

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

KALABALIK ORTAMLARDA ANOMALİ TESPİTİ

ÖMER CEBECİ

YÜKSEK LİSANS TEZİ
ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DANIŞMAN: DR. OGR. ÜYESİ ALİ KÖKSAL HOCAOĞLU

HAZİRAN 2025

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

KALABALIK ORTAMLARDA ANOMALİ TESPİTİ

ÖMER CEBECİ

YÜKSEK LİSANS TEZİ
ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DANIŞMAN: DR. OGR. ÜYESİ ALİ KÖKSAL HOCAOĞLU

HAZİRAN 2025

T.R.
GEBZE TECHNICAL UNIVERSITY
GRADUATE SCHOOL

ANOMALY DETECTION IN CROWDED SCENE



ÖMER CEBECİ

A THESIS OF MASTER OF SCIENCE
DEPARTMENT OF ELECTRONIC ENGINEERING

ADVISOR: ASIST. PROF. ALİ KÖKSAL HOCAOĞLU

JUNE 2025

YÜKSEKLİSANS JÜRİ ONAY FORMU

GTÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulunun 02/06/2025 tarih ve 2025/29 sayılı kararıyla oluşturulan jüri tarafından 26/06/2025 tarihinde tez savunma sınavı yapılan Ömer CEBECİ'nin tez çalışması Elektronik Mühendisliği Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

JÜRİ

ÜYE

(TEZ DANIŞMANI) : Dr. Öğr. Üyesi Köksal HOCAOĞLU

ÜYE

: Prof. Dr. Koray KAYABOL

ÜYE

: Doç. Dr. Aysun Taşyapı ÇELEBİ

ONAY

Gebze Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Yönetim Kurulunun
...../...../..... tarih ve/..... sayılı kararı.

İMZA/MÜHÜR



*Aileme
ve
Öğretmenlerime*

ÖZET

Kamera kullanımı, başta hastaneler ve şehir merkezleri gibi kamusal alanlar olmak üzere artmıştır. Kamera kullanımının başlıca sebepleri istenmeyen durumları tespit etmek ve kayıt altına almaktır. İzlenecek alan büyüdükçe kamera sayısı artmakta bu sebeple kamera görüntülerini analiz edilmesi de güçleşmektedir. Bu hem maliyet hem de hata oranının artması anlamına gelmektedir. Bu sebeplerden ötürü kamera videolarının otomatik bir şekilde analiz edilmesi önem taşımaktadır. Bu çalışmada, literatür araştırması yapılarak yaygın kullanılan anomali tespit yöntemleri araştırılmış ve uygun veri setleri belirlenmiştir. Son yapılan çalışmalarda gözlemlenen karma yöntem: optik akış harita görüntüleri ve otokodlayıcı derin öğrenme modeli kullanılarak kamera görüntülerinde bulunan anomalileri tespit edebilen bir algoritma önerilip performansı incelenmiştir. Yaya yollarında bulunan ve yüksek bir yere monte edilmiş sabit bir kamera ile elde görüntülerden oluşan UCSD ve Minnesota Üniversitesinin kalabalığın paniğe kapılarak kaçtığı durumları temsil etmek için oluşturduğu UMN veri setleri kullanılmıştır. Yaya yollarında yaya dışında farklı varlıkların bulunması, yayaların oluşturduğu anormal hareket örüntüleri (yayaları çimlere basması) ve kalabalığın aniden kaçışmaya başlaması anomali durumları olarak kabul edilmiştir. Test edilecek her görüntü için ayrı eğitim yapılması ve anomali eşik değerinin her test videosu için özel olarak belirlenmesi farklılıkları performansı arttıran unsurlardan olmuştur. Anomalinin kalabalık arasına girdiği ve hareket hızını düşürdüğü durumlarda algoritmanın performansının düştüğü gözlemlenmiştir. Sadece hıza bağlı anomaliler dışında hareket yönü temelli anomaliler de başarılı şekilde tespit edilebilmiştir. Önerilen yöntemin performansını ölçmek için “doğruluk” başarı metriği kullanılmıştır. UCSD Ped-1 veri setinde %81 UCSD Ped-2 veri setinde %82 ve UMN veri setinde %91.18 doğruluk ile başarı elde edilmiştir. Önerilen algoritmanın; gerçek zamanlı çalışabilirliğini daha güvenilir şekilde test etmek adına yüksek örnekleme ile elde edilmiş veri setleri kullanmak, performansını arttırmak için derin öğrenme modelinin performansını arttırmak gelecekte yapılacak çalışmalar arasındadır.

