



**DERİN ÖĞRENME İLE RESİM VE VİDEOLAR ÜZERİNDE DERİN
SAHTE TESPİTİ**

Metin BÜYÜKAVCILAR

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

HAZİRAN 2023

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde 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 çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Metin BÜYÜKAVCILAR

02/06/2023

DERİN ÖĞRENME İLE RESİM VE VİDEOLAR ÜZERİNDE DERİN SAHTE TESPİTİ
(Yüksek Lisans Tezi)

Metin BÜYÜKAVCILAR

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Haziran 2023

ÖZET

Günümüzde en başta sosyal medya olmak üzere çevrimiçi platformlarda resim ve video paylaşımları yapılmaktadır. Derin öğrenme ve yapay zekâ teknolojilerinin yardımıyla görüntü manipülasyonları hızla gelişmektedir. Görüntü manipülasyonu teknolojilerinin gelişmesiyle resim ve videolar değiştirilip sahte resim ve videolar oluşturulmaktadır. Bir resim ya da videonun içeriğindeki yüzün belirli hatlarıyla eşleşen başka yüzlerle değiştirilip yeniden oluşturulması işlemi Derin Sahtecilik olarak adlandırılır. Derin Sahteciliğin çeşitlik alanlarda kötü amaçlı kullanılabilmesi insanların ve toplulukların ciddi ölçüde maddi ve manevi zarara uğramasına sebebiyet verebilmektedir. Bu durumların önüne geçebilmek adına derin sahteciliğin tespitinin yapılabilmesi büyük bir öneme sahiptir. Yapılan çalışmada, EfficientNet B5 modeli üzerine 2 katmanlı Evrişimsel Sinir Ağı modeli birleştirilip derin sahtecilik tespiti yapılmıştır. Çalışma, FaceForensic++ veri setinde yüz değiştirme yöntemleri ile oluşturulan 640x480 çözünürlüklü 509 adet Derin Sahtecilik videolarından rastgele oluşturulmuş bir veri seti kullanılmıştır. Çalışmada önerilmiş model oluşturulan veri seti ile eğitilip test edilmiştir. Çalışmada, %95 öğrenme performansına sahip model ile %93,7 F1-skoru elde edilmiştir.

Bilim Kodu : 92432

Anahtar Kelimeler : Derin sahtecilik, Yapay zeka, Derin öğrenme, EfficientNet B5, Görüntü işleme, Evrişimsel sinir ağı

Sayfa Adedi : 58

Danışman : Prof. Dr. Aydın ÇETİN

DEEP FAKE DETECTION ON PICTURES AND VIDEOS WITH DEEP LEARNING
(M. Sc. Thesis)

Metin BÜYÜKAVCILAR

GAZİ UNIVERSITY
GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

June 2023

ABSTRACT

Today, pictures and videos are shared on online platforms, especially on social media. With the help of deep learning and artificial intelligence technologies, image manipulations are developing rapidly. With the development of image manipulation technologies, pictures and videos are changed and fake pictures and videos are created. The process of replacing and recreating the face in the content of a picture or video with other faces that match certain contours is called Deepfake. The malicious use of Deepfake in various fields can cause serious material and moral damage to people and communities. In order to prevent these situations, it is important to detect deepfake. In the study, Deepfake detection was performed by combining the 2-layer Convolutional Neural Network model on the EfficientNet B5 model. A randomly generated dataset from 509 Deepfake videos with 640x480 resolution created by face swapping methods in the FaceForensic++ dataset was used. The model proposed in the study was trained and tested with the created data sets. In this study, an F1-score of 93.7% was obtained with the model with a learning performance of 95%.

Science Code : 92432

Key Words : Deepfake, Artificial intelligence, Deep learning, EfficientNetB5, Convolutional neural networks, Face swapping

Page Number : 58

Supervisor : Prof. Dr. Aydın ÇETİN

TEŐEKKÜR

Yüksek lisans eğitimimde ve tez çalışmam süresince bilgisi ve deneyimiyle bana yol gösteren danışman hocam sayın Prof. Dr. Aydın ÇETİN'e, tüm zorlukların üstesinden birlikte geldiğim, sevgili eşim Gizem Betül BÜYÜKAVCILAR'a ve üzerimde emekleri çok olup tüm hayatım boyunca ne olursa olsun yanımda olan sevgili anne ve babam Meryem BÜYÜKAVCILAR ve Çetin BÜYÜKAVCILAR'a teşekkür ederim.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	x
RESİMLERİN LİSTESİ	xi
SİMGELER VE KISALTMALAR.....	xii
1.GİRİŞ	1
2.LİTERATÜR.....	9
3.YÖNTEM ve ARAÇLAR.....	13
3.1. Derin Sahtecilik	13
3.2. Derin Sahtecilik Oluşturma Yöntemleri	14
3.3. Derin Sahtecilik Tespit Yöntemleri	17
3.4. Yapay Sinir Ağları	19
3.5. Üretken Çekişmeli Ağlar (GAN).....	21
3.6. Evrişimsel Sinir Ağları (CNN)	22
3.7. Tekrarlayan Sinir Ağları	24
3.8. Uzun Kısa Süreli Bellek.....	26
3.9. Görsel Dönüştürücüler	27
3.10. EfficientNet.....	29
3.11. ImageNet.....	31
3.12. VGGNet	32

	Sayfa
3.13. ResNet.....	32
3.14. Derin Sahtecilik Veri Setinin Seçilmesi ve Kullanılması.....	33
3.15. Uygulamada Kullanılan Sistem ve Hiperparametrelerin Seçilmesi.....	35
4. UYGULAMA	39
5. SONUÇ VE ÖNERİLER.....	45
KAYNAKLAR	47
ÖZGEÇMİŞ	58

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 1.1. 2022 Ocak ayında Youtube platformunu kullanan kullanıcıların yaş aralığı tablosu	1
Çizelge 1.2. 2022 yılında Derin Sahtecilik hakkında bilgi sahibi olanların yüzde tablosu	2
Çizelge 1.3. Derin Sahtecilik Türleri ve İşlevleri	4
Çizelge 2.1. Derin Sahtecilik tespitinde kullanılan veri seti ve başarı tablosu	12
Çizelge 3.1. Derin Sahtecilik Uygulamaları ve özellikleri	17
Çizelge 3.2. Derin Sahtecilik video ve resim tespiti sırasında kullanılan yöntemler.....	19
Çizelge 3.3. Derin sahtecilik tespit yöntemlerinde sıklıkla kullanılan veri setlerinin detay tablosu	34
Çizelge 4.1. Çalışmada kullanılan hiperparametre değerleri	42
Çizelge 4.2. Çalışmada önerilen modelin performans sonuçları	43
Çizelge 4.3. En yüksek performansa sahip çalışmanın diğer literatür çalışmalarıyla karşılaştırma tablosu	44

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. Derin Sahtecilik teknolojisinin oluşturduğu endişe grafiği.....	3
Şekil 3.1. FaceApp Uygulamasının Derin Sahtecilik üretme şeması.....	15
Şekil 3.2. DeepfaceLab Uygulamasının mimarisi	16
Şekil 3.3. Standart bir Yapay Sinir Ağı modeli	20
Şekil 3.4. Genel Üretken Çekişmeli Ağ modeli.....	22
Şekil 3.5. Tipik bir Evrişimsel Sinir Ağı'nın mimarisi	23
Şekil 3.6. Tekrarlayan Sinir Ağı mimarisi	25
Şekil 3.7. Uzun Kısa süreli Bellek mimarisi.....	26
Şekil 3.8. Görsel Dönüştürücü mimarisi	28
Şekil 3.9. EfficientNet modellerinin Imagetnet veri setinde gösterdiği performans / parametre sayısı grafiği.....	29
Şekil 3.10. EfficientNet Modeli Deepwise ve Pointwise Evrişim Şeması.....	30
Şekil 3.11. 16 katmanlı Görsel Geometri Grubu Nöral Ağı mimarisi	32
Şekil 3.12. Artık Ağ (ResNet) mimarisi	33
Şekil 4.1. Çalışmanın süreç akış diyagramı	39
Şekil 4.2. Çalışmada kullanılan Derin Sahtecilik modeli	41

RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 1.1. Derin Sahtecilik teknolojisinin yüz üzerine uygulanması.....	5
Resim 3.1. ImageNet veri seti.....	31
Resim 3.2. FaceForensic++ verisetinden gerçek ve sahte örnekler.....	35

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

%

Açıklamalar

Yüzde

Kısaltmalar

AN

Adversarial Network

ANN

Artificial Neural Network

CNN

Convolutional Neural Network

DCGAN

Deep Convolutional Generative Adversarial Network

DFDC

Deepfake Detection Challenge

DFDCD

Deepfake Detection Challenge Dataset

FF+

Face Forensic++ Veri seti

FN

False Negative

FP

False Positive

GAN

Generative Adversarial Network

LSTM

Long Short-Term Memory

MFC

Media Forensic Challenge

ResNet

Residual Network

RNN

Recurrent Neural Network

SCN

Spatiotemporal Convolutional Network

TN

True Negative

TP

True Positive

VGG

Visual Geometry Group

ViT

Vision Transformer

1. GİRİŞ

Bilgisayarlar gerçekliği simüle etmede her geçen gün daha başarılı olmaktadır. Örneğin, sinemalarda kullanılan kullanışlı konumlar ve eşyalar yerine büyük ölçüde bilgisayarlar tarafından üretilen setler, manzaralar ve karakterler kullanılmaktadır. Bu sahneler ve karakterler gerçekçi gözükmemektedir [1].

En başta sosyal medya olmak üzere sosyal medya platformlarında resim ve video paylaşımları yapılmaktadır. Her gün milyonlarca resim ve video sosyal platformlar aracılığıyla internete yüklenmektedir. 2022 yılında yapılmış bir araştırmaya göre Instagram’da her gün yaklaşık 95 milyon resim ve video paylaşılmaktadır [2]. Araştırmaya göre 2022 yılının ağustos ayında Twitter’da saniyede ortalama 6000 tweet, dakikada ortalama 350 bin tweet, her gün ortalama 500 milyon tweet gönderilmektedir [3]. 2022 yılının haziran ayında Youtube platformunda Youtube Shorts videoları aylık olarak dünya çapında ortalama 1,5 milyar kez görüntülenmektedir [4]. 2023 yılındaki bir araştırmaya göre Youtube platformunda her gün ortalama 1 milyar saat video izlenmekte ve milyarlarca görüntülenme yapılmaktadır [5]. 2022 Ocak ayında Youtube platformunu kullanan kullanıcıların yaş aralığı / yüzde grafiği Çizelge 1.1’de verilmiştir [5].

Çizelge 1.1. 2022 Ocak ayında Youtube platformunu kullanan kullanıcıların yaş aralığı tablosu

Yaş Aralığı	Erkek Kullanıcılar	Kadın Kullanıcılar
18 Altı	%18,30	
18-24	%8,50	%6,00
25-34	%11,60	%8,60
35-44	%9,00	%7,50
45-54	%6,20	%5,70
55-64	%4,40	%4,50
65+	%4,30	%5,40

Yapay zekâ tarafından üretilen resim, videoların, resimlerin ve sesin kesiştiği noktada yeni bir kavram olarak ortaya çıkan, “Deep Learning” ve “Fake” terimlerinin birleşimi ve Türkçe karşılığı “derin sahte” olan “Deepfake”, mevcut bir resim ya da videoda yer alan bir kişinin Yapay Sinir Ağları kullanılarak bir başka kişinin görüntüsü ile değiştirildiği bir medya

türüdür [6]. Derin Sahtecilik, genel olarak Üretken Çekişmeli Ağlar (Generative Adversarial Network – GAN) ve otomatik kodlayıcılar gibi makine öğrenmesi yöntemlerini kullanılıp hazır görüntünün kaynak görüntü üzerinde küçük değişiklikler yapılarak birleştirilmesi veya görüntülerin üst üste konması şeklinde üretilmektedir.

Derin Sahtecilik, 2017 yılında ortaya çıkmıştır. Sosyal içerik paylaşımı yapılan Reddit platformunda, adsız bir kullanıcının yaptığı bazı paylaşımlarda ünlü sanatçıların da bulunduğu yetişkin içerikli videolar bulunmaktadır. Bu yetişkin içerikli videolar, o ünlü sanatçılara ait olmayıp onların yüz yapılarının başka vücutlara Derin Sahtecilik teknolojisi ile değiştirilmesi sonucu oluşturulmuştur [7].


Derin Sahtecilik videoları hakkında bilgisi olan insan sayısı her geçen gün artmaktadır. İproov Firmasının 2022 yılında 8 ülkeden 16.000 katılımcı ile yaptığı ankette derin sahtecilik hakkında bilgisi olan kişi sayısı hesaplanmıştır. Anketin sonuçları Çizelge 1.2’de verilmiştir

Çizelge 1.2. 2022 yılında Derin Sahtecilik hakkında bilgi sahibi olanların yüzde tablosu

Derin Sahteciliği biliyor musunuz?		
Ülke	Bilenlerin Sayısı	Bilmeyenlerin Sayısı
Dünya Geneli	%29	%71
Birleşik Krallık	%32	%68
Birleşik Eyaletler	%27	%73
Kanada	%28	%72
Avusturalya	%27	%73
İspanya	%25	%75
İtalya	%28	%72
Almanya	%25	%75
Meksika	%40	%60

Tabloya göre 2022 yılında dünya genelinde Derin Sahtecilik hakkında bilgi sahibi olan insanların sayısı %29 olmuştur. Firmanın yaptığı 2019 yılındaki ankette bu oran %13 olmuştur. 3 yıl içinde Derin Sahteciliği bilenlerin sayısı ikiye katlanmıştır [8].

Firmanın yaptığı bir diğer ankette insanların derin sahtecilik hakkında endişelendikleri durumlar ölçülmüştür. Genel olarak insanlar, doğru olmayan bir şeye inandırılmak, kimlik bilgilerinin çalınması gibi durumlara endişe duymaktadır. Şekil 1.1’de Derin Sahtecilik teknolojisinin oluşturduğu endişe grafiği verilmiştir [8].



Şekil 1.1. Derin Sahtecilik teknolojisinin oluşturduğu endişe grafiği

Derin sahtecilik içerikleri farklı türlerde üretilebilmektedir. Çizelge 1.3’te derin sahtecilik türleri ve kullanılış şekilleri verilmiştir [9].

Çizelge 1.3. Derin Sahtecilik Türleri ve İşlevleri

Derin Sahtecilik Türü	İşlev
Resim Derin Sahteciliği	Yüz ve vücut değiştirme, yüz değiştirme, yüzleri karıştırma
Ses Derin Sahteciliği	Ses değiştirme, ses taklit etme, yeni bir yazı üzerinden hedef alınan ses konuşturma
Video Derin Sahteciliği	Bir videodaki kişinin yüzünü başka bir kişinin yüzüyle değiştirme, bir kişinin görsel hareketlerini başka bir kişinin yüzü ve vücuduna aktararak yansıtma
Ses – Video Derin Sahteciliği	Dudak senkronizasyonu sağlama, konuşan bir yüz içeren videoda konuşan kişinin hareketlerini ve kelimelerini değiştirme

Paylaşılma amaçları doğrultusunda Derin Sahtecilik üreticilerini dört temel kategoride sıralamaktadır [9]:

1. Derin Sahtecilik videolarını eğlence/ hobi olarak üreten topluluklar,
2. Manipülatif kötü niyetli aktörler,
3. Siyasi aktörler ve aktivistler,
4. Televizyon, reklam şirketleri gibi meşru aktörler

Günümüzde Derin Sahtecilik teknolojisi her geçen gün daha başarılı ve daha gerçekçi bir hal almaktadır. Derin Sahtecilik hem iyi hem de kötü amaçla kullanılabilir.

Derin sahtecilik teknolojisinin kullanıldığı alanlar olarak:

- Eğitim videolarında birden fazla dilde konu anlatımı oluşturulması.
- Film ve Sanat alanında vefat etmiş bir ünlünün bir filmde derin sahtecilik yöntemleri ile kullanılması
- “Malaria No More” isimli İngiltere merkezli yardımcı kuruluş, David Beckham’ın dokuz dilde sıtma karşıtı mesaj ilettiği bir video oluşturmak için derin sahtecilik teknolojisini kullandı ve 9 ayrı dilde konuşmasını içeren videodaki [10, 11] gibi sağlık alanında bilginin dünyaya yayılması.

- Eğlence amaçlı kullanımı.
- İş alanında reklam ve ticaret işlemlerinde kullanılan bir modelin farklı ten rengi, farklı boy, kilo değerleri ile tekrar kullanılması verilebilir.

Resim 1.1’de Derin Sahtecilik kullanılarak oluşturulmuş yüzler verilmiştir.



