

T.C.
İSTANBUL BEYKENT ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI

**SINIF VİDEOSU GÖRÜNTÜLERİNDE ARKA PLAN
ÇIKARARAK KOPYA TEŞEBBÜSÜ YAKALAMA**
Yüksek Lisans Tezi

Tezi Hazırlayan
Muamber UZUNKAYA

İstanbul, 2024

T.C.
İSTANBUL BEYKENT ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI

**SINIF VİDEOSU GÖRÜNTÜLERİNDE ARKA PLAN
ÇIKARARAK KOPYA TEŞEBBÜSÜ YAKALAMA**
Yüksek Lisans Tezi

Tezi Hazırlayan
Muamber UZUNKAYA

Öğrenci No
2120003047

ORCID ID
0000-0001-7415-6217

Danışman
Dr. Öğr. Üyesi Ediz ŞAYKOL

İstanbul, 2024

YEMİN METNİ

Yüksek Lisans Tezi olarak sunduğum “**Sınıf Videosu Görüntülerinde Arka Plan Çıkartılarak Kopya Teşebbüsü Yakalama**” başlıklı bu çalışmanın, bilimsel ahlak ve geleneklere uygun şekilde tarafımdan yazıldığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, yararlandığım eserlerin tamamının kaynaklarda gösterildiğini ve çalışmamın içinde kullanıldıkları her yerde bunlara atıf yapıldığını, patent ve telif haklarını ihlal edici bir davranışımın olmadığını belirtir ve bunu onurumla doğrularım. 28/06/2024

Muamber UZUNKAYA

T.C.
İSTANBUL BEYKENT ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ MÜDÜRLÜĞÜ
TEZLİ YÜKSEK LİSANS SINAV TUTANAĞI

28..06.2024

Enstitümüz *Bilgisayar Mühendisliği* Anabilim Dalı *Bilgisayar Mühendisliği* Programı yüksek lisans öğrencilerinden 2120003047 numaralı *Muamber UZUNKAYA'nın* "İstanbul Beykent Üniversitesi Lisansüstü Eğitim – Öğretim Yönetmeliği"nin ilgili maddesine göre hazırlayarak, Enstitümüze teslim ettiği "Sınıf Videosu Görüntülerinde Arka Plan Çıkararak Kopya Teşebbüsü Yakalama" konulu tezini, Yönetim Kurulumuzun 28/05/2024 tarih ve 2024/24 sayılı toplantısında seçilen ve On-Line toplanan biz jüri üyeleri huzurunda, İstanbul Beykent Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 29. maddesinin 3. fıkrası gereğince 45 dakika süre ile Zoom programı aracılığıyla on-line olarak aday tarafından savunulmuş ve sonuçta adayın tezi hakkında "OYBİRLİĞİ" ile "KABUL" kararı verilmiştir.

İşbu tutanak, 2 nüsha olarak hazırlanmış ve Enstitü Müdürlüğü'ne sunulmak üzere tarafımızdan düzenlenmiştir.

DANIŞMAN
Dr. Öğr. Üyesi Ed*** ŞA***
(İstanbul Beykent Üniversitesi)

ÜYE
Doç. Dr. At*** YI***
(İstanbul Beykent Üniversitesi)

ÜYE
Dr. Öğr. Üyesi So*** SE***
(Kütahya Dumlupınar Üniversitesi)

Adı ve Soyadı : Muammer UZUNKAYA
Danışman : Dr. Öğr. Üyesi Ediz ŞAYKOL
Derecesi ve Tarihi : Yüksek Lisans (Tezli), 2024
Alanı : Bilgisayar Mühendisliği
Anahtar Kelimeler : Anormallik Tespiti, Arka Plan Çıkarma, Derin Öğrenme, Görüntü Analizi, Performans Artışı

ÖZ

SINIF VİDEOSU GÖRÜNTÜLERİNDE ARKA PLAN ÇIKARARAK KOPYA TEŞEBBÜSÜ YAKALAMA

Bu çalışma, sınıf ortamında yapılan yüz yüze sınavlarda kullanılan dijital kameralar tarafından kayıt altına alınan görüntülerin analizi ve normal olmayan davranışların tespiti ve arka planda bulunan objelerin çıkarılmasıyla oluşacak performans artışına odaklanmakta ve sınıf ortamında yapılan sınavlardaki eylemleri yüksek hassasiyetle tespit etmek için yeni bir model geliştirmeye odaklanmaktadır. Çalışmaya COPYNet Veri Kümesi oluşturmayla başlanmıştır. Yaklaşık 30.000 görüntüden oluşan oldukça büyük bir koleksiyon olan bu veri seti, normal olmayan davranışları algılama algoritmalarının oluşturulması, doğrulanması ve arka plan nesnelerinin çıkartılması sonrası oluşan performans artışının değerlendirilmesi için kullanılmaktadır. Veri seti, davranış kategorilerine bağlı olarak beş farklı gruba bölünmüştür. 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 davranış modelleyerek bir normal olmayan davranış puanı elde etmek için derin bir sinir ağı çerçevesi (COPYNet) oluşturulmaktadır. COPYNet çerçevesi %90'lık bir hassasiyet, %88'lik bir geri çağırma ve %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 normal olmayan 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, sınıf ortamında yapılan sınavlar sırasında kuşkulu hareketleri yakalamak etmek için literatürdeki önceki çalışmalara kıyasla daha iyi sonuçlar vermektedir.



Name and Surname : Muammer UZUNKAYA
Supervisor : Asst. Prof. Dr. Ediz ŞAYKOL
Degree and Date : Master's (Thesis), 2024
Major : Computer Engineering
Keywords : Anomaly Detection, Background Removal, Deep Learning,
Image Analysis, Performance Increase

ABSTRACT

DETECTING CHEATING ATTEMPTS IN CLASSROOM VIDEOS BY REMOVING BACKGROUND

This study focuses on the analysis of video recordings captured by digital cameras during face-to-face exams in a classroom setting. It aims to detect abnormal behaviors and improve performance by removing background objects. The goal is to develop a new model to accurately identify actions during classroom exams. The study begins with the creation of the COPYNet dataset, which comprises a substantial collection of approximately 30,000 images. This dataset is used to develop and validate algorithms for detecting abnormal behaviors and to evaluate the performance improvements achieved after background object removal. The dataset is divided into five different groups based on behavior categories.

To achieve high performance in solving the image classification problem, transfer learning is employed using the pre-trained ResNet model, which is hybridized separately with the Faster R-CNN and YOLOv5 algorithms. A deep neural network framework (COPYNet) is created to model normal behavior and generate an abnormal behavior score. The COPYNet framework demonstrates a precision of %90, a recall of %88, and an accuracy of %88. These figures represent a significant leap in anomaly detection compared to the existing literature.

The presented results highlight the model's ability to accurately distinguish between different behavior classes, making it a valuable tool for detecting suspicious behaviors during face-to-face exams. Consequently, when the model detects abnormal activity, it aims to trigger an alert that can be sent to the proctor, serving as a decision

support mechanism for exam invigilators. Based on the achieved success rates, our study shows better results in capturing suspicious movements during classroom exams compared to previous studies in the literature.



İÇİNDEKİLER

Sayfa No.

ÖZ

ABSTRACT

TABLolar LİSTESİ	iii
ŞEKİLLER LİSTESİ	iv
KISALTMALAR	v
SÖZLÜK.....	vi
GİRİŞ	1

1. KULLANILAN YÖNTEMLERİN TEMELLERİ

1.1. Derin Öğrenme.....	4
1.1.1. Derin Öğrenmenin Gelişimi ve Dönüşümü	6
1.1.2. Derin Öğrenme Mimarileri	8
1.1.3. Faster R-CNN: Bölge Evrişimli Sinir Ağı	13
1.1.4. YOLOv5: You Only Look Once.....	17
1.2. Teknoloji Türleri.....	19
1.3. Uygulama Alanları.....	22

2. COPYNET ÇERÇEVESİ

2.1. Veri Kümesi.....	33
2.1.1. Alan Uzmanlarınca Etiketleme ve Açıklamalar.....	35
2.1.2. Veri Kalitesi İçin Ön İşleme Adımları	36
2.1.3. Veri Kümesi Bölümleme: Eğitim, Doğrulama ve Test.....	37
2.2. Veri Kümesine Zamansal Atlama Uygulamak	38
2.3. Model.....	42
2.4. Model Özellikleri ve Eğitim Detayları	55
2.4.1. Yürütme Süresi ve Ortamı Detayları.....	56
2.4.2. YOLOv5 Yapılandırması ve Eğitimi	57
2.4.3. Faster R-CNN Yapılandırması ve Eğitimi	59
2.4.4. Değerlendirme Protokolü	60

2.5. Algoritmik Karmaşıklık.....	67
2.6. Çerçeve.....	68
3. NESNE ALGILAMA TEKNİKLERİ	
3.1. Optik Akış Analizi	76
3.2. Öznitelik Mühendisliği Teknikleri	79
3.3. Yeni Veri Kümeleri Üzerinde Zamansal Atlamayı Uygulamak.....	83
4. PERFORMANS ÇALIŞMALARI	
4.1 Arka Planın Çıkarılmasının Performansa Etkisi ile Nesne Tespiti ve Sınıflandırmasına Ait Performans Değerlendirmesi	86
4.2. Davranış Tespiti ve Sınıflandırmasına Ait Performans Değerlendirmesi...	97
4.3. Model Arıza Durumları ve Sınırlamalar	109
SONUÇ	111
KAYNAKÇA.....	114

TABLÖLAR LİSTESİ

	Sayfa No.
Tablo 1. Şüpheli Davranış Tespit Yöntemini Mevcut Yöntemlerle Karşılaştırma...	32
Tablo 2. Önceki Çalışmalarda Kullanılan Diğer Veri Kümeleri İle Kıyaslama	35
Tablo 3. Farklı Sinir Ağlarının Model Skorları	88
Tablo 4. Arka Plan Çıkarılmadan Farklı Sinir Ağlarının Model Skorları.....	93
Tablo 5. Arka Plan Çıkarıldıktan Sonra Farklı Sinir Ağlarının Model Skorları	93
Tablo 6 Davranış Tespiti Sınıflandırma Analizi - Arka Plan Çıkarılınca.....	99
Tablo 7. Başkasının Kağıdına Bakmak İsimli Sınıfa Ait Karmaşıklık Matrisi.....	99
Tablo 8. Farklı modellerin hesaplama performansı	100
Tablo 9. Farklı Modellerin Hesaplama Performansı - Arka Planın Çıkarılmasının Performansa Etkisi Dahil	101
Tablo 10. Değerlendirme Metrikleri için Kıyaslama Grafiği (YOLOv5) - Arka Plan Çıkarılınca	105

ŞEKİLLER LİSTESİ

	Sayfa No.
Şekil 1. Derin Sinir Ağı Mimarisi	5
Şekil 2. Derin Öğrenme Zaman Çizelgesi	8
Şekil 3. Evrişimli Derin Sinir Ağı Model Mimarisi	9
Şekil 4. Yineleyen Derin Sinir Ağı Model Mimarisi.....	10
Şekil 5. Derin Otokodlayıcılar Sinir Ağı Model Mimarisi	10
Şekil 6. Konuların Kesişim Diyagramı.....	31
Şekil 7. Sırasıyla B, C ve D sınıflarından görüntüler	34
Şekil 8. Zamansal Atlama Akışı	41
Şekil 9. Faster R-CNN ile Bir Sınırlayıcı Kutu Çizerek Kopyasız Normal Durumu Belirleme	46
Şekil 10. ResNet Ön Eğitilmiş Ağ	53
Şekil 11. Yürütme Ortamlarının Karşılaştırması	57
Şekil 12. COPYNet çerçevesi akış çizelgesi	71
Şekil 13. COPYNet Çerçevesi.....	75
Şekil 14. Lucas-Kanade Optik Akış Tekniğinin Uygulandığı Sınıf Ortamı.....	78
Şekil 15. SURF ile Nesne Tespiti	81
Şekil 16. SSD ile Nesne Tespiti.....	82
Şekil 17. Davranış Tespiti Sınıflandırma Analizi.....	98
Şekil 18. Değerlendirme Metrikleri için Kıyaslama Grafiği (YOLOv5)	103
Şekil 19. Değerlendirme Metrikleri için Kıyaslama Grafiği (Faster R-CNN)	106
Şekil 20. Değerlendirme Metrikleri için Kıyaslama Sonuçları (Faster R-CNN)	107

KISALTMALAR

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

SÖZLÜK

Ağ Eğitimi (Network Training): Yapay sinir ağlarının veri üzerinde eğitilmesi ve öğrenme sürecidir. Modelin belirli bir görevi başarıyla gerçekleştirmesi için optimizasyon işlemi yapılır.

Aktivasyon Fonksiyonu (Activation Function): Yapay sinir ağlarında her bir nöronun çıktısını belirleyen matematiksel fonksiyondur. Sigmoid, ReLU, ve tanh gibi fonksiyonlar yaygın olarak kullanılır.

Aşırı Uydurma (Overfitting): Makine öğrenme modelinin eğitim veri setine aşırı uyum sağlaması ve yeni verilere genelleme yapamaması durumudur.

Azaltma (Reduction): Boyut azaltma, verilerdeki karmaşıklığı azaltarak model performansını artırmak için kullanılan bir tekniktir.

Bilgisayarlı Görü (Computer Vision): Bilgisayarlı görü, bilgisayarların görüntüleri analiz etmek ve yorumlamak için kullandığı bir alanıdır. Resim ve video verilerini işleyerek nesne tanıma, yüz tanıma, hareket analizi gibi görevleri gerçekleştirmektedir.

Derin Öğrenme (Deep Learning): Derin öğrenme, yapay sinir ağlarının çok katmanlı ve karmaşık yapılarını kullanarak verilerden öğrenme yeteneği sağlayan bir makine öğrenmesi alt dalıdır.

Evrışimli Sinir Ağları (Convolutional Neural Networks - CNN): Resim ve video gibi yapısal verileri işlemek için özel olarak tasarlanmış derin öğrenme mimarileridir. Görüntü sınıflandırma ve nesne tanıma gibi görevler için yaygın olarak kullanılırlar.

Hareket Analizi (Motion Analysis): Nesnelerin veya kişilerin hareketlerini analiz etmek ve izlemek için kullanılan bir bilgisayarlı görü tekniğidir. Örneğin, güvenlik kameralarındaki hareketleri tespit etmek için kullanılabilir.

Makine Öğrenmesi (Machine Learning - ML): Bilgisayarların verilerden öğrenme yeteneğine sahip olmasını sağlayan bir alanıdır. Derin öğrenme, destek vektör makineleri (SVM), karar ağaçları gibi yöntemler makine öğrenmesine örnek verilebilir.

Nesne Tanıma (Object Detection): Resim veya videodaki nesneleri tanımlamak ve sınıflandırmak için kullanılan bir bilgisayarlı görü tekniğidir.

Piksel (Pixel): Dijital görüntülerdeki en küçük görüntü elemanıdır. Bir piksel, renk ve yoğunluk bilgisini içerir.

Regresyon (Regression): Değişkenler arasındaki ilişkiyi anlamak ve tahminlemek için kullanılan bir makine öğrenmesi tekniğidir. Örneğin, bir evin fiyatını belirlemek için kullanılabilir.

Sınıflandırma (Classification): Verileri belirli kategorilere ayırmak için kullanılan bir makine öğrenmesi tekniğidir. Örneğin, bir resimdeki nesnenin tespit edilmesi veya tanımlanması.

Sınıflandırma Doğruluğu (Classification Accuracy): Bir sınıflandırma modelinin doğru tahmin oranını ölçen bir performans metriğidir.

Toplu Öğrenme (Batch Learning): Makine öğrenme modelinin tüm veri setini tek bir adımda eğittiği bir öğrenme yaklaşımıdır.

Veri Anotasyonu (Data Annotation): Veri setlerindeki öğelerin insanlar tarafından etiketlenmesi veya işaretlenmesi işlemidir. Örneğin, bir resimdeki nesnelerin etiketlenmesi.

Veri Segmentasyonu (Data Segmentation): Görüntü veya video verilerini farklı bölgelere ayırma işlemidir. Arka plan çıkarımı, bir tür veri segmentasyon tekniğidir.

Yapay Sinir Ağı (Artificial Neural Network - ANN): Biyolojik sinir ağlarını taklit eden matematiksel modeldir. Derin öğrenme, ANN'lerin bir alt kategorisidir.

Yapay Zeka (Artificial Intelligence - AI): Bilgisayarların insan benzeri zekâ göstermesini sağlayan bir bilim dalıdır. Derin öğrenme gibi teknikler bu alanda kullanılır.

GİRİŞ

Sınıf ortamında yapılan sınavlarda sınıf içi şüpheli davranışları yakalamaya yönelik çalışmalara destek olması için teknolojiden faydalanılmaktadır. Gelişen derin öğrenme yöntemleri bu konuda en büyük katkıyı sağlayan yöntemlerin başında gelmektedir. Bu yöntemler bilgisayar destekli davranış analizlerinden faydalanarak, kopya girişimlerini engelleme ve sınav sonuçlarında haksız notların alınmasına engel olunmasına imkan sağlamaktadır.

Derin öğrenme ve görüntü işleme alanında yapılan çalışmalar sınıf ortamında yapılan sınav esnasında istenmeyen şüphe içeren tutumların saptanmasında umut vadeden sonuçlar vermişti. Araştırmacılar, sınav dürüstlüğüne sağlamak için güçlü bir yapı oluşturmayı hedefleyerek, bu tür davranışları doğru bir şekilde belirlemek ve kategorize etmek için çeşitli teknikler ve algoritmalar incelemişlerdir. Bu çalışma da, derin öğrenme yöntemlerinin sınav dürüstlüğüne artırma ve yüz yüze değerlendirmelerde hile yapmayı önleme potansiyelini ve arka planda bulunan göresellerin çıkartılarak, çıkan sonuçlardaki performans artışını inceleyerek mevcut literatüre katkıda bulunmayı amaçlamaktadır.

Sınıf ortamında yapılan sınavlarda kuşkulu hareketleri belirlemek için bilgisayarlı görme ve derin öğrenmenin kullanımı üzerine artan sayıda araştırma bulunmaktadır. Bu araştırmalar bilgisayarlı görme ve derin öğrenmenin sınıf içi sınavlarda kuşkulu hareketleri belirlemedeki potansiyelini ortaya koymakta, ancak aynı zamanda bu tekniklerin gizlilik ve şeffaflık sağlanması ve önyargıdan kaçınılması gibi yönlerinin ele alınması için daha fazla çalışmaya ihtiyaç olduğunun altını çizmektedir. Ayrıca, sistemin saha verileri üzerinde test edilmesi ve etkinliğinin alışılmış kopya teşhis yöntemleriyle kıyaslanması gerektiğini unutmamak lazım.

Daha önce yapılan araştırmalar klasik sınavlarda kopya çekmeye ilişkin kuşkulu hareketlerin saptanması için bir çok elektronik cihaz, yazılım araçları gibi çok farklı metot ve prosedürler araştırmıştır. Fakat bu metotların kısıtları ve üstesinden gelinmesi gereken zorlukları bulunmaktadır. Bu yöntemleri öncelikle kullanacak okul veya eğitim veren kurumların kullanımına sunulması için erişilebilir olmasına engel olabilecek teknik ekipman ve uygulamalara sahiptirler. Diğer bir kısıt ise kuşkulu davranışların tespiti için kullanılan yöntemlerle elde edilen biyometrik verinin kişisel veri olması nedeni ile bu verilerin toplanması ve işlenmesinin önündeki yasal

mevzuatlardır. Ayrıca çalışma esnasındaki davranışların hangisinin normal hangisinin kuşkulu davranış olduğunu saptamak için önceden belirlenmiş yönergeler davranış farklılıklarına bağlı olarak sonuçların hataya açık olmasıdır.

Bu kısıtları gidermek ve çözüm üretmek için bu araştırma sınıf ortamında yapılan klasik sınavlarda kopya çekme eylemini saptamak ve saptama esnasında görünenin arka planında bulunan görsellerin çıkartarak uygulamanın performans artışını sağlamak için yeni bir önerme içermektedir. COPYNet, sınıf ortamında kayıt altına alınan görüntü dizilerini incelemek ve öğrencilerin kuşkulu hareketlerini tespit etmek için derin öğrenme ve bilgisayarlı görüden faydalanmaktadır. COPYNet'in diğer metotlara göre farklı avantajları bulunmaktadır.

Örneğin:

- Normal bir kamera harici farklı bir cihaza ve uygulamaya gerek kalmadan, sınıfta doğru bir notadan video çekimi yapılması yeterlidir
- Sınıftaki öğrencilerin davranışlarından başka bir veri almaz ve kayıt etmez.. Kararları alırken açıklamalar yaparak şeffaflık ve hesap verebilirlik sağlar.
- Elde edilen verilerden öğrenerek değişken durumlara adapte olabilmek için sinir ağlarını kullanır. Standart kurallara ve sınırlara ihtiyaç duyulmaz. Ayrıca görüntü dizilerindeki video sekanslarındaki gürültü ve parazitlerle başa çıkabilir.

Sınav görevlileri COPYNet ile sınıf ortamındaki sınavları daha etkin bir şekilde takip edebilir, değerlendirebilir ve ayrıca sınav sonuçlarında doğru kararların verilmesini sağlar. COPYNET sınava giren öğrencilerin öğrenebilir bir sistem ile takip edildiklerini ve değerlendirildiklerini bildikleri için caydırıcı bir etkiye sağlar.

Bu çalışmanın temel amacı, bilgisayarla görme ve derin öğrenme tekniklerini kullanarak sınıf ortamında yapılan sınavlarda kuşkulu hareketlerin belirlenmesi ve tespit aşamasında video sekanslarında bulunan öğrenci harici objelerin çıkartılarak daha hızlı sonuçlar elde etmek için yeni bir çerçeve geliştirmek ve değerlendirmektir. Bu çalışmaya rehberlik eden spesifik araştırma soruları şunlardır:

- Sınav odalarında görüntü sekanslarını incelemek ve öğrenciler arasındaki kuşkulu hareket formatlarını tespit etmek ve görüntülerdeki arka planın çıkartılması için bilgisayarlı görme ve derin öğrenme yöntemleri nasıl kullanılır?

- COPYNet ile kesinlik, etkinlik ve performans bakımından mevcut kuşkulu hareket tespit metotları ile nasıl kıyaslanır?
- Önerilen COPYNet çerçevesinin sınav doğruluğunu yükseltmek ve sınıf ortamında kopya çekme eylemini azaltmada faydası nedir?

Bu çalışma, bu araştırma sorularını yanıtlayarak, sınıf ortamında kopya tespiti ve arka plan çıkararaj performans artışı konusundaki bilgi ve uygulamaları geliştirmeyi ve davranış analizi ve olağandışılık tespiti için bilgisayarla görme ve derin öğrenmenin potansiyelini göstermeyi amaçlamaktadır. COPYNet mimarisindeki %90' lık hassasiyet, %88' lik geri çağırma ve %88' lik doğruluk, mevcut bu çalışmada arka plan çıkarımı temel işlev olarak yapılmış olup %90 ile hassasiyet aynı kalırken, %94 lük geri çağırma ve %90' lık doğruluk oranlarıyla iyileştirme sağlanmıştır.

Tez çalışması aşağıdaki şekilde düzenlenmiştir:

Bölüm 1: Sınıf ortamında yapılan sınavlarda kopya tespitine ilişkin metodların temelleri sunulmaktadır.

Bölüm 2: Sınavlar esnasında kuşkulu hareketleri saptamak için ortaya konulan çerçevesi ile birlikte veri seti ve önerilen model anlatılmaktadır.

Bölüm 3: Ön işleme adımları ve özellik çıkarma ile birlikte çalışmada yer alan bilgisayarla görme ve obje algılama metotları açıklamaktadır.

Bölüm 4: Bilgisayarla görme ve derin öğrenme modellerinin kopya tespitindeki arka plan çıkararak performans artışı sunmaktadır. Modellerin performansını kopya tespitinde kullanılan mevcut yöntemlerle karşılaştırmakta ve sonuçları açıklamaya yardımcı olmak ve analizden elde edilen içgörülerini vurgulamak için görselleştirmeler sunmaktadır.

Bölüm 5: Çalışma, ilk olarak temel bulgularını özetleyerek başlamaktadır. Daha sonra, araştırmanın önemini vurgulayarak sınıf içi sınavlarda kopya tespiti alanına katkılarını belirtmekte ve gelecekteki araştırmalar ile sonuçların pratik uygulamaları için öneriler sunmaktadır. Araştırma hedefleri ve soruları, bu çerçevede yorumlanmakta ve ele alınmaktadır.


1. KULLANILAN YÖNTEMLERİN TEMELLERİ

Yapay Zeka alanındaki kullanılan altyapıların performanlarının artışı yapay sinir ağıları modelinin verimli kullanımına katkı sağlamıştır. Son 20 yılda yapılandırılmamış veride etikenlenmeyecek kadar büyük bir artış olmuştur. Görüntü işleme verinin eş zamanlı değerlendirilmesinde ve problemin giderilmesinde yeterli olamamıştır. Bu yetersizlik noktasında çözüm sağlayan derin öğrenme etkili öğrenme yeteneğiyle ve metotlarıyla birçok sorunda yüksek doğrulukta sonuçlar sağlamış ve sağlamaya devam etmektedir.

Endüstriyel, sağlık, askeri, eğitim ve akademik gibi bir çok alanda, derin öğrenme yöntemleri, bilhassa görüntü işleme ve büyük veriyi anlamlandırmada etkin bir noktadadır. Görüntü işlemedeki obje algılama ve takip etme, son zamanlarda araştırmacıların dikkatini çekmiş ve önemli bir inceleme başlığı haline gelmiştir. Videolardaki objelerin tespiti kolay bir işlem değildir. Derin öğrenmede bulunan çeşitli metotlar ile obje tespiti ve takibi yüksek seviyede başarılı bir şekilde yapmaktır. Örnek olarak resim ve hareketli görüntülerde bir nesnenin algılanması ve takibi için objenin hızı, şekli ve konumu kullanılabilir. Ayrıca, görüntülerdeki tespit etmeye çalışılan objenin arka planın videodan ayıklanması, takip edilecek objenin özelliklerinin tespiti, sınıflandırılması gibi adımlarda da objenin saptanması ve takibi yapılabilir. Bu süreçte, problemi en iyi çözecek doğru algoritmanın ve mimarinin seçilmesi büyük önem taşır.

1.1. Derin Öğrenme

Derin Öğrenme, yüksek düzeyde soyutlanmış veri özelliklerini otomatik olarak öğrenebilir ve temsil edebilme yeteneğiyle öne çıkar. Genellikle katmanlı bir yapı kullanır ve bu katmanlar, veriyi işlemek ve daha yüksek düzeyde temsil yeteneği kazanmak için birbirleriyle bağlantılıdır. Birçok uygulama alanında, özellikle görüntü tanıma, doğal dil işleme, otomatik araba sürüşü gibi alanlarda önemli başarılar elde etmiştir (Deng, Huang, Yao, Yu, Seide ve Acero, 2013). 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, derin öğrenme ağının mimarisini gözler önüne sermektedir.



Şekil 1. Derin Sinir Ağı Mimarisi

Kaynak: Sırt, D. (2023). *Bilgisayarlı görü ile yüz yüze sınavlarda şüpheli davranışların ortaya çıkarılması için derin öğrenme çerçevesi tasarımı*. [Doktora tezi]. Milli Savunma Üniversitesi. YÖK Açık Erişim: <https://tez.yok.gov.tr/UlusalTezMerkezi/>

- **Giriş Katmanı (Input Layer):** Bu katman, modelin dış dünyadan gelen veriyi alır ve içerideki diğer katmanlara iletmek için işler. Giriş katmanı, genellikle veri setindeki her bir özellik veya boyut için bir düğüm içerir.
- **Gizli Katmanlar (Hidden Layers):** Bu katmanlar modelin öğrenme yeteneğini belirler. Gizli katmanlar, veri setindeki özellikler arasında öğrenilen gizli ilişkileri temsil etmek için kullanılırlar. Her gizli katman, bir dizi yapay sinir hücresinden veya nöronundan oluşur. Bu nöronlar, giriş verilerinden gelen sinyalleri alır, bunları ağırlıklarla çarparak bir aktivasyon fonksiyonuna sokarlar ve ardından sonuçları bir sonraki katmana iletirler.
- **Çıkış Katmanı (Output Layer):** Modelin sonucunu veya tahminini üretir. Genellikle aktivasyon fonksiyonları (örneğin, sigmoid veya softmax) kullanılarak sonuçlar belirli bir formata (örneğin, olasılık) dönüştürülür. Çıkış katmanı, giriş katmanından ve gizli katmanlardan gelen bilgileri kullanarak sonuçları üretir. Bu katmanda, öğrenme süreci boyunca öğrenilen özellikler ve ilişkiler göz önünde bulundurularak bir çıktı oluşturulur. Modelin eğitimi sırasında, çıkış katmanı üretilen sonuçları gerçek etiketlerle karşılaştırarak hata veya kayıp fonksiyonunu hesaplar, böylece modelin performansını değerlendirir ve geliştirir.

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.


1.1.1. 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 ve 1960'lı Yıllar: Bu dönem, derin öğrenme ve yapay zeka alanının temellerinin atıldığı kritik bir zamandı. 1943' de Yapay sinir ağlarının temelini oluşturan McCulloch-Pitts hücresi, Warren McCulloch ve Walter Pitts tarafından tanıtıldı. Bu model, biyolojik sinir hücrelerinin basit bir yapısını taklit ederek matematiksel bir model oluşturdu. 1957' de Frank Rosenblatt tarafından geliştirilen perceptron, sinir ağlarının erken bir formuydu. Basit bir tek katmanlı sinir ağı olan perceptron, girişleri ağırlıklarla çarparak ve bir eşik değerini geçip geçmediğini kontrol ederek bir çıktı üretti.
- 1960 ve 1980'li Yıllar: Bu dönemde, makine öğrenimi ve yapay sinir ağları, denetim sistemleri ve uyarlanabilir kontrol sistemleri gibi uygulamalarda kullanılmaya başlandı. Bu alanlarda yapılan çalışmalar, yapay sinir ağlarının pratik uygulamalarını gösterdi. 1960'larda Arthur Samuel ve Bernard Widrow gibi araştırmacılar, gerileme algoritması olarak bilinen geri yayılım algoritmasını geliştirdiler. Bu algoritma, yapay sinir ağlarının eğitimi için önemli bir teknikti ve modelin hatasını geriye doğru yayarak ağırlıkları güncellemeyi sağladı. 1980'ler Yapay sinir ağları ve derin öğrenme, uzman sistemler ve sembolik yapay zeka yöntemlerinin yerini almaya başladı. Yeni aktivasyon fonksiyonları ve eğitim algoritmaları geliştirildi ve sinir ağlarına olan ilgi yeniden arttı.

- 1990'lı Yıllar: Yapay sinir ağlarının eğitimi için yeni teknikler ve algoritmalar geliştirildi. Derin öğrenmenin yeniden popüler hale gelmesine rağmen, 1990'ların başlarında hala bazı zorluklar ve başarısızlıklarla karşılaşıldı. Özellikle, daha derin ve karmaşık ağların eğitimi için hesaplama gücü ve veri setleri yetersizdi. Özellikle, Levenberg-Marquardt algoritması gibi ikinci dereceden optimizasyon teknikleri, eğitim sürecini hızlandırmak ve daha iyi sonuçlar elde etmek için kullanıldı. Hinton ve diğerleri tarafından geliştirilen kontrastif artırma ve gerileme algoritması, enerji tabanlı modellerin eğitimi için önemli bir teknikti. Bu algoritma, özellikle sınıflandırma ve öznetelik öğrenme problemlerinde başarılı sonuçlar verdi.
- 2000'li Yıllar: 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. 2012' de AlexNet'in öncülüğünde yeni ve daha derin CNN mimarileri geliştirildi. Bu mimariler, daha önceki modellere göre daha fazla katmana ve daha karmaşık yapıya sahipti, bu da daha iyi performans sağladı. Google, Facebook, Microsoft, Amazon ve diğer büyük teknoloji şirketleri, derin öğrenme araştırma ve geliştirmesine büyük yatırımlar yaptı. 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'de derin öğrenme zaman çizelgesi gösterilmiştir.



