basitleştirmek için ilk matematiksel modelini, (MP) modelini önerdiler [55]. 1950'lerin sonunda Rosenblatt bu modele öğrenme yeteneği ekleyerek tek katmanlı bir algılayıcı modeli önerdi. Ancak, tek katmanlı algılayıcı ağ, doğrusal ayrılmaz sorunları işleyemez [56]. 1986'da Hinton ve arkadaşları tek katmanlı algılayıcının çözemediği bazı sorunları ele alan, hata geri yayılım algoritması tarafından eğitilmiş çok katmanlı bir ileri beslemeli ağ önerdi [57]. Günümüze kadar birçok aşamadan geçerek şu anda kullanılan birçok algoritmanın temeli oluşturulmuştur.

Sınıflandırma başta olmak üzere birçok bilgisayarlı görü alanında kullanılan evrişimsel sinir ağları klasik sinir ağlarından farklı olarak, evrişim özellik çıkarma ve sınıflandırma katmanlarını içermektedir. Şekil 2. 9'da evrişimsel sinir ağı yapısının katmanları ve eğitim ile ilgili sınıflandırma aşamalarının genel bir gösterimine yer verilmiştir.



Şekil 2. 9. Evrişimsel sinir ağı yapısının katmanları [58]

Evrişim katmanı, ESA'ların temel parçasıdır. Bağlantı ağırlıklarını ve ağırlıklı toplamları kullanan diğer sinir ağlarından farklı olarak, evrişim katmanı, orijinal görüntülerin özellik haritalarını oluşturmak için evrişim çekirdeği adı verilen görüntü


dönüştürme filtrelerini kullanır. Evrişim katmanı, bir dizi evrişim çekirdeğidir. Evrişim çekirdeği görüntüler üzerinde kayar ve bir özellik haritası oluşturmak için üzerinde yüzdüğü piksellerin ağırlıklı toplamı ile yeni bir piksel hesaplar. Öznitelik haritası, orijinal görüntü için bir yönün özelliklerini yansıtır.

2.6.1.1. Giriş Katmanı

Giriş katmanı; üç katmanlı bir matris şeklinde olan ESA'nın ilk katmanıdır. Temsil edilen ağa beslenecek görüntü verilerini içerir. Ağın öğrenmedeki başarısı açısından verinin büyüklüğü, önem arz eder. Geniş hacimli veri, başarıyı çoğaltırken eğitim zamanını ve hafıza ihtiyacını da artırmaktadır. Giriş verisi küçük olduğunda ise eğitim zamanı azalırken, buna paralel olarak öğrenme de zor bir duruma dönüşür [59].

2.6.1.2. Evrişim Katmanı


Evrişim katmanı; ESA algoritmalarında görüntüyü ele alan ilk katmandır. Bilindiği üzere görseller aslında içlerinde belirli değerler taşıyan piksellerden oluşan matrislerdir. Evrişim katmanında da orijinal görsel boyutlarından daha küçük bir filtre görselin üzerinde gezer ve bu görsellerden belirli özellikleri yakalamaya çalışır. Evrişim katmanı, ESA'nın ana yapı taşıdır ve çoğu hesaplamalar bu katmanda yapılır. Nesne algılama algoritmaları ilkesine göre, ESA'ya dayalı görüntü yangın algılama algoritmalarının akışı Şekil 2. 10'da ki gibi tasarlanmıştır. Algılama ESA'sı bölge önerileri, özellik çıkarma ve sınıflandırma işlevlerine sahiptir. İlk olarak, ESA bir görüntüyü girdi olarak alır ve evrişim, havuzlama vb. ile bölge önerileri çıkarır. İkinci olarak bölge tabanlı nesne algılama; ESA, evrişimli katmanlar, havuzlama katmanları, tam bağlı katmanlar aracılığıyla teklif bölgelerinde yangının varlığına veya yokluğuna karar verir [3].



Şekil 2. 10. Algılama ESA'larına dayalı yangın algılama algoritmalarının akış şeması

2.6.1.3. Aktivasyon Katmanı

Son tam bağı katmana uygulanan aktivasyon fonksiyonu, genellikle diğerlerinden farklıdır. Her göreve göre uygun bir aktivasyon fonksiyonunun seçilmesi gerekir. Çok sınıflı sınıflandırma görevine uygulanan bir aktivasyon fonksiyonu, normalleştiren bir softmax fonksiyonudur [53]. Evrişim katmanında yapılan matematiksel işlemler sonrasında ağ çıktısı doğrusal bir yapıya dönüşür. Aktivasyon katmanında kullanılan doğrusal olmayan aktivasyon fonksiyonları ile doğrusal hale gelmiş ağ tekrar doğrusal olmayan bir şekilde biçimlendirilir. Böylece ağın daha süratli öğrenmesi sağlanır [60]. Şekil 2. 11'de sinir ağlarının eğitiminde yararlanılan çeşitli aktivasyon fonksiyonları gösterilmiştir.



Şekil 2. 11. Farklı aktivasyon fonksiyonları

2.6.1.4. Havuzlama Katmanı

İsteğe bağlı olarak yer alan ve veri boyutunu küçültmek maksadıyla, çoğunlukla ESA'nın aktivasyon fonksiyonlarından sonra kullanılan katmandır. Ağın genişlik ve yüksekliğinde azaltma yapmak bu katmanda olur. Havuzlama katmanı ağın ezberlemesini önler. Bunun sebebi bilgi kaybına neden olan boyut azaltma, sonraki katmanlar için hesaplama yükünü azaltmasındandır. Havuzlama işlemi, havuzlama katmanında da bazı filtreler görüntü üzerinde gezdirilerek, görüntüdeki piksellerin azami değeri ya da piksel değerlerinin ortalaması alınarak yapılır [61].

2.6.1.5. Tam Bağlantılı Katman

Tek boyutlu (1D) bir sayı dizisi (veya vektör) ve yoğun katmanlar olarak da bilinen bir veya daha fazla tamamen bağı katmana bağı olup, burada her girdi her çıktıya öğrenilebilir bir ağırlıkla bağlanır. Evrişim katmanları tarafından çıkarılan ve havuzlama katmanları tarafından alt örneklenen özellikler oluşturulduktan sonra, bunlar sınıflandırma

görevlerindeki her sınıf için olasılıklar gibi, ağın nihai çıktılarına tam olarak bağlı katmanların bir alt kümesi tarafından eşlenir. Nihai tamamen bağlı katman tipik olarak sınıf sayısı ile aynı sayıda çıkış düğümüne sahiptir [53]. Farklı mimarilerde değişen sayılarda bulunabilen bu katman, geleneksel bir sinir ağında nöronların düzenlenmesine benzer. Bu nedenle, tamamen bağlı bir katmandaki her düğüm, hem kendisinden önceki hem de sonraki katmanda yer alan her düğüme doğrudan bağlıdır. Bu katmandaki tüm nöronlar birer vektör olarak görüldüğünden önce düzleştirilir ve ağın son kısmında yer alarak genellikle sınıf belirleme gibi hedeflerin optimize edilmesi amacıyla kullanılır. Tam bağlantılı katmandan elde edilen verilerin ait olduğu sınıfların belirlenebilmesi için bir sınıflandırıcıya ihtiyaç duyulmaktadır.

2.6.1.6. Çıkış Katmanı

Evrişim ve havuzlama katmanları, orijinal görüntülerden yalnızca özellikleri çıkarabilir ve parametre sayısını azaltabilir. Ancak, nihai çıktıyı oluşturmak için ihtiyacımız olan sınıf sayısına eşit bir çıktı üretmek için tam bağlantılı bir katman uygulamamız gerekir. Bu sayıya sadece evrişim katmanları ile ulaşmak zorlaşır. Evrişim katmanları 3B aktivasyon haritaları oluştururken, çıktıya sadece bir görüntünün belirli bir sınıfa ait olup olmadığı konusunda ihtiyacımız vardır. Çıktı katmanı, tahmindeki hatayı hesaplamak için kategorik çapraz entropi gibi bir kayıp işlevine sahiptir. Bu katmandaki nöronların sayısı veri kümesindeki sınıf sayısına eşittir. Softmax veya Lojistik Katman, ESA'nın son katmanıdır. Lojistik Katman, ikili sınıflandırma için kullanılırken Softmax, çoklu sınıflandırmalar için tercih edilir.

3. MATERYAL VE YÖNTEM

Bu bölümde çalışma için kullanılacak DÖA tabanlı ESA'lar ve veri setleri ile bilgiler anlatılacaktır. Çalışmada yapılacak işlemler ve kullanılacak algoritmalar için kodlamada ve görüntü işlemede birçok kolaylık sunan MATLAB [5] programından faydalanılmıştır. Aynı zamanda bu program veri setinin eğitilmesi, test edilmesi ve karşılaştırmalı analizinde de kullanılmıştır. Kullanılan veri kümesinin %20'lik kısmı test verisi olarak geriye kalan % 80'lik kısmı ise eğitim verisi olarak kullanılmıştır.

3.1. Kullanılan Derin Öğrenme Algoritma Tabanlı ESA'lar

Derin Öğrenme Algoritmalarının ortaya çıkması YZ'ye olan ilgi ve alakanın sonucudur. Bu tez çalışmasında farklı sorunların çözümlerine yönelik geliştirilen ve Çizelge 3.1'de verilen birbirlerine göre farklı özellik ve kabiliyetteki 20 DÖA tabanlı ESA tercih edilmiştir.


Çizelge 3.1. Tezde Kullanılan DÖA tabanlı ESA'lar

KULLANILAN ESA'lar	
1	AlexNET [17]
2	DarkNET-19 [25]
3	DarkNET-53 [31]
4	DenseNet-201 [34]
5	EfficientNET-b0 [29]
6	GoogLeNET [20]
7	Places365
8	Inception-ResNet-v2 [33]
9	Inception-v3 [30]
10	MobileNET-v2 [22]
11	NASNET-Large [36]
12	NASNET-Mobile [28]
13	ResNET-101 [27]
14	ResNET-18 [21]
15	ResNET-50 [26]
16	ShuffleNET [19]
17	SqueezeNET [18]
18	VGG-16 [23]
19	VGG-19 [24]
20	Xception [32]

3.1.1. AlexNet Mimarisi

AlexNet, ilk olarak 2010 yılında ImageNet Büyük Ölçekli Görsel Tanıma Yarışmasında (IBÖGTY) ortaya çıkmış Krizhevsky tarafından önerilen derin bir ESA yapısına aittir [62]. AlexNet, diğer tüm geleneksel makine öğrenimi ve bilgisayarla görme yaklaşımlarına karşı, üstün bir şekilde tanıma doğruluğu elde etti. Görsel tanıma ve sınıflandırma görevleri için makine öğrenimi ve bilgisayar görüşü alanında önemli bir atılımdı ve tarihte derin öğrenmeye ilginin hızla arttığı noktadır [63]. 650.000 nöron içeren sinir ağı ve 60 milyon parametre ile beraber 3 tam bağlantılı katman ve 5 evrişim katmanı ile bunların birçoğunu takip eden maksimum havuzlama katmanından oluşmaktadır [64].

Girdi verilerinin boyutu $227 \times 227 \times 3$ olması gerekir. 1. evrişim katmanı 11×11 boyutunda 96 filtreden meydana gelir. Daha sonraki evrişim katmanı filtre boyutu 5×5 , öteki evrişim katmanların filtre boyutu 3×3 olmaktadır. AlexNet mimarisinde havuzlama katmanlarında maksimum havuzlama yöntemi kullanılırken, aktivasyon fonksiyonu olarak RELU kullanılmaktadır. Şekil 3. 1'de AlexNet modelinin genel yapısı verilmiştir.