Resim 1.1. Derin Sahtecilik teknolojisinin yüz üzerine uygulanması

Derin sahtecilik iyi amaçlarla kullanılabilmesine rağmen zaman geçtikçe kötü niyetli olarak da kullanımı ortaya çıkmıştır. Bu durum, arkadaşlar arası küçük kandırmaca ve manipülasyonlarla olabileceği gibi, işin içine politika, sağlık, eğitim gibi alanlarının da girmesiyle oldukça ciddi bir hal alabilmektedir. Derin Sahteciliğin kötü kullanım alanları olarak [12]:

- Birisi hakkında yapmadığı bir olayı yapmış gibi göstermek
- Eğitim kaynaklarını yanlış bilgilerle yozlaştırmak
- Ulusal güvenliği tehdit eden haberler ya da videolar yayınlamak
- Halkın güvenini sarsacak haberler yapmak
- Siber güvenlik problemleri ortaya çıkarmak

- Rusya Başkan Vladimir Putin'in Amerikan Halkını seçim müdahalesi ve ve artan siyasi bölünme hakkında uyaran videosu
- Kim Jong'un Derin Sahtecilik yöntemi ile oluşturulmuş videosu
- Rusya'nın Ukrayna başkanı Zelensky'nin Derin Sahtecilik kullanarak teslim olma çağrısını gerçekmiş gibi göstermesi [13]
- Jordan Peel isimli bir içerik üreticisi kendi söylediklerini eski Amerika Başkanı Barack Obama'nın konuşmasının olduğu bir içeriğe eklemiş ve konuşmayı Barack Obama yapmış gibi bir izlenim yaratılması [14, 15]
- Polisler Donald Trump'ı zorla tutuklayıp götürmeleri gibi gösterilmesi [16]
- Kamera kayıtları izlenirken olay yerinde olmayan birinin oradaymış gibi gösterilmesi

Bir politikacının söylemediği bir haberi söylemiş gibi göstermek, deneyler hakkında sonuçların başka birisinin ağzından başka bir şekilde söylenmesi gibi durumlar hem güvenlik hem de etik açısından dünyamızı tehdit etmektedir. Bu tür durumların önüne geçilebilmesi için bu video ve resimlerin sahte olup olmadığının tespiti kaçınılmaz hale getirmiştir. Bu sebeple sahte görüntü ve videoların tespiti oldukça önemli bir konudur.

Bu Tezde, Derin Sahtecilik tespiti için EfficientNet B5 modeline 2 katmanlı Evrişimsel Sınır Ağı (Convolutional Neural Network – CNN) modeli birleştirilip öznitelikler (attribute) değiştirilerek derin sahtecilik tespiti yapılmıştır.

Bu Tez ile ileride kullanılacak yöntemlere alternatif bir bakış açısı ve kayda alınması gereken bir yöntem sunulacaktır.

Bu Tez ile ilgili gerekli donanım açısından kullanılan araçlar yetersiz ve zayıf kalacaktır. Bir video işlemek için kullanılacak bilgisayarda yüksek performanslı bir ekran kartı ve işlemciye ihtiyaç duyulmaktadır. Bunun haricinde kullanılan yöntemlerin kodları ve kullanılan veri setleri eksik ve hatalı olabilir. Bu durumlar göz önüne alındığında hazırlanan bu çalışma oldukça dikkatli ve olabildiğince hatalı kısımları düzeltilerek yapılmıştır.

Tezin ilerleyen bölümlerinde konu ile ilgili çalışmalar, yayınlar ve araştırmalar incelenmiştir. Kullanılan yöntemler ve metotlar hakkında bilgi, kullanılan veri setleri ve neden tercih edildiği ve kullanılan öğrenilmiş model ve neden tercih edildiği anlatılmıştır.

Yapılan çalışma anlatılıp resim ve tablolarla desteklenmiştir. Son olarak da sonuçlar, öneriler ve ileride çalışmaya farklı olarak eklenebilecek özellikler anlatılmıştır.

2. LİTERATÜR

Bu bölümde çalışmada ele alınan derin sahtecilik üzerine yapılan çalışmalar incelemiş ve anlatılmıştır. Literatürdeki çalışmalar iki ayrı grup altında, derin sahtecilik oluşturma ve derin sahtecilik tespiti olarak incelenmiştir.

Derin Sahtecilik içeren resim ve videoları oluşturmak için iki farklı yaklaşım kullanılmaktadır. Bu yaklaşımlar, Değişken Otomatik Ağlar [17] ve GAN'dır [18].

Üretken Düşman Ağları iki farklı ağdan oluşmaktadır. Bu ağlar, videonun gerçek olup olmadığını tespit eden Ayrımıcı (The Discriminator) ağı ve videoyu gerçekçi olacak bir şekilde sahteleyen Oluşturucu ağıdır (The Generator). Üretken Düşman Ağları'nın kullanılmasıyla gerçekçi sonuçlar elde edilmiştir. Zaman içinde Üretken Düşman Ağları'ndan DiscoGAN, StarGAN, StyleGAN-V2 isimli yaklaşımlar ortaya çıkmıştır. Ortaya çıkan yaklaşımlardan en iyi sonuçlar StyleGAN-V2 yaklaşımı ile alınmıştır [19].

Denetimli öğrenmenin sıklıkla kullanıldığı CNN, bilgisayar görsel uygulamalarında yerini almıştır. Denetimsiz öğrenme daha az ilgi çekmiştir. Bu durumu azaltmak için belirli mimari sınırları olan ve denetimsiz öğrenme için güçlü bir aday olan Evrimsel Sinir Ağlarından yeni bir sınıf olan Derin Evrimsel Üretken Çekişmeli Nöral Ağlar (Deep Convolutional Generative Adversarial Neural Network – DCGAN) önerilmiştir. Farklı veri setlerinde eğitim yapılmış ve oluşturucu ve ayırıcı ağların ikisinde de başarılı bir öğrenme sergilemiştir [20].

Obje tespiti yapılırken meydana tıkanma ve deformasyonlar meydana gelmektedir. Bu durum tespit için zorlayıcı ve sorun çıkarıcı bir durum olmaktadır. Bu durumları çözmek için genellikle büyük çaplı veri setleri toplanmaktadır. Bu durum için tıkanmalar ve deformasyonlarla örnekler üreten bir Rakip Ağ (Adversarial Network – AN) öğrenmesi önerilmiştir. Rakibin amacı esne dedektörünün sınıflandırması zor olan örnekler oluşturmaktır. Çalışmanın çerçevesinde (framework) hem orijinal dedektör hem de düşman ortak bir şekilde öğrenilmiştir. Deneysel sonuçlar, Fast-RCNN boru hattına kıyasla VOC07'de %2,3'lük bir mAP artışı ve VOC2012 nesne algılama mücadelesinde %2,6'lık bir mAP artışı göstermiştir [21].

Bir çalışmada, Evrişimli Görüntü Transformatörü kullanılarak derin sahtecilik tespiti yapılmıştır [22]. Evrişimli Görüntü Transformatörü iki ayrı ağ modelini içermektedir. Bunlar, CNN ve Görüntü Transformatörü'dür (ViT). Evrişimsel Sinir Ağı modeli ile oluşturulan Evrişimli Görüntü Transformatörü modelinin öğrenilebilir özellikleri çıkartılırken, Görüntü Transformatörü modeli ile öğrenilmiş olan özellikler girdi olarak alınmıştır. Oluşturulan model bir dikkat mekanizması yolu ile girdileri kategorilere ayırmıştır. Önerilen model, Derin Sahtecilik Tespit Mücadelesi (DFDC) veri seti ile eğitilmiştir. Çalışmanın sonucu olarak modelden %91,5 doğruluk yüzdesi, %91 AUC değeri ve %32 kayıp değeri elde edilmiştir [22].

Yapay Sinir Ağları dışında piksel seviyesinde çalışılmasından kaçınıp, basit ikili sınıflandırıcılar ile multimedya akış tanımlayıcıları çözümüyle edip videolar tanımlanarak derin sahtecilik tespiti yapılmıştır [23]. Yapılan çalışmada Medya Adli Mücadelesi (Media Forensic Challenge – MFC) adlı veri seti tercih edilmiştir. Çalışmadan sonuç olarak %91,7 F1-skoru alınmıştır. Genel olarak üzerine çalışılan veri sınıflarını kullanarak alınmış bu sonuçlar, bu yaklaşımın, derin sahtecilik oluşturanların multimedya akışı tanımlayıcılarını özenli bir şekilde temizlenmediği durumlarda, üst düzey derin sahtecilik tespit puanı elde edebileceğini göstermiştir [23].

Derin Sahtecilik tespiti için yapılmış çalışmalardan bir diğeri, uzamsal zamansal tutarsızlık öğrenimi yöntemidir [24]. Çalışmada, videoların içerisindeki her kare sırasıyla parçalara ayrıştırılmıştır. İkili sınıflandırma yöntemi ile her bir resimdeki kare numarası, resim yüksekliği ve genişliği tek tek incelenip her kare içerisinde diziye dönüştürülerek uzamsal zamansal tutarsızlık öğrenimi yöntemi sunulmuştur. Çalışmada DFDC veri seti kullanılmış olup %89,8'lik bir başarı performansı alınmıştır [24].

Bir farklı yaklaşım olarak basit ağlar ile başlayan dikkat (attention) katmanlarını ve Siyam (Siamese) öğrenmesi ile birbirinden farklı modeller oluşturulmuştur. EfficientNet B4 modeli kullanılarak çalışmalar yapılmıştır. Nicolo Bonettini ve arkadaşları tarafından yapılan bu çalışmada ImageNet veri setinden %83'lük bir doğru tespit performansı elde edilmiştir [25].

Çeşitli Görüntü Transformatörlerini (Vision Transformers), Evrişimsel EfficientNet B0 ile özellikleri tespit edip çıkartarak farklı bir çalışma yapılmıştır. Çalışmada, Derin Sahteciliği tespit etmek amacıyla damıtma (Distillation) yöntemi veya toplama (Ensemble)

yöntemlerinden farklı bir yöntem kullanılmıştır [26]. Oluşturulan yöntem DFDC veri setinde test edilmiştir. Performans sonuçları olarak %91,9 doğruluk yüzdesi ve %83,8 F1-Skoru alınmıştır [26].

MINTIME: Çok Kimlikli Boyutta Değişmeyen Video Derin Sahtecilik Tespiti [28] çalışmasında uzamsal ve zamansal anormallikleri yakalayan ve aynı videodaki birden fazla kişinin örneklerini ve yüz boyutlarındaki farklılıkları işleyen bir video derin sahte algılama yaklaşımı olan MINTIME'ı tanıtılmıştır. Bu çalışmada bir videoda tasvir edilen çoklu kimliklerin yüz dizilerinden uzay-zamansal anomalileri yakalamak için Evrişimli Sinir Ağı omurgası ile birleştirilmiş bir Uzaysal-Zamansal ZamanSformer üzerine kurulmuştur. Bu yaklaşım çapraz sahtecilik ve çapraz veri seti bağlamlarında da yüksek genelleme düzeyi gösterip ve genellikle önceki yaklaşımlardan daha iyi performans göstermiştir [28].

StyleGAN3 adlı sentetik olarak üretilmiş verilerden yararlanarak herhangi bir gerçek veriye olan ihtiyacı ortadan kaldıran bir derin sahte tespit metodolojisi önerilmiştir [29]. Bu öneri yalnızca gerçek verileri kullanan geleneksel eğitim metodolojisiyle aynı düzeyde performans göstermekle kalmayıp aynı zamanda az miktarda gerçek veriyle ince ayar yapıldığında daha iyi genelleme yetenekleri göstermiştir. CelebAHQ veri setinin doğruluk sonuçları hem takas hem de test modeli SberSwap olan gerçek veriler üzerinde eğitilmiş model, %93,41'lik doğruluğuna sahip çıkmış ve aynı ayar için, sentetik veriler üzerinde eğitilen model %82,36'lık bir doğruluğa sahip olmuştur [29].

Çizelge 2.1'de yapılan çalışmalarda ve kullanılan yöntemlerde elde edilen doğruluk değerleri verilmiştir.

Çizelge 2.1. Derin Sahtecilik tespitinde kullanılan veri seti ve başarı tablosu

Çalışma	Veriseti	Yöntem	Başarı Oranı
StyleGAN3 sentetik (2021)	FFHQ & ADFES	GAN	%99
CNN Topluluğu (2020)	ImageNet	Farklı CNN'ler	%83,8
Convolutional Vision Transformer (2021)	DFDC	CNN ve ViT	%91,5
EfficientNet & Vision Transformers Birleştirilmesi (2021)	---	EfficientNet B0 ve ViT	%88
MINTIME Değişmeyen Video Derin Sahtecilik Tespiti (2022)	DFDC Preview	MINTIME-XC	%78

Üçüncü bölümde çalışmada kullanılan yöntemler ve araçlar anlatılmıştır. Yöntemlerin özellikleri ve kullanıldığı yerler anlatılmıştır. Çalışma yapılırken kullanılan araçlar anlatılmıştır.

3. YÖNTEM VE ARAÇLAR

Bu bölümde Derin Sahtecilik hakkında detaylı bilgi verilmiştir. Derin Sahtecilik oluşturma ve Derin Sahtecilik tespiti için kullanılan yöntem ve metotlar anlatılmıştır. Derin Sahtecilik tespitinde incelenen özellikler, Derin Sahtecilik tespitinde kullanılan nöral ağlar, kullanılan veri setleri ve özellikleri, öznelilikler detaylı bir şekilde anlatılmıştır.

3.1. Derin Sahtecilik

Yapay zekâ ve derin öğrenme yöntemleri ile görüntü işleme ve manipüle etme teknolojilerinin gelişmesiyle resim ve videolar kolaylıkla değiştirilerek sahte resim ve videolar ortaya çıkmıştır. Adobe Photoshop (Adobe, 2023a) gibi çeşitli sinyal işleme türlerini gerçekleştirip manipüle etmek için uzman yazılımlar bulunmaktadır. Videoların manipülasyonu için genel olarak son işleme bölümünde gelişmiş görsel efektler (VFX) eklenmektedir. Gerçekçi yüz ifadeleri ve hareketleri oluşturmak için izleme yardımıyla hareket yakalama teknikleri işaretçileri kullanılmaktadır. Örnek olarak James Cameron'ın Avatar (IMDb, 2021) filminde Adobe Photoshop gibi araçlarla beraber bu yöntemler kullanılmıştır [30].

Bir Derin Sahtecilik videosu iki makine öğrenmesi modelini kullanır. İlk model örnek videolardan oluşan bir veri kümesinden sahte kesitler oluştururken diğer model videonun sahte olup olmadığını tespit etmeye çalışır. İkinci model videonun sahte olup olmadığını söyleyemediğinde, yapılan Derin Sahtecilik bir insan için yeterince inandırıcı şekilde ayarlanmış olur. Aynı zamanda Derin Sahtecilik oluşturmak için kullanılan bu temel yöntem GAN'dır [14].

