

T.C.
MİLLÎ SAVUNMA ÜNİVERSİTESİ
ATATÜRK STRATEJİK ARAŞTIRMALAR VE
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYARLI GÖRÜ İLE YÜZ YÜZE SINAVLARDA
ŞÜPHELİ DAVRANIŞLARIN ORTAYA ÇIKARILMASI
İÇİN DERİN ÖĞRENME ÇERÇEVESİ TASARIMI

Doğu SIRT

DOKTORA TEZİ

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Doktora Programı

Danışman

Dr. Öğr. Üyesi Ediz ŞAYKOL

Kasım 2023

T.C.

MİLLÎ SAVUNMA ÜNİVERSİTESİ

ATATÜRK STRATEJİK ARAŞTIRMALAR VE LİSANSÜSTÜ
EĞİTİM ENSTİTÜSÜ

BİLGİSAYARLI GÖRÜ İLE YÜZ YÜZE SINAVLARDA
ŞÜPHELİ DAVRANIŞLARIN ORTAYA ÇIKARILMASI
İÇİN DERİN ÖĞRENME ÇERÇEVESİ TASARIMI

Doğu SIRT tarafından hazırlanan tez çalışması 10.11.2023 tarihinde aşağıdaki jüri tarafından Millî Savunma Üniversitesi Atatürk Stratejik Araştırmalar ve Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Doktora Programı **DOKTORA TEZİ** olarak kabul edilmiştir.

Dr. Öğr. Üyesi Ediz ŞAYKOL
Beykent Üniversitesi
Danışman

Jüri Üyeleri

Dr. Öğr. Üyesi Ediz ŞAYKOL, Danışman
Beykent Üniversitesi

Prof. Dr. Metin ZONTUL, Üye
Sivas Bilim ve Teknoloji Üniversitesi

Dr. Öğr. Üyesi Ömer ÇETİN, Üye
Millî Savunma Üniversitesi

Doç. Dr. Can EYÜPOĞLU, Üye
Milli Savunma Üniversitesi

Doç. Dr. Oğuz ATA, Üye
Altınbaş Üniversitesi

Danışmanım Dr. Öğr. Üyesi Ediz ŞAYKOL sorumluluğunda tarafımda hazırlanan “Bilgisayarlı Görü ile Yüz Yüze Sınavlarda Şüpheli Davranışların Ortaya Çıkarılması için Derin Öğrenme Çerçevesi Tasarımı” başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Doğu SIRT



*Eşime
ve
kızıma*

TEŞEKKÜR

Rehberliđi, desteđi ve benimle paylaştıđı bilgileri ile bu tezin ortaya ıkmasında byk pay sahibi olan danıřmanım sayın hocam Dr. đr. yesi Ediz řAYKOL'a, neri ve destekleriyle alıřmama katkıda bulunan Tez İzleme Komitesi yeleri Prof. Dr. Metin ZONTUL'a ve Dr. đr. yesi mer ETİN'e, bana deđerli zamanlarını ayırdıkları iin tez savunma jri yeleri Do. Dr. Can EYPOĐLU ve Do. Dr. Ođuz ATA'ya, alıřmalarım sresince beni her kořulda motive eden ve yařama sevincim olan sevgili eřim Merve SIRT ve kızım İlke SIRT'a teřekkür ederim.

Dođu SIRT

İÇİNDEKİLER

TEŞEKKÜR	v
SİMGE LİSTESİ	viii
KISALTMA LİSTESİ	ix
ŞEKİL LİSTESİ	x
TABLO LİSTESİ	xi
ÖZET	xii
ABSTRACT	xiv
1 GİRİŞ	16
2 KULLANILAN YÖNTEMLERİN TEMELLERİ	30
2.1 Derin Öğrenme.....	31
2.2 Teknoloji Türleri.....	32
2.3 Uygulama Alanları.....	34
3 COPYNET ÇERÇEVESİ	46
3.1 Veri Kümesi.....	46
3.1.1 Alan Uzmanlarınca Etiketleme ve Açıklamalar.....	48
3.1.2 Veri Kalitesi için Ön İşleme Adımları.....	49
3.1.3 Veri Kümesi Bölümleme: Eğitim, Doğrulama ve Test.....	50
3.2 Veri Kümesine Zamansal Atlama Uygulamak.....	52
3.3 Model.....	55
3.3.1 Kalıntı ağlar.....	62
3.4 Model Özellikleri ve Eğitim Detayları.....	66
3.4.1 Yürütme Süresi ve Ortamı Detayları.....	80
3.4.2 YOLOv5 Yapılandırması ve Eğitimi.....	68
3.4.3 Faster R-CNN Yapılandırması ve Eğitimi.....	83
3.4.4 Değerlendirme Protokolü.....	71
3.5 Algoritmik Karmaşıklık.....	75
3.6 Çerçeve.....	76
4 NESNE ALGILAMA TEKNİKLERİ	82
4.1. Optik Akış Analizi.....	82
4.2. Öznitelik Mühendisliği Teknikleri.....	83
4.3 Yeni Veri Kümeleri Üzerinde Zamansal Atlamayı Uygulamak.....	85
5 PERFORMANS ÇALIŞMASI	88

5.1 Nesne Tespiti ve Sınıflandırmasına Ait Performans Değerlendirmesi....	104
5.2 Davranış Tespiti ve Sınıflandırmasına Ait Performans Değerlendirmesi	111
5.3 Model Arıza Durumları ve Sınırlamalar	98
6 SONUÇ VE GELECEK TARTIŞMALARI	101
KAYNAKÇA	104
TEZDEN ÜRETİLMİŞ YAYINLAR	109



SİMGE LİSTESİ

I_x	1. Uzamsal türev
I_y	2. Uzamsal türev
I_z	Zamansal türev
log	Logaritma
reg	Ek evrişimli sinir ağı katmanı
cls	2. Ek evrişimli sinir ağı katmanı



KISALTMA LİSTESİ

CNN	Convolutional Neural Network
SSD	Single Shot Multibox Detector
SIFT	Scale Invariant Feature Transform
SURF	Speeded-Up Robust Features
FAST	Features from Accelerated Segment Test
MSOG	Multi Scale Oriented Gradient
LSTM	Long Short Term Memory
YOLO	You Only Look Once
GAN	Generative Adversarial Networks
RPN	Region Proposal Network
API	Application Programming Interface
GPU	Graphical Processing Unit
CPU	Central Processing Unit
TPU	Tensor Processing Unit
GRU	Gated Recurrent Unit
UCSD	University of California San Diego
MSE	Mean Squared Error
GMM	Gaussian Mixture Models

ŞEKİL LİSTESİ

Şekil 2.1 Derin sinir ağı mimarisi.....	20
Şekil 2.1 Derin öğrenme zaman çizelgesi.....	22
Şekil 2.3 Evrişimli derin sinir ağı model mimarisi.....	23
Şekil 2.4 Yineleyen derin sinir ağı model mimarisi.....	23
Şekil 2.5 Derin otokodlayıcılar sinir ağı model mimarisi.....	24
Şekil 2.6 Konuların kesişim diyagramı	42
Şekil 3.1 Sırasıyla B, C ve D sınıflarından görüntüler	47
Şekil 3.2 Zamansal atlama akışı.....	53
Şekil 3.3 Faster R-CNN ile kopyasız normal durumu belirleme.....	59
Şekil 3.4 ResNet ön eğitilmiş ağ	64
Şekil 3.5 Yürütme ortamlarının karşılaştırması.....	68
Şekil 3.6 COPYNet çerçevesi akış çizelgesi	78
Şekil 3.7 COPYNet çerçevesi.....	81
Şekil 4.1 Lucas-Kanade optik akış tekniğinin uygulandığı sınıf ortamı.....	82
Şekil 4.2 SURF ile nesne tespiti.....	84
Şekil 4.3 SSD ile nesne tespiti.....	85
Şekil 5.1 Sınıf adlarının geçtiği yerler.....	90
Şekil 5.2 Davranış tespiti sınıflandırma Analizi.....	92
Şekil 5.3 Değerlendirme metrikleri için kıyaslama grafiği (YOLOv5).....	95
Şekil 5.4 Değerlendirme metrikleri için kıyaslama grafiği (Faster R-CNN).....	97

TABLO LİSTESİ

Tablo 2.1. Şüpheli davranış tespit yöntemini mevcut yöntemlerle karşılaştırma..	43
Tablo 3.1 Önceki çalışmalarda kullanılan diğer veri kümeleri ile kıyaslama.....	49
Tablo 5.1 Farklı sinir ağlarının model skorları	90
Tablo 5.2 Başkasının kağıdına bakmak isimli sınıfa ait karmaşıklık matrisi.....	92
Tablo 5.3 Farklı modellerin hesaplama performansı.....	93



Bilgisayarlı Görü ile Yüz Yüze Sınavlarda Şüpheli Davranışların Ortaya Çıkarılması için Derin Öğrenme Çerçevesi Tasarımı

Doğu SIRT

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Programı

Doktora Tezi

Danışman: Dr. Öğr. Üyesi Ediz ŞAYKOL

Bu çalışma, yüz yüze sınavlarda kullanılan dijital kameralar tarafından kaydedilen görüntülerin analizi ve anormallik tespiti üzerine odaklanmakta ve sınavlardaki aktiviteleri yüksek doğrulukla tespit etmek için yeni bir model geliştirmeye odaklanmaktadır. Öncelikle, bu çalışma özelinde COPYNet Veri Kümesi oluşturulmuştur. Yaklaşık 30.000 görüntüden oluşan oldukça büyük bir koleksiyon olan bu veri kümesi, anormallik tespit algoritmalarının geliştirilmesi, doğrulanması ve performansının değerlendirilmesi için kullanılmaktadır. Veri kümesi, her biri belirli bir davranış kategorisiyle ilişkilendirilen beş farklı gruba dikkatlice ayrılmıştır. Bu amaçla, görüntü sınıflandırma probleminin çözümünde yüksek performans elde etmek için transfer öğrenme yöntemi, ResNet ön eğitilmiş modeli kullanılarak Faster R-CNN ve YOLOv5 algoritmalarıyla ayrı ayrı hibritleştirilmekte ve normal davranışı modelleyerek bir anormallik puanı elde etmek için derin bir sinir ağı çerçevesi (COPYNet) oluşturulmaktadır. COPYNet çerçevesi 0,90'lık bir hassasiyet, 0,88'lik bir geri çağırma ve 0,88'lik bir doğruluk

sergilemektedir. Bu rakamlar, mevcut literatürle karşılaştırıldığında anormallik tespitinde önemli bir sıçramaya işaret etmektedir. Sunulan sonuçlar, modelin farklı davranış sınıflarını doğru bir şekilde ayırt etme yeteneğini vurgulamakta ve modeli yüz yüze sınavlar sırasında şüpheli davranışları tespit etme zorluğunun üstesinden gelmek için bir araç haline getirmektedir. Sonuç olarak, model olağandışı bir aktivite tespit ettiğinde, gözetmene gönderilebilecek bir uyarıyı tetiklemeyi ve sınav gözetmenleri için bir karar destek mekanizması olarak çalışmayı amaçlamaktadır. Elde edilen başarı oranlarına göre çalışmamız, yüz yüze sınavlar sırasında şüpheli davranışları tespit etmek için literatürdeki önceki çalışmalara kıyasla umut verici bir çözüm sunmaktadır.

Anahtar Kelimeler: anormal davranış tespiti, sınav kopyası tespiti, derin öğrenme, transfer öğrenme.

Designing a Deep Learning Framework for Unveiling Suspicious Behavior in Face-to-Face Exams with Computer Vision

Doğu SIRT

Department of Computer Engineering

Doctor of Philosophy Thesis

Supervisor: Dr. Öğr. Üyesi Ediz ŞAYKOL

This study focuses on the analysis and anomaly detection of images recorded by digital cameras used in face-to-face exams, and focuses on developing a new model to detect activities in exams with high accuracy. First of all, COPYNet Dataset is created as the centerpiece of this work. This dataset, which consists of a sizable collection of about 30,000 images, is essential for developing, verifying, and evaluating the performance of anomaly detection algorithms. The dataset is carefully segmented into five different groups, each of which is associated with a certain behavioral category essential for anomaly detection. For this purpose, in order to achieve high performance in solving the image classification problem, the transfer learning method is separately hybridized with the Faster R-CNN and YOLOv5 algorithms using ResNet pretrained model, and a deep neural network framework (COPYNet) is created to obtain an anomaly score by modeling normal behavior. Notably, COPYNet framework exhibits an exceptional precision of 0.90, recall of 0.88 and accuracy of 0.88. These numbers signify a substantial leap in anomaly detection when compared to the existing literature. The presented results highlight the model's ability to accurately discern between different activity classes,

rendering it a promising tool for tackling the challenge of detecting suspicious behaviors during face-to-face exams. As a result, when the model detects an unusual activity, it is aimed at triggering an alert that can be sent to the proctor and operate as a decision support mechanism for exam invigilators. Based on the success rates obtained, our study offers a promising solution for detecting suspicious behavior during face-to-face exams compared to previous studies in the literature.

Keywords: abnormal behavior detection, exam copy detection, deep learning, transfer learning.



1 GİRİŞ

Yüz yüze değerlendirmelerde sınav bütünlüğünü sağlamaya yönelik artan ihtiyaç, araştırmacıları şüpheli davranışları tespit etmek için derin öğrenme tekniklerinin uygulanmasını keşfetmeye sevk etmiştir. Bu teknikler, bilgisayarla görme ve insan davranış analizinden yararlanarak sınav izleme sistemlerini geliştirme, kopya çekmeyi caydırma ve adil bir değerlendirme ortamı sağlama potansiyeli sunmaktadır.

Bilgisayarla görme ve derin öğrenme alanları, sınıf içi sınavlar sırasında şüpheli davranışların tespit edilmesi ve ortaya çıkarılması konusunda umut verici sonuçlar ortaya koymuştur. Araştırmacılar, sınav bütünlüğünü korumak için sağlam bir çerçeve oluşturmayı amaçlayarak, bu tür davranışları doğru bir şekilde tanımlamak ve sınıflandırmak için çeşitli yöntemler ve algoritmalar araştırmışlardır. Bu çalışmada, derin öğrenme tekniklerinin sınav bütünlüğünü artırma ve yüz yüze değerlendirmelerde kopya çekmeyi caydırma potansiyelini araştırarak mevcut literatüre katkıda bulunmayı amaçlamaktadır.

Sınıf içi sınavlar sırasında şüpheli davranışları tespit etmek için bilgisayarla görme ve derin öğrenme kullanımı konusunda giderek artan bir literatür bulunmaktadır. Bu çalışmalar, sınıf içi sınavlar sırasında şüpheli davranışları tespit etmek için bilgisayarlı görme ve derin öğrenmenin kullanılma potansiyelini ortaya koymakta, ancak aynı zamanda bu yöntemlerin gizlilik ve şeffaflığın sağlanması ve önyargıdan kaçınılması gibi teknik yönlerini ele almak için daha fazla araştırma yapılması gerektiğini vurgulamaktadır. Ayrıca, sistemin gerçek dünya verileri üzerinde değerlendirilmesi ve performansının geleneksel kopya tespit yöntemleriyle karşılaştırılması önemlidir.

Önceki çalışmalar, yüz yüze sınavlar sırasında kopya çekme davranışını tespit etmek için kameralar, mikrofonlar, göz izleyiciler, biyometrik sensörler veya yazılım araçları kullanmak gibi çeşitli yöntem ve teknikleri araştırmıştır. Ancak, bu yöntemlerin bazı sınırlamaları ve zorlukları vardır. Öncelikle, birçok eğitim kurumu veya sınav merkezi için uygulanabilir veya erişilebilir olmayabilecek pahalı ve karmaşık ekipman veya yazılım gerektirirler. İkinci olarak, öğrencilerden yüz ifadeleri, göz hareketleri, ses kalıpları veya fizyolojik sinyaller gibi hassas kişisel

verilerin toplanmasını ve işlenmesini içerdikleri için etik ve gizlilik endişelerini artırabilirler. Bunlara ek olarak, davranışı normal veya şüpheli olarak sınıflandırmak için önceden tanımlanmış kurallara veya eşiklere dayandıklarından, insan davranışının çeşitliliğini ve karmaşıklığını yakalayamayabilecekleri için hatalara veya önyargılara eğilimli olabilirler.

Bu eksiklikleri gidermek ve bu zorlukların üstesinden gelmek için bu çalışma, yüz yüze sınavlar sırasında kopya çekme davranışını tespit etmek için yeni bir çerçeve önermektedir. COPYNet, sınav odalarının video dizilerini analiz etmek ve öğrenciler arasındaki şüpheli davranış kalıplarını belirlemek için bilgisayarla görme ve derin öğrenmenin gücünden yararlanmaktadır. COPYNet'in mevcut yöntemlere göre çeşitli avantajları vardır.

Örneğin:

- Sınav odasını uygun bir açıdan çekebilen standart bir kamera dışında herhangi bir ek ekipman veya yazılım gerektirmez.
- Öğrencilerden, sınav salonundaki hareketleri ve eylemleri dışında herhangi bir kişisel veri toplamaz veya saklamaz. Ayrıca kararları için açıklamalar sunarak şeffaflık ve hesap verebilirlik sağlar.
- Sabit kurallara veya eşiklere dayanmak yerine verilerden öğrenmek ve farklı durumlara uyum sağlamak için sinir ağlarını kullanır. Ayrıca video sekanslarındaki gürültü ve oklüzyonla da başa çıkabilir.

Sınav yöneticileri ve eğitimciler, COPYNet'i kullanarak yüz yüze sınavları daha etkili ve verimli bir şekilde izleyip değerlendirebilir ve aynı zamanda sınav bütünlüğünü ve adaletini sağlayabilir. COPYNet ayrıca öğrencilerin akıllı bir sistem tarafından izlendiklerini ve değerlendirildiklerini fark etmelerini sağlayarak kopya çekme davranışını caydırabilir.

Bu çalışmanın temel amacı, bilgisayarla görme ve derin öğrenme tekniklerini kullanarak yüz yüze sınavlar sırasında kopya çekme davranışını tespit etmek için yeni bir çerçeve geliştirmek ve değerlendirmektir. Bu çalışmaya rehberlik eden spesifik araştırma soruları şunlardır:

- Sınav salonlarının video dizilerini analiz etmek ve öğrenciler arasındaki şüpheli davranış kalıplarını belirlemek için bilgisayarla görme ve derin öğrenme teknikleri nasıl uygulanabilir?

- Önerilen COPYNet çerçevesi, doğruluk, verimlilik ve sağlamlık açısından mevcut kopya tespit yöntemleriyle nasıl karşılaştırılır?
- Önerilen çerçevenin sınav bütünlüğünü artırma ve yüz yüze sınavlarda kopya çekme davranışını caydırma konusundaki etkileri ve katkıları nelerdir?

Bu çalışma, bu araştırma sorularını yanıtlayarak, yüz yüze sınavlarda kopya tespiti konusundaki bilgi ve uygulamaları geliştirmeyi ve davranış analizi ve anormallik tespiti için bilgisayarla görme ve derin öğrenmenin potansiyelini göstermeyi amaçlamaktadır.

Tez çalışması aşağıdaki şekilde düzenlenmiştir:

Bölüm 2'de yüz yüze sınavlarda kopya tespitine ilişkin yöntemlerin temelleri sunulmaktadır.

Bölüm 3'te sınavlar sırasında şüpheli davranışları tespit etmek için sunduğumuz COPYNet çerçevesinin yanı sıra kullanılan veri kümesi ve önerilen model tanıtılmaktadır.

Bölüm 4, ön işleme adımları ve özellik çıkarma dahil olmak üzere çalışmada kullanılan bilgisayarla görme ve nesne algılama tekniklerini açıklamaktadır.

Bölüm 5, bilgisayarla görme ve derin öğrenme modellerinin kopya tespitindeki performansını sunmaktadır. Modellerin performansını kopya tespitinde kullanılan mevcut yöntemlerle karşılaştırmakta ve sonuçları açıklamaya yardımcı olmak ve analizden elde edilen içgörülerini vurgulamak için görselleştirmeler sunmaktadır.

Bölüm 6, çalışmanın temel bulgularını özetleyerek başlamaktadır. Ardından, araştırmanın önemini ve sınıf içi sınavlarda kopya tespiti alanına yapılan katkıları vurgulamakta, gelecekteki araştırmalar ve sonuçların pratik uygulamaları için öneriler sunmaktadır. Araştırma hedefleri ve soruları ışığında yorumlanmakta ve tartışılmaktadır.


KULLANILAN YÖNTEMLERİN TEMELLERİ

Yapay Zeka alanındaki hem donanım hem yazılım yetkinliklerinin artması yapay sinir ağları modelinin etkin yönetimini hızlandırmıştır. 2007'den itibaren yapılandırılmamış verinin saklanması ve işlenmesindeki artış etiketlenilmeyecek kadar büyük verinin artışına sebep olmuştur. Görüntü işleme anlık verinin değerlendirilmesinde ve problemin çözümünde büyük yer kaplasa da yetersiz kalmıştır. Derin öğrenme bu yetersizlik noktasında çözüm sağlayarak güçlü öğrenme yetkinliği ve yöntemleri ile bir çok problemde yüksek doğruluk oranı elde etmiştir ve halen en etkili yöntem olarak kullanılmaktadır.

Endüstriyel, sağlık, askeri, eğitim ve akademik gibi bir çok alanda, derin öğrenme teknikleri, özellikle görüntü işleme ve büyük veri analizi konusunda etkili bir rol oynamaktadır. Görüntü işleme alanında, nesne algılama ve izleme, son yıllarda yoğun ilgi gören bir araştırma konusu haline gelmiştir. Hareketli görüntülerde nesnelerin tespiti, zorlu bir işlemdir. Derin öğrenme, nesne tespiti ve takibini yüksek düzeyde başarıyla yapmak için çeşitli yöntemler sunar. Örneğin, belirli bir nesnenin şekil, konum, renk, hız gibi özellikleri kullanılarak, görüntü ve videolarda bu nesnenin algılanması ve izlenmesi mümkündür. Ayrıca, arka planın videodan ayıklanması, izlenecek nesnenin özelliklerinin belirlenmesi, nesnenin sınıflandırılması gibi işlemlerle de nesne tespiti ve izlenmesi gerçekleştirilebilir. Bu süreçte, problemi en iyi çözecek doğru algoritmanın ve mimarinin seçilmesi büyük önem taşır.

2.1 Derin Öğrenme

Derin öğrenme, doğrusal olmayan çok katmanlı yapıları kullanarak ses dosyalarını metne çevirme, görüntü analizi ve sınıflandırması, veri işleme gibi çeşitli işlemler için tercih edilen bir makine öğrenmesi tekniğidir. Derin öğrenme sistemleri, birbirini takip eden katmanlardan oluşur ve her bir katman, kendisinden önceki katmandan aldığı çıktıyı girdi olarak kullanır [1]. Derin öğrenme modelinde, en baştaki katman girdi katmanı, en sondaki ise çıkış katmanı olarak tanımlanır. Bu iki katman arasında kalan katmanlara ise “gizli katmanlar” adı verilir. Şekil 1.1, derin öğrenme ağının mimarisini gözler önüne sermektedir.



Şekil 2.1 Derin sinir ağı mimarisi

- Giriş Katmanı (Input Layer): Verilerin modelinize girdiği yerdir. Her bir düğüm (nöron), bir özellik veya veri noktasını temsil eder.
- Gizli Katmanlar (Hidden Layers): Bu katmanlar modelin öğrenme yeteneğini belirler. Çok katmanlı yapılarda, her katman bir önceki katmandan çıktıyı alır, belirli bir aktivasyon fonksiyonu uygular ve sonucu bir sonraki katmana iletir.
- Çıkış Katmanı (Output Layer): Modelin sonucunu veya tahminini üretir. Genellikle aktivasyon fonksiyonları (örneğin, sigmoid veya softmax) kullanılarak sonuçlar belirli bir formata (örneğin, olasılık) dönüştürülür.

Bu temel mimari, derin öğrenme modellerinin çoğunda kullanılan standart yapıdır. Tabii ki, bu yapının karmaşıklığı ve derinliği, çözülmeye çalışılan probleme ve kullanılan derin öğrenme modeline göre değişiklik gösterebilir.

2.1.1 Derin Öğrenmenin Gelişimi ve Dönüşümü

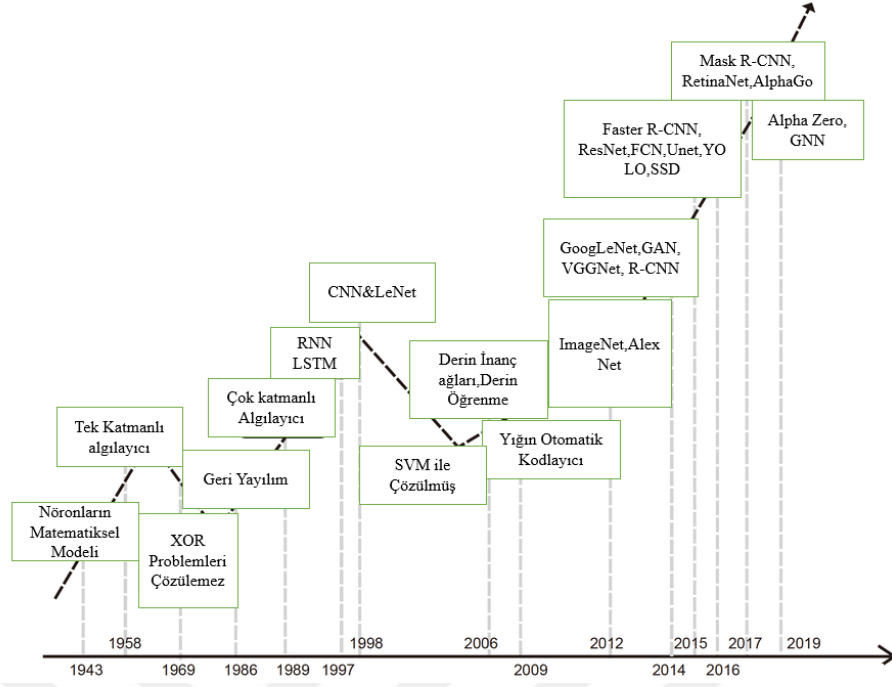
Derin öğrenme, insan beyninin nöronal yapısından esinlenerek geliştirilmiş bir alandır. Bu alanda, çok katmanlı sinir ağlarının eğitilmesi için araştırmacılar büyük çabalar sarf etmiştir. Derin öğrenme terimi, yapay sinir ağları üzerine çalışmalar yaparken ilk kez 2000'li yıllarda Igor Aizenberg ve arkadaşları tarafından kullanılmıştır.

Yapay zekâ ve derin öğrenmenin tarihsel sürecine bakıldığında, belirli dönemlere ait önemli kırılmalar göze çarpmaktadır:

- 1940 - 1960 arası : Bu dönemde derin olmayan sinir ağları üzerine çalışmalar yapılmış ve uygulamalar gerçekleştirilmiştir. 1943'te McCulloch ve Pitts, bir

sinir ağına ait ilk matematiksel modeli geliştirmişlerdir. 1950'de Alan Turing, makine öğreniminin gelecekteki etkilerini öngörmüş ve “Computing Machinery and Intelligence” adlı çalışmasında genetik algoritmalarından bahsetmiştir.

- 1960 - 1990 arası: Bu dönemde derin öğrenme ağları, geri yayılım, ilk yapay zeka kışı ve evrimsel sinir ağları gibi kavramlar ortaya çıkmıştır. 1965'te Alexey Ivakhnenko ve VG Lapa, grup veri işleme metodunu geliştirerek ilk derin öğrenme ağlarını oluşturmuşlardır. 1980'lerde Kunihiko Fukushima, çok katmanlı evrimsel yapay sinir ağını önermiştir. Terry Sejnowski, NetTalk oluşturarak İngilizce kelimelerin telaffuzunu geliştirmiştir. 1986'da Geoffrey Hinton, David Rumelhart ve Ronald J. Williams, sinir ağlarının geliştirilmesine büyük katkıda bulunmuşlardır. 1989'da Yann LeCun, evrimsel sinir ağlarını elle yazılmış çek ve posta kodlarını okumak için kullanmıştır.
- 1990 - 2000 arası: İkinci yapay zekâ kışı olarak adlandırılan bu dönemde, denetimsiz ve denetimli derin öğrenme kavramları ortaya çıkmıştır. 1993'te Jürgen Schmidhuber, çok derin öğrenme kavramıyla önemli bir adım atmıştır. 1995'te Corinna Cortes ve Vladimir Vapnik, destek vektör makinelerini geliştirmişlerdir. 1997'de Jürgen Schmidhuber ve Sepp Hochreiter, uzun kısa süreli bellek modelini önermişlerdir.
- 2000 - günümüz: Bu dönemde Hinton ve Salakhutdinov, çok katmanlı sinir ağlarının nasıl eğitilebileceğini göstermiş ve derin öğrenme kavramı popülerlik kazanmaya başlamıştır. 2009'da Fei Fei Li, ImageNet'i başlatarak denetimli öğrenme için büyük bir veri seti sunmuştur. 2014'te Facebook, DeepFace sistemini kullanarak otomatik fotoğraf etiketleme yapmıştır. 2016'da Google'ın AlphaGo programı, profesyonel bir Go oyuncusunu yenerek büyük bir başarı elde etmiştir. 2010 yılından sonra, büyük verinin işlenmesi ve yapay zekâ evriminde makine öğrenmesinin eksik kaldığı yerler, derin öğrenme ile tamamlanmıştır. Derin öğrenmenin zaman çizelgesi, bu önemli gelişmelerle doludur.. Şekil 2.2'de derin öğrenme zaman çizelgesi gösterilmiştir.

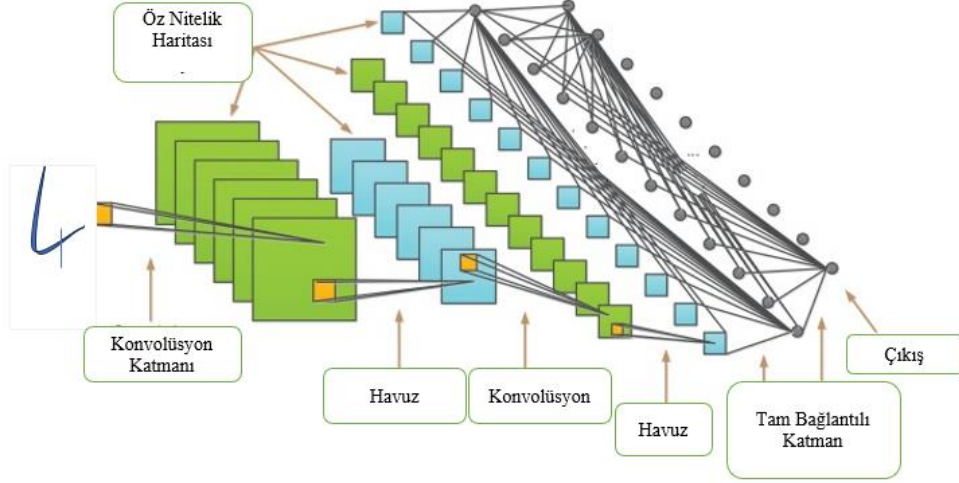


Şekil 2.2 Derin öğrenme zaman çizelgesi

2.1.2 Derin Öğrenme Mimarileri

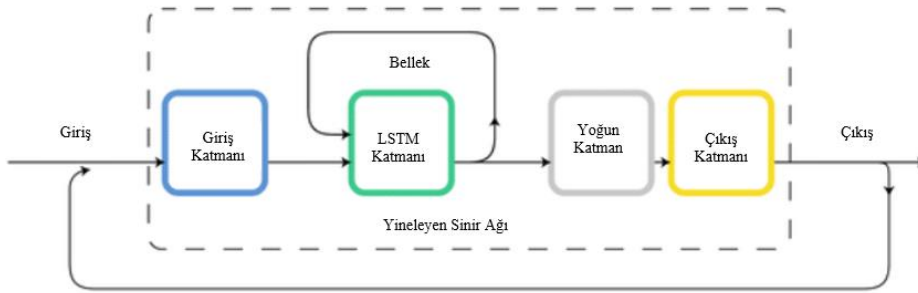
Kaliteli sonuçlar elde etmek için büyük veri setlerine ihtiyaç duyan bu yaklaşım, çok katmanlı sinir ağıları sayesinde karmaşık örüntüleri ve ilişkileri modelleyebilmektedir. Derin öğrenmenin temelinde, daha az ayırt edici özelliklerin alt katmanlarda, daha karmaşık özelliklerin ise üst katmanlarda işlendiği katmanlı bir yapı bulunmaktadır. Aşağıda, derin öğrenmenin temel mimarilerini ve güncel gelişmeleri incelenmektedir.