Anahtar Kelimeler: Optik Akış, Otokodlayıcı, Anomali, Yapay Sinir Ağı

ABSTRACT

The use of cameras has increased, particularly in public spaces such as hospitals and city centers. The primary purposes of camera usage are to detect and record undesired incidents. As the monitored area grows, the number of cameras increases, making it more challenging to analyze camera footage. This leads to higher costs and increased error rates. For these reasons, the automatic analysis of camera footage has become important. In this study, a literature review was conducted to examine commonly used anomaly detection methods, and an appropriate dataset was selected.

A hybrid method observed in recent studies—using optical flow map images and an autoencoder deep learning model—was proposed to detect anomalies in camera footage, and its performance was evaluated. The UCSD datasets, consisting of footage captured by a fixed camera mounted at a high point on pedestrian walkways, were utilized. Anomalies were defined as the presence of non-pedestrian entities on the walkways and abnormal movement patterns of pedestrians (e.g., pedestrians walking on grass). All anomalous situations occurred naturally. Training was conducted separately for each test image, and anomaly threshold values were determined specifically for each test video, which were factors that improved performance.

It was observed that the algorithm's performance decreased when anomalies entered crowded areas and reduced movement speed. However, direction-based anomalies, as opposed to those solely dependent on speed, were successfully detected. The performance of the proposed method was evaluated using the "accuracy" metric. The method achieved a success rate of 81% on the UCSD Ped-1 dataset and 82% on the UCSD Ped-2 dataset. To test the real-time operability of the proposed algorithm more reliably, future studies will focus on using datasets obtained with higher sampling rates and improving the performance of the deep learning model to enhance overall performance.

Keywords: Optical Flow, Autoencoder, Anomaly, Artificial Neural Network

TEŐEKKÜR

Tez süreci boyunca manevi desteęini hiçbir zaman esirgemeyen, bana inanan ve yanımda olan sevgili aileme sonsuz teőekkür ederim. Varlıkları, sabırları ve sevgileri bu süreci daha güçlü ve anlamlı kılmıőtır. Bu tez çalışmasının hazırlanmasında bilgi birikimi ile her zaman yol gösteren tez danışmanım Sayın Köksal Hocoaoęlu'na en içten teőekkürlerimi sunarım.

Ayrıca, yalnızca akademik deęil, kişisel gelişimime de katkı sağlayan, bu tezin yazılmasındaki temelleri atan deęerli lise ve ilkokul öğretmenlerime gönülden teőekkür ederim. Bugün attıęım her adımda onların emeęi ve özverisi bulunmaktadır.



İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	vi
ABSTRACT	vii
TEŞEKKÜR	viii
İÇİNDEKİLER	ix
SİMGELER ve KISALTMALAR DİZİNİ	xi
ŞEKİLLER DİZİNİ	xii
ÇİZELGELER DİZİNİ	xiv
1. GİRİŞ	1
1.1. Tezin Amacı, Katkısı ve İçeriği	3
1.2. Tezin Düzeni	4
2. LİTERATÜR	5
2.1. Anomali Tipleri	5
2.2. Anomali Tespit Çalışmalarının Sınıflandırılması	5
2.3. Literatürde Kullanılan Veri setleri	6
2.4. Performans Ölçüm Kriterleri	6
2.5. Önerilen Algoritmalar	7
3. YÖNTEM	14
3.1. Veri Ön İşlemesi	15
3.2. Optik Akış	17
3.3. Derin Öğrenme	19
3.3.1. Yapay Sinir Ağları	19
3.3.2. Otokodlayıcılar	21
3.4. Anomali Tespit Algoritması	23
4. TEST VE ANALİZ	26
4.1. Veri Setleri	26
4.1.1. UCSD Veri Seti	26
4.1.2. UMN Veri Seti	29
4.2. Performans Kriteri	31
4.3. Test Sonuçları	31
4.4. Gözlemlenen Test Senaryoları	49
4.4.1. Hareket Hızı Etkisi Test Senaryosu	49
4.4.2. Nesnenin Varlığı Sebebi ile Olan Anomali Test Senaryosu	53
4.4.3. Hareket Yönü Kaynaklı Anomali Test Senaryosu	56
4.4.4. Görüntünün Tamamında Meydana Gelen Anomali Test Senaryosu	57
4.4.5. Moving Average Filtresinde Pencere Boyutunun Değiştirilmesi	59
4.4.6. Derin Öğrenmeye Verilen Frame Sayısının Değiştirilmesi	62
4.4.7. Düşük FPS ile İnceleme	64
4.4.8. Anomali Bulunmayan Video Sekanslarının İncelenmesi	65
4.4.9. Adaptif Eşik Değerinin Farklı Periyotlar ile Değiştirilmesi	67
5. GENEL SONUÇLAR	71
6. GELECEK ÇALIŞMALAR	74