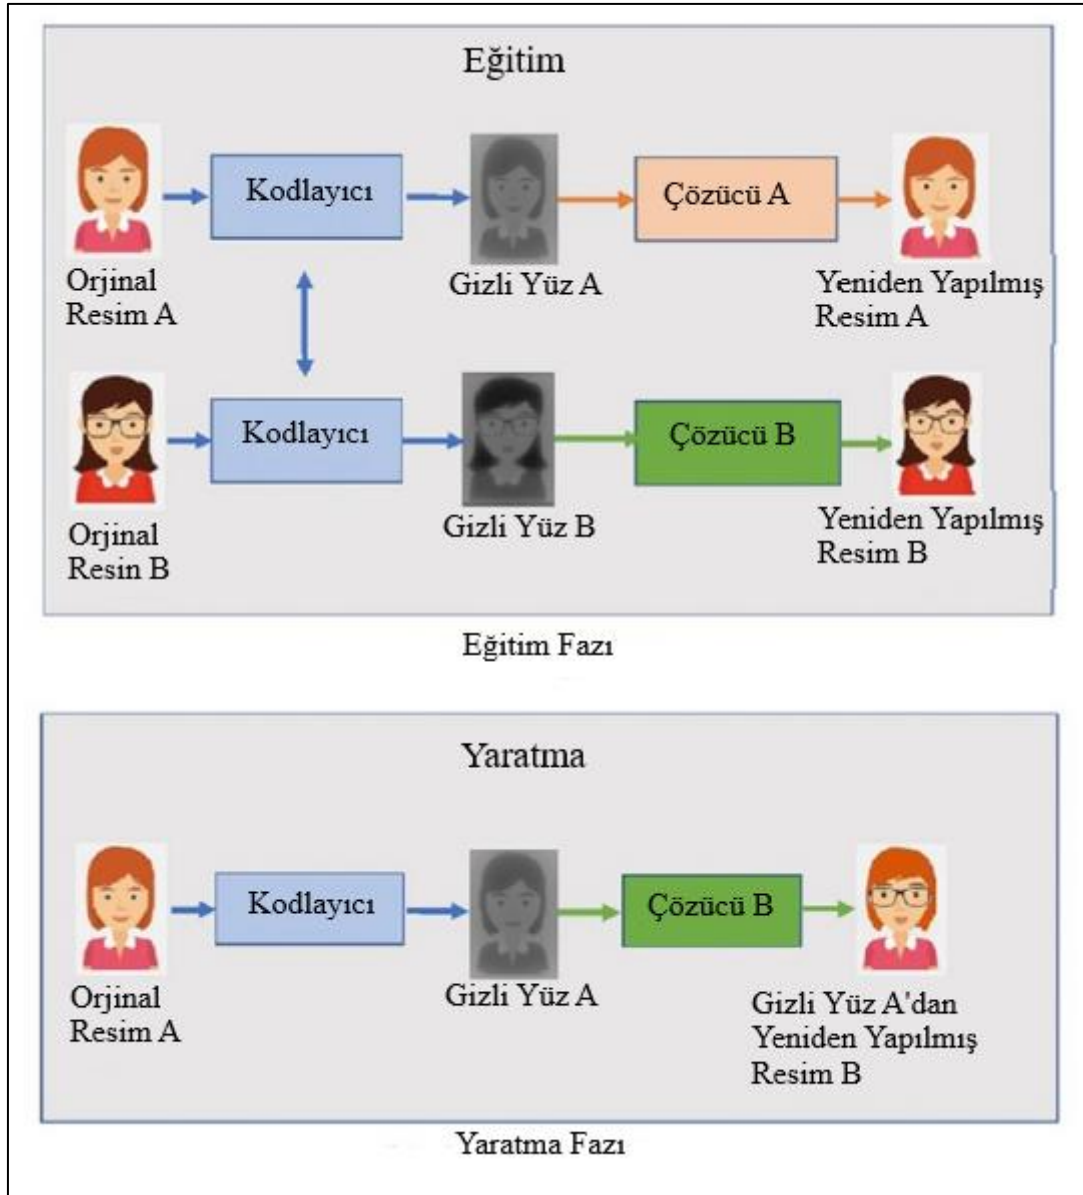
Derin sahtecilik tekniği, resim ve videoların üzerine yapılan işlemler yapay zekanın Derin Öğrenme alanı ile karşımıza çıkmaktadır. Derin Öğrenme, Bir veya daha fazla gizli katman içeren yapay sinir ağları ve benzeri makine öğrenme algoritmalarını kapsayan çalışma alanıdır. Derin öğrenme yöntemleri ile resim ve videolar üzerinde değişiklikler yapılabilmektedir [1].

3.2. Derin Sahtecilik Oluřturma Yöntemleri

Derin Sahtecilik oluřturulurken genellikle GAN kullanılmaktadır. Bu aęlar ve farklı yöntemler kullanılarak derin sahtecilik üreten çeřitli uygulamalar geliřtirilmiřtir [31].

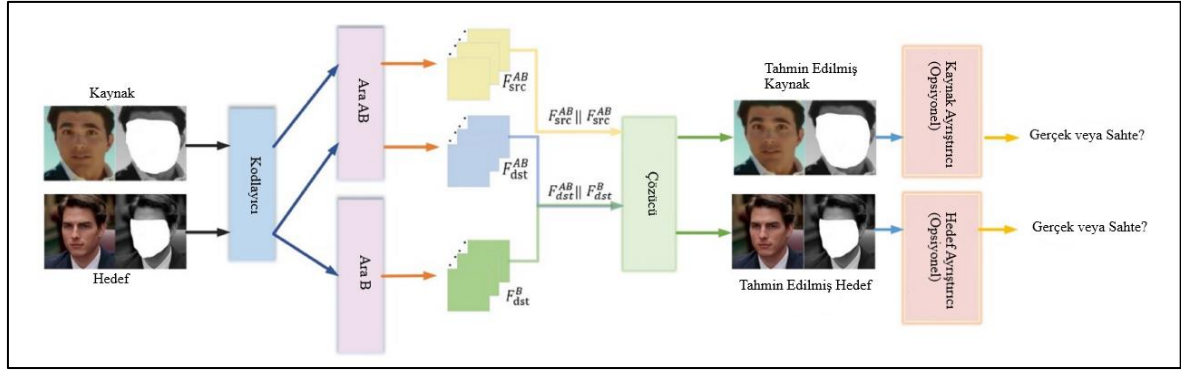
FaceApp, bir Reddit kullanıcısı tarafından otomatik kodlayıcı-kod çözücü eřleřtirme yapısını kullanarak derin sahteler oluřturmak için geliřtirilmiř bir uygulamadır [32, 33]. Bu teknik kullanılarak, yüz resimleri bir otomatik kodlayıcı ve bir kod çözücü kullanılarak çözülr. Giriř ve çıkıř resimleri arasındaki yüzleri deęiřtirmek için kodlama ve řifre çözme ikilileri gerekmektedir. Her ikili farklı bir görüntü koleksiyonunda eęitilir ve kodlayıcı parametreleri iki aę arasında paylařılır. Sonuç olarak, iki ikili kodlayıcı aynı aęı paylařır. Yüzler genellikle göz, burun ve aęız konumları olarak benzerdir ve bu nedenle bu yöntem, sıradan bir kodlayıcının iki yüz resmi seti arasındaki benzerlikleri öęrenmesini kolaylařtırmaktadır [31]. řekil 1'de, A yüzünün özelliklerinin, B yüzünü orijinal A yüzünden oluřturmak için B yüzünün kod çözücüsüne baęlandığı bir yaratma ařamalarını göstermektedir. Modelde iki ikili kodlayıcı-kod çözücünün kullanımını göstermektedir. Eęitim süreci için, iki aę aynı kodlayıcıyı ve çeřitli kod çözücülerini kullanmaktadır (řekil 4a). Standart kodlayıcı, derin sahte bir görüntü yaratmak için yüz A ve kod çözücü B'nin bir görüntüsünü kodlamaktadır (řekil 4b).

řekil 3.1'de FaceApp uygulamasının Derin Sahtecilik Üretme řeması verilmiřtir.



Şekil 3.1. FaceApp Uygulamasının Derin Sahtecilik üretme şeması

DeepFaceLab, derin sahtecilik oluşturma uygulamalarında yaygın olarak bulunan belirsiz iş akışı ve düşük performans sıkıntılarının üstesinden gelmek için tasarlanmıştır. Aralarında bir “ara” katman ve bir “hizalama” bulunan bir “kodlayıcı” ve “hedef kod çözücünden” oluşan bir dönüştürme aşaması kullanılmaktadır [34]. Şekil 3.2’de DeepFaceLab metodunun mimarisi verilmiştir.



Şekil 3.2 DeepfaceLab Uygulamasının mimarisi

Face Swap-GAN, bir GAN kullanan derin sahtecilik uygulamalarının gelişmiş bir versiyonudur [35]. Uygulama derin öğrenmede bulunan iki tür kayıptan yararlanmaktadır: çekişmeli (adversarial) kayıp ve algısal (perceptual) kayıp. Algısal kayıpta göz hareketleri daha doğal ve sabittir. Bu yöntem ile maskelerde bulunan kusurları yumuşatmaya yardımcı olarak daha yüksek kaliteli çıktı videoları elde edilir. Sonuç olarak 64x64, 128x128, 256x256 çözünürlüklü çıktılar oluşturulabilir [35].

FaceNet uygulaması [36], yüz algılamasını Güvenilir ve yüz tanıma daha doğru için çok görevli bir CNN sunmaktadır.

Çizelge 3.1’de kullanılan derin sahtecilik uygulamalarının bir özet özellik tablosu verilmiştir.

Çizelge 3.1. Derin Sahtecilik Uygulamaları ve özellikleri

Araç / Uygulama	Özellikler
DeepFaceLab	3 saat azaltılmış eğitim süresi Daha iyi poz ve ifade uyumu Keskin yüz işaretleri Dudak manipülasyonunu, kafa değiştirmeyi ve yaşlandırma
FSGAN	Yüz değiştirme, Canlandırma Konum ve duygu hareketlerine uyum
DiscoFaceGAN	Gizli ile sanal bireylerin yüz resimlerini oluşturulması Çekişmeli öğrenmede 3B öncelikleri kullanılması
FaceShifter	Yüksek doğrulukta yüz değiştirme

3.3. Derin Sahtecilik Tespit Yöntemleri

Derin Sahtecilik teknolojisinde geçtiğimiz yıllara göre yüksek gerçeklik seviyesi gösteren yeni algoritmalar ortaya çıkmıştır. Bu sahte video ve resimlerin son halleri, temel yüz değiştirme işleminin ötesine geçip baş sentezine, ortak görsel-işitsel senteze ve tüm vücut değiştirme sentezine kadar uzanmaktadır [37]. Derin Sahtecilik teknolojisi ilk bakışta fark edilmesi zor olsa da uygun yöntemlerle tespit edilebilecek bir teknolojidir.

Derin Sahtecilik teknolojisinin yapay zekanın kullanılmadığı tespit yöntemleri arasında istatistiksel anormallik tespiti ve korelasyonu kullanılmaktadır. Yapay zekâ yöntemlerinin etkin bir şekilde devreye girmesiyle Derin Sahtecilik teknolojisinin üretimi ve tespit edilmesi daha başarılı ve daha kolay bir hal almıştır [37]. Tespit yöntemi temel piksel seviyesine inen metotlar; resim ve videolardaki kalıntılara (artifact), izlere, renk uyumsuzluklarına, doku ve yapı bozukluklarına dikkat ederler. Bunların dışında pozlarda tutarsızlıkların bulunması, anormal göz hareketleri ve çeşitlik çarpıklıklar da Derin Sahtecilik teknolojisinin tespit edilmesinde kullanılmıştır [38].

Derin Sahtecilik teknolojisinin oluşturulma şekline bakılarak tespit ederken çerçeveler (frame) ve kareler arası çeşitli tutarsızlıklara bakılarak tespit edilmektedir. Derin Sahtecilik

teknolojisini tespit ederken yüz kalıntılarına bakılır. Yüz bölgesinin diğer alandakilere göre daha bulanık gözükmesi, parlaması, cilt tonundaki değişiklikler, yüz bölgesinde bulunabilen çift çene, çift kaş gibi küçük parçaların bulunması, el ile yüz bölgesi engellendiğinde o kısımda titreme ve bulanıklaşma olması Derin Sahtecilik teknolojisini tespitini kolaylaştırmaktadır.

Derin Sahtecilik teknolojisini tespitinde kullanılan yapay zekâya dayalı yöntemlerde, el yapımı veya gözlemlenebilen farklılıklar incelenmemektedir [38]. Yapay zekâya dayalı yaklaşımların çoğunda temelinde uygun bir derin sinir ağı modeli kullanılır. Evrişimli Sinir Ağları modellerini bir araya getirilmesi, İki farklı ağın modelinin birleştirilmesi, SCN, MesoNet, nöron kapsamaya dayalı yöntemleri, dikkat mekanizmaları(katmanları), artımlı öğrenme yöntemleri veya çok görevli öğrenme yapay zekâ ile Derin Sahtecilik tespitinde kullanılan yöntemlerdir. Bahsedilen tüm bu tespit yöntemlerinin karşılaştırılması zordur. Bunun nedeni, her bir yöntemin yazarları farklı değerlendirme ölçütleri kullanıp elde edilen performansları farklı veri setlerinde ölçmüştür.

Derin sahtecilik tespit yöntemleri, derin sahtecilik oluşturma yöntemlerine oldukça benzemektedir. Çünkü derin sahtecilik tespitinde kullanılacak tespit bölümü, derin sahtecilik oluşturma yöntemlerinde eğitim sürecinde kullanılan bir parçalardan biridir. Derin sahtecilik tespit yöntemleri içinde de çeşitli alanlarda birden fazla yöntem ve yaklaşım bulunmuştur.

Derin Sahtecilik kullanılmış resim ve videolarda, sınırlı veriler ile eğitilmiş Derin Sahtecilik oluşturuçularında bulunan ve yüz bölgesinde oluşan aydınlatmalardaki tutarsızlıklar sebebiyle titreyen görüntüler bulunabilmektedir. Bu görüntüler CNN özellikli sahte detektörler ile tespit edilebilmektedir [39].

Derin Sahtecilik çıktıları ile yüz pozları arasındaki farklılıklar, dönüm noktası odakları kullanılarak tespit edilebileceğini ve bu farklılıkların vektör makine modellerinde kullanılarak sınıflandırılabilirliği görülmüştür. Böylece ile baş ve yüz pozlarında oluşan uyumsuzluklar yakalanıp manipülasyonların tespiti yapılabilir [40].

Bağlantılı eylemler içeren karışık videolardaki zamansal etkileşimleri öğrenmek amacıyla farklı bir tasarıma ihtiyaç duyulmaktadır. Gürültülerin solması sebebiyle uzun videoların öğrenilme aşamasında Tekrarlayan Sinir Ağları ciddi sıkıntılar yaşanmıştır. Bu sıkıntının

çözümünde Uzun-Kısa Süreli Bellek (LSTM) olarak bilinen farklı bir çeşit RNN ağı bu sorunu çözmek için idealdir.

Çizelge 3.2’de Derin Sahtecilik video ve resim tespiti sırasında kullanılan yöntemler verilmiştir.

Çizelge 3.2. Derin Sahtecilik video ve resim tespiti sırasında kullanılan yöntemler


Resim Özellikleri	İnsan Özellikleri	Yapay Zeka Yöntemleri
Kalıntı ve İzler	Bozuk Göz Kırpmaları	Uçtan Uca Yaklaşım
Renk Tutarsızlığı	Yüz Çarpıtma	Dikkat Mekanizma ve Katmanları
Doku Bozulması	Yüz Şekil ve İfadeleri	Artımlı Öğrenme
Optik Akış Analizi		Nöral Ağlar
Fiziksel Kamera Özellikleri		Nöron Kapsama Yöntemleri

3.4. Yapay Sinir Ağları

Yapay Sinir Ağları (Artificial Neural Network – ANN, Neural Network – NN), biyolojik sinir ağlarından ilham alarak oluşturulmuş bilgi işlem yapılarıdır [41]. Bir ANN, bir beyindeki nöronları modelleyen yapay nöronlar adı verilen bağlı birimler veya düğümler topluluğuna dayanmaktadır. Bir beyindeki sinapslar gibi her bağlantı, diğer nöronlara bir sinyal iletebilir. Yapay bir nöron sinyalleri alır, ardından bunları işler ve kendisine bağlı nöronlara sinyal gönderir. Bir bağlantıdaki "sinyal" gerçek bir sayıdır ve her bir nöronun çıktısı, girdilerinin toplamının doğrusal olmayan bir fonksiyonu tarafından hesaplanmaktadır. Bu bağlantılara kenar denir. Nöronlar ve kenarlar öğrenme ilerledikçe ayarlanan bir ağırlığa sahiptir. Ağırlık, bir bağlantıdaki sinyalin gücünü artırır veya azaltır. Nöronlar, yalnızca toplam sinyal bu eşiği geçtiğinde bir sinyal gönderilecek şekilde bir eşiğe sahip olabilir [41].

Tipik olarak, nöronlar katmanlar halinde toplanmaktadır. Farklı katmanlar girdileri üzerinde farklı dönüşümler gerçekleştirebilir. Burada Sinyaller, muhtemelen katmanları birden çok

kez geçtikten sonra, ilk katmandan (giriş katmanı) son katmana (çıkış katmanı) gider [41]. Şekil 3.3'te standart bir Yapay Sinir Ağı modeli verilmiştir.



Şekil 3.3. Standart bir Yapay Sinir Ağı modeli

Yapay Sinir Ağları, doğrusal olmayan durumları ve karmaşık ilişkileri öğrenme ve modelleme yeteneğine sahiptir. Bu yetenek, nöronların çeşitli modellerde bağlanmasıyla elde edilmektedir ve bazı nöronların çıktısının diğerlerinin girdisi olmasına izin verilmektedir. Böylece Yapay Sinir Ağı, yönlendirilmiş, ağırlıklı bir grafik oluşturmaktadır [42].

Yapay Sinir Ağları evrilerek farklı türler elde edilmiştir. Bu türlere örnek olarak; görsel ve diğer iki boyutlu verileri işlemede özellikle başarılı olduğu kanıtlanmış CNN, yok olan gradyan probleminden kaçınarak geniş kelime dağarcığına sahip konuşma tanıma, metinden konuşma sentezine ve fotoğraf gerçekliğinde konuşan kafaların oluşturulmasında kullanılan LSTM, bir oyunu kazanmak ya da rakibi bir girdinin gerçekliği konusunda aldatmak gibi işlerde birbiriyle rekabet ettiği GAN verilebilir [42].