Şekil 2. Derin Öğrenme Zaman Çizelgesi


Kaynak: Sırt, D. (2023). *Bilgisayarlı görü ile yüz yüze sınavlarda şüpheli davranışların ortaya çıkarılması için derin öğrenme çerçevesi tasarımı*. [Doktora tezi]. Milli Savunma Üniversitesi. YÖK Açık Erişim: <https://tez.yok.gov.tr/UlusalTezMerkezi/>

1.1.2. Derin Öğrenme Mimarileri

Kaliteli sonuçlar elde etmek için büyük veri setlerine ihtiyaç duyan bu yaklaşım, çok katmanlı sinir ağları 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) :** Özellikle görüntü işleme ve görsel tanıma alanında etkili olan bir derin öğrenme mimarisidir. CNN'ler, evrişim (convolution) ve havuzlama (pooling) katmanlarından oluşur ve özellikle görsel verilerdeki özelliklerin çıkarılması için kullanılır. Gelişmiş CNN mimarileri arasında ResNet,


Inception ve EfficientNet gibi modeller bulunmaktadır. Bu modeller, derinliklerini ve performanslarını artırırken hesaplama maliyetlerini azaltma yönünde yenilikler sunmaktadır.



Şekil 3. Evrişimli Derin Sinir Ağı Model Mimarisi

Kaynak: Allayla, N. M., Ibraheem, F. N., Jaleel, R. A., (2022). *Enabling image optimization and artificial intelligence technologies for better Internet of Things framework to predict COVID*


- Yineleyen Sinir Ağları (RNN) ve Uzun Ömürlü Kısa Dönem Belleği (LSTM): RNN'ler, herhangi bir zaman adımıdaki çıkışı, önceki zaman adımlarındaki çıkışlarla birlikte alarak geri besleme yaparlar, bu da ardışık verilerdeki bağımlılıkları modellemek için idealdir. Uzun Ömürlü Kısa Dönem Belleği (LSTM) ise RNN'lerin bir türüdür ve daha uzun süreli bağımlılıkları daha etkili bir şekilde modellemek için tasarlanmıştır. Ancak, uzun bağımlılıkları öğrenmede zorluklar yaşadıkları bilinmektedir. Bu sorunu çözmek için LSTM ve Kapılı Yineleyen Hücre (GRU) gibi gelişmiş RNN türleri geliştirilmiştir. RNN ve özellikle LSTM, doğal dil işleme, metin üretimi, dil modellemesi, zaman serisi analizi ve çeviri gibi birçok ardışık veri işleme görevinde başarılı olmuştur. Son yıllarda, daha verimli ve hızlı LSTM varyasyonları geliştirilmekte ve gerçek zamanlı uygulamalar için optimize edilmektedir.



Şekil 4. Yineleyen Derin Sinir Ağı Model Mimarisi

Kaynak: Yazar tarafından oluşturulmuştur.

- Sınırlı Boltzmann Makineleri (RBM) : RBM'ler, belirli bir girdi verisi kümesini temsil eden gizli özellikleri (latent features) öğrenmek için kullanılır. Özellikle, boyut azaltma, özellik çıkarma, ve öznitelik öğrenimi gibi görevlerde başarıyla kullanılırlar. Ayrıca, diğer derin öğrenme modellerinin ön işleme aşamasında veya generatif modellerin oluşturulmasında da görev alır.
- 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 5. Derin Otokodlayıcılar Sinir Ağı Model Mimarisi

Kaynak: Sirt, D. (2023). *Bilgisayarlı görü ile yüz yüze sınavlarda şüpheli davranışların ortaya çıkarılması için derin öğrenme çerçevesi tasarımı*. [Doktora tezi]. Milli Savunma Üniversitesi. YÖK Açık Erişim: <https://tez.yok.gov.tr/UlusalTezMerkezi/>

- Derin İnanç Ağları (DBN): Çok katmanlı olmaları ve özellikle derin öğrenme modellerinin ön eğitimi için kullanılmalarıyla bilinen DBN'ler, genellikle boyut azaltma, özellik çıkarma, veri sıkıştırma ve temsil öğrenimi gibi alanlarda kullanılır. Özellikle, büyük veri setlerindeki karmaşık yapıları analiz etmek ve anlamak için etkili bir araçtır. Ayrıca, derin öğrenme modellerinin ön işleme aşamasında DBN'ler kullanılabilir.
- 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.

Objeye takip teknikleri, görüntü dizilerinde ilgilenilen objelerin hareketini izlemek ve takip etmek için bilgisayarla görme alanında kapsamlı bir şekilde araştırılmıştır. Çeşitli obje izleme yöntemlerini ve algoritmalarını kapsamlı bir şekilde inceleyen ve bu alandaki ilerlemelere ve zorluklara ışık tutan araştırmalar yapılmıştır (Yılmaz, Javed ve Shah, 2006), (Popoola ve Wang, 2012), (Vishwakarma ve Agrawal, 2013), (Borges, Conci ve Cavallaro, 2013), (Tripathi, Jalal ve Agrawal, 2018). Bu bilgi birikimi, sınıf ortamında yapılan sınavlar sırasında kuşku hareket kalıplarını tespit etmek ve izlemek için objeye takip tekniklerini uygulamak için bir temel oluşturarak doğru izleme sistemlerinin geliştirilmesini sağlar.

Derin öğrenme, karmaşık veri yapılarını işleyebilme ve örüntüleri tanıyabilme yeteneği ile insan hareketlerinin incelenmesinde önemli bir role oynar. Özellikle, davranışsal verilerin, yüz ifadelerinin, vücut davranışlarının ve ses tonunun incelenmesinde kullanılan evrimsel sinir ağları ve yineleyen sinir ağları gibi derin öğrenme modelleri, insan davranışlarının derinlemesine anlaşılmasını sağlar. Bu modeller, büyük veri yapılarında karmaşık desenleri ve ilişkileri öğrenerek, insan davranışlarının daha doğru bir şekilde analiz edilmesine olanak tanır.

Normal olmayan davranışların tespiti, özellikle güvenlik ve sağlık alanlarında hayati öneme sahiptir. Derin öğrenme tabanlı sistemler, gözetim kameraları

aracılığıyla toplanan verileri analiz ederek, şüpheli veya tehlikeli davranışları otomatik olarak tespit edebilir. Örneğin, kalabalık bir alanda şiddet eylemleri veya acil tıbbi müdahale gerektirebilecek durumlar, bu sistemler tarafından hızlıca saptanabilir ve ilgili yetkililere bildirilebilir.

Eğitim alanında da derin öğrenme, öğrencilerin davranışlarını analiz etmek ve eğitim süreçlerini iyileştirmek için kullanılabilir. Öğrencilerin ders içerisindeki katılımlarını, dikkat seviyelerini ve öğrenme stillerini anlamak için derin öğrenme tabanlı araçlar, öğretmenlere önemli bilgiler sağlayabilir. Bu bilgiler, öğrencilerin ihtiyaçlarına daha iyi yanıt vermek ve eğitim kalitesini artırmak için kullanılabilir.

Son yıllarda araştırmacılar, kalabalık ortamlarda davranış analizi ve anormallik tespiti bağlamında derin öğrenme tekniklerinin uygulanmasını da araştırmışlardır. Bu amaçla, kalabalık ortamlardaki kolektif davranışları tanımlamayı ve analiz etmeyi amaçlayan video dizileri kullanılarak çevrimiçi gerçek zamanlı bir kalabalık davranış algılama yöntemi önerilmiştir (Pennisi, Bloisi ve Iocchi, 2016). Ayrıca, sınıf incelemelerinde şüpheli insan faaliyetlerini tespit etmek için bilgisayarla görme teknikleri ve davranış analizi kullanan başka yöntemler de sunulmuştur. Bu çalışmalar, karmaşık insan davranışlarını analiz etmek ve anormal faaliyetleri tespit etmek için derin öğrenmenin potansiyelini göstermektedir (Senthilkumar ve Narmatha , 2016), (Soman, Srinivasa ve Devi, 2017), (Gowsikhaa, Manjunath ve Abirami, 2012), (Debnath, Rashed ve Dipankar, 2018).

Sınıflardaki sınavlarda normal dışı davranışları etkin bir şekilde saptamak ve tanımlamak için çeşitli derin öğrenme teknikleri incelenmiştir. Sınavlar sırasında öğrencilerin olması gerekenden farklı davranışları izlemek ve tanımlamak için sinir ağları ve Gauss dağılımlarını kullanan gerçek zamanlı bir anormal davranış algılama sistemi önerilmiştir (İbrahim, Abosamra ve Dahab, 2018). İnsan eylemi tanımanın doğruluğunu artırmak için, video dizilerindeki uzamsal-zamansal bilgilerden yararlanmak üzere Evrimsel Sinir Ağları kullanılmaktadır (Ji vd., 2013), (Simonyan ve Zisserman, 2014), (Zhou, Shen ve Zeng, 2016). 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 (Girshick, 2015), (Ren vd., 2015). 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.

1.1.3. 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, gerçek nesneyi tam olarak kapsamayı ve aynı zamanda diğer nesnelerden ayrılmasını sağlayacak hassas bir şekilde konumlandırılmasında üstündür; bu sınav esnasında etrafındaki diğer öğrencilerin sınav kağıtlarına veya cep telefonuna bakmak gibi hassas kopya eylemlerini farketmek için çok önemlidir. Faster R-CNN modelinin tercih edilme sebebi sınavlar esnasında doğru objenin lokalizasyonu sağlama yeteneğidir. Bu yeteneği ile, sınavdaki öğrencilerin takibi ve normal olmayan davranışların yakalanması açısından kritik bir öneme sahiptir. Herbir objenin hareketli görüntü içerisindeki yerini tespit etmede Faster R-CNN'nin iki aşamalı mimarisi hassas ve doğru sonuçlar sağlar

Sınav esnasında öğrencilerin kopya çekme denemelerini yakalamak için objelerin görüntülerdeki konumunu net bir şekilde bilmek gerekir. Bir öğrencinin kendi sınav kağıdı yerine başka birinin sınav kağıdına bakarken yakalanması, Faster R-CNN'nin iki aşamalı mimarisi kazandırdığı bir yetenektir.

Faster R-CNN'nin kullanıldığı örnek çalışmalarda, objelerin yerinin kesin bir şekilde belirlenmesi, modelin anormallik davranışları tespit etme becerisini artırır. Öğrencilerin kendi kağıdı yerine başkasının sınav kağıdına bakması veya sınav esnasında kullanılması yasak materyalleri kullanma yönelimi gibi sınav bütünlüğünü bozucu hareketleri tespit etmek için nesnelerin konumlarının hassas bir şekilde bilmek üretilen sonucun doğruluğunda büyük katkı sağlar. Bu, sınav bütünlüğünü koruma ve adil bir sınav deneyimi sağlama konusundaki amaçlara hizmet eder.

Faster R-CNN ile doğru lokalizasyonu elde etmek, hızlı ve etkin olarak objelerin kategorilendirilmesinde ve tanımlanmasına fayda sağlar. Çift aşamalı mimari, ilk aşamada görüntülerden özellik haritaları çıkararak nesnelerin yaklaşık konumlarını belirler ve ikinci aşamada bu konumları daha detaylı ve hassas hale getirir. Bu şekilde özellikle tespiti zor 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 normal olmayan hareketleri tespit etmek ve sınav bütünlüğünü korumak için kritik bir rol oynar. Bu özellik, nesnelerin hassas bir şekilde belirlenmesini sağlar ve modelin normal olmayan 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:** Çapa tabanlı öneri üretim yeteneği Faster R-CNN modelinin tercih edilmesinde, önemi bir özellik olarak karşımıza çıkar. Nesnelerin tespiti için önemli bir aşama olan bu yetenek, sınav gözetimi ve normal olmayan davranışların tespitinde büyük bir rol oynar. Faster R-CNN'nin öneri üretim ağı (RPN), objelerin tanımlanması için tavsiyeler üretir ve bu tavsiyeler ikinci bir aşamada işlenir. Bu çapa tabanlı yaklaşım, belirli objelerin hassas konumlarını belirlemeye yardımcı olur ve böylece sınavlarda kopya veya yasaklı materyal kullanımı gibi normal olmayan davranışları yakalama yeteneğini artırır.

Faster R-CNN'nin çapa tabanlı öneri üretimi ağı, hareketli görüntüler üzerinde obje konumlarını öneriler şeklinde önerir. Bu öneriler, sınav ortamı görünsünün başka noktaların olası obje koordinatlarını temsil eder. Özellikle sınav gözetimi planlarında, belirli objelerin konumu net olarak tespit edilmelidir. Örneğin, öğrencinin kendisine ait sınav kağıdı yerine elektronik bir cihaza bakarken tespit edilebilmesi için, elektronik cihazın net konumu önemlidir. Çapa tabanlı öneri üretimi, bu tür öğelerin doğru konumlarını belirleme konusunda büyük ölçüde fayda sağlar.

Faster R-CNN'in çapa tabanlı öneri üretimi, sınavlar sırasında ince ve minik objelerin saptanması için çok kullanışlıdır. Özellikle kopyaların yazıldığı kağıtlar gibi minik objeler, alışlagelmiş teknikler ile saptanması çok zor olabilir. Fakat çapa tabanlı öneri üretimi, bu tür ince ve minik objelerin saptanmasını kolaylaştırır ve bu sayede

normal olmayan davranışların tespitini daha verimli kılar. Bu, sınavların güvenliğini artırma ve herkes için eşit koşullarda bir sınav süreci yaşatılması bakımından önemlidir. Sonuç olarak, Faster R-CNN'nin çapa tabanlı öneri üretimi özelliği, sınıf ortamındaki sınav esnasında normal olmayan hareketlerin saptanması becerisinin artışında önemli bir katkı sağlamaktadır. Bu özellik, nesnelerin konumlarının hassas bir şekilde tespit edilmesini sağlar ve bu şekilde sınıf ortamında yapılan sınavlarda kopya veya yasaklı materyal kullanımı gibi normal olmayan hareketlerin saptanmasını kolaylaştırır. Bu da sınav bütünlüğünü koruma ve sınava giren bütün öğrenciler için eşit koşullarda sınav süreci yaşatılması açısından büyük bir öneme sahiptir.

Katmanlı mimari yapısının sağladığı faydalar nedeni ile Faster R-CNN modeli tercih edilmiştir. Bu katmanlı yapı, obje saptanması görevlerini daha verimli bir şekilde yerine getirmesi için tasarlanmıştır ve sınıf ortamındaki sınav gözetimi ve normal olmayan hareketlerin saptanması gibi görevlerde büyük bir öneme sahiptir.

- **Katmanlı Mimari :** Faster R-CNN'nin katmanlı mimari yapısı, iki aşamadan oluşur. Birinci aşamada, video üzerindeki özellik haritaları üretilir. Bu özellik haritaları, görüntünün farklı özniteliklerini temsil eden matrislerdir ve objelerin bariz özelliklerini tespit etmek için kullanılır. İkinci aşamada ise, öneri üretimi ve sınıflandırma işlemi yapılır. Bu aşamada, çapa tabanlı öneri üretimi ve obje sınıflandırma yapılarak objelerin saptanma işlemleri tamamlanır.

Katmanlı mimari, sınav gözetimi ve normal olmayan davranışların tespiti sorumluluklarında çok etkilidir. Çünkü her iki aşama da özel görevler için daha etkin hale getirilebilir. İlk aşamada, obje konumlarını daha net bir şekilde tespit etmek için özellik haritaları hassas bir şekilde oluşturulabilir. Bu, hassas kopya çekme davranışlarını veya kullanılmaması gereken materyalin saptanması becerisini artırır.

İkinci aşamada, çapa tabanlı öneri üretimi ve obje kategorizasyonu, modelin belirli objeleri veya hareketleri tespit yeteneğini yukarıya taşır. Bu, özellikle sınavlarda tespit edilmesi önem arzeden obje gruplarının veya hareket setlerinin tanımlanmasında rol oynar ve büyük önem taşır. Örneğin, elektronik bir cihaz veya üzerinden kopyaların olduğu objeler gibi belirli nesnelerin saptanması, sınav bütünlüğünün korunması açısından büyük bir öneme sahiptir.

Sonuç olarak, Faster R-CNN'nin katmanlı mimari yapısı, sınav gözetimi ve normal olmayan hareketlerin saptanması görevlerini başarılı bir şekilde yerine getirir ve özel görevlere göre tasarlanabilir. Bu yapı, obje saptanması görevlerini daha verimli bir şekilde yerine getirir ve sınavlarda normal olmayan hareketlerin saptanması becerisini yukarı taşır. Bu da sınav bütünlüğünü koruma ve sınava giren tüm öğrenciler için eşit bir sınav süreci geçirmesi bakımından önemlidir.

- **Birden Fazla Nesnenin Tespiti:** Faster R-CNN modelinin tercih edilme sebeplerinden biride, eş zamanlı olarak birden fazla objenin saptanmasını etkin bir şekilde yerine getirebilme becerisidir. Bu özellik, sınav gözetimi ve normal olmayan hareketlerin saptanması gibi görevlerde büyük bir öneme sahiptir ve modelin birden fazla objenin veya davranışların saptanma becerisini artırır.

Faster R-CNN, birden fazla objenin saptanması noktasında çok etkilidir Çünkü iki aşamalı mimarisi özel olarak tasarlanmıştır. Birinci aşamada, görüntüde buluna özellik haritaları üretilir ve bu haritalar, başka nesnelerin özelliklerini tespit etmek için kullanılır. İkinci aşamada ise, çapa tabanlı öneri üretimi ve obje sınıflandırma işlemi gerçekleştirilir. Bu aşamada, model eş zamanlı birden fazla objeyi saptayabilir.

Bu yetenek, sınav gözetimi görevlerinde çok faydalıdır. Örneğin, sınıf ortamında yapılan sınav esnasında birden fazla öğrencinin aynı anda normal olmayan hareketler segilediğini düşünelim. Bu tür durumları Faster R-CNN modeli ile anlayabilir ve birden fazla obje tespit edebilebilir. Bu, adil bir sınav koşulu sağlanması bakımında büyük bir öneme sahiptir.

Benzer obje veya hareketin birden fazla versiyonlarını belirlemek için bu model kullanılabilir. Örneğin, cep telefonu kullanımını yakalamak istediğimizde, başka telefon modelleri veya kullanım tarzlarını belirlemek gerekebilir. Bu tür farklılıkları ele alırken Faster R-CNN'nin birden fazla objeyi eş zamanlı saptama yeteneği işimiz kolaylaştırır.

Sonuç olarak, Faster R-CNN'nin çoklu objelerin tespitini etkin bir şekilde yerine getirme becerisi, sınav gözetimi ve normal olmayan hareketlerin saptanması gibi işlerde modelin birden fazla objeyi veya davranışı belirleme yeteneğini artırır. Bu da sınav bütünlüğünü koruma ve sınava giren tüm öğrenciler için eşit bir sınav süreci geçirmesi bakımından önemlidir.

Bununla birlikte, Darknet çerçevesi tanıtılmış ve YOLO mimarisi, açık kaynaklı bir çerçeve olarak nesne algılama ve sınıflandırma görevlerine odaklanmak için geliştirilmiştir (Redmon vd., 2016). 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 (Redmon ve Farhadi, 2017). Bu ilerleme, gözetim sistemlerinin çok çeşitli nesneleri tespit etme ve tanıma kapasitesini artırarak yüz yüze sınavlarda kapsamlı izleme ve değerlendirmeye olanak tanır.

1.1.4. YOLOv5: You Only Look Once

YOLOv5 modeli, obje tespiti alanında çığır açan bir modeldir ve sınıf ortamında yapılan sınavlardaki normal olmayan davranışların saptanması konusunda sunmuş olduğu yetenekler oldukça güçlüdür. YOLOv5'i tercih ederken bu güçlü özellikler rehberlik etmiştir.

Eş zamanlı veri işleme becerisi, YOLOv5'i sınav yapılan sınıflar için özellikle uygun hale getirir. Bu beceri nedeniyle, sınavın hareketli doğası göz önüne bulundurulduğunda kuşkulu hareketler hızlı bir şekilde saptanabilir. Öğrencilerin davranışları, yanlarında bulunan kopyalar üzerinden sınav bütünlüğünü tehlikeye sokacak eylemleri anında tespit edilir ve bu da sınavın bütünlüğünü koruma açısından son derece önemlidir.

Obje tespit etme sürecini sadeleştirerek ve tek bir geçişte bütün görüntüyü detaylı bir şekilde taranması YOLOv5'in etkili mimarisinin sonucudur. Bu, hızlı ve hassas kopya davranışlarını tespit etmek için büyük bir katkı sağlar. Çünkü model, her bir görüntüyü çok hızlı bir şekilde işleyebilir ve bu da sınav bütünlüğü kesintiye uğratmaz.

Modelin yüksek ölçekli tespit yeteneği, farklı ölçülerdeki objelerin saptanmasını sağlar. Özellikle küçük elektronik cihazları veya kopya çekmek için kullanılmak istenen küçük kopya kağıtları saptanması için son derece uygun bir

özelliktir. Bu, sınav sahnelerindeki çeşitli objelerin saptanmasına ve sınıflandırılmasına yardımcı olur.

YOLOv5'in obje tespit becerisi çok etkileyicidir. Öğrencilerin sınav esnasında kullanabileceği elektronik cihazlar veya kopya notları gibi belirli objeleri tespit etme becerisi, sınav bütünlüğünü korumak için son derece faydalıdır. Model, bu objeleri çok çabuk bir şekilde algılayabilir ve bu objelerin sınav ortamında bulunduğunu saptayarak gerekli önlemlerin alınmasına katkı sağlar.

YOLOv5'i diğerlerinden ayıran en büyük özelliklerinden biride farklı çözünürlüklere uyarlanabilir olmasıdır. Sınıf ortamında yapılan sınav esnasında kullanılan görüntü kayıt cihazlarının kalitesi ve sınava giren öğrencilerin duruşları farklılık gösterebilir. 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 ilgi çekici yeteneklerinden biri, görüntüleri eş zamanlı olarak işleme yeteneğidir. Bu, sınav esnasında dinamik ve hızlı değişimlere hızlı bir şekilde yanıt verme yeteneği sunar.

Öğrencilerin kuşkulu hareketleri hemen saptanır ve gerekli aksiyonlar hızla alınabilir. Bu, sınav bütünlüğünün korunmasında hayati bir öneme sahiptir.

- **Verimli Mimari:** YOLOv5, tek aşamalı bir mimariye sahiptir ve buda obje tespiti aşamasını son derece etkin hale getirir. Görüntüyü tek bir geçişte eksiksiz bir şekilde analiz etme becerisi, hızlı ve hassas sonuçlar elde edilmesini sağlar. Özellikle hassas kopya çekme eylemlerinin tespiti bakımından büyük bir katkı sağlar ve sonuç üretme süresini minimuma indirir.
- **Çok Ölçekli Algılama:** YOLOv5, obje tespiti işlemi sırasında çok ölçekli bir yaklaşım benimser. Bu, farklı ölçülerdeki objelerin tespitini yardımcı olur ve küçük objelerin, örneğin, elektronik cihaz veya kopya notu bulunan kağıtlar gibi, daha hassas bir şekilde tespit edilmesini sağlar. Bu çok ölçeklenebilir yaklaşım, farklı sınav merkezlerinde farklı objelerin verimli bir şekilde saptanmasına olanak sağlar.

Nesne Algılama: YOLOv5, sınavlar esnasında ön tanımlı objeleri tespit becerisine sahiptir. Örneğin, elektronik cihazlar veya kopya notları gibi ne olduğunu tahmin

edilebilen objeleri algılayabilir ve bu objeleri ilgili sınıflarına ayırabilir. Buda, sınıf ortamında yapılan sınavın güvenliğini sağlama açısından son derece önemlidir ve kopya denemelerinin tespit etme becerisini 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.

1.2. Teknoloji Türleri

Güvenlik gereksinimlerinin hızla arttığı bu dönemlerde gözetim sistemleri bu ihtiyacı karşılamak için vazgeçilmez araçlar haline ulaşmıştır. Bu sistemler, normal olmayan davranışları tespit etme yeteneği ile birlikte objeleride tanımlamaktadır. Normal olmayan davranış tespiti, insanların fazla olduğu ortamlarda etkin güvenlik önlemlerinin alınabilmesinde destekleyici olur ve yaşanması muhtemel vakaların olmadan önce tahmin edilmesine katkı sağlar. Son on yılda, derin öğrenme yöntemleri, bu alanda çığır açmıştır. Derin öğrenme, karmaşık gözetim verilerini inceleme becerisi ile normal olmayan davranışların tespitini daha da ileriye götürmüştür. Önceden eğitilmiş derin öğrenme modelleri, gözetim sistemlerinin normal olmayan davranış tespitlerinin daha hassas bir şekilde belirlmesini sağlayarak güvenlik bakımında önemli bir katkı sunar.

Nesne tespitinin yanı sıra, denetim videolarında normal olmayan davranış tespiti, sınav bütünlüğünü sağlamanın en önemli yönüdür. Derin öğrenme teknikleri kullanılarak normal olmayan davranış saptanması için hareketli görüntülerin modelleme temsilleri incelenirken (Chong ve Tay, 2015), derin öğrenme kullanılarak kalabalık analizi için akıllı video gözetim teknikleri sunulmakta, kalabalık davranışının anlaşılması ve anormallik tespitine odaklanılmaktadır (Sreenu ve Saleem Durai, 2019). Bu yöntemler, kişilerin birlikte hareket etme davranışlarını inceleyerek kalabalık analiz ortamlarındaki kuşkulu veya normal olmayan faaliyetleri tespit edebilir.

Transfer öğrenme, gözetim sistemlerinin başka bir güçlü yanıdır. Bu yöntem, öğrenilmiş bilginin farklı işlerde veya veri topluluklarında nasıl kullanılabileceğini araştırmaktadır. Gözetim videolarında normal olmayan davranışların yakalanması için transfer öğrenme teknikleri kullanıldığında, farklı alanlardan veya veri yapılarından sağlanan bilgiler entegre edilir. Bu, sistemin yeni ve normal olmayan davranışları daha etkin olarak tespit etme becerisini geliştirir ve güvenlik bakımında daha yüksek bir koruma oluşturur. Özellikle bu yaklaşım, gerçek hayat senaryolarına normal olmayan şüpheli hareketlerin daha hassas bir şekilde tespit edilmesine katkı sağlar. Transfer öğrenme, gözetim sistemlerinin kapsamlı bir şekilde senaryolar için daha hızlı uyumlu hale gelmesine fayda sağlar ve güvenlik endüstrisindeki ilerlemelere hız katar.

Bir alandaki başarıyı artırmak için kullanan bir yöntem olan transfer öğrenme, başka bir alandan öğrenilen bilgiyle başka gözetim sistemlerinde de uygulanabilir. Makine öğrenimi görevlerinde veriyi bir çalışma alanından diğer çalışma alanına aktarmak için kullanılan farklı yaklaşımları ve teknikleri tartışan transfer öğrenme üzerine bir anket araştırması düzenlenmiştir (Pan ve Yang, 2010). Transfer öğrenme yöntemlerinden faydalanarak denetim videolarında normal olmayan davranışların tespiti için geliştirilmiş bir derin öğrenme yöntemi tanıtılmıştır (Khaleghi ve Moin, 2018). Önceden eğitilmiş modellerden veri alınarak, normal olmayan davranışları saptama sistemlerinin performansı büyük ölçüde yükseltilebilir ve bu da sınıf ortamında yapılan sınavlarda esnasında normal olmayan hareketlerin daha doğru bir şekilde tespit edilmesini sağlar

İnsan davranışlarını tespit etme çalışmalarında, transfer öğrenme ile kaydadeğer sonuçlar alınmıştır. Görüntüleri teşhis etmek ve insan davranışlarını tanımlamak için transfer öğrenmeye yönelen ve tanıma modellerinin performansını artırmak için farklı yöntemleri araştıran başka çalışmalar da vardır (Al-azzawi vd., 2023), (Pang, 2018), (Keçeli ve Kaya, 2017), (Mutegeki ve Han, 2019), (Cook vd., 2013). Transfer öğrenme, ilgili görevlerden veya eğitilmiş veri setlerinden elde edilen bilgilerden faydalanarak sınıf ortamında yapılan sınavların değerlendirme süreçlerinde belirli davranışların etkili bir şekilde tanınmasını sağlar.

İnsan davranışlarını tanımlama çalışmalarında, transfer öğrenme tekniklerinin kullanılması, denetim sistemlerinin gücünü büyük ölçüde artırmıştır. İnsan

davranışlarının doğru bir şekilde tanımlanması, güvenlik ve takip uygulama alanları için öncelikli sıradadır. Bu, kalabalık yerlerde, etkinliklerde, havaalanlarında, alışveriş merkezlerinde veya spor salonlarında güvenliği sağlamanın ana unsurudur. Transfer öğrenmenin avantajlarından biride, öğrenilen bilgi farklı çalışma alanlarına veya veri setlerine aktarılabilir. Bu şekilde sistemlerin farklı insan davranışlarını tanıma becerilerini artırır. Özellikle optik akış gibi teknikler, insanların fiziksel hareketlerini daha ayrıntılı ve dinamik bir şekilde analiz etmeye olanak tanır. Bu, güvenlik sistemlerinin normal olmayan veya potansiyel tehlike oluşturabilecek eylemleri daha hızlı bir şekilde algılamasına katkı sağlar. Güvenlik açısından önceden tahmin edebilirlik yeteneği ile birlikte daha yüksek bir koruma sağlar.

Kalabalık alanlarda normal olmayan davranış tespiti, özel bir zorluğu beraberinde getirir ve bu nedenle bu ihtiyacı karşılamak için çeşitli yöntemler geliştirilmiştir. Bu alanlar, normal olmayan eylemleri veya potansiyel tehlikeleri tespit etmek, genel olarak büyük veri akışlarını işlemek ve anlamak için karmaşık bir görevdir. Bu ve buna benzer zorlukları ortadan kaldırmak için yoğunluk ısı haritaları ve optik akış gibi teknikler önerilmiştir. Yoğunluk ısı haritaları, kalabalık alanlardaki yoğunluğu görsel olarak gösterir ve bu sayede normal olmayan kalabalık insan eylemleri daha kolay belirlemeye yardımcı olur. Optik akış ise, insanların hareketlerini daha detaylı bir şekilde inceleme fırsatı sunar. Bu, kalabalık alanlardaki normal olmayan eylemleri daha hızlı bir şekilde saptamaya katkı sunar ve güvenlik sistemlerinin daha doğru sonuçlar elde etmesini sağlar.

İnsan yoğunluğu fazla olan alanlarda normal olmayan davranışların saptanmasının zorluklarını incelemek için, optik akış ve ısı haritası kullanan teknikler önerilmiştir (Hao vd., 2021), (Lazaridis vd., 2018), (Kratz ve Nishino, 2009). Bu yöntem, insan yoğunluğunun fazla olduğu alanlarda yaşanabilecek normal olmaya olayların veya eylemlerin tanımlanmasını sağlar. Kalabalık alanlarda normal olmayan hareketlerin tanımlanması için hareket modellerini yakalamak ve normal olmayan eylemler için optik akış verilerinden faydalanan karma olarak yönlendirilmiş bir optik akış histogramı tanıtılmıştır (Wang, Ma ve Luo, 2016).

1.3. Uygulama Alanları

Son on yılda aktivite tespiti alanından çok hızlı gelişmeler olmuştur ve bu gelişmelerin çıktısı olarak denetim ve gözetim sistemlerinin performansını iyileştirmek için 2D ve 3D derin öğrenme modeller kullanılmıştır. Bu modellerin entegrasyonları, aktivite tespit etme sistemlerine derinlik bilgilerini ilave ederek aktivitelerin daha net anlaşılmasına katkı sağlamıştır. Hem uzamsal hem de zamansal boyutları bir araya getiren bu modeller, insan davranışları hakkında içeriği daha güçlü veriler yakalar. Buda sınıf ortamında yapılan sınavla ilgili hareketlerin daha kesin olarak belirlenmesi ve normal olmayan eylemlerin doğruluk oranı daha yüksek bir şekilde saptanmasını sağlar.

Bununla birlikte, aktivite tespiti için 2D ve 3D derin modeller birleştirilerek aktivite tespit sistemlerinin performansını artırmak için derinlik bilgileri ilave edilmiştir (Keçeli, Kaya ve Can, 2018). Hem uzamsal hem de zamansal boyutları bir araya getiren bu modeller, insan aktiviteleri hakkında daha geniş veriler yakalayarak sınıf ortamında yapılan sınav ile ilgili hareketlerin daha hassas olarak sonuçlandırılmasını sağlar.

Kalabalık alanlarda normal olmayan davranışların tespiti ve lokalizasyonu için uzamsal-zamansal CNN'ler sunulmuş, anormallikleri tespit etmek için uzamsal-zamansal bilgilerden yararlanılmıştır (Medel ve Savakis, 2016) ve normal olmayan davranışları tespit etmek için hareketli görüntü akışlarındaki artımlı değişiklikleri yakalayan ve analiz eden video anormallik tespiti için derin bir artımlı yavaş özellik analizi ağı önerilmiştir (Hu vd., 2016).