- Evrişimli Derin Sinir Ağları (CNN) : Görüntü işleme ve nesne tanıma alanında başat olan CNN'ler, yerel örüntüleri tanımlama ve sınıflandırma konusunda etkilidir. Gelişmiş CNN mimarileri arasında ResNet, Inception ve EfficientNet gibi modeller bulunmaktadır. Bu modeller, derinliklerini ve performanslarını artırırken hesaplama maliyetlerini azaltma yönünde yenilikler sunmaktadır.



Şekil 2.3 Evrişimli derin sinir ağı model mimarisi


- Yineleyen Sinir Ağları (RNN) ve Uzun Ömürlü Kısa Dönem Belleği (LSTM): Zamansal veriler ve dizi problemleri için ideal olan RNN'ler, önceki bilgileri hatırlayabilme yeteneğine sahiptir. Ancak, uzun bağımlılıkları öğrenmede zorluklar yaşadıkları bilinmektedir. Bu sorunu çözmek için LSTM ve Kapılı Yineleyen Hücre (GRU) gibi gelişmiş RNN türleri geliştirilmiştir. LSTM, özellikle doğal dil işleme ve konuşma tanıma gibi alanlarda etkilidir. Son yıllarda, daha verimli ve hızlı LSTM varyasyonları geliştirilmekte ve gerçek zamanlı uygulamalar için optimize edilmektedir.



Şekil 2.4 Yineleyen derin sinir ağı model mimarisi

- Sınırlı Boltzmann Makineleri (RBM) : RBM'ler, özellikle boyut azaltma ve öneri sistemleri gibi alanlarda kullanılmaktadır. Güncel gelişmeler, bu modellerin derin öğrenme mimarileri ile entegre edilerek daha karmaşık görevlerde kullanıldığını göstermektedir.

- Derin Otokodlayıcılar: Veri sıkıştırma, gürültü azaltma ve özellik öğrenme gibi alanlarda kullanılan derin otokodlayıcılar, veriyi daha düşük boyutlu bir temsile indirgeyebilir. Günümüzde, varyasyonel oto kodlayıcılar gibi gelişmiş modeller sayesinde daha karmaşık veri dağılımları öğrenilebilmekte ve yaratıcı uygulamalarda kullanılmaktadır.



Şekil 2.5 Derin otokodlayıcılar sinir ağı model mimarisi

- Derin İnanç Ağları (DBN): Çok katmanlı olmaları ve özellikle derin öğrenme modellerinin ön eğitimi için kullanılmalarıyla bilinen DBN'ler, karmaşık veri yapılarını modellemek için etkili olabilmektedir. Güncel uygulamalar, DBN'lerin daha geniş ölçekte veri analizi ve örüntü tanıma alanlarında kullanıldığını göstermektedir.
- Gelişmiş Mimariler ve Hibrit Modeller: Günümüzde, derin öğrenme mimarilerinin birleştirilmesiyle oluşturulan hibrit modeller popülerlik kazanmıştır. Örneğin, CNN ve LSTM'yi birleştiren modeller, video analizi ve zamansal örüntülerin görüntü verileriyle ilişkilendirilmesinde başarılı sonuçlar vermektedir. Ayrıca, dikkat mekanizmaları ve transformer modeller gibi gelişmiş teknikler, derin öğrenme mimarilerinin performansını artırmakta ve yeni uygulama alanları açmaktadır.

Nesne izleme teknikleri, video dizilerinde ilgilenilen nesnelerin hareketini izlemek ve takip etmek için bilgisayarla görme alanında kapsamlı bir şekilde araştırılmıştır. Çeşitli nesne izleme yöntemlerini ve algoritmalarını kapsamlı bir şekilde inceleyen

ve bu alandaki ilerlemelere ve zorluklara ışık tutan arařtırmalar yapılmıřtır [2-6]. Bu bilgi birikimi, yüz yüze deęerlendirmeler sırasında řüpheli davranıř kalıplarını belirlemek ve izlemek için nesne izleme tekniklerini uygulamak için bir temel oluřturarak saęlam izleme sistemlerinin geliřtirilmesini saęlar.

Derin öğrenme, karmařık veri yapılarını iřleyebilme ve örüntüleri tanıyabilme yeteneęi ile insan davranıřlarının analizinde önemli bir role sahiptir. Özellikle, davranıřsal verilerin, yüz ifadelerinin, vücut dilinin ve ses tonunun incelenmesinde kullanılan evriřimsel sinir aęları ve yineleyen sinir aęları gibi derin öğrenme modelleri, insan davranıřlarının derinlemesine anlaşılmasını saęlar. Bu modeller, büyük veri kümelerinden karmařık desenleri ve iliřkileri öğrenerek, insan davranıřlarının daha doęru bir řekilde analiz edilmesine olanak tanır.

Anormal davranıřların tespiti, özellikle güvenlik ve saęlık alanlarında hayati öneme sahiptir. Derin öğrenme tabanlı sistemler, gözetim kameraları aracılıęıyla toplanan verileri analiz ederek, řüpheli veya tehlikeli davranıřları otomatik olarak tespit edebilir. Örneęin, kalabalık bir alanda řiddet eylemleri veya acil tıbbi müdahale gerektirebilecek durumlar, bu sistemler tarafından hızlıca saptanabilir ve ilgili yetkililere bildirilebilir.

Eęitim alanında da derin öğrenme, öğrencilerin davranıřlarını analiz etmek ve eęitim süreçlerini iyileřtirmek için kullanılabilir. Öğrencilerin ders ierisindeki katılımlarını, dikkat seviyelerini ve öğrenme stillerini anlamak için derin öğrenme tabanlı araçlar, öğretmenlere önemli bilgiler saęlayabilir. Bu bilgiler, öğrencilerin ihtiyalarına daha iyi yanıt vermek ve eęitim kalitesini artırmak için kullanılabilir.

Son yıllarda arařtırmacılar, kalabalık ortamlarda davranıř analizi ve anormallik tespiti baęlamında derin öğrenme tekniklerinin uygulanmasını da arařtırmıřlardır. Bu amala, kalabalık ortamlardaki kolektif davranıřları tanımlamayı ve analiz etmeyi amalayan video dizileri kullanılarak çevrimii gerek zamanlı bir kalabalık davranıř algılama yöntemi önerilmiřtir [7]. Ayrıca, sınıf incelemelerinde řüpheli insan faaliyetlerini tespit etmek için bilgisayarla görme teknikleri ve davranıř analizi kullanan başka yöntemler de sunulmuřtur. Bu alıřmalar, karmařık insan davranıřlarını analiz etmek ve anormal faaliyetleri tespit etmek için derin öğrenmenin potansiyelini göstermektedir [8-11].

Sınav odalarındaki anormal davranışları etkili bir şekilde tespit etmek ve tanımak için çeşitli derin öğrenme teknikleri araştırılmıştır. Sınavlar sırasında öğrencilerin anormal eylemlerini izlemek ve tanımlamak için sinir ağları ve Gauss dağılımlarını kullanan gerçek zamanlı bir anormal davranış algılama sistemi önerilmiştir [12]. İnsan eylemi tanımının doğruluğunu artırmak için, video dizilerindeki uzamsal-zamansal bilgilerden yararlanmak üzere Evrişimsel Sinir Ağları kullanılmaktadır [13-16]. Bu teknik, eylemlerin dinamik doğasını yakalayıp tanıma performansını artırır ve sınavlar sırasında öğrenci davranışının daha kesin bir şekilde tanımlanmasını sağlar.

Nesne tespiti için bölge tabanlı bir evrişimsel sinir ağı olan daha hızlı R-CNN önerilmiştir [17-18]. Bu yöntem, evrişimli katmanları paylaşarak gerçek zamanlı nesne tanıma elde eder ve sınav odaları içindeki nesnelerin verimli bir şekilde izlenmesine ve takip edilmesine olanak tanır. Nesneleri gerçek zamanlı olarak tespit etme ve izleme yeteneği, yüz yüze değerlendirmelerin bütünlüğünü sağlamak için çok önemlidir.

2.1.3 Faster R-CNN: Bölge Evrişimli Sinir Ağı

Faster R-CNN ayrıca sınav anormallik tespit senaryosuyla uyumlu benzersiz nitelikleri nedeniyle seçilmiştir:

- **Doğru Lokalizasyon:** Faster R-CNN'nin iki aşamalı mimarisi, bir görüntüdeki nesnelerin hassas bir şekilde konumlandırılmasında üstündür; bu, başka birinin kağıdına bakmak gibi ince kopya eylemlerini tanımlamak için çok önemlidir. Faster R-CNN modelinin seçilme nedenlerinden biri, sınavlar sırasında doğru nesne lokalizasyonu sağlama yeteneğidir. Bu özellik, sınav izleme ve anormallik tespiti açısından kritik bir öneme sahiptir. Faster R-CNN'nin iki aşamalı mimarisi, her nesnenin yerini belirleme konusunda son derece hassas ve doğru sonuçlar elde etmeyi mümkün kılar.

Öğrencilerin kopya girişimlerini tespit etmek için, hangi nesnenin hangi konumda olduğunu kesin bir şekilde belirlemek gereklidir. Örneğin, bir öğrencinin sınav kağıdı yerine cep telefonuna bakarken yakalanması, bu özelliğin kritik önemini vurgular.

Faster R-CNN'nin kullanıldığı senaryolarda, her bir nesnenin yerinin hassas bir şekilde belirlenmesi, modelin anormallik davranışları tespit etme yeteneğini

artırır. Özellikle sınav sahnelerinde, öğrencilerin kopya çekme veya yasaklı malzemeleri kullanma eylemleri gibi anormal davranışları tespit etmek için nesnelerin doğru konumunu bilmek hayati öneme sahiptir. Bu, sınav bütünlüğünü koruma ve adil bir sınav deneyimi sağlama konusundaki amaçlara hizmet eder.

Faster R-CNN ile doğru lokalizasyon elde etmek, hızlı ve etkili bir şekilde nesnelerin sınıflandırılmasına ve tanımlanmasına katkı sağlar. İki aşamalı mimari, ilk aşamada görüntülerden özellik haritaları çıkararak nesnelerin yaklaşık konumlarını belirler ve ikinci aşamada bu konumları daha ayrıntılı ve hassas hale getirir. Bu sayede özellikle ince ve küçük nesnelerin bile doğru bir şekilde belirlenmesi mümkün olur. Bu, öğrencilerin sınavlarda kopya girişimlerini yakalamak ve önlemek için güçlü bir araç sağlar. Sonuç olarak, Faster R-CNN'nin doğru lokalizasyon yeteneği, sınavlarda anormallik davranışları tespit etmek ve sınav bütünlüğünü korumak için kullanıldığında kritik bir rol oynar. Bu özellik, nesnelerin hassas bir şekilde belirlenmesini sağlar ve modelin anormal eylemleri hızlı ve doğru bir şekilde tanımlamasına yardımcı olur. Bu da adil bir sınav deneyimi sağlama ve sınav güvenliğini artırma açısından büyük önem taşır.

- Çapa Tabanlı Öneri Üretimi: Faster R-CNN modelinin seçilme nedenlerinden biri, çapa tabanlı öneri üretim özelliğiyle öne çıkar. Bu özellik, nesnelerin tespiti için önemli bir aşamadır ve sınav izleme ve anormallik tespiti gibi görevlerde büyük bir rol oynar. Faster R-CNN'nin öneri üretim ağı (RPN), nesnelerin tespit edilmesi için öneriler üretir ve bu öneriler daha sonra ikinci bir aşamada işlenir. Bu çapa tabanlı yaklaşım, belirli öğelerin hassas konumlarını belirlemeye yardımcı olur ve böylece sınavlarda kopya veya yasaklı malzeme kullanımını gibi anormal davranışları tespit etme yeteneğini artırır.

Faster R-CNN'nin çapa tabanlı öneri üretimi ağı, görüntüler üzerinde nesne konumlarını öneriler şeklinde önerir. Bu öneriler, görüntünün farklı bölgelerinde olası nesne konumlarını temsil eder. Özellikle sınav izleme senaryolarında, belirli öğelerin konumu kesin bir şekilde belirlenmelidir. Örneğin, bir öğrencinin sınav kağıdı yerine cep telefonuna bakarken yakalanabilmesi için, cep telefonunun kesin konumu önemlidir. Çapa tabanlı öneri üretimi, bu tür öğelerin doğru konumlarını belirleme konusunda büyük bir hassasiyet sağlar.

Faster R-CNN'in çapa tabanlı öneri üretimi, sınavlar sırasında ince ve küçük nesnelerin tespiti için de son derece kullanışlıdır. Özellikle kopya kağıdı gibi küçük öğeler, geleneksel yöntemlerle tespit edilmesi zor olabilir. Ancak çapa tabanlı öneri üretimi, bu tür nesnelerin tespitini kolaylaştırır ve böylece anormal davranışların tespitini daha etkili hale getirir. Bu, sınavların güvenliğini artırma ve adil bir sınav deneyimi sağlama açısından önemlidir. Sonuç olarak, Faster R-CNN'nin çapa tabanlı öneri üretimi özelliği, sınavlarda anormal davranışları tespit etme yeteneğini artırmada önemli bir role sahiptir. Bu özellik, nesnelerin hassas konumlarını belirleme konusunda büyük bir hassasiyet sağlar ve böylece sınavlarda kopya veya yasaklı malzeme kullanımı gibi anormal davranışların tespitini kolaylaştırır. Bu da sınav bütünlüğünü koruma ve adil bir sınav deneyimi sağlama açısından büyük bir önem taşır.

Faster R-CNN modelinin seçilme nedenlerinden biri, katmanlı mimari yapısının sunduğu avantajlardır. Bu katmanlı yapı, nesne algılama görevlerini daha etkili bir şekilde gerçekleştirmek için tasarlanmıştır ve sınav izleme ve anormallik tespiti gibi görevlerde büyük bir öneme sahiptir.

- **Katmanlı Mimari:** Faster R-CNN'nin katmanlı mimari yapısı, iki aşamadan oluşur. İlk aşamada, görüntü üzerinde özellik haritaları üretilir. Bu özellik haritaları, görüntünün farklı özniteliklerini temsil eden matrislerdir ve nesnelerin belirgin özelliklerini yakalamak için kullanılır. İkinci aşamada ise, öneri üretimi ve sınıflandırma işlemi gerçekleştirilir. Bu aşamada, çapa tabanlı öneri üretimi ve nesne sınıflandırma yapılarak nesnelerin tespiti tamamlanır.

Katmanlı mimari, sınav izleme ve anormallik tespiti görevlerinde özellikle etkilidir çünkü her iki aşama da özel görevler için optimize edilebilir. İlk aşamada, nesne konumlarını daha kesin bir şekilde belirlemek için özellik haritaları hassas bir şekilde oluşturulabilir. Bu, ince kopya eylemlerini veya yasaklı malzeme kullanımını tespit etme yeteneğini artırır.

İkinci aşamada, çapa tabanlı öneri üretimi ve nesne sınıflandırma, modelin belirli nesnelere veya davranışları tanımlama yeteneğini artırır. Bu, özellikle sınavlarda belirli öğelerin veya davranışların tanımlanması gerektiğinde önemlidir. Örneğin, cep telefonu veya kopya kağıdı gibi belirli nesnelerin tespiti, sınav bütünlüğünün korunması açısından büyük bir öneme sahiptir.

Sonuç olarak, Faster R-CNN'nin katmanlı mimari yapısı, sınav izleme ve anormallik tespiti görevlerinde başarılı bir şekilde kullanılabilen özel görevlere uygun olarak optimize edilebilir. Bu yapı, nesne algılama görevlerini daha etkili hale getirir ve sınavlarda anormal davranışları tespit etme yeteneğini artırır. Bu da sınav bütünlüğünü koruma ve adil bir sınav deneyimi sağlama açısından büyük bir önem taşır.

- Birden Fazla Nesnenin Tespiti: Faster R-CNN modelinin seçilme nedenlerinden biri, aynı anda birden fazla nesnenin tespitini etkili bir şekilde gerçekleştirebilme yeteneğidir. Bu özellik, sınav izleme ve anormallik tespiti gibi görevlerde büyük bir öneme sahiptir ve modelin çoklu nesnelere veya eylemleri tanımlama yeteneğini artırır.

Faster R-CNN, çoklu nesnelere tespiti konusunda özellikle etkilidir çünkü özel olarak tasarlanmış bir iki aşamalı mimariye sahiptir. İlk aşamada, görüntü üzerinde özellik haritaları üretilir ve bu haritalar, farklı nesnelere özelliklerini yakalamak için kullanılır. İkinci aşamada ise, çapa tabanlı öneri üretimi ve nesne sınıflandırma işlemi gerçekleştirilir. Bu aşamada, model aynı anda birden fazla nesneyi tespit edebilir.

Bu yetenek, sınav izleme görevlerinde özellikle faydalıdır. Örneğin, sınav sırasında birden fazla öğrencinin aynı anda kopya çektiğini veya benzer davranışlar sergilediğini düşünelim. Faster R-CNN modeli, bu tür durumları algılayabilir ve birden fazla nesneyi tanımlayabilir. Bu, sınav bütünlüğünün korunması açısından büyük bir öneme sahiptir.

Ayrıca, model, aynı nesne veya davranışın farklı varyasyonlarını tanımlamak için de kullanılabilir. Örneğin, cep telefonu kullanımını tespit etmek istediğinizde, farklı telefon modelleri veya kullanım şekillerini tanımlamak gerekebilir. Faster R-CNN'nin çoklu nesnelere tespit etme yeteneği, bu tür farklılıkları ele almayı kolaylaştırır.

Sonuç olarak, Faster R-CNN'nin birden fazla nesnenin tespitini etkili bir şekilde gerçekleştirme yeteneği, sınav izleme ve anormallik tespiti gibi görevlerde modelin çoklu nesnelere veya eylemleri tanımlama yeteneğini artırır. Bu da sınav bütünlüğünü koruma ve adil bir sınav deneyimi sağlama açısından büyük bir öneme sahiptir.

Bununla birlikte, Darknet çerçevesi tanıtılmış ve YOLO mimarisi, açık kaynaklı bir çerçeve olarak nesne algılama ve sınıflandırma görevlerine odaklanmak için geliştirilmiştir [19-20]. Bu çerçeve, gözetim sistemlerinde sinir ağlarını eğitmek için esnek ve verimli bir platform sağlar. YOLO mimarisi, inceleme ortamlarında doğru ve verimli nesne tespiti için umut verici bir yaklaşım sağlar. YOLO'nun geliştirilmiş bir versiyonu, çok sayıda nesne kategorisini tespit etmek ve sınıflandırmak için hiyerarşik sınıflandırmayı içerecek şekilde geliştirilmiştir [21]. Bu ilerleme, gözetim sistemlerinin çok çeşitli nesnelere tespit etme ve tanıma kapasitesini artırarak yüz yüze sınavlarda kapsamlı izleme ve değerlendirmeye olanak tanır.

2.1.4 YOLOv5: You Only Look Once

YOLOv5 modeli, nesne tespiti alanında çığır açan bir modeldir ve sınıf sınava anormallik tespiti bağlamında sunmuş olduğu özellikler oldukça etkileyicidir. Bu özelliklerin her biri, YOLOv5'i ideal bir seçim haline getirmektedir.

Gerçek zamanlı işleme yeteneği, YOLOv5'i sınıf sınava ortamları için özellikle uygun hale getirir. Bu yetenek sayesinde, sınavın dinamik doğası göz önüne alındığında şüpheli davranışlar hızlı bir şekilde tespit edilebilir. Öğrencilerin hareketleri, not alma girişimleri veya diğer kopya eylemleri anında algılanır ve bu da sınavın bütünlüğünü koruma açısından son derece önemlidir.

YOLOv5'in verimli mimarisi, nesne algılama sürecini basitleştirir ve tek bir geçişte tüm görüntüyü kapsamlı bir şekilde tarar. Bu, hızlı ve ince kopya eylemlerini yakalamak için büyük bir avantajdır. Çünkü model, her bir görüntüyü çok hızlı bir şekilde işleyebilir ve bu da sınav sürecinin akışını kesintiye uğratmaz.

Modelin çok ölçekli algılama yeteneği, farklı boyutlardaki nesnelere tespit edilmesini sağlar. Özellikle cep telefonları veya kopya çekmek için kullanılacak kopya kağıtları gibi küçük nesnelere tespit için son derece uygun bir özelliktir. Bu, sınav sahnelerindeki çeşitli nesnelere tespit edilmesine ve kategorize edilmesine yardımcı olur.

YOLOv5'in nesne algılama yeteneği oldukça etkileyicidir. Öğrencilerin sınav sırasında kullanabileceği cep telefonları veya notlar gibi belirli öğeleri tanımlama yeteneği, sınav bütünlüğünü korumak için son derece önemlidir. Model, bu öğeleri

hızlı bir şekilde tanımlayabilir ve bu nesnelerin sınav alanında bulunmasını algılayarak uygun önlemlerin alınmasına yardımcı olabilir.

YOLOv5'in farklı çözünürlüklere uyarlanabilir olması büyük bir avantajdır. Sınav sırasında kullanılan kameraların kalitesi ve öğrencilerin pozisyonları değişebilir. Bu nedenle, model farklı giriş çözünürlüklerine kolayca uyum sağlayabilir ve her türlü sınav ortamında etkili bir şekilde kullanılabilir. Bu, modelin çok yönlü ve uyarlanabilir olmasını sağlar.

- Gerçek Zamanlı İşleme: YOLOv5 modelinin en dikkat çekici özelliklerinden biri, görüntüleri gerçek zamanlı olarak işleme yeteneğidir. Bu, sınav sırasındaki dinamik ve hızlı değişimlere hızlı bir şekilde yanıt verme yeteneği sunar. Öğrencilerin şüpheli davranışları anında algılanır ve gerekli önlemler hızla alınabilir. Bu, sınav bütünlüğünün korunmasında hayati bir öneme sahiptir.
- Verimli Mimari: YOLOv5, tek aşamalı bir mimariye sahiptir ve bu, nesne algılama sürecini son derece verimli hale getirir. Görüntüyü tek bir geçişte eksiksiz bir şekilde inceleyebilme yeteneği, hızlı ve hassas sonuçlar elde edilmesini mümkün kılar. Özellikle ince kopya eylemlerini yakalama açısından büyük bir avantaj sunar ve işlem süresini minimize eder.
- Çok Ölçekli Algılama: YOLOv5, nesne algılama işlemi sırasında çok ölçekli bir yaklaşım benimser. Bu, farklı boyuttaki nesnelerin tespitini destekler ve küçük nesnelerin, örneğin cep telefonları veya kopya kağıtları gibi, daha hassas bir şekilde tespit edilmesini sağlar. Bu çok ölçekli yaklaşım, sınav sahnelerindeki farklı nesnelerin etkili bir şekilde tespit edilmesine olanak tanır.
- Nesne Algılama: YOLOv5, sınavlar sırasında belirli nesnelere tanımlama yeteneğine sahiptir. Örneğin, cep telefonları veya notlar gibi belirli öğeleri algılayabilir ve bu nesnelere ilgili kategorilere ayırabilir. Bu, sınavın bütünlüğünü koruma açısından son derece önemlidir ve kopya girişimlerini tespit etme yeteneğini güçlendirir.
- Farklı Çözünürlüklere Uyarlanabilme: YOLOv5, farklı sınav koşullarına kolayca uyum sağlayabilme yeteneği ile öne çıkar. Kullanılan kamera kalitesi veya öğrencilerin pozisyonlarındaki değişikliklere adapte olabilir. Bu, modelin çeşitli sınav koşullarında güvenilir sonuçlar üretebilmesini sağlar ve çok yönlü bir kullanım sunar. Bu uyum yeteneği, sınav deneyimini daha güvenli ve etkili hale getirir.

2.2 Teknoloji Türleri

Gözetim sistemleri, çağımızın en önemli güvenlik gereksinimlerini karşılamak için vazgeçilmez araçlar haline gelmiştir. Bu sistemler, sadece nesnelere tespit etmekle kalmayıp aynı zamanda anormallikleri de tanımlama yeteneği sunar. Anormallik tespiti, kalabalık yerlerdeki etkili güvenlik önlemlerinin uygulanmasına yardımcı olur ve olayların önceden tahmin edilmesine olanak tanır. Özellikle son yıllarda, derin öğrenme teknikleri, bu alanda devrim yaratmıştır. Derin öğrenme, karmaşık gözetim verilerini analiz etme yeteneği ile anormallik tespitini daha da geliştirmiştir. Önceden eğitilmiş derin öğrenme modelleri, gözetim sistemlerinin anormallikleri daha hassas bir şekilde belirlemesini sağlayarak güvenlik açısından önemli bir avantaj sunar. Bu, güvenlik açısından daha duyarlı ve etkili bir izleme sağlar.

Nesne tespitinin yanı sıra, gözetim videolarında anormallik tespiti, sınav bütünlüğünü korumanın kritik bir yönüdür. Derin öğrenme teknikleri kullanılarak anormallik tespiti için videoların modelleme temsilleri incelenirken [22], derin öğrenme kullanılarak kalabalık analizi için akıllı video gözetim teknikleri sunulmakta, kalabalık davranışının anlaşılması ve anormallik tespitine odaklanılmaktadır [23]. Bu teknikler, bireylerin kolektif davranışlarını analiz ederek kalabalık inceleme ortamlarındaki şüpheli veya olağandışı faaliyetleri belirleyebilir.

Transfer öğrenme, gözetim sistemlerinin başka bir güçlü yanıdır. Bu yöntem, öğrenilen bilginin farklı görevlerde veya veri kümelerinde nasıl kullanılabileceğini incelemektedir. Gözetim videolarında anormallik tespiti için transfer öğrenme teknikleri kullanıldığında, farklı alanlardan veya veri kaynaklarından elde edilen bilgiler entegre edilir. Bu, sistemin yeni ve olağandışı faaliyetleri daha etkili bir şekilde tanımlama yeteneğini geliştirir ve güvenlik açısından daha güçlü bir koruma sağlar. Özellikle bu yaklaşım, gerçek dünya uygulamalarında anormal davranışların daha doğru bir şekilde saptanmasını sağlar. Transfer öğrenme, gözetim sistemlerinin geniş bir yelpazede uygulamalar için daha adapte olabilir hale ve güvenlik endüstrisindeki gelişmelere büyük katkı sağlar. Bir görevden veya alandan öğrenilen bilgiyi başka bir alandaki performansı artırmak için kullanan bir teknik olan transfer öğrenme, gözetim sistemlerinde de uygulanmıştır. Makine öğrenimi görevlerinde bilgiyi bir alandan diğerine aktarmak için kullanılan farklı

yaklaşımları ve yöntemleri tartışan transfer öğrenme üzerine bir anket düzenlenmiştir [24]. Transfer öğrenme tekniklerinden yararlanarak gözetim videolarında anormallik tespiti için geliştirilmiş bir derin öğrenme yöntemi tanıtılmıştır [25]. Önceden eğitilmiş modellerden bilgi aktararak, anormallik tespit sistemlerinin performansı önemli ölçüde artırılabilir ve bu da yüz yüze değerlendirmeler sırasında anormal davranışların daha doğru bir şekilde tanımlanmasına yol açar. Özellikle, insan aktivitesi tanıma bağlamında, transfer öğrenme umut verici sonuçlar göstermiştir. Görüntüleri tespit etmek ve insan faaliyetlerini tanımak için transfer öğrenmeye odaklanan ve tanıma modellerinin performansını artırmak için farklı teknikleri araştıran başka çalışmalar da vardır [26-30].

Transfer öğrenme, ilgili görevlerden veya veri kümelerinden elde edilen bilgilerden yararlanarak yüz yüze değerlendirmelerle ilgili belirli faaliyetlerin etkili bir şekilde tanınmasını sağlar. Özellikle insan aktivitesi tanıma alanında, transfer öğrenme tekniklerinin kullanılması, gözetim sistemlerinin gücünü büyük ölçüde artırmıştır. İnsan faaliyetlerinin doğru bir şekilde tanınması, güvenlik ve izleme uygulamaları için vazgeçilmezdir. Bu, kalabalık yerlerde, havaalanlarında, alışveriş merkezlerinde veya stadyumlarda güvenliği sağlamanın temel bir bileşenidir. Transfer öğrenme sayesinde, öğrenilen bilgi farklı alanlara veya veri kümelerine taşınabilir ve bu da sistemlerin çeşitli insan aktivitelerini tanıma yeteneklerini artırır. Özellikle optik akış gibi teknikler, insanların fiziksel hareketlerini daha ayrıntılı ve dinamik bir şekilde analiz etmeye olanak tanır. Bu, güvenlik sistemlerinin olağandışı veya potansiyel tehdit oluşturan aktiviteleri daha hassas bir şekilde algılamasına yardımcı olur ve güvenlik açısından daha yüksek bir koruma seviyesi sağlar. Kalabalık sahnelerde anormallik tespiti, özel bir zorluğu temsil eder ve bu bağlamda çeşitli çözümler geliştirilmiştir. Bu sahnelerde, olağandışı faaliyetleri veya potansiyel tehditleri tanımlamak, genellikle büyük veri akışlarını işlemek ve anlamak için karmaşık bir görevdir. Yoğunluk ısı haritaları ve optik akış gibi teknikler, bu zorluklarla başa çıkmak için önerilmiştir. Yoğunluk ısı haritaları, kalabalık sahnelerdeki yoğunluğu görsel olarak gösterir ve bu sayede olağandışı kalabalık aktiviteleri veya anormallikleri daha kolay belirlemeye yardımcı olur. Optik akış ise, insanların hareketlerini daha detaylı bir şekilde analiz etme yeteneği sunar. Bu, kalabalık sahnelerdeki anormal faaliyetleri daha hassas bir şekilde tespit etmeye katkı sağlar ve güvenlik sistemlerinin daha doğru sonuçlar elde etmesine

yardımcı olur. Kalabalık sahnelerde anormallik tespiti için zorluklarını ele almak için, yoğun kalabalıklarda anormal davranışları tespit etmek için yoğunluk ısı haritalarını ve optik akışı kullanan yöntemler önerilmiştir [31-33]. Bu teknik, kalabalık yerlerde meydana gelebilecek olağandışı olayların veya faaliyetlerin tanımlanmasını sağlar. Ayrıca, kalabalık sahnelerde anormal davranış tespiti için, hareket modellerini yakalamak ve anormal faaliyetleri tanımlamak için optik akış bilgilerinden yararlanan hibrit bir yönlendirilmiş optik akış histogramı tanıtılmıştır [34].