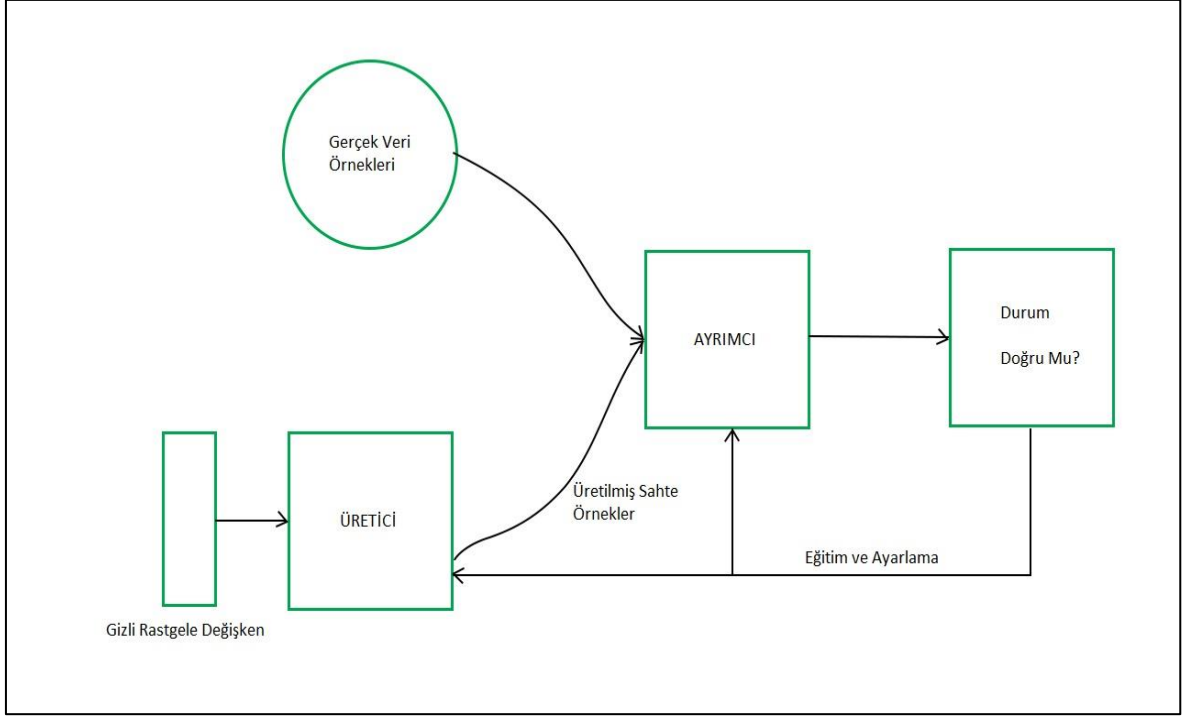
3.5. Üretken Çekişmeli Ağlar

GAN, Haziran 2014'te Ian Goodfellow ve arkadaşları tarafından tasarlanan bir makine öğrenimi çerçeveleri sınıfıdır [43]. Temeli, iki sinir ağı, bir temsilcinin kazancının diğerinin kaybı olduğu sıfır toplamlı bir oyun şeklinde birbiriyle yarışmasına dayanmaktadır.

Bir Üretken çekişmeli ağa eğitim seti verildiğinde, eğitim seti ile aynı istatistiklere sahip yeni veriler üretmeyi öğrenir. Fotoğraflar üzerine eğitilmiş bir GAN, en azından yüzeysel olarak gerçek görünen ve pek çok gerçekçi özelliğe sahip fotoğraflar üretebilmektedir. İlk olarak denetimsiz öğrenme için üretken bir model biçimi olarak önerilmiştir. Sonra da Üretken Çekişmeli Ağların ayrıca yarı denetimli öğrenme, tam denetimli öğrenme ve takviyeli öğrenme için faydalı olduğu kanıtlanmıştır [43].

Bir Üretken Çekişmeli Ağın temel yapısı, dinamik olarak güncellenmekte olan girdinin ne kadar "gerçekçi" görüldüğünü söyleyebilen başka bir sinir ağı olan "ayrımcı" ağ ile "dolaylı" eğitime dayanmaktadır. Üreticinin belirli bir görüntüye olan mesafeyi en aza indirmek için değil, ayrımcıyı kandırmak için eğitildiği anlamına gelmektedir. Bu da modelin denetimsiz bir şekilde öğrenmesini sağlar [44].

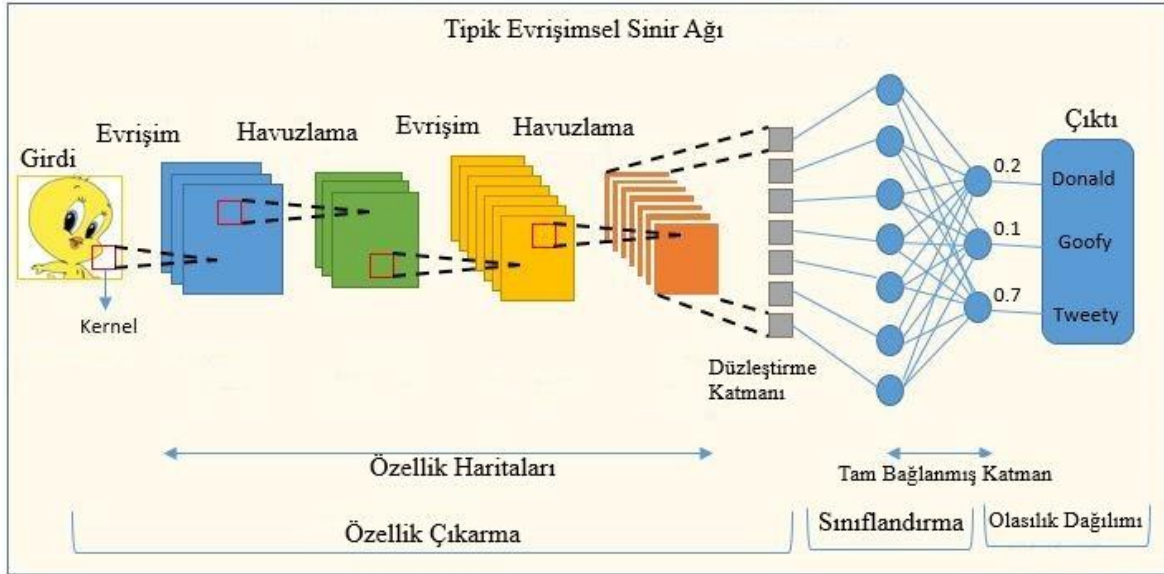
Üretken Çekişmeli Ağların genel model yapısı Şekil 3.4'te verilmiştir.



Şekil 3.4. Genel Üretken Çekişmeli Ağ modeli

3.6. Evrişimsel Sinir Ağları

CNN, katmanlarından en az bir tanesinde genel matris çarpımı yerine evrişim (convolution) adı verilen matematiksel bir işlemi kullanan özel bir yapay sinir ağıdır [37]. Pikselleri işlemek için özel olarak tasarlanmıştır. Katman sayılarına bağlı olarak VGG16, VGG19 gibi CNN modelinden türeyen derin ağ modelleri oluşturulmuştur. Şekil 3.5'te bir Evrişimsel Sinir Ağı'nın genel mimarisi verilmiştir.



Şekil 3.5. Tipik bir Evrişimsel Sinir Ağı'nın mimarisi

Evrişimsel Sinir Ağı'nın mimarisi genel olarak bir girdi katmanı, arada bulunan gizli katmanlar ve bir çıktı katmanından oluşmaktadır. Evrişimsel Sinir Ağları'ndaki gizli katmanlar evrişimi gerçekleştiren katmanları da içermektedir. Bu katmanlar, giriş matrisiyle evrişim çekirdeğinin noktasal çarpımını gerçekleştiren bir katmandır. Elde edilen çıktı sıklıkla Frobenius iç çarpımını olarak çıkar ve aktivasyon fonksiyonu genellikle doğrultucu (ReLU) olmaktadır. Evrişim çekirdeği, katman için girdi matrisi boyunca kayma yaparken, evrişim işlemi ise bir sonraki katmanın girdisine katkı sağlayan bir özellik haritası çıkarır. Sonra, havuzlama katmanları, tamamen bağlı katmanlar ve normalleştirme katmanları gibi diğer katmanlar modelin yapısını takip etmektedir [37].

Evrişimsel Sinir Ağları'ndaki tensör, giriş sayısı, giriş yüksekliği, giriş genişliği ve giriş kanallarından oluşur.

$$(giriş\ sayısı) \times (giriş\ yüksekliği) \times (giriş\ genişliği) \times (giriş\ kanalları)$$

(1)

Evrişimli bir katmandan geçtikten sonra elde edilen görüntü, aktivasyon haritası olarak da adlandırılan bir özellik haritasına soyutlanmaktadır.

(giriş sayısı) × (özellik haritası yüksekliği) × (özellik haritası genişliği) × (özellik haritası kanalları)

(2)

Evrişimli katmanlar, girdiyi evriştirip sonucunu bir sonraki katmana göndermektedir.

Evrişimli ağların katmanları, geleneksel evrişimli katmanların yanı sıra yerel veya küresel havuzlama katmanlarını içerebilmektedir. Bu katmanlar, bir katmanda bulunan nöronların sınıflarının çıktı değerlerini bir sonraki katmandan bir nörona birleştirerek verinin boyutlarını azaltmaktadır.

Tamamen bağlı katmanlar, bir katmandaki her nöronun başka bir katmanda bulunan her nörona bağlanmasını sağlamaktadır. Düzleştirilmiş matris, oluşan görüntüleri sınıflandırabilmek amacıyla tamamen bağlantılı olan bir katmandan geçmektedir.

Bir sinir ağında bulunan nöronlardan her biri, önceki katmanda bulunan alıcı nörondan alınan girdi değerlerine belli bir işlev uygulayıp bir çıktı değeri hesaplamaktadır. Girdi değerlerine uygulanmış bu işlev, bir ağırlık vektörü ve bir yanlılık tarafından belirlenmektedir. Elde edilen öğrenme, bu önyargıları ve ağırlıkları yinelemeli olarak ayarlamayla gerçekleşmektedir.

3.7. Tekrarlayan Sinir Ağları

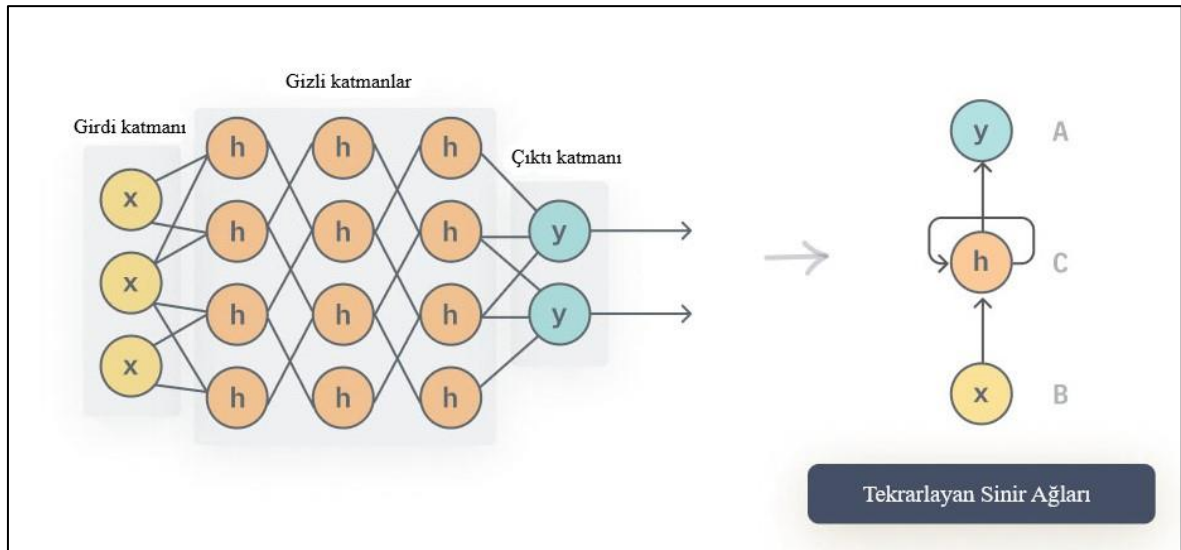
Tekrarlayan sinir ağları (Recurrent Neural Networks – RNN), düğümler arasındaki bağlantıların bir döngü oluşturduğu ve bazı düğümlerden gelen çıktılarının aynı düğümlere yapılan sonraki girdileri etkilemesine izin veren bir yapay sinir ağı türüdür [45]. Sıralı veya zaman serisi verilerini kullanır. Bu şekilde Tekrarlayan Sinir Ağı zamansal dinamik davranış sergiler. İleri beslemeli sinir ağlarından türetilen Tekrarlayan Sinir Ağları, değişken uzunluklu girdi dizilerini işlemek için bellek kullanabilir [46 ,47].

"Tekrarlayan Sinir Ağı" terimi, sonsuz dürtü tepkisine sahip ağ sınıfını ifade etmek için kullanılırken, "evrişimsel sinir ağı", sonlu dürtü tepkisine sahip ağ sınıfını ifade etmektedir. Her iki ağ sınıfı da zamansal dinamik davranış sergilemektedir [48].

Tekrarlayan Sinir Ağları, öğrenmek için eğitim veri setleri kullanılır. Geleneksel derin sinir ağlarında girdiler ve çıktılar birbirinden bağımsız olduğu varsayılırken tekrarlayan sinir ağlarının çıktısı, dizideki önceki unsurlara bağlıdır. Ağın her katmanında aynı ağırlık parametresini paylaşır [48].

Sonlu dürtü tepki veren tekrarlayan ağlar ve sonsuz dürtü tepki veren tekrarlayan ağlar ek depolanmış durumlara sahip olabilmektedir. Bu depolama, sinir ağı tarafından doğrudan kontrol altında olabilir. Ayrıca zaman gecikmeleri içeriyorsa veya geri besleme döngüleri varsa, bu depolama başka bir ağ veya grafikte de değiştirilebilmektedir. Bu tür kontrollü durumlar, kapılı durum (gate state) veya kapılı bellek (gate memory) olarak adlandırılır ve uzun kısa süreli bellek ağlarının LSTM ve kapılı tekrarlayan birimlerin parçası olmaktadır. Ayrıca Geri Bildirim Sinir Ağı (Feedback Neural Network – FNN) da denir [48].

Şekil 3.6’da Tekrarlayan Sinir Ağı Mimarisi verilmiştir.



Şekil 3.6. Tekrarlayan Sinir Ağı mimarisi

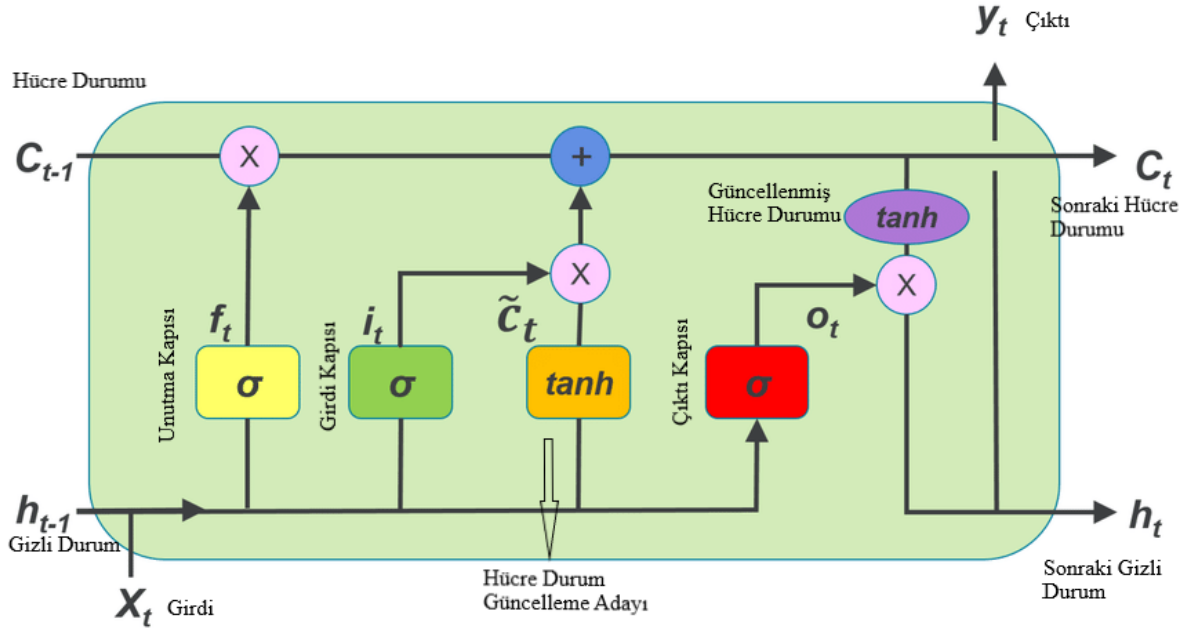
Tekrarlayan Sinir Ağları, herhangi bir uzunluktaki girdiyi işleyebilme, girdi boyutuna bağlı artmayan model boyutu, hesaplama yaparken geçmiş bilgileri dikkate alması ve ağırlığının zaman içinde paylaşılması gibi avantajları bulunmaktadır. Bunların yanında hesaplama süresinin uzun sürmesi, uzan zaman öncesine ait bilgilere erişme zorluğu, şu anki durum için gelecekteki hiçbir girdinin dikkate alınmaması gibi dezavantajları mevcuttur [49].