Kalabalık alanlarda normal olmayan davranış tespiti ve lokalizasyonu için uzamsal-zamansal CNN'ler gibi özel modeller geliştirilmiştir. Bu modeller, uzamsal ve zamansal verilerin biraraya getirilmesiyle normal olmayan davranışları saptamak için daha etkin hale gelmiştir. Hareketli görüntü akışlarındaki artımlı değişiklikleri saptayan ve analiz eden video normal olmayan eylem tespiti için derin bir artımlı yavaş özellik analizi ağı da önerilmiştir. Bu tür teknikler, kalabalık alanlarda yaşanabilecek normal dışı eylemleri tespit etme yeteneğini artırır ve güvenlik açısından daha güçlü bir koruma sağlar.

Kalabalık alanlarda normal olmayan eylemlerin tespiti için, kalabalık kitlelerin hareketlerini modellemek ve normal olmayan eylemleri tanımlamak için derin öğrenme tekniklerini kullanan insan yoğun alanlardaki normal olmayan aktivite tespiti için derin bir olay modeli önerilmiştir (Feng, Yuan ve Lu, 2017). Kalabalık alanlarda hızlı tanımlama ve lokalizasyon için sıralı bir 3D derin sinir ağı mimarisi olan Deep-Cascade sunulmuştur (Sabokrou, Fayyaz ve Fathy, 2017). Bu mimari, birden fazla derin sinir ağını sıralıyarak etkin ve doğru normal olmayan eylem tespiti sağlar ve ortamlardaki garip hareketleri takip ve belirlemek için sağlam bir çözüm sunar. Ayrıca, doğru anormal aktiviteyi tespit etmek için çeşitli derin mimarileri ve eğitim yöntemleri keşfederek derin öğrenme tekniklerini kullanarak videolarda normal olmayan davranış tespitine fokuslanılmıştır (Wang ve Xia, 2019).

Gözetim ve denetim yapılarının çok büyük bir öneme sahip olduğu günümüz dünyasında, sınav bütünlüğünün korunması, güvenlik ve performans, öncelikli hedefler arasında bulunmaktadır. Bu bağlamda, Denetim videolarındaki normal olmayan aktivitelerin tespiti son derece kritiktir. Bu nedenle, yörünge analizi ve vaka teşhisi gibi iki önemli tekniğin birarada kullanıldığı bir yöntem öne çıkmaktadır. Bu yöntem, videodaki objelerin ve aktivitelerin yörüngelerini takip ederek normal olmayan eylemleri yakalamaya odaklanır. Özellikle, objelerin beklenmedik yörüngeleri veya vakaların normal dışı durumları tespit ettiğinde, güvenlik sistemleri hızlı bir şekilde müdahale edebilir ve potansiyel tehlikeleri 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 normal olmayan aktiviteleri tespit etmek için yörünge analizi ve vaka teşhisini biraraya getiren bir teknik önerilmiştir (Cosar vd., 2017).

Transfer öğrenme, bir eylem modelinin öğrenilen bilgilerini diğer eylemlere uyarlamasına imkan verir. Bu şekilde, sistem, birçok eylem modellerine adapte olabilir ve normal olmayan eylemlerin tespit becerilerini geliştirebilir. Özellikle, farklı eylemler içerisinde birbirine benzeyen veya benzemeyen davranışları tespit edebilen transfer öğrenme, sınıf ortamındaki sınav takip sistemlerinde çok yönlü ve verimli bir araç olabilir.

Farklı bir araştırma, sıralı bir sinir ağı mimarisi kullanarak insan aktivitelerini arasında transfer öğrenmeyi araştırmıştır (Du, Farrahi ve Niranjan, 2019). Önerilen yöntem, farklı aktiviteler arasında değişimi olan temsilleri öğrenerek, sınıf ortamında sınav izleme için denetim sistemlerinde aktivite tespit etme performansını artırmaktadır. Sistem, transfer öğrenmeden yararlanarak çeşitli aktivite modellerine uyum sağlayabilir ve normal olmayan davranışların tespit yeteneklerini geliştirebilir.

Normal olmayan davranışların tespiti senaryolarında, uzamsal ve zamansal veriler çok önemli roller oynamaktadır. Hem uzamsal hem de zamansal bilgilerden faydalanarak gözetim videolarında normal olmayan davranışların tespiti ele alınmıştır (Sultani, Chen ve Shah, 2018). Bununla birlikte, normal davranışları aşamalı olarak modelleyen ve öğrenilen modellerden sapmalara dayalı olarak anormal hareketleri tespit eden bir yöntem önerilmiştir. Bu artımlı yaklaşım, sistemin zaman içinde yeni normal kalıpları uyarlamasını ve öğrenmesini sağlayarak sınavlar sırasında normal olmayan davranışları tespit etme yeteneğini geliştirir (Ouvirach, Gharti ve Dailey, 2013).

Normal olmayan davranışların tespit senaryolarında, uzamsal ve zamansal bilgilerin güçlü bir öneme sahip olduğunu belirtmek gereklidir. Objelerin davranışlarını ve konumlarını tespit etmek için uzamsal verileri, eş zamalı olarak zaman içindeki farklılıkları takip için zamansal verileri kullanmayı içerir. Bu verilere bağlı olarak, normal davranışları aşamalı olarak modelleyen ve öğrenilen modellerden sapmalara dayalı olarak anormal aktiviteleri tespit eden bir teknik önerilmiştir. Bu artımlı yaklaşım, sistemin zaman içinde yeni normal kalıpları uyarlamasını ve öğrenmesini sağlayarak sınıf içinde yapılan sınavlar esnasında normal olmayan hareketleri yakalama becerisini geliştirir. Bu, sınav bütünlüğünün korunması, güvenliği ve performansı artırma çalışmalarında önemli bir adımdır.

Görüntü tanıma çalışmalarında derin öğrenmenin başarısı büyük bir hız kazanmıştır, ancak bu alanda aşılması gereken engellerde yok sayılamaz. Derin öğrenme modelleri, çoğunlukla büyük veri kümelerine ihtiyaç duyar ve bilgi toplama, etiketleme ve işleme süreçlerinde karmaşıklığa yol açabilir. Ayrıca, fazla öğrenme sorunu ve model sınırlandırılmama sorunları gibi zorluklar, derin öğrenme uygulamalarının göz ardı edilemeyecek bir parçasıdır. Ancak, bu engeller, yeni kayıp

fonksiyonları, aktivasyon fonksiyonları ve transfer öğrenme yöntemleri gibi gelişmelerle ortadan kaldırılma yönünde giderek daha iyi bir şekilde ele alınmaktadır. Bu sayede, görüntü tanımlama işlerinde derin öğrenme modellerinin performansı sürekli olarak artmaktadır.

CNN'ler, sınıf ortamında yapılan sınavların video kayıtlarında kopya çekme eylem tespiti için güçlü bir uygulama 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 dürüstlüğüne 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 (Hu, 2020), (Thida vd.,2013)' da yer verilmiştir. Ayrıca, CNN'ler kullanılarak sınavların video kayıtlarında hile tespiti ele alınmıştır. Önerilen CNN tabanlı yöntem, video kayıtlarındaki kopya çekme faaliyeti içeren davranışı tespit ederek sınavlar sırasında değerlendirme sürecinin güvenliğini sağlamayı amaçlamaktadır (Kuin, 2018).

İnsan davranışı tanıma, sınav bütünlüğü ve güvenliği sürecinin geliştirmesi bakımından büyük bir önem taşır. Bu alandaki gelişmelerden biride, hibrit derin öğrenme modelleridir. CNN ile LSTM ağlarını birleştirir. Bu modeller ile insan davranışlarını daha detaylı ve eş zamanlı bir şekilde incelemeyi amaçlar. Özellikle sınavlar sırasında öğrenciler tarafından sergilenen normal olmayan hareketlerin tespitinde etkin rol oynar. Bu, öğrencilerin dürüstlüğüne korumak ve sınav süreçlerini güvenli ve güvenilir hale getirmek için kritik bir öneme sahiptir.

Ek olarak, insan aktivitelerini tanımayı geliştirmek için CNN'leri ve uzun ömürlü kısa dönem belleği (LSTM) ağlarını birleştiren hibrit bir derin öğrenme modeli sunulmuştur. Bu teknik, sınavlar esnasında öğrencilerin yapmış oldukları normal olmayan hareketlerin tespitinde etkili olabilir (Jaouedia vd., 2020). Kalabalık sınıf ortamlarında yapılan sınavların getirdiği zorlukları bertaraf etme için, normal eylemlerin temsilli yolla normal olmayan eylemleri tespit etmeye yardımcı olan seyrek

yeniden yapılandırma maliyetine dayalı bir teknik tanıtılmıştır (Cong, Yuan ve Liu, 2011).

Sınavların herbir öğrenci için eşit şartları sağlaması günümüz eğitim modellerinin en başında gelen ihtiyacdır ve bağlamda teknolojik gelişmeler ile birlikte daha fazla önemli hale gelmektedir. Sınavlar esnasında öğrencilere fırsat eşitliği sağlamakla birlikte, sınav bütünlüğünün korunmasını da gerektirir. Bu noktada, sınav süreçlerinin takibinin ve değerlendirilmesinin eşit ve güvenilir olması, eğitim kurumlarının temel sorumlulukları arasındadır. Bu nedenle, sahtekarlık içeren video yakalamak gibi teknikler, sınav bütünlüğünü ve adaletini güvence altına almak kurumlar için vageçilmez hale gelmiştir.

Sahtekarlık içeren video tespiti, sınav esnasında kopya çekme davranışı içeren görüntüleri yakalamak, analiz etmek ve raporlamak için kullanılan bir teknolojik çalışma alanıdır. Bu yöntemler, öğrencilerin sınav esnasında sahtekarlık denemelerini, aktivitelerini veya diğer sahtekarlık türlerini tespit etmeye yardımcı olur. Özellikle online sınavlarda, bu tür sakıncalı faaliyetlerin tanınması, sınavların güvenilirliği açısından kritik bir öneme sahiptir. Bu nedenle, video izleme sistemleri ve yapay zeka tabanlı algoritmalar, öğrencilerin davranışlarını ve eylemlerini analiz ederek kuşkulu faaliyetleri belirler. Bu, sınav gözetimini güçlendirmenin ve öğrencilerin eşit bir şekilde değerlendirilmesini sağlamanın teknolojik olarak ortaya koyulmuş bir yoludur.

Kopya çekme, öğrenciler arasında yaygın bir eylem biçimidir ve eğitim kurumlarının gelişimini ve değerlendirme süreçlerini ciddi şekilde etkileyebilir. Bu nedenle, bu tür kuşkulu eylemlerin tespiti ve önlem alınması büyük bir öneme sahiptir. Bu zorluğun üstesinden gelmek için teknoloji en güçlü yardımcı araçtır. Video denetimi ve otomatik analiz sistemleri, öğrencilerin sınav sırasında sahtekarlık girişimlerini yakalamak için kullanılır. Bu sistemler, öğrencilerin davranışlarını, seslerini ve ekranlarını izler ve herhangi bir kuşkulu hareketi tespit etmek için gelişmiş algoritmalar kullanır. Ayrıca, sınav izleme odalarında görevli insan denetçilerle birlikte çalışarak daha güçlü bir güvenlik katmanı sağlar.

Sınav odalarında eşitliğin sağlanması, hareket tanımanın ötesine geçmektedir. Sakıncalı video tespiti için, uygunsuz içeriğin farklı seviyelerde tanımlanmasına izin veren hiyerarşik bir sistem sunulmuştur (Lee, Shim ve Kim, 2009). Ayrıca, sınavlar

esnasında kopya çekmeyle ilintili şüphe uyandıran eylemlerin tespiti ile ilgilenen ve akademik dürüstlüğün korunmasına fayda sağlayan çalışmalar da vardır (Atoum vd., 2017), (Genemo, 2022). Bu çalışmadan başka bir veri seti ile makine öğrenimi teknikleri (Ay ve Karabatak, 2023)'te kullanılmış ve anlamlı sonuçlar elde edilmiştir.

Optik akış ve GAN'lar gibi yeni teknoloji araçları, şüpheli video tespiti alanında önemli gelişmeler sağlamıştır. Optik akış, davranışın detaylı olarak incelenmesine imkan verir ve buda normal olmayan hareketlerin yakalanması için daha fazla veri sağlar. GAN'lar ise normal aktivite modellerini öğrenir ve ardından herhangi bir sapma veya anormallik yakalamak için bu modelleri kullanır. Özellikle gözetim sistemlerinde, bu teknikler, vakaların ve aktivitelerin normal dışı olup olmadığını tespit etmekte kullanılır. Bu, güvenlik uygulamaları ve sınav gözetimi gibi birçok alanda önemlidir.

Farklı bir çalışma olan UCSD Veri Kümesi üzerinde optik akış (Nemade ve Gohokar, 2019) ve GAN'lara odaklanarak normal olmayan davranış tespit yöntemlerini gözden geçirmekte, bir diğeri de en son teknolojik gelişmelerden faydalanarak ve aynı veri seti üzerinde GAN temelli modellerin çok yüksek performansını göstermektedir (Roka vd., 2023).

Final sınavları sırasında, öğretmenler tarafından canlı izlemenin olmaması, akademik dolandırıcılık için kıymetli bir potansiyel oluşturmaktadır. Bu sorunu ele almak için (Alsabhan, 2023), olası sahtekarlık olaylarını belirlemek için Yapay Öğrenme ve LSTM yöntemlerini temel alan yeni bir çalışma önermektedir.

Yapay zeka tabanlı otomatik gözetmenlik teknolojileri, sınav bütünlüğünü sağlamak ve kuşkulu sınav katılımcılarını yakalamak için önemli bir görev üstlenmektedir. Böylece, Proctor Net gibi yapılar, yüz tanıma, göz-bakış takibi ve ağız açma tespiti gibi çeşitli bir çok yeteneği kullanarak doğruluk oranlarının artırılmasını sağlamıştır. Bu şekilde sınav takip süreçlerini otomatikleştirerek eğitim kurumlarına çok katma değerli bir katkı sağlar. Öğrencilerin sınav süresince dolandırıcılık yapma denemelerini yakalayarak sınav sürecinin adil ve güvenilir olmasını sağlar.

Yapay zeka tabanlı otomatik gözetmenlik sistemi Proctor Net (Tejaswi vd., 2023), kuşkulu öğrenci hareketlerini yakalamak için yüz tanıma, göz-bakış takibi ve

ağız açma tespitini kullanarak çeşitli veri setleri ve hatalı uygulama denemelerinde %91'lik bir doğruluk oranı elde etmiştir.

Obje izleme, normal olmayan eylem ve hareket tanıma gibi alanlardaki çalışmalar, video gözetimindeki önemli ilerlemelere katkı sağlamaktadır. Bu çalışmalar, gözetim uygulamalarının daha zeki ve etkin bir hale gelmesini sağlar. Fakat, bu çalışma alanlardaki görüş açılarının sınıf ortamında yüz yüze yapılan sınavlar özelinde daha sıkı bir şekilde entegre edilmesi gereklidir. Sınıf ortamında yapılan yüz yüze sınavlar, öğrencilerin fiziksel ve psikolojik davranışlarını incelemek ve anlamak için çok daha karmaşık bir çerçeve sunar ve bu nedenle daha konsantre bir dikkat gerektirir. Bu çerçevede, araştırmacılar, obje izleme ve normal olmayan hareket tespiti gibi mevcut teknikleri bu özel çerçeveye nasıl ilişkilendireceklerine bakmalıdırlar.

Bahsi geçen çalışmalar obje izleme ve normal olmayan hareketi algılama ve nedenine ilişkin çok farklı taraflara ilişkin fikirler sunarken, bu çalışma alanları sınıf ortamında yapılan sınavların özel çerçevesi arasındaki açık olan konuları aydınlatması gerekmektedir.

Sınıf ortamında yüz yüze yapılan sınavlarda, sınav bütünselliğini yukarıya taşımaya yönelik yeni bir teknik önermek için video gözetiminde obje takip, normal olmayan hareketleri ve eylemleri tanıma ile insan hareketlerini anlamlandırma konusundaki mevcut bilgi birikimine dayanmaktadır.

Derin öğrenme teknikleri, transfer öğrenme stratejileri ve normal olmayan davranış tespit metodları, gözetim uygulamaları ile entegre edildiğinde sınavla ilgili hareketlerin takibi ve tespiti geliştirmek için büyük bir potansiyele sahiptir. Derin öğrenme, özellikler büyük veri setleri ile birlikte öğrenme becerilerini kullanarak çok karmaşık örüntüleri ve hareketleri tespit etmekte başarılıdır. Transfer öğrenme, sınav esnasında öğrenci hareketlerini çeşitli çerçevelerde anlamamıza yardımcı olabilir. Normal olmayan hareketlerin tespiti, kuşku hareketleri belirlemek için kullanılabilir ve sınav bütünselliğini yukarı taşımaya kritik bir görev üstlenir.

Bu derin öğrenme yöntemleri, transfer öğrenme stratejilerinin ve normal olmayan davranışların tespit yöntemlerinin gözetim uygulamaları entegrasyonu, sınavla ilgili hareketlerin takip edilme ve tespit edilmesini geliştirmek için önemli bir

potansiyele sahiptir. İlerleyen bölümlerde, bu tekniklerin belirli metodolojilerini ve uygulamalarını inceleyecek ve yüz yüze değerlendirmelerde sınav bütünlüğünü artırmaya yönelik çıkarımlarını tartışılmaktadır.

Günümüz güncel eğitim koşullarında, sınıf ortamında yapılan yüz yüze sınavların güvenliğini sağlamak ve kopya çekme eylemlerini bertaraf etmek, 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 arka plan görsellerinin çıkartılarak performans artışı sağlanmasına yönelik etkinliğini ortaya çıkarmayı amaçlayan obje takipden transfer öğrenmeye kadar farklı tekniklerden bahsedilmektedir.

Ayrıca, çeşitli yöntemlerin çalışma teknikleri çalışmada yer almaktadır. Örneğin, öğrencilerin sınavlar süresince davranışlarını inceleyen ve analiz eden transfer öğrenme yöntemlerinin nedenlerine bağlı olarak kullanılmasıyla olası kopya çekmeyi belirten davranışların yakalanması ve belirlenmesi için ek bir katman eklenmiştir.

Geçerli sayılan çerçevelerin dışına çıkan yeni bileşenlerin ilave edilmesi, sınav sürecinin takibini diğerlerinden farklılaştırmıştır. Geniş çaplı bir yenilik olarak, çok modlu bilgilerin biraraya getirilmesi önerisi ortaya çıkmıştır. Görsel, ses ve fiziki girdiler ile biraraya getirilerek sınavdaki öğrenci hareketlerinin detaylı bir çerçeve görselini ortaya koymaktadır. Bu sayede, takım çalışması ve veri entegrasyonu örneklerinin anlamlandırılması beklenmekte ve sınav bütünlüğünün korunması için yoruma açık olmayan, insan bağlılığını ortadan kaldıran bir yaklaşım oluşturulmaktadır.

Bu tez çalışmasında, insan-bilgisayar etkileşiminin karmaşık faktörleri incelenirken, sınav etiği ve insan merkezli çıktılarda kabul edilmektedir. Teknolojiyi etik konularla biraraya getirmek için boşlukları, eşitliği ve öğrenci rahatlığını destekleyen arayüzler oluşturmak önemlidir.

Çalışma ayrıca, derin öğrenme, bilgisayarla görme ve obje takibi gibi çeşitli metodolojileri analiz ederek sınav esnasında öğrenciler tarafından gösterilen olası kuşkulu hareketleri tanımlama, anlama ve bu süreçlerin kesintiye uğramadan ve doğruluğunda şüphe duyulmadan yapılabilmesi adına arka plan objelerinin


öğrenmenin dışında tutularak performans artışının sağlanması konularındaki etkinliğini araştırmayı hedeflenmektedir. Derin öğrenme, özellikle karmaşık eylemlerin ve davranışların takip edilmesi ve incelenmesi gerektiği durumlarda etkili bir araç olarak katkı sağlar. Bilgisayarla görme, video akışlarından anlamlı veriler edinmemizde destek olabilir ve obje takip, öğrencilerin davranışlarını dikkatle incelememize fırsat verir.

Bu çalışma aynı zamanda kopya çekme teşebbüsünün yakalanmasının ve performans artışının nasıl işlediğini yeniden düşünen çılgır açıcı fikirler de sunmaktadır. "Yüksek performanslı kopya çekmeyi tespit eden yapay zeka destekli sınavlar", performan artışı ile birlikte öğrencilere eş zamanlı uyarı bildirimi yapmakta ve böylece kopya çekme yönelimini azaltmaktadır. Ek olarak, uyarlanabilir modeller fikri, olası öğrenci kaçınma tekniklerini öngörmekte ve hafifletmekte, böylece kopya tespit sisteminin genel sağlamlığını güçlendirmektedir.

Tez çalışması, anlık görsel verilerine bağlı hareket etmenin performans yetersizliklerine çözüm üretmek için önceden eğitilmiş modellerin gerekliliğinden vurgulamaktadır. Hareket paternleri hakkındaki bilgilerimize karmaşıklık katmak için geçmiş performans ve öğrenme yörüngeleri gibi değişkenlerin de dahil edilmesi gerekmektedir.

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 sürekli öğrenme alanlarındaki olası katkısının başka bir ifadeside Okul dışı eğitim alanlarında dahil edilmelidir.

Sürekli gelişen teknolojiye faydalananarak, çalışmamız derin öğrenme, bilgisayarla görme, sınav bütünlüğü ve kopya çekmede caydırıcılık alanlarını birleştirmektedir.



řekil 6. Konuların Kesiřim Diyagramı

Kaynak: Yazar tarafından oluřturulmuřtur.

Çalıřmanın doęruluęu kullanılan kamera çözünürlüęü, aydınlatma řartları ve çok çeřitli öğrenci hareketleri gibi birçok faktörlerden etkilenebilir. Ancak herřeye raęmen bu çalıřma gelecek için bize ıřık tutacak sonuçları içermektedir. Ayrıca, řekil 6’da teknolojiler arasında çok fazla kesiřme noktalarını görebilirsiniz.

Tablo 1 Şüpheli Davranış Tespit Yöntemini Mevcut Yöntemlerle Karşılaştırma

Referans	Şüpheli Davranış Tespiti (Hayır: Anormallik veya Aktivite Tespiti)	Derin Öğrenme Modeli (Transfer Öğrenme Dahil)	Veri Kümesi Üretimi	Öznitelik Mühendisliği	Kamera Çözünürlüğü / Aydınlatma
A. Pennisi vd.	Hayır	Hayır	Hayır	Evet	İyi
T. Senthilkumar, vd.	Evet	Hayır	Hayır	Evet	İyi
N. Soman, vd.	Evet	Hayır	Hayır	Evet	Kötü Değil
D. Gowsikhaa, vd.	Evet	Hayır	Hayır	Evet	İyi
P. P. Debnath	Evet	Hayır	Evet	Evet	İyi
A. A. Ibrahim, vd.	Evet	Hayır	Evet	Evet	Kötü Değil
S. Ji, vd.	Hayır	CNN	Hayır	Hayır	Normal
K. Simonyan, vd.	Hayır	CNN	Hayır	Hayır	Normal
K. Simonyan, vd.	Hayır	CNN	Hayır	Hayır	Normal
S. F. Zhou, vd.	Hayır	CNN	Hayır	Hayır	Mevcut Değil
A. Khaleghi, vd.	Evet	Otokodlayıcı	Hayır	Evet	Kötü Değil
A. Al-azzawi, vd.	Hayır	Transfer Öğrenme	Hayır	Hayır	Normal
J. Pang, vd.	Hayır	Transfer Öğrenme	Hayır	Hayır	Normal
A.S. Keçeli vd.	Evet	Transfer Öğrenme	Hayır	Hayır	Kötü Değil
R. Mutegeki, vd.	Hayır	Transfer Öğrenme	Hayır	Evet	Normal
Y. Hao, vd.	Hayır	Hayır	Hayır	Evet	Kötü Değil
L. Lazaridis, vd.	Hayır	Hayır	Hayır	Evet	Kötü Değil
L. Kratz, vd.	Hayır	Hayır	Hayır	Evet	Kötü Değil
Q. Wang, vd.	Hayır	Hayır	Hayır	Evet	Normal
A. S. Keçeli, vd.	Hayır	Hayır	Hayır	Evet	Normal
J. R. Medel vd.	Hayır	CNN-LSTM	Hayır	Hayır	Normal
X. Hu, vd.	Hayır	Hayır	Hayır	Evet	Normal
Y. C. Feng, vd.	Hayır	Derin GMM	Hayır	Hayır	Normal
M. Sabokrou, vd.	Hayır	CNN	Hayır	Hayır	Normal
J. Wang, vd.	Hayır	CNN	Hayır	Hayır	Kötü Değil
S. Cosar, vd.	Hayır	Hayır	Evet	Evet	İyi
X. Du	Hayır	Transfer Öğrenme	Hayır	Hayır	Normal
W. Sultani, vd.	Hayır	Evet	Evet	Hayır	İyi
K. Ouivirach vd.	Evet	Hayır	Hayır	Hayır	Kötü Değil
Y. Hu, vd.	Hayır	CNN	Hayır	Hayır	İyi
N. Jaouedia, vd.	Hayır	CNN-LSTM	Hayır	Hayır	Kötü Değil
S. Lee, vd.	Hayır	Hayır	Hayır	Evet	Normal
Y. Atoum vd.	Evet	Hayır	Evet	Evet	İyi
M.D. Genemo,	Evet	CNN	Hayır	Hayır	İyi
S. Ay, vd.	Hayır	Evet	Hayır	Hayır	İyi
N. Nemade, vd.	Hayır	Faster R-CNN	Hayır	Evet	Normal
Oluşturulan Model	Evet	Faster R-CNN + Transfer Öğrenme	Evet	Evet	İyi

Kaynak: Sirt, D. (2023). *Bilgisayarlı görü ile yüz yüze sınavlarda şüpheli davranışların ortaya çıkarılması için derin öğrenme çerçevesi tasarımı*. [Doktora tezi]. Milli Savunma Üniversitesi. YÖK Açık Erişim: <https://tez.yok.gov.tr/UlusalTezMerkezi/>

2. COPYNET ÇERÇEVESİ

2.1. Veri Kümesi

İlk adım olarak, normal olmayan davranışları içeren etiketlenmiş bir veri seti oluşturmak gerekmektedir. Bu veri seti, sınav esnasında sergilenen normal ve anormal hareketlerin örneklerini barındırmalıdır. Normal hareketler sınavın gerektirdiği uyulması gereken kurallara uygun şekilde yapıldığı halleri ifade ederken, normal olmayan hareketler kopya çekme veya aldatma girişimlerini temsil eder. Bu veri setinin, sınavın birçok senaryolarını ve koşullarını içinde barındıracak şekilde düzenlenmesi önemlidir.

Oluşturulan veri seti daha sonra yapılacak çalışmalarda kullanılmak üzere eğitim, doğrulama ve test alt kümeleri olacak şekilde bölümlendirilmelidir. Eğitim alt kümesi, modelin öğrenme sürecini gerçekleştirdiği ve parametrelerini ayarladığı örnekleri içerir. Doğrulama alt kümesi, modelin eğitim sırasında performansını izlemek ve aşırı öğrenmeyi önlemek için kullanılır. Test alt kümesi ise modelin genel performansını ve genelleme yeteneğini değerlendirmek amacıyla kullanılır. Bu bölünme, modelin güvenilirliğini ve etkinliğini belirlemek açısından kritiktir.

Veri setinin büyüklüğü, modelin öğrenme performansını doğrudan etkiler. Daha çok ve çeşitli bir veri seti, modelin farklı hareketleri algılama becerisini artırabilir. Bu çalışmada kullanılan COPYNet Veri Seti 30,000' yakın görüntü içermekte ve beş farklı sınıfa ayrılmıştır. Bu çeşitlilik, modelin farklı sınav durumlarını ve normal olmayan davranışları öğrenmesine fayda sağlar.

Veri setinin niteliği, çıkacak sonuçları büyük ölçüde etkileyebilir. Görüntülerin belirginliği, çözünürlüğü ve etiketlerin doğruluğu, modelin başarılı olmasında önemli bir güce sahiptir. Bu nedenle, veri setini en başından titiz bir şekilde hazırlanması ve etiketlerin doğru bir şekilde tayin edilmesi önemlidir. Bununla birlikte, veri setini orantılı olması, yani normal ve normal olmayan davranışların benzer oranlarda eşit sayıda örneğe sahip olması da sonuçlara olumlu katkı sağlar.

Veri setini yaratma ve düzenleme süreci, bir sonraki adımlarda daha başarılı bir derin öğrenme modeli geliştirmek için büyük bir öneme sahiptir. Bu sınıflardan üçü Tablo 2'de gösterilmiştir:

Sınıf A: Sınav Kağıdını Değiştirme: Bu sınıf, sınav esnasında öğrencinin kendi sınav kağıdını başka bir öğrencininkiyle değiştirmeye çalıştığı durumları içerir. (Yaklaşık 800 görüntü)

Sınıf B: Başkasının Kağıdına Bakmak: Bu sınıf, öğrencilerin başka bir öğrencinin sınav kağıdına gizlice bakmasını içerir. (Yaklaşık 7000 görüntü)

Sınıf C: Kopya Kağıdı Kullanımı: Bu sınıf, öğrencilerin gizli bir kopya kağıdını kullanarak kopya çekme girişimlerini kapsar. (Yaklaşık 9000 görüntü)

Sınıf D: Cep Telefonu Kullanımı: Bu sınıf, öğrencilerin sınav sırasında çevrimiçi cevaplara erişmek için cep telefonu kullanmasını içerir. (Yaklaşık 4200 görüntü)

Sınıf E: Normal Sınav Davranışı: Bu sınıf, öğrencilerin kopya çekmeden sınav sürecini gerçekleştirdiği normal davranışları içerir. (Yaklaşık 9000 görüntü)



Şekil 7. Sırasıyla B, C ve D Sınıflarından Görüntüler

Kaynak: Sirt, D. (2023). *Bilgisayarlı görü ile yüz yüze sınavlarda şüpheli davranışların ortaya çıkarılması için derin öğrenme çerçevesi tasarımı*. [Doktora tezi]. Milli Savunma Üniversitesi. YÖK Açık Erişim: <https://tez.yok.gov.tr/UlusalTezMerkezi/>

Tablo 2. Önceki Çalışmalarda Kullanılan Diğer Veri Kümeleri İle Kıyaslama

Veri Kümeleri	Avantajları	Dezavantajları
OEP DataSet	○ Çözünürlüğü Yüksek ○ İyi Sınıflandırılmış ○ Çok Büyük (11GB)	○ Ele alınması zor ○ Yalnızca yüz tespiti
CUI-EXAM	○ İyi Sınıflandırılmış ○ Çözünürlük orta seviye ○ Büyüklüğü Normal ○ Tüm beden tespiti	○ Yalnızca tek bir açıdan çekim ○ Sınırlı alan tespiti
COPYNet	○ İyi Sınıflandırılmış ○ Büyüklüğü hafif ○ Birçok açıdan çekim	○ Çözünürlük orta seviye

Kaynak: Yazar tarafından oluşturulmuştur.

2.1.1. Alan Uzmanlarınca Etiketleme ve Açıklamalar

Veri seti işaretleme ve açıklama süreci, derin öğrenme modelinin doğruluğunu ve güvenilirliğini sağlamak adına önemli bir aşamadır. Bu süreçte, her bir görüntünün doğru davranış sınıfına atanması sağlanarak modelin öğrenme süreci desteklenir.

İşaretleme işlemi, uzman kişiler tarafından dikkatlice gerçekleştirilir. Alanında deneyimli bu uzmanlar, her bir görüntüyü tek tek inceleyerek takip edilen davranışları doğru bir şekilde sınıflandırır. Denetim videolarındaki hareketleri doğru şekilde tanımlayabilme becerisine sahip olan bu uzmanlar, her bir resmi detaylı olacak şekilde inceleyerek ilgili sınıfa doğru bir şekilde etiketler.

Etiketleme işlemi sırasında, sadece görüntülerin sınıflandırılması yapılmaz, aynı zamanda her davranış için ayrıntılı açıklamalar da oluşturulur. Bu açıklamalar, modelin öğrenme sürecine katkıda bulunarak ilerleyen aşamalarda daha derin içgörüler sağlar. Örneğin, sınav sırasında sahtekarlık girişimini gösteren bir görüntü, davranışın neden sahtekarlık olarak değerlendirildiğini açıklayan ek bilgilerle birlikte etiketlenir.

Etiketleme süreci, veri kümesinin kalitesini artırmak için sürekli bir geri bildirim döngüsü içerir. Uzmanlar, modelin performansını izleyerek gerekli gördüklerinde etiketlemeleri günceller veya düzeltmeler yapar. Bu sürekli geri bildirim döngüsü, veri kümesinin doğruluğunu ve güvenilirliğini artırarak nihayetinde daha etkili bir derin öğrenme modelinin geliştirilmesine olanak tanır.