Şekil 3. 1. AlexNet modelinin genel yapısı [64]

3.1.2. VGG-16 Mimarisi

13 evrişimli, 2 tamamen bağlı katman ve 1 SoftMax sınıflandırıcı katmandan oluşan VGG-16 mimarisini; Karen SİMONYAN ve Andrew ZİSSERMAN, 2014 yılında Büyük Ölçekli Görüntü Tanıma için Çok Derin Evrişimli Ağ adlı makalelerinde tanıttılar. Karen ve Andrew, evrişimli ve tamamen bağlantılı katmanlardan oluşan 16 katmanlı bir ağ oluşturdular. Birinci ve ikinci evrişimli katmanlar 64 adet öznetelik çekirdek filtresinden oluşur ve filtrenin boyutu 3×3 'tür. Girdi görüntüsü (derinliği 3 olan RGB görüntüsü) birinci

ve ikinci evrişim katmanına geçerken boyutlar $224 \times 224 \times 64$ olarak değişir. Daha sonra elde edilen çıktı, 2'lik bir adımla maksimum havuzlama katmanına geçirilir. Üçüncü ve dördüncü evrişimli katmanlar, 124 öznitelik çekirdek filtresinden oluşur ve filtre boyutu 3×3 'tür. Bu iki katmanı adım 2 ile bir maksimum havuzlama katmanı takip eder ve ortaya çıkan çıktı $56 \times 56 \times 128$ 'e düşürülür. Beşinci, altıncı ve yedinci katmanlar çekirdek boyutu 3×3 olan konvolüsyonel katmanlardır. Üçü de 256 özellik haritası kullanır. Bu katmanları adım 2 ile bir maksimum havuzlama katmanı takip eder. Sekizden on üçe kadar, çekirdek boyutu 3×3 olan iki evrişimli katman kümesidir. Tüm bu evrişimli katman kümeleri, 512 çekirdek filtresine sahiptir. Bu katmanları, 1 adımlı maksimum havuzlama katmanı takip eder. 14 ve 15. katman, 4096 birimlik tamamen bağlantılı gizli katmanlardır ve ardından 1000 birimlik bir softmax yani 16. çıktı katmanı gelir [65]. Şekil 3. 2'de VGG-16 mimarisi yer almaktadır [66].




Şekil 3. 2. VGG-16 mimarisi[66]

3.1.3. VGG-19 Mimarisi

VGG19; 2014 yılında küresel bir görüntü tanıma yarışması olan IBÖGTY’de, bir sınıflandırma ve yerelleştirme yarışmasında birincilik kazandı [67]. VGGNet, ESA modelini temel alır ve ImageNet veri setine uygulanır. VGG-19, basitliği nedeniyle kullanışlıdır. Çünkü 3×3 evrişimli katmanlar, derinlik seviyesi ile artacak şekilde üste monte edilmiştir. Hacim boyutunu azaltmak için, VGG-19’da işleyici olarak maksimum havuzlama katmanları kullanılmıştır [68]. Oxford Üniversitesi’nde bulunan “Visual Geometry Group” isimli gruptan almış olup, sonda ki sayı ise 19 katman olduğunu göstermektedir. VGG19 mimari için de, 1 SoftMax, 3 full connected layer, 5 MaxPool, 16


konvolüsyon katmanı içermektedir. VGG-19 mimarisi 19,6 milyar flop'a sahiptir. Ayrıca VGG'nin farklı çeşitleri de bulunmaktadır. Görsel geometri grup ağı (VGGNet), çok katmanlı bir işleme sahip derin bir sinir ağı mimarisidir. Şekil 3. 3'te VGG-19 ağına ait mimari yapı gösterilmiştir.




Şekil 3. 3. VGG-19 Ağına Ait Yapısı [69]

3.1.4. GoogLeNET Mimarisi

GoogLeNet, yirmi iki katmanlı evrişimli bir yapay sinir ağı modelidir. ImageNet veri tabanı kullanılarak eğitilmiştir [70]. Inception v1 olarak bilinen GoogLeNet, Christian Szegedy ve arkadaşları tarafından geliştirilmiştir [71]. 2014 yılında, daha önce geliştirilen evrişimli sinir sisteminden daha küçük ve daha hızlı bir ağı olarak diğer sinir ağlarına göre farklı bir yöntem oluşturulmuştur [72]. GoogLeNet mimarisi Şekil 3. 4'de görüldüğü üzere; görüntüleri klavye, kurşun kalem, birçok hayvan çeşidini ve diğerleriyle toplamda 1000 ayrı nesneyi gruplandırarak sınıflandırabilmektedir.



A) Başlangıç modülü ,saf versiyon



B) Boyut azaltmalı başlangıç modülü

Şekil 3. 4. GoogLeNet ağı [69]


Places365 verileriyle eğitilen ağ mimarisi; ImageNet'te eğitilen ağı benzese de görüntüleri park, alan, pist ve lobi gibi 365 farklı yer kategorisine sınıflandırmaktadır. Her bloğa 'inception' adı verilmektedir. Toplam 9 inception bloğundan oluşan modele, LeNet modeline atıf yapılarak GoogLeNet adı verilmiştir [73]. IBÖGTY Challenge 2014 sınıflandırma yarışmasında burada dış verilerle ilgili herhangi bir eğitim almadan %6.67'lik bir ilk 5 hata oranı ile IBÖGTY 2014'te diğer sinir ağlarından daha iyi puanlar aldı ve mücadeleyi kazandı [74].

3.1.5. Places-365

Aktarım öğrenimini kullanarak yeni bir görevi gerçekleştirmek için bir GoogLeNet ağını yeniden eğitebilirsiniz. Transfer öğrenimi gerçekleştirirken, en yaygın yaklaşım, ImageNet veri setinde önceden eğitilmiş ağı kullanmaktır. Yeni görev, sahneleri sınıflandırmaya benzerse, Places-365'te eğitilmiş ağı kullanmak daha yüksek doğruluk sağlayabilir. Places-365 çok çeşitli görüntüler için farklı özellik temsillerini öğrenmiştir. Önceden eğitilmiş bu ağ 224'e 224 görüntü giriş boyutuna sahiptir [75].

3.1.6. ResNET-18 Mimarisi

Derinlik artışının neden olduğu gradyan kaybolması/ patlaması ve performans düşüşü sorunu çözmek için Kaiming HE ve arkadaşları tarafından 2015 yılında ResNet'i önerdi. Aynı zamanda ResNet, görüntü sınıflandırmasında da iyi bir performansa sahiptir. ResNet-18, bir 7x7 konvolüsyonel katman, 2 havuz katmanı, 8 artık birim ve bir tam bağlı katmandan oluşur. Kalan birimlerin her biri iki adet 3x3 konvolüsyonel katman içeren ve tam bağlantılı 10 çeşit TUSP görüntüsünden oluşmaktadır [76]. Şekil 3. 5'de ResNET-18 model mimarisine ait katmanlar gösterilmiştir.




Şekil 3. 5. ResNET-18 model mimarisi [76]

3.1.7. ResNET-50 Mimarisi

Transfer öğreniminde AlexNet, GooLeNet, VGG modelleri daha yaygındır. ESA ağlarıyla ilgili bazı zorluklar vardır. Bunlar ağların optimizasyonu, kaybolan gradyan sorunu ve bozulma sorunları gibi. ResNet yeni bir çözüm sunarak; karmaşık görevleri çözüp, ayrıca algılama doğruluğunu artırıyor. ResNet, derin ESA'nın eğitim sürecindeki zorlukları, doyumluğu ve doğruluğun bozulmasını çözmeye çalışır. ResNet50'de 50 katman vardır.

Eğri çizgileri, sonra ki katmanlarda önceki katmanların kullanımını belirtmek için kullanılan tanımlama bloklarını temsil eder. ResNet50'deki temel fark, çok derin ağların eğitiminde kaybolan veya patlayan gradyanların bozulma ve taklit sorununun olmasıdır [77].




Şekil 3. 6. ResNET-50 Mimarisi [78]

Şekil 3. 6’da ResNET-50 mimarisinin yer aldığı görseldeki gibi farklı katman gruplarına sahiptir. Birinci katman çekirdek boyutu 7×7 olan 64 filtreye sahiptir Bunu 3×3 boyutunda bir maksimum havuzlama katmanı takip eder. İlk katman grubu üç özdeş bloktan oluşur. Aynı şekilde 2.grupta 4 özdeş blok, 3. grupta 6 özdeş blok varken, 4. grupta 3 özdeş blok bulunmaktadır. Tüm bu bloklardan sonra, sınıflandırma görevinden sorumlu toplamda 38 tam bağlantılı katman vardır [77].

3.1.8. ResNET-101 Mimarisi


ResNet tasarımında VGG-19 modelinden esinlenilmiştir. IBÖGTY için önerilen en derin mimarilerden biridir. Genellikle, bir ESA’da birkaç katman birbirine bağlıdır ve çeşitli görevleri yerine getirmek için eğitilir. Ağ, katmanlarının sonunda birkaç özellik düzeyi öğrenir. Bu modeldeki evrimsel katmanların boyutu çoğunlukla 33 filtreye sahiptir. ResNet’te, katmanlar aynı çıktı özellik haritası boyutu için aynı sayıda filtreye sahiptir ve her katman için zaman karmaşıklığını korumak için özellik haritası boyutu yarıya indirilirse, filtre sayısı iki katına çıkar. Alt örneklemeyi, katmanları iki adımda katlayarak doğrudan yürütür. Bu ResNet, global bir ortalama havuzlama katmanı ve bir SoftMax ile etkinleştirilen tam bağlantılı katman ile sona erer. ResNet-101, 101 katmanlı artık ağıdır ve 50 katmanlı ResNet’in değiştirilmiş bir sürümüdür [79]. Şekil 3. 7’de ResNet-101 tabanlı derin özellik çıkarıcının yapısına ait mimarinin yapısı yer almaktadır.



Şekil 3. 7. ResNet-101 tabanlı derin özellik çıkarıcının yapısı [80]

3.1.9. ShuffleNET Mimarisi

ShuffleNet; son teknoloji bir ağ mimarisi olup hesaplama açısından oldukça iyi bir ESA mimarisidir. Cep telefonları gibi düşük kaliteli cihazlarda yaygın olarak benimsenmiştir [81]. Zhang ve arkadaşları tarafından çok sınırlı bilgi işlem gücüne sahip taşınabilir yani mobil cihazlar için özel olarak tasarlanmış olan ShuffleNet mimarisi analiz kabiliyeti bakımından da oldukça randımanlı sonuçlar veren bir ESA'dır. Yeni mimari, doğruluğu korurken hesaplama maliyetini büyük ölçüde azaltmak için noktasal grup evrişimi ve kanal karıştırma olmak üzere iki yeni işlem kullanmaktadır. Bir mobil cihazda ShuffleNet, karşılaştırılabilir doğruluğu korurken AlexNet'e kıyasla yaklaşık 13 kat gerçek hızlanma elde etmiştir [82]. Şekil 3. 8'de kanal karıştırma işleminden yararlanarak küçük ağlar için özel olarak tasarlanmış yeni bir ShuffleNet birimi gösterilmiştir.




Şekil 3. 8. Yığılmış iki grup kıvrımı ile kanal karıştırma işlemi [83]

Şekil 3. 8’de gösterildiği üzere; a) Aynı sayıda gruba sahip iki küme konvülosyon katmanı. Her çıkış kanalı yalnızca grup içindeki giriş kanallarına bağlıdır. Çapraz bağ yok b) GrupConv2 ve GrupConv1’in farklı kümelerden çapraz bağlanması c) Kanalların çapraz bağlanarak elde edildiği Shuffle katmanıdır [84].

3.1.10. MobileNet Mimarisi


MobilNet; mobil uygulamalarda kullanılan derin öğrenme mimarilerinin ilk akla gelen örneklerindendir. Şekil 3. 9’da MobileNetV2 modelinin mimarisi yer almaktadır. Mobil uygulamalar için tasarlanmış olsa bile, masaüstü uygulamalarda da tercih edilmektedir. ESA tabanlı MobileNetV2, görüntüleri sınıflandırmak için yaygın olarak kullanılan bir mimaridir. Bu mimarinin en büyük faydası bilinen ESA modeline oranla daha az hesaplama yapmasıdır [85]. Böylelikle, düşük donanımına sahip bilgisayarlar ve mobil cihazlar üzerinde de çalışmaya daha elverişli bir mimaridir [86].



Şekil 3. 9. MobileNet V2 modelinin mimarisi [87]

3.1.11. NASNET-Mobile Mimarisi


Nasnet, pekiştirmeli öğrenme kullanılarak optimize edilmiş temel yapı taşlarından yani hücrelerden oluşan ölçeklenebilir bir ESA mimarisidir. Bir hücre yalnızca birkaç işlem (birkaç ayrılabilir evrişim ve havuzlama) oluşur ve ağırlıklı kapasitesine göre birçok kez tekrarlanır. Mobil sürümü (Nasnet-Mobile) 5,3 milyon parametre ve 564 milyon çarpma kapasiteli 12 hücreden oluşur [88]. Şekil 3. 10'da NASNET-Mobile ait örnek mimari gösterilmiştir.