2.3 Uygulama Alanları

Son yıllarda, eylem tanıma alanında büyük ilerlemeler kaydedilmiştir ve bu ilerlemelerin bir sonucu olarak, gözetim sistemlerinin performansını artırmak için 2D ve 3D derin model entegrasyonları geliştirilmiştir. Bu entegrasyonlar, eylem tanıma sistemlerine derinlik bilgileri eklemek suretiyle eylemlerin daha iyi anlaşılmasına yardımcı olur. Hem uzamsal hem de zamansal boyutları bir araya getiren bu modeller, insan eylemleri hakkında daha zengin bilgiler yakalar. Bu, sınavla ilgili davranışların daha kesin bir şekilde tanımlanmasına ve olağandışı faaliyetlerin daha doğru bir şekilde tespit edilmesine olanak sağlar.

Bununla birlikte, eylem tanıma için 2D ve 3D derin modeller birleştirilerek eylem tanıma sistemlerinin performansını artırmak için derinlik bilgileri dahil edilmiştir [35]. Hem uzamsal hem de zamansal boyutları bir araya getiren bu modeller, insan eylemleri hakkında daha zengin bilgiler yakalayarak sınavla ilgili davranışların daha kesin bir şekilde tanımlanmasını sağlar.

Kalabalık sahnelerde anormallik tespiti ve lokalizasyonu için uzamsal-zamansal CNN'ler sunulmuş, anormallikleri tespit etmek için uzamsal-zamansal bilgilerden yararlanılmıştır [36] ve anormallikleri tespit etmek için video akışlarındaki artımlı değişiklikleri yakalayan ve analiz eden video anormallik tespiti için derin bir artımlı yavaş özellik analizi ağı önerilmiştir [37].

Kalabalık sahnelerde anormallik tespiti ve lokalizasyonu için uzamsal-zamansal CNN'ler gibi özel modeller geliştirilmiştir. Bu modeller, uzamsal ve zamansal bilgilerin birleştirilmesiyle anormallikleri tespit etmek için daha etkili hale gelmiştir. Video akışlarındaki artımlı değişiklikleri yakalayan ve analiz eden video

anormallik tespiti için derin bir artımlı yavaş özellik analizi ağı da önerilmiştir. Bu tür teknikler, kalabalık sahnelerde meydana gelebilecek olağandışı olayları tanımlama yeteneğini artırır ve güvenlik açısından daha güçlü bir koruma sağlar.

Kalabalık sahnelerde anormallik tespitini geliştirmek için, kalabalık davranışlarını modellemek ve anormal olayları tanımlamak için derin öğrenme tekniklerini kullanan kalabalık anormallik tespiti için derin bir olay modeli önerilmiştir [38]. Kalabalık sahnelerde hızlı anormallik tespiti ve lokalizasyonu için basamaklı bir 3D derin sinir ağı mimarisi olan Deep-Cascade sunulmuştur [39]. Bu mimari, birden fazla derin sinir ağını basamaklandırarak verimli ve doğru anormallik tespiti sağlar ve ortamlardaki anormal davranışları izlemek ve tanımlamak için sağlam bir çözüm sunar. Ayrıca, doğru anormallik tespiti elde etmek için farklı derin mimarileri ve eğitim stratejilerini keşfederek derin öğrenme tekniklerini kullanarak videolarda anormal davranış tespitine odaklanmıştır [40].

Gözetim sistemlerinin hayati öneme sahip olduğu günümüz dünyasında, sınav bütünlüğünün korunması ve güvenlik, öncelikli hedefler arasında yer almaktadır. Bu bağlamda, gözetim videolarındaki anormal davranışların tespiti son derece kritik bir rol oynamaktadır. Bu amaçla, yörünge analizi ve olay tespiti gibi iki önemli yöntemin birleştirildiği bir yaklaşım öne çıkmaktadır. Bu yöntem, videodaki nesnelerin ve faaliyetlerin yörüngelerini izleyerek anormal davranışları tespit etmeye odaklanır. Özellikle, nesnelerin beklenmedik yörüngeleri veya olayların olağandışı süreçleri algılandığında, güvenlik sistemleri hızlı bir şekilde müdahale edebilir ve potansiyel riskleri en aza indirebilir. Bu, sınav bütünlüğünün korunması açısından kritik bir adımdır.

Video gözetiminde anormal yörünge ve olay tespiti, sınav bütünlüğünü korumak için çok önemlidir. Gözetim videolarındaki anormal davranışları belirlemek için yörünge analizi ve olay tespitini birleştiren bir yöntem önerilmiştir [41].

Transfer öğrenme, bir faaliyet modelinin öğrenilen bilgilerini diğer faaliyetlere uyarlamasına olanak tanır. Bu sayede, sistem, çeşitli faaliyet modellerine uyum sağlayabilir ve anormallik tespit yeteneklerini geliştirebilir. Özellikle, farklı faaliyetler arasındaki benzerlikleri ve farkları yakalayabilen transfer öğrenme, sınav izleme sistemlerinde çok yönlü ve etkili bir araç olabilir.

Başka bir çalışma, kademeli bir sinir ağı mimarisi kullanarak insan faaliyetleri arasında transfer öğrenmeyi araştırmıştır [42]. Önerilen yöntem, farklı faaliyetler arasında paylaşılan temsilleri öğrenerek, sınav izleme için gözetim sistemlerinde faaliyet tanıma performansını artırmaktadır. Sistem, transfer öğrenmeden yararlanarak çeşitli faaliyet modellerine uyum sağlayabilir ve anormallik tespit yeteneklerini geliştirebilir.

Gerçek dünya anormallik tespit senaryolarında, uzamsal ve zamansal bilgiler çok önemli roller oynamaktadır. Hem uzamsal hem de zamansal bilgilerden yararlanarak gözetim videolarında gerçek dünya anormallik tespiti ele alınmıştır [43]. Bununla birlikte, normal davranışları aşamalı olarak modelleyen ve öğrenilen modellerden sapmalara dayalı olarak anormal faaliyetleri tespit eden bir yöntem önerilmiştir. Bu artımlı yaklaşım, sistemin zaman içinde yeni normal kalıpları uyarlamasını ve öğrenmesini sağlayarak sınavlar sırasında anormal davranışları tespit etme yeteneğini geliştirir [44].

Gerçek dünya anormallik tespit senaryolarında, uzamsal ve zamansal bilgilerin büyük bir öneme sahip olduğunu vurgulamak önemlidir. Bu, nesnelerin hareketlerini ve konumlarını anlamak için uzamsal bilgileri, aynı zamanda zaman içindeki değişiklikleri izlemek için zamansal bilgileri kullanmayı içerir. Bu bilgilere dayalı olarak, normal davranışları aşamalı olarak modelleyen ve öğrenilen modellerden sapmalara dayalı olarak anormal faaliyetleri tespit eden bir yöntem önerilmiştir. Bu artımlı yaklaşım, sistemin zaman içinde yeni normal kalıpları uyarlamasını ve öğrenmesini sağlayarak sınavlar sırasında anormal davranışları tespit etme yeteneğini geliştirir. Bu, sınav bütünlüğünün korunması ve güvenliği artırma çabalarında önemli bir adımdır.

Görüntü tanıma alanında derin öğrenmenin başarısı büyük bir ivme kazanmıştır, ancak bu alanda karşılaşılan zorluklar da göz ardı edilemez. Derin öğrenme modelleri, genellikle büyük veri setleri gerektirir ve bu, veri toplama, etiketleme ve işleme süreçlerinde karmaşıklıklara yol açabilir. Ayrıca, aşırı öğrenme sorunu ve model genelleme sorunları gibi zorluklar, derin öğrenme uygulamalarının önemli bir parçasıdır. Ancak, bu zorluklar, yeni kayıp fonksiyonları, aktivasyon fonksiyonları ve transfer öğrenme yöntemleri gibi gelişmelerle giderek daha iyi bir şekilde ele alınmaktadır. Bu sayede, görüntü tanıma görevlerindeki derin öğrenme modellerinin performansı sürekli olarak artmaktadır.

CNN'ler, sınavların video kayıtlarında sahtekarlık tespiti için güçlü bir araç haline gelmiştir. Özellikle online sınavların yaygınlaşmasıyla birlikte, sınav güvenliği ve değerlendirme sürecinin bütünlüğü önemli hale gelmiştir. CNN tabanlı yöntemler, video kayıtlarındaki kopya içeren faaliyetleri tespit etmek için görüntü analizi ve özellik mühendisliği tekniklerini kullanır. Bu, öğrencilerin dürüstlüğünü korumak ve sınav sonuçlarını güvence altına almak için kritik bir rol oynar.

Görüntü tanıma için derin öğrenmede karşılaşılan zorluklar ve ilerlemeler, görüntü tanıma görevleri için derin öğrenme modellerinin eğitiminde karşılaşılan zorluklar da dahil olmak üzere [45-46]'da verilmiştir. Ayrıca, CNN'ler kullanılarak sınavların video kayıtlarında sahtekarlık tespiti ele alınmıştır. Önerilen CNN tabanlı yöntem, video kayıtlarındaki kopya içeren faaliyetleri tespit ederek sınavlar sırasında değerlendirme sürecinin bütünlüğünü sağlamayı amaçlamaktadır [47].

İnsan eylemi tanıma, sınav güvenliği ve değerlendirme sürecinin iyileştirilmesi açısından büyük bir öneme sahiptir. Bu alandaki ilerlemelerden biri, hibrit derin öğrenme modelleridir. Bu modeller, CNN ile LSTM ağlarını birleştirir ve insan eylemlerini daha ayrıntılı ve dinamik bir şekilde analiz etmeyi amaçlar. Özellikle sınavlar sırasında öğrenciler tarafından sergilenen anormal eylemlerin belirlenmesinde etkili olabilirler. Bu, öğrencilerin dürüstlüğünü korumak ve sınav süreçlerini güvenli ve güvenilir hale getirmek için kritik bir öneme sahiptir.

Bunlara ek olarak, insan eylemi tanımayı iyileştirmek için CNN'leri ve uzun ömürlü kısa dönem belleği (LSTM) ağlarını birleştiren hibrit bir derin öğrenme modeli tanıtılmıştır. Bu yöntem, sınavlar sırasında öğrenciler tarafından sergilenen anormal eylemlerin belirlenmesinde etkili olabilir [48]. Kalabalık sınav ortamlarının yarattığı zorlukların üstesinden gelmek için, normal davranışın temsili yoluyla anormal olayları tanımlamaya yardımcı olan seyrek yeniden yapılandırma maliyetine dayalı bir yaklaşım tanıtılmıştır [49].

Sınavların adaletle gerçekleşmesi, modern eğitim sistemlerinin temel bir gerekliliğidir ve bu hedefe ulaşmak için teknolojinin kullanımı giderek önem kazanmaktadır. Sınavlar sırasında adaletin sağlanması, öğrencilere eşit fırsatlar sunmanın yanı sıra, sınav bütünlüğünün korunmasını da içerir. Bu noktada, sınav izleme ve değerlendirme süreçlerinin adil ve güvenilir olması, eğitim kurumlarının

temel sorumlulukları arasındadır. Bu nedenle, sakıncalı video tespiti gibi teknikler, sınavların bütünlüğünü ve adaletini güvence altına almak için önemli bir rol oynar.

Sakıncalı video tespiti, sınav sırasında kopya içeren davranışları tespit etmek ve raporlamak için kullanılan bir teknoloji alanıdır. Bu teknikler, öğrencilerin sınavları sırasında kopya girişimlerini, kopya çekme eylemlerini veya diğer sahtekarlık türlerini tespit etmeye yardımcı olur. Özellikle online sınavlarda, bu tür sakıncalı faaliyetlerin tanınması, sınavların güvenilirliği açısından kritik bir öneme sahiptir. Bu bağlamda, video izleme sistemleri ve yapay zeka tabanlı algoritmalar, öğrencilerin hareketlerini ve davranışlarını analiz ederek şüpheli faaliyetleri belirler. Bu, sınav gözetimini güçlendirmenin ve öğrencilerin adaletli bir şekilde değerlendirilmesini sağlamanın bir yoludur.

Kopya çekme, öğrenciler arasında yaygın bir sahtekarlık biçimidir ve eğitim kurumlarının itibarını ve değerlendirme süreçlerini ciddi şekilde etkileyebilir. Bu nedenle, bu tür şüpheli faaliyetlerin tanınması ve engellenmesi büyük bir öneme sahiptir. Teknoloji, bu zorluğun üstesinden gelmek için güçlü bir araç olarak hizmet eder. Video gözetimi ve otomatik inceleme sistemleri, öğrencilerin sınav sırasında kopya çekme girişimlerini tespit etmek için kullanılır. Bu sistemler, öğrencilerin hareketlerini, seslerini ve ekranlarını izler ve herhangi bir şüpheli davranışı belirlemek için gelişmiş algoritmalar kullanır. Ayrıca, sınav izleme odalarında görevli insan denetçilerle birlikte çalışarak daha güçlü bir güvenlik katmanı sağlar.

Sınav ortamında adaletin sağlanması, davranış tanınmanın ötesine geçmektedir. Sakıncalı video tespiti için, uygunsuz içeriğin farklı seviyelerde tanımlanmasına izin veren hiyerarşik bir sistem sunulmuştur [50]. Ayrıca, sınavlar sırasında kopya çekmeyle ilişkili şüpheli faaliyetlerin tanınmasıyla ilgilenen ve akademik dürüstlüğü korumasına katkıda bulunan çalışmalar da vardır [51-52]. Bu çalışmadan farklı bir veri kümesi üzerinde makine öğrenimi teknikleri [53]'te kullanılmış ve anlamlı sonuçlar elde edilmiştir.

Optik akış ve GAN'lar gibi son teknoloji araçlar, video anormallik tespiti alanında önemli ilerlemeler sağlamıştır. Optik akış, hareketin ayrıntılı bir şekilde analiz edilmesine olanak tanır ve bu, anormal davranışları tespit etmek için daha fazla bilgi sağlar. GAN'lar ise normal davranış modellerini öğrenir ve ardından herhangi bir sapma veya anormallik tespit etmek için bu modelleri kullanır. Özellikle gözetim

sistemlerinde, bu teknikler, olayların ve davranışların anormal olup olmadığını belirlemek için kullanılır. Bu, güvenlik uygulamaları ve sınav gözetimi gibi birçok alanda önemlidir.

Bir başka çalışma, UCSD Veri Kümesi üzerinde optik akış [54] ve GAN'lara odaklanarak anormallik tespit tekniklerini gözden geçirmekte, bir diğeri de son teknoloji yöntemleri kullanarak ve aynı veri kümesi üzerinde GAN tabanlı modellerin güçlü performansını göstermektedir [55].

Özellikle final sınavları sırasında, doğrudan öğretmen izlemesinin olmaması, akademik sahtekârlık için önemli bir potansiyel oluşturmaktadır. Bu sorunu ele almak için [56], olası kopya olaylarını belirlemek için Yapay Öğrenme ve LSTM tekniklerini kullanan yeni bir yaklaşım önermektedir.

Yapay zeka temelli otomatik gözetmenlik sistemleri, sınav bütünlüğünü korumak ve şüpheli sınav katılımcılarını tespit etmek için önemli bir rol oynamaktadır. Bu bağlamda, Proctor Net gibi sistemler, yüz tanıma, göz-bakış takibi ve ağız açma tespiti gibi çeşitli özellikleri kullanarak yüksek doğruluk oranları elde etmektedir. Bu, sınav izleme süreçlerini otomatikleştirerek eğitim kurumlarına önemli bir avantaj sağlar. Bu sistemler, öğrencilerin sınavlarda sahtekarlık yapma girişimlerini tespit ederek sınavların güvenilirliğini artırır.

Yapay zeka tabanlı otomatik gözetmenlik sistemi Proctor Net [57], şüpheli sınav katılımcısı davranışlarını tespit etmek için yüz tanıma, göz-bakış takibi ve ağız açma tespitini kullanarak çeşitli veri kümeleri ve yanlış uygulama senaryolarında %91'lik bir doğruluk oranı elde etmiştir.

Özellikle nesne takibi, anormal davranış tanıma ve etkinlik tanıma gibi alanlardaki çalışmalar, video gözetimindeki önemli gelişmelere ışık tutmaktadır. Bu çalışmalar, gözetim sistemlerinin daha akıllı ve etkili hale gelmesini sağlar. Ancak, bu alanlardaki içgörülerin yüz yüze değerlendirmelerin özel bağlamı ile daha sıkı bir şekilde entegre edilmesi gereklidir. Yüz yüze değerlendirmeler, öğrencilerin fiziksel ve psikolojik tepkilerini analiz etmek için karmaşık bir bağlam sunar ve bu nedenle özel bir dikkat gerektirir. Bu bağlamda, araştırmacılar, nesne takibi ve anormal davranış tespiti gibi mevcut teknikleri bu özel bağlama nasıl uyarlayabileceklerini incelemelidir.

Yukarıda bahsedilen çalışmalar nesne takibi, anormal davranış tanıma ve davranış anlamının çeşitli yönlerine ilişkin içgörüler sunarken, bu alanlar ile yüz yüze değerlendirmelerin özel bağlamı arasındaki boşluğu doldurmaya ihtiyaç vardır.

Bu çalışma da, yüz yüze değerlendirmelerde sınav bütünlüğünü artırmaya yönelik yeni bir yaklaşım önermek için video gözetiminde nesne izleme, anormal davranış tanıma, etkinlik tanıma ve insan davranışını anlama konusundaki mevcut bilgi birikimine dayanmaktadır.

Derin öğrenme teknikleri, transfer öğrenme stratejileri ve anormallik tespit yöntemleri, gözetim sistemlerine entegre edildiğinde sınavla ilgili davranışların izlenmesini ve tanınmasını iyileştirmek için büyük bir potansiyele sahiptir. Özellikle, derin öğrenme, büyük veri kümeleri üzerinde öğrenme yeteneği sayesinde karmaşık örüntüleri ve davranışları tanımlamada etkilidir. Transfer öğrenme, öğrenci davranışlarını çeşitli bağlamlarda anlamamıza yardımcı olabilir. Anormallik tespiti, şüpheli davranışları belirlemek için kullanılabilir ve bu, sınav bütünlüğünü artırmada kritik bir rol oynar.

Bu derin öğrenme tekniklerinin, transfer öğrenme stratejilerinin ve anormallik tespit yöntemlerinin gözetim sistemlerine entegrasyonu, sınavla ilgili davranışların izlenmesini ve tanınmasını iyileştirmek için önemli bir potansiyele sahiptir. İlerleyen bölümlerde, bu tekniklerin belirli metodolojilerini ve uygulamalarını inceleyecek ve yüz yüze değerlendirmelerde sınav bütünlüğünü artırmaya yönelik çıkarımlarını tartışılmaktadır.

Modern eğitim alanında, yüz yüze sınavların gerçekliğini sağlamak ve kopya çekme davranışını önlemek, derin öğrenme ve bilgisayarla görme gibi en son teknolojilerin araştırılmasına yol açmıştır. Bu tez çalışmasında, bu teknolojilerin sınavlar sırasında öğrenciler tarafından sergilenen şüpheli davranışları tanımlama ve anlamadaki etkinliğini ortaya çıkarmayı amaçlayan nesne izlemeden transfer öğrenmeye kadar çeşitli metodolojilerde gezinilmektedir.

Ayrıca, çeşitli tekniklerin işleyişi dikkatle incelenmektedir. Örneğin, öğrencilerin sınavlar boyunca hareketlerini dikkatle gözlemleyen ve analiz eden transfer öğrenme tekniklerinin stratejik olarak kullanılmasıyla potansiyel kopya çekmeye işaret eden eylemlerin tespit edilmesi ve tanınmasına bir karmaşıklık katmanı eklenmiştir.

Kabul edilen sınırların ötesine geçen yeni unsurların eklenmesi, bu değerlendirmeyi benzersiz kılan şeydir. Büyük bir atılım olarak, çok modlu verilerin birleştirilmesi fikri ortaya atılmıştır. Görsel ipuçları işitsel ve fizyolojik girdilerle birleştirilerek öğrenci davranışının kapsamlı bir bağlamsal resmi ortaya çıkarılmaktadır. Böylece, ekip çalışması ve bilgi alışverişi örneklerinin tanınması teşvik edilmekte ve akademik dürüstlüğün korunmasına yönelik daha tarafsız bir yaklaşım sağlanmaktadır.

Bu tez çalışmasında, insan-bilgisayar etkileşiminin karmaşık dinamikleri araştırılırken, daha geniş etik ve insan merkezli sonuçları da kabul edilmektedir. Teknolojiyi etik konularla bütünleştirmek için açıklığı, adaleti ve öğrenci konforunu teşvik eden arayüzler oluşturmak önemlidir.

Bu çalışma, derin öğrenme, bilgisayarla görme ve nesne izleme gibi çeşitli metodolojileri inceleyerek sınavlar sırasında öğrenciler tarafından sergilenen şüpheli davranışları tanımlama ve anlama konusundaki etkinliğini araştırmayı amaçlamaktadır. Derin öğrenme, özellikle karmaşık davranışların ve hareketlerin izlenmesi ve analiz edilmesi gerektiği durumlarda güçlü bir araç olarak ortaya çıkar. Bilgisayarla görme, video akışlarından anlamlı bilgiler çıkarmamıza yardımcı olabilir ve nesne izleme, öğrencilerin hareketlerini dikkatle izlememize olanak tanır.

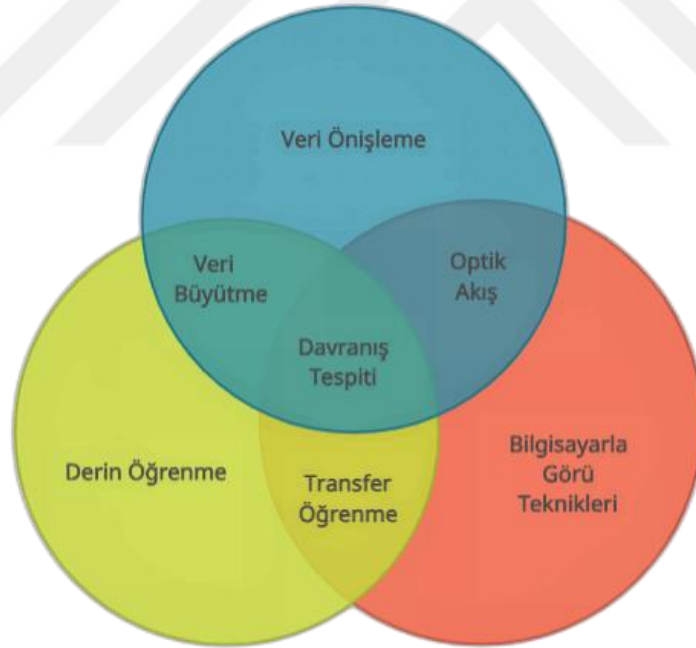
Bu çalışma aynı zamanda kopya tespitinin nasıl işlediğini yeniden düşünen çığır açıcı fikirler de sunmaktadır. "Kopya caydırıcı yapay zeka destekli sınavlar", reaktif teknoloji kullanımından proaktif izlemeye doğru bir paradigma değişimine işaret ederek öğrencilere gerçek zamanlı geri bildirim sağlamakta ve böylece kopya çekme teşvikini azaltmaktadır. Ek olarak, uyarlanabilir modeller fikri, olası öğrenci kaçınma tekniklerini öngörmekte ve hafifletmekte, böylece kopya tespit sisteminin genel sağlamlığını güçlendirmektedir.

Tez çalışması, sadece görsel sinyallere bağlı olmanın eksikliklerini çözmek için önceden eğitilmiş modellerin önemini de vurgulamaktadır. Davranış kalıpları hakkındaki bilgilerimize karmaşıklık katmak için geçmiş performans ve öğrenme yörüngeleri gibi değişkenlerin de dahil edilmesi gerekmektedir. Kültürler arası araştırma talebi, kültürel normların kopya çekme eğilimlerini etkilediğini ve çeşitli

öğrenci popülasyonları arasında doğru sonuçları garanti etmek için kültürel olarak uyarlanmış uygulamalar gerektirdiğini de kabul etmektedir.

Kapsamı sınav salonlarının ötesine genişleterek sürekli dürüstlük izleme fikri teşvik edilmektedir. Bu araçların daha geniş bir eğitim ekosistemine entegre edilmesiyle bir öğrencinin eğitim yolculuğu boyunca akademik dürüstlük kültürü teşvik edilmektedir. Bu teknolojilerin yaşam boyu öğrenme alanındaki potansiyel değerinin bir başka göstergesi de profesyonel sertifika testlerine ve mesleki sınavlara dahil edilmeleridir.

Bu konuyu gündeme getirerek, çalışmamız derin öğrenme, bilgisayarla görme, sınav bütünlüğü ve kopya önleme alanlarını birleştirmektedir. Bu inceleme, eğitimciler, araştırmacılar ve politika yapımcıların, yaklaşımları inceleyerek, yenilikçi unsurlar sunarak ve etik ve kültürel faktörleri vurgulayarak akademik değerlendirmenin kutsallığını korurken teknolojinin potansiyelinden yararlanmaları için bir yol çizmektedir.



Şekil 2.6 Konuların kesişim diyagramı

Bu teknikler umut verici sonuçlar ortaya koysa da, yine de çeşitli sınırlamalara ve zorluklara tabi olduklarını belirtmek gerekir. Örneğin, doğruluk kamera çözünürlüğü, aydınlatma koşulları ve öğrenci davranışı gibi çeşitli faktörlerden

etkilenebilir. Ayrıca, Şekil 2.1’de belirtildiği gibi, bu teknolojiler arasında çok fazla kesişme noktası vardır ve bu sistemleri kullanırken bunları göz önünde bulundurmamak önemlidir. Uygulamanın özel gereksinimlerine bağlı olarak kullanılacak başka birçok algoritma vardır. Ayrıca, tespitin doğruluğunu artırmak için birden fazla algoritma birleştirilebilir.

Tablo 2.1 Şüpheli davranış tespit yöntemini mevcut yöntemlerle karşılaştırma

Referans	Şüpheli Davranış Tespiti	Derin Öğrenme Modeli	Veri Kümesi Üretimi	Öznelik Mühendisliği	Kamera Çözünürlüğü / Aydınlatma
A. Pennisi vd. [7]	Hayır	Hayır	Hayır	Evet	İyi
T. Senthilkumar, vd. [8]	Evet	Hayır	Hayır	Evet	İyi
N. Soman, vd. [9]	Evet	Hayır	Hayır	Evet	Kötü Değil
D. Gowsikhaa, vd. [10]	Evet	Hayır	Hayır	Evet	İyi
P. P. Debnath [11]	Evet	Hayır	Evet	Evet	İyi
A. A. Ibrahim, vd. [12]	Evet	Hayır	Evet	Evet	Kötü Değil
S. Ji, vd. [13]	Hayır	CNN	Hayır	Hayır	Normal
K. Simonyan, vd. [14]	Hayır	CNN	Hayır	Hayır	Normal
K. Simonyan, vd. [15]	Hayır	CNN	Hayır	Hayır	Normal

Tablo 2.1 Şüpheli davranış tespit yöntemini mevcut yöntemlerle karşılaştırma (devamı)

S. F. Zhou, vd. [16]	Hayır	CNN	Hayır	Hayır	Mevcut Değil
A. Khaleghi, vd. [25]	Evet	Otokodlayıcı	Hayır	Evet	Kötü Değil
A. Al-azzawi, vd. [26]	Hayır	Transfer Öğrenme	Hayır	Hayır	Normal
J. Pang, vd. [27]	Hayır	Transfer Öğrenme	Hayır	Hayır	Normal
A.S. Keçeli vd. [28]	Evet	Transfer Öğrenme	Hayır	Hayır	Kötü Değil
R. Mutegeki, vd. [29]	Hayır	Transfer Öğrenme	Hayır	Evet	Normal
Y. Hao, vd. [31]	Hayır	Hayır	Hayır	Evet	Kötü Değil
L. Lazaridis, vd. [32]	Hayır	Hayır	Hayır	Evet	Kötü Değil
L. Kratz, vd. [33]	Hayır	Hayır	Hayır	Evet	Kötü Değil
Q. Wang, vd. [34]	Hayır	Hayır	Hayır	Evet	Normal
A. S. Keçeli, vd. [35]	Hayır	Hayır	Hayır	Evet	Normal
J. R. Medel vd. [36]	Hayır	CNN- LSTM	Hayır	Hayır	Normal
X. Hu, vd. [37]	Hayır	Hayır	Hayır	Evet	Normal
Y. C. Feng, vd. [38]	Hayır	Derin GMM	Hayır	Hayır	Normal

Tablo 2.1 Şüpheli davranış tespit yöntemini mevcut yöntemlerle karşılaştırma (devamı)

M. Sabokrou, vd. [39]	Hayır	CNN	Hayır	Hayır	Normal
J. Wang, vd. [40]	Hayır	CNN	Hayır	Hayır	Kötü Değil
S. Cosar, vd. [41]	Hayır	Hayır	Evet	Evet	İyi
X. Du [42]	Hayır	Transfer Öğrenme	Hayır	Hayır	Normal
W. Sultani, vd. [43]	Hayır	Evet	Evet	Hayır	İyi
K. Ouivirach vd. [44]	Evet	Hayır	Hayır	Hayır	Kötü Değil
Y. Hu, vd. [45]	Hayır	CNN	Hayır	Hayır	İyi
N. Jaouedia, vd. [48]	Hayır	CNN-LSTM	Hayır	Hayır	Kötü Değil
S. Lee, vd. [50]	Hayır	Hayır	Hayır	Evet	Normal
Y. Atoum vd. [51]	Evet	Hayır	Evet	Evet	İyi
M.D. Genemo, [52]	Evet	CNN	Hayır	Hayır	İyi
S. Ay, vd. [53]	Hayır	Evet	Hayır	Hayır	İyi
N. Nemade, vd. [54]	Hayır	Faster R-CNN	Hayır	Evet	Normal
Oluşturulan Model	Evet	Faster R-CNN + TL	Evet	Evet	İyi

3.1 Veri Kümesi

Öncelikle, anormal davranışları içeren bir etiketli veri kümesi oluşturulmalıdır. Bu veri kümesi, normal ve anormal davranışları içeren örneklerden oluşmalıdır. Normal davranışlar, sınavın doğru bir şekilde gerçekleştiği durumları temsil ederken, anormal davranışlar, kopya veya sahtekarlık girişimlerini simgeler. Bu veri kümesi, sınavın farklı senaryolarını ve koşullarını yansıtacak şekilde çeşitlendirilmelidir.

Oluşturulan veri kümesi daha sonra eğitim, doğrulama ve test alt kümelerine ayrılmalıdır. Eğitim alt kümesi, modelin öğrenme sürecini gerçekleştirdiği ve parametrelerini ayarladığı yerdir. Doğrulama alt kümesi, modelin eğitim sırasında performansını izlediği ve aşırı uyuma karşı kontrol ettiği alandır. Test alt kümesi ise modelin son performansının değerlendirildiği ve genelleme yeteneğinin ölçüldüğü bölümdür. Bu bölünme, modelin güvenilirliğini ve etkinliğini belirlemek için önemlidir.