KAYNAKLAR	75
ÖZGEÇMİŞ	78
TEZ METNİNDEN TÜRETİLEN YAYINLAR	79



SİMGELER ve KISALTMALAR DİZİNİ

Δt	: Birim zaman
∂	: Kısmi Türev operatörü
AVENUE	: Anomalous Event Detection in Urban Scenes
FPS	: Frame Per Second
LR	: Linear Regression
PCA	: Principal Component Analysis
SVM	: Support Vector Machine
UCSD	: University of California San Diego
UMN	: University of Minnesota



ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 2.1: Wang'ın çalışması blok diyagramı.	8
Şekil 2.2: Bansod ve Nandedkar'ın çalışması blok diyagramı.	9
Şekil 2.3: Duman ve Erdem'in çalışması blok diyagramı.	9
Şekil 2.4: Hemant'ın çalışması blok diyagramı.	10
Şekil 2.5: Doshi ve Yılmaz'ın çalışması blok diyagramı.	11
Şekil 2.6: Li ve Chang'ın çalışması blok diyagramı.	12
Şekil 3.1: Genel akış diyagramı.	15
Şekil 3.2: Ham test görüntüsünden arka plan çıkarılmış görüntü.	16
Şekil 3.3: Test görüntüsünün optik akış haritası.	17
Şekil 3.4: Yapay sinir ağı katmanları.	19
Şekil 3.5: Yapay sinir hücresi.	20
Şekil 3.6: Optimum değerler.	21
Şekil 3.7: Derin öğrenme modeli.	22
Şekil 3.8: Havuzlama katmanı uygulaması.	23
Şekil 3.9: Ucsd ped-2 test-1 filtrelenmemiş mse grafiği.	24
Şekil 3.10: Ucsd ped-2 test-1 filtrelenmiş mse grafiği.	25
Şekil 4.1: Ucsd ped-1 test-10.	27
Şekil 4.2: Ucsd ped-1 test-1.	27
Şekil 4.3: Ucsd ped-2 test 4.	28
Şekil 4.4: Ucsd ped-2 test 11.	28
Şekil 4.5: Umn klip 1.	29
Şekil 4.6: Umn klip 3.	30
Şekil 4.7: Umn klip 4.	30
Şekil 4.8: Ucsd ped-2 test-2 verisi grafiği.	33
Şekil 4.9: Ucsd ped-2 test-5 verisi grafiği.	33
Şekil 4.10: Ucsd ped-1 test-31 verisi grafiği.	34
Şekil 4.11: Ucsd ped-1 test-22 verisi grafiği.	34
Şekil 4.12: Ucsd ped-2 test-4 verisi grafiği.	35
Şekil 4.13: Ucsd ped-1 test-8 verisi grafiği.	36
Şekil 4.14: Ucsd ped-2 test-1 verisi grafiği.	36
Şekil 4.15: Ucsd ped-1 test-19 verisi grafiği.	37
Şekil 4.16: Umn klip-1 verisi grafiği.	38
Şekil 4.17: Umn klip-6 verisi grafiği.	39
Şekil 4.18: Umn klip-7 verisi grafiği.	39
Şekil 4.19: Umn klip-4 verisi grafiği.	40
Şekil 4.20: Doğru pozitif roc eğrisi.	48
Şekil 4.21: Yanlış pozitif roc eğrisi.	48
Şekil 4.22: Ucsd ped-1 test-4 87. görüntü.	50
Şekil 4.23: Ucsd ped-1 test-4 114. görüntü.	51
Şekil 4.24: Ucsd ped-1 test-4 verisi grafiği.	51
Şekil 4.25: Ucsd ped-1 test-7 50. görüntü.	52
Şekil 4.26: Ucsd ped-1 test-7 150. görüntü.	52
Şekil 4.27: Ucsd ped-1 test-7 verisi grafiği.	52
Şekil 4.28: Umn veri seti klip-11 hareket hızı etkisi.	53
Şekil 4.29: Ucsd ped-1 test-26 verisi grafiği.	54
Şekil 4.30: Ucsd ped-1 test-19 60. görüntü.	55