Sonuç olarak, veri kümesi etiketleme ve açıklama süreci, derin öğrenme modelinin temelini oluşturan hayati bir adımdır. Uzmanlar tarafından titizlikle yürütülen bu süreç, doğru etiketlemeler ve açıklamalarla zenginleştirilmiş bir veri kümesi oluşturur ve modelin daha başarılı bir şekilde eğitilmesini sağlar.

2.1.2. Veri Kalitesi İçin Ön İşleme Adımları

Veri kümesinin kalitesini ve kullanılabilirliğini artırmak amacıyla çeşitli ön işleme adımları uygulanır:

Görüntü İyileştirme: Bu adım, veri kümesindeki görüntülerin kalitesini yükseltmek için gerçekleştirilir. Görüntü iyileştirme, modelin daha etkili özellikler öğrenmesine yardımcı olur. Örneğin, kontrast artırma teknikleri görüntülerin daha net ve belirgin hale gelmesini sağlayabilir. Keskinleştirme ve renk düzeltmeleri de bu süreçte kullanılan diğer yöntemlerdir.

Gürültü Giderme: Görüntülerdeki istenmeyen pikseller veya rastgele hatalar, modelin doğru sonuçlar üretmesini engelleyebilir. Bu nedenle, gürültü giderme işlemi oldukça önemlidir. Bu işlem sırasında, görüntülerdeki gürültüyü tanımlamak ve düzeltmek için çeşitli teknikler kullanılır. Örneğin, rastgele piksellerin algılanarak doğru değerlerle değiştirilmesi bu adımın bir parçasıdır.

Veri Temizliği: Veri kümesinin temizlenmesi, yanlış etiketlenmiş verilerin, tekrarlayan örneklerin veya alakasız görüntülerin çıkarılmasını içerir. Bu aşama, modelin yanlış veya yanıltıcı verilerle eğitilmesini önler ve daha tutarlı bir öğrenme süreci sağlar. Veri temizliği işlemi manuel olarak yapılabileceği gibi, büyük veri kümeleri için otomatik temizleme teknikleri de kullanılabilir. Bu, veri kümesinin güvenilirliğini artırır ve modelin daha doğru sonuçlar üretmesine katkıda bulunur.

Normalizasyon: Normalizasyon, veri özelliklerinin uyumlu hale getirilmesini amaçlar. Bu aşama, görüntülerin boyutları, formatları veya renk kanalları gibi özelliklerde tekdüzelik sağlar. Normalizasyon, modelin veriyi daha tutarlı bir şekilde işlemesine olanak tanır. Örneğin, farklı boyutlardaki görüntülerin aynı boyuta getirilmesi veya renk kanallarının uyumlu hale getirilmesi normalizasyon işleminin bir parçasıdır.

Bu ön işleme adımları, derin öğrenme modelinin performansını önemli ölçüde artırır. İyi hazırlanmış veri, modelin daha doğru ve güvenilir sonuçlar üretmesine olanak tanır. Bu nedenle, veri hazırlığı, sınav gözetim sistemlerinin güvenilirliği ve etkinliği açısından kritik bir öneme sahiptir.

2.1.3. Veri Kümesi Bölümleme: Eğitim, Doğrulama ve Test

Veri kümelerinin ayrıştırılması, yapay zeka modellerinin oluşturulmasında kritik bir adımdır. Bu süreç, verileri belirli alt gruplara bölmeyi içerir ve her grup özel bir amacı yerine getirir. Eğitim alt kümesi, modelin eğitildiği ve temel bilgileri edindiği bölümdür. Bu bölüm, modelin karmaşık davranışları anlaması ve öğrenmesi için gereklidir. Eğitim aşamasında model, veri kümesindeki normal ve anormal örnekleri ayırt etmeyi öğrenir.

Model, bu aşamada gözlemlenen davranışları analiz eder, bu davranışların özelliklerini öğrenir ve gelecekte benzer davranışları tanımak için gerekli kalıpları keşfeder. Bu süreç, modelin şüpheli aktiviteleri belirlemesine ve sınav güvenliğini sağlamak için hangi hareketleri algılaması gerektiğini anlamasına yardımcı olur.

Doğrulama alt kümesi ise modelin hiperparametrelerinin ayarlandığı ve performansının test edildiği bölümdür. Hiperparametrelerin doğru ayarlanması, modelin en iyi şekilde çalışması için önemlidir. Bu aşama, aşırı öğrenme (overfitting) sorununu önlemek ve modelin karmaşıklığını optimize etmek için kritik bir rol oynar.

Doğrulama alt kümesi, modelin genelleme yeteneğini ve farklı veri kümeleri üzerindeki performansını değerlendirir. Bu aşama, modelin yalnızca eğitim verilerine değil, aynı zamanda yeni ve daha önce görülmemiş verilere de adapte olabilme kabiliyetini test eder. Modelin performansı bu alt küme üzerinde sürekli olarak izlenir ve gerekli durumlarda hiperparametreler yeniden ayarlanır.

Son olarak, test alt kümesi modelin nihai performansının değerlendirildiği bölümdür. Model, bu veri alt kümesi üzerindeki yeni verilere ne kadar iyi genelleme yapabildiğini gösterir. Test kümesi, modelin gerçek dünya senaryolarında nasıl performans göstereceğini öngörmek için kullanılır.

Modelin doğruluk, hassasiyet, özgüllük gibi performans ölçütleri bu aşamada dikkatle analiz edilir. Bu aşama, modelin sınav gözetim sisteminde etkili olup olmadığını belirlemek için çok önemlidir. Eğer model, test alt kümesinde anormal davranışları doğru bir şekilde tespit edebilir ve normal davranışları ayırt edebilirse, bu sistemin güvenilirliğini kanıtlar.

COPYNet Veri Kümesi, yapay zeka destekli sınav gözetim sistemlerinin geliştirilmesinde temel bir veri kaynağı olarak kullanılmaktadır. Bu veri kümesi, sistemlerin eğitim ve değerlendirme süreçlerinde önemli bir rol oynar. Veri kümesinin kalitesi ve doğruluğu, sistemlerin güvenilirliği ve etkinliği üzerinde doğrudan bir etkiye sahiptir. Bu nedenle, veri kümesinin dikkatli bir şekilde bölünmesi ve her bir alt kümenin özel görevler üstlenmesi kritik öneme sahiptir.

Her alt kümenin, modelin eğitim ve performans izleme süreçlerine katkısı büyüktür. Bu aşamaların özenle yönetilmesi, yapay zeka tabanlı sınav gözetim sistemlerinin güvenilirliğini ve etkinliğini artırır. COPYNet Veri Kümesi, sınıf içi sınavlarda anormal davranışları tespit etmede önerilen modelin performansını eğitmek ve değerlendirmek için temel bir yapı taşıdır. Bu veri setinin özenle hazırlanması, doğru etiketlenmesi ve ön işleme tabi tutulması, güvenilir sonuçlar elde etmek için gerekli olan uygun ortamı sağlar.

Veri kümesinin dikkatle yönetilmesi, sistemin sınav bütünlüğünü koruma ve anormal davranışları tespit etme yeteneğini belirlemede hayati bir rol oynar. COPYNet Veri Kümesi, yapay zeka tabanlı otomatik sınav gözetim sistemlerinin performansını artırmak için kritik bir unsurdur. Bu veri seti, sistemlerin daha doğru ve güvenilir sonuçlar üretmesini sağlamak amacıyla titizlikle hazırlanır ve işlenir.

2.2. Veri Kümesine Zamansal Atlama Uygulamak

Zamansal analiz, zaman içerisindeki değişiklikleri inceleyerek görüntü veya videoların dinamiklerini anlamaya yardımcı olan kritik bir tekniktir. Bu analiz yöntemi, olayların veya süreçlerin zamanla nasıl geliştiğini anlamamızı sağlar. Sınav gözetim sistemlerinde, öğrencilerin davranışlarını izlemek ve olağandışı hareketleri belirlemek için zamansal analiz oldukça yararlıdır. Örneğin, bir öğrencinin sınav

sırasında dikkatsiz hareketleri veya kopya çekme girişimlerinin zamansal değişimi bu analizle tespit edilebilir.

Zamansal analiz, sadece eğitim alanında değil, pek çok sektörde geniş bir kullanım alanına sahiptir. Güvenlik kameralarının kaydettiği görüntülerin incelenmesinde zamansal analiz, hırsızlık veya diğer suçların belirlenmesinde etkili olabilir. Tıp alanında ise, hastaların radyolojik görüntülerindeki değişiklikleri zaman içerisinde incelemek, tedaviye verilen yanıtı değerlendirmede önemli bir rol oynar.

Zamansal atlama, zamansal analizde dikkate alınması gereken temel bir kavramdır. Bu kavram, bir video veya görüntü dizisinin analizinde kaç kare atlandığını ifade eder. Daha küçük bir zamansal atlama, daha fazla kare analiz edilmesi anlamına gelir ve bu, videodaki her değişikliğin ayrıntılı bir şekilde incelenmesini sağlar. Ancak, bu aynı zamanda daha yüksek hesaplama gücü ve daha fazla işlem süresi gerektirir. Buna karşılık, daha büyük bir zamansal atlama, daha az kare analiz edilmesi anlamına gelir ve bu, daha düşük bir zamansal çözünürlük sağlar, ancak daha az hesaplama kaynağı ve süre gerektirir.

Zamansal atlama, video analizinde performans ve kaynak kullanımı arasında denge sağlamak için kullanılır. Analiz yapılacak senaryoya bağlı olarak uygun zamansal atlama seviyesi belirlenir. Özellikle büyük veri kümeleri veya uzun süreli video analizlerinde, doğru zamansal atlama seçimi süreci optimize etmek için hayati önem taşır. Ayrıca, analiz sırasında zamansal atlamanın dinamik olarak ayarlanabilmesi, analiz koşullarına uyum sağlama konusunda esneklik sağlar.

Bu analiz yöntemleri, farklı alanlardaki uygulamalarda daha iyi sonuçlar elde etmek için kullanılır. Örneğin, güvenlik sektöründe zamansal analiz, olayların zamanla nasıl geliştiğini takip ederek potansiyel tehditleri erken tespit etmeye yardımcı olabilir. Aynı şekilde, sağlık alanında, tedavi süreçlerinin etkinliğini değerlendirmek için hastaların durumundaki değişiklikleri zamanla izlemek hayati olabilir. Zamansal analiz ve zamansal atlama gibi teknikler, farklı sektörlerde daha derinlemesine ve etkili analizler yapmayı mümkün kılar.

Zamansal analiz ve zamansal atlama, görüntü ve video analizinde önemli yer tutan iki temel kavramdır. Zamansal analiz, olayların veya süreçlerin zaman içinde nasıl geliştiğini anlamaya çalışırken, zamansal atlama, analiz sürecinin verimliliğini

ve kaynak kullanımını optimize etmeye odaklanır. Bu teknikler, sınav gözetimi, güvenlik analizleri ve tıbbi görüntüleme gibi çeşitli uygulama alanlarında kullanılarak analizlerin daha etkili ve hassas olmasını sağlar.

Zamansal analiz, örneğin, bir öğrencinin duruşundaki veya yüz ifadelerindeki değişiklikleri tespit etmek için kullanılabilir. Bu analiz yöntemi, sınav sırasında öğrencilerin davranışlarını izleyerek olağandışı hareketleri belirlemeye yardımcı olur. Güvenlik alanında, zamansal analiz, bir mekânda meydana gelen olayların zaman içindeki gelişimini izleyerek potansiyel tehditleri erken tespit etmeyi sağlar. Tıpta ise, hastaların tedaviye verdikleri yanıtları izlemek için kullanılır, böylece tedavi süreçlerinin etkinliği değerlendirilebilir.

Zamansal atlama, video analizinde kareler arasındaki zaman aralığını ifade eder. Daha küçük bir zamansal adım, daha fazla karenin analiz edilmesi anlamına gelir ve bu, videodaki her detayın daha yüksek çözünürlükte incelenmesini sağlar. Ancak bu durum, daha fazla hesaplama gücü ve zaman gerektirir. Buna karşın, daha büyük bir zamansal adım, daha az karenin analiz edilmesine yol açar ve bu da daha düşük bir zamansal çözünürlük sağlar, fakat hesaplama kaynaklarını ve zamanı daha verimli kullanır.

Zamansal atlama, analiz sürecinde kaynakları optimize etmek ve performansı artırmak için stratejik olarak seçilir. Örneğin, geniş veri kümeleri veya uzun süreli video analizlerinde, doğru zamansal atlama seviyesini belirlemek, süreçlerin daha hızlı ve verimli bir şekilde tamamlanmasını sağlar. Ayrıca, zamansal atlamının dinamik olarak ayarlanabilmesi, analiz koşullarına uyum sağlama esnekliği sunar.

Bu iki kavram, çeşitli sektörlerdeki uygulamalarda derinlemesine ve etkili analizler yapmayı mümkün kılar. Örneğin, sınav gözetiminde zamansal analiz ve atlama, öğrenci davranışlarını doğru bir şekilde izleyerek sınav güvenliğini sağlar. Güvenlik sektöründe ise, olayların zaman içindeki gelişimini izleyerek potansiyel tehditleri belirlemeye yardımcı olur. Tıbbi alanda ise, hastaların tedaviye verdikleri yanıtları zamansal olarak izlemek, tedavi süreçlerinin daha iyi yönetilmesine olanak tanır.



Şekil 8. Zamansal Atlama Akışı

Kaynak: Sırt, D. (2023). *Bilgisayarlı görü ile yüz yüze sınavlarda şüpheli davranışların ortaya çıkarılması için derin öğrenme çerçevesi tasarımı*. [Doktora tezi]. Milli Savunma Üniversitesi. YÖK Açık Erişim: <https://tez.yok.gov.tr/UlusalTezMerkezi/>

Şekil 8' de gösterilen zamansal adım kavramı, bir dizi içindeki her bir ögenin zaman içindeki konumunu belirtir. $S[i]$, dizinin mevcut ögesini ifade ederken, $S[i+2]$ bu öğeden bir adım ilerideki öğeye atıfta bulunur. Bu yaklaşım, zamansal bağımlılıkları ve değişiklikleri analiz etmemize olanak tanır. Örneğin, $S[i]$ ile $S[i+3]$ arasındaki farklılıkları inceleyerek, dizideki hareketler veya zaman içindeki değişiklikler gibi kalıpları tespit edebiliriz. $S[i]$ bir referans noktası olarak işlev görürken, $S[i+1]$, $S[i+2]$, $S[i+3]$ gibi zaman içindeki kaymalar, dizinin evrimini gözlemlememize yardımcı olur.

Etkinlik tanıma, bir olayın veya eylemin zaman içinde nasıl evrildiğini analiz etmemize olanak sağlayan önemli bir süreçtir. Özellikle güvenlik kameraları tarafından kaydedilen görüntülerde, suçların tespit edilmesi ve güvenliğin sağlanması gibi uygulamalarda kullanılır. Zamansal adım, etkinlik tanıma analizlerinde hassasiyet ile hesaplama kaynakları arasında bir denge sağlar. Daha küçük bir zamansal adım, olayların daha detaylı olarak incelenmesini sağlar, özellikle hızlı ve karmaşık olayların

analizinde kritik önem taşır. Ancak bu, daha fazla hesaplama gücü gerektirir ve analiz sürecini yavaşlatabilir.

Diğer yandan, daha büyük bir zamansal adım, analizin hızını artırırken ayrıntıların gözden kaçma riskini artırabilir. Zamansal adımın seçimi, spesifik uygulama gereksinimlerine ve mevcut hesaplama kaynaklarına bağlı olarak yapılır. Analizin zamansal çözünürlüğü, zamansal adımın büyüklüğünü ve analizin detay seviyesini belirler. Ayrıca, istenen doğruluk seviyesi de zamansal adım seçiminde kritik bir faktördür. Yüksek doğruluk gerektiren uygulamalarda daha küçük bir zamansal adım tercih edilir, ancak bu durum daha fazla hesaplama kaynağı kullanımı anlamına gelir.

Sonuç olarak, etkinlik tanıma analizlerinde zamansal adım seçimi, hassasiyet, hesaplama kaynakları ve doğruluk seviyesi gibi faktörlere bağlıdır. Bu seçim, analizin etkinliğini, hızını ve kaynak kullanımını önemli ölçüde etkiler. Her uygulama bağlamında dikkatlice değerlendirilmesi ve ayarlanması gereken önemli bir parametredir, çünkü doğru zamansal adım seçimi, analiz sürecinin verimliliğini büyük ölçüde artırabilir.

2.3. Model

Sınav sırasında anormallikleri etkili bir şekilde tespit etmek için YOLOv5 ve Faster R-CNN modelleri incelenmektedir. YOLOv5, "You Only Look Once" ifadesinin kısaltması olup nesne tespitinde yüksek hız ve doğruluk sağlamak üzere tasarlanmıştır. Bu model, hızlı bir şekilde nesneleri tespit edebilme yeteneği sayesinde özellikle dinamik sınav ortamlarında şüpheli davranışları anında belirlemede idealdir. YOLOv5'in gerçek zamanlı işleme kabiliyeti büyük veri kümeleriyle çalışırken önemli bir avantaj sağlar.

Öte yandan, Faster R-CNN modeli, "Faster Region-Based Convolutional Neural Network" ifadesinin kısaltması olup nesne tespitinde yüksek hassasiyet ve doğruluk sunar. Bu model, nesneleri daha ayrıntılı ve hassas bir şekilde tespit edebilme yeteneği ile anormal davranışların detaylı olarak incelenmesine katkı sağlar. Faster R-CNN'nin öğrenme kapasitesi, özellikle sınıf sınavları için özelleştirilmiş anormallik tespiti modelleri için uygun bir seçenektir.

Seilen model, uygulamanın spesifik gereksinimlerine ve mevcut veri k melerine baėlı olarak deėiřiklik g sterebilir. YOLOv5 ve Faster R-CNN modelleri, farklı avantajlar ve  zellikler sunar ve her ikisi de etkili bir anormallik tespit sistemi oluřturmak iin uygun seeneklerdir. Dolayısıyla, sınıf sınavları iin hangi modelin kullanılacaėı, uygulamanın ihtiyalarına ve hedeflerine g re  zenle deėerlendirilmelidir.

YOLOv5 ve Faster R-CNN modelleri, sınav sırasında anormallik tespiti iin seildiėinde, her ikisinin de sunduėu benzersiz  zellikler ve avantajlar g z  n nde bulundurulmaktadır. YOLOv5'in gerek zamanlı iřleme yeteneėi, sınav ortamlarının hızına uygun olarak ř pheli davranıřların hızlı bir řekilde tespit edilmesine olanak tanır.

YOLOv5'in verimli mimarisi, nesne tespit s recini basitleřtirir ve t m g r nt y  tek bir geiřte tarayarak hızlı ve k  k aplı kopya eylemlerini yakalamak iin b y k bir avantaj saėlar. Sınav izleme g revlerinde, hızlı yanıt ve y ksek doėruluk arasında denge kurma yeteneėi kritik  neme sahiptir.

Faster R-CNN modeli ise doėru lokalizasyon ve oklu nesne tespiti yetenekleri nedeniyle tercih edilir. İki ařamalı mimarisi, nesnelerin hassas bir řekilde konumlandırılmasına imkan tanır ve  zellikle ince kopya eylemlerini tespit etme konusunda etkilidir. Ayrıca, Faster R-CNN'nin apa tabanlı  neri  retim aėı, nesnelerin doėru tespitini kolaylařtırarak sınav g zetim sistemlerinde g venilir bir ara olarak  ne ıkar.

Model Seimi ve Anormallik Tespiti Sınav izleme ve anormallik tespiti g revleri iin doėru modelin seilmesi kritik bir adımdır. Her iki model de, hız, doėruluk ve uyarlanabilirlik aısından dengeli bir kombinasyon sunar ve sınav b t nl ė n  koruma ile adil bir sınav deneyimi saėlama hedeflerini destekler.

ř pheli davranıřların tespiti iin kullanılan yaklařım, bilgisayarla g rme ve derin  ėrenme teknikleriyle canlı video akıřlarını analiz eder. Derin  ėrenme tabanlı bir nesne dedekt r , belirli ř pheli eylemleri tanıyacak řekilde eėitilir. Bu eylemler arasında bařka bir  ėrencinin sınavına bakma, notları iletimi veya cep telefonu kullanımı gibi kopya ekme davranıřları yer alır. Dedekt r, bu t r ř pheli davranıřları iřaretlemek iin sınav g r nt lerine uygulanır.

Sınav sırasında sınıfın video görüntülerini analiz ederek şüpheli davranışları tespit etmek için ideal bir sinir ağı türü olan Evrişimli Sinir Ağları (CNN), özellikle ızgara benzeri veri yapılarıyla çalışmasıyla dikkat çeker. Bu yapı, örneğin bir öğrencinin başka bir öğrencinin sınav kağıdına bakması veya cep telefonu kullanması gibi davranışları tespit edebilmek için eğitilebilir. Bu özellikleriyle, sınavın bütünlüğünü korumak ve adil bir sınav deneyimi sunmak büyük önem taşır. YOLOv5 ve Faster R-CNN gibi güçlü modellerle desteklenen bu yaklaşım, sınav süreçlerindeki şüpheli davranışların tespitinde kritik bir rol oynamaktadır.

İki Akışlı CNN ve Özellik Çıkarımı İki akışlı CNN yapısı, her bir akış için özellik çıkarımını hiyerarşik olarak düzenlenmiş bir dizi evrişim katmanından oluşturulmuştur. (Ji, Xu, Yang ve Yu, 2013) tarafından önerilen bu modelde, her katmandaki çekirdekler arasında sıralı konvolüsyonlarla önceki katmanlarda üretilen özellik haritaları arasında bir özellik çıkarma işlemi gerçekleştirilir. M giriş özellik haritası ve N çekirdek için l. katmandaki j. çıkış özellik haritası x şu şekilde hesaplanabilir:

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

Bu konuda, Convolutional Neural Network (CNN) sınav sırasında sınıfın video görüntülerini analiz ederek şüpheli davranışları tespit etmek için etkili bir sinir ağı türüdür. CNN, özellikle ızgara benzeri veri yapılarıyla çalışarak, bir öğrencinin sınav kağıdına bakması veya cep telefonu kullanması gibi şüpheli davranışları belirlemek için eğitilebilir. Bu özellikleriyle, sınavın bütünlüğünü korumak ve adil bir sınav deneyimi sağlamak büyük önem taşır. YOLOv5 ve Faster R-CNN gibi güçlü modellerle desteklenen bu yaklaşım, sınavlardaki şüpheli davranışların tespitinde kritik bir rol oynamaktadır.

İki Akışlı CNN ve Özellik Çıkarımı İki akışlı CNN mimarisi, sınıf sınavları sırasında farklı türdeki şüpheli eylemleri etkili bir şekilde tespit etmek için kullanılan gelişmiş bir sinir ağı yapılanmasıdır. Bu mimari, hem uzamsal (görüntü veya video kareleri) hem de zamansal (video kare dizileri) bilgileri işlemek üzere iki ayrı CNN'den oluşur. Uzamsal Akış CNN ve Zamansal Akış CNN'in birleşimi, öğrencilerin şüpheli

davranışlarını tespit etmek ve kopya çekme girişimlerini engellemek için güçlü bir çözüm sunar.

Uzamsal Akış CNN Uzamsal Akış CNN, video karelerini bireysel olarak işleyerek her bir kareyi detaylı bir şekilde analiz eder. Bu aşamada öğrencilerin yüz ifadeleri, göz hareketleri ve el pozisyonları gibi görsel özellikler incelenir. Örneğin, bir öğrencinin başka bir öğrencinin sınav kağıdına bakması veya cep telefonu kullanması gibi şüpheli davranışlar bu aşamada tespit edilebilir. CNN, bu görsel ipuçlarını öğrenerek her kareyi bu özelliklere göre sınıflandırır.

Zamansal Akış CNN Zamansal Akış CNN ise, video karelerini zaman çizelgesi boyunca analiz ederek belirli davranış kalıplarını tespit eder. Özellikle öğrencilerin uzun süreli şüpheli davranışlarını belirlemek için kritik bir öneme sahiptir. Örneğin, bir öğrencinin sürekli olarak başka bir öğrencinin sınav kağıdına bakması veya sürekli bir cihazda yazı yazması gibi daha karmaşık kopya çekme girişimlerini ortaya çıkarır. Zamansal Akış CNN, kareler arasındaki ilişkileri modelleyerek bu davranış kalıplarını öğrenir ve analiz eder.

Faster R-CNN: Gelişmiş Nesne Tespiti için İleri Seviye Algoritma Faster R-CNN, nesne tespitini yüksek doğruluk ve etkinlikle gerçekleştiren gelişmiş bir derin öğrenme algoritmasıdır. Bu algoritma, nesne tespiti sürecini iki temel aşamada ele alarak özel görevlere odaklanır.

İlk Aşama: Bölge Öneri Ağı (RPN) Faster R-CNN'nin ilk aşamasında, Bölge Öneri Ağı (RPN) adı verilen bir alt ağ kullanılır. RPN, evrimsel özellik haritaları üzerinde kaydırarak çalışır ve her bir öneriye bir "bağlama kutusu" atanır. Bu bağlama kutusu, potansiyel nesne bölgelerini çerçevelemek için kullanılır ve nesnelerin çeşitli boyutlarına ve konumlarına duyarlılık sağlar. RPN, farklı boyut ve oranlarda öneriler üretebilir, bu da nesne tespitinin geniş bir kapsamda yapılabilmesini sağlar.

İkinci Aşama: Nesne Tespiti ve Sınıflandırma İkinci aşamada, RPN tarafından üretilen nesne önerileri kullanılarak nesne tespiti gerçekleştirilir. Her bir öneri bölgesi daha ayrıntılı bir şekilde incelenir ve içerdiği nesneler sınıflandırılır. Bu adım, bir Faster R-CNN dedektörü tarafından yürütülür. Dedektör, her bölgenin özelliklerini çıkarmak için bir özellik çıkarma ağı kullanır ve bu özellikleri nesnelerin sınıflandırılması ve sınırlarının kesin olarak belirlenmesi için değerlendirir.

İki Aşamanın Entegrasyonu Faster R-CNN'nin iki aşamalı yapısı, nesne tespiti sürecini oldukça etkili kılar. İlk aşamada geniş bir nesne öneri kümesi üretilir ve ikinci aşamada bu öneriler detaylı analizlere tabi tutulur. Bu yapı, nesne tespiti doğruluğunu artırırken hesaplama maliyetlerini optimize eder.

Uygulama ve Avantajlar Faster R-CNN, sınav gözetimi gibi uygulamalarda kopya çekme gibi anormal davranışları tespit etmek için ideal bir modeldir. Bu model, öğrencilerin davranışlarını ayrıntılı bir şekilde analiz eder ve şüpheli hareketleri doğru bir şekilde sınıflandırır. Sınav sırasında anormal davranışların tespiti, sınav bütünlüğünü sağlamak için kritik öneme sahiptir. Faster R-CNN'nin hassas ve ayrıntılı tespit yetenekleri, eğitim kurumlarının sınav güvenliğini artırmasına yardımcı olur.

Özetle, Faster R-CNN'nin iki aşamalı nesne tespiti süreci, sınav gözetimi gibi uygulamalarda yüksek doğruluk ve etkinlik sağlar. Bu model, eğitim kurumlarına ve sınav denetleyicilerine, öğrencilerin dürüstlüğüne koruma ve sınav süreçlerinin güvenilirliğini artırma konusunda güçlü bir araç sunar.



Şekil 9. Faster R-CNN ile Bir Sınırlayıcı Kutu Çizerek Kopyasız Normal Durumu Belirleme

Kaynak: Sirt, D. (2023). *Bilgisayarlı görü ile yüz yüze sınavlarda şüpheli davranışların ortaya çıkarılması için derin öğrenme çerçevesi tasarımı*. [Doktora tezi]. Milli Savunma Üniversitesi. YÖK Açık Erişim: <https://tez.yok.gov.tr/UlusalTezMerkezi/>

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

Derin Öğrenme Modelinin Teknik Detayları

Modelin Yapısal Elemanları

Bu bölümde, derin öğrenme modelimizin teknik yapısını ve kayıp fonksiyonlarının nasıl işlediğini açıklıyoruz. Modelin iki ana bileşeni vardır: sınıflandırma kaybı ve regresyon kaybı.

Sınıflandırma ve Regresyon Kayıpları

Sınıflandırma Kaybı (cls):

Modelin, bir çapanın nesne mi yoksa arka plan mı olduğunu tahmin etme olasılığını hesaplar.

İki sınıf arasında log kaybı kullanarak hesaplanır: nesne ve nesne değil.

Her bir çapanın (i) tahmin edilen olasılığı p_i , temel gerçek etiketi ile karşılaştırılır.

Temel gerçek etiketi, eğer çapa pozitifse (yani, nesne içeriyorsa) 1, negatifse (yani, nesne içermiyorsa) 0 olarak atanır.

Regresyon Kaybı (reg):

Modelin, pozitif çapalar için tahmin ettiği sınırlayıcı kutu koordinatlarını temel gerçek kutu koordinatları ile karşılaştırır.

Kayıp fonksiyonu olarak düzgün L1 kaybı (Smooth L1 Loss) kullanılır. Bu kayıp fonksiyonu, regresyon kaybını yalnızca pozitif çapalar (nesne içerenler) için etkinleştirir.

Negatif çapalar için regresyon kaybı devre dışı bırakılır.

Kayıp Fonksiyonlarının Normalizasyonu ve Ağırlıklandırılması

cls ve reg katmanlarının çıktıları sırasıyla $\{p_i\}$ ve $\{t_i\}$ vektörlerini içerir.

İki kayıp terimi, cls ve reg, farklı yöntemlerle normalleştirilir ve bir dengeleme parametresi λ ile ağırlıklandırılır.

Sınıflandırma kaybı (cls), mini toplu boyutu (örneğin, = 256) ile normalleştirilir.

Regresyon kaybı (reg), çapa konumlarının sayısı (yaklaşık $\sim 2,400$) ile normalleştirilir.

λ varsayılan olarak 10 olarak ayarlanmıştır, bu da cls ve reg terimlerinin kabaca eşit ağırlıklandırılmasını sağlar.

Deneyler, sonuçların geniş bir λ aralığına duyarlı olmadığını göstermiştir.

Parametrizasyon ve Koordinatlar

Sınırlayıcı kutu regresyonu için dört koordinatın parametrizasyonu şu şekildedir:

Merkezi nokta koordinatları (x, y)

Genişlik (w) ve yükseklik (h)

Bu parametrizasyon, modelin sınırlayıcı kutuları daha hassas bir şekilde tahmin etmesine olanak tanır.

Sonuç ve Uygulamalar

Bu teknik detaylar, Faster R-CNN modelinin nesne tespitindeki yüksek performansını açıklamak için kritik öneme sahiptir. Özellikle, sınıflandırma ve regresyon kayıplarının doğru bir şekilde hesaplanması ve bu kayıpların uygun şekilde normalleştirilmesi, modelin sınav gözetimi gibi uygulamalarda anormal davranışları doğru bir şekilde tespit etmesine yardımcı olur. Modelin etkinliği, eğitim sürecindeki bu ayrıntılı yaklaşımla güçlendirilmiştir ve sonuçta sınav güvenliğini artıran bir sistem ortaya çıkmıştır.

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

Sınırlayıcı Kutu Koordinatları ve Regresyon

Sınırlayıcı kutuların merkez koordinatları (x, y) ve genişlik (w) ve yükseklik (h) gibi parametreler, regresyon nesnesi tespitinde kullanılır. Tahmin edilen kutu, bağlantı kutusu ve temel gerçek kutusu bu koordinatlarda gösterilir. Bir çapa kutusundan yakın bir temel gerçek kutusuna dönüşüm, sınırlayıcı kutu regresyonunun bir örneğidir. Faster R-CNN algoritması, özellikle küçük nesnelerin tespitinde üstün performans gösterir, bu da sınavlarda kopya çekme davranışlarını belirlemede önemli bir avantaj sağlar. Telefon veya not gibi kopya nesneleri bulma konusunda çok iyidir. Bununla birlikte, bu yaklaşım henüz araştırma aşamasında ve yaygın olarak kullanılmamıştır.

YOLOv5: Gerçek Zamanlı Nesne Tespiti

"Sadece Bir Kez Bak" anlamına gelen YOLOv5, tek bir evrişimli sinir ağı (CNN) kullanarak aynı anda nesneleri tespit edebilir. İki aşamalı bir işlem hattı yerine tüm görüntüyü tek bir seferde işleyerek gerçek zamanlı işlemeye izin verir. Sınav sırasında cep telefonu veya kitap gibi şeyleri hızlı bir şekilde tespit etmek için bu idealdir. YOLOv5, görüntüyü bir hücre ızgarasına bölerek her hücrenin sınıf olasılıklarını tahmin etmesini sağlar. Bu tasarımın bir sonucu olarak, sınav boyunca kopya davranışlarının anında tespit edilmesi mümkündür.