Veri kümesinin büyüklüğü, modelin öğrenme kapasitesini etkiler. Daha büyük ve çeşitli bir veri kümesi, modelin farklı davranışları tanıma yeteneğini artırabilir. COPYNet Veri Kümesi, yaklaşık 30000 görüntü içerir ve 5 farklı sınıfa ayrılmıştır. Bu çeşitlilik, modelin farklı sınav senaryolarını ve anormal davranışları öğrenmesine yardımcı olur.

Veri kümesinin kalitesi de sonuçları büyük ölçüde etkiler. Görüntülerin netliği, çözünürlüğü ve etiketlerin doğruluğu, modelin başarısını etkiler. Veri kümesinin özenle hazırlanması ve etiketlerin doğru bir şekilde atanması önemlidir. Ayrıca, veri kümesinin dengeli olması da önemlidir, yani normal ve anormal davranışların yaklaşık olarak eşit sayıda örneğe sahip olması tercih edilir.

Bu aşamada, veri kümesi oluşturma ve hazırlama sürecine özenle yaklaşmak, sonraki adımlarda daha başarılı bir derin öğrenme modeli geliştirmek için kritik bir öneme sahiptir. Bu sınıflardan üçü sırasıyla Şekil 3.1'de gösterilmiştir:

- Sınıf A: Sınav Kağıdını Değiştirme: Bu sınıftaki örnekler, bir öğrencinin kendi sınav kağıdını başka bir öğrencininkiyle değiştirmeye çalıştığı durumları simüle eder. (Yaklaşık görüntü sayısı: 800)
- Sınıf B: Başkasının Kağıdına Bakmak: Bu sınıf altında yakalanan eylemler, öğrencilerin başka bir öğrencinin sınav kağıdına gizlice bakmasını içermektedir. (Yaklaşık görüntü sayısı: 7000)
- Sınıf C: Kopya Kağıdı Kullanımı: Bu sınıf, öğrencilerin gizli bir kopya kağıdına başvurarak kopya çektikleri davranışları kapsar. (Yaklaşık görüntü sayısı: 9000)
- Sınıf D: Cep Telefonu Kullanımı: Öğrencilerin sınav sırasında çevrimiçi cevaplara erişmek için cep telefonu kullandığı durumlar bu sınıfa girer. (Yaklaşık görüntü sayısı: 4200)
- Sınıf E: Normal Sınav Davranışı: Öğrencilerin normal, kopya çekmeden sınava girme sürecini tasvir eden temel sınıf. (Yaklaşık görüntü sayısı: 9000)



Şekil 3.1 Sırasıyla B, C ve D sınıflarından görüntüler

Tablo 0.1 Önceki çalışmalarda kullanılan diğer veri kümeleri ile kıyaslama

Veri Kümeleri	Avantajları	Dezavantajları
OEP DATASET [50]	<ul style="list-style-type: none">• İyi sınıflandırılmış• Çözünürlüğü yüksek• Çok büyük (11 GB)	<ul style="list-style-type: none">• Ele alınması zor• Yalnızca yüz tespiti
CUI-EXAM [51]	<ul style="list-style-type: none">• İyi sınıflandırılmış• Çözünürlüğü orta seviye• Büyüklüğü normal• Tüm beden tespiti	<ul style="list-style-type: none">• Yalnızca bir açıdan çekim• Sınırlı alan tespiti
COPYNet DATASET	<ul style="list-style-type: none">• İyi sınıflandırılmış• Büyüklüğü hafif• Bir çok açıdan görüntü	<ul style="list-style-type: none">• Çözünürlük orta seviye

3.1.1 Alan Uzmanlarınca Etiketleme ve Açıklamalar

Veri kümesi etiketleme ve açıklama süreci, derin öğrenme modelinin doğru ve güvenilir sonuçlar üretebilmesi için temel bir adımdır. Bu süreç, her bir görüntünün ilgili davranış sınıfına doğru bir şekilde atanmasını sağlar ve bu da modelin öğrenme sürecini destekler.

Etiketleme işlemi, insan yorumcular tarafından titizlikle gerçekleştirilir. Alan uzmanları, gözlemlenen davranışa ilişkin kategorizasyonla ilgili olarak her bir görüntüyü manuel olarak incelerler. Bu uzmanlar, genellikle ilgili alanlarda uzmanlaşmış kişilerdir ve gözetim videosundaki davranışları doğru bir şekilde tanımlayabilme yeteneğine sahiptirler. Her bir görüntü üzerinde çalışırken, görüntüdeki davranışı anlamak ve ilgili sınıfa etiketlemek için detaylı bir gözlem yaparlar.

Etiketleme işlemi sırasında, görüntülerin yanı sıra her davranışın ayrıntılı açıklamaları da oluşturulur. Bu açıklamalar, modelin öğrenme sürecini destekler ve

ilerleyen aşamalarda daha fazla içgörü sağlar. Örneğin, bir öğrencinin sınav sırasında sahtekarlık yapma girişimini gösteren bir görüntü, ilgili davranışın yanı sıra neden bu davranışın sahtekarlık olarak kabul edildiği konusunda bir açıklama içerebilir.

Etiketleme süreci, veri kümesinin kalitesini artırmak için sürekli bir geri bildirim döngüsünü içerebilir. Uzmanlar, modelin performansını izler ve gerektiğinde etiketlemeleri günceller veya düzeltmeler yapar. Bu sürekli geri bildirim, veri kümesinin doğruluğunu ve güvenilirliğini artırır ve sonuçta daha iyi bir derin öğrenme modelinin oluşturulmasına katkı sağlar.

Sonuç olarak, veri kümesi etiketleme ve açıklama süreci, derin öğrenme modelinin temelini oluşturan önemli bir aşamadır. Uzmanlar tarafından dikkatle yürütülen bu süreç, doğru etiketlemeler ve açıklamalarla zenginleştirilen bir veri kümesi oluşturur ve modelin daha iyi bir şekilde eğitilmesini sağlar.

3.1.2 Veri Kalitesi için Ön İşleme Adımları

Veri kümesinin kalitesini ve faydasını artırmak için bir dizi ön işleme adımından geçer:

- **Görüntü İyileştirme:** Veri kümesinin hazırlık aşamasının kritik bir parçası, görüntü iyileştirme adımıdır. Bu adım, veri kümesinde bulunan görüntülerin kalitesini artırmayı amaçlar. Görüntü iyileştirme, modelin daha iyi özellikler öğrenmesine yardımcı olur çünkü daha net ve anlaşılır görüntülerle çalışmayı sağlar. Bu aşamada, görüntüler üzerinde çeşitli işlemler uygulanabilir. Örneğin, kontrast artırma, görüntülerin daha belirgin hale gelmesini sağlayabilir. Ayrıca, keskinleştirme teknikleri veya renk düzeltmeleri de görüntü kalitesini artırmak için kullanılabilir.
- **Gürültü Giderme:** Gürültü, görüntülerdeki istenmeyen, anlamsız veya rastgele pikselleri ifade eder. Modelin yanıtılmasına veya yanlış sonuçlar üretmesine neden olabileceği için gürültü, veri kümesinin temizlenmesi gereken bir özelliktir. Gürültü giderme işlemi, veri kümesi üzerinde hassas bir şekilde yapılır. Bu aşamada, görüntülerdeki gürültüyü tanımlamak ve düzeltmek için çeşitli teknikler kullanılır. Örneğin, görüntülerdeki rastgele pikselleri algılamak ve bu pikselleri doğru değerlerle değiştirmek gürültü giderme işlemine örnek verilebilir.

- **Veri Temizliği:** Veri kümesinin temizlenmesi, mükerrer örneklerin, yanlış etiketlenmiş verilerin veya alakasız görüntülerin kaldırılmasını içerir. Bu aşama, modelin yanıltıcı verileri öğrenmesini önlemek ve daha tutarlı bir öğrenme deneyimi sağlamak için gereklidir. Veri temizliği işlemi, manuel veya otomatik olarak gerçekleştirilebilir. Büyük veri kümeleriyle çalışırken, otomatik veri temizleme teknikleri kullanılabilir. Bu, veri kümesinin güvenilirliğini artırır ve modelin daha kesin sonuçlar üretmesine yardımcı olur.
- **Normalizasyon:** Normalizasyon, görüntü özelliklerini tutarlı hale getirmeyi amaçlar. Bu aşama, görüntülerin boyutları, formatları veya renk kanalları gibi özelliklerinde tekdüzelik sağlar. Modelin öğrenme sürecini optimize etmeye yardımcı olur çünkü verinin daha tutarlı bir şekilde sunulmasını sağlar. Örneğin, farklı boyutlarda görüntülerle çalışırken, bu görüntülerin aynı boyuta getirilmesi normalizasyonun bir parçası olabilir. Ayrıca, renk kanallarının uyumlu hale getirilmesi de normalizasyonun bir yönü olabilir.

Bu ön işleme adımları, derin öğrenme modelinin başarısını büyük ölçüde etkiler. Daha iyi veri hazırlığı, modelin daha doğru ve güvenilir sonuçlar üretmesini sağlar. Bu nedenle, veri hazırlığına verilen önem, sınav gözetim sistemlerinin güvenilirliği ve etkinliği açısından kritiktir.

3.1.3 Veri Kümesi Bölümleme: Eğitim, Doğrulama ve Test

Veri kümesinin bölünmesi, bir yapay zeka modelinin geliştirilmesinde kritik bir aşamadır. Bu aşama, veri kümesinin farklı alt kümelerine ayrılmasını içerir ve her bir alt kümenin belirli bir rolü vardır. Eğitim alt kümesi, modelin eğitildiği ve davranışları tanımak için gerekli bilgileri öğrendiği aşamadır. Bu alt küme, modelin temelini oluşturan verileri içerir ve modelin karmaşıklığını artırmak için kullanılır. Model, bu aşamada veri kümesindeki normal ve anormal davranışları ayırt etmeyi öğrenir.

Özellikle, model, gözlemlendiği davranışları analiz eder, bu davranışların özelliklerini öğrenir ve gelecekte bu tür davranışları tanımak için gerekli olan desenleri keşfeder. Bu aşama, modelin bir şüpheli davranışı tanıdığını ve sınav bütünlüğünü korumak için ne tür davranışları algılaması gerektiğini anlaması için kritiktir.

Doğrulama alt kümesi, modelin hiperparametre ayarının yapıldığı ve

performansının izlendiği kritik bir aşamadır. Hiperparametreler, modelin en iyi performansı sergilemesi için ayarlanmalıdır. Bu, aşırı uyumun (overfitting) önlenmesi ve modelin uygun karmaşıklık seviyesine sahip olması açısından son derece önemlidir. Doğrulama alt kümesi, modelin genellemesini ve başka veri kümeleri üzerinde nasıl çalışabileceğini ölçmek için kullanılır. Bu aşama, modelin sadece eğitim verilerine uygun değil, aynı zamanda farklı verilere de genelleme yapabilme yeteneğini değerlendirir. Modelin performansı, doğrulama alt kümesi üzerinde dikkatlice izlenir ve hiperparametre ayarı gerektiğinde yeniden yapılandırılır.

Test alt kümesi, modelin nihai performansının değerlendirildiği aşamadır. Model, bu veri alt kümesi üzerindeki görünmeyen verilere ne kadar iyi genelleme yapabildiğini göstermelidir. Test seti, modelin gerçek dünya uygulamalarında nasıl çalışacağını tahmin etmek için kritik bir rol oynar.

Modelin doğruluğu, hassasiyeti, özgüllüğü ve diğer performans metrikleri dikkatlice değerlendirilir. Bu aşama, modelin sınav gözetim sisteminde başarılı olup olmadığını belirlemek için son derece önemlidir. Eğer model, test alt kümesinde anormal davranışları başarıyla tespit edebilir ve normal davranışları doğru bir şekilde sınıflandırabilirse, bu, sistemin güvenilir olduğunu gösterir.

COPYNet Veri Kümesi, gibi yapay zeka tabanlı otomatik gözetmenlik sistemlerinin geliştirilmesi için kullanılan veri kümesi, bu sistemlerin performansını eğitmek ve değerlendirmek için temel bir kaynaktır.

Bu veri kümesinin kalitesi ve doğruluğu, sistemin ne kadar güvenilir ve etkili olduğunu doğrudan etkiler. Bu nedenle, veri kümesinin dikkatli bir şekilde bölünmesi ve her bir alt kümenin rolü, sistemin sınav bütünlüğünü korumada ve anormal davranışları tanımlamada nasıl başarılı olabileceğini belirlemek için vazgeçilmezdir.

Her bir alt kümenin veri kümesine katkısı, modelin eğitimi ve performansının izlenmesi açısından büyük bir öneme sahiptir. Bu aşamaların titizlikle yönetilmesi, yapay zeka tabanlı sınav gözetmenlik sistemlerinin güvenilirliğini ve etkinliğini artırır.

Özünde COPYNet Veri Kümesi, sınıf sınavları sırasında anormal davranışları tespit etmede önerilen modelin performansını eğitmek ve değerlendirmek için temel taşı

olarak hizmet eder. Titiz kompozisyon, etiketleme ve ön işleme prosedürleri, veri setinin güvenilirliğini ve anlamlı analiz ve kesin sonuçlar için uygunluğunu sağlar.

3.2 Veri Kümesine Zamansal Atlama Uygulamak

Zamansal analiz, bir görüntü veya video içindeki zaman içindeki değişiklikleri incelemek için kullanılan bir önemli bir tekniktir. Bu analiz türü, bir olayın veya değişikliğin nasıl geliştiğini ve zaman içinde nasıl evrildiğini anlamamıza yardımcı olur. Özellikle, sınav gözetimi gibi uygulamalarda, öğrencilerin davranışlarını izlemek ve anormal eylemleri tespit etmek için zamansal analiz büyük bir öneme sahiptir. Örneğin, bir öğrencinin cevap kağıdını inceleme sürecinde dikkatsiz davranışları veya kopya çekme girişimleri zaman içinde nasıl değişiyor, bu zamansal analiz ile anlaşılabilir.

Zamansal analiz, video veya görüntü analizinde farklı sektörlerde de kullanılır. Örneğin, güvenlik kameraları tarafından kaydedilen görüntülerin analizi sırasında, zamansal analiz hırsızlık girişimleri veya diğer suçların tespit edilmesine yardımcı olabilir. Ayrıca, tıp alanında da kullanılır, bir hastanın radyolojik görüntüleri zaman içinde nasıl değişiyor ve tedaviye nasıl yanıt veriyor, bu tür soruların yanıtlanmasında zamansal analiz kritik bir rol oynar.


Zamansal atlama ise, zamansal analiz sırasında dikkate alınması gereken önemli bir kavramdır. Bu kavram, bir video veya görüntü analizi sırasında atlanan kare sayısını ifade eder. Zamansal atlama, analiz edilen kareler arasındaki zaman aralığını temsil eder. Daha küçük bir zamansal adım, daha fazla karenin analiz edildiği anlamına gelir. Bu, daha yüksek bir zamansal çözünürlükle sonuçlanır ve video içindeki her değişikliği daha ayrıntılı bir şekilde yakalamaya olanak tanır. Ancak, aynı zamanda daha fazla hesaplama kaynağı ve zaman gerektirir. Öte yandan, daha büyük bir zamansal adım, daha az karenin analiz edildiği anlamına gelir. Bu, daha düşük bir zamansal çözünürlükle sonuçlanır ve daha az hesaplama kaynağı ve zaman gerektirir.

Zamansal atlama, video analizi sırasında performans ve kaynak kullanımı arasında bir denge sağlamak için kullanılır. Bir analiz yapılacak senaryoya bağlı olarak, uygun zamansal atlama seviyesi seçilir. Özellikle büyük veri kümeleri veya uzun süreli video analizlerinde, doğru zamansal atlama seviyesi seçimi analiz sürecini

optimize etmek için kritik öneme sahiptir. Ayrıca, analiz sırasında zamansal atlamanın dinamik olarak ayarlanabilmesi, analiz esnasında değişen koşullara uyum sağlamada yardımcı olabilir.

Zamansal analiz ve zamansal atlama, görüntü ve video analizi alanında önemli kavramlardır. Zamansal analiz, bir olayın veya değişikliğin zaman içinde nasıl evrildiğini anlamamıza yardımcı olurken, zamansal atlama, analiz sürecinin performansını ve kaynak kullanımını optimize etmek için kullanılır. Bu kavramlar, sınav gözetimi, güvenlik analizi, tıbbi görüntüleme ve daha birçok uygulamada kullanılmaktadır ve analizlerin daha etkili ve hassas olmasına katkı sağlar.

Zamansal analiz, bir öğrencinin duruşundaki veya yüz ifadelerindeki değişiklikleri tespit etmek gibi, bir görüntü veya videodaki zaman içindeki değişiklikleri analiz etmek için kullanılabilen bir tür tekniktir. Ayrıca, zamansal atlama video analizinde kullanılan bir kavramdır ve bir video işlenirken atlanan kare sayısını ifade eder. Başka bir deyişle, analiz edilen kareler arasındaki zaman aralığıdır. Daha küçük bir zamansal adım, daha fazla karenin analiz edildiği anlamına gelir, bu da daha yüksek bir zamansal çözünürlükle sonuçlanır, ancak aynı zamanda daha fazla hesaplama kaynağı ve zaman gerektirir. Daha büyük bir zamansal adım, daha az karenin analiz edildiği anlamına gelir, bu da daha düşük bir zamansal çözünürlükle sonuçlanır, ancak aynı zamanda daha az hesaplama kaynağı ve zaman gerektirir.



Şekil 3.2 Zamansal atlama akışı

Şekil 3.2'de yer alan zamansal adım bağlamında, $S[i]$ bir dizideki mevcut kareyi veya örneği temsil eder. $S[i+2]$ 'ye atıfta bulunduğumuzda, esasen $S[i]$ 'ye kıyasla zamanda bir adım ileri kaydırılmış olan dizideki bir sonraki kareye veya örneğe atıfta bulunmuş oluruz. $S[i]$ ve $S[i+1]$ arasındaki kayma, zamansal bağımlılıkları yakalamamıza ve zaman içinde dizideki değişiklikleri analiz etmemize olanak tanır. Sonuç olarak $S[i]$, $S[i+1]$, $S[i+2]$ ve $S[i+3]$ arasındaki farkları inceleyerek dizideki hareket veya zamansal değişimler gibi kalıpları veya eğilimleri tespit edebiliriz. Sonuç olarak, $S[i]$ bir referans noktası olarak hizmet eder ve $S[i+1]$, $S[i+2]$, $S[i+3]$ vb. kaymalar dizinin zamansal gelişimi hakkında fikir verir.

Etkinlik tanıma, bir olayın veya bir eylemin bir video veya görüntü üzerindeki evrimini anlamamıza yardımcı olan bir analiz alanıdır. Bu tür analizler, birçok uygulama alanında kritik bir rol oynar. Örneğin, güvenlik kameraları tarafından kaydedilen görüntülerin etkinlik tanıma analizleri, suçların tespiti, hırsızlık girişimlerinin izlenmesi ve olay yerlerinin güvenliği için kullanılabilir.

Zamansal adım, etkinlik tanıma analizlerindeki hassasiyet ve hesaplama kaynakları arasındaki dengeyi belirler. Daha küçük bir zamansal adım, bir etkinliğin daha ayrıntılı bir şekilde incelenmesine olanak tanır. Özellikle hızlı ve karmaşık etkinliklerin analizi için bu ayrıntı seviyesi önemlidir.

Ancak, daha küçük bir zamansal adım daha fazla hesaplama kaynağı gerektirir ve analiz sürecini yavaşlatabilir. Bu nedenle, özellikle büyük veri kümeleri veya gerçek zamanlı analiz gerektiren uygulamalarda, zamansal adımın dikkatlice seçilmesi önemlidir. Daha büyük bir zamansal adım, analizin daha hızlı bir şekilde gerçekleşmesini sağlayabilir, ancak aynı zamanda ayrıntıları kaçırma riski taşır.

Zamansal adımın seçimi, özel uygulamanın gereksinimlerine ve kullanılabilir hesaplama kaynaklarına bağlıdır. Analizin zamansal çözünürlüğü, zamansal adımın boyutunu ve analizin ne kadar ayrıntılı olacağını belirler. Ayrıca, istenen doğruluk seviyesi de dikkate alınmalıdır. Örneğin, yüksek doğruluk gerektiren uygulamalarda daha küçük bir zamansal adım kullanmak önemlidir, ancak bu, daha fazla hesaplama kaynağı gerektirir.

Sonuç olarak, etkinlik tanıma analizlerinde zamansal adımın seçimi, hassasiyet, hesaplama kaynakları ve doğruluk seviyesi gibi faktörlere bağlıdır. Bu seçim, analizin etkinliğini, hızını ve kaynak kullanımını büyük ölçüde etkiler. Bu nedenle,

her uygulama bağlamında dikkatlice düşünülmesi ve ayarlanması gereken önemli bir parametredir.

3.3 Model

Sistemin hassasiyeti, doğruluğu ve genel performansı üzerinde önemli bir etkiye sahiptir. Bu çalışmada, YOLOv5 ve Faster R-CNN modelleri, sınıf sınavlarında etkili bir anormallik tespit sistemi oluşturmak için dikkate alınan iki ana modeldir.

YOLOv5 modeli, "Sadece Bir Kez Bak" anlamına gelir ve nesne tespiti görevlerinde yüksek hızlı ve doğru sonuçlar elde etmek için tasarlanmıştır. Bu model, nesnelere hızlı bir şekilde tespit etme yeteneği sayesinde, sınav sırasında anormal davranışları hızlı bir şekilde tanımlamak için ideal bir seçenek olabilir. YOLOv5'in hızı ve performansı, büyük veri kümelerini işlerken avantaj sağlar ve sınıf sınavlarının genellikle büyük ölçekte gerçekleştiği düşünüldüğünde bu önemlidir.

Öte yandan, Faster R-CNN modeli, Daha Hızlı Bölge Evrişimli Sinir Ağı anlamına gelir ve nesne tespiti görevlerinde yüksek hassasiyet ve doğruluk sunar. Bu model, nesnelere daha ayrıntılı ve hassas bir şekilde tanımlanmasını sağlar, bu da anormal davranışların daha ince ayrıntılara dayalı olarak tespit edilmesine yardımcı olabilir. Faster R-CNN, eğitim sürecinde ayrıntılı bir öğrenme sağladığı için sınıf sınavları için özelleştirilmiş ve ihtiyaçlarına uygun bir anormallik tespit modeli olarak tercih edilebilir.

Seçilen model, uygulamanın özel gereksinimlerine ve kullanılabilir veri kümesine bağlı olarak değişebilir. YOLOv5 ve Faster R-CNN, farklı avantajlara ve özelliklere sahip olsalar da, her ikisi de etkili bir anormallik tespit sistemi oluşturmak için uygun seçeneklerdir. Bu nedenle, sınıf sınavları için hangi modelin seçileceği, uygulamanın ihtiyaçlarına ve hedeflerine göre dikkatlice değerlendirilmelidir.

Sınıf sınavı anormallik tespiti uygulaması için YOLOv5 ve Faster R-CNN modellerinin seçilmesi, bu iki güçlü modelin sunduğu özelliklere dayanmaktadır. YOLOv5 modeli, gerçek zamanlı işleme yeteneği ile ön plana çıkmaktadır. Sınavlar, dinamik ve hızlı tempolu ortamlardır, bu nedenle şüpheli davranışların

gecikme olmaksızın anında tespit edilmesi kritik bir öneme sahiptir. YOLOv5, bu gereksinimi karşılamak için ideal bir seçenek sunar.

Ayrıca, YOLOv5'in verimli mimarisi, nesne algılama sürecini basitleştirir ve tek bir geçişte tüm görüntüyü kapsar. Bu, hızlı ve ince kopya eylemlerini yakalamak için avantaj sağlar. Sınav izleme görevlerinde, hızlı yanıt ve yüksek doğruluk arasında bir denge sağlama yeteneği büyük öneme sahiptir.

Faster R-CNN modeli ise doğru lokalizasyon ve çoklu nesne algılama yetenekleri nedeniyle tercih edilmiştir. İki aşamalı mimarisi, nesnelerin hassas bir şekilde konumlandırılmasına yardımcı olur. Bu, özellikle ince kopya eylemlerini tanımlamak için önemlidir. Ayrıca, Faster R-CNN'nin çapa tabanlı öneri üretimi, nesnelerin doğru tespitini kolaylaştırır.

Model seçimi, sınav izleme ve anormallik tespiti görevleri için kritik bir adımdır. Her iki model de hız, doğruluk ve uyarlanabilirlik açısından dengeli bir kombinasyon sunar. Bu, sınav bütünlüğünü koruma ve adil bir sınav deneyimi sağlama hedeflerini destekler.

Sınav sırasında şüpheli davranışları tespit etme yaklaşımı, bilgisayarla görme ve derin öğrenme tekniklerini kullanarak canlı video akışlarını analiz eder. Derin öğrenme tabanlı bir nesne dedektörü, belirli şüpheli eylemleri tanımak için eğitilir. Bu eylemler, başka bir öğrencinin sınavına bakma, notları iletmek veya cep telefonu kullanmak gibi kopya çekme davranışlarını gösterir. Bu dedektör daha sonra bu şüpheli davranışları işaretlemek için görüntülere uygulanır.

Son olarak, bir CNN görüntü gibi ızgara benzeri bir yapıya sahip verileri işlemek için ideal bir sinir ağı türüdür. Bu bağlamda, bir CNN, sınav sırasında bir sınıfın video görüntülerini analiz ederek şüpheli davranışları gösteren kalıpları veya özellikleri aramak için kullanılabilir. Örneğin, bir öğrencinin başka bir öğrencinin sınav kağıdına baktığını veya bir öğrencinin cep telefonu kullandığını anlamak için eğitilebilir. Bu, sınav bütünlüğünün korunması ve adil bir sınav deneyimi sağlanması açısından büyük bir öneme sahiptir. Bu nedenle, YOLOv5 ve Faster R-CNN modelleri gibi güçlü araçlarla desteklenen bu yaklaşım, sınavlardaki şüpheli davranışların tespitinde önemli bir rol oynamaktadır.

İki akışlı CNN ilk olarak [13] tarafından önerilmiş olup her bir akış, görüntü özelliği çıkarımı için hiyerarşik olarak düzenlenmiş bir dizi evrişimli katmandan

oluşmaktadır. Spesifik olarak, özellik çıkarma adımı, her katmandaki çekirdekler ile önceki katmanda üretilen özellik haritaları arasında sıralı konvolüsyon yoluyla elde edilir. M giriş özellik haritasına ve N çekirdeğe sahip l . katman için j . çıkış özellik haritası x şu şekilde hesaplanabilir:

$$x_i^l = f \left(\sum_{i=1}^M x_{i^*}^{l-1} k_{ij} + b \frac{l}{j} \right) j = 1, L, N \quad (3.1)$$

İki akışlı evrişimli sinir ağı, sınıf sınavları sırasında şüpheli davranışları tespit etmek için kullanılabilecek bir tür sinir ağı mimarisidir. İki akışlı CNN mimarisi [36], biri uzamsal bilgileri (yani görüntüler veya video kareleri) ve diğeri zamansal bilgileri (yani video kareleri dizileri) işlemek için iki ayrı CNN'den oluşur.

Uzamsal Akış CNN ve Zamansal Akış CNN, video verilerinin derinlemesine analizi için geliştirilen karmaşık derin öğrenme teknikleridir. Bu iki ayrı akışın birleştirilmesi, öğrencilerin sınav sırasındaki şüpheli davranışlarını tespit etme veya kopya çekme girişimlerini önleme gibi önemli görevler için son derece güçlü bir yaklaşım sunar. İlk olarak, Uzamsal Akış CNN, video karelerini ayrı ayrı ele alır ve her kareyi CNN kullanarak işler. Bu aşamada, bir öğrencinin yüz ifadesi, göz hareketleri veya el pozisyonu gibi görsel özellikler incelenebilir. Örneğin, bir öğrencinin başka bir öğrencinin sınav kağıdına bakması veya cep telefonu kullanması gibi şüpheli davranışlar bu aşamada tespit edilebilir. CNN, bu görsel ipuçlarını öğrenir ve her bir kareyi bu özelliklere göre sınıflandırır.

Zamansal Akış CNN ise işlenmiş video karelerini bir zaman çizelgesi boyunca analiz etmek için kullanılır. Bu, belirli davranış kalıplarını tespit etmek için oldukça kritik bir adımdır. Örneğin, bir öğrencinin uzun bir süre boyunca başka bir öğrencinin sınav kağıdına bakması veya bir cihazda sürekli yazması gibi daha karmaşık kopya biçimlerini tespit etmek için kullanılır. Zamansal Akış CNN, her bir kare arasındaki ilişkileri modellemek ve bu davranış kalıplarını öğrenmek için özel olarak tasarlanmıştır. Bu, öğrencilerin uzun vadeli kopya girişimlerini veya sürekli şüpheli davranışları tespit etmek için son derece faydalıdır ve sadece tek bir karede bulunmayan ancak bir dizi karede görülen davranışları analiz edebilir.

Bu iki akışın çıktıları daha sonra birleştirilir ve bir son sınıflandırıcıya beslenir. Sınıflandırıcı, öğrencinin davranışının şüpheli olup olmadığını belirler. Bu

sınıflandırma, eğitilmiş bir model tarafından yapılır ve belirli davranış kalıplarına veya nesnelere dayalı olarak bir sonuç üretir. Örneğin, bir öğrencinin sınav sırasında belirli bir süre boyunca sürekli olarak başka bir öğrencinin sınav kağıdına bakması veya belirli yasaklı nesnelere kullanması gibi davranışları tespit etmek için kullanılabilir. Bu sonuçlar, eğitim kurumları veya sınav denetleyicileri tarafından değerlendirilerek uygun önlemlerin alınmasına yardımcı olabilir.

Sonuç olarak, bu karmaşık video analizi yaklaşımı, eğitim kurumlarına ve sınav denetleyicilerine öğrencilerin dürüstlüğüne koruma ve kopya çekme girişimlerini tespit etme konusunda güçlü bir araç sunar. Ayrıca, genel görsel veri analizi ve davranış izleme uygulamalarında da büyük bir potansiyele sahiptir ve farklı endüstrilerde güvenlik ve izleme amaçları için uyarlanabilir.

Faster R-CNN, nesne tespiti sürecini oldukça etkili bir şekilde gerçekleştiren gelişmiş bir derin öğrenme tabanlı algoritmadır. Bu algoritma, nesne tespiti aşamasını iki temel adıma böler ve her aşamada özel görevlere odaklanır.