Şekil 4.31: Ucsd ped-1 test-19 140. görüntü.	55
Şekil 4.32: Ucsd ped-1 test-19 verisi grafiği.	55
Şekil 4.33: Ucsd ped-1 test-11 120. görüntü.	56
Şekil 4.34: Ucsd ped-1 test-11 68. görüntü.	57
Şekil 4.35: Ucsd ped-1 test-11 verisi grafiği.	57
Şekil 4.36: Umn klip-5 verisi grafiği.	58
Şekil 4.37: Ucsd ped-2 test-1 pencere boyutu 12.	59
Şekil 4.38: Ucsd ped-2 test-1 pencere boyutu 24.	60
Şekil 4.39: Ucsd ped-2 test-1 pencere boyutu 40.	60
Şekil 4.40: Umn klip-1 verisi pencere boyutu 12.	60
Şekil 4.41: Umn klip-1 verisi pencere boyutu 24.	60
Şekil 4.42: Umn klip-1 verisi pencere boyutu 40.	61
Şekil 4.43: Ucsd ped-2 test-4 frame sayısı 10.	63
Şekil 4.44: Ucsd ped-2 test-4 frame sayısı 20.	63
Şekil 4.45: Ucsd ped-2 test-8 frame sayısı 10.	63
Şekil 4.46: Ucsd ped-2 test-8 frame sayısı 20.	64
Şekil 4.47: Ucsd ped-2 eğitim-2.	66
Şekil 4.48: Ucsd ped-2 eğitim-3.	66
Şekil 4.49: Umn veri seti klip-1 eşik değer grafiği.	68
Şekil 4.50: Umn veri seti klip-6 eşik değer grafiği.	68
Şekil 4.51: Ucsd ped-2 test-2 farklı eşik değerleri.	69

ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Çizelge 4.1: Ucsd veri setleri bilgilendirme tablosu.	28
Çizelge 4.2: Umn veri seti bilgilendirme tablosu.	30
Çizelge 4.3: Ucsd veri seti frame bazında test sonuçları.	40
Çizelge 4.4: Umn veri seti frame bazında test sonuçları.	41
Çizelge 4.5: Karşılaştırmalı kesinlik tablosu.	44
Çizelge 4.6: Karmaşıklık kıyaslama tablosu.	47
Çizelge 4.7: Moving average filtrelemede pencere boyutunun süreye etkisi.	61
Çizelge 4.8: Ucsd ped-2 test-1 farklı pencere boyutunun performans etkisi.	62
Çizelge 4.9: Umn klip-1 farklı pencere boyutunun performans etkisi.	62
Çizelge 4.10: Ucsd ped-2 test-1 fps analiz sonuçları.	65
Çizelge 4.11: Umn klip-1 fps analiz sonuçları.	65
Çizelge 4.12: Hata değerlerinin kıyaslanması.	67
Çizelge 4.13: Sekans sonu eşik değeri ile performans analizi.	70
Çizelge 4.14: Sekans ortasında eşik güncelleme performans analizi.	70

1. GİRİŞ

Gelişen teknoloji ile günümüzde kamusal alanlar başta olmak üzere alışveriş merkezleri, parklar, kavşaklar, bankalar vs. gibi halka açık alanlarda kamera kullanımı yaygınlaşmıştır [1]. Kamera kullanımının başlıca sebepleri; suçlar, yasadışı faaliyetler, trafik kazaları gibi anormal olayları tespit etmektir. Beklenmeyen bir olay meydana geldiğinde müdahale edilebilmesi veya sonradan yapılacak işlemler için kayıt teşkil etmesi amacıyla kullanılabilir. Kamera kullanımının en büyük zorluğu görüntülerin analiz edilmesidir. İzlenecek alan büyüdükçe kamera sayısı artmakta bu sebeple kamera görüntülerini analiz edilmesi de güçleşmektedir [2]. Bu hem maliyet hem de hata oranının artması anlamına gelmektedir. İnsan faktörünü ve insandan kaynaklanabilecek hataları en aza indirmek için otomatik video anomali tespit algoritmaları geliştirilmektedir. Kamera kayıtlarında örüntüyü bozan görüntülere anomali denir. Anomali olarak adlandırılacak olay normal faaliyetlere göre nadiren meydana gelir [3]. Aynı zamanda kameranın konulduğu sahneye göre “anomali olayın” tanımı değişebilmektedir. Çocuk parkı içerisinde koşan bir insan anomali oluştururken stadyum da koşan oluşturmaz. Bu durumda anomali tespitini zorlaştırır [4]. Geliştirilen yöntemin kullanılan bir veri setinde çok iyi sonuç verirken farklı bir veri setinde iyi performans göstermemesine sebep olur.