Şekil 3. 10. NASNET-Mobile mimarisi [89]

3.1.12. EfficientNET-B0 Mimarisi


Şekil 3. 11'de Efficientnet-B0 mimarisine ait görsel yer almaktadır. EfficientNet-B0 (224x224x3) giriş şekline sahiptir ve ImageNet ağırlıkları ile yüklenmiştir. Bu model, eğitilebilir parametreleri fazlasıyla azaltan ters döndürülmüş artık bloğu kullanır. En son kullanılan ESA modellerine göre yüksek doğruluk ve daha iyi verimlilik sonuçlarıyla, parametre boyutunu ve saniyede kayan nokta (floating-point per second) büyüklük sırasına göre azalttığı görülmüştür [90].



Şekil 3. 11. Efficientnet-B0 Mimari Görüntüsü [91]

3.1.13. Inception-v3 Mimarisi

Inception-v3 modeli daha çok görüntü tanımda kullanılır ve önceden tanımlanmış bir ESA'dır. Toplam olarak 28 katman içerir [91]. Inception-v3 ağ modeli TensorFlow'da önceden eğitilmiş modellerden biridir. 2015 yılındaki Inception-v1, Inception-v2 sonrasında bilgisayarla görmenin ilk yapısının yeniden düşünülmesidir. Inception-v3 modeli, 1000 kişiyi tanımlayabilen bilgileri içeren ImageNet veri kümeleri ile %3,5 hata oranı üzerinden eğitilmiştir. TensorFlow ayrıca transfer öğrenimini kullanarak Inception'ın son katmanını yeni kategoriler için yeniden eğitmek için ayrıntılı öğreticiler sağlar. Düşük tasarımlı (işlemci, ram, ekran kartı gibi) bir bilgisayar ile doğrudan eğitmek çok zordur ve bu en az birkaç gün sürebilir [92]. Inception algoritmasında, katman olarak derine inmek yerine genişlemek temel amaçtır. Şekil 3. 12'de Inception-v3 modelinin genel ağ yapısı verilmiştir.



Şekil 3. 12. Inception-v3 modelinin mimarisi [73]

3.1.14. DarkNet-19 Mimarisi

2016 yılında Joseph Redmon ve ark. [93] tarafından önerilen DarkNet-19 ağı 20,8 milyon parametre içerir ve ağ tamamen bağlı katmanlar yerine evrişimli katmanlar kullanır [94]. 5 maksimum havuzlama katmanı ve 19 konvolüsyonel katmanından oluşan DarkNet-19 mimarisi Şekil 3. 13’de gösterilmektedir

	Type	Filters	Size	Output
1x	Convolutional	32	3 × 3	256 × 256
	Convolutional	64	3 × 3 / 2	128 × 128
	Convolutional	32	1 × 1	
	Convolutional	64	3 × 3	
	Residual			128 × 128
2x	Convolutional	128	3 × 3 / 2	64 × 64
	Convolutional	64	1 × 1	
	Convolutional	128	3 × 3	
	Residual			64 × 64
8x	Convolutional	256	3 × 3 / 2	32 × 32
	Convolutional	128	1 × 1	
	Convolutional	256	3 × 3	
	Residual			32 × 32
8x	Convolutional	512	3 × 3 / 2	16 × 16
	Convolutional	256	1 × 1	
	Convolutional	512	3 × 3	
	Residual			16 × 16
4x	Convolutional	1024	3 × 3 / 2	8 × 8
	Convolutional	512	1 × 1	
	Convolutional	1024	3 × 3	
	Residual			8 × 8
	Avgpool		Global	
	Connected		1000	
	Softmax			

Şekil 3. 13. DarkNet-19 mimarisi [95]

YOLOv2’nin [96] omurgası olarak kullanılan evrişimli bir sinir ağıdır. Çoğunlukla kullandığı VGG modellerine benzer 3x3 her havuzlama adımından sonra kanalları filtreler ve sayısını ikiye katlar. Network in Network (NIN) üzerinde yapılan çalışmanın ardından, tahminler yapmak için küresel ortalama havuzlamayı kullanır. 1×1 arasında özellik temsilini sıkıştırmak için filtreler 3×3 kıvrımlar. Toplu normalleştirme, eğitimi sabitleştirmek, yakınsamayı hızlandırmak ve model grubunu düzenli hale getirmek için kullanılır.

3.1.15. DarkNET-53 Mimarisi

2018 yılında tanıtılan DarkNet-53, gerçek zamanlı nesne algılama ağı YOLOv3’te temel özellik çıkarma modülü olarak kullanılmaktadır[94]. YOLO ImageNet veri kümesi üzerinde eğitilmiş 53 katmanlı bir ağa sahip olan DarkNet’in bir varyantını kullanmaktadır [97]. Algoritma; ayrıca mimarisinde artık bloklar, ağ bağlantıları ve üst örnekleme gibi birçok önemli öğeyi de içerir. Algılama görevi için üzerine 53 katman daha yığılır ve bu


da bize YOLO için 106 kat tamamen evrişimli bir mimari sağlar [98]. ResNet ile karşılaştırıldığında DarkNet-53 daha iyi performansa sahiptir ve 1,5 kat daha hızlıdır. Kısa yol bağlantılarına sahip DarkNet-53 ve özellik harita örnekleme ve birleştirme yeteneklerine sahiptir [94]. DarkNet-53 genellikle nesne algılama sorunları ve YOLO iş akışların da temel olarak kullanılır. Şekil 3. 14’de DarkNet-53 ağ yapısına ait görsel yer almaktadır.

Type	Filters	Size	Output
Convolutional	32	3 × 3	256 × 256
Convolutional	64	3 × 3 / 2	128 × 128
1× Convolutional	32	1 × 1	
1× Convolutional	64	3 × 3	
1× Residual			128 × 128
Convolutional	128	3 × 3 / 2	64 × 64
2× Convolutional	64	1 × 1	
2× Convolutional	128	3 × 3	
2× Residual			64 × 64
Convolutional	256	3 × 3 / 2	32 × 32
8× Convolutional	128	1 × 1	
8× Convolutional	256	3 × 3	
8× Residual			32 × 32
Convolutional	512	3 × 3 / 2	16 × 16
8× Convolutional	256	1 × 1	
8× Convolutional	512	3 × 3	
8× Residual			16 × 16
Convolutional	1024	3 × 3 / 2	8 × 8
4× Convolutional	512	1 × 1	
4× Convolutional	1024	3 × 3	
4× Residual			8 × 8
Avgpool		Global	
Connected		1000	
Softmax			

Şekil 3. 14. DarkNet-53 mimarisi [94]

3.1.16. Xception Mimarisi


Xception algoritmasının temel özelliği, modelin ayrılabilir evrişime sahip olmasıdır. Inception tarzı modellerin temel yapı taşı, birkaç farklı sürümü bulunan Inception modülüdür. Inception modülünün ardındaki bu fikir, bağımsız olarak kanallar arası korelasyonlara ve uzamsal korelasyonlara bakacak bir dizi operasyonu açıkça çarpanlara ayırarak, bu süreci daha kolay ve daha verimli hale getirmektir. Daha kesin olarak tipik Inception modülü önce bir dizi 1x1 evrişim yoluyla kanallar arası korelasyonlara bakar. Giriş verilerini orijinal giriş alanından daha küçük olan 3 veya 4 ayrı alana eşler. Ardından bu daha küçük üç boyutlu alanlardaki tüm korelasyonları haritalar. 36 konvolüsyonel katmandan oluşur ve artık bağlantıları olan 14 modüle yerleştirilmiştir [99]. Xception olarak adlandırılan bu mimari, ImageNet veri kümesinde, 350 milyon görüntü ve 17000 sınıftan oluşmaktadır. Xception mimarisi, Inception V3 ile aynı sayıda parametreye sahip olduğundan performans kazanımları artan kapasiteden değil, daha çok



Şekil 3. 16. Inception-Resnet [101]

3.1.18. DenseNet-201 Mimarisi


201 adet katman içeren DenseNet-201, derin öğrenme ağından oluşmaktadır. Katmanlar doğrudan diğer tüm katmanlarla ilintilidir. Yani bir katmana önceki katman ile birlikte arkasında kalan bütün katmanlardan bilgi girişi bulunmaktadır [102]. DenseNet-201 ağının katmanlarının birbirleriyle aracısız bağlantıları sayesinde, özneteliği yeniden kullanmaya yönelik avantajı vardır. Fakat katmanların bağlantıları dolayısıyla, büyük bir sisteme ihtiyaç duyulması ağın olumsuz tarafıdır [103]. Şekil 3. 17’de DenseNet-201 ağ yapısına ait görsel yer almaktadır.



Şekil 3. 17. DenseNet-201 ağ yapısı [90]

3.1.19. SqueezeNET Mimarisi

Bir ESA modeli olarak başvuru alan mimarilerden biride SqueezeNET mimarisidir. SqueezeNET mimarisi Iandola ve arkadaşları tarafından 2016 yılında sunulmuştur [104]. SqueezeNET mimarisinin hedefi daha az parametreye sahip, bir sinir ağı oluşturmak ve 50 kat daha az parametre ile AlexNet düzeyinde doğruluk sağlamaktır. SqueezeNET mimarisinin avantajı ise daha verimli dağıtılmış katmanlar sayesinde, sinir ağındaki iş yükü azalmakta ve bu nedenle de daha hızlı çalışmaktadır [105]. Şekil 3. 18’de SqueezeNET yapılandırma detayları gösterilmektedir.




Şekil 3. 18. SqueezeNET yapılandırma detayları [106]

3.1.20. NASNET-Large Mimarisi

NAS terimi, makine destekli verimli sinir ağı mimari tasarımına yönelik gelişmekte olan bir araştırma alanını ifade eder. Budama, niceleme ve tensör ayrışımına dayalı verimli ağ tasarımlarının aksine NAS, temel modele dayanmadan verimli bir derin sinir ağılar arar. Bir süper ağı eğitmek, örneklenmiş ağıları değerlendirmek ve keşfedilen ağı eğitmek modern NAS mimarilerindeki üç temel süreçtir [107]. Google, geniş bilgisayar kapasitesi ve mühendislik yeteneği sayesinde ideal ESA mimarisini bulma görevini bir Pekiştirmeli Öğrenme(PÖ) sorunu olarak tanımlayan Neural Architecture Search Network-Large (NASNet-Large) hizmetini başlatmış olup, esas amaç verilen arama uzayında filtre boyutları, çıkış kanalları, adımlar, katman sayısı ve diğer özelliklerin en uygun kombinasyonunu bulmaktır. Verilen veri kümesinde aranan mimarinin doğruluğu, bu PÖ ortamındaki her arama döngüsünün telafisidir. ImageNet yarışmasında NASNet-Large çok başarılı bir sonuç aldı. ESA NASNet-Large, ImageNet koleksiyonundaki bir milyondan fazla fotoğraf ile eğitilmiştir. Ağ, 1000 farklı nesne sınıfına ayırabilir. Sonuç olarak ağ,

çeşitli görüntüler için çeşitli zengin özellik yorumlamaları öğrenmiştir. Ağın resim giriş boyutu 331×331 pikseldir [108]. Şekil 3. 19’da NASNET-Large genel ağ yapısına ait mimari yer almaktadır.



Şekil 3. 19. NASNET-Large genel mimarisi

3.2. Kullanılan Yangın Veri Seti

Kaggle, veri bilimi zorluklarına ev sahipliği yapmanın yanı sıra çok sayıda veri kümesinin yanında, bulut tabanlı bir veri bilimi ortamı da sağlar. Birçok veri setini barındıran, açık bir veri platformu olarak şekillenmiştir. Bununla beraber, kullanıcılarına en son teknoloji konteynerizasyon teknolojisiyle desteklenen web tabanlı bir veri bilimi ortamı sağlamaya başlamıştır [109]. Google LLC(limited liability company)’nin bir yan kuruluşu olan Kaggle, veri bilimciler ve makine öğrenimi uygulayıcılarından oluşan çevrimiçi bir platformdur. Kaggle, kullanıcıların veri kümelerini bulmasına ve yayınlamasına, web tabanlı bir veri bilimi ortamında modeller keşfetmesine olanak tanır. Kaggle ilk olarak 2010 yılında makine öğrenimi yarışmaları sunarak başlamıştır. Ayrıca bir genel veri platformu , veri bilimi için bulut tabanlı bir çalışma alanı ve YZ eğitimi sunmaktadır.