- İlk aşama, Bölge Öneri Ağı (RPN) adı verilen bir alt ağ kullanır. RPN, temel amacı nesne sınırlarını tahmin etmek ve olası nesne konumlarını öneriler halinde sunmaktır. Bu aşamada, girdi olarak alınan evrişimli özellik haritaları üzerinde kaydırarak çalışır ve her bir öneriye bir "bağlama kutusu" atanır. Bu bağlama kutusu, potansiyel nesne bölgelerini çerçevelemek için kullanılır ve bu bölgelerin ne tür nesnelere içerdiğini sınıflandırmak için sonraki aşamada kullanılır. RPN, birçok farklı boyutta ve oranlarda öneriler üretebilir, bu da nesnelere farklı boyutları ve konumları için duyarlılık sağlar. Bu şekilde, algoritma çeşitli nesne boyutları ve konumlarına uygun öneriler üretebilir.
- İkinci aşama, RPN tarafından üretilen nesne önerilerini kullanarak nesne tespiti yapar. Bu aşamada, her öneri bölgesini daha ayrıntılı bir şekilde incelemek ve içerdikleri nesnelere sınıflandırmak için kullanılır. Bu adım, bir Faster R-CNN dedektörü tarafından gerçekleştirilir. Dedektör, her bölgenin özelliklerini çıkarmak için bir özellik çıkarma ağı kullanır ve bu özellikleri nesnelere sınıflandırılması ve sınırlarının kesin olarak belirlenmesi için kullanır. Sonuç olarak, her bölge nesne sınıflandırması ve sınırlarının tahmin edilmesi ile ilgili bilgilere sahip oluruz.

Faster R-CNN'nin bu iki aşaması, nesne tespiti sürecini son derece etkili bir şekilde gerçekleştirir. İlk aşama sayesinde, çok sayıda nesne önerisi üretilir ve ikinci aşamada bu öneriler daha ayrıntılı bir analize tabi tutulur. Bu, nesne tespiti doğruluğunu artırırken hesaplama maliyetini azaltır.



Şekil 3.3 Faster R-CNN ile kopyasız normal durumu belirleme

$$L(\{p_i\}, \{t_i\}) = \frac{1}{N_{cls}} \sum_i L_{cls}(p_i, p_i^*) + \lambda \frac{1}{N_{reg}} \sum_i p_i^* L_{reg}(t_i, t_i^*). \quad (3.2)$$

Burada i , mini toplu bir çapanın indeksidir ve p_i , i çıpasının bir nesne olmasının tahmin edilen olasılığıdır. Temel gerçek etiketi, çapa pozitif ise 1, negatif ise 0'dır. t_i , tahmin edilen sınırlayıcı kutunun dört parametrelili koordinatlarını temsil eden bir vektördür ve pozitif bir çapa ile ilişkili temel gerçek kutusunun koordinatlarıdır. Sınıflandırma kaybı, iki sınıf (nesne ve nesne değil) üzerindeki log kaybıdır. Regresyon kaybı için $(,) = R(-)$ kullanılır; burada R , (2)'de tanımlanan tutarlı kayıp fonksiyonudur (düzgün L1). Terim, regresyon kaybının yalnızca pozitif çapalar ($= 1$) için etkinleştirildiği ve aksi takdirde ($= 0$) devre dışı bırakıldığı anlamına gelir. cls ve reg katmanlarının çıktıları sırasıyla $\{p_i\}$ ve $\{t_i\}$ 'den oluşur. İki terim ve ile normleştirilir ve bir dengeleme parametresi λ ile ağırlıklandırılır. Mevcut uygulamamızda (yayınlanan kodda olduğu gibi), Eşitlik (2)'deki cls terimi

mini toplu boyutu (yani, = 256) ile normalleştirilir ve reg terimi çapa konumlarının sayısı (yani, ~ 2, 400) ile normalleştirilir. Varsayılan olarak $\lambda = 10$ olarak ayarlanmıştır ve böylece hem cls hem de reg terimleri kabaca eşit ağırlıklandırılmıştır. Sonuçların geniş bir aralıkta λ değerlerine karşı duyarsız olduğunu deneylerle gösteriyoruz. Ayrıca, yukarıdaki gibi normalleştirmenin gerekli olmadığını ve basitleştirilebileceğini de not ediyoruz. Sınırlayıcı kutu regresyonu için, dört koordinatın parametrizasyonlarını aşağıdaki gibi benimsiyoruz:

$$\begin{aligned}
t_x &= (x - x_a) / w_a, \quad t_y = (y - y_a) / h_a, \\
t_w &= \log(w / w_a), \quad t_h = \log(h / h_a), \\
t_x^* &= (x^* - x_a) / w_a, \quad t_y^* = (y^* - y_a) / h_a, \\
t_w^* &= \log(w^* / w_a), \quad t_h^* = \log(h^* / h_a),
\end{aligned} \tag{3.3}$$

Burada x , y , w ve h kutunun merkez koordinatları ile genişlik ve yüksekliğini göstermektedir. x , y ve h değişkenleri sırasıyla tahmin edilen kutu, bağlantı kutusu ve temel gerçek kutusu içindir (aynı şekilde y ; w ; h için). Bu, bir çapa kutusundan yakındaki bir yer-gerçek kutusuna sınırlayıcı kutu regresyonu olarak düşünülebilir.

Faster R-CNN algoritması, nesne tespiti alanında önemli bir ilerleme olarak kabul edilir ve özellikle küçük nesnelerin tespitinde oldukça başarılıdır. Bu, kopya davranışlarının tespitinde büyük bir potansiyele işaret eder, çünkü telefonlar veya notlar gibi küçük nesneler genellikle sınav kopyalarının temel unsurlarıdır. Ancak, bu teknik henüz gerçek dünya uygulamalarında yaygın olarak kullanılmamaktadır ve araştırma aşamasında bulunmaktadır. Ayrıca, kopya davranışlarını etkili bir şekilde tespit etmek için yüksek kaliteli verilere ihtiyaç vardır ve bu verilerin elde edilmesi ve geliştirilmesi zor olabilir.

Diğer bir nesne tespiti yöntemi olan YOLOv5, tek bir evrişimli sinir ağı (CNN) kullanarak nesnelere aynı anda tespit etme yeteneğine sahiptir. Faster R-CNN gibi iki aşamalı bir işlem hattı kullanmak yerine, YOLOv5 tüm görüntüyü tek bir seferde işler. Bu, gerçek zamanlı işlemeye izin verir ve cep telefonu veya kitap gibi kopya ile ilişkilendirilebilecek nesnelerin hızlı bir şekilde tespit edilmesini sağlar. Bu özellik, sınav sırasında gerçek zamanlı izleme veya denetim için son derece faydalı olabilir.

YOLOv5'in çalışma prensibi, görüntüyü bir hücre ızgarasına böler ve her hücrenin sınıf olasılıklarıyla birlikte bir dizi sınırlayıcı kutu tahmin etmesini içerir. Bu, YOLOv5'in videolar üzerinde gerçek zamanlı olarak çalışabilmesini sağlar, bu da sınav sırasında kopya davranışlarının anında tespit edilmesine yardımcı olabilir. Ancak, YOLOv5 de diğer teknikler gibi yüksek kaliteli veriye ihtiyaç duyar ve bu verilerin temini zor olabilir. Ayrıca, hesaplama kaynakları gerektirir ve çevresel faktörlere karşı hassas olabilir.

Eğitim prosedürü, modelin başarı oranını artırmak için oldukça önemlidir. YOLOv5'de, çapraz entropi kaybı kullanılarak eğitim yapılır. Bu kayıp fonksiyonu, iki olasılık dağılımı arasındaki mesafeyi ölçer ve sınıf tahminlerinin doğruluğunu artırır. Ayrıca, modelin optimize edilmesi için Adam Eniyileyici gibi güçlü bir optimizasyon yöntemi ve modelin performansı ölçülmek için doğruluk metriği kullanılmaktadır.

Son olarak, modelin performansını artırmak için veri artırımı yöntemleri kullanılabilir. Bu, eğitim örneklerini rastgele dönüştürerek daha fazla çeşitlilik eklemeyi içerir. Örneğin, görüntüleri kırmak, ölçeklemek, yansıtmak veya renk değiştirmek gibi işlemlerle veri artırımı yapılabilir. Bu, modelin daha genelleştirilebilir hale gelmesine yardımcı olabilir ve daha geniş bir nesne tespiti uygulama yelpazesi için daha iyi sonuçlar elde etmeye yardımcı olabilir.

Önerilen model, sınav ortamındaki şüpheli faaliyetleri tanımak ve sınıflandırmak için bir derin öğrenme yaklaşımı kullanır. Bu tür bir problemi çözmek için kullanılan temel mimari, CNN tabanlıdır. Bu, görüntü verilerini işlemek ve anormal davranışları tespit etmek için güçlü bir araçtır. Özellikle, Inception-v3 adlı bir CNN mimarisi kullanılarak eğitilmiştir. Bu, önceden eğitilmiş bir modelin (transfer öğrenme) veri kümesi ile özelleştirilmesini ve daha iyi sonuçlar elde etmesini sağlar.

Anormallik tespiti, özellik çıkarımı ve anormallik tespit modelinin kullanılması gereken iki temel bileşeni içerir. Bu iki bileşen, sırasıyla, davranışın belirli özelliklerini çıkarmak ve bu özelliklere dayalı olarak anormalliği tespit etmekle görevlidir. İlk adımda, videonun fiziksel ve zaman aralıklarına göre segmentasyon yapılır. Bu, hedef bölgenin daha iyi anlaşılmasına yardımcı olan özelliklerin

çıkarılmasına olanak tanır. Eğitim aşamasında, bu özellikler kullanılarak normal davranış modellenir ve bu model öğrenilir.

Test aşamasında, belirtilen özellikteki anormal davranışın tespiti için öğrenilen normal davranış modeli kullanılır. Bu aşamada, test edilen davranışın anormal olup olmadığını belirlemek için özelliklerin anormallik seviyeleri hesaplanır. Özellik çıkarma ve anormal davranış tespiti modelleme ve sınıflandırma süreçleri, anormal davranışın tespitinde kritik öneme sahiptir ve modelin başarısını büyük ölçüde etkiler.

Modelin geliştirilmesi için Keras [58], derin öğrenme mekanizmalarına sahip bir üst düzey sinir ağı API'si olarak kullanılmıştır. Keras, modelin daha hızlı ve modüler bir şekilde geliştirilmesini sağlar ve görüntü işleme ve analiz için özel olarak tasarlanmış CNN gibi özelliklerle desteklenir. Ayrıca, bu uygulamanın hem CPU'lar hem de GPU'lar ile uyumlu çalışmasını sağlar, bu da yüksek performans ve ölçeklenebilirlik sağlar.

Bu gelişmiş model, sınav ortamındaki şüpheli faaliyetleri tespit etmek ve sınıflandırmak için güçlü bir araç sunar. Anormal davranışların hızlı ve hassas bir şekilde tanımlanması, eğitim kurumları ve sınav denetleyicileri için çok önemlidir ve bu model bu amaçla kullanılabilir bir çözüm sunar. Ayrıca, bu tür uygulamaların geliştirilmesi, derin öğrenme ve görüntü işleme alanlarındaki araştırmalara ve teknolojik ilerlemelere de katkı sağlar.

3.3.1 Kalıntı ağlar

Çalışmada, ResNet-50 mimarisini hem sınıflandırma hem de transfer öğrenme için kullanıyoruz. LeNet ailesinin mimarisi, derin öğrenme alanındaki erken dönemdeki bir dönüm noktası olmuştur. Ancak, LeNet ve onun gibi standart CNN mimarileri, sınırlı sayıda katmanla sınırlıdır ve karmaşık verileri öğrenme yetenekleri sınırlıdır. Ayrıca, bu tür basit mimariler, derin ağlarda karşılaşılan kaybolan gradyan sorununa daha duyarlıdır. Bu, çok katmanlı ağlarda eğitim sırasında gradyanların kaybolması veya patlaması gibi sorunları ifade eder. Bu tür sorunlar, daha derin ağların eğitimini zorlaştırabilir ve performanslarını düşürebilir.

ResNet, bu sorunları ele almak için geliştirilmiş bir derin öğrenme mimarisi örneğidir. ResNet ayrıca, katmanların arasına eklenen kalıntı bağlantıları sayesinde kaybolan gradyan sorununu aşmaktadır. Kalıntı bağlantıları, bir katmandan

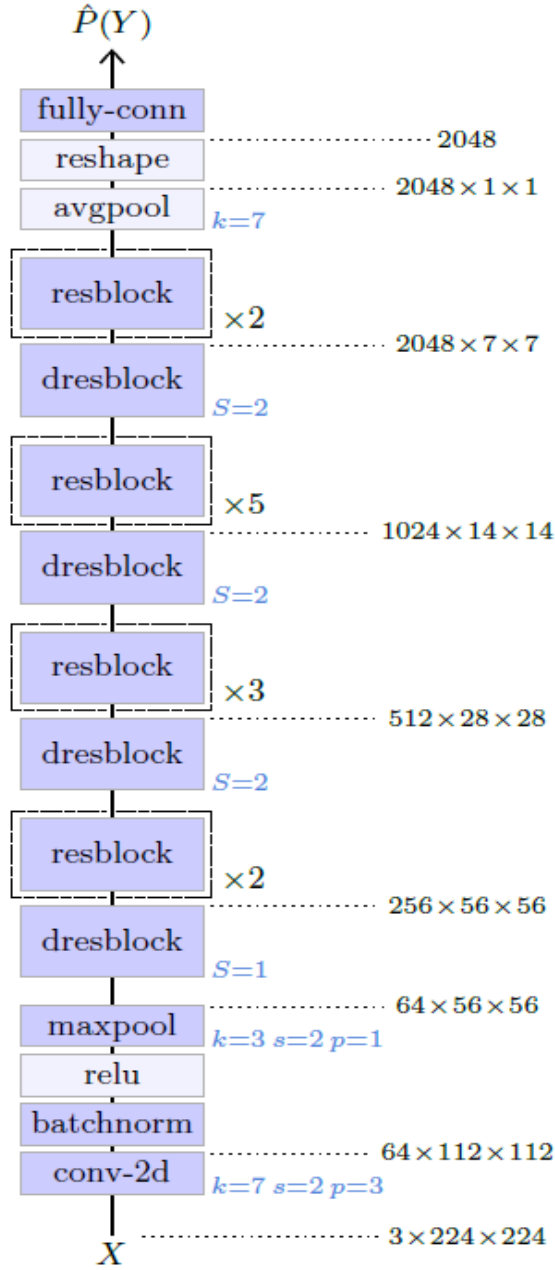
diğerine doğrudan bağlantılar oluşturarak, gradyanların daha kolay bir şekilde geriye yayılmasını sağlar. Bu, ağın daha derin olmasını mümkün kılar. ResNets, özellikle bilgisayarla görme uygulamaları için standart mimariler haline gelmiştir ve farklı sayıda katmanları olan birçok versiyona sahiptir. Örneğin, ResNet-50, 50 katmana sahip bir derin ağ modelini ifade eder ve büyük ve karmaşık veri kümesi üzerinde etkileyici sonuçlar verir.

Çalışmada, ResNet-50 mimarisi hem sınıflandırma hem de transfer öğrenme görevleri için kullanılmaktadır. Bu, ResNet-50'nin çok amaçlı bir model olduğunu gösterir. Sınıflandırma görevlerinde, ResNet-50, farklı nesnelere veya sınıfları tanımlamak için kullanılabilir. Transfer öğrenme ise önceden eğitilmiş bir modelin bilgilerini yeni bir görevde kullanmayı içerir. Bu, özellikle veri miktarı sınırlı olduğunda veya özel bir uygulama için özelleştirilmiş bir model oluşturmanın zor olduğu durumlarda faydalıdır. ResNet-50 gibi güçlü bir model, bu tür görevlerde verimli bir şekilde kullanılabilir ve daha yüksek başarı oranlarına ulaşmanıza yardımcı olabilir.

Sonuç olarak, ResNets gibi derin öğrenme mimarileri, CNN dünyasında önemli bir evrimi temsil eder. Kaybolan gradyan sorununa getirdiği çözümlerle daha derin ve daha etkili ağların inşa edilmesini mümkün kılar ve birçok bilgisayarla görme uygulamasında kullanılır hale gelir. Bu, derin öğrenmenin daha geniş bir alanı kapsayarak daha fazla veri işleme ve analiz görevini başarılı bir şekilde gerçekleştirmesine olanak sağlar.

$$x_{i+1} = \sigma\left(x_i + F\left(x_i; W_i\right)\right) \quad (3.4)$$

Burada x_i ve x_{i+1} sırasıyla ağın birinci katmanının giriş ve çıkışıdır. $F(x_i; W_i)$, CNN filtrelerinin ağırlığının doğrusal olmayan artık eşlemesidir.



Şekil 3.4 ResNet ön eğitilmiş ağı

ResNet-50, üç kanallı giriş görüntüsünü yarı boyutta 64 kanallı bir görüntüye dönüştüren 7×7 evrişimli bir katmanla başlar, ardından dört bölümlük artık blokları gelir. Son artık bloğun çıktısı $2048 \times 7 \times 7$ 'dir ve bu çıktı 7×7 boyutunda ortalama bir çekirdek havuzlamasıyla 2048 boyutunda bir vektöre dönüştürülür ve ardından burada 5 sınıf için nihai logitleri elde etmek üzere tam bağlantılı bir katmanda işlenir.

Sınırlayıcı kutu eşleşmeleri içermeyen diğer her eksen, "nesne yok" sınıfını tahmin etmek için yalnızca çapraz entropi cezasına neden olur. nesne tespiti için eğitim veri

setlerinin oluşturulması, sınırlayıcı kutularla etiketleme gerekliliği nedeniyle oldukça zahmetli ve zaman alıcı bir süreçtir. Ayrıca, bu süreç insan müdahalesi gerektirir ve bu da ek iş yükü ve maliyetlerle sonuçlanabilir. Bu sorunu hafifletmek ve nesne tespiti modelinin eğitimini daha verimli hale getirmek için standart bir yaklaşım kullanılır.

Bu yaklaşım, önceden eğitilmiş büyük bir sınıflandırma veri kümesi üzerinde çalışan bir evrişimli modelle başlar. Örneğin, ResNet gibi güçlü bir evrişimli ağ modeli tercih edilir. Bu modeller, genellikle genel nesne tanıma görevleri için öğrenilmiş genel özellikleri temsil ederler. Ancak, nesne tespiti için kullanılmadan önce bazı değişikliklere ihtiyaç duyarlar.

Bu modeldeki değişiklikler, modelin sonundaki tam bağlantılı katmanların, yeni nesne tespiti görevine uygun hale getirilmesini içerir. Bu, tam bağlantılı katmanların yerine ek evrişimli katmanlar eklenerek gerçekleştirilir. Bu yeni katmanlar, özellikle nesne tespiti için gerekli olan geometrik özellikleri öğrenmek üzere tasarlanmıştır. Örneğin, sınırlayıcı kutuların boyutları ve konumları gibi geometrik bilgileri öğrenmek bu katmanların görevlerindedir.

Eğitim süreci sırasında, her sınırlayıcı kutu, temel özelliklere dayalı olarak belirli bir nesneyi temsil ettiği sınıflandırma veri kümesi ile ilişkilendirilir. Bu, her sınırlayıcı kutunun, ilgili nesneyi tanımlamak için kullanılacak olan özelliklerin temsilcisi olduğu anlamına gelir. Ayrıca, her bir sınırlayıcı kutu için, nesne varlığını tahmin etmek ve sınırlayıcı kutunun doğru boyutları ve konumunu tahmin etmek üzere iki farklı kayıp terimi kullanılır.

Sınırlayıcı kutu eşleşmeleri içermeyen her bir ekseninde, "nesne yok" sınıfını tahmin etmek için yalnızca çapraz entropi kaybı uygulanır. Bu, bir nesnenin belirli bir sınırlayıcı kutuyla ilişkilendirilmediği durumları ifade eder. Bu şekilde, model, nesne tespiti görevini gerçekleştirebilmek için gerekli olan sınırlayıcı kutuları ve özellikleri öğrenir. Eğitim sırasında, her temel gerçek sınırlayıcı kutu eksenleriyle ilişkilendirilir ve logitler için çapraz entropi kaybından ve sınırlayıcı kutu koordinatları için Ortalama Kare Hata gibi bir regresyon kaybından oluşan bir kayıp terimine neden olur.

Sonuç olarak, bu yaklaşım, önceden eğitilmiş sınıflandırma modellerini nesne tespiti görevlerine uyarlayarak verimli bir yol sunar. Bu, nesne tespiti için daha az

etiketleme işlemini gerektirirken, aynı zamanda eğitim sürecinin daha hızlı ve maliyet açısından daha verimli olmasını sağlar. Bu yöntem, nesne tespiti modellerinin daha hızlı geliştirilmesini ve geniş veri kümeleri üzerinde daha iyi performans göstermesini sağlar.

3.4 Model Özellikleri ve Eğitim Detayları

Seçilen modeller, YOLOv5 ve Faster R-CNN, özenle belirlenmiş ayarlarla kurulmuş ve sınıf sınavındaki anormallik tespit sürecindeki performanslarını optimize etmek için titiz bir eğitim sürecinden geçirilmiştir. Bu eğitim süreci, bu iki modelin nesne tespiti ve anormallik algılama görevlerini en üst düzeye çıkarmak için çeşitli önemli adımları içermiştir.

İlk olarak model eğitimi için kullanılan veri kümesi dikkatlice seçilmiştir. Bu veri kümesi, sınav sırasındaki potansiyel anormallik durumlarını içeren zengin ve çeşitli içeriğe sahip olmalıdır. Veri kümesinin doğru bir şekilde etiketlenmesi ve sınıflandırılması, modelin bu anormallik durumlarını doğru bir şekilde tanımasını sağlamak için hayati önem taşır.

Eğitim aşamasında, modelin öğrenmesi gereken özelliklerin belirlenmesi için özel bir özellik mühendisliği aşaması vardır. Bu, sınav sırasındaki potansiyel anormallik işaretlerini temsil eden özelliklerin doğru bir şekilde tanımlanmasını ve modelin bu özellikleri ayırt etmeyi öğrenmesini sağlar.

Ayrıca, eğitim süreci sırasında, modelin hiperparametreleri ve ağırlıkları düzenli olarak ayarlanır ve optimize edilir. Bu, modelin performansını artırmak ve ağırlıkların kaybolmasını veya patlamasını önlemek için önemlidir. Eğitim sırasında kullanılan kayıp fonksiyonları ve optimize edici algoritmalar da bu ayarlamaların bir parçasıdır ve modelin daha hızlı ve daha kararlı bir şekilde eğitilmesini sağlar.

Ayrıca, veri artırımı teknikleri de eğitim sürecinin önemli bir parçasını oluşturur. Bu teknikler, modele daha fazla çeşitlilik ve genelleme yeteneği kazandırmak için kullanılır. Örneğin, veri artırımı, aynı nesne veya olayın farklı açılardan, boyutlardan veya aydınlatma koşullarından görüldüğü çeşitli örneklerin üretilmesini içerebilir.

Son olarak, modelin performansı düzenli olarak doğrulama veri kümesi üzerinde test edilir ve geliştirilir. Bu testler, modelin doğruluk oranını ve anormallik tespit yeteneğini ölçmek için kullanılır. Modelin performansı düzeltilir ve daha iyi sonuçlar elde etmek için gerekli iyileştirmeler yapılır.

Tüm bu adımların birleşimi, YOLOv5 ve Faster R-CNN gibi seçilen modellerin sınıf sınavındaki anormallik tespit görevinde yüksek performans sergilemelerini sağlar. Bu, öğrencilerin kopya davranışlarına karşı daha iyi bir şekilde korunmasına ve eğitim kurumlarının daha etkili bir şekilde denetim yapmasına yardımcı olur.

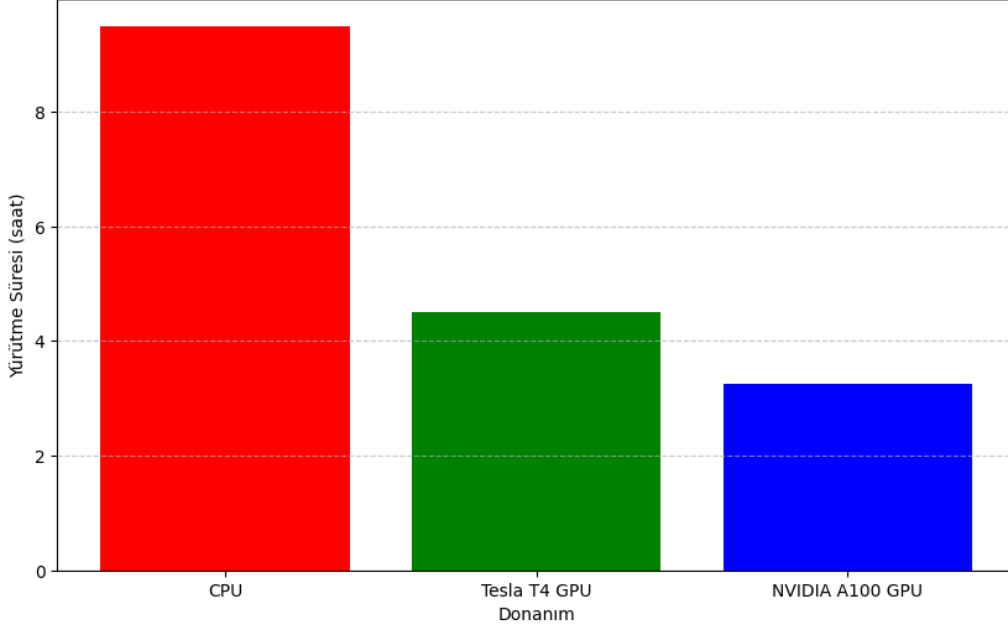
3.4.1 Yürütme Süresi ve Ortamı Detayları

Google Colab, buluttaki hesaplama kaynaklarına ücretsiz erişim sunarak veri bilimciler ve derin öğrenme uygulayıcıları önemli bir araç haline gelmiştir. Colab varsayılan bir CPU çalışma zamanı sunarken, hızlandırılmış hesaplama için Grafik İşlem Birimlerinin (GPU) ve Tensör İşlem Birimlerinin (TPU) muazzam gücünden yararlanmayı sağlamaktadır. Tezimizde, Google Colab GPU'ları ve getirileri adım adım incelenmekte ve CPU'lardan farkları vurgulanmaktadır. Google Colab'da GPU seçeneklerinin kullanılabilirliği, Colab tarafından tahsis edilen kaynaklara bağlı olduğundan zaman içinde değişebilmektedir.

Bu bağlamda Tesla T4 GPU, 2560 CUDA çekirdeği, 16GB GDDR6 bellek ile derin öğrenme uygulamaları için çok uygun hale getiren gelişmiş performans sunar.

NVIDIA A100 GPU ise, 6912 CUDA çekirdeği, 40GB grafik belleği ve 1,6TB/s grafik belleği bant genişliğine sahip olma özelliğiyle daha ileri imkanlar sağlamaktadır. Şekil 3.4'te ilgili ortamlar üzerinde koşturulan COPYNet çerçevesinin yürütme süresi karşılaştırması yer almaktadır.

Bu hızlandırıcılar ve CPU'lar arasındaki farkları anlamak, derin öğrenme iş akışları için uygun donanımı seçerken bilinçli kararlar vermeyi sağlamaktadır.



Şekil 3.5 Yürütme ortamlarının karşılaştırması

3.4.2 YOLOv5 Yapılandırması ve Eğitimi

Model, YOLOv5 için aşağıdaki hiperparametreler ile kurulmuştur:

- Giriş Çözünürlüğü: 416x416 piksel
- Toplu İş Boyutu: 16
- Öğrenme Oranı: 0.001
- Yineleme Sayısı: 100
- Eniyileyici: Adam
- Kayıp Fonksiyonu: Sınırlayıcı kutu regresyonu için Ortalama Karesel Hata (MSE), sınıflandırma için Çapraz Entropi

Eğitim süreci, kopya davranışlarını temsil eden beş farklı gruba ayrılmış yaklaşık 30.000 etiketli görüntü içeren özel bir veri kümesi kullanılarak başlamıştır. Bu veri kümesi, sınav sırasında yaygın olarak görülen potansiyel kopya davranışlarını yansıtan farklı senaryoları içermelidir. Öğrencilerin sınav sırasında çekebileceği kopyaların çeşitliliği göz önüne alındığında, bu veri kümesi bu davranışları yakalamak ve modelin eğitimini sağlamlaştırmak için temel bir bileşen oluşturur.

Eğitim sürecinin ilk adımlarından biri, veri normalizasyonu ve büyütme işlemlerini içeren ön işlemdir. Veri normalizasyonu, görüntü piksellerini belirli bir aralığa ölçeklemek için kullanılır. Bu, modelin öğrenme işlemini hızlandırır ve daha iyi

sonular elde etmesini saęlar. Bytme iřlemi ise grntleri farklı aılardan ve boyutlardan incelemek iin kullanılır. Bu, modelin daha genel ve saęlam bir temel oluřturmasına yardımcı olur.

Eęitim sırasında, modelin ęrenme oranını ynetmek ve ayarlamak iin stel bozunmaya sahip bir ęrenme oranı zamanlayıcısı kullanılmıřtır. Bu, modelin bařlangıta hızlı bir řekilde ęrenmesini ve daha sonra daha kk adımlarla yakınsamasını saęlar. Ayrıca, kayıp ve doęrulama doęruluęu gibi nemli parametreleri izleyerek modelin performansını deęerlendirmek ve izlemek iin bir izleme sistemi oluřturulmuřtur.

Ařırı uyumu nlemek ve modelin daha genelleřtirilebilir olmasını saęlamak iin bir bırakma katmanı eklenmiřtir. Bırakma katmanı, rastgele bir řekilde birimleri devre dıřı bırakarak modelin ęrenme sırasında ařırı uyuma eęilimini azaltır. Bu, modelin eęitim veri setine ařırı uyum yapmasını ve yeni verilere daha iyi uyarlanmasını saęlar.

Son olarak, modelin eęitimi GPU hızlandırması kullanılarak gerekleřtirilmiřtir ve bu sre Google Colab gibi bulut tabanlı platformlar zerinde gerekleřtirilmiřtir. Bu, modelin daha hızlı bir řekilde eęitilmesini saęlar ve yksek hesaplama gcne eriřim saęlar.

Tm bu adımların birleřimi, gl ve saęlam bir modelin oluřturulmasına katkı saęlar. Bu model, sınav sırasındaki kopya davranıřlarını tespit etmek iin kullanılabilir ve eęitim kurumlarının daha etkili bir řekilde sınav denetimi yapmalarına yardımcı olmaktadır.

3.4.3 Faster R-CNN Yapılandırması ve Eęitimi

Faster R-CNN'nin konfigrasyonu ařaęıdaki unsurları iermektedir:

- Omurga: ResNet-50
- Giriř Grnt Boyutu: 600x600 piksel
- apa Oranları: [0.5, 1, 2]
- Toplu İř Boyutu: 8
- ęrenme Oranı: 0.001
- Yineleme Sayısı: 50
- Eniyileyici: Adam

- Kayıp Fonksiyonu: Sınıflandırma için Çapraz Entropi, sınırlayıcı kutu regresyonu için Ortalama Kare Hata (MSE)

Veri kümesi, YOLOv5 gibi güçlü bir nesne tespiti modeli eğitiminde olduğu gibi, veri artırma ve normalleştirmeyi içeren bir ön işleme tabii tutulmuştur. Bu adım, modelin daha iyi genelleme yapabilmesi ve daha güçlü özellikler öğrenebilmesi için önemlidir. Veri artırma, mevcut veri kümesini dönüştürerek yeni örnekler oluşturmayı içerir. Örneğin, görüntüleri döndürme, yansıtma, kesme ve renk değiştirme gibi tekniklerle veri çeşitliliği artırılır. Normalleştirme ise görüntülerin piksel değerlerini belirli bir aralığa ölçeklemeyi içerir. Bu, modelin öğrenme işlemini hızlandırır ve istikrarlı hale getirir.