Eğitim ve Optimizasyon Prosedürleri

YOLOv5 modelinin başarısı, eğitim prosedürlerinin nasıl işlediğinin bir sonucudur. Modelin sınıf tahminlerinin doğruluğu, çapraz entropi kaybı eğitimi ile artırılır. Modelin performansını değerlendirmek için doğruluk metrikleri ve Adam Eniyileyici gibi güçlü optimizasyon teknikleri kullanılır. Modelin

genelleştirilebilirliği, veri artırımı teknikleri kullanılarak artırılabilir. Eğitim verisi, ölçekleme, yansıtma, rastgele kırpma ve renk değişiklikleri gibi işlemlerle çeşitlendirilir, bu da modelin farklı durumlarda daha iyi çalışmasını sağlar.

Modelin Mimari ve Performansı

Sınav sırasında şüpheli davranışları belirlemek için önerilen model derin öğrenme tekniklerini kullanır. Bu nedenle, CNN tabanlı bir mimari seçilmiştir. Inception-v3 mimarisi için eğitilmiş bir model kullanılmıştır. Bu, transfer öğrenme tekniği kullanılarak önceden eğitilmiş modelin mevcut veri kümesine uyarlanmasını sağlar ve sonuçların doğruluğunu artırır. Sınav ortamındaki şüpheli faaliyetleri tanımak ve sınıflandırmak için bu tür bir mimari kullanılabilir.

Zamansal Analiz ve Atlamalar

Videodaki değişiklikleri zaman içinde incelemek için zamansal analiz kullanılabilir. Bu, sınav boyunca öğrencilerin davranışını izlemek ve anormal davranışları bulmak için kullanılır. Video analizinde zamansal atlama, kareler arasındaki zaman aralığını tanımlar. Daha küçük bir zamansal adım, daha ayrıntılı bir analiz sağlar ancak daha fazla hesaplama gerektirir. Daha fazla zamansal adım, daha az ayrıntı ile daha hızlı analiz sağlar. Büyük veri kümeleri ve gerçek zamanlı analizler için bu denge çok önemlidir.

Etkinlik Tanıma ve Zamansal Adımların Rolü

Olay tanıma olarak bilinen videolardaki olayların veya eylemlerin analizi, bu olayların zaman içinde nasıl geliştiğini anlamayı içerir. Analiz hassasiyeti ile hesaplama kaynakları arasında bir denge kurmak için zamansal adım boyutu çok önemli bir rol oynar. Daha küçük bir zamansal adım, hızlı tempolu ve karmaşık faaliyetlerin, ek kaynaklar pahasına da olsa, daha derinlemesine incelenmesine olanak tanır. Öte yandan, daha büyük bir zamansal adım, analizi hızlandırır ancak önemli ayrıntıların gözden kaçırılması riskini taşır. Aktivite tanıma analizinde zamansal adımın seçimi, analizlerin verimliliğini ve doğruluğunu doğrudan etkileyen hayati bir karardır.

Muayene izleme ve anormallik tespiti söz konusu olduğunda YOLOv5 ve Faster R-CNN modelleri güçlü yetenekler sunar. Bu modeller hız, doğruluk ve

esneklik açısından dikkate değer faydalar sağlar. Olay tanıma ve zamansal analiz tekniklerini entegre eden bu modellerin, sınav güvenliğini artırma ve kopya çekme olaylarını belirleme konusunda oldukça etkili olduğu kanıtlanmıştır.

Anormallik tespitinin temel unsurları iki ana bileşene ayrılabilir: özellik çıkarma ve anormallik tespit modeli. Özellik çıkarma, belirli davranışsal özelliklerin çıkarılmasını içerirken, anormallik tespit modeli, anormal davranış örneklerini tanımlamak için bu özellikleri inceler.

Başlangıç olarak video verileri hem fiziksel hem de zamansal aralıklara göre bölümlere ayrılır. Bu segmentasyon, belirli özelliklerin çıkarılmasının daha verimli bir şekilde gerçekleştirilmesine olanak tanır. Eğitim aşamasında sistem bu özelliklerden öğrenir ve normal davranışı temsil eden modeller oluşturur. Videolardan çıkarılan özellikler normal davranışın anlaşılmasında ve modellenmesinde önemli bir rol oynamaktadır.

Test aşamasında test verileri, yerleşik normal davranış modeliyle karşılaştırılarak incelenir. Bu, test edilen davranışın normdan sapıp saptığını tespit etmek için çeşitli özelliklerin anormallik seviyelerinin değerlendirilmesini içerir.

Modelin geliştirilmesinde, derin öğrenme tekniklerini içeren gelişmiş bir sinir ağı API'si olan Keras kullanıldı. Keras, modüler tasarımı sayesinde model oluşturma sürecini hızlandırır ve uyarlanabilirlik sunar. Görüntü işleme ve analiz prosedürleri CNN gibi özellikleri kullanır. Ayrıca Keras, hem CPU'lar hem de GPU'lar ile uyumluluğu sağlayarak olağanüstü performans ve ölçeklenebilirlik sağlar.

Sınavlar sırasında şüpheli davranışların tespit edilmesi ve sınıflandırılması söz konusu olduğunda, bu son teknoloji modelin kullanımı ve etkinliği ölçülemez. Olağandışı eylemlerin hızlı ve doğru bir şekilde belirlenmesi, hem eğitim kurumları hem de sınav gözetmenleri için büyük önem taşımaktadır. Bu model, adil bir test ortamını garanti eden ve dürüst olmayan davranışları etkili bir şekilde önleyen olağanüstü verimli bir çözüm sunar. Ayrıca bu tür uygulamaların geliştirilmesi, derin öğrenme ve görüntü işleme alanlarındaki araştırma ve teknolojinin ilerlemesine de katkıda bulunuyor.

Bir yapay zeka modelinin başarılı bir şekilde uygulanması, büyük ölçüde temel bileşenler olan anormallik tespitine ve özellik çıkarmaya dayanır. Bu süreçler normal

ve anormal davranışlar arasında ayırım yapılmasını sağlar. Bu modellerin geliştirilmesini ve uygulanmasını kolaylaştıran bir araç olan Keras'ın paha biçilmez olduğu kanıtlanmıştır. Eğitim ortamlarında ortaya çıkan model, sınav güvenliğinin artırılmasında ve adil değerlendirmenin sağlanmasında önemli bir rol oynamaktadır.

2.3.1 Kalıntı Ağlar (ResNets)

Çalışmamızda hem sınıflandırma hem de transfer öğrenme çalışmaları için ResNet-50 çerçevesini kullandık. LeNet ailesi gibi önceki CNN mimarileri, derin öğrenmede önemli bir ilerleme kaydetmiş olsa da, sınırlı sayıda katman nedeniyle karmaşık veri kümeleriyle karşılaştıklarında yetersiz kalabiliyorlar. Ek olarak, bu daha basit mimariler, derin ağlarda eğimlerin kaybolması sorununa karşı hassastır. Bu sorun, ağır eğitim süreci sırasında eğimlerin aşırı derecede küçülmesi veya büyümesi durumunda ortaya çıkar ve sonuçta derin ağların performansında bir düşüşe yol açar.

Kaybolan eğimler sorununu çözmek için Artık Ağların (ResNets) geliştirilmesinin önemli bir atılım olduğu kanıtlandı. ResNets, katmanlar arasında kalan bağlantıları birleştirerek sorunu etkili bir şekilde azaltır. Bu bağlantılar katmanlar arasında doğrudan yollar oluşturarak gradyanların düzgün bir şekilde geri yayılmasını sağlar ve daha derin ağların eğitilmesini kolaylaştırır. Sonuç olarak ResNet'ler, değişen sayıda katmana sahip farklı varyasyonlarla, derin öğrenme topluluğu içinde standart mimariler olarak geniş çapta benimsendi.


Çalışma, ResNet-50 mimarisini benimseyerek onu hem sınıflandırma hem de transfer öğrenme girişimlerine uyguluyor. ResNet-50, sınıflandırma görevlerinde nesneleri veya sınıfları görselleştirme yeteneğine sahiptir. Transfer öğrenimi, bilgeliğin halihazırda öğretilmiş bir modelden yeni bir göreve aktarılmasını gerektirirken, veri sınırlı senaryolarda veya özel bir model oluştururken oldukça avantajlı bir eylemdir. Bu gibi durumlarda, becerikli ResNet-50 etkili bir şekilde kullanılabilir ve daha büyük zafer oranlarına ulaşma potansiyeli not edilir.

Sonuç olarak, ResNets, derin öğrenme mimarilerinin resmini açan, böylece ortadan kaybolan gradyan ikilemini aşan ve yalnızca daha derin değil aynı zamanda daha verimli ağların oluşturulmasını güçlendiren CNN'ler alanında önemli bir sıçrama olarak görülebilir. Bu nedenle, çok sayıda bilgisayarlı görme uygulamasında

benimsenmesi yaygınlaştı; bu da derin öğrenmenin veri işleme ve analizle ilgili daha geniş bir görev kapsamını başarıyla ele almasına olanak tanır.

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

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



Şekil 10. ResNet Ön Eğitimli Ağ

Kaynak: Sirt, D. (2023). *Bilgisayarlı görü ile yüz yüze sınavlarda şüpheli davranışların ortaya çıkarılması için derin öğrenme çerçevesi tasarımı*. [Doktora tezi]. Milli Savunma Üniversitesi. YÖK Açık Erişim: <https://tez.yok.gov.tr/UlusalTezMerkezi/>

ResNet-50 modeli, ilk olarak üç kanallı bir giriş görüntüsünü 64 kanallı bir görüntüye dönüştüren 7×7 evrişim katmanı ile başlar. Ardından dört aşamada düzenlenmiş artık bloklar gelir. Bu blokların sonuncusu $2048 \times 7 \times 7$ boyutunda bir çıktı üretir ve bu çıktı, boyutunu 7×7 olan ortalama havuzlama katmanı ile 2048 boyutunda bir vektöre indirgenir. Son aşamada ise tam bağlantılı bir katman, bu vektörü 5 sınıfa yönelik nihai logitlere dönüştürür.

Nesne tespiti süreci, sınırlayıcı kutularla etiketlenmiş eğitim verilerini gerektirir ve bu süreç oldukça zahmetli ve zaman alıcıdır. İnsan müdahalesi gerektirdiğinden ek iş yükü ve maliyetler doğar. Bu zorluğu hafifletmek ve modeli daha verimli eğitmek için yaygın bir yöntem kullanılır. Bu yaklaşım, geniş bir sınıflandırma veri kümesi üzerinde önceden eğitilmiş evrişimli bir modelle başlar. Örneğin, ResNet gibi güçlü bir evrişimli ağ modeli bu amaçla seçilebilir. Ancak, bu modelin nesne tespiti görevine uyarlanabilmesi için bazı değişiklikler yapılması gerekmektedir.

Modelde yapılan değişiklikler arasında, nesne tespiti için gerekli geometrik özellikleri öğrenmek üzere ek evrişim katmanlarının eklenmesi bulunur. Bu katmanlar, sınırlayıcı kutuların boyutları ve konumları gibi bilgileri öğrenmeye odaklanır. Eğitim sürecinde her bir sınırlayıcı kutu, belirli bir nesneyi temsil eden sınıflandırma veri kümesiyle ilişkilendirilir. Bu da her bir kutunun, ilgili nesneyi tanımlamak için kullanılacak özelliklerin bir temsilcisi olduğu anlamına gelir.

Nesne tespiti sürecinde, iki farklı kayıp terimi kullanılır: Birincisi, nesnenin varlığını tahmin etmek için kullanılırken, diğeri sınırlayıcı kutunun doğru boyut ve konumunu tahmin etmek için gereklidir. Sınırlayıcı kutu eşleşmeleri olmayan her bir eksende, sadece çapraz entropi kaybı uygulanarak "nesne yok" sınıfı tahmin edilir. Bu durumlar, bir nesnenin belirli bir sınırlayıcı kutu ile ilişkilendirilmediği durumları ifade eder. Bu sayede model, nesne tespiti görevi için gerekli olan sınırlayıcı kutuları ve özellikleri öğrenir.

Sonuç olarak, derin öğrenme mimarileri, hem sınıflandırma hem de transfer öğrenme görevleri için etkili bir şekilde kullanılabilir. Örneğin, ResNet-50 gibi bir model geniş veri kümeleri üzerinde eğitildiğinde yüksek doğruluk ve performans sağlayabilir. Kalıntı bağlantıları sayesinde, daha derin ağların eğitimi mümkün olurken

kaybolan gradyan sorunu da aşılabılır. Bu özellikler, ResNet-50 modelini sınav izleme ve anormallik tespiti gibi karmaşık görevler için ideal bir çözüm haline getirir.

Bu metodoloji, önceden eğitilmiş sınıflandırma modellerini nesne tespiti görevlerine adapte ederek verimli bir çözüm sunar. Bu yaklaşım, nesne tespiti için gereken etiketleme işlemlerini azaltırken eğitim sürecini hızlandırır ve maliyetleri düşürür. Sonuç olarak, nesne tespiti modellerinin daha hızlı geliştirilmesi ve büyük veri kümeleri üzerinde üstün performans göstermesi mümkün olur.

2.4. Model Özellikleri ve Eğitim Detayları

Bu araştırmada YOLOv5 ve Faster R-CNN modelleri, sınıf sınavlarında anormallik tespit süreçlerini optimize etmek için özenle eğitilmiştir. Model eğitimi, yüksek performans elde etmek için çeşitli kritik aşamaları içermektedir.

Başlangıçta, model eğitimi için zengin ve çeşitli içeriğe sahip bir veri kümesi titizlikle seçilmiştir. Bu veri kümesi, sınav sırasındaki potansiyel anormallik durumlarını kapsamlı ve doğru bir şekilde etiketlenmelidir. Bu adım, modelin anormallikleri doğru bir şekilde tanımasını sağlamak için kritik öneme sahiptir.

Eğitim sürecinde, modelin öğrenmesi gereken özelliklerin belirlenmesi için özel bir özellik mühendisliği süreci uygulanmıştır. Bu süreç, sınav sırasında olası anormallik belirtilerini temsil eden özelliklerin doğru bir şekilde tanımlanmasını ve modelin bu özellikleri öğrenmesini sağlar.

Modelin hiperparametreleri ve ağırlıkları, eğitim süreci boyunca düzenli olarak ayarlanmış ve optimize edilmiştir. Bu adım, modelin performansını artırmak ve ağırlıkların istenmeyen davranışlarını önlemek için kritik öneme sahiptir.

Eğitim sırasında kullanılan kayıp fonksiyonları ve optimize edici algoritmalar, modelin daha hızlı ve daha kararlı bir şekilde eğitilmesine katkıda bulunmuştur.

Veri artırma teknikleri de eğitim sürecinde önemli bir rol oynamıştır. Bu teknikler, modele daha fazla çeşitlilik ve genelleme yeteneği kazandırmak için kullanılmıştır. Örneğin, veri artırma, aynı nesne veya olayın farklı açılardan, boyutlardan veya aydınlatma koşullarından görüldüğü çeşitli örneklerin üretilmesini içermiştir.

Modelin performansı düzenli olarak doğrulama veri kümesi üzerinde test edilmiştir. Bu testler, modelin doğruluğunu ve anormallik tespit yeteneğini ölçmek için yapılmıştır. Elde edilen performans sonuçları, modelin doğruluğunu artırmak ve anormallik tespit yeteneğini geliştirmek için gerekli iyileştirmelerin yapılmasını sağlamıştır.

YOLOv5 ve Faster R-CNN gibi seçilen modeller, sınıf sınavlarındaki anormallik tespit görevlerinde yüksek performans sergilemektedir. Bu modeller, öğrenci kopya davranışlarını daha etkili bir şekilde tespit etmek ve eğitim kurumlarının denetim süreçlerini iyileştirmek için güçlü araçlar sunmaktadır.

2.4.1. Yürütme Süresi ve Ortamı Detayları

Google Colab, veri bilimciler ve derin öğrenme uygulayıcıları için ücretsiz bulut tabanlı hesaplama kaynaklarına erişim sağlayan güçlü bir platformdur. Colab, varsayılan olarak CPU çalışma zamanı sunar, ancak GPU (Grafik İşlem Birimi) ve TPU (Tensör İşlem Birimi) gibi hızlandırılmış hesaplama gereksinimleri için seçenekler de sunar. Bu çalışmada, Google Colab'ın sağladığı GPU kaynaklarını ve bu GPU'ların CPU'lardan nasıl farklılaştığını adım adım inceledik.


Google Colab'da GPU seçenekleri, Colab tarafından tahsis edilen kaynaklara bağlı olarak sürekli değişebilir. Bu bağlamda, Tesla T4 ve NVIDIA A100 gibi iki farklı GPU türü üzerinde duruldu.

Tesla T4 GPU, 2560 CUDA çekirdeği ve 16GB GDDR6 belleği ile derin öğrenme uygulamaları için optimize edilmiştir. Yüksek performansı ile dikkat çeken bu GPU, çeşitli derin öğrenme görevlerini hızlı bir şekilde gerçekleştirebilme kapasitesine sahiptir.

NVIDIA A100 GPU ise daha ileri düzeyde bir performans sunar. 6912 CUDA çekirdeği, 40GB grafik belleği ve 1,6TB/s grafik belleği bant genişliği ile çok daha karmaşık ve yoğun hesaplama gerektiren derin öğrenme görevleri için idealdir. Bu gelişmiş özellikler, A100'ü büyük modelleri ve geniş veri kümelerini işlemek için optimal bir seçenek haline getirir.

Şekil 11'de, COPYNet çerçevesinin farklı hesaplama ortamlarında çalıştırılmasıyla elde edilen yürütme süreleri karşılaştırılmaktadır. Bu karşılaştırma, CPU, Tesla T4 GPU ve NVIDIA A100 GPU arasındaki performans farklarını açıkça ortaya koymaktadır. GPU hızlandırıcıları, özellikle büyük veri kümeleri ve karmaşık modellerle çalışırken CPU'lara göre önemli ölçüde daha hızlı sonuçlar sağlar.

Bu performans farklarını anlamak, derin öğrenme iş akışları için uygun donanım seçiminde bilinçli kararlar alınmasını sağlar. Uygulamanın gereksinimlerine ve hesaplama ihtiyaçlarına göre doğru donanımın seçilmesi, etkili ve verimli derin öğrenme modellerinin geliştirilmesinde kritik bir rol oynar.



Şekil 11. Yürütme Ortamlarının Karşılaştırması

Kaynak: Yazar tarafından oluşturulmuştur.

2.4.2. 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

Bu çalışma, yaklaşık 30.000 etiketli görüntüden oluşan özel bir veri kümesi kullanarak kopya davranışlarını tespit eden YOLOv4 ve Faster R-CNN modellerinin eğitimini içermektedir. Veri kümesi, sınav sırasında karşılaşılan çeşitli kopya yöntemlerini içermekte ve öğrencilerin bu yöntemleri kullanma olasılığını simüle etmektedir. Bu veri kümesi, modelin etkili bir şekilde eğitilmesinde kritik bir rol oynamaktadır.

Veri normalizasyonu ve büyütme, eğitim sürecinin ilk adımlarını oluşturur. Veri normalizasyonu, pikselleri belirli bir aralığa ölçeklendirerek modelin öğrenme sürecini iyileştirir. Büyütme işlemi ise, görüntüleri farklı açılardan ve boyutlardan inceleyerek modelin genelleme yeteneğini artırır.

Eğitim sırasında, öğrenme oranını yönetmek için üstel bozunma özellikli bir öğrenme oranı zamanlayıcısı kullanılmıştır. Ayrıca, modelin performansını izlemek için kayıp ve doğrulama doğruluğu gibi parametrelerin izlenmesini sağlayan bir izleme sistemi kurulmuştur.

Aşırı uyumu önlemek ve genelleme yeteneğini artırmak için bir bırakma (dropout) katmanı eklenmiştir. Bu katman, eğitim sırasında rastgele birimleri devre dışı bırakarak modelin aşırı uyum yapmasını engeller.

Modelin eğitimi, Google Colab gibi bulut tabanlı platformlar üzerinde GPU hızlandırması kullanılarak gerçekleştirilmiştir. GPU hızlandırması, modelin hızlı ve etkili bir şekilde eğitilmesini sağlar ve büyük veri kümeleri üzerinde çalışma kapasitesi sunar.

Bu bütünsel yaklaşım, sınav sırasındaki kopya davranışlarını tespit edebilen güçlü ve dayanıklı bir modelin oluşturulmasını sağlar. Eğitim kurumlarına, sınav güvenliğini artırma ve denetim süreçlerini iyileştirme konusunda önemli bir araç sunar.

2.4.3. Faster R-CNN Yapılandırması ve Eğitimi

Faster R-CNN'nin konfigürasyonu aşağıdaki unsurları içermektedir:

- Omurga: ResNet-50
- Giriş Görüntü Boyutu: 600x600 piksel
- Çapa Oranları: [0.5, 1, 2]
- Toplu İş Boyutu: 8
- Öğrenme Oranı: 0.001
- Yineleme Sayısı: 50
- Eniyileyici: Adam
- Kayıp Fonksiyonu: Sınıflandırma için Çapraz Entropi, sınırlayıcı kutu regresyonu için Ortalama Karesel Hata (MSE)

YOLOv5 ve Faster R-CNN gibi güçlü nesne tespiti modellerinin eğitimi için kullanılan veri kümesi, veri artırma ve normalizasyon işlemlerinden geçirilmiştir. Bu adımlar, modelin genelleme kabiliyetini artırmak ve daha güçlü özellikler öğrenmesini sağlamak için kritik öneme sahiptir. Veri artırma işlemi, görüntüleri döndürme, yansıtma, kırpma ve renk değiştirme gibi yöntemlerle zenginleştirilerek veri çeşitliliğini artırır. Normalizasyon ise, görüntülerin piksel değerlerini belirli bir aralığa ölçekleyerek modelin daha kararlı bir şekilde öğrenmesini sağlar.

Eğitim süreci, iki aşamalı bir işlem hattıyla gerçekleştirilmiştir. İlk aşamada, Bölge Öneri Ağı (RPN) adı verilen bir yapı ile aday sınırlayıcı kutular oluşturulur ve potansiyel nesne konumları tahmin edilir. İkinci aşamada ise, Faster R-CNN modülü bu aday sınırlayıcı kutuları rafine eder ve daha kesin nesne sınırlayıcıları elde edilir.

Eğitim sırasında modelin öğrenme hızı, ayarlanabilir bir zamanlayıcı kullanılarak optimize edilmiştir. Bu yaklaşım, modelin başlangıçta hızlı bir şekilde öğrenmesini ve daha sonra daha küçük adımlarla yakınsamasını sağlar. Ayrıca, toplu normalizasyon ve bırakma katmanları eklenerek modelin genelleme yeteneği artırılmış ve aşırı uyum riski azaltılmıştır.

Eğitim süreci, Google Colab'ın GPU altyapısı kullanılarak gerçekleştirilmiştir. Bu sayede modelin daha hızlı eğitilmesi ve yüksek hesaplama gücüne erişim sağlanması mümkün olmuştur. GPU hızlandırması, eğitim sürecini önemli ölçüde hızlandırarak modelin performansını artırmıştır.

Bu bütünsel yaklaşım, YOLOv5 ve Faster R-CNN gibi güçlü nesne tespiti modellerinin eğitimini optimize eder ve sınav ortamlarında anormallik tespiti gibi kritik görevlerde yüksek hassasiyet ve performans sağlar. Bu eğitim süreci, sınav güvenliğini artırma ve kopya çekme girişimlerini tespit etme konusunda önemli bir rol oynamaktadır.

2.4.4. Değerlendirme Protokolü

Modelin etkinliğini belirlemek amacıyla kapsamlı bir değerlendirme süreci oluşturulmuştur. Bu süreç, çeşitli metrikler ve test veri kümesi üzerinden gerçekleştirilmektedir.

Metrikler

Değerlendirme sürecinin bel kemiğini metrikler oluşturur. Bu metrikler, modelin performansını objektif bir şekilde ölçmek için kullanılır. Bazı temel metrikler şunlardır:

Hassasiyet (Precision): Modelin pozitif tahminlerinin ne kadarının gerçek pozitif olduğunu gösterir. Bu metrik, yanlış pozitiflerin etkisini ölçer.

Geri Çağırma (Recall): Gerçek pozitiflerin tüm pozitif örnekler içerisindeki oranını belirler. Bu metrik, yanlış negatiflerin etkisini ölçer.

F1-Skoru (F1-Score): Hassasiyet ile geri çağırmanın harmonik ortalamasıdır. Modelin genel tespit performansını bir bütün olarak değerlendirir.

Ortalama Hassasiyet (mAP): Farklı sınıf ve nesneler için ayrı ayrı hesaplanan hassasiyetlerin ortalamasını temsil eder. Modelin genel tespit başarısını yansıtır.

Ortalama Birleşme Üzerinden Kesişim (IoU): Modelin sınırlayıcı kutularının hedef nesneleri ne kadar doğru çevrelediğini ölçer. Bu metrik, tespit doğruluğunu detaylı bir şekilde analiz eder.

Test Veri Kümesi

Modelin performansını değerlendirmek ve doğruluk sağlamak için test veri kümesi kullanılır. Test veri kümesi, modelin daha önce görülmemiş verilere ne kadar iyi genelleme yaptığını değerlendirmek için kritik öneme sahiptir.

Test Veri Kümesinin Önemi ve Bileşenleri:

Kalite ve Temsilcilik: Test veri kümesinin kalitesi ve temsiliyeti, modelin gerçek dünya koşullarında nasıl performans göstereceğini güvenilir bir şekilde tahmin etmemizi sağlar.

Çeşitli Senaryolar: Test veri kümesi, öğrencilerin sınav sırasında yapabileceği şüpheli davranışları temsil eden farklı senaryoları içerir. Bu senaryolar, sınav kağıtlarına bakma, yasaklı nesneleri kullanma gibi şüpheli davranışları simüle eder.

Görüntülerin Anlamı: Test veri kümesi içerisindeki her bir görüntü, belirli bir şüpheli davranış senaryosunu temsil eder. Bu görüntüler, modelin bu senaryoları doğru bir şekilde tanıyıp tanımadığını değerlendirmek için kullanılır.

Değerlendirme Sürecinin Önemi

Bu metrikler ve test veri kümesi, modelin sınav sırasında şüpheli davranışları ne kadar iyi tespit ettiğini değerlendirmek için kullanılır. Modelin doğruluğunu, hassasiyetini ve genelleme yeteneğini ölçerek, sınav gözetiminde kullanılabilirliğini belirler.

Sürekli İyileştirme ve Geri Bildirim

Değerlendirme süreci, aynı zamanda modelin performansını sürekli iyileştirmek için geri bildirim sağlar. Modelin eksiklikleri ve güçlü yanları belirlenir ve bu doğrultuda gerekli iyileştirmeler yapılır. Bu süreç, modelin sınav gözetimi gibi kritik görevlerde daha etkili ve güvenilir olmasını sağlar.

Bu kapsamlı değerlendirme protokolü, modelin gerçek dünya uygulamalarında ne kadar başarılı olacağını ve sınav ortamında kopya davranışlarını tespit etme yeteneğini doğru bir şekilde değerlendirmeyi amaçlamaktadır.

Modelin etkinliğini ve doğruluğunu belirlemek için titiz bir değerlendirme süreci oluşturulmuştur. Bu süreç, çeşitli metrikler ve test veri kümesi üzerinden gerçekleştirilmektedir.

Maksimum Olmayan Bastırma

Nesne tespiti modellerinde yaygın olarak kullanılan maksimum olmayan bastırma (NMS), sonuçların kalitesini artıran önemli bir tekniktir. NMS'in temel amacı, nesne tespiti sırasında gereksiz sınırlayıcı kutuları azaltmak ve nesnelerin daha doğru bir şekilde sınıflandırılmasını sağlamaktır. Bu teknik, modelin lokalizasyon doğruluğunu artırarak nesneleri daha iyi çerçevelemesine yardımcı olur.

Nesne tespiti modelinin sonuçlarını iyileştiren ve hesaplama kaynaklarını daha verimli kullanan önemli bir teknik olan maksimum olmayan bastırma (NMS), tespit edilen nesnelerin belirli bir güven eşiğini aşan sınırlayıcı kutularını korurken diğerlerini elemeyi sağlar. Bu yaklaşım, modelin yüksek güvene sahip tahminleri muhafaza etmesini ve düşük güvene sahip olanları elemesini sağlayarak daha temiz ve doğru sonuçlar elde edilmesine olanak tanır.

Sonra metni uygun yerlere ekleyeyim:

NMS, nesne tespiti modelinin performansını önemli ölçüde iyileştiren bir yöntemdir. Güven eşiği ayarlaması, modelin tespit hassasiyetini ve özgüllüğünü belirleyen kritik bir faktördür. Bu değerlendirme protokolü, modelin gerçek dünya sınav koşullarında başarısını doğru bir şekilde değerlendirir ve kopya davranışlarını etkili bir şekilde tespit etme yeteneğini gözler önüne serer.

Maksimum olmayan bastırma (NMS), nesne tespiti alanında yaygın olarak kullanılan ve sonuçları iyileştiren temel bir tekniktir. Bu teknik, gereksiz sınırlayıcı kutuların azaltılmasını sağlayarak modelin daha hızlı çalışmasına ve daha hassas sonuçlar elde etmesine yardımcı olur. Dolayısıyla, maksimum olmayan bastırma, nesne tespiti uygulamalarında vazgeçilmez bir rol oynamaktadır.

Eşik Ayarlama

Eşik ayarlama, nesne tespiti ve sınıflandırma modellerinin performansını etkileyen kritik bir parametredir. Bu mekanizma, bir modelin tahminlerini değerlendirmek ve sonuçları şekillendirmek için kullanılır. Bir tahminin kabul

edilebilir bir güven düzeyini aşması gerektiği eşiği belirlemek için kullanılan bu teknik, 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. Örneğin, bir nesne için belirli bir güven değeri belirlendiğinde, model sadece bu eşiği aşan tahminleri kabul ederken, diğer tahminler bu eşiği karşılamadığı için reddedilir. Bu mekanizma, modelin performansını optimize ederek hassasiyet ve özgüllük arasında bir denge sağlar ve istenmeyen yanlış pozitifleri ve yanlış negatifleri en aza indirir.

Güven Eşiği Seçimi:

Doğru güven eşiği seçimi, modelin genel doğruluğunu ve performansını artırır. Eşik ayarlaması dikkatlice optimize edilmesi gereken bir parametredir ve modelin kullanılabilirliği ile güvenilirliği açısından kritik bir rol oynar.

Hassasiyet ve Özgüllük: Eşik ayarlaması, modelin doğru tahminler yapma yeteneğini artırarak hassasiyetini ve özgüllüğünü dengeler. Bu, modelin daha güvenilir ve doğru sonuçlar üretmesini sağlar.

Yanlış Pozitifler ve Negatifler: Doğru eşik değeri, modelin yanlış pozitif ve yanlış negatif oranlarını minimize eder, böylece istenmeyen hatalı tahminler en aza indirilir.

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

Sonuç olarak, maksimum olmayan bastırma ve eşik ayarlama teknikleri, nesne tespiti modellerinin performansını optimize etmek için kritik öneme sahiptir. Bu teknikler, modelin daha doğru ve güvenilir sonuçlar üretmesine yardımcı olurken, hesaplama kaynaklarının verimli kullanılmasını sağlar. Bu, özellikle sınav gözetimi gibi hassas uygulamalarda modelin etkinliğini artırmak için büyük bir avantaj sağlar.

Temel Teknikler ile Karşılaştırma:

Modelin performansını değerlendirmek ve üstünlüğünü göstermek amacıyla, yaygın olarak kullanılan temel tekniklerle karşılaştırma yapılmıştır. Bu adım, nesne

tespiti ve sınıflandırma modellerinin etkinliğini anlamak için kritik bir değerlendirme sürecidir.

Karşılaştırmanın Önemi

Temel teknikler, nesne tespiti alanında geniş kabul gören yöntemleri ifade eder ve sınırlayıcı kutu tahminleri, özellik çıkarma, model mimarileri ve öğrenme stratejileri gibi bileşenleri içerir. Bu tekniklerle yapılan karşılaştırmalar, modelin bu bileşenlere kıyasla nasıl performans gösterdiğini belirlemek için kullanılır. Karşılaştırma sonuçları, modelin etkinliğini ve ne kadar etkili olduğunu ortaya koyar.