Bu çalışmada Kaggle’den temin edilen [110,111] farklı iki veri setinden istifade ettik. Kullanılan görüntüler değişken boyutlarda JPG ve PNG formatındadır. Bu veri kümelerinden birinde, sadece yangın görseli olup 110 adet ve JPG formatındadır. Diğer

veri seti ise iki kategoriye (yangın ve yangın olmayan) sahip görüntüler içerir. Bu veri setindeki yangın görseli sayısı 755'tir. 244 adedi de, yangının olmadığı görselden oluşur ve PNG formatındadır. Birleştirilmiş iki genel yangın görüntüsüyle meydana getirilen veri seti ile bilgiler Çizelge 3. 2'de tablo halinde gösterilmiştir. Veriler 2 klasöre ayrılmıştır. Yangın var klasörü 865 adet yangın görüntüsünden oluşmaktadır. Bunlardan bazıları yoğun duman içerir. Yangın yok klasörü ise 244 doğa görüntüsü içermektedir(Ör: orman, çimen, nehir, insanlar, sisli orman, göl, hayvan gibi). Yangın tespitinde derin öğrenme algoritmalarının karşılaştırmalı analizi için yangının olduğu ve yangının olmadığı görüntüler gerekir. DÖA'nın mukayese edilebilmesi yani yangını algılama doğruluğu, yangını tespit süresinin hızı ve hassasiyeti bakımından ölçümü için veri setine gereksinim vardır. Bunun için paylaşıma açık olan; Fire Dataset içindeki Fire Images ve Non Fire Images veri setlerinden yararlanarak test edilmiştir. Bu veri setine ait bilgiler Çizelge 3.2'de gösterilmiştir.

Çizelge 3.2. Tezde Kullanılan Veri Seti


	Oran	Veri Seti	Yangının Olduğu Görüntüler	Yangının Olmadığı Görüntüler	Toplam Görüntü Sayısı
Eğitim	%80	Kaggle	865	244	1109
Test	%20				

Veri setinde, 865 adet yangının olduğu(fire) ve 244 adet yangının olmadığı(non fire) görüntü olmak üzere toplam da 1109 adet görüntü mevcuttur. Tezde yangının olduğu ve yangının olmadığı görüntülerin % 80'lik kısmına karşılık gelen sayıda görüntü, eğitim için kullanılmıştır. Geriye kalan % 20'lik kısmı ise test verisi olarak değerlendirilmiştir. Veri seti büyüdükçe modelin eğitim süreci de uzamaktadır. Bu durum veri seti büyüklük ve çeşitliliğinin dezavantajıdır.

Veri setimiz de bulunan ve bunlar içerisinde seçilen ve birbirinden farklı yangın görselinin olduğu 9 adet örnek resim görseline Şekil 3. 20'de yer verilmiştir. Bunun yanında Şekil 3. 21'de ise yine veri setinden alınmış örnek 9 adet yangının olmadığı görüntülere yer verilmiştir.



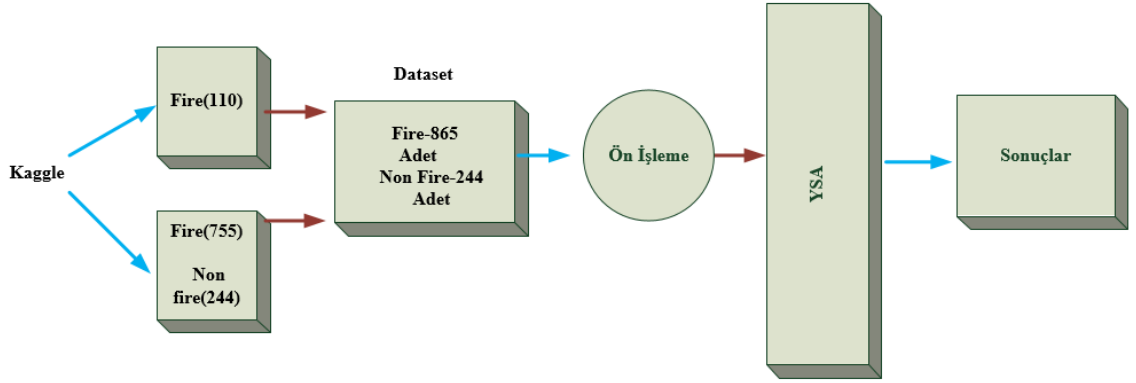
Şekil 3. 20. Veri Setinden Alınmış Örnek Yangın Görüntüleri



Şekil 3. 21. Veri Setinden Alınmış Örnek Yangın Olmayan Görüntüler

3.3. Transfer Öğrenme Yoluyla Yapay Sinir Ağlarının Eğitilmesi

Önce iki farklı veri setinde bulunan resimler alınarak hibrit(melez) bir veri seti oluşturuldu. Bu veri setindeki görüntüler MatLab programında her bir algoritma için 5 kat çapraz doğrulama tekniği kullanılarak eğitildi. Transfer öğrenmede önceden eğitilmiş bir ağın tam bağlantılı katmanı ve sınıflandırma katmanlarının eğitilecek veri setindeki sınıf sayısına uyumlu hale getirilmesi gerçekleştirilmiştir. Ayrıca her bir ağın giriş ölçüleri farklı olabileceğinden veri setindeki resimler ilgili ağ için yeniden boyutlandırılarak(ön işlem) uyumlu hale getirilmiştir. Bu işlemler, çalışmada kullanılan her bir ESA için yapılmıştır. Şekil 3. 22’de transfer öğrenme yoluyla yapay sinir ağlarının eğitilmesine ait görsel yer almaktadır.




Şekil 3. 22. Transfer öğrenme yoluyla yapay sinir ağlarının eğitilmesi

3.3.1. Çapraz Doğrulama Tekniği

Sınıflandırma aşamasında kullanılan 5-kat çapraz doğrulama tekniği topluluk öğrenme sınıflandırıcılarında daha iyi başarımlar elde ettiği gözlemlenmiştir [112]. Çapraz doğrulama tekniği; yapılan bir istatistiksel analizin bağımsız bir veri setinde nasıl bir sonuç elde edeceğini sınavan bir model doğrulama tekniğidir [113]. Başlıca kullanım alanı bir öngörü sisteminin pratikte hangi doğrulukla çalışacağını kestirmektir. Şekil 3. 23’te 5-kat çapraz doğrulama tekniğinin nasıl uygulandığı gösterilmiştir. Çapraz doğrulama tekniği kullanımı, orijinal veri setinin eğitim ve test seti olarak ikiye bölünmesi ile yapılır. Tezde kullanılan veri seti beş parçaya bölünmüştür. Bu beş parçadan biri test diğerleri de eğitim için kullanılmıştır. Böldükten sonra eğitim setiyle tek seferlik eğitip test setiyle doğruluğunu ölçersek bu bize doğru sonuçlar vermeyebilir. Bundan dolayı çapraz doğrulama işlemi yapmak akıllıca bir yöntem olarak kullanılabilir. Veri seti 5’e

bölünüp (her kutu veri setinin temsili 5'e bölünmesini göstermektedir), ardından 1 numaralı kutuyu dışarda tutarak; 2, 3, 4 ve 5 numaralı kutuyla modelimizi eğitiriz. 1 numaralı kutuyla da test ederiz. Daha sonra 2 numaralı kutuyu dışarda tutarak 1, 3, 4 ve 5 numaralı kutuyla modelimizi eğitirken, 2 numaralı kutudaki verilerle test ederiz. Bu şekilde sırayla birini dışarda tutarak diğerlerini eğiterek sonuçları alırız. Bu sonuçların ortalamasını alarak doğrulanmış eğitim başarımızı buluruz. Bu işlemi yapmaktaki temel amaç; veri setinin rastgele olarak eğitim/test olarak bölünmesi esnasında oluşabilecek tesadüfi hataları/başarımları ortadan kaldırarak daha genel bir başarımlar sonucu elde etmektir.



Şekil 3. 23. 5 Kat Çapraz Doğrulama Tekniğinin Uygulanması

3.3.2. Eğitim Parametreleri

3.3.2.1. Kullanılan Bilgisayarın Donanım Özellikleri

Modelimizde kullandığımız algoritmaların görüntülerden yangın tespiti gerçekleştirmesi için oldukça üst düzey performanslı donanıma sahip bilgisayar kullanmak gerekir. Görüntüden yangının tespiti için yüksek performans sağlayan NVIDIA RTX 3090

ekran kartlı donanım üzerinde çalışmalar gerçekleştirilmiştir. Çizelge 3.3'te donanım özellikleri verilen bilgisayar kullanılmıştır.

Çizelge 3.3. Donanım Özellikleri

İşlemci	AMD Ryzen Threadripper PRO 3975WX 32-Çekirdek
Ram ve Sistem	128 GB 64-bit işletim sistemi
Ekran Kartı	NVIDIA RTX 3090
Sürüm	21H2
Düzenleme	Windows Server 2022 Standart

3.3.2.2. Kullanılan Yazılım

Tezde kullanılan MatLab programı; Matrix Laboratory kelimesinin ilk üç harfini alarak isimlendirilmiş ve daha çok matematiksel işlemlerin yapılmasına yönelik tasarlanmış olan bir programlama dilidir. Sistemlerin simülasyonunu ve modellemesini gerçekleştirmeye yarayan görsel bir yazılım ortamıdır [22].

3.3.2.3. Eğitim Seçenekleri

Bu tez çalışmasında yapılan tüm eğitim ve test işlemleri Çizelge 3.4'te gösterilen parametreler kullanılarak gerçekleştirilmiştir.

Çizelge 3.4. Çalışmada Kullanılan Eğitim ve Test Parametreleri

Eğitim Seçenekleri (TrainingOptions)	Değer (Value)
Çözümleyici(Solver)	sgdm
Maksimum döngü sayısı (MaxEpoch)	100
Büyük veri setlerini bölme işlemi (MiniBatch)	64
Öğrenme Hızı (InitialLearnRate)	0.001
Ayrıntılı Frekans (VerboseFrequency)	20
Yürütme Ortamı (ExecutionEnviroment)	gpu
İlk Öğrenme Oranı (InitialLearnRate)	0.001
ÖğrenOranDüşme Faktörü (LearnRateDropFactor)	30
Öğrenme oranını zamanlama (LearnRateSchedule)	Piecewise (Parça parça)

3.3.2.4. Performans Metrikleri

Tezde kullandığımız ESA'ların yangın tespitindeki çalışma başarısını kıyaslarken, kullanacağımız bazı temel değerlendirme metrikleri vardır. Bunları Şekil 3. 24'te yer alan karışıklık matrisi(confusion matrix) ifadeleri ile açıklayabiliriz. Karışıklık matrisi bir sınıflandırma modelinin yaptığı doğru ya da yanlış tahmin edilen örnek sayısını özetleyen matrise denir [114].

		Tahmin Edilen Değerler		
		Pozitif	Negatif	
Gerçek Değerler	Pozitif	TP Doğru Pozitif	FP Yanlış Negatif	Sensitivity (Duyarlılık) $TP/(TP+FN)$
	Negatif	FN Yanlış Pozitif	TN Doğru Negatif	Specificity (Özgüllük) $TN/(TN+FP)$
		Precision (Kesinlik) $TP/(TP+FP)$	Negative Predictive Value Negatif Öngörü Değeri $TN/(TN+FN)$	Accuracy (Doğruluk) $TP+TN/(TP+TN+FP+FN)$

Şekil 3. 24. Karışıklık Matrisi

Bu matris sınıflandırma yaparken, ağın veri üzerindeki sınıf referanslı başarımının gözlenebileceği bir gösterim biçimidir. Bunlar; toplam doğruluk, pozitif yorum gücü, negatif yorum gücü, duyarlılık, F-değerlendirme ve özgüllük değerleridir. Bu değerler hesap edilirken modellerin sonuç sayısı kullanılır. Karışıklık matrisini oluştururken pozitif ve negatif (yangın var, yangın yok) etiketli 2 gruplandırma ortaya konulmuştur. Bu gruplar veya sınıflar tahminin doğru ya da yanlış olmasına göre sınıflandırılır. Çizelge 3.5'te bu modelin oluşturduğu kombinasyon çeşitleri yer almaktadır.