Eğitim süreci boyunca, iki aşamalı bir işlem hattı kullanılmıştır. İlk aşama, Bölge Öneri Ağı (RPN) olarak adlandırılır ve bu aşamada aday sınırlayıcı kutular oluşturulur. RPN, görüntülerin farklı bölgelerinde potansiyel nesne konumlarını tahmin eder. Ardından, Faster R-CNN modülü, RPN tarafından oluşturulan aday sınırlayıcı kutuları rafine eder. Bu aşama, sınırlayıcı kutuların daha kesin ve doğru hale getirilmesini sağlar.

Eğitim sırasında öğrenme hızı, öğrenme hızları için bir zamanlayıcı kullanılarak ayarlanabilir şekilde ayarlanmıştır. Bu, modelin eğitim sürecinin başlangıcında hızlı bir şekilde öğrenme sağlarken, daha yakınsama aşamasında daha küçük adımlarla ilerlemesini sağlar. Bu, modelin dengeli bir şekilde eğitilmesini sağlar ve aşırı uyum riskini azaltır.

Modelin genelleme yeteneğini artırmak için toplu normalleştirme ve bırakma katmanları eklenmiştir. Toplu normalleştirme, her eğitim örneği üzerinde normalizasyon yaparak öğrenme sürecini daha kararlı hale getirir. Bırakma katmanları ise rastgele birimleri devre dışı bırakarak aşırı uyumu önler.

Son olarak, eğitim süreci, GPU hızlandırması kullanılarak Google Colab'ın GPU altyapısı üzerinde gerçekleştirilmiştir. Bu, modelin daha hızlı bir şekilde eğitilmesini sağlar ve yüksek hesaplama gücüne erişim sağlar. Bu sayede, model daha kısa sürede daha iyi sonuçlar elde eder.

Tüm bu adımların birleşimi, YOLOv5 ve Faster R-CNN gibi güçlü nesne tespiti modellerinin eğitimini optimize eder ve daha etkili sonuçlar elde etmelerini sağlar.

Bu modeller, nesne tespiti görevlerinde yüksek hassasiyet ve performans sergilemektedirler.

3.4.4 Değerlendirme Protokolü

Modelin etkinliğini belirlemek için titiz bir değerlendirme süreci geliştirilmiştir:

- **Metrikler:** Değerlendirme sürecinin temelini metrikler oluşturur. Bu metrikler, modelin performansını objektif bir şekilde değerlendirmek için kullanılır. Hassasiyet, geri çağırma ve F1-skoru, bu metriklerden bazılarıdır. Hassasiyet, modelin pozitif tahminlerinin gerçek pozitiflerle oranını gösterir. Geri çağırma, gerçek pozitiflerin tüm pozitif örnekleri ne kadar kapsadığını gösterir. F1-skoru ise hassasiyet ile geri çağırmanın harmonik ortalamasıdır ve modelin tespit performansının bir ölçüsüdür.

Ayrıca, özellikle çoklu sınıf sınavlarında tespit hassasiyetini ölçmek için Ortalama Hassasiyet (mAP) ve Ortalama Birleşme Üzerinden Kesişim (IoU) gibi özel metrikler de kullanılmıştır. Ortalama Hassasiyet (mAP), farklı sınıf ve öğeler için ayrı ayrı hesaplanan hassasiyetlerin ortalamasıdır ve modelin genel tespit başarısını yansıtır. Ortalama Birleşme Üzerinden Kesişim (IoU), modelin sınırlayıcı kutuların doğru bir şekilde hedef nesnelere nasıl çevrelediğini değerlendirmek için kullanılır. Bu metrikler, modelin tespit doğruluğunu daha ayrıntılı bir şekilde analiz etmemize yardımcı olur.

- **Test Veri Kümesi:** Modelin performansını değerlendirmek ve doğru sonuçlar elde etmek için kullanılan test veri kümesi, herhangi bir yapay zeka modelinin performansının kritik bir göstergesidir. Bu bölümde, test veri kümesinin önemi ve bileşenleri daha ayrıntılı bir şekilde ele alınacaktır.

Test veri kümesi, modelin daha önce görülmemiş verilere ne kadar iyi genelleme yaptığını ölçmek için kullanılır. Bu nedenle, test veri kümesinin kalitesi ve temsilciliği son derece önemlidir. Test veri kümesi, modelin gerçek dünya koşullarında nasıl performans göstereceğini daha güvenilir bir şekilde tahmin etmemizi sağlar.

Test veri kümesi, farklı senaryoları içermelidir. Öğrencilerin sınav sırasında yapabileceği şüpheli davranışları temsil eden çeşitli senaryoları içerir. Bu senaryolar, öğrencilerin sınav kağıtlarına bakmaları, cep telefonları veya

kitaplar gibi yasaklı nesnelere kullanılmaları gibi şüpheli davranışları simüle eder.

Test veri kümesi içerisindeki görüntüler, bu şüpheli davranış senaryolarını açıklar. Her bir görüntü, farklı bir şüpheli davranış senaryosunu temsil eder ve modelin bu senaryoları doğru bir şekilde tanıyıp tanımadığını değerlendirmek için kullanılır. Bu görüntüler, modelin sınav sırasındaki şüpheli davranışları doğru bir şekilde tespit edip etmediğini değerlendirmek için kullanılır.

Test veri kümesi içerisindeki görüntüler, modelin farklı şüpheli davranışları tanıma yeteneğini test etmek için dikkatle seçilir. Ayrıca, görüntülerin gerçek dünya sınav koşullarını yansıtmak şeklinde hazırlanması önemlidir. Bu nedenle, test veri kümesi içerisindeki görüntüler öğrencilerin sınav sırasındaki potansiyel kopya davranışlarını doğru bir şekilde simüle etmelidir.

Tüm bu görüntüler, modelin şüpheli davranışları doğru bir şekilde tespit edip etmediğini değerlendirmek için kullanılır. Test veri kümesi içerisindeki görüntüler, modelin performansını objektif bir şekilde değerlendirmemize yardımcı olan önemli bir öğe olarak önemlidir. Bu görüntüler, modelin gerçek dünya sınav koşullarında nasıl performans göstereceğini daha iyi anlamamıza yardımcı olur.

- **Maksimum Olmayan Bastırma:** Maksimum olmayan bastırma, nesne tespiti modellerinde yaygın olarak kullanılan ve sonuçların kalitesini artıran önemli bir tekniktir. Maksimum olmayan bastırmanın temel amacı, nesne tespiti sırasında gereksiz sınırlayıcı kutuları azaltmak ve nesnelerin daha doğru bir şekilde sınıflandırılmasını sağlamaktır. Bu teknik, modelin lokalizasyon doğruluğunu artırarak nesnelere daha iyi çerçevelemesine yardımcı olur.

Maksimum olmayan bastırma, tespit edilen nesnelerin belirli bir güven eşiğini aşan sınırlayıcı kutularını tutar ve diğerlerini eler. Bu, modelin yüksek güvene sahip tahminleri korumasına ve düşük güvene sahip tahminleri elemesine olanak sağlar. Sonuç olarak, daha temiz ve doğru sonuçlar elde edilir.

Maksimum olmayan bastırma sırasında kullanılan güven eşiği, modelin tespit hassasiyetini ve özgüllüğünü etkiler. Bu nedenle, ideal bir güven eşiği bulmak önemlidir. Dikkatlice ayarlanmış bir güven eşiği, modelin istenmeyen yanlış pozitifleri azaltmasına ve yalancı tespitleri en aza indirmesine yardımcı olur.

Maksimum olmayan bastırma, nesne tespiti modelinin performansını önemli ölçüde iyileştirebilir. Gereksiz sınırlayıcı kutuların azaltılması, modelin daha hızlı çalışmasına ve daha hassas sonuçlar elde etmesine olanak tanır. Bu, modelin kullanılabilirliğini ve güvenilirliğini artırır.

Maksimum olmayan bastırma, nesne tespiti alanında yaygın olarak kullanılan bir tekniktir ve birçok başarılı modelde bulunur. Bu teknik, nesne tespiti modelinin sonuçlarını iyileştirirken aynı zamanda hesaplama kaynaklarını daha verimli bir şekilde kullanmasına yardımcı olur. Bu nedenle, maksimum olmayan bastırma, nesne tespiti uygulamalarında vazgeçilmez bir rol oynamaktadır.

- **Eşik Ayarlama:** Eşik ayarlama, nesne tespiti ve sınıflandırma modellerinin performansını etkileyen kritik bir parametredir. Bir modelin tahminlerini değerlendirmek ve sonuçları şekillendirmek için kullanılan bir mekanizmadır. Bu mekanizma, bir tahminin kabul edilebilir bir güven düzeyini aşması gerektiği eşiğini belirlemek için kullanılır. Eşik, bir nesnenin ne kadar güçlü bir şekilde tespit edilmesi gerektiğini ve modelin tahminlerini hangi güven seviyelerine göre filtreleyeceğini belirler.

Eşik ayarlama, bir güven eşiği belirleyerek çalışır. Bu güven eşiği, modelin tahminlerini değerlendirmek için kullanılır. Örneğin, bir nesne için belirli bir güven değeri belirlediğinizde, model sadece bu eşiği aşan tahminleri kabul edecektir. Diğer tahminler, bu eşiği karşılamadığı için reddedilecektir.

Eşik ayarlama, modelin performansını şekillendiren önemli bir parametredir. Doğru bir güven eşiği seçimi, modelin hassasiyetini ve özgüllüğünü dengeleyerek istenmeyen yanlış pozitifleri ve yanlış negatifleri en aza indirebilir. Bu, modelin daha doğru sonuçlar üretmesine yardımcı olur.

Bununla birlikte eşik ayarlama, optimize edilmesi gereken bir parametre olarak karşımıza çıkar. Modelin performansını en iyi şekilde şekillendirmek için dikkatlice ayarlanmalıdır. Bu, modelin kullanılabilirliği ve güvenilirliği açısından kritik bir öneme sahiptir.

Eşik ayarlama, nesne tespiti ve sınıflandırma modellerinin birçok uygulamasında kullanılır. İstenen sonuçları elde etmek ve modelin belirli bir uygulamada başarılı olmasını sağlamak için doğru eşikleri belirlemek önemlidir. Bu nedenle, eşik ayarlamasının önemi ve etkisi göz ardı edilmemelidir.

- Temel Teknikler ile Karşılaştırma: Modelin üstün olduğunu göstermek için performans, literatürde yaygın olarak kullanılan temel tekniklerle karşılaştırılmıştır. Temel teknikler ile karşılaştırma, nesne tespiti ve sınıflandırma modellerinin performansını değerlendirmek ve modelin ne kadar etkili olduğunu anlamak için kritik bir adımdır.

Temel teknikler, nesne tespiti alanında yaygın olarak kullanılan ve iyi bilinen yöntemleri ifade eder. Bu yöntemler, sınırlayıcı kutu tahminleri, özellik çıkarma, model mimarileri ve öğrenme stratejileri gibi temel bileşenleri içerir. Temel teknikler ile karşılaştırma, modelin bu temel bileşenlere göre nasıl performans gösterdiğini belirlemek için yapılır.

Karşılaştırmada kullanılan metrikler, modelin performansını değerlendirmek için önemlidir. Hassasiyet, geri çağırma, F1-skoru ve Ortalama Hassasiyet (mAP) gibi metrikler, modelin tespit doğruluğunu ve sınıflandırma yeteneğini ölçmek için kullanılır. Bu metrikler, temel tekniklerin karşılaştırılmasında objektif bir temel sağlar.

Temel teknikler ile karşılaştırma sonuçları, modelin performansını değerlendirmek ve hangi yöntemlerin daha iyi çalıştığını anlamak için incelenmelidir. Bu inceleme, modelin güçlü yönlerini ve zayıf yönlerini belirlemeye yardımcı olur. Ayrıca, belirli bir uygulama için en uygun tekniklerin seçilmesine yardımcı olmaktadır.

Temel teknikler ile karşılaştırma, modelin daha iyi performans göstermesi için bir yol haritası çıkarmaya da yardımcı olmaktadır. Hangi bileşenlerin daha fazla iyileştirme potansiyeline sahip olduğunu belirlemek, modelin geliştirilmesi için kritik öneme sahiptir. Bu nedenle, temel teknikler ile karşılaştırma, modelin optimize edilmesine ve daha iyi sonuçlar elde etmesine yardımcı olabilir.

Temel teknikler ile karşılaştırma, nesne tespiti ve sınıflandırma modellerinin performansının değerlendirilmesinde vazgeçilmez bir adımdır. Modelin gerçek dünya uygulamalarında ne kadar etkili olduğunu anlamak için temel tekniklerle karşılaştırma yapılmalıdır. Bu, modelin güvenilirliğini ve uygulanabilirliğini artırmaktadır.

Modellerin sınıf sınavları sırasında şüpheli faaliyetleri tespit etme ve kategorize etmedeki etkinliği, bu değerlendirme süreci sıkı bir şekilde takip edilerek ölçülmüştür. Sürecin başlangıcında, belirli sınav koşullarında neyin şüpheli olarak kabul edileceği net bir şekilde tanımlanmıştır. Veri toplama ve etiketleme

aşamasında, uygun veriler toplanarak farklı şüpheli davranışları içeren bir veri kümesi oluşturulmuştur. Model eğitimi sırasında, bu veri kümesi kullanılarak modellerin şüpheli faaliyetleri tanıma yetenekleri geliştirilmiştir. Değerlendirme sürecinde, hassasiyet, geri çağırma, F1-skoru ve Ortalama Hassasiyet (mAP) gibi metrikler kullanılarak modellerin performansı ölçülmüştür. Değerlendirme sonuçları, modellerin şüpheli faaliyetleri ne kadar etkili bir şekilde tespit ettiğini ve kategorize ettiğini göstermiştir. Bu süreç, modellerin güvenilirliğini ve uygulanabilirliğini sağlamak için önemli bir adım olmuştur.

3.5 Algoritmik Karmaşıklık

İlk olarak, algoritmanın performansını veya gereksinimlerini en kötü durumda ne kadar hızlı büyüdüğünü gösteren Büyük O gösterimi cinsinden karmaşıklık ifade edilmiştir.

COPYNet, Faster R-CNN, YOLOv5 ve ResNet gibi bileşenleri içerdiğinden, her bir bileşenin karmaşıklığını ayrı ayrı incelemek gerekmektedir.

Faster R-CNN, nesne tespiti için bir dizi adımı içerir. Önce bir görüntü üzerinde bir dizi sabit boyutlu pencere taranır. Bu adımda, RPN kullanılır ve bu işlem genellikle $O(n^2)$ karmaşıklığa sahiptir, burada n görüntünün boyutudur. Ardından, her bir teklif üzerinde sınıflandırma ve sınırlayıcı kutu regresyonu yapılır. Bu adımların karmaşıklığı genellikle sabit boyutlu bir işlem olarak kabul edilir, yani $O(1)$ 'dir.

YOLOv5 ise, görüntüyü tek bir işlemde işleyerek nesnelere tespit eder. YOLOv5, çok sayıda evrişimsel katman içerir ve genellikle karmaşıklığı, katman başına işlem sayısına bağlıdır. Genel olarak, YOLOv5'in karmaşıklığı $O(n^2.k)$ olarak kabul edilebilir, burada n görüntünün boyutu ve k katman başına işlem sayısıdır.

ResNet'te ise her bir katmanın karmaşıklığı, katmanın parametre sayısına bağlıdır ve genellikle $O(p)$ olarak ifade edilir, burada p parametre sayısıdır.

COPYNet'in genel karmaşıklığını belirlemek için bu bileşenlerin her birinin karmaşıklığını göz önünde bulundurarak bir toplam oluşturmak gerekir. Bu nedenle COPYNet'in karmaşıklığı $O(n^2.k)$ ve ResNet'teki $O(p)$ 'nin büyük olanı kadardır. Ancak, unutulmamalıdır ki pratikte, donanım optimizasyonları ve paralel işleme gibi faktörler bu teorik analizin sonuçlarını etkileyebilir.

3.6 Çerçeve

Yazılımın çalışma sürecini daha ayrıntılı olarak açıklamak gerekirse, öncelikle normal davranışları tanımak için öğrencilerin sınavlar sırasındaki yüz ifadeleri ve baş hareketleri gibi verileri mermi tipi kameralar aracılığıyla toplar. Bu veriler, öğrencilerin tipik sınav davranışlarını anlamak için kullanılır.

Daha sonra yazılım, toplanan bu verileri kullanarak bir makine öğrenimi modelini eğitir. Model, normal davranış kalıplarını öğrenir ve bu kalıpları anormal davranışlardan ayırabilme yeteneği kazanır. Bu eğitim aşaması, modelin doğru ve güvenilir sonuçlar üretebilmesi için oldukça kritiktir.

Sınav sırasında yazılım, öğrencilerin davranışlarını izlemek ve analiz etmek için eğitilen modeli kullanır. Sınavı kaydeder, öğrenci davranışlarını sürekli olarak analiz eder ve herhangi bir şüpheli faaliyeti tespit ederse bu durumu işaretler. Bu, sınav sürecini yakından takip etmek ve anormal davranışları hızlı bir şekilde tespit etmek için kullanışlı bir araçtır.

Eğer yazılım bir öğrencinin davranışlarında anormal bir durum tespit ederse, hemen bir alarm oluşturur. Bu alarm, öğretmenleri veya gözetmenleri daha fazla araştırma yapmaları için uyarır. Bu, öğretmenlere geri bildirim sağlar ve şüpheli davranışların hızlı bir şekilde ele alınmasına yardımcı olur.

Özellikle, ilk iki hatada yazılım sadece sarı bir kart gösterir, bu da "kontrol altında tut" anlamına gelir. Ancak üçüncü hatada, daha ciddi bir adım atılır. Öğrencinin adı ve video görüntüsü, öğrencinin sınavı devam edip etmeyeceğine karar vermesi için öğretmenle paylaşılır.

Son olarak, yazılımın araştırma yapabilmesi için anormal davranışları özetleyen bir rapor oluşturduğunu belirtmek önemlidir. Bu rapor, öğretmen veya gözetmenin kopya çekme veya başka bir şüpheli davranış olup olmadığına karar vermesine yardımcı olur. Bu sayede hızlı ve etkili bir müdahale sağlanır ve sınavın dürüstlüğü korunur.

Şekil 3.6'da gösterilen akış şeması, sınıf içi sınavlarda anormal davranışları tespit etmek amacıyla kullanılacak genel teknoloji ve işlem adımlarını açıklayan önemli bir rehberdir. Bu akış şeması, sınav denetimi ve dürüstlüğünün korunması açısından son derece kritik olan yazılımın işleyişini anlatır.

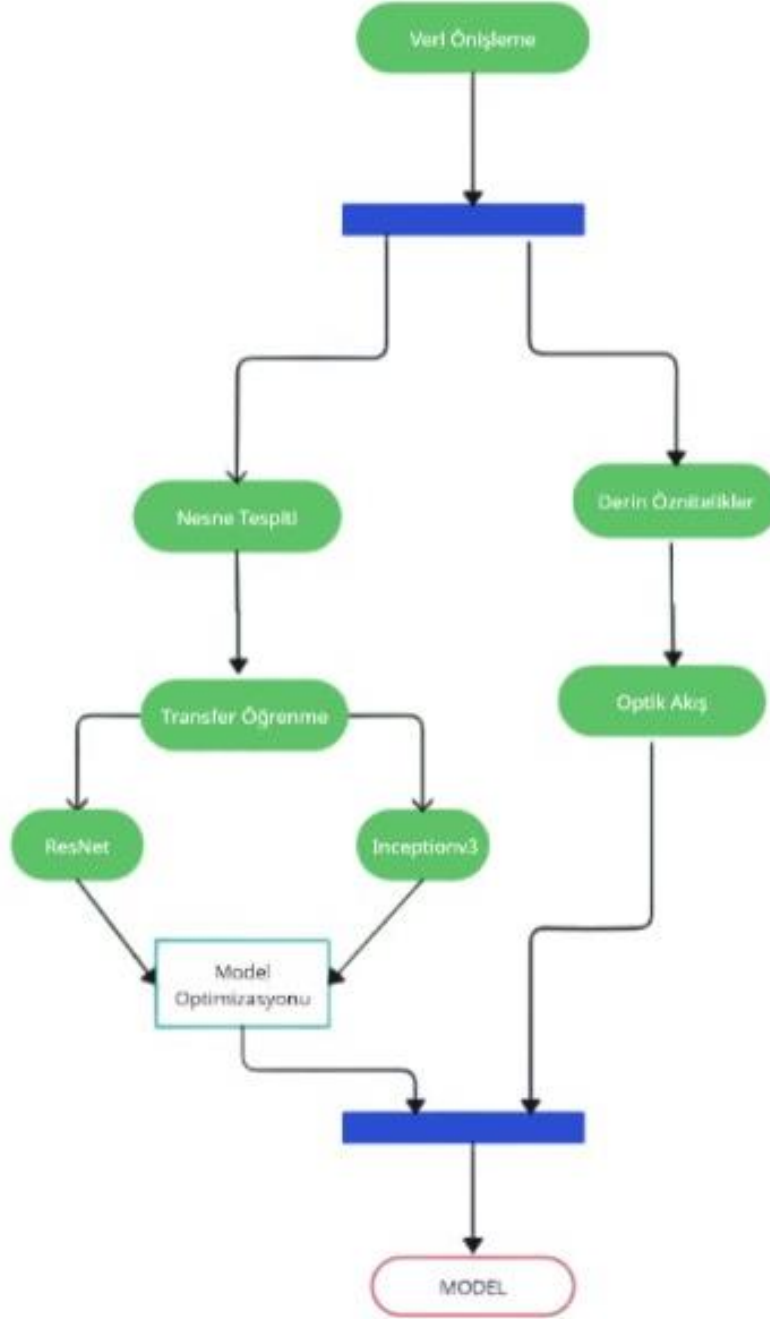
İlk adım, yazılımın öğrencilerin sınavlar sırasındaki normal davranışlarını anlamak için veri toplamakla başlar. Bu veriler, öğrencilerin yüz ifadeleri, baş hareketleri ve genel davranışları gibi normal sınav alışkanlıklarını yakalamak için mermi tipi kameralar kullanılarak elde edilir. Bu veriler, daha sonra kullanılacak olan anormal davranışları tespit etmek için önemli bir temel oluşturur.

Veri toplama aşamasından sonra, yazılım bu verileri kullanarak bir makine öğrenimi modeli oluşturur ve eğitir. Model, öğrencilerin normal davranışlarını tanıyabilme yeteneği kazanır ve bu davranışları anormal durumları ayırt edebilecek bir biçimde öğrenir. Eğitim, modelin doğru sonuçlar üretebilmesi için son derece önemlidir, çünkü bu aşamada normal ve anormal davranışların ayrımı yapılır.

Sınav sırasında yazılım, eğitilen modeli kullanarak öğrencileri izler. Bu model, sınavın her anını dikkatle takip eder ve öğrencilerin davranışlarını analiz eder. Herhangi bir anormal davranış tespit edildiğinde, yazılım hızla bir alarm oluşturur. Bu alarm, öğrencinin kopya çekme veya sınavın kurallarına uymama gibi şüpheli bir faaliyetle ilişkilendirilmiş olabileceğini bildirir.

Alarm oluşturulduktan sonra, öğretmen veya gözetmen daha fazla araştırma yapabilir. Anormal davranışın nedeni ve ciddiyeti incelenir ve bir karara varılır. Eğer şüpheli davranış doğrulanırsa, uygun önlemler alınabilir ve sınavın dürüstlüğü korunabilir.

Son olarak, bu işlem sürecine dayanarak yazılım tarafından anormal davranışı özetleyen bir rapor oluşturulur. Bu rapor, öğretmen veya gözetmenin daha fazla aksiyon alması gerekip gerekmediğini değerlendirmelerine yardımcı olur. Bu nedenle, sınavın güvenliği ve dürüstlüğü açısından kritik olan bu akış şeması, öğrencilerin adil bir sınav ortamında olmalarını sağlama amacıyla etkili bir şekilde çalışır.



Şekil 3.6 COPYNet çerçevesi akış çizelgesi

Veri toplama aşaması, sınıf sınavlarının video görüntülerini toplamayı içerir. Bu görüntüler, sınavın tam bir görüntüsünü sunmanın ötesinde, ses veya metin verileri gibi ek veri kaynakları ile zenginleştirilebilir. Öğrencilerin yüz ifadeleri, kalem hareketleri veya kitap sayfaları gibi önemli ayrıntıları içeren bu veriler, daha sonraki adımlar için kritik bir temel oluşturur. Veri toplama süreci, kameraların

yerleştirilmesi, kayıt cihazlarının yapılandırılması ve veri depolama altyapısının oluşturulmasını içerir. Bu adımın sorunsuz bir şekilde işlemesi, sonraki analizlerin ve öğrenci davranışlarının izlenmesinin anahtarıdır.

Ön işleme adımı, verilerin analiz için hazırlanmasını içerir ve bu süreç görüntü iyileştirme, gürültü giderme ve veri temizleme gibi görevleri içerir. Bu, verilerin daha iyi anlaşılmasını ve daha doğru sonuçlar elde edilmesini sağlar. Özellikle, sınavın düşük ışık koşullarında veya gürültülü bir ortamda gerçekleştiği durumlarda bu adım büyük önem taşır. Ön işleme, verileri düzeltmek ve anlamlı desenleri vurgulamak için çeşitli teknikleri içerebilir. Bu adım, veri toplama aşamasından gelen ham verileri işlenmiş ve kullanıma hazır hale getirilmiş verilere dönüştürür.

Özellik çıkarma adımı, verilerden ilgili özellikleri çıkarma işlemine odaklanır. Bu adım, renk histogramları, kenar algılama, hareket geçmişi görüntüleri veya optik akış gibi veri analitiği tekniklerini içerebilir. Bu özellikler daha sonra bir sonraki adım için girdi olarak kullanılır. Özellik çıkarma, verinin içerdiği bilgileri daha yüksek seviyeli temsilcilere dönüştürür ve bu, makine öğrenimi modelinin daha iyi öğrenmesini ve anormal davranışları tanımlamasını kolaylaştırır.

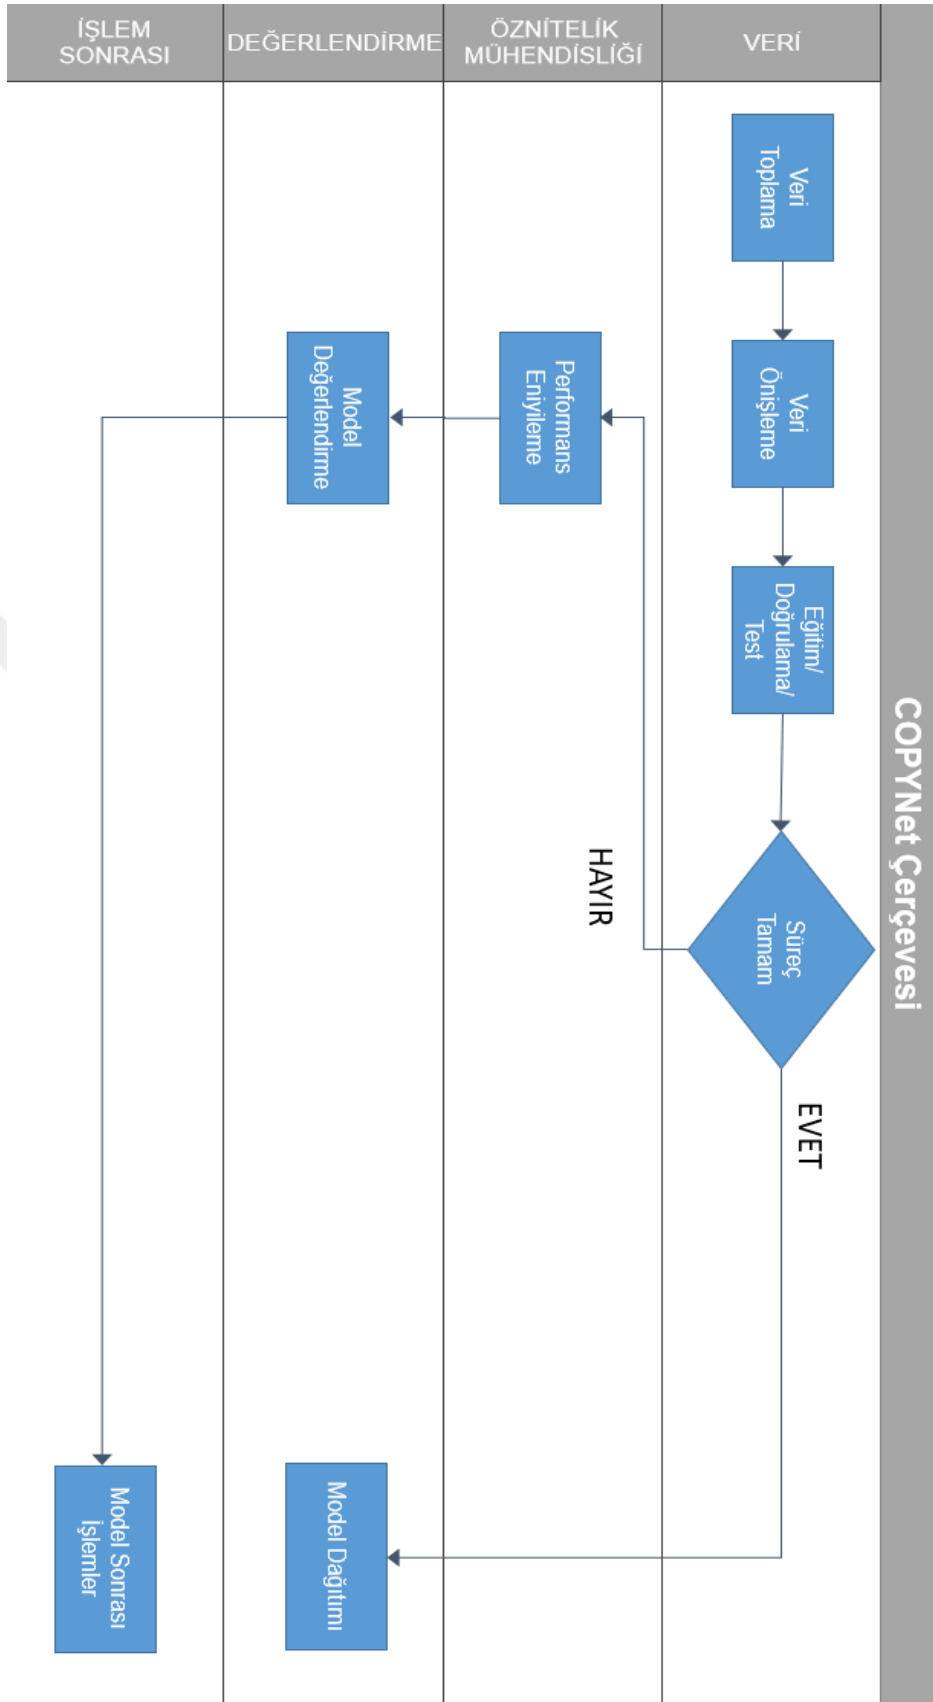
Model eğitimi adımı, çıkarılan özellikleri girdi olarak ve etiketli verileri çıktı olarak kullanarak bir makine öğrenimi modelinin eğitilmesini içerir. Bu adımın amacı, bir öğrencinin kopya çekmesi veya yasaklanmış bir kaynağı kullanması gibi belirli olayları veya durumları tanıyabilen bir model oluşturmaktır. Model eğitimi, veri kümesini eğitim ve doğrulama verilerine bölmeyi, öğrenme algoritmalarını seçmeyi, hiperparametreleri ayarlamayı ve modelin aşırı uyuma karşı direncini artırmak için önlemler almayı içerir. Bu adım, makine öğrenimi modelinin temelini oluşturur ve modelin davranışları üzerindeki etkisi büyüktür.