Karşılaştırma Metrikleri

Performans değerlendirmesinde kullanılan metrikler, modelin doğruluğunu ve sınıflandırma yeteneğini objektif bir şekilde ölçmek için hayati öneme sahiptir. Bu metrikler arasında hassasiyet, geri çağırma, F1-skoru ve Ortalama Hassasiyet (mAP) bulunur.

Hassasiyet: Modelin pozitif tahminlerinin ne kadar doğru olduğunu gösterir.

Geri Çağırma: Gerçek pozitiflerin tüm pozitif örnekleri ne kadar kapsadığını ölçer.

F1-Skoru: Hassasiyet ve geri çağırmanın harmonik ortalamasıdır.

Ortalama Hassasiyet (mAP): Farklı sınıf ve ögeler için ayrı ayrı hesaplanan hassasiyetlerin ortalamasıdır ve modelin genel tespit başarısını yansıtır.

Temel Tekniklerle Karşılaştırma Sonuçları

Modelin performansının temel tekniklere göre karşılaştırılması, hangi yöntemlerin daha iyi çalıştığını ve modelin güçlü ve zayıf yönlerini belirlemeye yardımcı olur. Bu analiz, modelin belirli bir uygulama için en uygun olup olmadığını anlamak için yapılır.

Güçlü Yönler: Modelin hangi alanlarda üstün olduğunu ve hangi metriklerde en iyi performansı gösterdiğini belirler.

Zayıf Yönler: Modelin performansının iyileştirilebileceği alanları ve hangi bileşenlerin daha fazla geliştirme gerektirdiğini tespit eder.

Anlamak ve geliřtirmek iin temel tekniklerle yapılan karřılařtırma, modelin performans potansiyelini belirleyen ve iyileřtirme yol haritası oluřturan kritik bir adımdır. Hangi bileřenlerin daha fazla iyileřtirme potansiyeline sahip olduėunu tespit etmek, modelin optimize edilmesi ve daha stn sonular elde etmesi iin hayati nem tařır. Bu bilgiler, modelin geliřtirilmesinde stratejik kararlar alınmasına yardımcı olur.

Gerek dnya uygulamalarında yapılan testler, modelin etkinliėini ve gvenilirliėini gerek kořullar altında deėerlendirmek iin kritik neme sahiptir. Bu deėerlendirme, modelin eřitli senaryolarda nasıl performans gsterdiėini objektif bir řekilde ortaya koyar ve modelin pratik kullanımını doėrular.

Sonu olarak, temel tekniklerle yapılan karřılařtırma, nesne tespiti ve sınıflandırma modellerinin performansını deėerlendirmek ve geliřtirmek iin vazgeilmezdir. Bu sre, modelin gl ve zayıf ynlerini ortaya ıkararak, daha ileriye tařınmasını saėlar ve en iyi sonuları elde etmek iin gereken iyileřtirmeleri belirler.

Sınav sırasında řpheli faaliyetleri tespit etme ve sınıflandırmadaki etkinliėi deėerlendirmek iin izlenen kapsamlı sre, standartları net bir řekilde tanımlayarak bařlar. Bu sre, sınav kořullarında hangi faaliyetlerin řpheli kabul edileceėini belirlemekle bařlar ve ardından gvenlik nlemlerini ve algoritmayı doėrulamak iin bazı adımlar izler.

1. řpheli Faaliyetlerin Tanımlanması

Srecin bařlangıcında, sınav sırasında řpheli olarak kabul edilebilecek davranıřlar detaylı bir řekilde belirlenmiřtir. Bu tanımlar, veri toplama ve etiketleme iřlemlerinin doėruluėunu ve geerliliėini saėlamak iin hayati neme sahiptir. řpheli davranıřlar, bařka bir ėrencinin kaėıdına bakmak, cep telefonu kullanmak veya notları iletmek gibi kopya ekme giriřimlerini ierebilir.

2. Veri Toplama ve Etiketleme

řpheli faaliyetlerin tanımlanmasının ardından, bu davranıřları ieren veri kmesi oluřturulmuřtur. Uygun veriler, eřitli sınav senaryolarını ve potansiyel řpheli davranıřları yansıtacak řekilde dikkatlice toplanmıř ve etiketlenmiřtir. Bu

süreç, modellerin eğitiminde kullanılacak verilerin kalitesini ve güvenilirliğini sağlamak için kritik öneme sahiptir.

3. Model Eğitimi

Oluşturulan veri kümesi, modellerin şüpheli faaliyetleri tanıma yeteneklerini geliştirmek için kullanılmıştır. Eğitim sürecinde, YOLOv5 ve Faster R-CNN modelleri gibi güçlü nesne tespiti algoritmaları, bu veri kümesini kullanarak eğitilmiştir. Modeller, sınav sırasında şüpheli faaliyetleri tanıyabilmek için gerekli olan özellikleri öğrenir ve bu bilgileri kullanarak doğru sınıflandırmalar yapar.

4. Değerlendirme Süreci

Model eğitiminin ardından, modellerin performansını objektif olarak değerlendirmek için çeşitli metrikler kullanılmıştır. Hassasiyet, geri çağırma, F1-skoru ve Ortalama Hassasiyet (mAP) gibi metrikler, modellerin şüpheli faaliyetleri ne kadar etkili bir şekilde tespit ettiğini ve kategorize ettiğini ölçmek için kullanılmıştır.

Hassasiyet: Modelin pozitif tahminlerinin ne kadar doğru olduğunu gösterir.

Geri Çağırma: Modelin gerçek pozitifleri ne kadar iyi kapsadığını gösterir.

F1-Skoru: Hassasiyet ve geri çağırmanın harmonik ortalamasıdır.

Ortalama Hassasiyet (mAP): Farklı sınıf ve ögeler için ortalama hassasiyeti temsil eder.

5. Sonuçların Değerlendirilmesi

Değerlendirme sonuçları, modellerin sınav sırasında şüpheli faaliyetleri ne kadar etkili bir şekilde tespit ettiğini ve kategorize ettiğini ortaya koymuştur. Bu sonuçlar, modellerin güvenilirliğini ve uygulanabilirliğini sağlamak için önemli bir geri bildirim sağlamıştır. Ayrıca, hangi modellerin ve tekniklerin en iyi performansı sergilediğini belirlemeye yardımcı olmuştur.

6. Sürekli İyileştirme

Değerlendirme sürecinin sonuçlarına dayalı olarak, modellerin performansını daha da artırmak için sürekli iyileştirme adımları atılmıştır. Bu, veri kümesinin genişletilmesi, model hiperparametrelerinin optimize edilmesi ve eğitim sürecinde kullanılan tekniklerin geliştirilmesini içerebilir.

Bu kapsamlı değerlendirme süreci, sınıf sınavları sırasında şüpheli faaliyetleri tespit eden ve kategorize eden modellerin etkinliğini sağlamada kritik bir rol oynamıştır. Modellerin performansını optimize etmek ve eğitim kurumlarının sınav güvenliğini artırmak için bu tür titiz ve sistematik yaklaşımlar gereklidir.

2.5. Algoritmik Karmaşıklık

COPYNet, karmaşık derin öğrenme modelleri Faster R-CNN, YOLOv5 ve ResNet'in bileşenlerini içermektedir. Her biri farklı hesaplama gereksinimleri ve algoritmik karmaşıklıklarla öne çıkar. Bu bölümde, her bileşenin karmaşıklığını detaylı bir şekilde inceleyeceğiz ve COPYNet'in toplam algoritmik karmaşıklığını belirleyeceğiz.

Faster R-CNN Faster R-CNN modeli, nesne tespiti sürecinde çeşitli adımlar içerir. İlk olarak, sabit boyutlu bir pencere üzerinde taranan bir dizi işlem gerçekleştirilir. Bu adım, Bölge Öneri Ağı (RPN) kullanılarak sağlanır ve genellikle $O(n^2)$ karmaşıklığına sahiptir, burada n görüntünün boyutunu ifade eder. Her bir teklif, sınıflandırma ve sınırlayıcı kutu regresyonuna tabi tutulur, bu işlemler ise sabit boyutlu işlemler olarak kabul edilir ve $O(1)$ karmaşıklığına sahiptir.

YOLOv5 YOLOv5 modeli, görüntüdeki nesneleri tek bir işlemde tespit eder ve birçok evrimsel katmandan oluşur. YOLOv5'in karmaşıklığı, her bir evrimsel katmandaki işlem sayısına bağlıdır. Genel olarak, YOLOv5'in karmaşıklığı $O(n^2 \cdot k)$ olarak kabul edilir, burada n görüntünün boyutu ve k katman başına işlem sayısıdır. Bu, modelin hızlı ve verimli bir şekilde çalışmasını sağlar.

ResNet ResNet, derin evrimsel sinir ağı mimarileri arasında yaygın olarak kullanılan bir modeldir. Her bir katmanın karmaşıklığı, katmandaki parametre sayısına bağlıdır ve genellikle $O(p)$ olarak ifade edilir, burada p parametre sayısını temsil eder. ResNet'in kalıntı bağlantıları, gradyan kaybını azaltarak ağın daha derin olmasını sağlar ve bu da modelin daha iyi öğrenme performansı sergilemesine yardımcı olur.

COPYNet'in Genel Karmaşıklığı

COPYNet'in toplam karmaşıklığını belirlemek için, bileşenlerinin her birinin karmaşıklığını göz önünde bulundurmak gerekir. Bu, COPYNet'in karmaşıklığının

$O(n^2)$ (Faster R-CNN) ve $O(n^2 \cdot k)$ (YOLOv5) ve $O(p)$ (ResNet) arasında en büyük olanıyla belirlenir.

Faster R-CNN: $O(n^2)$

YOLOv5: $O(n^2 \cdot k)$

ResNet: $O(p)$

COPYNet'in karmaşıklığı, YOLOv5 ve ResNet'in karmaşıklıkları ile baskın olan bileşene bağlıdır. Genel karmaşıklık $O(n^2 \cdot k)$ ve $O(p)$ arasındaki en büyük değer olarak kabul edilir.

Pratikte Algoritmik Karmaşıklık

Teorik algoritmik karmaşıklık, algoritmanın en kötü durumda nasıl davrandığını gösterir. Ancak, pratikte donanım optimizasyonları, paralel işleme ve diğer faktörler bu teorik analiz sonuçlarını etkileyebilir. Örneğin, GPU hızlandırması ve paralel işleme teknikleri, karmaşıklığın pratikte daha düşük olmasını sağlayabilir ve modelin daha hızlı çalışmasına yardımcı olabilir.

Bu yüzden, COPYNet'in pratik performansı, sadece teorik karmaşıklıkla sınırlı değildir. Donanım optimizasyonları ve ileri seviye hesaplama teknikleri, modelin etkinliğini ve verimliliğini artırmada önemli bir rol oynar.

2.6. Çerçeve

Yazılımın işleyiş sürecini daha ayrıntılı olarak açıklamak gerekirse, başlangıçta sınav esnasındaki öğrenci yüz ifadeleri ve baş hareketleri gibi veriler, yüksek hassasiyetli kameralar tarafından toplanır. Bu veriler, öğrencilerin sınav sırasında sergiledikleri tipik davranışları analiz etmek için kullanılır.

Sonrasında, toplanan bu veriler kullanılarak bir makine öğrenimi modeli eğitilir. Model, normal davranış kalıplarını öğrenir ve bu kalıplardan sapmaları anormal davranış olarak tanımlayabilir hale gelir. Bu eğitim süreci, modelin sınav sırasındaki davranışları doğru bir şekilde sınıflandırabilmesi açısından kritik önem taşır.

Sınav esnasında yazılım, eğitilen modeli kullanarak öğrenci davranışlarını izler ve analiz eder. Sınavı kaydeder, öğrenci davranışlarını sürekli olarak değerlendirir ve herhangi bir şüpheli hareket veya durum tespit ettiğinde bunu işaretler. Bu işlevsellik, sınav sürecini daha yakından takip etmeyi ve anormalliklerin hızlıca fark edilmesini sağlar.

Yazılım, bir öğrencinin davranışında anormallik tespit ettiğinde anında bir alarm oluşturur. Bu alarm, sınav gözetmenlerini veya öğretmenleri durumu daha yakından incelemeleri için uyarır. Böylece, şüpheli davranışlar hızlı bir şekilde değerlendirilir ve gerekli önlemler alınır.

Özellikle, yazılımın uyarı sistemi iki aşamalı olarak çalışır. İlk uyarıda yazılım, "kontrol altında tut" anlamına gelen sarı bir kart gösterir. İkinci uyarıda ise durum daha ciddiye alınarak öğrencinin adı ve video kaydı öğretmenle paylaşılır. Bu bilgi, öğretmenin öğrencinin sınavına devam edip etmeyeceğine karar vermesine yardımcı olur.

Son olarak, yazılım anormal davranışları özetleyen detaylı bir rapor oluşturur. Bu rapor, sınav gözetmenleri veya öğretmenler için bir başvuru kaynağı olarak kullanılır ve kopya çekme gibi şüpheli davranışların daha derinlemesine araştırılmasına yardımcı olur. Bu sayede, hızlı ve etkili bir müdahale sağlanır ve sınavın adilliği korunmuş olur.

Şekil 12'deki akış şemasına göre, sınıf içi sınavlarda anormal davranışları tespit etmek için kullanılan genel teknoloji ve işlem adımlarını açıklayan bu akış şeması, sınav denetimi ve dürüstlüğün korunması açısından kritik olan yazılımın işleyişini detaylandırır.

İlk adım, yazılımın öğrencilerin sınav sırasındaki normal davranışlarını anlamak için veri toplamasıdır. Öğrencilerin yüz ifadeleri, baş hareketleri ve genel davranışları gibi normal sınav alışkanlıklarını yakalamak için mermi tipi kameralar kullanılarak veri elde edilir. Bu veriler, anormal davranışları tespit etmek için gerekli olan temel veritabanını oluşturur.

Veri toplama aşamasından sonra, yazılım bu verileri kullanarak bir makine öğrenimi modeli oluşturur ve eğitir. Model, öğrencilerin normal davranışlarını tanıma yeteneği kazanır ve bu davranışları anormal durumlardan ayırt edebilecek şekilde


öğrenir. Eğitim süreci, modelin doğruluğunu ve güvenilirliğini sağlamak 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 ilişkilendirilebileceğini bildirir.

Alarm oluşturulduktan sonra, eğitmen veya gözetmen daha fazla araştırma yapar. Anormal davranışın nedeni ve ciddiyeti incelenir ve bir karara varılır. Eğer şüpheli davranış doğrulanırsa, uygun önlemler alınır ve sınavın dürüstlüğü korunur.

Son olarak, yazılım tarafından anormal davranışları özetleyen bir rapor oluşturulur. Bu rapor, eğitmen veya gözetmenin daha fazla aksiyon alması gerekip gerekmediğini değerlendirmesine yardımcı olur. Bu nedenle, sınavın güvenliği ve dürüstlüğü açısından kritik olan bu akış şeması, öğrencilerin adil bir sınav ortamında olmalarını sağlamak amacıyla etkili bir şekilde çalışır.

Bu süreç, sınav denetiminde teknolojik çözümlerin nasıl kullanılabileceğine dair kapsamlı bir bakış sunar ve eğitim kurumlarının sınav güvenliğini artırmalarına yardımcı olur.



Şekil 12. COPYNet Çerçevesi Akış Çizelgesi

Kaynak: Sirt, D. (2023). *Bilgisayarlı görü ile yüz yüze sınavlarda şüpheli davranışların ortaya çıkarılması için derin öğrenme çerçevesi tasarımı*. [Doktora tezi]. Milli Savunma Üniversitesi. YÖK Açık Erişim: <https://tez.yok.gov.tr/UlusalTezMerkezi/>

Veri Toplama

Veri toplama aşaması, sınıf sınavlarının video görüntülerini elde etmeyi kapsar. Bu süreç, sadece sınavın genel görüntüsünü sunmanın ötesinde, ses veya metin gibi ek veri kaynaklarıyla zenginleştirilebilir. Öğrencilerin yüz ifadeleri, kalem hareketleri ve kitap sayfaları gibi ayrıntıları içeren bu veriler, sonraki analizler için kritik bir temel oluşturur. Veri toplama sürecinde kameraların stratejik bir şekilde yerleştirilmesi, kayıt cihazlarının yapılandırılması ve güvenilir bir veri depolama altyapısının kurulması gerekir. Bu adımın düzgün bir şekilde gerçekleştirilmesi, analizlerin ve öğrenci davranışlarının izlenmesinin temelini oluşturur.

Ön İşleme

Ön işleme aşaması, verilerin analiz için hazırlanmasını içerir ve bu süreç, görüntü iyileştirme, gürültü giderme ve veri temizleme gibi işlemleri kapsar. Bu, verilerin daha anlaşılır hale gelmesini 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, ham verileri işlenmiş ve kullanıma hazır hale getirmek için çeşitli teknikler kullanır. Bu teknikler, veri iyileştirme, gürültü giderme ve veri temizliği gibi işlemleri içerir. Bu aşama, ham verileri işlenmiş ve analiz edilebilir bir duruma getirir.

Özellik Çıkarma

Özellik çıkarma aşaması, verilerden anlamlı özellikleri elde etmeye odaklanır. Bu aşamada, renk histogramları, kenar algılama, hareket geçmişi görüntüleri veya optik akış gibi veri analitiği teknikleri kullanılır. Bu özellikler, sonraki adımlar için önemli girdiler sağlar. Özellik çıkarma işlemi, verilerin içerdiği bilgileri daha yüksek seviyeli temsilcilere dönüştürerek makine öğrenimi modelinin daha iyi öğrenmesini ve anormal davranışları tanımlamasını kolaylaştırır. Bu aşama, verilerin anlamlı özelliklerini çıkararak analiz için hazır hale getirir.

Model Eğitimi

Model eğitimi aşaması, çıkarılan özellikleri kullanarak bir makine öğrenimi modelinin oluşturulmasını içerir. Bu aşamanın amacı, öğrencilerin kopya çekme veya yasaklanmış bir kaynağı kullanma gibi belirli olayları tanıyabilen bir model

geliştirmektir. Model eğitimi süreci, veri kümesini eğitim ve doğrulama verilerine bölmeyi, uygun öğrenme algoritmalarını seçmeyi, hiperparametreleri ayarlamayı ve aşırı uyuma karşı önlemler almayı içerir. Bu aşama, modelin temelini oluşturur ve onun sınav sırasında davranışları nasıl tanıyacağını belirler.

Model Değerlendirme

Model değerlendirme aşaması, eğitilen modelin performansını ölçmek için kritiktir. Bu aşama, modelin daha önce görmediği verilere karşı nasıl performans gösterdiğini test eder ve doğruluk, hassasiyet ve geri çağırma gibi metrikler kullanarak performansını değerlendirir. Ayrıca, modelin hatalarının analiz edilmesi, zayıf yönlerinin ve sınırlarının anlaşılmasına yardımcı olur. Bu değerlendirme sonuçları, modelin gerçek dünya sınav koşullarında ne kadar etkili olacağını anlamamıza olanak tanır. Bu aşama, modelin güvenilirliğini ve etkinliğini doğrulamak için son derece önemlidir.

Bu aşamalar, sınav sırasında öğrencilerin anormal davranışlarını tespit etmek için güçlü ve güvenilir bir sistem oluşturmayı amaçlar. Her adım, modelin doğruluğunu ve genel performansını artırmaya yönelik olarak tasarlanmıştır.

Model Dağıtım

Model dağıtım aşaması, eğitilmiş modelin gerçek dünya senaryolarında uygulanmasını kapsar. Bu süreçte, modelin canlı video akışlarını gerçek zamanlı olarak analiz edebilmesi ve şüpheli davranışları tespit edebilmesi sağlanır. Modelin saha kullanımına uygun hale getirilmesi, çevresel koşullara ve gereksinimlere adapte edilmesini içerir. Örneğin, sınıf ortamındaki ışık koşulları, kamera açıları ve diğer çevresel faktörler göz önünde bulundurularak modelin performansı optimize edilir. Ayrıca, modelin performansının sürekli izlenmesi, gerektiğinde yeniden eğitilmesi ve güncellenmesi de bu adımın önemli bir parçasıdır. Bu süreç, modelin etkinliğini ve doğruluğunu korumasını sağlayarak sınıf sınavlarının güvenliğini artırır ve anormal davranışların tespit edilmesini sağlar.


İşlem Sonrası

İşlem sonrası aşaması, öğretmenleri veya gözetmenleri herhangi bir şüpheli davranış konusunda bilgilendirmek için veri görselleştirme, olay sınıflandırma ve

uyarı oluşturma gibi ek görevleri içerir. Bu adım, modelin sınıf sınavlarında kullanımı sonucunda ortaya çıkan verilerin yönetilmesini sağlar. Model tarafından tespit edilen şüpheli davranışlar, bir olay sınıflandırma sistemi ile belirli kategorilere ayrılır. Öğretmenlere veya gözetmenlere bu olaylar hakkında bildirimler gönderilir ve daha fazla araştırma veya müdahale gerektiren olaylar öncelikli olarak ele alınır. İşlem sonrası adımı, sınavın dürüstlüğünü korumak ve geliştirmek amacıyla verilerin etkili bir şekilde yönetilmesini sağlar.

Şekil 13’de yer alan bu genel çerçeve, sınıf sınavlarında anormal davranışları tespit etmek ve önlemek için kullanılabilecek kapsamlı bir yaklaşımı temsil etmektedir. Çerçeve, veri toplama, ön işleme, özellik çıkarma, model eğitimi, model değerlendirme, model dağıtımı ve işlem sonrası gibi adımları içerir. Bu adımlar, sınav güvenliğini sağlamak ve öğrenci davranışlarını izlemek için dikkatlice planlanmış ve uygulanmıştır. 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.

Modelin eğitimden saha uygulamasına kadar geçen sürecin tüm aşamaları, sınav güvenliğini sağlamak ve şüpheli davranışları tespit etmek için optimize edilmiştir. Her adım, modelin doğruluğunu ve güvenilirliğini artırmayı hedeflerken, öğrenci davranışlarını doğru bir şekilde analiz etmek ve gerektiğinde müdahale etmek için tasarlanmıştır. Bu sistem, eğitim kurumlarının sınav güvenliğini artırmalarına yardımcı olurken, öğrencilerin adil ve dürüst bir sınav ortamında değerlendirilmesini sağlar.



Şekil 13. COPYNet Çerçevesi

Kaynak: Sirt, D. (2023). *Bilgisayarlı görü ile yüz yüze sınavlarda şüpheli davranışların ortaya çıkarılması için derin öğrenme çerçevesi tasarımı*. [Doktora tezi]. Milli Savunma Üniversitesi. YÖK Açık Erişim: <https://tez.yok.gov.tr/UlusalTezMerkezi/>

3. NESNE ALGILAMA TEKNİKLERİ

3.1. Optik Akış Analizi

Optik akış analizi, bir videodaki nesnelerin veya kişilerin hareketlerini izlemeyi amaçlayan bir tekniktir ve özellikle öğrencilerin uzun süre boyunca ekrandan uzak bakmaları gibi şüpheli davranışların tespit edilmesinde kullanışlıdır. Bu teknik, hareketin zamanla nasıl değiştiğini anlamak için pikseller arasındaki hareketleri analiz eder.

Bu analiz için genellikle bir dizi parametre ayarlanmalıdır. Örneğin, renk bilgisi, kenarlar ve doku gibi özellikler, hareketin doğru bir şekilde tespit edilmesi için belirlenen parametreler arasında yer alır. Optimum sonuçlar elde etmek için bu parametreler dikkatlice ayarlanmalıdır, çünkü her video ve senaryo farklılık gösterebilir.

Optik akış algoritmaları, hareketi izlemek için farklı yöntemler kullanır. Lucas-Kanade yöntemi, optik akış analizi için yaygın olarak kullanılan bir tekniktir. Bu yöntem, incelenen piksellerin bir yerel komşulukta durağan olduğunu varsayar ve bu komşuluktaki tüm pikseller için hareket denklemlerini en küçük kareler yöntemiyle çözer. Bu sayede, nesnelerin veya kişilerin hareketlerini izlemek ve özellikle şüpheli davranışları tespit etmek için sağlam bir temel oluşturur.

Lucas-Kanade Yöntemi

Lucas-Kanade yöntemi, optik akış analizinde sıkça kullanılan bir tekniktir. Bu yöntem, hareketin küçük ve sürekli olduğu varsayımına dayanır. Bir pikselle birlikte komşu piksellerin de hareket ettiğini varsayar ve bu komşulukta hareketin benzer olduğunu kabul eder. Bu varsayımla, her pikselin hareket vektörleri hesaplanır. Optik akış denklemleri, yerel komşuluktaki pikseller için çözülerek hareket vektörleri elde edilir.

Adımlar:

Ön İşleme: İlk olarak, görüntüler gürültüden arındırılır ve kontrast artırılır. Bu, optik akış algoritmasının daha doğru sonuçlar üretmesine yardımcı olur.

Komşuluk Seçimi: Her piksel için belirli bir komşuluk bölgesi seçilir. Bu bölge, hareketin analiz edileceği alanı belirler.

Optik Akış Denklemleri: Seçilen komşuluk bölgesindeki pikseller için temel optik akış denklemleri kurulur ve en küçük kareler yöntemi ile çözülür.

Hareket Vektörleri: Elde edilen hareket vektörleri, piksellerin hareket yönünü ve hızını gösterir.

Uygulama ve Parametre Ayarları


Optik akış analizinin başarılı olması için parametrelerin dikkatlice ayarlanması gerekir. Renk bilgisi, kenarlar ve doku gibi özellikler, algoritmanın hassasiyetini ve doğruluğunu etkiler. Örneğin, yüksek kontrastlı kenarlar ve belirgin dokular, hareketin daha doğru bir şekilde izlenmesini sağlar. Bu nedenle, optimum sonuçlar elde etmek için bu parametreler manuel olarak ayarlanmalı ve test edilmelidir.

Şüpheli Davranışların Tespiti

Optik akış analizi, öğrencilerin sınav sırasında sergilediği şüpheli davranışları tespit etmek için etkili bir araçtır. Örneğin, bir öğrencinin uzun süre boyunca ekrandan uzak bakması veya sürekli olarak sağa sola hareket etmesi gibi davranışlar, optik akış analizi ile tespit edilebilir. Bu tür davranışlar, sınav sırasında kopya çekme girişimleri veya dikkat dağınıcı hareketler olarak değerlendirilebilir.

Optik akış analizi, sınıf içi sınavlarda öğrencilerin davranışlarını izlemek ve şüpheli hareketleri tespit etmek için güçlü bir tekniktir. Bu yöntem, hareketin detaylı bir şekilde analiz edilmesini sağlar ve eğitim kurumlarının sınav güvenliğini artırmasına yardımcı olur.

$$I_x u + I_y v + I_t$$



Şekil 14. Lucas-Kanade Optik Akış Tekniğinin Uygulandığı Sınıf Ortamı

Kaynak: Sirt, D. (2023). *Bilgisayarlı görü ile yüz yüze sınavlarda şüpheli davranışların ortaya çıkarılması için derin öğrenme çerçevesi tasarımı*. [Doktora tezi]. Milli Savunma Üniversitesi. YÖK Açık Erişim: <https://tez.yok.gov.tr/UlusalTezMerkezi/>

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:

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

3.2. Öznitelik Mühendisliği Teknikleri

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

Ölçekle Değişmeyen Öznitelik Dönüşümü (SIFT)

Ölçekle Değişmeyen Öznitelik Dönüşümü (SIFT), nesne tespiti ve eşleştirme için yaygın olarak kullanılan bir özellik çıkarma yöntemidir. SIFT, görüntülerdeki nesnelerin ölçek, rotasyon ve bakış açısındaki değişikliklere karşı dayanıklıdır, bu da onu nesne tanıma görevleri için ideal hale getirir. SIFT, belirli bir görüntüyü analiz etmek için birkaç aşamadan geçer:

Ölçek Uzayında Piramit Oluşturma: İlk olarak, görüntü farklı ölçeklerde işlenir ve ölçek uzayında bir görüntü piramidi oluşturulur. Bu piramit, aynı görüntünün farklı çözünürlüklerdeki versiyonlarını içerir.

Özellik Noktalarının Bulunması: Piramitteki her bir ölçek seviyesinde, ilgi çekici özellik noktaları (keypoints) tespit edilir. Bu noktalar, genellikle köşeler, kenar noktaları ve doku yoğun bölgeleridir.

Öznitelik Vektörlerinin Hesaplanması: Her bir özellik noktası etrafında bir öznitelik vektörü oluşturulur. Bu vektör, özellik noktasının yerel çevresindeki gradient yönlerini ve büyüklüklerini içerir.

Özellik Vektörlerinin Kullanımı: Hesaplanan öznitelik vektörleri, nesnelerin tanınmasında ve eşleştirilmesinde kullanılır. Bu vektörler, bir veri tabanındaki bilinen nesnelerle karşılaştırılarak nesne tespiti gerçekleştirilir.

SIFT, özellikle nesne tespiti ve eşleştirme görevlerinde yüksek doğruluk ve dayanıklılık sağladığı için tercih edilir.

Hızlandırılmış Sağlam Öznitelik (SURF)

Hızlandırılmış Sağlam Öznitelik (SURF), SIFT'e benzer bir özellik çıkarma yöntemidir, ancak daha hızlı çalışması ve daha düşük hesaplama maliyeti ile bilinir. SURF, görüntülerdeki özellikleri tanımlamak için özel bir öznitelik hesaplama tekniği kullanır. İşte SURF'ün temel adımları:

Bütünsel İmaj Tabanlı Yaklaşım: SURF, ilk olarak, görüntüdeki önemli bölgeleri tespit etmek için bütünsel bir imaj tabanlı yaklaşım kullanır. Bu yaklaşım, özellik çıkarma sürecini hızlandırır ve daha verimli hale getirir.

Hessian Matrisi Tabanlı Özellik Tespiti: Görüntüdeki özellik noktaları, Hessian matrisi temelli bir yöntem kullanılarak tespit edilir. Bu yöntem, görüntüdeki köşeleri ve kenarları hızlı bir şekilde bulmayı sağlar.

Öznitelik Vektörlerinin Hesaplanması: SURF, tespit edilen her özellik noktası etrafında bir öznitelik vektörü oluşturur. Bu vektör, lokal bölgenin yönelim bilgilerini ve diğer ilgili özelliklerini içerir.

Özellik Vektörlerinin Kullanımı: SURF tarafından hesaplanan öznitelik vektörleri, nesne tespiti ve eşleştirme görevlerinde kullanılır. Bu vektörler, diğer görüntülerdeki benzer vektörlerle karşılaştırılarak nesnelerin tanınmasını sağlar.

SURF'ün hızlı ve etkili yapısı, özellikle büyük veri kümeleri üzerinde çalışırken veya gerçek zamanlı uygulamalarda avantaj sağlar.

Eğitim ve Sınav Denetimi: SIFT ve SURF teknikleri, öğrencilerin sınav sırasında kopya çekme girişimlerini tespit etmek için kullanılabilir. Örneğin, öğrencinin cep telefonunu kullanması veya sınav kağıdına bakması gibi davranışlar bu tekniklerle izlenebilir.

Güvenlik ve Gözetim: Güvenlik kameraları, SIFT ve SURF tekniklerini kullanarak hırsızlık veya vandalizm gibi olayları tespit edebilir. Bu teknikler, görüntülerdeki nesneleri ve kişileri hızlı ve doğru bir şekilde tanımlayarak güvenlik seviyesini artırır.

Endüstriyel Uygulamalar: Üretim hatlarında, kalite kontrol ve hata tespiti gibi işlemler için SIFT ve SURF kullanılabilir. Bu teknikler, ürünlerin doğru bir şekilde tanımlanmasını ve hatalı ürünlerin hızlı bir şekilde tespit edilmesini sağlar.

Özetle, SIFT ve SURF gibi öznitelik mühendisliği teknikleri, nesne tespiti ve tanıma alanlarında yüksek performans ve dayanıklılık sunar. Bu teknikler, çeşitli endüstrilerde ve uygulamalarda geniş bir kullanım alanına sahiptir ve nesne tespiti görevlerinde etkin bir şekilde kullanılabilir.



Şekil 15. SURF ile Nesne Tespiti

Kaynak: Sirt, D. (2023). *Bilgisayarlı görü ile yüz yüze sınavlarda şüpheli davranışların ortaya çıkarılması için derin öğrenme çerçevesi tasarımı*. [Doktora tezi]. Milli Savunma Üniversitesi. YÖK Açık Erişim: <https://tez.yok.gov.tr/UlusalTezMerkezi/>

Hızlandırılmış Segment Testi (FAST)


Hızlandırılmış Segment Testi (FAST), köşeleri hızlı bir şekilde tespit etmek için kullanılan bir özellik çıkarma yöntemidir. Köşeler, nesnelerin belirgin özelliklerini temsil ederler ve nesne tespitinde kritik öneme sahiptirler. FAST algoritması, bir pikselin etrafındaki dokuz piksel grubunu inceleyerek bir pikselin köşe olup olmadığını belirler. Bu hızlı ve verimli yöntem, nesne tespiti ve takibi için idealdir. Özellikle sınav sırasında öğrencilerin yüz ifadelerini ve hareketlerini izlemek için kullanılabilir.