Bu sinir ağı modeli, Makine çevirisi, robot kontrolü, zaman-seri tahmini, konuşma tanıma, beyin – bilgisayar arayüzü, insan hareket tanıma, el yazısı tanıma, ritim öğrenme, metinden video modelleme gibi amaçlarda kullanılmaktadır.

3.8. Uzun Kısa Süreli Bellek

LSTM, derin öğrenme alanında kullanılan bir yapay sinir ağıdır [50]. İleri beslemeli sinir ağlarının aksine, Uzun Kısa Süreli Bellek Ağları geri besleme bağlantılarına sahiptir. Bu şekilde yapay sinir ağı görüntüler gibi yalnızca tek veri noktalarını işlemekle kalmayıp video veya konuşma gibi tüm veri dizilerini işleyebilir. Bu özellik de Uzun Kısa Süreli Bellek Ağlarını verileri işleyip tahmin etmek için uygun hale getirmektedir [50].

Şekil 3.7’de Uzun Kısa Süreli Bellek Ağlarının yapısı verilmiştir



Şekil 3.7. Uzun Kısa süreli Bellek mimarisi

Uzun Kısa Süreli Bellek Ağları, El yazısı tanıma, konuşma tanıma, makine çevirisi, robot kontrolü, video oyunları ve sağlık hizmetleri alanlarında kullanılmaktadır.

Uzun Kısa Süreli Bellek Ağları, bir zaman serisindeki olaylar arasında belirsiz süreli gecikmeler olabilme ihtimaline karşın, zaman serisi verilerine dayalı olarak sınıflandırma, işleme ve tahmin etmeye uygundur. Geleneksel Tekrarlayan sinir ağları eğitirken karşılaşılabilen yok olan gradyan sorununun [51] üstesinden gelmek için geliştirilmiştir.

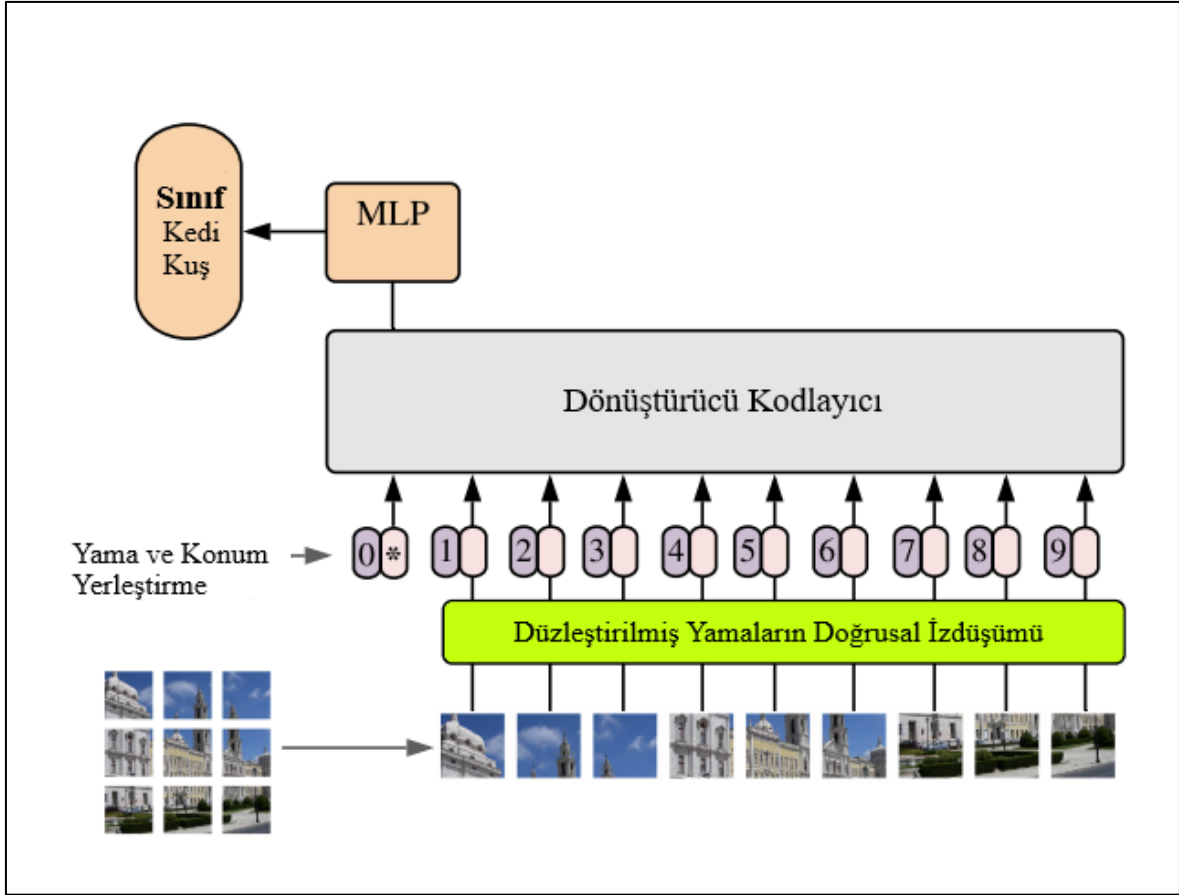
3.9. Görsel Dönüştürücüler

Bir ViT görüntüyü hatırlama gibi görsel işleme işlemlerini yapmayı hedef alan bir dönüştürücüdür. Dönüştürücüler dikkat (attention) olarak adlandırılan girdi belirteçlerini ikililerini arasındaki ilişkileri ölçer. Görüntünün çeşitli küçük bölümlerindeki pikseller arasındaki büyük ölçüde azaltılmış bir maliyetle hesaplamaktadır. Hesaplama yapılırken bölümler bir sıraya yerleştirilir. Bu yerleştirmeler öğrenilebilir vektörlerdir. Her bölüm doğrusal bir sıra halinde düzenlenir ve gömme matrisi ile çarpılır. Sonuç da pozisyon gömme ile transformatöre beslenir [52].

Görüntü sınıflandırma mimarisi olarak görüntü dönüştürücüleri en yaygın olanıdır ve çeşitli girdi belirteçlerini dönüştürmek için yalnızca dönüştürücü kodlayıcı kullanır.

Görsel Dönüştürücüler, resim sınıflandırma, obje tespiti, video derin sahtecilik tespiti, anormallik tespiti, resim sentezi, kümeleme sentezi ve otonum sürüş alanlarında kullanılmaktadır.

Şekil 3.8’de görsel dönüştürücülerin çalışma mimarisi verilmiştir.



Şekil 3.8. Görsel Dönüştürücü mimarisi

Görsel Dönüştürücü giriş görüntüsünü görüntü parçalarına dönüştürür ve parçaların hangi sırayla geldiğini bilmek amacıyla bir konum numarası verir. Sonraki adımda Görüntü parçaları gömülü verilere dönüşür. Ağ için bir normalizasyon işlemi yapılır. Ardından parçalanmış görüntü dikkat katmanına gönderilir ve işlenir. Son olarak MLP katmanına ulaşır. Bu katmanda bir girdinin öğrenilen özelliklerini bir sınıf çıktısına dönüştürülür [53].


Evrişimsel Sinir Ağı ve Görsel Dönüştürücüler karşılaştırıldığında aralarında mimari farklılıklarından kaynaklanan farklar bulunmaktadır. Bu farklar;

- Evrişimsel Sinir Ağları piksel dizilerini kullanırken, Görsel Dönüştürücüler görüntüyü görsel bölümlere ayırır.
- Görsel Dönüştürücülerin performansı kararlara bağlı olması nedeniyle Evrişimsel Sinir Ağları'nın optimizasyonu daha kolaydır.
- Görsel Dönüştürücüler Evrişimsel Sinir Ağları nazaran daha büyük veri setlerinde doğru sonuçlar vermektedir.

3.10. EfficientNet

EfficientNet, bir grup CNN modelidir. Bir bileşik katsayı kullanarak tüm derinlik, genişlik ve çözünürlük boyutlarını tek tip olarak ölçekleyebilen bir CNN mimarisi ve ölçekleme yöntemidir [54]. Bu faktörleri isteğe bağlı olarak ölçeklendiren geleneksel uygulamaların tersine, EfficientNet, ölçekleme yöntemi, ağ genişliğini, derinliğini ve çözünürlüğü bir dizi sabit ölçeklendirme katsayısıyla eşit olarak ölçeklemektedir [55]. İncelikleri sayesinde önceki modellerin çoğundan daha kazançlı bir modeldir. EfficientNet, B0 ile başlayıp B7'ye kadar olan 8 ayrı modelden oluşmaktadır. Modelin sayısı büyüdükçe hesaplanan parametre sayısı ve doğruluk oranı artmaktadır [55].

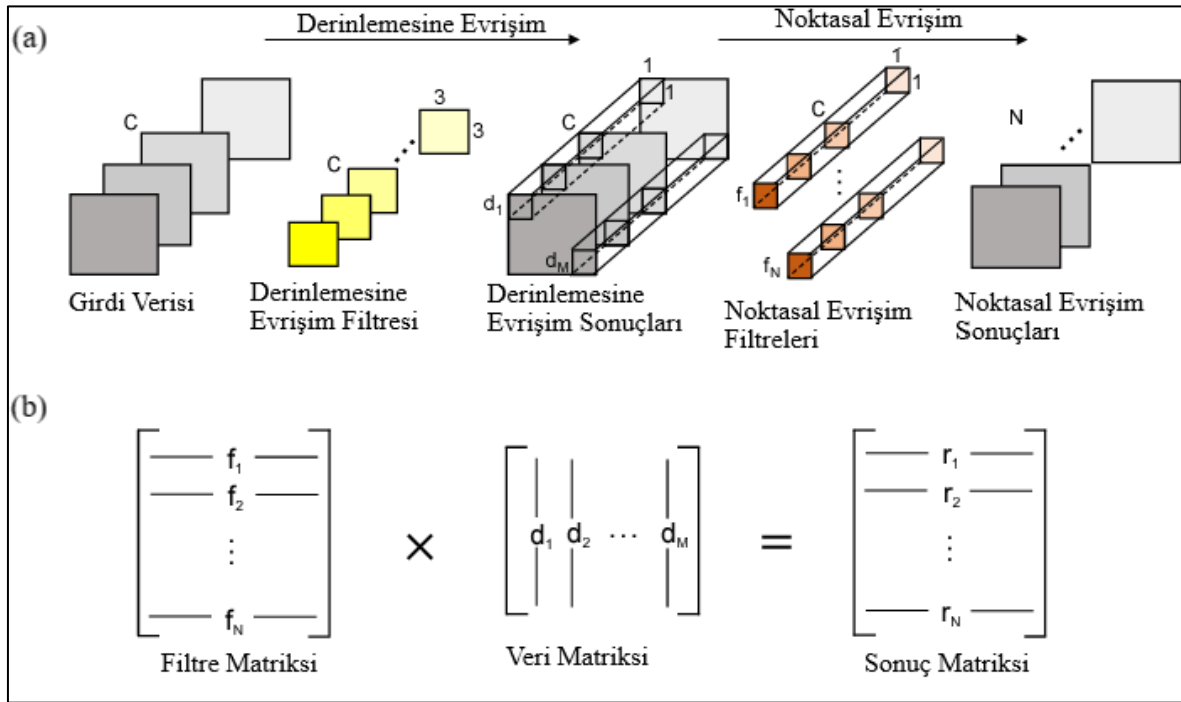
Şekil 3.9'da EfficientNet Modellerinin ImageNet veri setinde parametre/performans grafiği verilmiştir.



Şekil 3.9. EfficientNet modellerinin ImageNet veri setinde gösterdiği performans / parametre sayısı grafiği

Bu kısımda çalışmada neden EfficientNet model serisi seçildiği sebeplerle anlatılmıştır. Derinlemesine Evrişim ve Noktasal Evrişim özelliği ile hesaplama işleminin maliyetini minimum doğruluk kaybıyla ciddi ölçüde azaltmak için orijinal evrişimi iki parçaya böler.

Şekil 3.10'da EfficientNet Depthwise ve Pointwise Evrişim modeli gösterilmiştir.



Şekil 3.10. EfficientNet Modeli Deepwise ve Pointwise Evrişim Şeması

Ters çevrilmiş Res: ResNet (Residual Network) blokları, kanalların sıkıştırıldığı katmandan sonra kanalları genişleten başka bir katmandan oluşmaktadır. Böylece ResNet'te bulunan atlama bağlantıları ile zengin kanal katmanlarını bağlanmış olur. Ancak MBConv'da, bloklar önce kanalları genişleten, sonra bunları sıkıştıran bir katmandan oluşmaktadır. Bu şekilde daha az kanal sayısına sahip katmanlar atlanarak bağlanmaktadır.

Lineer darboğaz: ReLU'dan gelecek bilgi kaybını önlemek ya da en aza indirmek için her bloğun son katmandaki lineer aktivasyonu kullanmaktadır [54]. Ayrıca CIFAR-100 (%91,7), Flowers (%98,8) gibi veri setlerinde, büyüklük sırasına göre daha az parametreyle, daha iyi aktarım yapabilmekte ve en iyi doğruluğu elde edebilmektedir [55].

3.11. ImageNet

ImageNet, görsel olarak nesne tanıma arařtırmalarında kullanılan büyük bir görsel veri setidir. Bu veri seti 14 milyondan fazla görüntüye sahiptir [56, 57]. Hangi nesnelerin eklendiđi açıklamalara eklenmiřtir. ImageNet, birkaç yüz görüntüden oluřan "balon" veya "çilek" gibi tipik bir kategoriyle [57] 20.000'den fazla kategori içerir [58]. Üçüncü taraf resim URL'lerinin ek açıklamalarının veri tabanına doğrudan ImageNet'in sayfasından ücretsiz olarak erişilebilir. Resim 3.1'de ImageNet veri setinden bir kesit verilmiřtir.

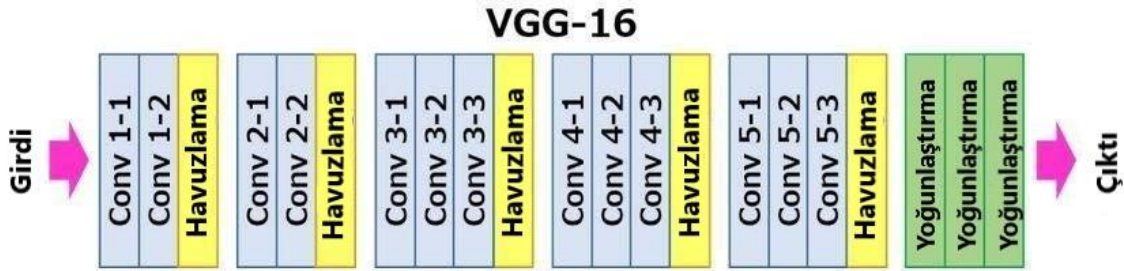


Resim 3.1. ImageNet veri seti

3.12. VGGNet

Görsel Geometri Grubu (Visual Geometry Group), çok katmanlı Derin bir CNN mimarisidir. Derin kavramı VGG-16 ile VGG-19 olarak 16 ve 19 evrişimsel katmanı ifade etmektedir [59].

Şekil 3.11’de 16 katmanlı Görsel Geometri Grubu Nöral Ağının mimarisi verilmiştir.