Çizelge 3.5. Modelin Oluşturduğu Kombinasyon Çeşitleri

Doğru pozitif (TP, True Positive)	Doğru tahmin edilen Pozitifler
Yanlış pozitif (FP, False Positive)	Yanlış tahmin edilen Pozitifler
Yanlış negatif (FN, False Negative)	Yanlış tahmin edilen Negatifler
Doğru negatif (TN, True Negative)	Doğru tahmin edilen Negatifler

Yapılan çalışmada doğru-pozitifin anlamı; tezde yürütülen çalışmanın yer aldığı örnek uzayda, gerçekte yangın içeren görsel veriler için, algoritmalar tarafından da yangın içerdiği sonucu çıkarılan işlem sayısına karşılık gelmektedir. Doğru-negatif; gerçekte yangın içermeyen fakat algoritmalar tarafından da yangın içermediği tespit edilen görsel verilere karşılık gelen sayıları ifade eder. Yanlış-pozitif; gerçekte yangın olmadığı halde modelin görselde yangın varmış gibi gruplandırılan veri sayısını ifade eder. Yanlış-negatif ise gerçekte yangın olduğu halde ağın yangın içermiyormuş gibi gruplandırılan veri sayısına karşılık gelen ifadedir. Tezde kullanılan algoritmaların gerçeğe uygun sonuçlar çıkarması doğru-pozitif ve doğru-negatif değerlerin yüksek olduğunu gösterir. Tezde kullanılan algoritmaların gerçeğe uygun sonuçlar bulmaması ise yanlış-pozitif ve yanlış-negatif sayısının fazla olduğunu gösterir. Tezde kullanılan ESA ile alakalı yorum ve karşılaştırma yapabilmek için karışıklık matris verilerinin yanında bazı metriklerden yararlanarak daha gerçekçi yorumlar yapabiliriz. Bunlar Çizelge 3.6'da tablo halinde verilmiştir. Değerler tüm sınıftaki verilerin, veri setimizdeki bulunma sayısına göre hesap edilmiştir.

Çizelge 3.6. Performans Karşılaştırma Metrikleri

Ölçüt	Açıklama	Denklem(Formül)
Kesinlik(Precision)	Gerçek değeri pozitif iken pozitif olarak sınıflandırılan değer sayısının bütün pozitif değere sınıflandırılanların sayısına oranıdır.	$TP / TP + FP$
Doğruluk(Accuracy)	Doğru tahminlerin tahmin edilen tüm değerlere oranını ifade etmektedir.	$\frac{TP + TN}{TP + TN + FP + FN}$
Duyarlılık(Recall)	Gerçek değeri pozitifken pozitif olarak sınıflandırılan değer sayısının bütün gerçek pozitif değer sayısına oranıdır.	$\frac{TP}{TP + FN}$
F-1 (F measure)	Kesinlik ve duyarlılık skorunun harmonik ortalamasını ifade etmektedir. F skoru iki ölçütü birleştirerek tek bir ölçüt olarak kullanılmaktadır.	$2 \times \frac{PxR}{P + R}$
Özgünlük(Specificity)	Negatif olarak sınıflandırılan gerçekten olumsuz durumların oranıdır; yani sınıflandırıcımızın olumsuz durumları ne kadar iyi tanımladığının bir ölçüsüdür. Aynı zamanda gerçek negatif oran (true negatif rate) olarak da bilinir	$\frac{TN}{FP + TN}$

4. BULGULAR VE TARTIŞMA

Bu tez çalışmasında yangın görselleri üzerinden; yangının hızlı ve doğru tespit edilerek sınıflandırılmasında kullanılan mimarilerin kıyaslanması hedeflenmiştir. Yangın görsellerini sınıflandırmak için derin öğrenme araçlarından transfer öğrenme ve ESA mimarilerinden istifade edilmiştir. Tezde kullanılan veri setindeki yangın görsellerinin eğitimi için 5 kat çapraz doğrulama yöntemi kullanılmıştır. Bu yöntemle başarımların doğruluğu artırılmaya çalışılmıştır. Eğitimde kullanılan birçok farklı ESA mimarisi ile transfer öğrenme kullanılmıştır. Çizelge 4.1’de kullanılan ESA mimarilerine ait doğru tahmin oranları verilmiştir. Bunun yanında minimum, maksimum ile ortalama doğruluk oran yüzdeleri belirlenerek gösterilmiştir. Bu sonuçlar incelendiğinde ESA modellerinin %95’ler seviyesinin üzerinde doğruluk oranlarını sağladığı ve bunu en iyi sağlayan modelinde %98,92 ile Places365 olduğu görülmektedir. Bu nedenle de 0 başarımlı (1 ve 4 nolu) eğitimler ortalama başarıma dâhil edilmemiştir.

Çizelge 4.1. Yapılan Eğitim Sonrası Elde Edilen Başarım Sonuçları

Eğitim No	Ağın Adı	Eğitim Sayısı	Doğruluk Oranı	En Küçük Doğruluk Oranı	En Büyük Doğruluk Oranı	Ortalama Doğruluk Oranı
1	alexnet	1	0,977477477	0,968468468	1	0,980159798
2		2	1			
3		3	0,977375566			
4		4	0,968468468			
5		5	0,977477477			
6	vgg16	1	0,981981982	0,981981982	1	0,988276059
7		2	1			
8		3	0,986425339			
9		4	0,981981982			
10		5	0,990990991			
11	vgg19	1	0	0,779279279	0,98648649	0,917397035
12		2	0,779279279			
13		3	0,986425339			
14		4	0			
15		5	0,986486486			
16	googlenet	1	0,986486486	0,986425339	0,99099099	0,988276059
17		2	0,990990991			
18		3	0,986425339			
19		4	0,986486486			
20		5	0,990990991			
21	places365	1	0,977477477	0,977477477	1	0,989181036
22		2	0,990990991			
23		3	0,990950226			
24		4	0,986486486			
25		5	1			

26	resnet18	1	0,972972973	0,972972973	0,99099099	0,983767478
27		2	0,990990991			
28		3	0,981900452			
29		4	0,986486486			
30		5	0,986486486			
31	resnet50	1	0,963963964	0,963963964	0,99547511	0,983779707
32		2	0,986486486			
33		3	0,995475113			
34		4	0,986486486			
35		5	0,986486486			
36	resnet101	1	0,968468468	0,968468468	0,99099099	0,983775631
37		2	0,990990991			
38		3	0,990950226			
39		4	0,981981982			
40		5	0,986486486			
41	inceptionresnetv2	1	0,968468468	0,941441441	0,98198198	0,958517794
42		2	0,945945946			
43		3	0,954751131			
44		4	0,981981982			
45		5	0,941441441			
46	inceptionv3	1	0,959459459	0,959459459	0,98648649	0,973849415
47		2	0,986486486			
48		3	0,972850679			
49		4	0,977477477			
50		5	0,972972973			
51	xception	1	0,977477477	0,972972973	0,98648649	0,980163874
52		2	0,981981982			
53		3	0,981900452			
54		4	0,986486486			
55		5	0,972972973			
56	mobilenetv2	1	0,954954955	0,954954955	0,9954955	0,978362072
57		2	0,977477477			
58		3	0,981900452			
59		4	0,995495495			
60		5	0,981981982			
61	densenet201	1	0,963963964	0,963963964	0,99099099	0,981060699
62		2	0,986486486			
63		3	0,977375566			
64		4	0,990990991			
65		5	0,986486486			
66	shufflenet	1	0,968468468	0,968468468	0,9954955	0,983771554
67		2	0,986486486			
68		3	0,986425339			
69		4	0,981981982			
70		5	0,995495495			
71	darknet19	1	0,981981982	0,977477477	1	0,986470181
72		2	0,990990991			
73		3	0,981900452			
74		4	0,977477477			
75		5	1			
76	darknet53	1	0,977477477	0,972972973	0,99099099	0,981965676
77		2	0,990990991			
78		3	0,981900452			
79		4	0,972972973			
80		5	0,986486486			

81	squeezeNet	1	0,968468468	0,968468468	0,99099099	0,980167951
82		2	0,990990991			
83		3	0,986425339			
84		4	0,972972973			
85		5	0,981981982			
86	efficientNetB0	1	0,963963964	0,963963964	0,99099099	0,98108
87		2	0,990990991			
88		3	0,977375566			
89		4	0,981981982			
90		5	0,990990991			
91	nasNetMobile	1	0,954954955	0,954954955	0,97747748	0,96396
92		2	0,968468468			
93		3	0,963800905			
94		4	0,977477477			
95		5	0,954954955			
96	nasNetLarge	1	0,972972973	0,963800905	0,97747748	0,97116
97		2	0,968468468			
98		3	0,963800905			
99		4	0,972972973			
100		5	0,977477477			

Çalışmada veri setinin eğitiminin yapıldığı ESA'ların transfer öğrenme süreleri Çizelge 4.2'de gösterilmiştir. Çizelgede, ESA'lara ait 5 farklı öğrenme süresi minimum, maksimum ile ortalama öğrenme süreleri saniye olarak verilmiştir. Öğrenme süresi sonuçlarına göre en başarılı olan Vgg-19 mimarisi (987,33 sn) olmuşsa da önceki paragraflarda da değinildiği üzere Vgg-19'daki (1 ve 4 numaralı eğitimlerdeki) hesaplama sorunları sebebiyle dikkate alınmamıştır. Öğrenme süreleri ile ele alındığında, ortalama da en başarılı sonuçlara sahip ESA mimarisinin GoogLeNet olduğu görülmektedir.

Çizelge 4.2. ESA'ların Transfer Öğrenme Süreleri


Eğitim No	Ağın Adı	Eğitim Sayısı	Eğitim Süresi(sn)	Asgari Eğitim Süresi(sn)	Azami Eğitim Süresi(sn)	Ortalama Eğitim Süresi(sn)
1	alexnet	1	1491,388126	1197,835944	1491,388126	1363,152331
2		2	1304,288956			
3		3	1410,524461			
4		4	1197,835944			
5		5	1411,724168			
6	vgg16	1	1635,138579	1375,094825	1635,138579	1552,484385
7		2	1375,094825			
8		3	1599,696503			
9		4	1565,348172			
10		5	1587,143847			
11	vgg19	1	102,5019074	1505,025376	1662,549113	1592,657486
12		2	1610,397969			
13		3	1662,549113			
14		4	56,1791197			
15		5	1505,025376			
16	googlenet	1	1240,027384	1190,833327	1301,263993	1247,653539
17		2	1190,833327			
18		3	1290,659744			
19		4	1301,263993			
20		5	1215,483246			
21	places365	1	1437,911175	1313,061871	2013,672564	1714,209101
22		2	2013,672564			
23		3	2001,327226			
24		4	1805,07267			
25		5	1313,061871			
26	resnet18	1	1300,32182	1289,122754	1485,557024	1354,328316
27		2	1311,403556			
28		3	1289,122754			
29		4	1485,557024			
30		5	1385,236424			
31	resnet50	1	1645,829891	1623,943107	1667,26938	1651,648521
32		2	1661,276191			
33		3	1659,924037			
34		4	1667,26938			
35		5	1623,943107			
36	resnet101	1	2879,792123	2780,589837	2965,620491	2868,680915
37		2	2780,589837			
38		3	2851,331718			
39		4	2866,070407			
40		5	2965,620491			
41	inceptionresnetv2	1	6976,200272	5199,9173	6976,200272	5825,375097
42		2	5344,980397			
43		3	5199,9173			
44		4	5611,611903			
45		5	5994,165614			
46	inceptionv3	1	2619,109458	2498,057331	2619,109458	2539,803748
47		2	2505,139634			
48		3	2546,037788			
49		4	2498,057331			
50		5	2530,67453			