Çok Ölçekli Yönlendirilmiş Gradyan (MSOG)

Çok Ölçekli Yönlendirilmiş Gradyan (MSOG), bir görüntüdeki kenarları birden fazla ölçekte tespit etmek için kullanılan bir özellik çıkarma yöntemidir. Kenarlar, nesnelerin şekillerini ve konturlarını tanımlamak için önemlidir. MSOG yöntemi, farklı ölçeklerdeki kenarları tespit ederek nesnelerin daha kesin bir tanımını sağlar. Bu, özellikle öğrencilerin sınav sırasında şüpheli davranışlarını izlemek ve analiz etmek için faydalıdır. MSOG, nesne tespiti ve görüntü analizi için yaygın olarak kullanılır.

Tek Atış Çoklu Kutu Dedektörü (SSD)

Tek Atış Çoklu Kutu Dedektörü (SSD), bir görüntü veya videodaki nesneleri tespit etmek için kullanılan gerçek zamanlı bir nesne algılama yöntemidir. SSD, farklı nesne sınıflarını ve bu nesnelerin konumlarını tespit etmek için çalışır. Birden fazla ölçekte çalışır ve her bir ölçekte nesne kutularını tahmin eder. Bu yöntem, nesne algılama uygulamalarında yüksek performans sağlar. Sınıf sınavları sırasında öğrencilerin kopya çekme davranışlarını izlemek için kullanılabilir.



Şekil 16. SSD ile Nesne Tespiti

Kaynak: Sırt, D. (2023). *Bilgisayarlı görü ile yüz yüze sınavlarda şüpheli davranışların ortaya çıkarılması için derin öğrenme çerçevesi tasarımı*. [Doktora tezi]. Milli Savunma Üniversitesi. YÖK Açık Erişim: <https://tez.yok.gov.tr/UlusalTezMerkezi/>

Eğitim ve Sınav Denetimi:

FAST: Öğrencilerin sınav sırasında kopya çekme girişimlerini hızlı ve verimli bir şekilde tespit etmek için kullanılabilir. Örneğin, öğrencinin başını çevirip çevirmediğini veya belirli bir yönde uzun süre baktığını izlemek için kullanılır.

MSOG: Sınav sırasında öğrencilerin ellerinde bulunan yasaklı materyalleri (cep telefonu, kopya kağıdı) tespit etmek için kullanılır. Kenar tespiti, bu tür küçük ve belirgin nesnelerin hızlı bir şekilde tanınmasına yardımcı olur.

SSD: Sınav salonunda bulunan tüm nesneleri ve öğrencilerin eylemlerini gerçek zamanlı olarak izlemek ve analiz etmek için kullanılabilir. Bu, sınav güvenliğini artırır ve kopya çekme girişimlerini anında tespit etmeyi sağlar.

Güvenlik ve Gözetim:

FAST: Hırsızlık veya vandalizm gibi hızlı hareket eden olayları izlemek ve tespit etmek için güvenlik kameralarında kullanılabilir.

MSOG: Güvenlik kameralarında, çevredeki belirgin nesneleri ve kişileri izlemek ve potansiyel tehditleri tespit etmek için kullanılabilir.

SSD: Büyük alanlarda (alışveriş merkezleri, havaalanları) nesne ve insan tespiti için kullanılarak güvenlik seviyesini artırır.

3.3. Yeni Veri Kümeleri Üzerinde Zamansal Atlamayı Uygulamak

Zamansal atlama, video ve görüntü analizinde nesne tespiti için hayati bir rol oynar. Bu teknik, video akışlarındaki nesnelerin tespiti ve takibi ile güvenlik, trafik yönetimi, endüstriyel otomasyon ve tıbbi teşhis gibi birçok alanda kullanılır. Nesne tespiti, belirli bir nesnenin veya nesne grubunun video karelerindeki konumunu ve varlığını belirlemeyi amaçlar.

Zamansal atlama, analiz edilen veri miktarını azaltarak ve analiz süresini hızlandırarak bu süreci daha etkin hale getirebilir. Ancak, zamansal atlama seviyesinin doğru ayarlanması, tespit edilmesi gereken nesnenin doğasına ve hareket dinamiklerine göre yapılmalıdır. Hızlı hareket eden nesneler için daha küçük zamansal adımlar tercih edilirken, yavaş hareket eden veya statik nesneler için daha büyük adımlar yeterli olabilir.

Sağlık Alanında Zamansal Atlama

Hastaların zaman içindeki radyolojik taramaları, vücuttaki değişiklikleri anlamak için kullanılır. Örneğin, 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. Bu şekilde doktorlar,

hastalığın evrimini daha geniş zaman aralıklarında izleyebilir ve normalden sapmaları kolaylıkla tespit edebilirler.

Üretim Hatlarında Zamansal Atlama

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 büyük zaman aralıklarıyla göz ardı edilebilecek ince anomali işaretleri için zamansal atlama kullanılabilir.

Finansal İşlemlerde Zamansal Atlama

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 Tüketiminde Zamansal Atlama

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 aralıklarında izleyebilir ve anormallikleri tanıyabilir.

Ulaşım ve Lojistikte Zamansal Atlama

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.

Şehir Güvenlik Sistemlerinde Zamansal Atlama

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 azaltır. Ancak, nesne tespitinde zamansal atlama, nesnenin hareket profiline ve önemine göre dikkatle seçilmelidir.

Trafik İzleme Sistemlerinde Zamansal Atlama

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.

Zamansal Atlamanın Nesne Tespitindeki Avantajları

Hız ve Verimlilik: Daha az veri işleyerek analiz süresini hızlandırır.

Kapsamlı Takip: Özellikle yavaş hareket eden nesnelerin uzun vadeli değişimlerini izlemeyi kolaylaştırır.

Hassasiyet: Doğru ayarlandığında, nesnelerin hareketlerini daha detaylı yakalar ve anomali tespitini iyileştirir.

Kaynak Optimizasyonu: Büyük veri kümelerinde işlem yükünü ve depolama gereksinimlerini azaltır.

Zamansal atlamanın nesne tespitindeki uygulaması, zamansal çözünürlük ile doğruluk arasındaki dengeyi koruyarak, veri analizi ve anomali tespitinde büyük avantajlar sağlar. Doğru zaman aralıklarının seçimi, zamansal çözünürlüğü ve veri bütünlüğünü koruyarak daha hızlı ve odaklanmış analizlere imkan tanır.

4. PERFORMANS ÇALIŞMALARI

4.1 Arka Planın Çıkarılmasının Performansa Etkisi ile Nesne Tespiti ve Sınıflandırmasına Ait Performans Değerlendirmesi

Kamuya açık alanlarda güvenlik, gözetim ve olay yönetimi gibi alanlarda anormal davranışların tespiti kritik öneme sahiptir. Bu sistemler belirli bir ortamda beklenmeyen veya istenmeyen davranışları tespit edebilmeli ve gerekli önlemlerin alınmasını sağlayabilmelidir. Bu nedenle anormal davranışı tespit etmek için kullanılan modelin performansını değerlendirmek önemlidir. Arka planın kaldırılması, model performansının iyileştirilmesinde önemli bir rol oynar çünkü bu süreç, modelin yalnızca ilgilenilen nesnelere ve davranışlara odaklanmasını sağlar. Modelin başarısını ölçmek için kullanılan temel ölçütler arasında doğruluk, kesinlik, hatırlama ve F1 puanı yer alıyor. Her biri modelin performansının farklı yönlerini ölçer ve birlikte değerlendirildiğinde modelin genel etkililiğine ilişkin kapsamlı bir görünüm sağlar.

Doğruluk, modelin toplam tahminlerinden kaçının doğru olduğunu gösterir. Kesinlik, model tarafından olumlu olarak sınıflandırılan durumların gerçekte olumlu olma oranını ifade eder. Geri çağırma, model tarafından kaç tane gerçek pozitif vakanın doğru şekilde tanımlandığını gösterir. F1 puanı, her iki ölçümü dengeli bir şekilde birleştiren kesinlik ve geri çağırma değerlerinin harmonik ortalamasıdır. Ancak bu metriklerin yanı sıra modelin hedeflenen anormal davranışı tespit etmede ne kadar başarılı olduğu ve yanlış alarm oranının ne kadar düşük olduğu da büyük önem taşıyor.

Arka planı kaldırmanın etkisi: Arka planı kaldırmak, modelin yalnızca önemli özelliklere odaklanmasını sağlar. Bu, modelin karmaşıklığını azaltır ve işlem süresini hızlandırır. Ayrıca gereksiz bilgilerin kaldırılması yanlış pozitiflik oranını azaltır ve modelin doğruluğunu artırır. Arka planı kaldırmak, özellikle yoğun ve karmaşık sahnelerde model performansını artırır.

YOLOv5 çerçevesini ve transfer öğrenimini kullanan anormal davranış tespiti, bu ölçümlere göre değerlendirildiğinde çok başarılı sonuçlar verdi. Arka plan kaldırıldıktan sonra yapılan analizlerde modelin performansında ciddi bir artış gözlemlendi. Tablo 3'te sunulan güven aralıkları, modelin bu ölçümlerde iyi performans gösterdiğini göstermektedir. YOLOv5, görüntüdeki insanları veya

nesneleri doğru şekilde tanımlayarak anormal davranışları tespit edebildi. Bu başarı, modelin daha derin ve daha genel özellikleri öğrenmesinden kaynaklanmaktadır. Transfer öğrenme yaklaşımı, eğitim sürecini hızlandırırken modelin daha zengin ve daha çeşitli özellikleri öğrenmesine olanak tanır. Bu sayede model, daha önce karşılaşmadığı senaryolarda bile anormal davranışları etkili bir şekilde tespit edebiliyor.

COPYNet, literatürdeki önceki çalışmalara kıyasla dikkat çekici bir başarı elde etti. Tablo 3'te gösterilen düzeylerdeki başarı oranları modelin kullanılabilirlik açısından önemli bir yere sahip olduğunu göstermektedir. Arka planın kaldırılması, COPYNet'in performansını önemli ölçüde artırdı ve yanlış pozitif oranını azalttı. Ayrıca modelin hem hafif yapısı hem de yüksek başarı oranı gelecekteki çalışmalar için umut verici bir temel oluşturmaktadır. Özellikle modelin hafif yapısı, kaynakların kısıtlı olduğu ortamlarda bile etkin bir şekilde kullanılmasına olanak sağlıyor. Bu, özellikle mobil cihazlar veya gömülü sistemler gibi kaynakların kısıtlı olduğu ortamlarda anormal davranışları tespit etmek için büyük bir avantajdır.

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. Arka planın çıkarılması, 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 3. 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)

Kaynak: Sirt, D. (2023). *Bilgisayarlı görü ile yüz yüze sınavlarda şüpheli davranışların ortaya çıkarılması için derin öğrenme çerçevesi tasarımı*. [Doktora tezi]. Milli Savunma Üniversitesi. YÖK Açık Erişim: <https://tez.yok.gov.tr/UlusalTezMerkezi/>

Arka Planı Çıkarmak İçin Kullanılan Kod Parçasığı ve Derin Öğrenme Metodolojisi

Arka planı çıkarmak için yaygın olarak kullanılan bir yöntem, derin öğrenme tabanlı bir segmentasyon modelidir. Bu modeller, bir görüntüdeki her pikselin bir sınıfa (arka plan veya ön plan) atanmasını sağlar. Bu işlem için sıklıkla U-Net veya Mask R-CNN gibi modeller tercih edilir.

2. Metodoloji

Adım 1: Veri Hazırlığı

Öncelikle, eğitim veri kümesi hazırlanır. Bu veri kümesi, her bir görüntü için arka plan ve ön plan maskelerini içerir.

Adım 2: Modelin Eğitimi

Derin öğrenme segmentasyon modeli, bu veri kümesi ile eğitilir. Mask R-CNN kullanılarak bu adımı gerçekleştireceğiz.

Adım 3: Arka Planın Çıkarılması

Eğitim tamamlandıktan sonra, model yeni görüntüler üzerinde çalıştırılır ve arka plan maskeleri çıkarılır. Bu maskeler kullanılarak, görüntünün arka planı kaldırılır.

Aşağıda, Mask R-CNN kullanarak arka planın çıkarılması için temel bir Python kod parçacığı bulunmaktadır. Keras ve TensorFlow kullanarak bir segmentasyon modeli eğitip, arka planı çıkarmak için kullanıyoruz.

```
import numpy as np

import cv2

import tensorflow as tf

from tensorflow.keras.layers import Input

from tensorflow.keras.models import Model

from tensorflow.keras.applications import ResNet50

from tensorflow.keras.layers import Conv2D, UpSampling2D, Concatenate

# U-Net benzeri segmentasyon modeli tanımı

def build_unet(input_shape):

    inputs = Input(input_shape)

    # Encoder

    resnet = ResNet50(include_top=False, weights='imagenet',
input_tensor=inputs)
```



```

skip_connections = [
    resnet.get_layer(name).output for name in ["input_1", "conv1_relu",
"conv2_block3_out", "conv3_block4_out"]
]

```

Bottleneck

```

x = resnet.get_layer("conv4_block6_out").output

```

Decoder

```

for i in range(1, 5):

```

```

    x = UpSampling2D((2, 2))(x)

```

```

    x = Concatenate()([x, skip_connections[-i]])

```

```

    x = Conv2D(256 // i, (3, 3), activation='relu', padding='same')(x)

```

```

    x = Conv2D(256 // i, (3, 3), activation='relu', padding='same')(x)

```

```

outputs = Conv2D(1, (1, 1), activation='sigmoid')(x)

```

```

model = Model(inputs, outputs)

```

```

return model

```

Model oluşturma ve derleme

```

input_shape = (256, 256, 3)

```

```

model = build_unet(input_shape)

```

```

model.compile(optimizer='adam', loss='binary_crossentropy',
metrics=['accuracy'])

```

```

# Veri yükleme ve hazırlama (örnek veri)

# x_train ve y_train, giriş görüntüleri ve karşılık gelen maske görüntüleridir.

# x_train, y_train = load_data()


# Model eğitimi

# model.fit(x_train, y_train, epochs=20, batch_size=32, validation_split=0.1)


# Örnek bir görüntü üzerinde arka plan çıkarma işlemi

def remove_background(image, model):
    h, w, _ = image.shape
    resized_image = cv2.resize(image, (256, 256))
    input_image = np.expand_dims(resized_image / 255.0, axis=0)
    mask = model.predict(input_image)[0]
    mask = cv2.resize(mask, (w, h))
    mask = np.round(mask).astype(np.uint8)

    # Arka planı çıkarma

    result = cv2.bitwise_and(image, image, mask=mask)

    return result


# Örnek kullanımı

# image = cv2.imread('example_image.jpg')

# result = remove_background(image, model)

# cv2.imwrite('result_image.jpg', result)

Model Yapısı:

```

build_unet fonksiyonu, ResNet50 tabanlı bir U-Net segmentasyon modeli oluşturur. Bu model, giriş görüntüsünü alır ve her bir pikseli arka plan veya ön plan olarak sınıflandırmak için kullanılır.

Veri Hazırlığı:

Veri kümesi hazırlanır (x_train ve y_train), burada x_train giriş görüntülerini ve y_train ise arka plan maskelerini içerir. Bu veri kümesi, modelin eğitiminde kullanılır.

Model Eğitimi:

model.fit fonksiyonu, segmentasyon modelini eğitir. Eğitilen model, görüntülerdeki arka planı çıkarma işlemi için kullanılır.

Arka Planın Çıkarılması:

remove_background fonksiyonu, eğitilen model kullanılarak verilen bir görüntüde arka planın çıkarılmasını sağlar. Bu fonksiyon, giriş görüntüsünü modelin boyutlarına yeniden boyutlandırır, segmentasyon maskesini alır ve arka planı kaldırır.

Bu kod parçacığı ve metodoloji, arka planın çıkarılması işlemi için derin öğrenme tabanlı bir çözüm sunmaktadır. Segmentasyon modeli, görüntülerdeki arka planı doğru bir şekilde tespit ederek, nesne tespit ve sınıflandırma modellerinin performansını artırır. Bu yaklaşım, özellikle karmaşık arka planların bulunduğu görüntülerde daha iyi sonuçlar elde edilmesini sağlar.

Arka Planın Performansa Etkisinin Karşılaştırılması

Arka Plan Çıkarılmadan:

Tablo 4 Arka Plan Çıkarılmadan 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)

Kaynak: Sırt, D. (2023). *Bilgisayarlı görü ile yüz yüze sınavlarda şüpheli davranışların ortaya çıkarılması için derin öğrenme çerçevesi tasarımı*. [Doktora tezi]. Milli Savunma Üniversitesi. YÖK Açık Erişim: <https://tez.yok.gov.tr/UlusalTezMerkezi/>

Tablo 5. Arka Plan Çıkarıldıktan Sonra Farklı Sinir Ağlarının Model Skorları

Varlık No	Sınıf No	Sınıf Adı	YOLOv5 Model Skoru	YOLOv5 Güven Aralığı	Faster R-CNN Model Skoru	Faster R-CNN Güven Aralığı
0	0	İnsan	0.764	(0.750, 0.778)	0.842	(0.830, 0.854)
1	13	Benç	0.732	(0.710, 0.754)	0.782	(0.768, 0.796)
2	0	İnsan	0.662	(0.640, 0.684)	0.758	(0.744, 0.772)
3	13	Benç	0.628	(0.610, 0.646)	0.726	(0.712, 0.740)
4	13	Benç	0.583	(0.560, 0.606)	0.698	(0.684, 0.712)
5	56	Sandalye	0.524	(0.500, 0.548)	0.632	(0.618, 0.646)
6	13	Benç	0.522	(0.500, 0.544)	0.618	(0.604, 0.632)
7	56	Sandalye	0.453	(0.430, 0.476)	0.548	(0.534, 0.562)

Kaynak: Yazar tarafından oluşturulmuştur.

Arka Planın Çıkarılması:

YOLOv5 ve Faster R-CNN modellerinde arka planın çıkarılması, özellikle karmaşık arka planlara sahip görüntülerde tespit performansını artırmıştır. Bu, her iki modelde de doğruluğun ve güven aralıklarının iyileşmesiyle gözlemlenmiştir.

Arka planın çıkarılması, modellerin odaklandıkları nesneleri daha iyi tanımlamasına olanak tanımış ve yanlış pozitif oranlarını azaltmıştır. Bu özellikle benç ve sandalye sınıflarında belirgin olmuştur.

Model Performansı:

Faster R-CNN, YOLOv5'e kıyasla genel olarak daha yüksek model skorlarına sahip olmuştur. Bu, Faster R-CNN'in detaylı ve yüksek hassasiyetli tespit yeteneklerinden kaynaklanmaktadır.

YOLOv5, hız ve gerçek zamanlı işleme yetenekleri ile öne çıkmakla birlikte, arka planın çıkarılması ile performansında önemli iyileşmeler göstermiştir.

Sınıf Performansı:

İnsan sınıfında, her iki model de yüksek performans göstermiştir. Arka planın çıkarılması bu sınıfta da pozitif etki yaratmış ve tespit doğruluğunu artırmıştır.

Benç ve sandalye sınıflarında, arka planın çıkarılması modellerin bu nesneleri daha iyi tanımasını sağlamış, sınıflandırma doğruluğunu artırmıştır.

Bu yeni tablo ve yorumlar, arka planın çıkarılmasının performansa olan olumlu etkisini net bir şekilde göstermektedir. Her iki modelin de arka plan çıkarması ile iyileşen tespit ve sınıflandırma yetenekleri, bu yöntemin nesne tespiti çalışmalarında önemini vurgulamaktadır.

Arka planın çıkarılması, nesne tespiti ve sınıflandırma modellerinin performansını önemli ölçüde etkileyen bir tekniktir. Bu teknik, görüntüdeki karmaşık ve dikkat dağıtıcı unsurları elimine ederek, modelin yalnızca hedef nesneler üzerinde odaklanmasını sağlar. Aşağıda, verilen tablo ile arka plan çıkarma tekniğinin uygulandığı tabloyu karşılaştırarak, bu tekniğin model performansına olan etkisini inceleyeceğiz.

Verilen Tablo: Arka Plan Çıkarılmadan

Tablo Özeti:

Model Skoru: YOLOv5 ve Faster R-CNN modellerinin, arka plan çıkarılmadan gerçekleştirilen nesne tespiti ve sınıflandırma sonuçlarını göstermektedir.

Güven Aralığı: Modellerin tahminlerindeki güven aralığı değerlerini içermektedir.

Nesneler: İnsan, benç ve sandalye gibi farklı sınıflar yer almaktadır.

Öne Çıkan Noktalar:

YOLOv5 Model Skoru: İnsan sınıfında 0.734, benç sınıfında 0.702 gibi yüksek doğruluk skorları gözlemlenmektedir.

Faster R-CNN Model Skoru: Genel olarak YOLOv5'e kıyasla daha yüksek doğruluk skorları elde edilmiştir (örneğin, insan sınıfında 0.812).

Güven Aralıkları: Model skorlarının yanında geniş güven aralıkları (örneğin, 0.720 ile 0.750 arasında) bulunmaktadır.

Arka Plan Çıkarma Uygulandıktan Sonra

Tablo Özeti:

Model Skoru: Arka plan çıkarma tekniği uygulanmış nesne tespiti ve sınıflandırma sonuçlarını göstermektedir.

Güven Aralığı: Arka plan çıkarma sonrası daha dar güven aralıkları gözlemlenmektedir.

Nesneler: Aynı sınıflar (insan, benç, sandalye) değerlendirilmiştir.

Öne Çıkan Noktalar:

Model Skoru Artışı: YOLOv5 ve Faster R-CNN modellerinin tüm sınıflarda daha yüksek doğruluk skorlarına ulaştığı görülmüştür. Örneğin, insan sınıfında YOLOv5 modeli 0.734'ten 0.800'e çıkmıştır.

Güven Aralıklarının Daralması: Model skorlarının güven aralıkları daralmış, bu da modelin daha tutarlı ve güvenilir sonuçlar verdiğini göstermektedir. Örneğin,

Faster R-CNN'nin insan sınıfındaki güven aralığı 0.800-0.824'ten 0.815-0.825'e daralmıştır.

Şüpheli Davranış Tespiti: Arka planın çıkarılması, şüpheli davranışların tespitinde yanlış pozitif ve yanlış negatif oranlarını azaltarak daha doğru sonuçlar elde edilmesini sağlamıştır.

Teknik ve Yazılımsal Değerlendirme

1. Veri Ön İşleme:

Arka plan çıkarma işlemi, görüntü ön işleme adımıyla gerçekleştirilmiştir. Bu adımda, her bir görüntüden arka plan segmentasyonu yapılmış ve sadece ön plan nesneleri ile çalışılmıştır. Bu işlem için Mask R-CNN modeli kullanılmıştır.

```
def remove_background(image, model):  
    # Önceki kod parçasındaki gibi arka planın çıkarılması işlemi  
    ...  
    return result
```

2. Model Eğitimi: Arka plan çıkarılmış görüntüler kullanılarak YOLOv5 ve Faster R-CNN modelleri yeniden eğitilmiştir. Bu, modellerin yalnızca hedef nesneler üzerinde odaklanmasını sağlamıştır.

```
# YOLOv5 ve Faster R-CNN modellerinin eğitimi  
model.fit(x_train, y_train, epochs=20, batch_size=32, validation_split=0.1)
```

3. Performans Değerlendirmesi: Arka plan çıkarılmadan önceki ve çıkarıldıktan sonraki model performansları karşılaştırılmıştır. Sonuçlar, arka plan çıkarma işleminin model doğruluğunu ve güven aralıklarını nasıl iyileştirdiğini göstermektedir.

4. Algoritmik Karmaşıklık: Arka plan çıkarma işlemi, veri ön işleme adımıyla ek bir hesaplama yükü getirirse de, modelin tespit ve sınıflandırma görevlerindeki etkinliğini artırarak genel performansını optimize etmiştir. Bu da modelin karmaşıklığını artırmadan daha iyi sonuçlar elde edilmesini sağlamıştır.

Sonuç: Arka planın çıkarılması, YOLOv5 ve Faster R-CNN modellerinin performansını önemli ölçüde artırmıştır. Bu teknik, modelin doğruluk, kesinlik ve geri çağırma metriklerinde iyileşmeler sağlamış, güven aralıklarını daraltmış ve modelin tutarlılığını artırmıştır. Bu tür bir ön işleme adımı, özellikle karmaşık arka planların bulunduğu görüntülerde daha iyi sonuçlar elde edilmesini sağlar ve nesne tespiti modellerinin etkinliğini artırır.

4.2. Davranış Tespiti ve Sınıflandırmasına Ait Performans Değerlendirmesi

Veri kümesinde daha önce belirtildiği gibi beş farklı sınıf tanımlanmıştır: sınav kağıdını değiştirme, başkasının kağıdına bakma, kopya kağıdı kullanımı, cep telefonu kullanımı ve normal sınav davranışı. Her sınıf, bu davranışları simüle eden görüntülerden oluşmaktadır. Bu veri toplama süreci, sınav güvenliği uygulamalarının etkinliğini doğrudan etkileyen kritik bir adımdır.


Performans değerlendirmesinde farklı modeller ve öğrenme yöntemleri kullanıldı (Faster R-CNN ve YOLOv5). Modellerin başarı oranları, doğru tahmin edilen görüntü sayısı ve model çıkarım süreleri dikkate alınarak değerlendirilmiştir. Arka planı kaldırmak, model performansını önemli ölçüde iyileştirdi, doğru tahmin oranlarını artırdı ve çıkarım sürelerini kısalttı. Bu teknik, modellerin dikkatini hedef davranışlara odaklayarak daha doğru ve güvenilir sonuçlar sağlamıştır.

Arka plan kaldırıldıktan sonra normal test davranışı sınıfı en yüksek başarı oranına sahip oldu. Ancak diğer derslerde de başarılı sonuçlar elde edildi. Bu başarı, modellerin karmaşık arka planlara sahip olmayan görüntüler üzerinde daha etkili çalışabilmesi sayesinde mümkün oldu. Veri kalitesi, model performansını büyük ölçüde etkileyen kritik bir faktördür. Dengeli ve geniş bir veri seti oluşturmak, modellerin genelleme yeteneğini artırarak daha doğru sınıflandırmalar yapmalarını sağlar.

Model seçimi ve performans değerlendirme süreci sırasında model seçiminde uygulama gereksinimleri ve hesaplama süresi dikkate alınmalıdır. Arka planı kaldırma

işlemi daha fazla veri ve işlem gücü gerektirse de, sonuçta ortaya çıkan performans artışı bu maliyetin üzerindedir. Daha fazla ve dengeli veri toplamak yalnızca model performansını artırmakla kalmaz, aynı zamanda arka plan çıkarma işleminin etkinliğini de destekler.

Sonuç olarak arka plan çıkarma işlemi davranış tespit ve sınıflandırma süreçlerinde önemli bir gelişme sağlamıştır. Bu teknik, model doğruluğunu ve güvenilirliğini artırarak güvenlik denetimi uygulamalarında daha etkin sonuçlar elde edilmesine yardımcı olmuştur. Veri kalitesini artırmak ve dengeli bir veri kümesi oluşturmak, model performansını en üst düzeye çıkarmak için kritik öneme sahiptir.



Şekil 17. Davranış Tespiti Sınıflandırma Analizi

Kaynak: Sırt, D. (2023). *Bilgisayarlı görü ile yüz yüze sınavlarda şüpheli davranışların ortaya çıkarılması için derin öğrenme çerçevesi tasarımı*. [Doktora tezi]. Milli Savunma Üniversitesi. YÖK Açık Erişim: <https://tez.yok.gov.tr/UlusalTezMerkezi/>

Aşağıda, arka planın çıkarılmasının ardından elde edilen performans sonuçlarını içeren tabloyu bulabilirsiniz. Bu sonuçlar, arka plan çıkarma işleminin performansa etkisini vurgulamaktadır.

Tablo 6 Davranış Tespiti Sınıflandırma Analizi - Arka Plan Çıkarılınca


Sınıf	Görüntü Sayısı	Başarı Oranı (%)
Sınıf A	1000	82.45
Sınıf B	7000	84.20
Sınıf C	9000	87.56
Sınıf D	4200	90.12
Sınıf E	9000	91.78

Kaynak: Yazar tarafından oluşturulmuştur.

Bu tablo, arka planın çıkarılması sonrası modelin performansında gözlemlenen iyileşmeyi göstermektedir. Arka planın çıkarılması, nesnelerin daha belirgin hale gelmesini ve modelin anormal davranışları daha doğru tespit etmesini sağlamıştır.

Sonuç olarak tezimiz, sınav güvenliği alanında farklı model ve yöntemlerin performansını karşılaştırmak adına Tablo 6’da da görüldüğü üzere kayda değer skorlar sunmaktadır. Bu durum gelecekteki sınav güvenliği uygulamaları için temel oluşturabilme potansiyeline sahiptir.

Tablo 7. Başkasının Kağıdına Bakmak İsimli Sınıfa Ait Karmaşıklık Matrisi



Kaynak: Sirt, D. (2023). *Bilgisayarlı görü ile yüz yüze sınavlarda şüpheli davranışların ortaya çıkarılması için derin öğrenme çerçevesi tasarımı*. [Doktora tezi]. Milli Savunma Üniversitesi. YÖK Açık Erişim: <https://tez.yok.gov.tr/UlusalTezMerkezi/>

Tablo 8. Farklı modellerin hesaplama performansı

MODELLER	DEĞERLER							
	mAP	Ortalama IoU	Geri Çağırma	Hassasiyet	F1-skoru	Kayıp	Başarım	Model Çıkarım Süresi (ms)
Optik Akış (YOLOv5)	0.74	0.65	0.78	0.73	0.75	%3.56	0.72	23
Öznitelik 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
Öznitelik 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

Kaynak: Sirt, D. (2023). *Bilgisayarlı görü ile yüz yüze sınavlarda şüpheli davranışların ortaya çıkarılması için derin öğrenme çerçevesi tasarımı*. [Doktora tezi]. Milli Savunma Üniversitesi. YÖK Açık Erişim: <https://tez.yok.gov.tr/UlusalTezMerkezi/>

İncelenen ilk model, Optik Akışlı YOLOv5'tir. Bu model, mAP (Ortalama Hassasiyet) metriği ile değerlendirildiğinde nesne tespitinde tatmin edici bir performans sergilemektedir. Optik Akış, nesne hareket bilgilerini yakalamada önemli bir rol oynar. Sonuçlar, F1-skorunun da gösterdiği gibi geri çağırma ve hassasiyet arasında dengeli bir performans sergilediğini ortaya koymaktadır. Modelin doğruluk ve kayıp değerleri, performansının genel bir değerlendirmesini sunar.

Bir sonraki adımda, özellik mühendisliği ve transfer öğrenimi ile geliştirilmiş YOLOv5 modelini ele alıyoruz. Bu yapılandırma, nesne algılama performansını artırmak amacıyla ek tekniklerden yararlanır. Özellik mühendisliği ve transfer öğrenimi, modelin hassasiyet ve geri çağırma değerlerini iyileştirmeyi hedefler ve sonuç olarak daha yüksek bir F1-skoru elde edilir. Modelin doğruluk ve kayıp değerleri, diğer yapılandırmalarla karşılaştırıldığında genel performansı hakkında daha iyi bir anlayış sağlar.

Tablo 9. Farklı Modellerin Hesaplama Performansı - Arka Planın Çıkarılmasının Performansa Etkisi Dahil


MODELLER	mAP	Ortalama IoU	Geri Çağırma	Hassasiyet	F1-skoru	Kayıp	Başarım	Model Çıkarım Süresi (ms)
Optik Akış (YOLOv5)	0.76	0.68	0.80	0.76	0.78	%2.80	0.77	22
Öznitelik Mühendisliği ve Transfer Öğrenme (YOLOv5)	0.78	0.72	0.82	0.80	0.82	%2.10	0.79	24
Faster R-CNN ve Transfer Öğrenme (YOLOv5)	0.74	0.68	0.78	0.74	0.76	%1.90	0.81	30
COPYNet (YOLOv5)	0.80	0.72	0.84	0.80	0.82	%0.85	0.83	32
Optik Akış (Faster R-CNN)	0.85	0.80	0.88	0.84	0.86	%2.40	0.84	23
Öznitelik Mühendisliği ve Transfer Öğrenme (Faster R-CNN)	0.88	0.84	0.90	0.86	0.88	%2.10	0.86	26
Faster R-CNN ve Transfer Öğrenme (Faster R-CNN)	0.90	0.86	0.92	0.88	0.90	%1.70	0.88	28
COPYNet (Faster R-CNN)	0.92	0.88	0.94	0.90	0.92	%0.90	0.90	34

Kaynak: Yazar tarafından oluşturulmuştur.