Şekil 3.11. 16 katmanlı Görsel Geometri Grubu Nöral Ağı mimarisi

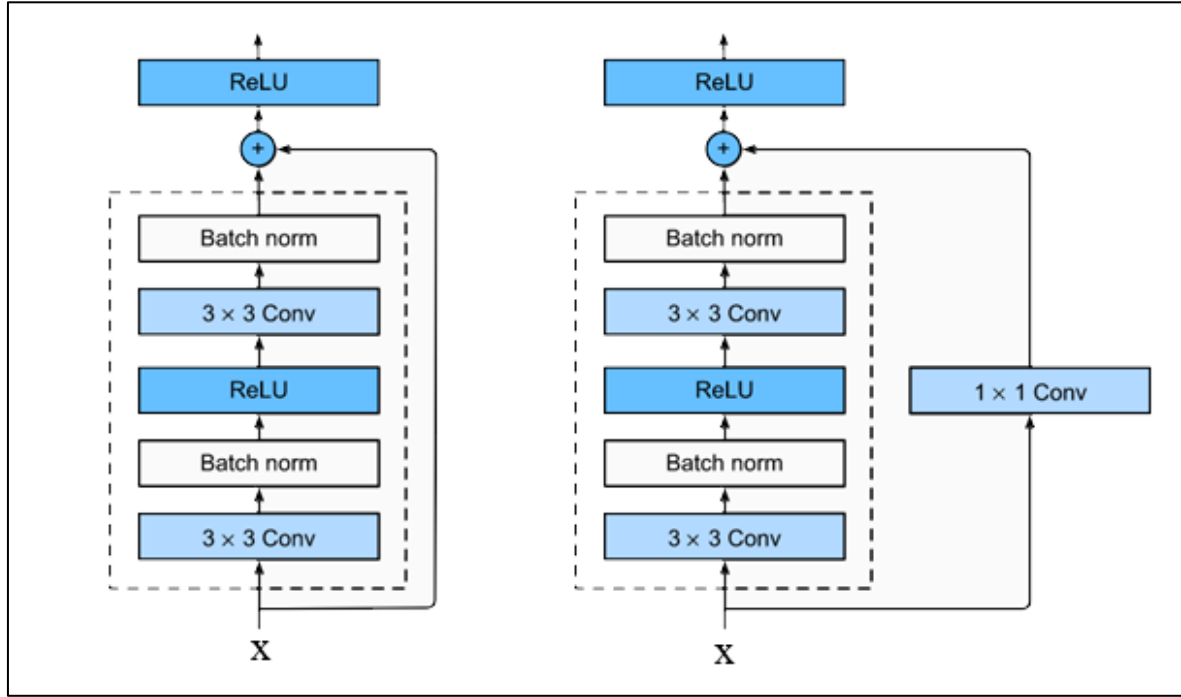
16 katmanlı Görsel Geometri Grubu Ağı oldukça pahalı bir nöral ağıdır. Yaklaşık olarak 138 milyon parametre içermektedir. Günümüzdeki standartlara göre bu ağ oldukça büyük bir ağıdır. Büyük bir ağ olduğu için eğitilmesi oldukça bir zaman almaktadır.

Görsel Geometri Grubu Ağı Büyük bir ağ olmasına rağmen mimarisi diğer mimarilere göre daha basittir. Bu Ağın tasarımında, kullanılabilir filtre sayısı her evrişimsel katmanda 2 katına çıkmaya dayanmaktadır. Kullanımının kolay olması dolayısıyla öğrenme amacıyla kullanılabilir [59].

3.13. ResNet

ResNet, Kaiming He, Xiangyu Zhang, Shaoqing Ren ve Jian Sun tarafından 2015 yılında ağların eğitimini kolaylaştırmak için “Deep Residual Learning for Image Recognition” adlı makalede tanıtılmış bir sinir ağı türüdür. Artık Ağların derinliği 150 katmana kadar ulaşabilmesine rağmen düşük bir karmaşıklığa sahiptir. ImageNet veri setinde VGG ağlarından daha yüksek bir performans göstermiştir. Artık Ağların diğer ağlardan farklı olarak kısa yol atlamalarına sahiptir. Bu şekilde duruma göre katman atlayarak çalışabilmektedir [58].

Şekil 3.12’de bir Artık Ağ mimarisi verilmiştir.



Şekil 3.12. Artık Ağ (ResNet) mimarisi

3.14. Derin Sahtecilik Veri Setinin Seçilmesi ve Kullanılması

Bu tezde derin sahtecilik tespiti video üzerinden yapılacaktır. Çalışma için video veri setleri incelenmiştir.

Çizelge 3.3’te derin sahtecilik tespitinde sık kullanılan veri setlerinin içerikleri gösterilmiştir.

Çizelge 3.3. Derin sahtecilik tespit yöntemlerinde sıklıkla kullanılan veri setlerinin detay tablosu

Veri seti	Çözünürlük	Sahte veri		Gerçek veri	
		Video	Frame	Video	Frame
FaceForensics++(FFDF)	480+	1 000	509 900	1 000	509 900
DFDC	480+	104 500	10M+	23 654	10M+
DFDC preview	480+	4 113	1 783 300	1 131	488 400
UADFV	-	49	17 300	49	17 300
Celeb-DF	256	5 639	2 116 800	590	225 400
DeepFake-TIMITHQ	128	320	34 000	320	34 000
Google/Jigsaw DeepFake (DFD)	480+	3 068	2 242 700	363	315 400
DeepFake-TIMITLQ (DF-TIMIT)	64	320	34 000	320	34 000

Bu çalışmada FaceForensic++ (FF++) veri seti kullanılmıştır. Veri setinden rastgele videolar seçilerek hatalı ya da eksik olanlar ayrıştırılmıştır. Çalışmanın veri seti oluşturulurken FF++ veri setindeki derin sahtecilik manipülasyonlarının yapıldığı Face2Face, Deepfakes, FaceSwap, NeuralTextures yöntemleri bulunmaktadır. Bu çalışma için FaceSwap (Yüz Değiştirme) yöntemi ile oluşturulmuş derin sahtecilik videoları seçilmiştir. Çalışma için veri setinden rastgele 509 video seçilmiştir. Seçilen videolardan 400 video eğitim amaçlı, 109 video da test amaçlı kullanılmıştır. Veri setinden alınan videoların kalitesi 480p çözünürlükleri de 640x480 pikseldir. Seçilmiş her bir videodan rastgele bir kare seçilerek çalışmada kullanılacak resim veri setleri oluşturulmuştur. Seçilmiş resimler performans kaybına sebep olmadan eğitim ve test aşamalarını hızlandırmak için 256x256 piksel boyutuna indirgenmiştir.

Resim 3.2’de FaceForensic++ veri setinden örnekler verilmiştir.



Resim 3.2. FaceForensic++ veri setinden gerçek ve sahte örnekler

3.15. Uygulamada Kullanılan Sistem ve Hiperparametrelerin Seçilmesi

Çalışmada yüksek performanslı donanıma sahip olacak bir geliştirme ortamı seçilmiştir. Programlama dilleriyle yazılmış derin öğrenme geliştirme ortamları olarak; Anaconda, Neural Designer, FloydHub, Google Colaboratory, Microsoft Azure platformları verilebilir. Bu platformların ücretli ya da açık kaynak kodlu versiyonları bulunmaktadır. Bu çalışma için yüksek performanslı GPU ve CPU paylaşımı yapan bulut tabanlı Google Colaboratory geliştirme platformu seçilmiştir. Google Colaboratory platformunda Grafik İşlemci olarak Tesla K80 12GB GDDR5 VRAM, merkezi işlemci olarak Intel Xeon CPU @2.20GHz kullanılmaktadır.

Derin öğrenme üzerine yapılmış çalışmalarda genel olarak Theano, PyTorch, Keras, TensorFlow gibi kütüphaneler kullanılmıştır. Bu çalışmada, geliştirme ortamlarında sorunsuz çalışabilmesi, birbiri ile uyumlu çalışabilmesi ve yaygın kullanılabilmesinden dolayı Keras ve TensorFlow kütüphaneleri tercih edilmiştir. Keras kütüphanesi, ağ katman sayısı kontrolü, modeli hatasız ve en uygun hale getirebilmek için gereken işlemleri sunabilen ancak düşük seviye işlemleri destekleyemeyen bir kütüphanedir. Bu kütüphane kod değişikliği yapılmasına ihtiyaç olmadan Theano, TensorFlow gibi düşük seviye kütüphaneler ile uyumlu çalışmaktadır. Tensorflow, Google firmasının geliştirdiği, farklı projelere kolaylıkla uyum sağlayabilen, hızlı, ölçülebilir işlem performansına sahip,

kullanımı kolay metot ve fonksiyonlara sahip açık kaynak kodlu bir kütüphanedir [23].

Derin öğrenme tabanlı çalışmalarda başarı yüzdesini artırmak amacıyla daha önce farklı veriler ile eğitilmiş ağ modellerini kullanmak sıklıkla tercih edilen bir yöntemdir. Bu sebeple, bu yapılan çalışmada CNN modeli ve EfficientNet B5 modeli kullanılmıştır. İlk olarak, oluşturulan modele 256x256 piksel boyutunda girdi olacak şekilde EfficientNet B5 modeli bağlanmıştır. Üzerine girdi değerleri 32 ve 64 olacak üzere 2 katmanlı bir CNN modeli eklemiştir. Bu oluşturulan modeli sadeleştirmek için üzerine dense işlemi yapılmıştır. Modeli tek katmanlı sıralı dizi haline getirmek için düzleştirildikten sonra çıktı alınmıştır. Çalışmanın modeli oluşturulurken kullanılacak çok sayıda hiperparametre bulunmaktadır. Kullanılacak farklı hiperparametrelerin olması, modelin mimarisinde değişiklik yapmadan araştırmacılara modelin üzerinde değişiklikler yapabilme imkânı sağlamaktadır. Hiperparametreler, modelin başarısı üzerinde oldukça kritik bir öneme sahiptir. Fakat modelde kullanılacak hiperparametrelerden hangilerinin kullanıma uygun olduğu sadece deneme yanılma yoluyla tespit edilebilmektedir.

Derin öğrenme optimizasyon fonksiyonu, yapay sinir ağının ağırlık değerlerinin geri yayılım (back propagation) yöntemi ile güncellenebilmesi için ağırlık düzgün eğitilmesinden, ağırlık hata değerlerinin ortaya çıkarılmasına kadar bir sürü işlemi kapsamaktadır. Bu optimizasyon fonksiyonun temel görevi oluşabilecek hata değerlerini minimuma indirmektir. Günümüzde yapılan çalışmalarda yaygın olarak kullanılan optimizasyon fonksiyonlarına, ADAM, OLSİ, SGD, Ada Delta, ve AdaGrad fonksiyonları örnek verilebilir. Bu çalışmada, modele uygunluk ve yaygınlık açısından ADAM optimizasyon fonksiyonunun kullanılması tercih edilmiştir [60].

Derin öğrenme tabanlı çalışmalarda tahmin edilen sonuçla elde edilen sonuç arasındaki farkı gösteren, modelin ne kadar doğru çalıştığını ortaya koyan fonksiyon, Kayıp (Loss) fonksiyonudur [60]. Genel olarak kullanılan kayıp fonksiyonları; Ortalama Kare Hatası (Mean Squared Error), Çapraz Entropi (Cross Entropy) veya Kategorik Menteşe (Categorical Hinge) fonksiyonlarıdır. Bu çalışmada kullanım açısından yaygın olan Çapraz Entropi(binary) kullanılmıştır.

Veri setinde yer alan video ve resimlerin ağ modelinden bir defa tam olarak geçmesi işlemi epoch sayısı ile ifade edilmektedir. Oluşturulan Ağ modellerinin yeterli seviyeye

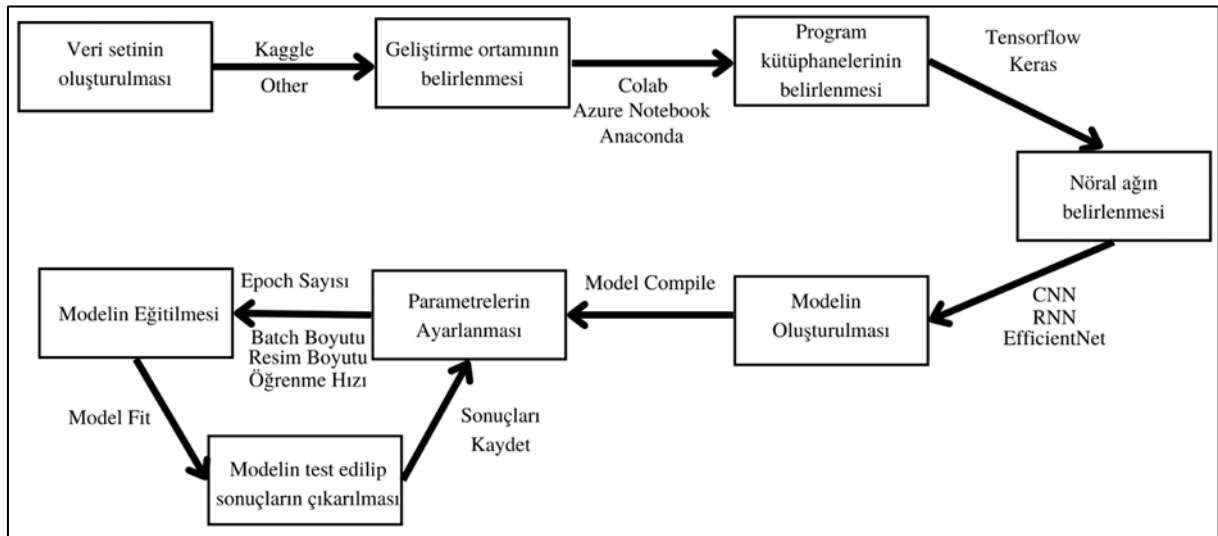
ulařabilecek kadar eđitilmesi sadece epoch sayısının arttırılması ile m¼mk¼n olmaktadır [60]. Bu alıřmada modelin y¼ksek eđitim performansına sahip olması iin farklı epoch deđerleri test edilmiřtir. Modelin en y¼ksek ¼đrenim performansı ve en d¼ř¼k kayıp performansı 19 epoch deđerini ile alınmıřtır.

Bir ađ modeli eđitilirken her seferinde ađa g¼nderilen paket veri sayısına batch boyutu (batch size) denilmektedir. Yapılan alıřmada batch boyutu, RAM kullanımını ve hız aısından 16 olarak seilmiřtir. Daha y¼ksek batch boyutu iin daha y¼ksek hafızaya sahip RAM'e ihtiya duyulmaktadır.

4. UYGULAMA

Bu bölümde tezde yapılan çalışmanın aşamaları anlatılmıştır. Çalışmanın süreç şeması, yapılan çalışmada kullanılan model gösterilmiştir. Süreç şemasının adımları açıklanarak anlatılmıştır.

Çalışmada uygulanan süreç şeması, genel hatları ile Şekil 4.1’de verilmiştir.



Şekil 4.1. Çalışmada kullanılan süreç akış diyagramı

Veri seti oluşturulurken, FF++ veri setinin Yüz değiştirme yöntemi ile oluşturulmuş video ile manipüle edilmemiş videolardan belirli kesitler alınıp bir veri seti oluşturulmuştur. Veri seti kontrol edilip bozulmuş videolar, videonun başından sonuna kadar derin sahtecilik bulunmayan videolar ve hatalı sınıflandırılmış videolar oluşturulan veri setinden kaldırılmıştır. Temizleme işlemlerinden sonra veri seti, 2 parçaya bölünüp ilk veri seti eğitim, ikinci veri seti test amaçlı olarak ayrılmıştır. Oluşturulan modelin başarılı öğrenme yapabilmesi için eğitim veri seti 400 veriden test veri seti 109 veriden oluşturulmuştur. Tek sınıflı aşırı öğrenmeden kaçınmak için eğitim veri seti 200 gerçek ve 200 sahte veriden oluşturulmuştur.

Geliştirme ortamını belirlerken modelin yüksek performanslı ve hızlı çalışabilmesi için kullanılan donanımın da bir o kadar da güçlü olmalıdır. Bu ihtiyacı sağlayabilmek için çalışma ortamı olarak Google şirketinin bulut ortamında sunduğu Google Colaboratory

ortamı seçilmiştir. Google Colaboratory ortamının ücretsiz versiyonunda GPU olarak Tesla K80 12GB GDDR5 VRAM, CPU olarak Intel Xeon CPU @2.20GHz kullanılmaktadır.

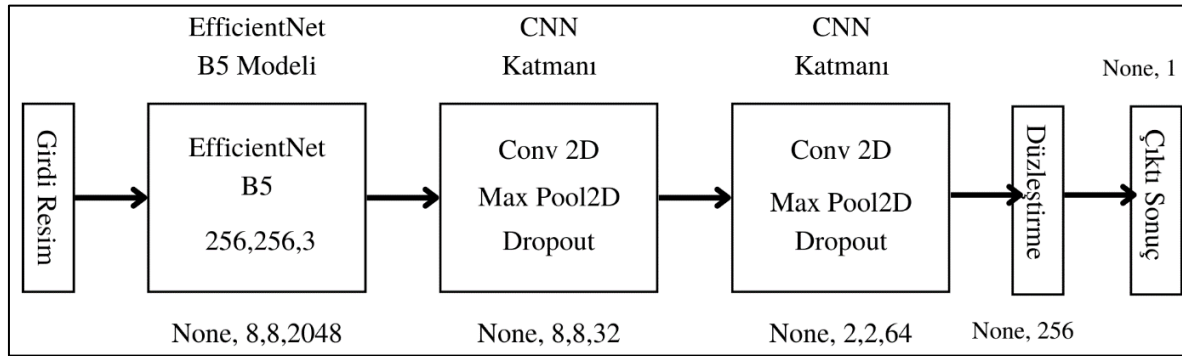
Program kütüphanelerin belirlenmesi uygulamaya yüklenmiştir edilmiştir. Kullanılan yardımcı kütüphaneler: keras_applications, ve tensorflow, pandas, numpy, imageio, cv2, os kütüphaneleridir. Keras applications kütüphanesi önceden eğitilmiş ağırlıkları bulunan kullanıma açılmış derin öğrenme modelleridir. Bu modellerin içinde EfficientNet serisi, Xception, VGG16, ResNet50 gibi modeller bulunmaktadır. EfficientNet B5 modelini yükleyip önceden eğitilmiş halini kullanabilmek için bu kütüphane projeye eklenmiştir. Tensorflow, modelin oluşturulmasında kullanılan kodlar için eklenmiştir. Pandas elde edilen verilerin analizini yapabilmek için projeye eklenmiştir, numpy kütüphanesi matematik işlemlerini gerçekleştirmek için kullanılmaktadır. Imageio ve cv2 kütüphaneleri videoların karelerinden resimleri çıkartmak ve kaydetmek için kütüphaneye eklenmiştir. Google Drive ortamından veri setini .zip olarak indirip ortama çıkartma işlemleri ve dosya yolu uzantılarını kullanmak için os kütüphanesi çalışmaya eklenmiştir.