51	xception	1	2808,731762	2808,731762	2899,488189	2853,817524
52		2	2899,379295			
53		3	2899,488189			
54		4	2823,93131			
55		5	2837,557065			
56	mobilenetv2	1	1500,696728	1471,132689	1910,810964	1651,501554
57		2	1471,132689			
58		3	1910,810964			
59		4	1582,31886			
60		5	1792,54853			
61	densenet201	1	6037,627773	6037,627773	6168,288577	6121,425466
62		2	6093,987576			
63		3	6168,288577			
64		4	6157,340886			
65		5	6149,882516			
66	shufflenet	1	1517,110468	1336,174888	1711,299711	1519,915535
67		2	1472,689073			
68		3	1562,303535			
69		4	1336,174888			
70		5	1711,299711			
71	darknet19	1	1277,61207	1277,61207	1526,030085	1426,15075
72		2	1444,860113			
73		3	1526,030085			
74		4	1379,137287			
75		5	1503,114195			
76	darknet53	1	2492,581764	2433,511199	2554,307606	2490,211615
77		2	2486,30638			
78		3	2554,307606			
79		4	2484,351127			
80		5	2433,511199			
81	squeezezenet	1	1363,345142	1278,2581	1564,866986	1391,218494
82		2	1278,2581			
83		3	1445,699498			
84		4	1303,922745			
85		5	1564,866986			
86	efficientnetb0	1	3425,724434	3352,167013	3566,620011	3440,622553
87		2	3566,620011			
88		3	3355,723108			
89		4	3502,8782			
90		5	3352,167013			
91	nasnetmobile	1	4083,264023	3862,246771	4117,353122	4039,916127
92		2	4088,673528			
93		3	4117,353122			
94		4	4048,043191			
95		5	3862,246771			
96	nasnetlarge	1	64203,65962	50707,5322	64203,65962	55155,78144
97		2	53066,79025			
98		3	56133,84086			
99		4	50707,5322			
100		5	51667,08428			

Çalışmada kullanılan ESA mimarilerinin başarımları ve öğrenme süreleriyle ilgili yorum yapmamızı sağlayacak olup her iki veriyi bir arada veren Şekil 4. 1'deki doğruluk-zaman balon grafiğidir. Aslında bu şekil Çizelge 4.1 ve Çizelge 4.2'nin görsel olarak bir araya getirilmiş halidir. Doğruluk-zaman balon grafiği incelendiğinde sırasıyla

Place365, GoogLeNet, VGG-16 ve DarkNet gibi ESA mimari modellerinin yangını tespit süresi ve doğru tahmin etme oranlarının oldukça yüksek olduğu görülmektedir. Her ne kadar %100 doğruluk oranları elde edilmiş olsa da bu durum, seçilen veri seti parçalarının kolaylığı ile izah edilebilir. Bu nedenle 5 kat çapraz doğrulama sonuçları daha önem arz etmektedir. Bir diğer dikkat çeken husus Vgg-19 mimarisinin 2 eğitimde 0 başarımla göstermesidir. Bu durum veri setinde ki o dağılımların Vgg-19 öğrenmesinde bir hesaplama hatası sorunu veya işlemsel bir hata ile açıklanabilir. Öte yandan(Vgg-19 hariç) neredeyse tüm ESA modellerinin %95'in üzerinde ortalama başarımla göstermesi sınıf sayısının az(2 sınıf) olması ile veri setinin amacı yeterli şekilde temsil etmesiyle açıklanabilir.

Sonuç olarak yangın tespitinde transfer öğrenme yoluyla yapılan bu çalışmada süresel olarak GoogLeNet ve başarımsal olarak GoogLeNet tabanlı Place365 mimarilerinin öne çıktığı görülmektedir. Kompleks ve gelişmiş yapısıyla NasNet mimarileri süre ve başarımsal olarak beklenen performansı(bu veri seti özelinde) gösterememişlerdir.



Şekil 4. 1. Kullanılan Algoritmalarının Doğruluk-Zaman Balon Grafiği

5. SONUÇ VE ÖNERİLER

Bu çalışmada, görüntülerden yangının algılanması teknolojisinin geliştirilmesi için kullandığımız ve özü itibariyle YSA olan ESA'ların sergilediği performanslar(doğruluk, eğitim süresi) her ne kadar %100 doğruluk oranları elde edilmiş olsa da bu durum, seçilen veri seti parçalarının kolaylığı ile izah edilebilir. Bu nedenle 5 kat çapraz doğrulama sonuçları daha önem arz etmektedir. Bir diğer dikkat çeken husus Vgg-19 mimarisinin (1 ve 4 numaralı) 2 eğitimde 0 başarımla göstermesidir. Bu durum veri setinde ki o dağılımların Vgg-19 öğrenmesinde hesaplama sorunu veya işlemsel bir hata ile açıklanabilir. Öte yandan(Vgg-19 hariç) neredeyse tüm ESA modellerinin %95'in üzerinde ortalama başarımla göstermesi sınıf sayısının az(2 sınıf) olması ile veri setinin amacı yeterli şekilde temsil etmesiyle açıklanabilir. Çizelge 4.1 ile Çizelge 4.2 ve Şekil 4. 1'deki doğruluk-zaman balon grafiğinde ayrıntılı olarak yer almaktadır. Çalışmada 20 farklı ESA mimarisinden elde edilen sonuçlar doğrultusunda yangının doğru tespit edilmesinde neredeyse tüm algoritmaların %95'in üzerinde(genel olarak ta %98 seviyesinde) doğru tespit yaptığı görülmektedir. Çalışma sonucundaki test sonuçlarına göre bir karşılaştırma yapacak olursak, başarımla en yüksek algoritma **%98,92** ile **Place365** olmuştur. Süre bakımından **1247,65** saniye ortalama eğitim süresiyle **GoogLeNet** en iyi ağ olmuştur.

Algoritmaların bu kadar yüksek performans sergilemeleri, derin öğrenme tabanlı ESA mimarilerinin kullanımının, yangının erken tespit edilerek can ve mal kayıplarının önlenmesi veya asgari düzeyde tutulmasında önemli bir alternatif çözüm yaklaşımı olarak karşımıza çıkmaktadır. Bu çalışma bize göstermiştir ki yangın tespitinde GoogLeNet tabanlı ESA mimarileri(GoogLeNet ve Place365) daha etkin sonuçlar vermektedir. Gelecek çalışmalar için de GoogLeNet tabanlı bu derin öğrenme mimarilerinin yangın tespiti amaçlı özelleştirilerek başarımlarının daha da artırılması düşünülmektedir.

KAYNAKLAR

- [1] K. Avazov, M. Mukhiddinov, F. Makhmudov, and Y. I. Cho, “Fire detection method in smart city environments using a deep-learning-based approach,” *Electron.*, vol. 11, no. 1, pp. 1–17, 2022, doi: 10.3390/electronics11010073.
- [2] C. Tao, J. Zhang, and P. Wang, “Smoke Detection Based on Deep Convolutional Neural Networks,” in *2016 International Conference on Industrial Informatics - Computing Technology, Intelligent Technology, Industrial Information Integration (ICIICII)*, Dec. 2016, pp. 150–153. doi: 10.1109/ICIICII.2016.0045.
- [3] P. Li and W. Zhao, “Image fire detection algorithms based on convolutional neural networks,” *Case Stud. Therm. Eng.*, vol. 19, p. 100625, Jun. 2020, doi: 10.1016/j.csite.2020.100625.
- [4] K. Muhammad, J. Ahmad, I. Mehmood, S. Rho, and S. W. Baik, “Convolutional Neural Networks Based Fire Detection in Surveillance Videos,” *IEEE Access*, vol. 6, pp. 18174–18183, 2018, doi: 10.1109/ACCESS.2018.2812835.
- [5] G. Lindfield and J. Penny, “Numerical methods: Using MATLAB,” *Numer. Methods Using MATLAB*, pp. 1–608, 2018, doi: 10.1016/C2016-0-00395-9.
- [6] B. Akalın and M. Demirbaş, “Rehabilitasyon Hizmetlerinde Yapay Zekâ Uygulamaları,” *Acta Infologica*, vol. 6, no. 2, pp. 141–161, 2022, doi: 10.26650/acin.1068576.
- [7] A. Ramesh, C. Kambhampati, J. Monson, and P. Drew, “Artificial intelligence in medicine,” *Ann. R. Coll. Surg. Engl.*, vol. 86, no. 5, pp. 334–338, Sep. 2004, doi: 10.1308/147870804290.
- [8] P. Hamet and J. Tremblay, “Artificial intelligence in medicine,” *Metabolism*, vol. 69, pp. S36–S40, Apr. 2017, doi: 10.1016/j.metabol.2017.01.011.
- [9] D. . Pham and P. T. . Pham, “Artificial intelligence in engineering,” *Int. J. Mach. Tools Manuf.*, vol. 39, no. 6, pp. 937–949, Jun. 1999, doi: 10.1016/S0890-6955(98)00076-5.
- [10] V. V. Nabiyev, *Yapay zeka: insan-bilgisayar etkileşimi*. Seçkin Yayıncılık, 2012.
- [11] K. Ozturk and M. Şahin, “Yapay Sinir Ağları ve Yapay Zekâ’ya Genel Bir Bakış-A General View of Artificial Neural Networks and Artificial Intelligence,” *Tak. Vekayi*, vol. 6, no. 2, pp. 25–36, 2018.
- [12] R. A. Lewis, “A review of terahertz sources,” *J. Phys. D. Appl. Phys.*, vol. 47, no. 37, p. 374001, Sep. 2014, doi: 10.1088/0022-3727/47/37/374001.
- [13] Y. Jiang, X. Li, H. Luo, S. Yin, and O. Kaynak, “Quo vadis artificial intelligence?,” *Discov. Artif. Intell.*, vol. 2, no. 1, p. 4, Mar. 2022, doi: 10.1007/s44163-022-00022-8.
- [14] T. Schmidt and T. Strassner, “Artificial Intelligence in Foreign Language Learning and Teaching,” *Anglistik*, vol. 33, no. 1, pp. 165–184, 2022, doi: 10.33675/angl/2022/1/14.
- [15] A. M. Andrew, “Continuity and Artificial Intelligence,” *Kybernetes*, vol. 20, no. 6, pp. 69–80, Jun. 1991, doi: 10.1108/eb005905.
- [16] M. R. Genesereth and N. J. Nilsson, “Nonmonotonic Reasoning,” in *Logical*

- Foundations of Artificial Intelligence*, Elsevier, 1987, pp. 115–159. doi: 10.1016/B978-0-934613-31-6.50012-4.
- [17] E. Southgate, “Artificial Intelligence and Machine Learning,” in *Digital Disruption In Teaching And Testing*, New York: Routledge, 2021, pp. 60–74. doi: 10.4324/9781003045793-3.
- [18] J. Bell, “What Is Machine Learning?,” in *Machine Learning and the City*, Wiley, 2022, pp. 207–216. doi: 10.1002/9781119815075.ch18.
- [19] C. Janiesch, P. Zschech, and K. Heinrich, *Machine learning and deep learning*, vol. 31, no. 3. 2021. doi: 10.1007/s12525-021-00475-2.
- [20] B. Raju *et al.*, “Big data, machine learning, and artificial intelligence: a field guide for neurosurgeons,” *J. Neurosurg.*, vol. 135, no. 2, pp. 373–383, Aug. 2021, doi: 10.3171/2020.5.JNS201288.
- [21] R. Saravanan and P. Sujatha, “A State of Art Techniques on Machine Learning Algorithms: A Perspective of Supervised Learning Approaches in Data Classification,” in *2018 Second International Conference on Intelligent Computing and Control Systems (ICICCS)*, Jun. 2018, pp. 945–949. doi: 10.1109/ICCONS.2018.8663155.
- [22] Y. M. Kızılkaya and A. Oğuzlar, “Bazı Denetimli Öğrenme Algoritmalarının R Programlam Dili İle Kıyaslanması,” *Dergi Karadeniz*, vol. 37, no. 37, pp. 90–98, 2018, doi: 10.17498/kdeniz.405746.
- [23] B. D. Peterson *et al.*, “Automated Prioritization of Sick Newborns for Rapid Whole Genome Sequencing Using Clinical Natural Language Processing and Machine Learning,” *medRxiv*, p. 2022.05.06.22274688, 2022, [Online]. Available: <https://www.medrxiv.org/content/10.1101/2022.05.06.22274688v1%0Ahttps://www.medrxiv.org/content/10.1101/2022.05.06.22274688v1.abstract>
- [24] X. Yin, J. Han, J. Yang, and P. S. Yu, “Efficient classification across multiple database relations: a CrossMine approach,” *IEEE Trans. Knowl. Data Eng.*, vol. 18, no. 6, pp. 770–783, Jun. 2006, doi: 10.1109/TKDE.2006.94.
- [25] S. Panigrahi, A. Nanda, and T. Swarnkar, “A Survey on Transfer Learning,” *Smart Innov. Syst. Technol.*, vol. 194, pp. 781–789, 2021, doi: 10.1007/978-981-15-5971-6_83.
- [26] K. Weiss, T. M. Khoshgoftaar, and D. Wang, “A survey of transfer learning,” *J. Big Data*, vol. 3, no. 1, p. 9, Dec. 2016, doi: 10.1186/s40537-016-0043-6.
- [27] L. Deng, “Deep Learning: Methods and Applications,” *Found. Trends® Signal Process.*, vol. 7, no. 3–4, pp. 197–387, 2014, doi: 10.1561/20000000039.
- [28] T. Ibrikci, E. M. Karabulut, and J. D. Uwisengeyimana, “Meta Learning on Small Biomedical Datasets,” 2016, pp. 933–939. doi: 10.1007/978-981-10-0557-2_89.
- [29] Y. Bengio, *Learning Deep Architectures for AI*, vol. 2, no. 1. 2009. doi: 10.1561/22000000006.
- [30] Y. Lecun, “Scaling Learning Algorithms Towards AI Authors : Yoshua Bengio , Yann LeCun Presenter : Marilyn Vazquez Curse of Dimensionality Shallow Learning,” *dergipark*, 2017, [Online]. Available: <https://dergipark.org.tr/en/pub/gbad/issue/31228/330663>