Model değerlendirme adımı, eğitilen modelin performansını ölçmek için önemlidir. Bu adım, eğitilen modelin görünmeyen verilere karşı nasıl performans gösterdiğini test eder ve metrikler aracılığıyla performansını değerlendirir. Bu metrikler arasında doğruluk, kesinlik ve geri çağırma gibi yaygın ölçütler bulunur. Ayrıca, modelin başarısız olduğu durumları ve sınırlarını anlamak için hataların analiz edilmesi de bu adımın önemli bir parçasıdır. Model değerlendirme sonuçları, modelin sınıf sınavları sırasında nasıl performans göstereceğine dair önemli bilgiler sağlar.

Model dağıtımını adımı, eğitilen modelin gerçek bir dünya senaryosunda kullanılmak üzere dağıtılmasını içerir. Bu, canlı video görüntülerini gerçek zamanlı olarak analiz etmek ve şüpheli davranışları tespit etmek için modelin kullanılmasını içerebilir. Bu adım, modelin çevresel koşullara ve gereksinimlere uygun şekilde dağıtılmasını içerir. Ayrıca, modelin güncel tutulması, performansının izlenmesi ve gerektiğinde yeniden eğitilmesi de bu adımın bir parçasıdır. Modelin saha kullanımı, sınıf sınavlarının güvenliğini artırmak ve anormal davranışları tespit etmek için kritik bir aşamadır.

İşlem sonrası adımı, öğretmenleri herhangi bir şüpheli davranıştan haberdar etmek için veri görselleştirme, olay sınıflandırma ve uyarı oluşturma gibi ek görevleri içerir. Bu adım, modelin sınıf sınavlarında kullanılmasından kaynaklanan verilerin yönetilmesini içerir. Örneğin, model tarafından işaretlenen şüpheli davranışlar, bir olay sınıflandırma sistemi kullanılarak belirli kategorilere atanır. Öğretmenlere veya gözetmenlere bu olaylar hakkında bildirimler gönderilir ve daha fazla inceleme veya müdahale gerektiren olaylar öncelikli olarak ele alınır. İşlem sonrası, sınavın dürüstlüğüne korumak ve geliştirmek için verilerin etkili bir şekilde yönetilmesini sağlar.

Şekil 3.7’de yer alan bu genel çerçeve, sınıf sınavlarında anormal davranışları tespit etmek ve önlemek için kullanılabilecek kapsamlı bir yaklaşımı temsil etmektedir. Ancak, her bir adımın ayrıntıları, kullanılan veri kümeleri ve özel gereksinimler gibi faktörlere bağlı olarak değişebilir. Bu nedenle, her aşamanın titizlikle planlanması ve uygulanması, başarılı bir sınav güvenliği stratejisi oluşturmanın temelidir.



Şekil 3.7 COPYNet çerçevesi

4.1. Optik Akış Analizi

Bu teknik, bir videodaki nesnelerin veya kişilerin hareketini izlemeyi içerir ve bu, özellikle bir öğrencinin uzun bir süre boyunca ekranından uzağa bakması gibi şüpheli davranışları tespit etmek için kullanışlıdır. Çalışmada, bu yöntemin uygulanması bir dizi parametre ayarının programcı tarafından manuel olarak yapılmasını gerektirir. Bu parametreler, renk bilgisi, kenarlar, doku gibi kullanılan özelliklerin sayısına bağlı olarak değişebilir ve optimum sonuçlar elde etmek için dikkatli bir şekilde ayarlanmalıdır.

Optik akış algoritması, hareketin izlenmesi amacıyla Lucas-Kanade yöntemi gibi yöntemler kullanır. Bu algoritma, incelenen pikselin yerel bir komşulukta esasen durağan olduğunu varsayar ve bu komşuluktaki tüm pikseller için temel optik akış denklemlerini en küçük kareler yöntemi kullanarak çözer. Bu sayede nesnelerin veya kişilerin hareketini izlemek ve şüpheli davranışları tespit etmek için bir temel oluşturulur.

$$I_x u + I_y v + I_t = 0 \quad (4.1)$$



Şekil 4.1 Lucas-Kanade optik akış tekniğinin uygulandığı sınıf ortamı.

Denklem 2 optik akışı hesaplamak için bir formüldür, burada (u, v) bilinmemektedir ve f_x ve f_y görüntü gradyanlarının yanı sıra f_t zaman gradyanına da bağlıdır. İki bilinmeyen unsur, tek bir denklemin çözülmesini zorlaştırır. Bu sorun birkaç şekilde çözülebilir. Lucas-Kanade (LK) yaklaşımı bunlardan biridir. LK tekniği, ikinci varsayıma dayalı olarak benzer harekete sahip konumları çevreleyen 3x3 parçalarını dikkate alır:

$$\begin{bmatrix} u \\ v \end{bmatrix} = \begin{bmatrix} \sum_i f_{x_i}^2 & \sum_i f_{x_i} f_{y_i} \\ \sum_i f_{x_i} f_{y_i} & \sum_i f_{y_i}^2 \end{bmatrix}^{-1} \begin{bmatrix} -\sum_i f_{x_i} f_{t_i} \\ -\sum_i f_{y_i} f_{t_i} \end{bmatrix} \quad (4.2)$$

4.2 Öznitelik Mühendisliği Teknikleri


Sınıf sınavları sırasında şüpheli davranışları tespit etmek için kullanılacak çeşitli nesne tespit teknikleri vardır:

- Ölçekle Değişmeyen Öznitelik Dönüşümü (SIFT): SIFT, nesne tespiti ve eşleştirme için kullanılan bir özellik çıkarma yöntemidir. Görüntülerdeki nesnelerin ölçek, rotasyon ve bakış açısındaki değişikliklere karşı dayanıklıdır. Bir görüntüyü analiz etmek için önce ölçek uzayında farklı ölçeklerde görüntü piramitleri oluşturur. Daha sonra bu piramitlerde özellik noktaları bulur ve her bir özellik noktası etrafındaki öznitelik vektörünü hesaplar. Bu özellik vektörleri, nesnelerin tanınmasında ve eşleştirilmesinde kullanılır.
- Hızlandırılmış Sağlam Öznitelik (SURF): SURF, SIFT'e benzer bir özellik çıkarma yöntemidir, ancak daha hızlıdır ve yüksek işlem gücü gerektirmez. SURF, görüntülerdeki özellikleri tanımlamak için özel bir öznitelik hesaplama tekniği kullanır. Bu tekniğin avantajı, yüzeylerin ölçek, rotasyon ve konum değişikliklerine dayanıklı olmasıdır. Bu nedenle nesne tespiti ve eşleştirme görevlerinde tercih edilir.



Şekil 4.2 SURF ile nesne tespiti

- Hızlandırılmış Segment Testinden (FAST) : FAST, köşeleri hızlı bir şekilde tespit etmek için kullanılan bir özellik çıkarma yöntemidir. Köşeler, nesnelerin belirgin özelliklerini temsil ederler. FAST, bir pikselin etrafındaki dokuz piksel grubunu inceleyerek bir pikselin köşe olup olmadığını tespit eder. Bu yöntem, nesne tespiti ve takibi için hızlı ve verimli bir şekilde çalışır.
- Çok Ölçekli Yönlendirilmiş Gradyan (MSOG): MSOG, bir görüntüdeki kenarları birden fazla ölçekte tespit etmek için kullanılan bir özellik çıkarma yöntemidir. Kenarlar, nesnelerin şekillerini ve konturlarını tanımlamak için önemlidir. MSOG, farklı ölçeklerdeki kenarları tespit ederek nesnelerin daha kesin bir tanımını sağlar. Bu yöntem, nesne tespiti ve görüntü analizi için yaygın olarak kullanılır.
- Tek Atış Çoklu Kutu Dedektörü (SSD): Bir görüntü veya videodaki nesnelere tespit etmek için kullanılan gerçek zamanlı bir nesne algılama yöntemidir. SSD, farklı nesne sınıflarını ve bu nesnelerin konumlarını tespit etmek için kullanılır. Birden fazla ölçekte çalışır ve her bir ölçekte nesne kutularını tahmin eder. Nesne algılama uygulamalarında oldukça verimlidir ve yüksek performans sağlar.



Şekil 4.3 SSD ile nesne tespiti

Her bir özellik çıkarma yöntemi, farklı uygulamalara ve işlem gereksinimlerine göre seçilir. Bu yöntemler, nesne tespiti, şüpheli davranış izleme ve daha fazlası gibi birçok görüntü işleme görevinde başarıyla kullanılır.

4.3 Yeni Veri Kümeleri Üzerinde Zamansal Atlamayı Uygulamak

Zamansal atlama, video ve görüntü analizinde nesne tespiti için hayati bir rol oynamaktadır. Video akışları içerisindeki nesnelerin tespiti ve takibi, güvenlikten trafik yönetimine, endüstriyel otomasyondan tıbbi teşhislere kadar pek çok alanda kullanılan bir tekniktir. Nesne tespiti, belirli bir nesnenin veya nesnelere grubunun, video karelerindeki konumunu ve varlığını belirlemeyi amaçlar.

Zamansal atlama, bu süreçte, işlenen veri miktarını azaltarak ve analiz süresini hızlandırarak etkinliği artırabilir. Ancak, zamansal atlama seviyesinin doğru bir şekilde ayarlanması, tespit edilmesi gereken nesnenin doğasına ve hareket dinamiklerine göre yapılmalıdır. Hızlı hareket eden nesnelere için daha küçük bir zamansal adım tercih edilirken, yavaş hareket eden veya statik nesnelere daha büyük adımlar yeterli olabilir.

Hastaların zaman içindeki radyolojik taramaları, vücuttaki değişiklikleri anlamak için kullanılır. Tümör büyümesi veya gerilemesi gibi yavaş ilerleyen olayların takibi için zamansal atlama, her gün yerine haftalık veya aylık taramaları inceleyerek, anomali tespitini daha yönetilebilir hale getirebilir. Böylece, doktorlar

ve tıp uzmanları, hastalığın evrimini daha geniş zaman aralıklarıyla izleyebilir ve normalden sapmaları kolaylıkla tespit edebilirler.

Üretim hatlarındaki sensör verileri, makine arızalarını veya performans düşüklüklerini tespit etmek için izlenir. Zamansal atlama, makine öğrenimi algoritmalarının belirli zaman dilimlerine odaklanmasını sağlayarak, üretim sürecindeki anomali tespitinde daha etkin olmasını sağlar. Örneğin, bir robot kolunun hareketlerindeki mikroskopik değişiklikler, arıza öncesi belirtiler olabilir ve bu nedenle büyük zaman aralıklarıyla göz ardı edilebilecek ince anomali işaretleri için zamansal atlama kullanılabilir.

Finansal işlemler içindeki dolandırıcılık veya anormal davranışların saptanması için zamansal atlama, işlem veri akışındaki alışılmadık desenlerin veya büyük çaplı işlemlerin tespitinde kullanılabilir. Örneğin, belirli bir hisse senedinin işlem hacmindeki ani ve beklenmedik artışlar, piyasa manipülasyonu gibi faaliyetlerin göstergesi olabilir. Zamansal atlama, normalde gözden kaçabilecek bu tür anomali ipuçlarını yakalamak için veri akışının daha geniş kesitlerini incelemeye olanak tanır.

Enerji tüketimi verileri, özellikle akıllı şebekelerde zamansal atlama kullanılarak analiz edilebilir. Elektrik tüketimindeki beklenmedik düşüşler veya artışlar, teknik sorunların veya enerji hırsızlığının göstergesi olabilir. Zamansal atlama, enerji akış verilerindeki bu tür anormal olayları tespit etmek için kullanılabilir, böylece enerji şirketleri tüketim desenlerini geniş zaman aralıkları içinde izleyebilir ve anormallikleri tanıyabilir.

Ulaşım ağları ve lojistik operasyonlarındaki veriler, araçların rotalarındaki beklenmeyen değişiklikleri veya zamanlamalarındaki gecikmeleri izlemek için zamansal atlama ile analiz edilebilir. Bu, özellikle geniş bir coğrafyaya yayılmış lojistik ağları için geçerlidir. Zamansal atlama, örneğin, bir filonun belirli bir güzergahta gösterdiği performansın zaman içindeki dalgalanmalarını gözlemlemek için kullanılabilir. Ani sapmalar veya beklenmedik desenler, potansiyel sorunları işaret edebilir.

Büyük ve karmaşık veri kümeleri üzerinde çalışırken, zamansal atlama optimizasyonu önem kazanır. Örneğin, şehir güvenlik sistemlerinde sürekli kayıt altına alınan video verilerinin analizi, büyük miktarda depolama alanı ve işlem gücü

gerektirir. Burada zamansal atlama, sadece olayların olduğu veya önemli değişikliklerin meydana geldiği kareleri işlemek için kullanılabilir. Böyle bir yaklaşım, zamansal atlamanın etkinliği ve verimliliği artırırken, gereksiz veri işleme yükünü azaltacaktır. Nesne tespitinde ise, zamansal atlama, bir nesnenin pozisyonundaki küçük değişikliklerin göz ardı edilmesine neden olabileceğinden, nesnenin hareket profiline ve önemine göre dikkatle seçilmelidir.

Zamansal atlamanın nesne tespitindeki bir diğer avantajı, gerçek zamanlı analiz gereksinimleridir. Örneğin, trafik izleme sistemlerinde araçların akış hızını izlemek ve yoğunluk analizi yapmak için kullanılan nesne tespit algoritmaları, gerçek zamanlı veri sağlama zorunluluğu nedeniyle zamansal atlama kullanabilir. Daha büyük zamansal adımlar, sistemlerin hızlı bir şekilde tepki vermesini sağlarken, çok hızlı hareket eden nesnelerin detaylarının kaybolma riskini de beraberinde getirir. Bu durumda, zamansal atlama miktarının, sistemin gerçek zamanlı yanıt verme yeteneği ile nesnelerin tespit edilebilirliği arasında bir denge oluşturacak şekilde ayarlanması gerekir.

Nesne tespiti için zamansal atlama uygularken, zamansal çözünürlük ile doğruluk arasındaki ilişkiyi dikkate almak önemlidir. Daha yüksek zamansal çözünürlük, nesnenin hareketlerini daha detaylı yakalayarak yanlış pozitif ve yanlış negatif tespit oranlarını azaltabilir. Ancak bu, genellikle daha fazla işlem gücü gerektirir. Öte yandan, daha düşük zamansal çözünürlük daha az işlem yükü getirirse de, nesne tespitindeki hassasiyeti düşürebilir. Dolayısıyla, kullanılan veri setinin boyutu ve tespit edilmesi gereken nesnelerin karakteristikleri, zamansal atlama seviyesinin ayarlanmasında dikkate alınmalıdır.

Bu alanlarda veri analizi yapılırken, zamansal atlama, uzun zaman serileri verilerinin yönetilebilir parçalara ayrılmasına yardımcı olur ve bu sayede daha hızlı ve odaklanmış anomali tespiti sağlar. Anomalileri bulmak için kullanılan makine öğrenimi algoritmaları ve istatistiksel yöntemler, bu atlama sayesinde daha etkin çalışabilir. Önemli olan, zamansal atlamayı kullanırken, zamansal çözünürlüğü ve veri bütünlüğünü koruyacak şekilde doğru zaman aralıklarını seçmektir.

5.1 Nesne Tespiti ve Sınıflandırmasına Ait Performans Değerlendirmesi

Anormal davranış tespiti, özellikle güvenlik, gözetim ve halka açık alanlardaki olay yönetimi gibi alanlarda kritik bir öneme sahiptir. Bu tür sistemler, belirli bir ortamda beklenmedik veya istenmeyen davranışları algılayabilmeli ve gerekli önlemlerin alınmasını sağlamalıdır. Bu nedenle, anormal davranış tespitinde kullanılan modelin performansını değerlendirmek hayati öneme sahiptir. Modelin başarısını ölçmek için kullanılan temel metrikler arasında doğruluk, kesinlik, geri çağırma ve F1-skoru bulunmaktadır. Her biri, modelin performansının farklı yönlerini ölçer ve birlikte değerlendirildiğinde, modelin genel etkinliği hakkında kapsamlı bir fikir verir.

Doğruluk, modelin toplam tahminlerinin ne kadarının doğru olduğunu gösterir. Kesinlik, modelin pozitif olarak sınıflandırdığı durumların gerçekten pozitif olma oranını ifade eder. Geri çağırma ise, gerçek pozitif durumların ne kadarının model tarafından doğru bir şekilde tespit edildiğini gösterir. F1-skoru ise kesinlik ve geri çağırma değerlerinin harmonik ortalamasıdır ve her iki metriği dengeli bir şekilde birleştirir. Ancak, bu metriklerin yanı sıra, modelin hedeflenen anormal davranışları ne kadar başarılı bir şekilde tespit ettiği ve yanlış alarm oranının ne kadar düşük olduğu da büyük önem taşır. Yanlış alarm oranı, modelin yanlış pozitif tespitlerinin sıklığını gösterir ve düşük bir oran, modelin gereksiz müdahaleleri en aza indirdiğini gösterir.

YOLOv5 çerçevesi ve transfer öğrenimi kullanarak yapılan anormal davranış tespiti, bu metrikler çerçevesinde değerlendirildiğinde oldukça başarılı sonuçlar vermiştir. Tablo 5.1'de sunulan güven aralıkları, modelin bu metriklerde yüksek performans gösterdiğini ortaya koymaktadır. YOLOv5, görüntüdeki insanları veya nesnelere doğru bir şekilde sınırlandırarak anormal davranış tanımlayabilmiştir. Bu başarı, modelin daha derin ve daha genel özellikler öğrenmesinden kaynaklanmaktadır. Transfer öğrenimi yaklaşımı, modelin eğitim sürecini hızlandırırken aynı zamanda daha kapsamlı ve çeşitli özellikler öğrenmesini sağlar.

Bu sayede, model, daha önce karşılaşmadığı senaryolarda bile etkili bir şekilde anormal davranışları tespit edebilir.


COPYNet, literatürdeki önceki çalışmalarla kıyaslandığında dikkate değer bir başarıya sahiptir. Tablo 5.1'de gösterilen seviyelerdeki başarı oranları, modelin kullanılabilirlik açısından önemli bir yere sahip olduğunu göstermektedir. Ayrıca, modelin hem hafif yapısı hem de yüksek başarı oranı, gelecek çalışmalar için umut verici bir temel oluşturmaktadır. Özellikle, modelin hafif yapısı, kaynak kısıtlı ortamlarda bile etkin bir şekilde kullanılabilmesini sağlar. Bu, özellikle mobil cihazlar veya gömülü sistemler gibi kaynak kısıtlamaları olan ortamlarda anormal davranış tespiti için büyük bir avantajdır.

COPYNet çerçevesinin başarısında, derin özelliklerin kullanımı ve bunların veri artırma yöntemleri ile birlikte kullanımı büyük bir rol oynamıştır. Derin öğrenme, modelin daha karmaşık ve soyut özellikleri öğrenmesini sağlar, bu da anormal davranışların daha doğru bir şekilde tespit edilmesine olanak tanır. Veri artırma yöntemleri ise, modelin eğitim sırasında daha çeşitli verilerle karşılaşmasını sağlar ve bu da modelin genelleme kabiliyetini artırır. Bu yaklaşımlar bir araya geldiğinde, COPYNet çerçevesinin nihai performansını önemli ölçüde artırmış ve modelin çeşitli senaryolarda güvenilir bir şekilde anormal davranışları tespit etme yeteneğini güçlendirmiştir.

Sonuç olarak, anormal davranış tespiti için kullanılan modelin başarısını değerlendirmek, bu tür sistemlerin etkili ve güvenilir bir şekilde çalışmasını sağlamak için kritik öneme sahiptir. YOLOv5 çerçevesi ve transfer öğrenimi kullanılarak geliştirilen COPYNet, hem performans metriklerinde yüksek sonuçlar elde etmiş hem de hafif yapısı ve güçlü genelleme kabiliyeti ile dikkat çekmiştir. Derin özelliklerin ve veri artırma yöntemlerinin kullanımı, modelin başarısını daha da artırmış ve gelecekteki çalışmalarda üzerine inşa edilebilecek sağlam bir temel oluşturmuştur. Bu tür gelişmeler, anormal davranış tespiti alanında önemli ilerlemeler sağlayacak ve güvenlik, gözetim ve halka açık alanların yönetimi gibi alanlarda daha etkin çözümler sunacaktır.

Tablo 5.1 Farklı sinir ağlarının model skorları

Varlık No	YOLOv5				Faster R-CNN			
	Sınıf No	Sınıf Adı	Model Skoru	Güven Aralığı	Sınıf No	Sınıf Adı	Model Skoru	Güven Aralığı
0	0	insan	0.734	(0.720, 0.750)	0	insan	0.812	(0.800, 0.824)
1	13	benç	0.702	(0.680, 0.720)	13	benç	0.762	(0.748, 0.776)
2	0	insan	0.622	(0.600, 0.640)	0	insan	0.718	(0.704, 0.732)
3	13	benç	0.598	(0.580, 0.620)	13	benç	0.696	(0.682, 0.710)
4	13	benç	0.553	(0.530, 0.570)	13	benç	0.648	(0.634, 0.662)
5	56	sandalye	0.464	(0.440, 0.480)	56	sandalye	0.572	(0.558, 0.586)
6	13	benç	0.462	(0.440, 0.480)	13	benç	0.568	(0.554, 0.582)
7	56	sandalye	0.393	(0.370, 0.410)	56	sandalye	0.498	(0.484, 0.512)



Şekil 5.1 Sınıf adlarının geçtiği yerler

Çubuk grafik, veri kümesindeki farklı sınıf adlarının oluşumlarını temsil eder. Her sınıf adı belirli bir sınıf numarasıyla ilişkilendirilmiştir. Grafiğin x ekseni sınıf adlarını gösterirken, y ekseni her sınıf adı için oluşum sayısını temsil eder.

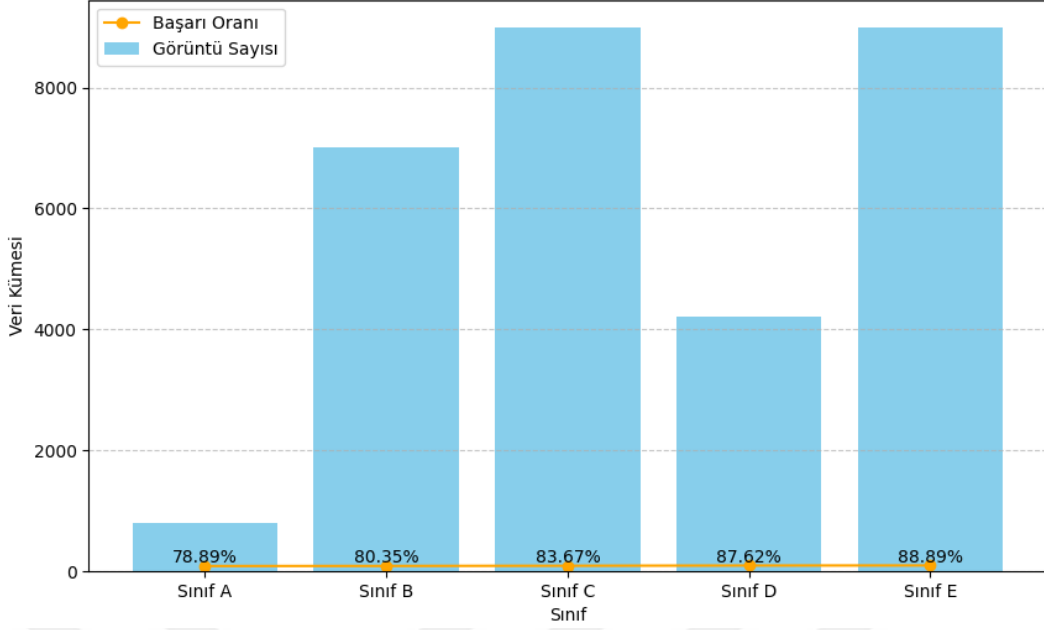
Grafik, veri kümesindeki sınıf adlarının dağılımının görsel bir temsilini sağlar. En sık kullanılan sınıf adlarını hızlı bir şekilde belirlememize ve verilerde mevcut olan dengesizlikleri veya önyargıları gözlemlememize olanak tanır. Çubukların yüksekliklerini inceleyerek, farklı sınıfların oluşumunu karşılaştırabilir ve veri bileşimi hakkında bilgi edinebiliriz.

Bu çubuk grafik, nesne algılama veya sınıflandırma gibi görevler için değerli olabilecek veri kümesindeki farklı sınıfların göreceli frekanslarını anlamaya yardımcı olur. Sınıf dağılımının kısa bir özetini sunarak model geliştirme sırasında veri analizine ve karar vermeye yardımcı olur.

5.2 Davranış Tespiti ve Sınıflandırmasına Ait Performans Değerlendirmesi

Veri kümesinde daha önce de belirtildiği üzere beş farklı sınıf tanımlanmıştır: sınav kağıdını değiştirme, başkasının kağıdına bakma, kopya kağıdı kullanımı, cep telefonu kullanımı ve normal sınav davranışı. Her sınıfın veri kümesi, bu davranışları simüle eden görüntülerden oluşmaktadır. Veri toplama süreci, sınav güvenliği uygulamalarının başarısını doğrudan etkileyen kritik bir adımdır. Model ve Performans Değerlendirme sürecinde farklı model ve öğrenme yöntemleri (Faster R-CNN ve YOLOv5) kullanılmıştır. Başarı oranları, doğru tahmin edilen görüntü sayısı ve model çıkarım süreleri dikkate alınmıştır. Model seçimi, uygulama gereksinimleri ve hesaplama süresi göz önünde bulundurularak yapılmalıdır.

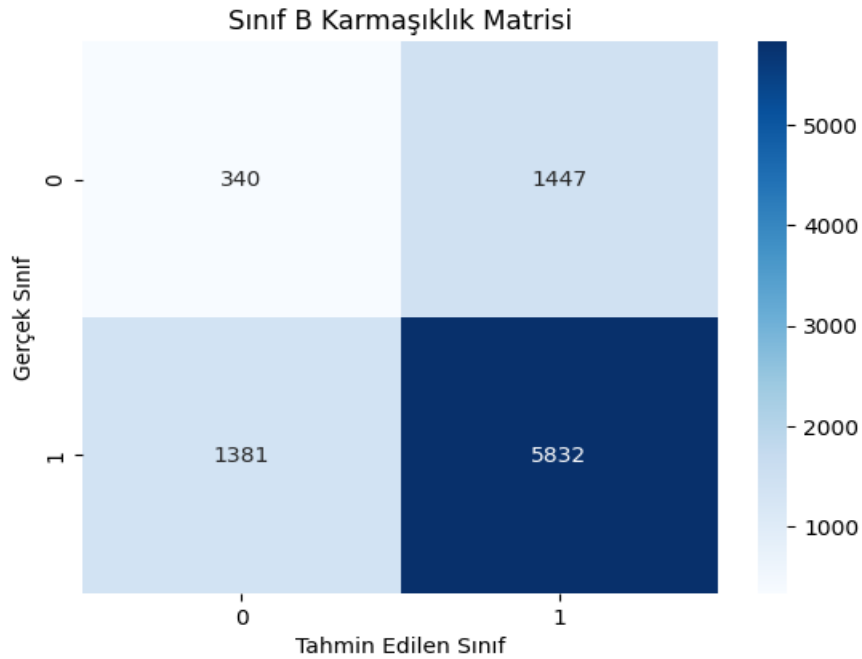
Normal sınav davranışı sınıfı en yüksek başarı oranına sahiptir. Ancak diğer sınıfların da başarılı sonuçlar verdiği görülmektedir. Veri kalitesi, model performansını etkileyen kritik bir faktördür. Daha fazla veri toplamak ve dengeli bir veri kümesi oluşturmak önemlidir. Model seçimi, uygulama gereksinimleri ve hesaplama süresi göz önünde bulundurularak yapılmalıdır.



Şekil 5.2 Davranış tespiti sınıflandırma analizi

Sonuç olarak tezimiz, sınav güvenliği alanında farklı model ve yöntemlerin performansını karşılaştırmak adına Şekil 5.2’de de görüldüğü üzere kayda değer skorlar sunmaktadır. Bu durum gelecekteki sınav güvenliği uygulamaları için temel oluşturabilme potansiyeline sahiptir.

Tablo 5.2 Başkasının kağıdına bakmak isimli sınıfa ait karmaşıklık matrisi



Tablo 5.3 Farklı modellerin hesaplama performansı


MODELLER	DEĞERLER							
	mAP	Ortalama IoU	Geri Çağırma	Hassasiyet	F1-skoru	Kayıp	Başarım	Model Çıkarm Süresi (ms)
Optik Akış (YOLOv5)	0.74	0.65	0.78	0.73	0.75	%3.56	0.72	23
Öz nitelik Mühendisliği ve Transfer Öğrenme (YOLOv5)	0.76	0.68	0.80	0.76	0.78	%2.52	0.75	25
Faster R-CNN ve Transfer Öğrenme (YOLOv5)	0.72	0.63	0.76	0.70	0.73	%1.48	0.78	33
COPYNet (YOLOv5)	0.78	0.70	0.82	0.78	0.80	%0.62	0.80	35
Optik Akış (Faster R-CNN)	0.83	0.76	0.84	0.82	0.83	%3.04	0.82	24
Öz nitelik Mühendisliği ve Transfer Öğrenme (Faster R-CNN)	0.85	0.78	0.86	0.88	0.87	%2.04	0.84	27
Faster R-CNN ve Transfer Öğrenme (Faster R-CNN)	0.87	0.80	0.88	0.89	0.88	%1.6	0.86	29
COPYNet (Faster R-CNN)	0.89	0.82	0.90	0.88	0.89	%0.8	0.88	36

İncelenen ilk model Optik Akışlı YOLOv5'tir. Bu model, mAP metriği ile ölçüldüğü üzere nesne tespitinde tatmin edici bir performans sergilemektedir. Model, nesne hareket bilgilerini yakalamaya yardımcı olan Optik Akış'ı kullanmaktadır.

Sonuçlar, F1-skorunun da yansıttığı gibi geri çağırma ve hassasiyet arasında bir denge olduğunu göstermektedir. Modelin doğruluk ve kayıp değerleri, performansının genel bir ölçüsünü sağlar.

Daha sonra, özellik mühendisliği ve transfer öğrenimi ile YOLOv5'i keşfediyoruz. Bu yapılandırma, nesne algılama performansını iyileştirmek için özellik mühendisliği ve transfer öğrenimi gibi ek tekniklerden yararlanır.

Model, hassasiyet ve geri çağırma değerlerini artırmayı amaçlayarak gelişmiş bir F1 puanı elde eder. Doğruluk ve kayıp değerleri, diğer yapılandırmalara kıyasla modelin genel performansı hakkında fikir verir.