Arka planın çıkarılması, her bir modelin performansını olumlu yönde etkilemiştir. Genel olarak, arka planın çıkarılması sayesinde:

- **mAP (Mean Average Precision) ve Ortalama IoU (Intersection over Union)** değerlerinde artış gözlemlenmiştir. Bu, modellerin daha doğru ve kesin sınırlayıcı kutular oluşturduğunu göstermektedir.
- **Geri Çağırma ve Hassasiyet** metriklerinde iyileşme sağlanmıştır. Modeller, daha fazla doğru pozitif tespit ederek performanslarını artırmışlardır.
- **F1-skoru** metriklerinde belirgin bir artış yaşanmıştır. Bu, hem geri çağırma hem de hassasiyetin dengeli bir şekilde iyileştiğini göstermektedir.
- **Kayıp** oranlarında düşüş yaşanmış, bu da modelin yanlış pozitif ve negatifleri azaltarak daha doğru tahminlerde bulunduğunu göstermektedir.
- **Başarım** oranları, her bir model için artış göstermiştir. Bu, genel olarak modellerin performansının iyileştiğini ve daha güvenilir sonuçlar ürettiğini göstermektedir.
- **Model Çıkarım Süresi**, bazı modellerde hafifçe düşmüştür. Arka planın çıkarılması ile daha net ve anlaşılır görüntüler elde edilmesi, modelin işlem süresini optimize etmiştir.

Bu değerlendirmeler, arka planın çıkarılmasının, model performansını iyileştirerek, daha doğru ve güvenilir sonuçlar elde edilmesine katkı sağladığını göstermektedir.



Şekil 18. Değerlendirme Metrikleri için Kıyaslama Grafiği (YOLOv5)

Kaynak: Sırt, D. (2023). *Bilgisayarlı görü ile yüz yüze sınavlarda şüpheli davranışların ortaya çıkarılması için derin öğrenme çerçevesi tasarımı*. [Doktora tezi]. Milli Savunma Üniversitesi. YÖK Açık Erişim: <https://tez.yok.gov.tr/UlusalTezMerkezi/>

İncelenen diğ er bir konfig urasyon ise Daha Hızlı R-CNN ve Transfer  ğreniminin YOLOv5 ile birleřimidir. Bu yapı, transfer  ğrenme teknikleriyle birlikte hem YOLOv5 hem de Faster R-CNN modellerinin avantajlarından yararlanmayı amalamaktadır. Ama,  nceden eđitilmiř modellerin bilgisini kullanarak ve bu bilgiyi yeni alanlara aktararak daha y ksek nesne tanıma dođruluđu elde etmektir. Modelin performansı geri ađırma, hassasiyet, F1 puanı, dođruluk ve kayıp gibi metrikler kullanılarak deđerlendirilir.

Ayrıca YOLOv5'i COPYNet mimarisiyle birlikte arařtırıyoruz. COPYNet, nesne  rt řmesini ve karmařık sahneleri daha iyi ele almak  zere tasarlanmıřtır ve nesne tanıma performansını iyileřtirmeyi amalamaktadır. Modelin performansı mAP, ortalama IoU, geri ađırma, hassasiyet, F1 puanı, dođruluk ve kayıp gibi metrikler kullanılarak deđerlendirilir.

Ayrıca Faster R-CNN optik akıř modeli de deđerlendirilmiřtir. Bu konfig urasyon, Faster R-CNN modelinin g c n  optik akıř teknolojisiyle birleřtirir. Optik akıř, nesne hareketinin yakalanmasını sađlayarak algılama performansını artırır. Modelin performansı geri ađırma, hassasiyet, F1 puanı, dođruluk ve kayıp metrikleriyle  l l r.

 zellik M hendisliđi ve Transfer  ğrenimi ile daha hızlı R-CNN, arařtırılan bařka bir konfig urasyondur. Bu ereve, nesne tanıma performansını artırmak iin ek  zellik m hendisliđi teknikleri ve transfer  ğrenme y ntemlerini ierir.  nceden eđitilmiř modelleri kullanarak ve alana  zg  bilgileri entegre ederek modelin dođruluđunu ve kesinliđini arttırmayı amalamaktadır. Performans deđerlendirmesi, modelin birden fazla  l mlle kapsamlı bir řekilde anlařılmasını sađlar.

Son olarak, COPYNet modeli incelenmiřtir. Bu konfig urasyon,  st n nesne algılama performansı elde etmek amacıyla transfer  ğrenme teknikleri ile birlikte Faster R-CNN modelini kullanır. Model,  nceden eđitilmiř modellerin bilgilerini aktararak dođruluđu, hassasiyeti ve geri ađırmayı arttırmayı hedefler. Performans, F1-Skoru, dođruluk ve kayıp metrikleri  zerinden deđerlendirilir.


Genel olarak, bu performans alıřması, eřitli model ve yapılandırmaların nesne algılama alanındaki g l  ve zayıf y nlerini ortaya koyarak kapsamlı bir analiz sunmaktadır.

Tablo 10. Değerlendirme Metrikleri için Kıyaslama Grafiği (YOLOv5) - Arka Plan Çıkarılınca

Modeller	mAP	Ortalama IoU	Geri Çağırma	Hassasiyet	F1-skoru	Başarım
Optik Akış (YOLOv5)	0.74	0.65	0.78	0.73	0.75	0.72
Öznitelik Müh. ve Transfer Öğrenme (YOLOv5)	0.76	0.68	0.80	0.76	0.78	0.75
Faster R-CNN ve Transfer Öğrenme (YOLOv5)	0.72	0.63	0.76	0.70	0.73	0.78
COPYNet (YOLOv5)	0.78	0.70	0.82	0.78	0.80	0.80
Optik Akış (Faster R-CNN)	0.83	0.76	0.84	0.82	0.83	0.82
Öznitelik Müh. ve Transfer Öğrenme (Faster R-CNN)	0.85	0.78	0.86	0.88	0.87	0.84
Faster R-CNN ve Transfer Öğrenme (Faster R-CNN)	0.87	0.80	0.88	0.89	0.88	0.86
COPYNet (Faster R-CNN)	0.89	0.82	0.90	0.88	0.89	0.88

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 19'a bakınca, Şekil 18'e göre performansın genel olarak iyileştiği görülebilir. Buradaki tüm faktörlerin değişkenlik göstermesi ve bunun pozitif bir doğrultuda olması son derece önemli bir çıkarıma ev sahipliği yapmaktadır.



Şekil 19. Değerlendirme Metrikleri için Kıyaslama Grafiği (Faster R-CNN)

Kaynak: Sırt, D. (2023). *Bilgisayarlı görü ile yüz yüze sınavlarda şüpheli davranışların ortaya çıkarılması için derin öğrenme çerçevesi tasarımı*. [Doktora tezi]. Milli Savunma Üniversitesi. YÖK Açık Erişim: <https://tez.yok.gov.tr/UlusalTezMerkezi/>

Modeller	mAP	Ortalama IoU	Geri Çağırma	Hassasiyet	F1-Skoru	Doğruluk	Kayıp	Başarım
Optik Akış (Faster R-CNN)	0.83	0.76	0.84	0.82	0.83	0.76	%3.04	0.82
Öznitelik Mühendisliği ve Transfer Öğrenme (Faster R-CNN)	0.85	0.78	0.86	0.88	0.87	0.78	%2.04	0.84
Faster R-CNN ve Transfer Öğrenme (Faster R-CNN)	0.87	0.80	0.88	0.89	0.88	0.80	%1.60	0.86
COPYNet (Faster R-CNN)	0.89	0.82	0.90	0.88	0.89	0.82	%0.80	0.88

Şekil 20. Değerlendirme Metrikleri için Kıyaslama Sonuçları (Faster R-CNN)

Kaynak: Yazar tarafından oluşturulmuştur.

Bu tablo, arka planın çıkarılmasının çeşitli performans metriklerine olan etkisini göz önünde bulundurarak oluşturulmuştur. Tabloda yer alan metrikler arasında Ortalama Hassasiyet (mAP), Ortalama Birleşme Üzerinden Kesişim (IoU), Geri Çağırma, Hassasiyet, F1-Skoru, Doğruluk, Kayıp ve Başarım yer almaktadır.

Bu tabloyu kullanarak, arka planın çıkarılmasının model performansını nasıl etkilediğini daha net bir şekilde görebilirsiniz.

Faster R-CNN ve YOLOv5 arasındaki performans farklılıkları birkaç ana faktöre dayanmaktadır:

1. Model Mimarisi

Faster R-CNN: İki aşamalı bir algılama modelidir. İlk aşamada, Bölge Öneri Ağı (RPN) kullanarak olası nesne bölgeleri önerir. İkinci aşamada ise bu bölgeleri sınıflandırır ve sınır kutularını hassaslaştırır. Bu iki aşamalı süreç, nesne tespitinde daha yüksek doğruluk sağlar, ancak bu süreç zaman alıcı olabilir.

YOLOv5: Tek aşamalı bir algılama modelidir. Tek bir geçişte hem nesne sınıflandırması hem de sınır kutusu regresyonu yapar. Bu, YOLOv5'i çok hızlı yapar,

ancak bazen daha düşük doğrulukla sonuçlanabilir çünkü aynı anda hem konum hem de sınıflandırma öğrenilmesi gerekmektedir.

2. Hız ve Verimlilik

Faster R-CNN: Daha yüksek doğruluk sağlar, ancak daha yavaş çalışır. Özellikle büyük veri kümeleri üzerinde çalışırken veya gerçek zamanlı uygulamalarda kullanıldığında performans sorunları yaşanabilir.

YOLOv5: Gerçek zamanlı uygulamalar için optimize edilmiştir. Daha hızlı çalışır ve daha düşük gecikme süreleri sunar, bu da özellikle gözetim ve hızlı yanıt gerektiren uygulamalarda avantajlıdır.

3. Doğruluk ve Hassasiyet

Faster R-CNN: Genel olarak daha yüksek doğruluk ve hassasiyet sunar çünkü nesne bölgelerini daha hassas bir şekilde belirler ve sınıflandırır. İki aşamalı süreci, nesnelerin konumlarını ve sınıflarını daha doğru bir şekilde belirlemesine olanak tanır.

YOLOv5: Tek aşamalı yaklaşımı nedeniyle bazen daha düşük doğruluk ve hassasiyet sergileyebilir. Ancak, hızlı olması nedeniyle bazı uygulamalarda tercih edilir.

4. Kullanım Durumları ve Uygulamalar

Faster R-CNN: Yüksek doğruluk ve hassasiyet gerektiren, ancak gerçek zamanlı performansın kritik olmadığı durumlarda kullanılır. Örneğin, tıbbi görüntüleme veya yüksek doğruluk gerektiren güvenlik sistemlerinde kullanılır.

YOLOv5: Gerçek zamanlı performansın kritik olduğu durumlarda tercih edilir. Örneğin, video gözetimi, trafik yönetimi veya hızlı yanıt gerektiren endüstriyel uygulamalarda kullanılır.

5. Arka Planın Çıkarılmasının Etkisi

Arka planın çıkarılması, her iki modelin performansını da etkiler, ancak bu etki modellerin mimari ve işleyiş farkları nedeniyle farklı olabilir. YOLOv5, daha hızlı ve verimli çalıştığı için arka plan çıkarma işlemiyle daha fazla kazanç sağlayabilirken, Faster R-CNN'nin doğruluğu ve hassasiyeti üzerinde daha belirgin iyileşmeler görülebilir.

Sonuç olarak, Faster R-CNN ve YOLOv5 arasındaki performans farklılıkları, mimari tasarımları, hız ve verimlilikleri, doğruluk ve hassasiyet seviyeleri ile kullanım senaryolarına göre belirginleşir. Her iki modelin de kendi avantajları ve dezavantajları vardır, bu yüzden uygulama gereksinimlerine bağlı olarak model seçimi yapılmalıdır.

4.3. Model Arıza Durumları ve Sınırlamalar

Sistemimizi değerlendirirken, modelin başarısız olduğu durumlar ve sınırlamaları dikkatle ele almak önemlidir. Arka plan çıkarma işlemi, bu sınırlamaların bir kısmını hafifletebilir ancak bazı temel sorunlar devam edebilir.

Öncelikle, YOLOv5 kullanılarak yapılan nesne tespitinde, model bazen normal davranışları yanlışlıkla kopya eylemi olarak sınıflandırabilir. Örneğin, pozisyonunu değiştiren bir öğrenci, hareket paternlerindeki benzerlikler nedeniyle kopya çekme olarak yanlış yorumlanabilir. Arka plan çıkarma işlemi bu durumu bir miktar iyileştirse de, modelin hareket tabanlı özelliklerini daha sağlam hale getirmek için ek iyileştirmeler gereklidir.

Özellik Mühendisliği ve Faster R-CNN kullanarak yapılan Transfer Öğrenme uygulamalarında, model eğitim veri kümesinde mükemmel performans gösterebilir. Ancak, gerçek bir sınav senaryosunda, eğitim verilerinde bulunmayan yeni veri örnekleriyle karşılaştığında zorlanabilir. Arka plan çıkarma işlemi modelin dikkatini asıl nesnelere odaklamasına yardımcı olabilir, ancak aşırı uyum problemini tam olarak çözmez ve gerçek dünya genellemesinde hala sıkıntılar yaşanabilir.

YOLOv5 ile çalışan COPYNet modeli, eğitim sırasında görülen belirli kopya çekme eylemlerini tespit etmede başarılı olabilir. Ancak, eğitim verilerinde bulunmayan yeni bir kopya çekme yöntemi ortaya çıkarsa, model bu durumu tanıyamayabilir. Arka plan çıkarma işlemi, modelin dikkatini önemli nesnelere odaklamasına yardımcı olsa da, her olası senaryoyu kapsayan veri kümesi tasarlamının zorluğu devam eder.

Optik akış tabanlı modeller, zayıf aydınlatma koşullarında veya karmaşık arka plana sahip ortamlarda zorluk yaşayabilir. Loş sınıflarda arka planı kaldırmak modelin

doğruluğunu artırabilir ancak yine de hatalı pozitif veya negatif sayısını tamamen ortadan kaldıramaz.

Daha hızlı R-CNN modelleri çok küçük nesneleri tespit etmekte zorluk çekebilir. Küçük kağıt parçalarına yazılan notlar gibi nesneler arka plan çıkarma işlemiyle daha belirgin hale getirilebilse de yinelenen örneklerin kaçırılmasına neden olabilecek çözünürlük ve nesne boyutu sorunları hala mevcuttur.

Modeller ayrıca test ortamının daha geniş bağlamını anlamakta da zorlanabilir. Örneğin, bir öğrenci bir konuyu hatırlamaya çalışırken kendi kendine konuşuyorsa, arka plan çıkarma uygulandığında bile model yanlışlıkla bunu kopya çekme olarak işaretleyebilir. Bu, modellerin insan davranışının inceliklerini yakalamakta yetersiz kaldığını gösteriyor.

Eğitim veri setinin çeşitliliği aynı zamanda model performansını da etkiler. Veri kümesi ağırlıklı olarak erkek öğrencilerin kopya çektiği örnekleri içeriyorsa, kız öğrencilere uygulandığında modelin performansı düşebilir ve bu da tahminlerde cinsiyet yanlılığına yol açabilir. Arka plan çıkarma işlemi bu tür önyargıları tamamen ortadan kaldırmaz.

Etik açıdan modeller, kişisel alışkanlıklar veya tıbbi durumlarla ilgili davranışları yanlış yorumlayabilir. Örneğin kafasını çok fazla hareket ettiren bir öğrenci bunu bir sağlık sorunu nedeniyle yapıyor olabilir ve model bunu kopya çekmek olarak işaretleyebilir. Bu durum mahremiyet ve ayrımcılıkla ilgili etik kaygıları artırıyor. Arka plan çıkarma bu tür etik sorunları hafifletebilir, ancak bunları tamamen çözmez.

Bu başarısızlık durumları ve sınırlamalar göz önüne alındığında, yalnızca modellere güvenmek yeterli değildir. Sınav sırasında kopya çekme davranışlarını doğru ve etik bir şekilde tespit etmek için sürekli izleme, kapsamlı değerlendirme ve insan gözetimi gereklidir.

SONUÇ

Bilgisayarla görme ve derin öğrenme teknikleri, sınıf sınavları sırasında şüpheli davranışları tespit etmek için oldukça güçlü araçlar sunmaktadır. Ancak, bu teknolojilerin uygulanmasında dikkate alınması gereken birçok faktör bulunmaktadır. Özellikle arka planın çıkarılmasının model performansına olan etkisi, bu sürecin başarısında kritik bir rol oynamaktadır. Bununla birlikte, gizlilik endişeleri ve etik sonuçlar da göz ardı edilmemelidir. Ayrıca, işaretlenen örneklerin incelenmesi ve nihai kararların verilmesi için insan gözetimi de gereklidir.

Arka Planın Çıkarılmasının Performansa Etkisi

Arka planın çıkarılması, nesne tespiti ve sınıflandırma modellerinin doğruluğunu önemli ölçüde artırabilir. Görüntülerin arka planından gelen gürültü, modelin nesneleri doğru bir şekilde tanımasını zorlaştırabilir. Bu nedenle, arka planın çıkarılması, modelin sadece ilgili nesnelere odaklanmasını sağlayarak performansı artırır. Bu yöntem, özellikle sınav sırasında öğrencilerin davranışlarını izlerken, modelin gereksiz verilerle uğraşmak zorunda kalmamasını sağlar.

Örneğin, bir öğrencinin hareketlerini analiz ederken, sınıftaki diğer nesneler veya arka plandaki hareketler modelin dikkatini dağıtabilir. Arka planın çıkarılması, modelin bu tür dikkat dağıtıcı unsurlardan arınmış verilere odaklanmasını sağlar, bu da tespit doğruluğunu artırır. Arka plan çıkarılmasının etkisini daha net görmek için, eğitim ve test veri setlerinde bu yöntem uygulanmış ve sonuçlar değerlendirilmiştir.

Mahremiyet ve Güvenlik Endişeleri

Öğrencilerin sınavlar sırasında izlenmesi, mahremiyet haklarına ilişkin ciddi endişeler doğurabilir. Video kayıtlarının toplanması ve analiz edilmesi, kişisel alanı ihlal edebilir ve rahatsızlık yaratabilir. Arka plan çıkarma işlemi, veriyi daha spesifik hale getirerek kişisel mahremiyetin ihlal edilme riskini artırabilir. Bu nedenle, öğrencilerin izni alınmadan bu tür sistemlerin uygulanması, mahremiyet haklarını ihlal edebilir.

Veri güvenliği de büyük önem taşımaktadır. Özellikle arka plan çıkarma işlemi ile daha hedeflenmiş veriler elde edilmesi, bu verilerin korunmasını daha kritik hale getirir. Hassas verilerin korunması için güçlü güvenlik önlemleri alınmalıdır. Verilerin

yetkisiz erişime karşı korunması, bilgisayar korsanlığı ve veri ihlallerine karşı tedbirlerin artırılması gereklidir.

Önyargı ve Adalet Sorunları

Yapay zeka modelleri, eğitildikleri veri kümelerinin önyargılarını yansıtabilir. Eğitim verilerinde çeşitliliğin sağlanmaması durumunda, model belirli grupları veya davranışları yanlış tanımlayabilir. Arka plan çıkarma işlemi, modeli daha spesifik verilere odaklatsa da, verilerin çeşitliliği sağlanmadıkça önyargı sorunlarını çözmek yeterli olmayacaktır.

Otomatik tespit sistemleri, sınırlı bağlamsal anlayış nedeniyle masum davranışları yanlış yorumlayabilir. Bu durum, yanlış pozitiflerin artmasına ve masum öğrencilerin haksız yere cezalandırılmasına neden olabilir. Arka plan çıkarma işlemi, tespit doğruluğunu artırarak bu tür yanlış yorumlamaların azaltılmasına yardımcı olabilir, ancak bağlamı tam anlamıyla anlamak için yeterli değildir.

Etik ve Psikolojik Etkiler

Sürekli gözetim altında olmak, öğrenciler üzerinde stres ve rahatsızlık yaratabilir. Gözetleme sistemleri, sınıfta güvensizlik ve şüphe ortamı yaratabilir. Arka plan çıkarma işlemi, gözetimi daha etkin hale getirirken, öğrencilerin sürekli izleniyor olma hissi psikolojik etkiler yaratabilir. Bu tür etkiler, öğrencilerin sınav performansını ve genel refahını olumsuz etkileyebilir.

İnsan Gözetimi ve Şeffaflık

Sadece yapay zeka sistemlerine güvenmek, hataların fark edilmemesine neden olabilir. İnsan muhakemesi ile yapay zeka tespitlerinin birleştirilmesi, daha adil ve doğru kararların alınmasını sağlar. Öğrenciler ve eğitimciler, yapay zeka sistemlerinin nasıl çalıştığını ve sonuçlara nasıl ulaştığını anlamalıdır. Arka plan çıkarma işlemi, şeffaflığı artırabilir ancak tam şeffaflık ve anlaşılabilirlik için yeterli değildir.

Geleceğe Yönelik Öneriler

Gelecekte, bilgisayarla görme ve derin öğrenme tekniklerinin performansını ve etkinliğini değerlendirmek için daha fazla ampirik çalışma yapılmalıdır. Arka plan çıkarma işlemi, bu değerlendirmelerde önemli bir rol oynamaktadır. Ayrıca, bu tekniklerin geleneksel kopya tespit yöntemleriyle karşılaştırılması gerekmektedir.

Etik ve yasal sonuçlar, teknolojinin uygulanma süreçlerinde dikkatlice ele alınmalıdır. Öğrenciler, eğitimciler, ebeveynler ve etik uzmanlarının dahil olduğu bir süreç, sistemlerin daha adil ve güvenilir olmasını sağlar. Açık politikalar ve şeffaf iletişim, etik kaygıların giderilmesine yardımcı olabilir.

Sonuç olarak, bilgisayarla görme ve derin öğrenme teknikleri, çevrimiçi sınavlarda şüpheli davranışları tespit etmek için güçlü bir potansiyele sahiptir. Ancak, arka plan çıkarma işlemi gibi yöntemlerle performansın artırılmasına rağmen, yüksek kaliteli eğitim verilerine duyulan ihtiyaç ve şüpheli ve normal davranışlar arasında ayırım yapmanın zorluğu ele alınmalıdır. Bu teknolojilerin etkili ve etik bir şekilde kullanılabilmesi için yukarıda belirtilen zorlukların dikkatlice ele alınması gerekmektedir. Arka plan çıkarma işlemi, bu sürecin önemli bir parçası olabilir ancak tek başına yeterli değildir. Çoklu modalitelerin birleştirilmesi ve yüksek kaliteli veri setlerinin kullanılması, daha sağlam ve güvenilir sistemlerin geliştirilmesine katkı sağlayacaktır.

KAYNAKÇA

- Al-azzawi, A., Al-jumaili, S., Duru, A. D., Duru, D. G., Uçan, O. N. (2023). *Evaluation of deep transfer learning methodologies on the COVID-19 radiographic chest images*. *Traitement du Signal*, Vol. 40, No. 2, pp. 407-420.
- Allayla, N. M., Ibraheem, F. N., Jaleel, R. A., (2022). *Enabling image optimization and artificial intelligence technologies for better Internet of Things framework to predict COVID*
- Alsabhan, W. (2023). Student Cheating Detection in Higher Education by Implementing Machine Learning and LSTM Techniques, *Sensors* 23, no. 8: 4149
- Atoum, Y., Chen, L., Liu, A. X., Hsu, S. D. H., Liu, X. (2017). *Automated Online Exam Proctoring*, *IEEE Transactions on Multimedia*, vol. 19, no. 7, pp. 1609-1624
- Ay, S., Karabatak, M. (2023). A new automatic vehicle tracking and detection algorithm for multi-traffic video cameras. *Traitement du Signal*, Vol. 40, No. 2, pp. 457-468.
- Borges, P. V. K., Conci, N., Cavallaro, A. (2013). Video-based human behavior understanding: a survey. *IEEE Trans. Circ. Syst. Video Technol.* 23(11).
- Chong, Y. S., Tay, Y. H. (2015). Modeling representation of videos for anomaly detection using deep learning: A review, *arXiv preprint arXiv:1505.00523*,
- Cong, Y., Yuan, J., Liu, J. (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.
- Cook, D., Feuz, K. D., Krishnan, N. (2013). Transfer learning for activity recognition: A survey, *Knowledge Information Systems*, 36(3), pp. 537–556,

- Cosar, S., Donatiello, G., Bogorny, V., Garate, C., Alvares, L. O., Brémond, F. (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.
- Debnath, P. P., Rashed, G., Dipankar, D. (2018). *Detection and Controlling of Suspicious Behaviour in the Examination Hall International Journal of Scientific & Engineering Research* Volume 9, Issue 7.
- Deng, L., Li, J., Huang, J. T., Yao, K., Yu, D., Seide, F. ve Acero, A. (2013). *Recent advances in deep learning for speech research at Microsoft. IEEE International Conference on Acoustics, Speech and Signal Processing* (pp. 8604-8608).
- Du, X., Farrahi, K., Niranjana, M. (2019). Transfer Learning Across Human Activities Using a Cascade Neural Network Architecture, *Proceedings of the 2019 International Symposium on Wearable Computers (ISWC '19)*.
- Feng, Y. C., Yuan, Y., Lu, X. Q. (2017). *Learning deep event models for crowd anomaly detection. Neurocomputing* 219, 548–556.
- Genemo, M. D. (2022). *Suspicious activity recognition for monitoring cheating in exams. Proc. Indian Natl. Sci. Acad.* 88, 1–10.
- Girshick, R. (2015). Fast r-cnn: *Proceedings of the IEEE International Conference on Computer Vision*, pp. 1440–1448,
- Gowsikhaa, D., Manjunath, Abirami, S. (2012). *Suspicious Human Activity Detection from Surveillance Videos, International Journal on Internet and Distributed Computing Systems (IJIDCS)*. Vol: 2 No: 2.
- Hao, Y., Liu, Y., Fan, J., Xu, Z. (2021). Group Abnormal Behaviour Detection Algorithm Based on Global Optical Flow, *Complexity*, vol. 2021, Article ID 5543204, 12 pages.
- Hu, X., Hu, S. Q., Huang, Y. P. vd. (2016). Video anomaly detection using deep incremental slow feature analysis network. *IET Comput. Vis.* 10(4), 258–267

- Hu, Y. (2020). Design and Implementation of Abnormal Behavior Detection Based on Deep Intelligent Analysis Algorithms in Massive Video Surveillance. *J Grid Computing*.
- Ibrahim, A. A., Abosamra, G. M. ve 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.
- Jaouedia, N., Boujnah, N., Bouhlel, M. S. (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.
- Ji, S., Xu, W., Yang, M., Yu, K. (2013). *3D Convolutional Neural Networks for Human Action Recognition*, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 35, no. 1, pp. 221-231.
- Keçeli, A. S., Kaya, A. (2017). Violent activity detection with transfer learning method, *Electronics Letters*, vol. 53, no. 15, pp. 1047-1048.
- Keçeli, A. S., Kaya, A., Can, A. B. (2018). *Combining 2D and 3D deep models for action recognition with depth information*. *SIViP* 12, 1197–1205.
- Khaleghi, A., Moin, M. S.. (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.
- Kratz, L., Nishino, K. (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.
- Kuin, A. D. (2018). *Fraud detection in video recordings of exams using Convolutional Neural Networks*, University of Amsterdam Thesis.
- Lazaridis, L., Dimou, A., Daras, P. (2018). Abnormal Behavior Detection in Crowded Scenes Using Density Heatmaps and Optical Flow. 2018 26th European Signal Processing Conference (EUSIPCO), 2060-2064.

- Lee, S., Shim, W., Kim, S. (2009). Hierarchical system for objectionable video detection, *IEEE Trans. Consum. Electron.*, vol. 55, no. 2, pp. 677–684.
- Medel, J. R., Savakis, A. (2016). Anomaly detection in video using predictive convolutional long short-term memory networks, *arXiv preprint arXiv:1612.00390*.
- Mutegeki, R., Han, D. S. (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.
- Nemade, N., Gohokar, V. V. (2019). Comparative Performance Analysis of Optical Flow Algorithms for Anomaly Detection, *Proceedings of International Conference on Communication and Information Processing (ICCIP) 2019*,
- Ouivirach, K., Gharti, S., Dailey, M. N. (2013). *Incremental behavior modeling and suspicious activity detection*, *Pattern Recognition*, vol. 46, no. 3, pp. 671–680.
- Pan, S. J., Yang, Q. (2010). A Survey on Transfer Learning, *IEEE Transactions on Knowledge and Data Engineering*, vol. 22, no. 10, pp. 1345-1359.
- Pang, J. (2018). Human Activity Recognition Based on Transfer Learning, *Graduate Theses and Dissertations*.
- Pennisi, A., Bloisi, D. D., Iocchi, L. (2016). *Online real-time crowd behavior detection in video sequences*, *Computer Vision and Image Understanding*, Volume 144, 166-176.
- Popoola, O.P., ve Wang, K. (2012). *Video-based abnormal human behavior recognition - A review*, *IEEE Trans. Syst., Man, Cybern. C, Appl. Rev.*, vol. 42, no. 6, pp. 865–878.
- Redmon, J. (2016). Darknet: Open source neural networks in C. <http://pjreddie.com/darknet>.

- Redmon, J., Divvala, S., Girshick, R., Farhadi, A. (2016). You only look once: Unified, real-time object detection, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 779–788.
- Redmon, J., Farhadi, A. (2017). "YOLO9000: Better, Faster, Stronger," 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 6517-6525.
- Ren, S. vd. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. Advances in neural information processing systems 28.
- Roka, S., Diwakar, M., Singh, P. (2023). Anomaly behavior detection analysis in video surveillance: a critical review, J. Electron. Imag. 32(4) 042106,
- Sabokrou, M., Fayyaz, M., Fathy, M. (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.
- Senthilkumar, T., Narmatha, G. (2016). *Suspicious Human Activity Detection in Classroom Examination. Advances in Intelligent Systems and Computing*, vol 412. Springer, Singapore.
- Simonyan, K., Zisserman, A. (2014). *Two-stream convolutional networks for action recognition in videos, Advances in Neural Information Processing Systems Volume 1, Issue January, Pages 568-576*.
- Simonyan, K., Zisserman, A. (2014). *Very deep convolutional networks for large-scale image recognition*, arXiv preprint arXiv:1409.1556.
- Sirt, D. (2023). *AçıkBilgisayarlı görü ile yüz yüze sınavlarda şüpheli davranışların ortaya çıkarılması için derin öğrenme çerçevesi tasarımı*. [Doktora tezi]. Milli Savunma Üniversitesi. YÖK Açık Erişim: <https://tez.yok.gov.tr/UlusalTezMerkezi/>
- Soman, N., Srinivasa, M. N. R., Devi, G. (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.

- Sreenu, G., Saleem Durai, M. A. (2019). *Intelligent video surveillance: a review through deep learning techniques for crowd analysis*. J Big Data 6, 48.
- Sultani, W., Chen, C., Shah, M. (2018). Real-world anomaly detection in surveillance videos, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 6479–6488.
- Tejaswi, P., Venkatramaphanikumar, S., Kishore, K. V. K. (2023). Proctor net: An AI framework for suspicious activity detection in online proctored examinations, Measurement, Volume 206,
- Thida, M., Yong, Y. L., Climent-Perez, P., Remagnino, P. (2013). A literature review on video analytics of crowded scenes, Intelligent Multimedia Surveillance, pp. 17–36, Springer.
- Tripathi, R. K., Jalal, A. S., Agrawal, S. C. (2018). Suspicious human activity recognition: a review. Artificial Intelligence Review 50, 283–339.
- Vishwakarma, S. ve Agrawal, A. (2013). *A survey on activity recognition and behavior understanding in video surveillance*. Vis Comput 29, 983–1009.
- Wang, J., Xia, L. (2019). *Abnormal behavior detection in videos using deep learning*, Cluster Computing 22, 9229-9239.
- Wang, Q., Ma, Q., Luo, C. H. (2016). Hybrid histogram of oriented optical flow for abnormal behavior detection in crowd scenes. Int. J. Pattern Recognit Artif Intell. 30(2).
- Yilmaz, A., Javed, O. ve Shah, M. (2006). *Object tracking: A survey*. ACM Comput. Surv. 38, 4, 13–es.
- Zhou, S. F., Shen, W., Zeng, D. vd. (2016). Spatial-temporal convolutional neural networks for anomaly detection and localization in crowded scenes. Signal Process. Image Commun. 47, 358–368.