- [31] Ö. İnik and E. Ülker, “Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri,” *Gaziosmanpasa J. Sci. Res.*, vol. 6, no. 3, pp. 85–104, 2017.
- [32] F. Doğan and İ. Türkoğlu, “Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması,” *Sak. Univ. J. Comput. Inf. Sci.*, vol. 1, no. 1, pp. 10–21, 2018.
- [33] D. Ciregan, U. Meier, and J. Schmidhuber, “Multi-column deep neural networks for image classification,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, no. February, pp. 3642–3649, 2012, doi: 10.1109/CVPR.2012.6248110.
- [34] M. Zou and Y. Zhong, “Transfer Learning for Classification of Optical Satellite Image,” *Sens. Imaging*, vol. 19, no. 1, p. 6, Dec. 2018, doi: 10.1007/s11220-018-0191-1.
- [35] H. Ugail, “Deep Face Recognition,” in *Deep Learning in Visual Computing*, no. Section 3, Boca Raton: CRC Press, 2022, pp. 31–47. doi: 10.1201/9781003091356-4.
- [36] K. Sirinukunwattana, S. E. A. Raza, Y.-W. Tsang, D. R. J. Snead, I. A. Cree, and N. M. Rajpoot, “Locality Sensitive Deep Learning for Detection and Classification of Nuclei in Routine Colon Cancer Histology Images,” *IEEE Trans. Med. Imaging*, vol. 35, no. 5, pp. 1196–1206, May 2016, doi: 10.1109/TMI.2016.2525803.
- [37] N. Kussul, M. Lavreniuk, S. Skakun, and A. Shelestov, “Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data,” *IEEE Geosci. Remote Sens. Lett.*, vol. 14, no. 5, pp. 778–782, 2017, doi: 10.1109/LGRS.2017.2681128.
- [38] D. Y. George E. Dahl, Jack W. Stokes, Li Deng, “Large-Scale Malware Classification Using Random Projections And Neural Networks George E . Dahl University of Toronto Department of Computer Science Toronto , ON , Canada Jack W . Stokes , Li Deng , Dong Yu One Microsoft Way,” in *in Acoustics, Speech and Signal Processing (ICASSP), 2013 IEEE International Conference on.*, 2013, pp. 3422–3426.
- [39] P. Bhatt, R. Bhatt, M. D. Mukadam, and S. M. Yusuf, “Prussian blue based molecular magnet $K_{0.3}Mn_{2.85}[Cr(CN)_6]_2 \cdot nH_2O$ with ferrimagnetic ordering temperature of 60 K,” *AIP Conf. Proc.*, vol. 1512, pp. 1082–1083, 2013, doi: 10.1063/1.4791421.
- [40] F. Doğan and İ. Türkoğlu, “Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme,” *DÜMF Mühendislik Derg.*, vol. 10, no. 2, pp. 409–445, 2019, doi: 10.24012/dumf.411130.
- [41] Ü. Budak, A. Şengür, A. B. Dabak, and M. Çibuk, “Transfer Learning Based Object Detection and Effect of Majority Voting on Classification Performance,” in *2019 International Artificial Intelligence and Data Processing Symposium (IDAP)*, 2019, pp. 1–4. doi: 10.1109/IDAP.2019.8875920.
- [42] J. Guo, T. Ren, and J. Bei, “Salient object detection for RGB-D image via saliency evolution,” in *2016 IEEE International Conference on Multimedia and Expo (ICME)*, Jul. 2016, pp. 1–6. doi: 10.1109/ICME.2016.7552907.
- [43] Z. Q. Zhao, P. Zheng, S. T. Xu, and X. Wu, “Object Detection with Deep Learning: A Review,” *IEEE Trans. Neural Networks Learn. Syst.*, vol. 30, no. 11, pp. 3212–3232, 2019, doi: 10.1109/TNNLS.2018.2876865.

- [44] K. Suzuki, "Overview of deep learning in medical imaging," *Radiol. Phys. Technol.*, vol. 10, no. 3, pp. 257–273, 2017, doi: 10.1007/s12194-017-0406-5.
- [45] L. Cai, J. Gao, and D. Zhao, "A review of the application of deep learning in medical image classification and segmentation," *Ann. Transl. Med.*, vol. 8, no. 11, pp. 713–713, 2020, doi: 10.21037/atm.2020.02.44.
- [46] S. M. Plis *et al.*, "Deep learning for neuroimaging: A validation study," *Front. Neurosci.*, vol. 8, no. 8 JUL, pp. 1–11, 2014, doi: 10.3389/fnins.2014.00229.
- [47] M. Aslan, "Derin Öğrenme Tabanlı Otomatik Beyin Tümör Tespiti," *Fırat Üniversitesi Mühendislik Bilim. Derg.*, vol. 34, no. 1, pp. 399–407, 2022, doi: 10.35234/fumbd.1039825.
- [48] A. K. Jain, Jianchang Mao, and K. M. Mohiuddin, "Artificial neural networks: a tutorial," *Computer (Long. Beach. Calif.)*, vol. 29, no. 3, pp. 31–44, Mar. 1996, doi: 10.1109/2.485891.
- [49] N. Hoffmann, "Simulation Neuronaler Netze," *Simul. Neuronaler Netze*, 1992, doi: 10.1007/978-3-322-83200-9.
- [50] M. Mohammadhassani, H. Nezamabadi-Pour, M. Z. Jumaat, M. Jameel, and A. M. S. Arumugam, "Application of artificial neural networks (ANNs) and linear regressions (LR) to predict the deflection of concrete deep beams," *Comput. Concr.*, vol. 11, no. 3, pp. 237–252, 2013, doi: 10.12989/cac.2013.11.3.237.
- [51] J. Gu *et al.*, "Recent advances in convolutional neural networks," *Pattern Recognit.*, vol. 77, pp. 354–377, May 2018, doi: 10.1016/j.patcog.2017.10.013.
- [52] K. G. Kim, "Deep learning book review," *Nature*, vol. 29, no. 7553, pp. 1–73, 2019, [Online]. Available: <http://www.e-hir.org/upload/pdf/hir-22-351.pdf>
- [53] R. Yamashita, M. Nishio, R. K. G. Do, and K. Togashi, "Convolutional neural networks: an overview and application in radiology," *Insights Imaging*, vol. 9, no. 4, pp. 611–629, Aug. 2018, doi: 10.1007/s13244-018-0639-9.
- [54] W. S. McCulloch and W. Pitts, "A logical calculus of the ideas immanent in nervous activity," *Bull. Math. Biophys.*, vol. 5, no. 4, pp. 115–133, Dec. 1943, doi: 10.1007/BF02478259.
- [55] W. S. McCulloch and W. H. Pitts, "A logical calculus of the ideas immanent in nervous activity," *Syst. Res. Behav. Sci. A Sourceb.*, vol. 5, pp. 93–96, 2017, doi: 10.7551/mitpress/12274.003.0011.
- [56] M. Cernansky, "Rosenblattov perceptrón," vol. 65, no. 1958, 1958, [Online]. Available: http://www2.fiit.stuba.sk/~cernans/nn/nn_texts/neuronove_siete_priesvitky_02_Q.pdf
- [57] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning representations by back-propagating errors," *Nature*, vol. 323, no. 6088, pp. 533–536, Oct. 1986, doi: 10.1038/323533a0.
- [58] H. Üzen and K. Hanbay, "Yaya Özelliik Tanıma için LM Filtre Temelli Derin Evrişimsel Sinir Ağı," *Politek. Derg.*, vol. 23, no. 3, pp. 605–613, Sep. 2020, doi: 10.2339/politeknik.525600.
- [59] S. N. Sivanandam and S. N. Deepa, "Genetic Algorithms," in *Introduction to*

- Genetic Algorithms*, vol. 173, Berlin, Heidelberg: Springer Berlin Heidelberg, 2021, pp. 15–37. doi: 10.1007/978-3-540-73190-0_2.
- [60] S. N. Sivanandam and S. N. Deepa, “Genetic Algorithms,” in *Introduction to Genetic Algorithms*, Berlin, Heidelberg: Springer Berlin Heidelberg, pp. 15–37. doi: 10.1007/978-3-540-73190-0_2.
 - [61] S. Albawi, O. Bayat, S. Al-Azawi, and O. N. Ucan, “Social touch gesture recognition using convolutional neural network,” *Comput. Intell. Neurosci.*, vol. 2018, 2018, doi: 10.1155/2018/6973103.
 - [62] C. Alippi, S. Disabato, and M. Roveri, “Moving Convolutional Neural Networks to Embedded Systems: The AlexNet and VGG-16 Case,” in *2018 17th ACM/IEEE International Conference on Information Processing in Sensor Networks (IPSN)*, Apr. 2018, vol. 30, no. 2010, pp. 212–223. doi: 10.1109/IPSN.2018.00049.
 - [63] H. Ismail Fawaz *et al.*, “InceptionTime: Finding AlexNet for time series classification,” *Data Min. Knowl. Discov.*, vol. 34, no. 6, pp. 1936–1962, 2020, doi: 10.1007/s10618-020-00710-y.
 - [64] A. LeNail, “NN-SVG: Publication-Ready Neural Network Architecture Schematics,” *J. Open Source Softw.*, vol. 4, no. 33, p. 747, Jan. 2019, doi: 10.21105/joss.00747.
 - [65] S. Tammina, “Transfer learning using VGG-16 with Deep Convolutional Neural Network for Classifying Images,” *Int. J. Sci. Res. Publ.*, vol. 9, no. 10, p. p9420, 2019, doi: 10.29322/ijsrp.9.10.2019.p9420.
 - [66] Z. Song, L. Fu, J. Wu, Z. Liu, R. Li, and Y. Cui, “Kiwifruit detection in field images using Faster R-CNN with VGG16,” *IFAC-PapersOnLine*, vol. 52, no. 30, pp. 76–81, 2019, doi: 10.1016/j.ifacol.2019.12.500.
 - [67] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” *3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc.*, pp. 1–14, 2015.
 - [68] M. Mateen, J. Wen, Nasrullah, S. Song, and Z. Huang, “Fundus Image Classification Using VGG-19 Architecture with PCA and SVD,” *Symmetry (Basel)*, vol. 11, no. 1, p. 1, Dec. 2018, doi: 10.3390/sym11010001.
 - [69] L. Wen, X. Li, and L. Gao, “A transfer convolutional neural network for fault diagnosis based on ResNet-50,” *Neural Comput. Appl.*, vol. 32, no. 10, pp. 6111–6124, May 2020, doi: 10.1007/s00521-019-04097-w.
 - [70] G. Zeng, Y. He, Z. Yu, X. Yang, R. Yang, and L. Zhang, “Preparation of novel high copper ions removal membranes by embedding organosilane-functionalized multi-walled carbon nanotube,” *J. Chem. Technol. Biotechnol.*, vol. 91, no. 8, pp. 2322–2330, 2016, doi: 10.1002/jctb.4820.
 - [71] M. Längkvist, L. Karlsson, and A. Loutfi, “Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning,” *Pattern Recognit. Lett.*, vol. 42, no. 1, pp. 11–24, 2014, [Online]. Available: <http://arxiv.org/abs/1512.00567>
 - [72] H.-J. Yoo, “Deep Convolution Neural Networks in Computer Vision: a Review,” *IEIE Trans. Smart Process. Comput.*, vol. 4, no. 1, pp. 35–43, 2015, doi: 10.5573/ieiespc.2015.4.1.035.
 - [73] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, “Rethinking the