Bir sonraki süreçte tez çalışmasında kullanılacak yapay sinir ağı modeli seçilmiştir. “Yöntem ve Araçlar” bölümünde anlatılan sinir ağlarından özellikleri ve kullanılışı açısından Evrişimsel Sinir Ağları tercih edilmiştir. Evrişimsel Sinir Ağına ek olarak bir model seçilmiştir. Model olarak da parametre sayısı ile performans açısından uygun olan, EfficientNet B5 modeli seçilmiştir.

Eklenen kütüphaneler, videolardan rastgele karelerin çıkartılması, gerekli matematiksel hesaplamaların yapılması, modelin oluşturulup eğitilmesi gibi işlemleri yapmaktadır. zipFile kütüphanesi ile Google Drive’a yüklenmiş olan veri setini alıp .zip uzantılı dosyasından çıkartılmıştır. Veri setini Google Drive ortamından almak sistemin hazırlanmasını hızlandırmıştır. Çıkarılan klasörlere eğitim ve test için değişken ataması yapılmıştır. Çıkarılan videolardan rastgele bir kareyi resim olarak çıkartmak için bir metot yazılıp eğitim ve test veri setleri için çalıştırılmıştır. Metodun çalışması sonucunda resim veri seti elde edilmiştir. Çıkarılan veri seti üzerinden ImageDataGenerator sınıfı kullanılarak videolardan çıkarılan resimler 256x256 piksel boyutuna indirgenmiştir. İndirgeme işlemi karışık özelliği aktif, sınıf modu “binary” ve 16 büyüklüğünde batch size olarak ayarlanmıştır. Veri seti işlemlerinden sonra bir Evrişimsel Sinir Ağı oluşturularak EfficientNet B5 modeli ile 2 katmanlı Evrişimsel Sinir Ağı birleştirilerek yeni bir model oluşturulmuştur. Oluşturulan

model derlenip herhangi bir hata olup olmadığı tespit edilmiştir. Hatasız bir model oluşturulduktan sonra model, eğitim veri seti ile eğitilmiştir. Model eğitilirken performans testleri yapmak için, batch_size, epoch sayısı, optimizer, kayıp fonksiyonu gibi hiperparametrelerde değişiklikler yapıp model farklı hiperparametrelerle derlenip eğitilmiştir.

Çalışmada oluşturulan model şeması Şekil 4.2’de verilmiştir.



Şekil 4.2. Çalışmada kullanılan Derin Sahtecilik modeli

Oluşturulan modelde ilk olarak 256x256 piksel ölçülerinde 3 renkli girişi EfficientNet B5 modeli olan bağlanmıştır. Üstüne bir evrişimsel katman oluşturulup keras kütüphanesinden conv2d metodu ile eklenmiştir. Conv2d, bir çıktı tensörü üretmek için katman girdisiyle evrişen bir evrişim çekirdeği oluşturmaktadır. İlk olarak efficientnet modelini bağlandığı için input shape verilmesine gerek olmamıştır., havuzlama ile her bir giriş kanalı için giriş penceresinden maksimum değerler alınarak yükseklik ve 4 genişlik boyunca giriş altörneklenir. Oluşturulan pencere her bir boyut boyunca adımlarla kaydırılır. Dropout katmanı ile eğitim süresi boyunca her adımda bir hız frekansı ile giriş birimleri rastgele 0 olarak ayarlanır ve böylece fazla öğrenme önlenmiş olur. 0 ayarlanmayan girişler ise tüm girişlerin toplamı değişmeyecek şekilde 1 / (1-oran) oranında büyütülür. İkinci evrişimsel katman da eklenerek havuzlama ve dropout işlemlerinden sonra düzleştirme katmanı ile tek boyuta indirilip çıktı elde edilmiştir. Bu işlemler sonucunda 29 187 928 parametreye sahip bir model oluşturulmuştur.

Yüksek performans gösteren modelde kullanılan hiperparametreler Çizelge 4.1’de verilmiştir.

Çizelge 4.1. Çalışmada kullanılan hiperparametre değerleri

Hiperparametreler	Değer
Öğrenme Oranı	0,01
Optimizer	Adam
Kayıp Fonksiyonu	Binary_crossentropy
Batch Boyutu	16
Epoch Sayısı	19
Toplam Parametre Sayısı	29 187 928

Yapılan çalışma sonuçları karşılaştırırken değerlendirme ölçütleri olarak performans ölçütleri bölümünde verilmiş doğruluk oranı, duyarlılık, kesinlik ve F1-score değerleri kullanılmıştır. Bu elde edilen değerlere göre yapılan çalışmaların sonuçları tartışılmıştır.

Veri seti model ve araç gereçler hazırlandıktan sonra ön temizlik yapılarak uygulama çalıştırılmıştır. Doğruluk oranı eğitim verisi ile modelin eğitilmesinden sonra test verilerinin ne sıklıkta doğru tahmin edildiğinin oranını göstermektedir. Fakat doğruluk oranıyla modelin başarısını değerlendirmek yetersiz olacağı için diğer ölçütler de hesaplanmıştır. Gerçek ve sahte videolar arasında eşit bir veri dağılımı olmadığı için F1-skor değeri de göz önüne alınmıştır. Değerlendirme ölçütleri hesaplanırken dört farklı sonuca göre işlemler yapılmıştır. Bunlar; doğru pozitif (True Positive - RP), doğru negatif (True Negative - RN), yanlış pozitif (False Positive - FP) ve yanlış negatif (False Negative - FN) sonuçlarıdır. TP, tahminde doğru bulunduğu pozitifleri, TN, doğru bulunduğu negatifleri, FP, yanlış tahmin ettiği pozitifleri ve FN de yanlış tahmin ettiği negatifleri göstermektedir. Değerlendirme ölçütlerinin hesaplanmasında aşağıdaki Doğruluk Oranı, Duyarlılık, Kesinlik ve F1-Skor formülleri kullanılmıştır:

$$Doğruluk\ Oranı = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

$$Duyarlılık = \frac{TP}{TP + FN} \quad (4)$$

$$Kesinlik = \frac{TP}{TP + FP} \quad (5)$$

$$F1 - Score = 2 * \frac{Kesinlik * Duyarlilik}{Kesinlik + Duyarlilik} \quad (6)$$

Yapılan çalışmanın sonucunda elde edilen performans değerleri Çizelge 4.2’de verilmiştir.

Çizelge 4.2. Çalışmada önerilen modelin performans sonuçları

Epoch Sayısı	Batch Boyutu	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1 Skoru (%)	Parametre Sayısı
30	16	%88,99	%95,59	%87,84	%91,55	29 187 928
25	16	%89,91	%97,06	%88,00	%92,31	29 187 928
20	16	%82,57	%91,18	%82,67	%86,71	29 187 928
19	16	%91,74	%98,52	%89,33	%93,70	29 187 928
15	16	%78,90	%88,24	%80,00	%83,92	29 187 928

Yapılan çalışmalarda en yüksek performans başarısına sahip çalışmanın modelinin eğitim sonucu %5 kayıp ve %95 öğrenme doğruluğu ile sonuçlanmıştır. Bu modelin eğitiminden sonra yapılan test sonucunda, Derin Sahtecilik tespiti %91,74 doğruluk ve %93,70 F1 skor performansı ile yapılmıştır. Bu yapılan çalışma iyi bir performans göstermiştir. Çalışma bu performans sonuçları ile derin sahtecilik tespitinde kullanılabilecek bir yöntem olabilir. Yapılan çalışmanın performans değerleri, yapılan diğer akademik çalışmalar ile karşılaştırılmıştır. Sonuçlar Çizelge 4.3’te verilmiştir. Yapılan değerlendirme doğruluk yüzdeleri üzerinden yapılmıştır.

Çizelge 4.3. En yüksek performansa sahip çalışmanın diğer literatür çalışmalarıyla karşılaştırma tablosu

Çalışma Adı	Algoritma	Veri seti	Doğruluk
Video Multimedia Streamer (Guera D.) [23]	Video multimedya akış tanımlayıcıları üzerine ikili sınıflandırma	Medya Adli Mücadele (MFC)	%91,70
STIL (Spatiotemporal Inconsistency Learning) (Zhihao G. vd.) [24]	Uzayzamansal Tutarsızlık Öğrenme (STIL) yöntemi	DFDC	%89,80
Convolutional Vision Transformer (Deressa W. vd.) [22]	CNN + ViT	DFDC	%91,50
Ensemble of CNN's (Bonettini N. vd.) [25]	Siemese öğrenmesi yöntemi + EfficientNet B4	ImageNet	%83,00
Learning to Detect Manipulated Facial Images (Rossler A.) [61]	XceptionNet	FaceForensic++	%90,29
Tez Çalışması	EfficientNet B5 üzerine 2 Katmanlı CNN yaklaşımı	FaceForensic++	%91,74

Yapılan çalışma diğer literatür çalışmalarıyla karşılaştırıldığında ileride kullanılabilir bir performans göstermiştir. İleride yapılacak çalışmalarda kullanılan modelin Evrişimsel Sinir Ağı modelinde kullanılan katman sayısı artırılabilir. Ayarlanan hiperparametrelerdeki epoch sayısı ve batch boyutu değerleri değiştirilebilir. Evrişimsel Sinir Ağı yerine farklı sinir ağları ya da farklı Efficient Net bağlanarak farklı bir çalışma yapılabilir. Veri seti değiştirilip iyileştirilebilir.

5. SONUÇ VE ÖNERİLER

Derin sahtecilik, yüz manipülasyonu veya yüz değiştirme gibi yöntemler kullanılarak oluşturulan gerçek olmayan bir videonun, sesin, resmin, yazının gerçekmiş gibi görünen başka bir video, resim, ses haline getirilerek gösterilmesidir. Bu sahtecilik yöntemleri her geçen gün askeri, politika, eğlence gibi farklı alanlarda yaygınlaşmaktadır. Derin sahtecilik yöntemleri dünya genelinde yapılan çalışmalar ile gelişmekte ve anlaşılması zor hale gelmektedir. Toplumlar için derin sahtecilik önemli tehlikeler içermektedir. Örneğin, bir yetkilinin yapmadığı bir konuşmayı yapılmış gibi gösterilerek yanıltıcı videolar oluşturulabilir. Bu sebeple, derin sahteciliğin kötü amaçlı kullanımların önüne geçmek için derin sahteciliğin tespit edilmesi büyük önem arz etmektedir.

Bu tez çalışmasında EfficientNet B5 üzerine 2 katmanlı Evrişimsel Sinir Ağı eklenerek bir model oluşturulmuştur. Model, farklı hiperparametrelerle tekrar tekrar denenerek eğitilmiş ve derin sahtecilik tespitinde kullanılabilecek bir model elde edilmiştir. Çalışmada kullanılan veri seti oluşturulurken, FF++ veri setinde var olan yöntemlerden, yüz değiştirme yöntemi ile oluşturulmuş videolarından rastgele bir video grubu seçilmiş, bu grup videoların her birinden rastgele kareler seçilip resim veri seti oluşturulmuştur. Model, oluşturulan veri setlerinden eğitim veri seti ile eğitilip diğer veri seti üzerinde test yapılmıştır. Test sonucunda %91,74 doğruluk yüzdesi ve %93,70 F₁-skoru yüzdesi elde edilmiştir. Sonuçlar literatürdeki önceki çalışmalar ile karşılaştırılmıştır.

Asıl çalışma yapılırken batch_size, epoch sayısı, optimizer gibi hiperparametrelerde değişiklikler yapılarak farklı sonuçlar elde edilmiştir. Elde edilen sonuçlar, epoch sayısının belirli bir düzeye gelene kadar doğruluk değerinde artış oluştur. Bu çalışmada epoch hiperparametresi 19 değerinde en yüksek performansa ulaşmıştır. 19'dan sonra performans sonucu düşmüştür.

Batch size hiperparemetresinin değiştirilmesi ile elde edilen sonuçlar orantısız bir şekilde değişmiştir. Bu yüzden batch_size parametresi sadece deneme yanılma yolu ile ayarlanabilir. Ayrıca batch size hiperparametresinin daha yüksek değerlerde kullanıp modeli eğitebilmek için daha yüksek kapasiteli bir RAM'e ihtiyaç duyulmaktadır.

Veri setinin içeriğine baęlı olarak veriler ön iřlemden ve elemeden geęirilmeden kullanılabilir. Bu alıřmada veri setinin baęımsız ve sırasız olması iin veri seti ön iřlemden geęirilmiřtir.

alıřmada elde edilen sonular, derin sahtecilik tespiti yaparken kullanılan veri setinin, hiperparametrelerin deęiřtirilmesi ve elde edilen modelin doęru eęitilmesi, sonuların ne denli deęiřebileceğini gstermektedir. Ayrıca alıřmaya farklı derin ęrenme modelleri uygulayarak sonuların iyileřtirilebileceęi dřnlmektedir.

KAYNAKLAR

1. İnternet: What is a deepfake? Everything you need to know about the AI-powered fake media. URL: <https://www.businessinsider.com/guides/tech/what-is-deepfake>, Son Erişim Tarihi: 04.12.2022.
2. İnternet: Instagram Demographic Statistics. URL: <https://www.wordstream.com/blog/ws/2017/04/20/instagram-statistics>, Son Erişim Tarihi: 01.04.2023.
3. İnternet: David Sayce. URL: <https://www.dsayce.com/social-media/tweets-day>, Son Erişim Tarihi: 01.04.2023.
4. İnternet: Most popular social networks worldwide as of January 2023, ranked by number of monthly active users. URL: <https://www.statista.com/statistics/272014/global-social-networks-ranked-by-number-of-users>, Son Erişim Tarihi: 09.04.2023.
5. İnternet: Youtube User Statistics 2023. URL: <https://www.globalmediainsight.com/blog/youtube-users-statistics>, Son Erişim Tarihi: 09.04.2023.
6. İnternet: Deepfake. URL: <https://tr.wikipedia.org/wiki/Deepfake>, Son Erişim Tarihi: 09.04.2023.
7. İnternet: DeepFake Teknolojisi ve Dezenformasyonda Kullanılabilecek Zararlı Yapısı Hakkında Araştırma ile Hukuki Düzenleme Gereksinimleri. URL: <https://web.archive.org/web/20210812103354/https://www.usmed.org.tr/wp-content/uploads/2021/08/Engin-Dinc-DeepFake-Teknolojisi-ve-Dezenformasyonda-Kullanilabilecek-Zararli-Yapisi-Hakkinda-Arastirma-ile-Hukuk-Duzenleme-Gereksinimleri.pdf>, Son Erişim Tarihi: 09.04.2023.
8. İnternet: How To Protect Against Deepfakes – Statistics and Solutions. URL: <https://www.iproov.com/blog/deepfakes-statistics-solutions-biometric-protection>, Son Erişim Tarihi: 15.04.2023.
9. Karakoç, E., Zeybek, B. (2022). Görmek İnanmaya Yeter Mi? Görsel Dezenformasyonun Ayırt Edici Biçimi Olarak Siyasi Deepfake İçerikler. *Öneri Dergisi*, 17(57), 50-72.
10. İnternet: behind The startup that Deepfake David Beckham video just raised \$3M. URL: <https://techcrunch.com/2019/04/25/the-startup-behind-that-deep-fake-david-beckham-video-just-raised-3m/>, Son Erişim Tarihi: 11.12.2022.
11. İnternet: David Beckham can speak nine languages in launch Malaria Must Die Voice Petition, <https://youtu.be/QiiSAvKJIHo>, Son Erişim Tarihi: 11.12.2022.
12. Westerlund, M. (2019). The Emergence of Deepfake Technology: A Review. *Technology Innovation Management Review*, 9(11), 39-52.