Anomali sınıflandırılması literatürde farklı şekillerde yapılmaktadır. Fakat genel kapsayıcı bir tablo çizmek istenirse: Görsel Anomaliler, davranışsal anomaliler ve bağlamsal anomaliler olmak üzere 3 sınıfta incelenebilir [5].

Görsel anomaliler, ortamda bulunmaması gereken bir nesnenin varlığı ile ilgilidir. Kalabalıkta silah ile yürüyen insan veya terkedilmiş çanta bu tür anomalilere örnek olarak gösterilebilir. Obje tespiti yöntemleri ile görsel anomalilere çözüm üretilebilmektedir.

Davranışsal anomaliler, kişinin veya kalabalığın o sahne için olan normalden sapmış hareketleridir. Aşırı hızlı veya aşırı yavaş yürüyen insanlar, ani yön değiştirmek, kaçma eylemleri ve kalabalığın bir anda çoğalması ile panik halinin oluşması örnek olarak gösterilebilir.

Bağlamsal anomaliler, ortamın bağlamına göre anomali olarak kabul edilen olaylar için kullanılır. Örnek vermek gerekirse: Bir sokakta insanın beklemesi gündüz vakitlerinde anomali olarak kabul edilmezken gece saatlerinde beklemesi anomali olarak görülebilir.

Literatürde yukarıda belirtilenden farklı sınıflandırma yöntemleri de kullanıldığı görülmüştür. Fakat bu konu ile yapılan çalışmaların ortak zorluğu öne sürülen anomali tespit algoritmalarının kapsayıcı olamamasıdır. Bir tür anomali için başarılı sonuç üretirken farklı tür için performansı düşük kalabilmektedir. Bu çalışmada bütün anomalilerin tespiti gerçekleştirilecektir hedefinden ziyade anomali tanımının daha dar ve belirli ortamlarda gerçekleştirebilen bir algoritma önerilmiştir.

Literatürde gerçekleştirilen çalışmaların bir diğer problemi de veri setlerine olan bağımlılıktır. Eğitim aşamasında belirlenen parametreler, anomali eşik değeri gibi, farklı veri setlerinde değişmektedir. Bu çalışmada öne sürülen algoritmanın farklı veri setlerinde hiçbir parametresi değiştirilmeden kullanılabilmesi üzerine çalışılmıştır.

Kalabalık ortamlarda güvenlik ve kamu düzeninin sağlanması açısından anomali tespiti önemli bir rol oynamaktadır [6]. Güvenlik açısından incelemek gerekirse: Silahlı saldırı, şüpheli nesnelere veya kavga gibi güvenlik problemi yaratacak olayların önceden tespit edilebilmesi veya olaydan sonra araştırmanın hızlı ilerlemesinin sağlanması için anomali tespiti önemlidir [7]. Acil çıkışların kapatılması durumu, anormal yoğunluk artışı, metro istasyonlarında raylardan düşen insanlar gibi kamu düzenini etkileyen durumların anlaşılabilmesi için de kalabalık ortamlarda anomali tespit çalışmaları önem arz etmektedir. Literatürde bahsedilen bu olayların hepsini çözüp algılayabilen tek bir algoritma gerçekleştirebilmek zordur. Çünkü daha önceden de bahsedildiği gibi anomali olarak adlandırılan olaylar çok çeşitli ve bazı durumlarda anomali olarak kabul edilmeyebilir durumdadır. Bu çalışmada ise anomali tanımını daraltarak anomali kümesi küçültülmüştür. Daha az türden anomali tespiti gerçekleştirebilen algoritma öne sürülürken bu algoritmanın eğitim verisine olan bağımlılığı azaltılması ve gerçek zamanlı çalışabilmesi gibi anomali tespit çalışmalarının diğer problemlerinin çözümüne çalışılmıştır.

Bu çalışmada optik akış ve otokodlayıcı yöntemleri ile hareket hızı kaynaklı anomalilerin tespit edilmesini sağlayan bir algoritma öne sürülmüş ve UCSD ile UMN açık kaynaklı veri setleri kullanılarak performans değerlendirilmesi yapılmıştır. İlgili veri setlerini kullanarak gerçekleştirilen diğer çalışmalar ile kıyaslamalar yapılmıştır. Öne sürülen algoritmanın başarılı ve başarısız olduğu noktalar incelenmiştir.