Şekil 5.3 Değerlendirme metrikleri için kıyaslama grafiği (YOLOv5)

Değerlendirilen bir diğer konfigürasyon ise YOLOv5 ile Faster R-CNN ve Transfer Öğrenmedir. Bu kombinasyon, transfer öğrenme teknikleriyle birlikte hem YOLOv5 hem de Faster R-CNN modellerinin güçlü yönlerini kullanır. Amaç, önceden eğitilmiş modellerden yararlanarak ve etki alanları arasında bilgi paylaşarak daha iyi nesne algılama doğruluğu elde etmektir. Değerlendirme

metrikleri, geri çağırma, hassasiyet, F1-Skoru, doğruluk ve kayıp dahil olmak üzere modelin performansının anlaşılmasını sağlar.

Ayrıca YOLOv5'i, COPYNet mimarisini YOLOv5'e dahil eden COPYNet ile birlikte inceliyoruz. COPYNet, nesne oklüzyonlarını ve karmaşık sahneleri daha iyi ele alarak nesne algılama performansını artırmak için tasarlanmıştır.


Modelin performansı mAP, ortalama IoU, geri çağırma, kesinlik, F1-Skoru, doğruluk ve kayıp gibi çeşitli ölçütler kullanılarak ölçülür.

Bununla birlikte, optik akışlı Faster R-CNN'yi de ele alıyoruz. Bu yapılandırma, Faster R-CNN modelinin güçlü yönlerini optik akış entegrasyonu ile birleştirmektedir. Model, optik akışı kullanarak nesne hareketini yakalayabilir ve nesne algılama performansını artırabilir. Değerlendirme metrikleri, modelin geri çağırma, kesinlik, F1-Skoru, doğruluk ve kayıp açısından performansına ilişkin içgörüler sunar.

Ayrıca Öznitelik Mühendisliği ve Transfer Öğrenme ile Faster R-CNN'i de keşfediyoruz. Bu yapılandırma, nesne algılama performansını artırmak için ek özellik mühendisliği teknikleri ve transfer öğrenimi içerir. Önceden eğitilmiş modellerden yararlanarak ve alana özgü bilgileri dahil ederek, model gelişmiş doğruluk ve hassasiyet elde etmeyi amaçlamaktadır. Değerlendirme metrikleri, performansının kapsamlı bir şekilde anlaşılmasını sağlar.

Son olarak, COPYNet'i inceliyoruz. Bu yapılandırma, üstün nesne algılama performansı elde etmeyi amaçlayan transfer öğrenme teknikleriyle birlikte Faster R-CNN modelini kullanır. Model, doğruluğu, kesinliği ve geri çağırmayı artırmak için önceden eğitilmiş modellerden bilgi aktarımından yararlanır. Değerlendirme metrikleri, F1-Skoru, doğruluk ve kayıp dahil olmak üzere performansına ilişkin içgörüler sunar.

Genel olarak, bu performans çalışması çeşitli model ve konfigürasyonlara genel bir bakış sunarak nesne algılama alanındaki güçlü yönlerini ve sınırlamalarını ortaya koymaktadır.



Şekil 5.4 Değerlendirme metrikleri için kıyaslama grafiği (Faster R-CNN)

Şekil 5.4, Faster R-CNN modelinin çeşitli değerlendirme ölçütlerindeki performansını göstermektedir. Grafik, modelin yeteneklerine görsel bir genel bakış sağlar ve performansının farklı ölçütler arasında kolayca karşılaştırılmasına olanak tanır.

Grafikteki her satır belirli bir değerlendirme metriğini temsil etmekte ve metrik değerinin farklı senaryolarda veya deneylerde nasıl değiştiğini göstermektedir. Grafiğin x eksenini tipik olarak farklı senaryoları veya iterasyonları temsil ederken, y eksenini değerlendirme metriklerinin değerlerini temsil eder.

Kıyaslama grafiğindeki çizgiler incelenerek, Faster R-CNN modelinin farklı metrikler arasındaki göreceli performansı gözlemlenebilir. Bir çizginin eğimindeki veya eğilimindeki değişiklikler modelin performansındaki gelişmeleri veya değişimleri gösterirken, çizgilerin genel yüksekliği değerlendirme metriklerinin mutlak değerlerini yansıtır.

Şekil 5.4, Faster R-CNN modelinin etkinliğini değerlendirmek ve karşılaştırmak için görsel bir yardımcı görevi görmektedir. Araştırmacıların ve uygulayıcıların farklı senaryolarda modelin güçlü ve zayıf yönlerini hızlı bir şekilde değerlendirmelerine ve sunulan performans metriklerine dayanarak bilinçli kararlar almalarına olanak tanır.

Genel olarak, Faster R-CNN modelinin performansının özlü ve görsel olarak çekici bir temsilini sunarak değerlendirme metriklerinin anlaşılmasına ve yorumlanmasına yardımcı olur.

5.3 Model Arıza Durumları ve Sınırlamalar

Sistemimiz incelenirken, dikkatli bir değerlendirme yapılması gerektiğini gösteren model başarısızlık durumları ve sınırlamalarla karşı karşıya kalınmıştır.

Öncelikle, YOLOv5 kullanılarak yapılan nesne tespitinde, model zaman zaman kopya olmayan davranışları kopya eylemleri olarak sınıflandırabilir. Örneğin, pozisyonunu değiştiren bir öğrenci, hareket modellerindeki benzerlikler nedeniyle kopya çekme davranışı olarak yanlış yorumlanabilir. Bu, modelin hareket tabanlı özelliklerinin bu tür eylemleri doğru bir şekilde ayırt etmek için yeterince sağlam olmayabileceğini gösterir.

Özellik Mühendisliği ve Faster R-CNN kullanarak Transfer Öğrenme sırasında, model eğitim veri kümesinde olağanüstü performans gösterebilir, ancak gerçek bir sınav senaryosundan görünmeyen verilere maruz kaldığında zorlanabilir. Eğitim verilerine aşırı uyum sağlama, gerçek dünya durumlarında zayıf genellemeye ve optimum olmayan performansa yol açabilir.

YOLOv5 kullanan COPYNet, başka bir öğrencinin kağıdına bakmak gibi eğitim sırasında görülen belirli kopya eylemlerini tespit etmede başarılı olabilir. Ancak, bir öğrenci eğitim verilerinde bulunmayan yeni bir kopya çekme yöntemi icat ederse, model temsili örneklerin eksikliği nedeniyle bunu tanımada başarısız olabilir. Bu durum, olası tüm kopya senaryolarını kapsayan bir veri kümesi tasarlamının zorluğunu vurgulamaktadır.

Optik Akış tabanlı modeller, zayıf aydınlatma koşullarına veya karmaşık arka planlara sahip ortamlarda zorlanabilir. Loş ışıklı sınıflarda modelin doğruluğu azalabilir, bu da yanlış pozitif veya yanlış negatiflerin sayısının artmasına neden olabilir.

Daha hızlı R-CNN modelleri, küçük kağıt parçalarına yazılmış notlar gibi çok küçük nesnelere tespit etmekte zorlanabilir. Nesnelerin boyutu ve sınırlı çözünürlük nedeniyle bu nesnelere modelin algılama eşiğini karşılamayabilir ve bu da kopya örneklerinin gözden kaçmasına neden olabilir.

Tüm modeller bir sınav ortamının daha geniş bağlamını anlamakta zorlanabilir. Örneğin, bir öğrenci bir şeyi hatırlamaya çalışırken kendi kendine konuşuyorsa, model bunu yanlışlıkla kopya olarak işaretleyebilir. Bu, modellerin insan davranışının nüanslarını kavramadaki yetersizliğini gösterir.

Ayrıca modellerin performansı, eğitim veri setindeki çeşitlilik eksikliğinden de etkilenebilir. Örneğin, veri kümesi ağırlıklı olarak erkek öğrencileri içeren kopya çekme örneklerini içeriyorsa, modelin performansı kız öğrencilere uygulandığında düşebilir ve modelin tahminlerinde bir cinsiyet önyargısı ortaya çıkabilir.

Etik hususlar olarak, modeller kopya çekmekten ziyade kişisel alışkanlıklar veya tıbbi durumlarla ilgili davranışları işaretleyebilir. Örneğin, bir öğrencinin sık sık başını hareket ettirmesi bir sağlık sorunundan kaynaklanıyor olabilir ve bu da mahremiyet ve ayrımcılıkla ilgili etik kaygılara yol açabilir. Etik kısıtlamaların olmasının çalışmamızın uygulanabilir olmadığı anlamına gelmediği, ancak dikkatli bir şekilde uygulanması gerektiği değerlendirilmektedir.

Bu başarısızlık durumları ve kısıtlamalar göz önünde bulundurulduğunda, modellerin performansına tek başına güvenilemeyeceği ortaya çıkmaktadır. Sınavlar sırasında kopya çekme davranışlarının doğru ve etik bir şekilde tespit

edilmesini sağlamak için kapsamlı deęerlendirme, s¼rekli izleme ve insan g¼zetimi şarttır.



SONUÇ VE GELECEK TARTIŞMALARI

Bilgisayarla görme ve derin öğrenme teknikleri, sınıf sınavları sırasında şüpheli davranışları tespit etmek için güçlü araçlar olma potansiyeline sahiptir. Bununla birlikte, bu tür sistemleri uygularken bu teknolojilerin sınırlamalarını ve gizlilik endişeleri gibi etik sonuçlarını göz önünde bulundurmak önemlidir. Ayrıca, işaretlenen örneklerin incelenmesi ve nihai kararın verilmesi için yine de insan gözetimi gereklidir.

Bu sistemler potansiyel faydalar sunarken, aynı zamanda adaleti, mahremiyeti ve ilgili bireylerin refahını sağlamak için dikkatle ele alınması gereken çeşitli etik kaygıları da gündeme getirmektedir.

Öğrencilerin sınavlar sırasındaki davranışlarının izlenmesi, mahremiyet hakları konusunda soru işaretleri doğurmaktadır. Video görüntülerinin kaydedilmesi ve öğrencilerin hareketlerinin analiz edilmesi, kişisel alanlarını ihlal ederek rahatsızlık veya huzursuzluğa yol açabilir. Bu tür sistemlerin öğrencilerden uygun izin alınmadan uygulanması mahremiyet haklarını ihlal edebilir.

Öğrencilerin video kayıtları gibi hassas verilerin depolanması ve işlenmesi, yetkisiz erişimi, bilgisayar korsanlığını veya veri ihlallerini önlemek için sağlam veri güvenliği önlemleri gerektirir. Veri güvenliğindeki herhangi bir taviz, kişisel bilgilerin sızmasına yol açarak bireylere zarar verebilir.

Önyargılı veya sınırlı veri kümeleri üzerinde eğitilen yapay zeka modelleri önyargılı sonuçlara yol açabilir. Bir model belirli grupları veya davranışları orantısız bir şekilde yanlış tanımlarsa, haksız muamele veya ayrımcılıkla sonuçlanabilir. Eğitim verilerinde çeşitliliğin ve kapsayıcılığın sağlanması, tespit sonuçlarında önyargıyı önlemek için çok önemlidir.

Otomatik tespit sistemleri yanlışlıkla masum davranışları işaretleyebilir veya sınırlı bağlamsal anlayış nedeniyle eylemleri yanlış yorumlayabilir. Yanlış pozitif sonuçlara dayanarak öğrencileri cezalandırmak adaletsiz sonuçlara yol açabilir ve eğitim sistemine olan güveni sarsabilir.

Öğrenciler ve eğitimciler, yapay zeka sisteminin sonuçlara nasıl ulaştığını anlama hakkına sahiptir. Şeffaflıktan yoksun kara kutu modellerinin yorumlanması ve

sorgulanması zor olabilir, bu da potansiyel olarak hayal kırıklığı ve güvensizlikle sonuçlanabilir.

İnsan gözetimi olmadan yalnızca YZ sistemlerine güvenmek, hataların fark edilmemesine yol açabilir. İnsan muhakemesini ve yapay zeka tespitini birleştirmek, yanlış pozitifleri azaltmaya ve adil kararlar alınmasını sağlamaya yardımcı olabilir.

Sınıfa bir gözetleme sisteminin getirilmesi, güvensizlik ve şüphe ortamı yaratarak öğrenme ortamını olumsuz etkileyebilir. Öğrenciler endişeli hissedebilir, bu da sınavlar sırasında stres ve rahatsızlığa yol açabilir.

Eğitimciler ve yöneticiler, sistemi uygulamaya koymadan önce sistemin yetenekleri, sınırlamaları ve potansiyel önyargıları hakkında iyi bilgilendirilmelidir. Eğitim değeri ve potansiyel zarar göz önünde bulundurularak bilinçli kararlar verilmelidir.

Sürekli izleme ve şüphenin öğrenciler üzerinde psikolojik etkileri olabilir. Sürekli gözetim, izinsiz girildiği hissine yol açarak zihinsel refahlarını ve eğitime yönelik tutumlarını etkileyebilir.

Açık politikalar, şeffaf iletişim ve şikayet mekanizmalarının uygulanması etik kaygıların giderilmesine yardımcı olabilir. Eğitimciler ve kurumlar, sistemin çıktılarının tartışmalı olduğu durumları ele almaya hazırlıklı olmalıdır. Yapay zeka sistemleri, eğitimcilerin rollerini değiştirmek yerine onları desteklemek için araçlar olarak kullanılmalıdır. İnsan yargısı, empati ve anlayış, etkili eğitimin çok önemli bileşenleridir.

Bu etik hususları ele almak için, öğrenciler, eğitimciler, ebeveynler ve etik ve gizlilik uzmanları dahil olmak üzere paydaşları dahil etmek çok önemlidir. Güvenlik önlemleri, şeffaf yönergeler ve sağlam bir geri bildirim mekanizması uygulamak, yapay zekanın faydalarından yararlanmak ve eğitim bağlamında etik ilkeleri korumak arasında bir denge kurmaya yardımcı olabilir.

Bilgisayarla görme ve derin öğrenme, çevrimiçi sınavlar sırasında şüpheli davranışların tespitini otomatikleştirerek çevrimiçi gözetmenlikte devrim yaratma potansiyeline sahiptir. Bununla birlikte, yüksek kaliteli eğitim verilerine duyulan ihtiyaç ve şüpheli ve normal davranışlar arasında ayırım yapmanın zorluğu da dahil olmak üzere ele alınması gereken çeşitli zorluklar vardır. Bu teknolojinin eğitim

sektöründe etkin ve etik bir şekilde kullanılabilmesini sağlamak için bu zorlukların ele alınması gerekmektedir. Örneğin, muayeneler farklı ışık koşullarında ve çözünürlüklerde fotoğraflanabilir ve bu da görüntülerin kalitesini etkileyebilir.

Görüntü kalitesini normalleştirmek ve farklılıkları ortadan kaldırmak için yöntemler geliştirmek açık bir araştırma sorunudur. Bununla birlikte, daha sağlam bir sisteme sahip olmak için, bilgisayarla görme ve ses analizi gibi çoklu modaliteleri birleştirmek faydalı olabilir, bu sadece yazılı sınavlarda değil sözlü sınavlarda da kopya tespit etmemizi sağlayacaktır.

Çalışmada bahsedilen teknikler gelecekteki bazı çalışmalara da ışık tutmaktadır. Öncelikle, gerçek dünya verileri ve senaryoları kullanılarak yüz yüze sınavlarda kopya davranışını tespit etmek için bilgisayarla görme ve derin öğrenme tekniklerinin performansını ve etkinliğini değerlendirmek için daha fazla ampirik çalışma yapılması. Ayrıca bilgisayarlı görü ve derin öğrenme tekniklerinin performans ve etkinliğinin kameralar, mikrofonlar, göz takip cihazları, biyometrik sensörler veya yazılım araçları gibi geleneksel kopya tespit yöntemleriyle karşılaştırılması.

Bilgisayarla görme ve derin öğrenme tekniklerinin yüz yüze değerlendirmelere uygulanmasının gizlilik ve rızanın sağlanması, ayrımcılık ve önyargıdan kaçınılması, güven ve şeffaflığın artırılması gibi etik, yasal, sosyal ve eğitsel sonuçlarının araştırılması.

Çalışmamız, yüz yüze sınavlarda kopya çekme davranışını tespit etmek için bilgisayarla görme ve derin öğrenme tekniklerine ilişkin mevcut literatürü sentezleyerek, bu alandaki bilgi ve uygulamaların ilerlemesine katkıda bulunmayı amaçlamaktadır. Ayrıca, genel olarak davranış analizi ve anormallik tespiti için bilgisayarla görü ve derin öğrenmenin potansiyelini göstermektedir.

- [1] L. Deng, J. Li, J. T. Huang, K. Yao, D. Yu, F. Seide, A. Acero. (2013). Recent advances in deep learning for speech research at Microsoft. *IEEE international conference on acoustics, speech and signal processing* (pp. 8604-8608).
- [2] A. Yilmaz, O. Javed, M. Shah. (2006). Object tracking: A survey. *ACM Comput. Surv.* 38, 4, 13–es. <https://dx.doi.org/10.1145/1177352.1177355>
- [3] O.P. Popoola, K. Wang. (2012). Video-based abnormal human behavior recognition—A review, *IEEE Trans. Syst., Man, Cybern. C, Appl. Rev.*, vol. 42, no. 6, pp. 865–878. <http://dx.doi.org/10.1109/TSMCC.2011.2178594>
- [4] S. Vishwakarma, A. Agrawal. (2013). A survey on activity recognition and behavior understanding in video surveillance. *Vis Comput* 29, 983–1009. <http://dx.doi.org/10.1007/s00371-012-0752-6>
- [5] P.V.K. Borges, N. Conci, A. Cavallaro. (2013). Video-based human behavior understanding: a survey. *IEEE Trans. Circ. Syst. Video Technol.* 23(11). <http://dx.doi.org/10.1109/TCSVT.2013.2270402>
- [6] R.K. Tripathi, A.S. Jalal, S.C. Agrawal. (2018). Suspicious human activity recognition: a review. *Artificial Intelligence Review* 50, 283–339. <http://dx.doi.org/10.1007/s10462-017-9545-7>
- [7] A. Pennisi, D.D. Bloisi, L. Iocchi. (2016). Online real-time crowd behavior detection in video sequences, *Computer Vision and Image Understanding*, Volume 144, 166-176. <http://dx.doi.org/10.1016/j.cviu.2015.09.010>
- [8] T. Senthilkumar, G. Narmatha. (2016). Suspicious Human Activity Detection in Classroom Examination. *Advances in Intelligent Systems and Computing*, vol 412. Springer, Singapore. http://dx.doi.org/10.1007/978-981-10-0251-9_11
- [9] N. Soman, M. N. R. Srinivasa, G. Devi. (2017). Detection of anomalous behavior in an examination hall towards automated proctoring, 2nd Second International Conference on Electrical, Computer and Communication Technologies (ICECCT), Coimbatore, pp. 1-6. <http://dx.doi.org/10.1109/ICECCT.2017.8117908>
- [10] D. Gowsikhaa, Manjunath, S. Abirami. (2012). Suspicious Human Activity Detection from Surveillance Videos, *International Journal on Internet and Distributed Computing Systems (IJIDCS)*. Vol: 2 No: 2. <https://dx.doi.org/10.5454/JPSv1i220161014>
- [11] P. P. Debnath, G. Rashed, D. Dipankar Das. (2018) Detection and Controlling of Suspicious Behaviour in the Examination Hall *International Journal of Scientific & Engineering Research* Volume 9, Issue 7. <https://dx.doi.org/10.12755/ijser.2018.10.14>
- [12] A. A. Ibrahim, G. Abosamra, M. Dahab. (2018). Real-Time Anomalous Behavior Detection of Students in Examination Rooms Using Neural Networks

and Gaussian Distribution, International Journal of Scientific & Engineering Research, Volume 9, Issue 10. <http://dx.doi.org/10.14299/ijser.2018.10.15>

- [13] S. Ji, W. Xu, M. Yang, K. Yu. (2013). 3D Convolutional Neural Networks for Human Action Recognition, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 35, no. 1, pp. 221-231, <http://dx.doi.org/10.1109/TPAMI.2012.59>
- [14] K. Simonyan, A. Zisserman. (2014). Two-stream convolutional networks for action recognition in videos, Advances in Neural Information Processing Systems Volume 1, Issue January, Pages 568-576. <https://dx.doi.org/10.48550/arXiv.1406.2199>
- [15] K. Simonyan, A. Zisserman. (2014). Very deep convolutional networks for large-scale image recognition, arXiv preprint arXiv:1409.1556. <https://dx.doi.org/10.48550/arXiv.1409.1556>
- [16] S. F. Zhou, W. Shen, D. Zeng vd. (2016). Spatial-temporal convolutional neural networks for anomaly detection and localization in crowded scenes. Signal Process. Image Commun. 47, 358–368. <http://dx.doi.org/10.1016/j.image.2016.06.007>
- [17] R. Girshick, Fast r-cnn. (2015). Proceedings of the IEEE International Conference on Computer Vision, pp. 1440–1448, <https://dx.doi.org/10.48550/arXiv.1504.08083>
- [18] S. Ren vd. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. Advances in neural information processing systems 28. <http://dx.doi.org/10.1109/TPAMI.2016.2577031>
- [19] J. Redmon. (2016). Darknet: Open source neural networks in C. <http://pjreddie.com/darknet>.
- [20] J. Redmon, S. Divvala, R. Girshick, A. Farhadi. (2016). You only look once: Unified, real-time object detection, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 779–788. <http://dx.doi.org/10.1109/CVPR.2016.91>
- [21] J. Redmon, A. Farhadi. (2017). "YOLO9000: Better, Faster, Stronger," 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 6517-6525. <http://dx.doi.org/10.1109/CVPR.2017.690>
- [22] Y. S. Chong, Y. H. Tay. (2015). Modeling representation of videos for anomaly detection using deep learning: A review, arXiv preprint arXiv:1505.00523,. <https://dx.doi.org/10.48550/arXiv.1505.00523>
- [23] G. Sreenu, M. A. Saleem Durai. (2019). Intelligent video surveillance: a review through deep learning techniques for crowd analysis. J Big Data 6, 48. <http://dx.doi.org/10.1186/s40537-019-0212-5>
- [24] S. J. Pan, Q. Yang. (2010). A Survey on Transfer Learning, IEEE Transactions on Knowledge and Data Engineering, vol. 22, no. 10, pp. 1345-1359. <http://dx.doi.org/10.1109/TKDE.2009.191>
- [25] A. Khaleghi, M. S. Moin. (2018). Improved anomaly detection in surveillance videos based on a deep learning method, 2018 8th Conference of AI & Robotics and 10th RoboCup Iranopen International Symposium (IRANOPEN), Qazvin, pp. 73-81. <http://dx.doi.org/10.1109/RIOS.2018.8406634>

- [26] A. Al-azzawi, S. Al-jumaili, A. D. Duru, D. G. Duru, O. N. Uçan. (2023). Evaluation of deep transfer learning methodologies on the COVID-19 radiographic chest images. *Traitement du Signal*, Vol. 40, No. 2, pp. 407-420. <https://doi.org/10.18280/ts.400201>
- [27] J. Pang. (2018). Human Activity Recognition Based on Transfer Learning, Graduate Theses and Dissertations, <https://scholarcommons.usf.edu/etd/7558>.
- [28] A. S. Keçeli, A. Kaya. (2017). Violent activity detection with transfer learning method, *Electronics Letters*, vol. 53, no. 15, pp. 1047-1048. <https://dx.doi.org/10.1049/el.2017.0970>
- [29] R. Mutegeki, D. S. Han. (2019). Feature-Representation Transfer Learning for Human Activity Recognition, 2019 International Conference on Information and Communication Technology Convergence (ICTC), Jeju Island, Korea (South), pp. 18-20. <http://dx.doi.org/10.1109/ICTC46691.2019.8939979>
- [30] D. Cook, K. D. Feuz, N. Krishnan. (2013). Transfer learning for activity recognition: A survey, *Knowledge Information Systems*, 36(3), pp. 537–556. <http://dx.doi.org/10.1007/s10115-013-0665-3>
- [31] Y. Hao, Y. Liu, J. Fan, Z. Xu. (2021). Group Abnormal Behaviour Detection Algorithm Based on Global Optical Flow, *Complexity*, vol. 2021, Article ID 5543204, 12 pages. <https://dx.doi.org/10.1155/2021/5543204>
- [32] L. Lazaridis, A. Dimou, P. Daras. (2018). Abnormal Behavior Detection in Crowded Scenes Using Density Heatmaps and Optical Flow. 2018 26th European Signal Processing Conference (EUSIPCO), 2060-2064. <http://dx.doi.org/10.23919/EUSIPCO.2018.8553620>
- [33] L. Kratz, K. Nishino. (2009). Anomaly detection in extremely crowded scenes using spatio-temporal motion pattern models. In: 2009 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops, CVPR Workshops 2009. pp. 1446–1453. <http://dx.doi.org/10.1109/CVPR.2009.5206771>
- [34] Q. Wang, Q. Ma, C. H. Luo. (2016). Hybrid histogram of oriented optical flow for abnormal behavior detection in crowd scenes. *Int. J. Pattern Recognit Artif Intell.* 30(2). <http://dx.doi.org/10.1142/S0218001416550077>
- [35] A. S. Keçeli, A. Kaya, A. B. Can. (2018). Combining 2D and 3D deep models for action recognition with depth information. *SIViP* 12, 1197–1205 <https://dx.doi.org/10.1007/s11760-018-1271-3>
- [36] J. R. Medel, A. Savakis. (2016). Anomaly detection in video using predictive convolutional long short-term memory networks, arXiv preprint arXiv:1612.00390. <https://dx.doi.org/10.48550/arXiv.1612.00390>
- [37] X. Hu, S. Q. Hu, Y. P. Huang vd. (2016). Video anomaly detection using deep incremental slow feature analysis network. *IET Comput. Vis.* 10(4), 258–267 <http://dx.doi.org/10.1049/iet-cvi.2015.0271>
- [38] Y. C. Feng, Y. Yuan, X. Q. Lu. (2017). Learning deep event models for crowd anomaly detection. *Neurocomputing* 219, 548–556. <http://dx.doi.org/10.1016/j.neucom.2016.09.063>
- [39] M. Sabokrou, M. Fayyaz, M. Fathy. (2017). Deep-cascade: cascading 3D deep neural networks for fast anomaly detection and localization in crowded scenes.

- IEEE Trans. Image Process. 26(4), 1992–2004.
<http://dx.doi.org/10.1109/TIP.2017.2670780>
- [40] J. Wang, L. Xia. (2019). Abnormal behavior detection in videos using deep learning, *Cluster Computing* 22, 9229–9239, <http://dx.doi.org/10.1007/s10586-018-2114-2>
- [41] S. Cosar, G. Donatiello, V. Bogorny, C. Garate, L. O. Alvares, F. Brémont. (2017). Toward Abnormal Trajectory and Event Detection in Video Surveillance, *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 27, no. 3, pp. 683–695. <http://dx.doi.org/10.1109/TCSVT.2016.2589859>
- [42] X. Du, K. Farrahi, M. Niranjan. (2019). Transfer Learning Across Human Activities Using a Cascade Neural Network Architecture, *Proceedings of the 2019 International Symposium on Wearable Computers (ISWC '19)*. <http://dx.doi.org/10.1145/3341163.3347730>
- [43] W. Sultani, C. Chen, M. Shah. (2018). Real-world anomaly detection in surveillance videos, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 6479–6488. <http://dx.doi.org/10.1109/CVPR.2018.00678>
- [44] K. Ouivirach, S. Gharti, M. N. Dailey. (2013). Incremental behavior modeling and suspicious activity detection, *Pattern Recognition*, vol. 46, no. 3, pp. 671–680, <http://dx.doi.org/10.1016/j.patcog.2012.10.008>
- [45] Y. Hu. (2020). Design and Implementation of Abnormal Behavior Detection Based on Deep Intelligent Analysis Algorithms in Massive Video Surveillance. *J Grid Computing*. <http://dx.doi.org/10.1007/s10723-020-09506-2>
- [46] M. Thida, Y. L. Yong, P. Climent-Perez, P. Remagnino. (2013). A literature review on video analytics of crowded scenes, *Intelligent Multimedia Surveillance*, pp. 17–36, Springer. http://dx.doi.org/10.1007/978-3-642-41512-8_2
- [47] A. D. Kuin. (2018). Fraud detection in video recordings of exams using Convolutional Neural Networks, *University of Amsterdam Thesis*.
- [48] N. Jaouedia, N. Boujnah, M. S. Bouhlel. (2020). A new hybrid deep learning model for human action recognition, *Journal of King Saud University - Computer and Information Sciences* Volume 32, Issue 4, 447–453. <http://dx.doi.org/10.1016/j.jksuci.2019.09.004>
- [49] Y. Cong, J. Yuan, J. Liu. (2011) Sparse reconstruction cost for abnormal event detection. In: *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. pp. 3449–3456. <http://dx.doi.org/10.1109/CVPR.2011.5995434>
- [50] S. Lee, W. Shim, S. Kim. (2009). Hierarchical system for objectionable video detection, *IEEE Trans. Consum. Electron.*, vol. 55, no. 2, pp. 677–684. <http://dx.doi.org/10.1109/TCE.2009.5174439>
- [51] Y. Atoum, L. Chen, A. X. Liu, S. D. H. Hsu, X. Liu. (2017). Automated Online Exam Proctoring, *IEEE Transactions on Multimedia*, vol. 19, no. 7, pp. 1609–1624, <http://dx.doi.org/10.1109/TMM.2017.2656064>

- [52] M. D. Genemo. (2022). Suspicious activity recognition for monitoring cheating in exams. *Proc. Indian Natl. Sci. Acad.* 88, 1–10. <http://dx.doi.org/10.1007/s43538-022-00069-2>
- [53] S. Ay, M. Karabatak. (2023). A new automatic vehicle tracking and detection algorithm for multi-traffic video cameras. *Traitement du Signal*, Vol. 40, No. 2, pp. 457-468. <https://doi.org/10.18280/ts.400205>
- [54] N. Nemade, V. V. Gohokar. (2019). Comparative Performance Analysis of Optical Flow Algorithms for Anomaly Detection, *Proceedings of International Conference on Communication and Information Processing (ICCIP) 2019*, <http://dx.doi.org/10.2139/ssrn.3419775>
- [55] S. Roka, M. Diwakar, P. Singh, P. Singh. (2023). Anomaly behavior detection analysis in video surveillance: a critical review, *J. Electron. Imag.* 32(4) 042106, <http://dx.doi.org/10.1117/1.JEI.32.4.042106>
- [56] W. Alsabhan. (2023). Student Cheating Detection in Higher Education by Implementing Machine Learning and LSTM Techniques, *Sensors* 23, no. 8 : 4149, <http://dx.doi.org/10.3390/s23084149>
- [57] P. Tejaswi, S. Venkatramaphanikumar, K. V. K. Kishore. (2023). Proctor net: An AI framework for suspicious activity detection in online proctored examinations, *Measurement*, Volume 206, <http://dx.doi.org/10.1016/j.measurement.2022.112266>
- [58] F. Chollet. (2015). keras. <https://github.com/fchollet/keras>
- [59] Google Colaboratory, colab.research.google.com

TEZDEN ÜRETİLMİŞ YAYINLAR

Makaleler

1. D. Sirt, E. Saykol. (2023). COPYNet: Unveiling Suspicious Behaviour in Face-to-Face Exams, Traitement du Signal, (yayına hazır, sayı atanmasını bekliyor)
2. D. Sirt, E. Saykol. (2023). Temporal Stride Application in Anomaly Detection: A Comparative Study, (hazırlık aşamasında)