- Inception Architecture for Computer Vision,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-Decem, pp. 2818–2826, 2016, doi: 10.1109/CVPR.2016.308.
- [74] C. Szegedy *et al.*, “Going deeper with convolutions,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 07-12-June, pp. 1–9, 2015, doi: 10.1109/CVPR.2015.7298594.
- [75] “GoogLeNet evrişimli sinir ağı-MATLAB googlenet.” [Online]. Available: https://www.mathworks.com/help/deeplearning/ref/googlenet.html#mw_d60d4ed6-a2c9-44f1-93b8-977191c6cfea
- [76] M. Guo and Y. Du, “Classification of Thyroid Ultrasound Standard Plane Images using ResNet-18 Networks,” in *2019 IEEE 13th International Conference on Anti-counterfeiting, Security, and Identification (ASID)*, Oct. 2019, pp. 324–328. doi: 10.1109/ICASID.2019.8925267.
- [77] I. Z. Mukti and D. Biswas, “Transfer Learning Based Plant Diseases Detection Using ResNet50,” in *2019 4th International Conference on Electrical Information and Communication Technology (EICT)*, Dec. 2019, pp. 1–6. doi: 10.1109/EICT48899.2019.9068805.
- [78] E. Rezende, G. Ruppert, T. Carvalho, F. Ramos, and P. De Geus, “Malicious software classification using transfer learning of ResNet-50 deep neural network,” *Proc. - 16th IEEE Int. Conf. Mach. Learn. Appl. ICMLA 2017*, vol. 2017-Decem, pp. 1011–1014, 2017, doi: 10.1109/ICMLA.2017.00-19.
- [79] P. Ghosal, L. Nandanwar, S. Kanchan, A. Bhadra, J. Chakraborty, and D. Nandi, “Brain Tumor Classification Using ResNet-101 Based Squeeze and Excitation Deep Neural Network,” in *2019 Second International Conference on Advanced Computational and Communication Paradigms (ICACCP)*, Feb. 2019, pp. 1–6. doi: 10.1109/ICACCP.2019.8882973.
- [80] J. Chen, M. Zhou, D. Zhang, H. Huang, and F. Zhang, “Quantification of water inflow in rock tunnel faces via convolutional neural network approach,” *Autom. Constr.*, vol. 123, no. March, p. 103526, Mar. 2021, doi: 10.1016/j.autcon.2020.103526.
- [81] J. Bobo, C. Hudley, and C. Michel, “The Black studies reader,” *Black Stud. Read.*, pp. 1–488, 2004, doi: 10.4324/9780203491348.
- [82] R. Zhang *et al.*, “Automatic Segmentation of Acute Ischemic Stroke From DWI Using 3-D Fully Convolutional DenseNets,” *IEEE Trans. Med. Imaging*, vol. 37, no. 9, pp. 2149–2160, 2018, doi: 10.1109/TMI.2018.2821244.
- [83] X. Zhang, “Machine Translated by Google ShuffleNet : Mobil Cihazlar İçin Son Derece Verimli Evrişimli Sinir Ağı Cihazlar Xinyu Zhou Mengxiao Lin Machine Translated by Google,” pp. 1–9.
- [84] Z. Zhang, T.-Y. Hsu, H.-H. Wei, and J.-H. Chen, “Development of a Data-Mining Technique for Regional-Scale Evaluation of Building Seismic Vulnerability,” *Appl. Sci.*, vol. 9, no. 7, p. 1502, Apr. 2019, doi: 10.3390/app9071502.
- [85] N. Kosova, E. Devyatkina, and S. Petrov, “Fast and Low-cost Synthesis of LiFePO₄ /C Composites using Fe³⁺ Precursor,” *ECS Trans.*, vol. 25, no. 14, pp. 27–35, Feb. 2010, doi: 10.1149/1.3301809.

- [86] B. Khasoggi, E. Ermatita, and S. Samsuryadi, "Efficient mobilenet architecture as image recognition on mobile and embedded devices," *Indones. J. Electr. Eng. Comput. Sci.*, vol. 16, no. 1, p. 389, Oct. 2019, doi: 10.11591/ijeecs.v16.i1.pp389-394.
- [87] P. N. Srinivasu, J. G. Sivasai, M. F. Ijaz, A. K. Bhoi, W. Kim, and J. J. Kang, "Networks with MobileNet V2 and LSTM," pp. 1–27, 2021.
- [88] F. Saxen, P. Werner, S. Handrich, E. Othman, L. Dinges, and A. Al-Hamadi, "Face Attribute Detection with MobileNetV2 and NasNet-Mobile," in *2019 11th International Symposium on Image and Signal Processing and Analysis (ISPA)*, Sep. 2019, pp. 176–180. doi: 10.1109/ISPA.2019.8868585.
- [89] H. -, G. Putra, and S. -, "Classification of C2C e-Commerce Product Images using Deep Learning Algorithm," *Int. J. Adv. Comput. Sci. Appl.*, vol. 10, no. 9, 2019, doi: 10.14569/IJACSA.2019.0100925.
- [90] R. H. Hridoy, F. Akter, M. Mahfuzullah, and F. Ferdowsy, "A Computer Vision Based Food Recognition Approach for Controlling Inflammation to Enhance Quality of Life of Psoriasis Patients," in *2021 International Conference on Information Technology (ICIT)*, Jul. 2021, pp. 543–548. doi: 10.1109/ICIT52682.2021.9491783.
- [91] M. Nikhitha, S. Roopa Sri, and B. Uma Maheswari, "Fruit Recognition and Grade of Disease Detection using Inception V3 Model," in *2019 3rd International conference on Electronics, Communication and Aerospace Technology (ICECA)*, Jun. 2019, vol. 9, pp. 1040–1043. doi: 10.1109/ICECA.2019.8822095.
- [92] Xiaoling Xia, Cui Xu, and Bing Nan, "Inception-v3 for flower classification," in *2017 2nd International Conference on Image, Vision and Computing (ICIVC)*, Jun. 2017, pp. 783–787. doi: 10.1109/ICIVC.2017.7984661.
- [93] J. Redmon and A. Farhadi, "Yolo V2.0," *Cvpr2017*, no. April, pp. 187–213, 2017, [Online]. Available: http://www.worldscientific.com/doi/abs/10.1142/9789812771728_0012
- [94] J. Redmon and A. Farhadi, "YOLOv3: An Incremental Improvement," Apr. 2018, doi: 10.11772/j.issn.1001-9081.2018102190.
- [95] J.-H. Won, D.-H. Lee, K.-M. Lee, and C.-H. Lin, "An Improved YOLOv3-based Neural Network for De-identification Technology," in *2019 34th International Technical Conference on Circuits/Systems, Computers and Communications (ITC-CSCC)*, Jun. 2019, pp. 1–2. doi: 10.1109/ITC-CSCC.2019.8793382.
- [96] X. Huang *et al.*, "PP-YOLOv2: A Practical Object Detector," pp. 1–7, 2021, [Online]. Available: <http://arxiv.org/abs/2104.10419>
- [97] J. Deng, W. Dong, R. Socher, L.-J. Li, Kai Li, and Li Fei-Fei, "ImageNet: A large-scale hierarchical image database," in *2009 IEEE Conference on Computer Vision and Pattern Recognition*, Jun. 2009, pp. 248–255. doi: 10.7287/peerj.preprints.27880v1.
- [98] R. S. T. De Menezes, J. V. A. Luiz, A. M. Henrique-Alves, R. M. Santa Cruz, and H. Maia, "Mice Tracking Using The YOLO Algorithm," pp. 162–173, 2020, doi: 10.5753/semish.2020.11326.
- [99] F. Chollet, "Xception: Deep Learning with Depthwise Separable Convolutions," in

2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Jul. 2017, pp. 1800–1807. doi: 10.1109/CVPR.2017.195.

- [100] Y. Bhatia, A. Bajpayee, D. Raghuvanshi, and H. Mittal, “Image Captioning using Google’s Inception-resnet-v2 and Recurrent Neural Network,” in *2019 Twelfth International Conference on Contemporary Computing (IC3)*, Aug. 2019, pp. 1–6. doi: 10.1109/IC3.2019.8844921.
- [101] C. Szegedy, S. Ioffe, V. Vanhoucke, and A. Alemi, “Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning,” *Proc. AAAI Conf. Artif. Intell.*, vol. 31, no. 1, Feb. 2017, doi: 10.1609/aaai.v31i1.11231.
- [102] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, “Densely connected convolutional networks,” *Proc. - 30th IEEE Conf. Comput. Vis. Pattern Recognition, CVPR 2017*, vol. 2017-Janua, pp. 2261–2269, 2017, doi: 10.1109/CVPR.2017.243.
- [103] K. Zhang, Y. Guo, X. Wang, J. Yuan, and Q. Ding, “Multiple Feature Reweight DenseNet for Image Classification,” *IEEE Access*, vol. 7, pp. 9872–9880, 2019, doi: 10.1109/ACCESS.2018.2890127.
- [104] F. Iandola, A. Shaw, R. Krishna, and K. Keutzer, “SqueezeBERT: What can computer vision teach NLP about efficient neural networks?,” in *Proceedings of SustaiNLP: Workshop on Simple and Efficient Natural Language Processing*, 2020, pp. 124–135. doi: 10.18653/v1/2020.sustainlp-1.17.
- [105] F. Özyurt, E. Sert, E. Avci, and E. Dogantekin, “Brain tumor detection based on Convolutional Neural Network with neutrosophic expert maximum fuzzy sure entropy,” *Measurement*, vol. 147, p. 106830, Dec. 2019, doi: 10.1016/j.measurement.2019.07.058.
- [106] S. Minaee, R. Kafieh, M. Sonka, S. Yazdani, and G. Jamalipour Soufi, “Deep-COVID: Predicting COVID-19 from chest X-ray images using deep transfer learning,” *Med. Image Anal.*, vol. 65, p. 101794, Oct. 2020, doi: 10.1016/j.media.2020.101794.
- [107] D. Ghimire, D. Kil, and S. Kim, “A Survey on Efficient Convolutional Neural Networks and Hardware Acceleration,” *Electronics*, vol. 11, no. 6, p. 945, Mar. 2022, doi: 10.3390/electronics11060945.
- [108] S. I. Hossain *et al.*, “Exploring convolutional neural networks with transfer learning for diagnosing Lyme disease from skin lesion images,” *Comput. Methods Programs Biomed.*, vol. 215, p. 106624, Mar. 2022, doi: 10.1016/j.cmpb.2022.106624.
- [109] L. Quaranta, F. Calefato, and F. Lanubile, “KGTorrent: A Dataset of Python Jupyter Notebooks from Kaggle,” in *2021 IEEE/ACM 18th International Conference on Mining Software Repositories (MSR)*, May 2021, pp. 550–554. doi: 10.1109/MSR52588.2021.00072.
- [110] A. Said and Others, “Fire Data Set,” 2018. <https://www.kaggle.com/datasets/phylake1337/fire-dataset>
- [111] A. Kumar, “Fire Images Data Set,” 2020. <https://www.kaggle.com/datasets/atulyakumar98/test-dataset>
- [112] M. Burukanli, M. Çibuk, and Ü. Budak, “Saldırı Tespiti için Makine Öğrenme Yöntemlerinin Karşılaştırmalı Analizi Comparative Analysis of Machine Learning

- Methods for Intrusion Detection,” *BEU J. Sci.*, vol. 10, no. 2, pp. 613–624, 2021.
- [113] R. Kohavi, “A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection,” *Int. Jt. Conf. Artif. Intell.*, no. March 2001, 1995.
- [114] F. Uyanık and M. C. and Kasapbaşı, “Telekomünikasyon Sektörü için Veri Madenciliği ve Makine Öğrenmesi Teknikleri ile Ayrılan Müşteri Analizi,” *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 2021.