13. İnternet: Deepfake presidents used in Russia-Ukraine war. URL: <https://www.bbc.com/news/technology-60780142>, Son Erişim Tarihi: 11.12.2022.
14. İnternet: What is Deepfake Technology? URL: <https://www.techslang.com/what-is-deepfake-technology>, Son Erişim Tarihi: 08.12.2022.
15. İnternet: You Won't Believe What Obama Says In This Video! URL: <https://youtu.be/cQ54GDm1eL0>, Son Erişim tarihi: 10.12.2022.
16. İnternet: Eerie deepfakes claiming to show Trump's arrest spread across Twitter. <https://nypost.com/2023/03/22/chilling-deepfakes-claiming-to-show-trumps-arrest-spread-across-twitter>, Son Erişim Tarihi: 11.12.2022.
17. Kingma, D.P., Welling, M. (2014). *Auto-encoding variational bayes*, ICLR, Banff.
18. Goodfellow, I.J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., Bengio, Y. (2014). Generative adversarial networks. *Communications of the ACM*, 63(11), 139-144.
19. Coccomini, D., Messina, N., Gennaro, C., Falchi, F. (2022). *Combining EfficientNet and Vision Transformers for Video Deepfake Detection*. International Conference on Image Analysis and Processing, Italy.
20. Radford, A., & Metz, L., Chintala, S. (2016). *Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks*. ICLR, San Juan.
21. Wang X., Shrivastava A., Gupta A. (2017). *A-Fast-RCNN: Hard Positive Generation via Adversary for Object Detection*. IEEE Conference on Computer Vision and Pattern Recognition, Honolulu.
22. Wodajo, D., & Atnafu, S. (2021). Deepfake Video Detection Using Convolutional Vision Transformer. *arXiv preprint arXiv:2102.11126*.
23. Guera, D., Baireddy, S., Bestagini, P., Tubaro, S., Delp, E. (2019). We Need No Pixels: Video Manipulation Detection Using Stream Descriptor's. *arXiv preprint arXiv:1906.08743*.
24. Gu, Z., Chen, Y., Yao, T., Ding, S., Li, J., Huang, F., Ma, L. (2021). Spatiotemporal Inconsistency Learning for DeepFake Video Detection. *arXiv:2109.01860*.
25. Bonettini, N., Cannas, E., Mandelli, S., Bondi, L., Bestagini, P., Tubaro, S. (2020). Video Face Manipulation Detection Through Ensemble of CNNs. *arXiv:2004.07676*.
26. De Lima, O., Franklin, S., Basu, S., Karwoski, B., George, A. (2020). Deepfake Detection using Spatiotemporal Convolutional Networks. *arXiv:2006.14749*.
27. Perov, I., Gao, D., Chervoniy, N., Liu, K., Marangonda, S., Umé, C., Dpfks, M., Facenheim, C.S., RP, L., Jiang, J. (2020). Deepfacelab: A simple, flexible and extensible face swapping framework. *arXiv:2005.05535*.

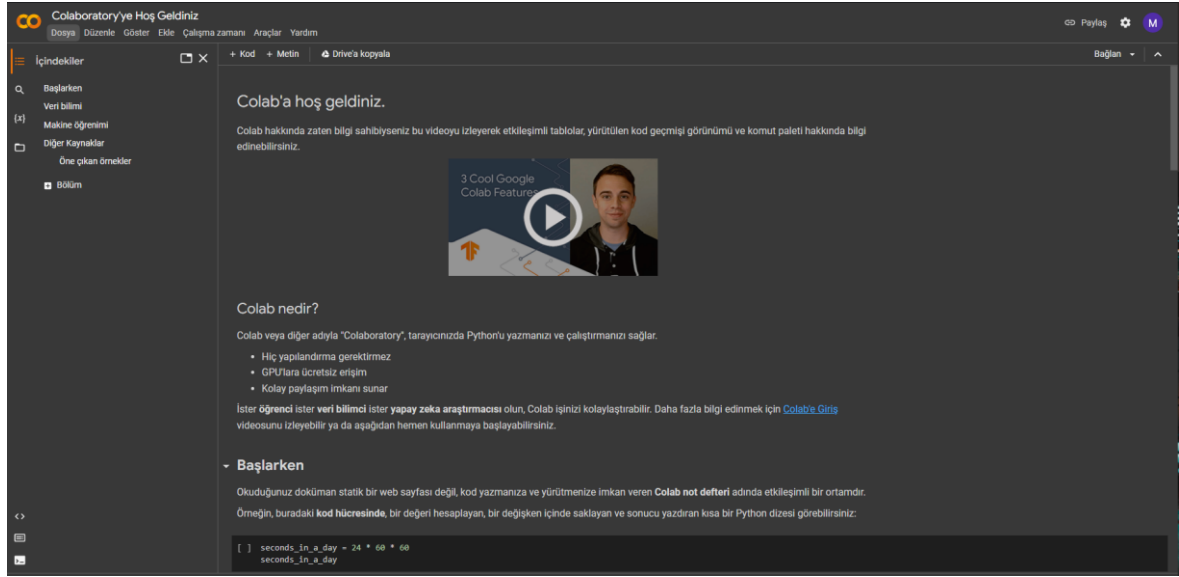
28. Coccomini, D., Zilos, G., Caldelli, R., Giuseppe, A., Falchi, F., Papadopoulos, S., Gennaro C. (2022). MINTIME: Multi-Identity Size-Invariant Video Deepfake Detection. *10.48550/arXiv.2211.10996*.
29. Jain A., Memon N., Togelius, J. (2022). *A Dataless FaceSwap Detection Approach Using Synthetic Images*. 2022 IEEE International Joint Conference on Biometrics, Abu Dhabi.
30. Juefei-Xu, F., Wang, R., Huang, Y., Guo, Q., Ma, L., Liu, Y. (2022). Countering Malicious DeepFakes: Survey, Battleground, and Horizon. *International Journal of Computer Vision*, 130, 1-57.
31. Shahzad, H.F., Rustam, F., Flores, E.S., Lu s Vidal Maz n, J., de la Torre Diez, I., Ashraf, I. (2022). A Review of Image Processing Techniques for Deepfakes. *Sensors* (22) 4556.
32. İnternet: Faceswap: Deepfakes Software for All. 2020. URL: <https://github.com/deepfakes/faceswap>, Son Eriřim Tarihi: 09.04.2023.
33. İnternet: FakeApp 2.2.0. URL: <https://www.malavida.com/en/soft/fakeapp>, Son Eriřim Tarihi: 09.04.2023.
34. İnternet: Creating Realistic Deepfakes With DeepFaceLab. URL: <https://medium.com/geekculture/realistic-deepfakes-with-deepfacelab-530e90bd29f2>, Son Eriřim Tarihi: 09.04.2023.
35. İnternet: Faceswap-GAN. URL: <https://github.com/shaoanlu/faceswap-GAN>, Son Eriřim Tarihi: 09.04.2023.
36. İnternet: FaceNet. URL: <https://github.com/davidsandberg/facenet>, Son Eriřim Tarihi: 09.04.2023.
37. İlhan İ., Karak se M. (2021). Derin Sahte Videoların Tespiti Ve Uygulamaları İin Bir Karşılařtırma alıřması. *Adıyaman  niversitesi M hendislik Bilimleri Dergisi*, 8(2021), 47-60.
38. Li, Y., Lyu, S. (2018). Exposing deepfake videos by detecting face warping artifacts. *arXiv preprint arXiv:1811.00656*.
39. Dang, H., Liu, F., Stehouwer, J., Liu, X., Jain, A. K. (2020). *On the detection of digital face manipulation*. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, Seattle.
40. Yang X., Li, Y., Lyu, S. (2019). *Exposing deep fakes using inconsistent head poses*. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Brighton.
41. Yang, Z.R., Yang, Z. (2014). *Comprehensive Biomedical Physics*. (1. Baskı). Stockholm, Sweden : Karolinska Institute.

42. Zell, A. (1994). Simulation neuronaler Netze. *Addison-Wesley*. 1(5.3).
43. Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., Bengio, Y. (2014). *Generative Adversarial Nets*. Proceedings of the International Conference on Neural Information Processing Systems NIPS, 2672–2680.
44. İnternet: GANs in computer vision - Introduction to generative learning. URL: <https://theaisummer.com/gan-computer-vision>, Son Erişim Tarihi: 04.04.2023.
45. İnternet: What are recurrent neural networks? URL: <https://www.ibm.com/topics/recurrent-neural-networks>, Son Erişim Tarihi: 09.04.2023.
46. Dupond, S. (2019). A thorough review on the current advance of neural network structures. *Annual Reviews in Control*, 14, 200–230.
47. Abiodun, I., Jantan, A., Omolara, A., Dada, V., Mohamed, A., Arshad, H. (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4(11).
48. Miljanovic, M. (2012). Comparative analysis of Recurrent and Finite Impulse Response Neural Networks in Time Series Prediction. *Indian Journal of Computer and Engineering*, 3(1).
49. İnternet: Recurrent Neural Networks cheatsheet URL: <https://stanford.edu/~shervine/teaching/cs-230/cheatsheet-recurrent-neural-networks>, Son Erişim Tarihi: 09.04.2023.
50. Schmidhuber, S. (1997). «Long Short-Term Memory,» *Neural Comput*, 9(8) 1735–1780.
51. Hochreiter, S. (1991). *Untersuchungen zu dynamischen neuronalen Netzen*. Diploma Thesis, Technical University of Munich, Institute of Computer Science, Germany.
52. İnternet: Are Transformers better than CNN's at Image Recognition?: URL: <https://towardsdatascience.com/are-transformers-better-than-cnns-at-image-recognition-ced60ccc7c8>, Son Erişim Tarihi: 30.05.2023.
53. İnternet: Vision Transformers ViTs. URL: <https://cobanov.dev/diffusion/vit/>, Son Erişim Tarihi: 09.04.2023.
54. İnternet: Kızrak, A. (2022, 25 Şubat). Ölçeklendirme ile CNN Modelinin Doğruluk ve Verimliliğini Artırma: EfficientNet, URL: <https://ayyucekizrak.medium.com/ölçeklendirme-ile-cnn-modelinin-doğruluk-ve-verimliliğini-artırma-efficientnet-cb6f2b6512de>, Son Erişim Tarihi: 04.12.2022.
55. Tan, M., & Le, Q.V. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *ArXiv*, *abs/1905.11946*.
56. İnternet: New computer vision challenge wants to teach robots to see in 3D. URL: <https://www.newscientist.com/article/2127131-new-computer-vision-challenge-wants-to-teach-robots-to-see-in-3d>, 7 Son Erişim Tarihi: 03.04.2023.

57. İnternet: Markoff, John (19 November 2012). "For Web Images, Creating New Technology to Seek and Find". The New York Times. Son Erişim Tarihi: 09.04.2023.
58. İnternet: From not working to neural networking". URL: <https://www.economist.com/special-report/2016/06/23/from-not-working-to-neural-networking>, Son Erişim Tarihi: 09.04.2023.
59. İnternet: VGG Very Deep Convolutional Networks (VGGNet) <https://viso.ai/deep-learning/vgg-very-deep-convolutional-networks>, Son Erişim Tarihi: 09.04.2023.
60. Dilber, İ., Çetin, A. (2021). Adli Bilişim İncelenme Süreçlerinde Yapay Zeka Kullanımı: VGG16 ile Görüntü Sınıflandırma, *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 9(5), 1695-1706.
61. Rössler A., Cozzolino, D., Verdoliva, L., Riess, C., Thies, J., Niessner, M. (2019). *FaceForensics++: Learning to Detect Manipulated Facial Images*. IEEE/CVF International Conference on Computer Vision (ICCV), Seoul, Korea (South), 1-11.

EKLER

EK-1. Google Colaboratory ortamı



Resim 1.1. Google Colaboratory ortamı

EK-2. Oluşturulan modelin şeması

```

Downloading data from https://storage.googleapis.com/keras-applications/efficientnetb5\_notop.h5
115263384/115263384 [=====] - 1s 0us/step
Model: "sequential"

```

Layer (type)	Output Shape	Param #
efficientnetb5 (Functional)	(None, 8, 8, 2048)	28513527
conv2d (Conv2D)	(None, 8, 8, 32)	589856
max_pooling2d (MaxPooling2D)	(None, 4, 4, 32)	0
dropout (Dropout)	(None, 4, 4, 32)	0
conv2d_1 (Conv2D)	(None, 4, 4, 64)	18496
max_pooling2d_1 (MaxPooling2D)	(None, 2, 2, 64)	0
dropout_1 (Dropout)	(None, 2, 2, 64)	0
flatten (Flatten)	(None, 256)	0
dense (Dense)	(None, 256)	65792
dropout_2 (Dropout)	(None, 256)	0
dense_1 (Dense)	(None, 1)	257

```

=====
Total params: 29,187,928
Trainable params: 29,015,185
Non-trainable params: 172,743

```

Resim 2.1. Oluşturulan modelin iç şeması

EK-3. Oluşturulan modelin eğitim şeması

```
[8] history = model.fit(
    x=generator,
    batch_size=16,
    epochs=19,
)

Fit model on training data
Epoch 1/19
25/25 [=====] - 690s 24s/step - loss: 0.9582 - accuracy: 0.4800
Epoch 2/19
25/25 [=====] - 605s 24s/step - loss: 0.7549 - accuracy: 0.5475
Epoch 3/19
25/25 [=====] - 600s 24s/step - loss: 0.6965 - accuracy: 0.5975
Epoch 4/19
25/25 [=====] - 604s 24s/step - loss: 0.6573 - accuracy: 0.6850
Epoch 5/19
25/25 [=====] - 604s 24s/step - loss: 0.4788 - accuracy: 0.7925
Epoch 6/19
25/25 [=====] - 611s 24s/step - loss: 0.4197 - accuracy: 0.8175
Epoch 7/19
25/25 [=====] - 599s 24s/step - loss: 0.3841 - accuracy: 0.8450
Epoch 8/19
25/25 [=====] - 586s 23s/step - loss: 0.3897 - accuracy: 0.8600
Epoch 9/19
25/25 [=====] - 593s 24s/step - loss: 0.2826 - accuracy: 0.8825
Epoch 10/19
25/25 [=====] - 588s 24s/step - loss: 0.2205 - accuracy: 0.9525
Epoch 11/19
25/25 [=====] - 591s 24s/step - loss: 0.3093 - accuracy: 0.8850
Epoch 12/19
25/25 [=====] - 595s 24s/step - loss: 0.2835 - accuracy: 0.8950
Epoch 13/19
25/25 [=====] - 590s 24s/step - loss: 0.2313 - accuracy: 0.9025
Epoch 14/19
25/25 [=====] - 591s 24s/step - loss: 0.1344 - accuracy: 0.9675
Epoch 15/19
25/25 [=====] - 584s 23s/step - loss: 0.2015 - accuracy: 0.9175
Epoch 16/19
25/25 [=====] - 582s 23s/step - loss: 0.2295 - accuracy: 0.9275
Epoch 17/19
25/25 [=====] - 580s 23s/step - loss: 0.1190 - accuracy: 0.9600
Epoch 18/19
25/25 [=====] - 584s 23s/step - loss: 0.1097 - accuracy: 0.9625
Epoch 19/19
25/25 [=====] - 586s 23s/step - loss: 0.0777 - accuracy: 0.9725
```

Resim 3.1. Oluşturulan modelin eğitim aşamasındaki isabet ve kayıp değerleri

EK-4. Modelin test performans sonuç görüntüsü

```

1/1 [=====] - 0s 335ms/step
1/1 [=====] - 0s 345ms/step
1/1 [=====] - 1s 548ms/step
1/1 [=====] - 1s 552ms/step
1/1 [=====] - 1s 561ms/step
1/1 [=====] - 1s 552ms/step
1/1 [=====] - 0s 408ms/step
1/1 [=====] - 0s 334ms/step
1/1 [=====] - 0s 329ms/step
1/1 [=====] - 0s 339ms/step
1/1 [=====] - 0s 337ms/step
1/1 [=====] - 0s 323ms/step
1/1 [=====] - 0s 327ms/step
1/1 [=====] - 0s 348ms/step
1/1 [=====] - 0s 332ms/step
1/1 [=====] - 0s 350ms/step
1/1 [=====] - 0s 332ms/step
1/1 [=====] - 0s 329ms/step
1/1 [=====] - 0s 325ms/step
1/1 [=====] - 0s 328ms/step
1/1 [=====] - 0s 343ms/step
1/1 [=====] - 0s 331ms/step
1/1 [=====] - 0s 332ms/step
1/1 [=====] - 0s 448ms/step

Test Çalışması Sonunda:
Doğruluk: 0.9174311926605505
Ayarlılık: 0.8933333333333333
Kesinlik: 0.9852941176470589
F1-Score: 0.9370629370629371
Doğru Tespit Gerçekler: 67
Doğru Tespit Sahteler: 33
Yanlış Tespit Gerçekler: 1
Yanlış Tespit Sahteler: 8
Toplam: 109
Bulunmuştur

```

Resim 4.1. Modelin test sonuçları



Gazili olmak ayrıcalıktır