Literatürde benzer çalışmalar incelendiğinde kullanılan veri setleri eğitim ve test olarak ayrılmıştır. Eğitim kısmında test aşamasında kullanılacak bazı önemli parametreler belirlenmiştir. Bu çalışmada farklı olarak ayrı bir eğitim aşaması gerçekleştirilmemiştir. Her görüntü için kendinden önceki kısa süreli gözlemler kullanılarak eğitim yapılmıştır. Bir görüntünün anomali kararı belirli sayıda görüntü için eğitim yapıldıktan sonra, bir periyot boyunca, verilmiştir. Anomali kararının verilmesi için kritik olan parametreler ise eğitim aşamasında belirlenip sabit olarak bütün test verisinde kullanılmaktansa belirli periyotlar ile değiştirilmiştir. Bu iki farklılık algoritmanın eğitim verisine olan bağımlılığını azaltacağı düşünülmüştür.

1.1. Tezin Amacı, Katkısı ve İçeriği

Gelişen teknoloji ile günümüzde kamusal alanlar başta olmak üzere alışveriş merkezleri, parklar, kavşaklar, bankalar vs. gibi halka açık alanlarda kamera kullanımı yaygınlaşmıştır. İstenmeyen durumların tespit edilmesinde kameralar önemli rol oynamaktadır. Bu tezin amacı kamera görüntülerinde anormal durumların herhangi bir insan müdahalesi olmadan gerçek zamanlı bir şekilde tespit edilebilmesini sağlayan ve eğitim verilerine bağımlılığı olmayan bir algoritma ortaya koymaktır. Bu algoritmanın gerçek zamanlı çalışabilme hedefi ve eğitim verisine bağımlı olmaması literatüre olan katkısı olarak görülmüştür.

Bu çalışmada UCSD ve UMN veri setlerinde anomali bulunduran görüntülerin tespit edilmesi gerçekleştirilmiştir. Literatürde yapılan kalabalık ortamlarda anomali tespiti çalışmalarında veri seti eğitim ve test olarak ayrılmıştır. Eğitim sırasında test aşamasında kullanılacak parametreler, anomali eşik değeri gibi, belirlenmektedir. Bu parametrelerin eğitim aşamasında bir kez belirlenmesi algoritmanın farklı veri setlerinde performansının düşmesine sebep olmaktadır. Bundan kaçınmak için model farklı veri setlerinde tekrar eğitilerek parametreler yeniden belirlenmektedir. Bu

durumlar eğitim kümesine olan bağlılığı arttırmaktadır. Bu çalışmada farklı olarak sadece normal görüntüler kullanarak bir eğitim yapılmamıştır. Her görüntü, kendinden önce gelen kısa süreli gözleme ait veriler kullanılarak eğitilmiştir. Aynı zamanda adaptif eşik (adaptive threshold) yöntemi ile anomali kararını etkileyen parametreler belirli periyotla sürekli güncellenmiştir. Böylelikle eğitim verisine olan bağlılık azaltılmıştır.

Aynı zamanda kurulan derin öğrenme modeli ve anomali karar mekanizması sayesinde farklı çalışmalarla kıyaslandığında kesinlik derecesinin bazı veri setleri için %8.44 arttığı görülmüştür.

1.2. Tezin Düzeni

Bu tezin yapısı şu şekildedir: 2. Bölümde literatürde kalabalık ortamlarda anomali tespiti için gerçekleştirilen çalışmalarda incelenen anomali çeşitleri hakkında bilgi verilip çalışmaların sınıflandırılması yapılmıştır. En yaygın kullanılan veri setleri hakkında genel bilgiler verilmiştir. Diğer çalışmalarda önerilen algoritmaların performansını ölçmek için kullanılan kriterler hakkında bilgi verilmiştir. Farklı çalışmalardan bahsedilip blok diyagramları verilmiştir. 3. Bölüm’ de veri ön işlemenin nasıl yapıldığını, derin öğrenme modelinin oluşturulması ve anomali tespit algoritması açıklanmaktadır. 4. Bölüm ‘de kullanılan veri setleri tanıtılmış, kurulan modelin test edilmesi ve diğer çalışmaların sonuçları ile kıyaslanması gerçekleştirilmiştir. 5. Bölüm ’de çalışmanın genel değerlendirilmesi yapıp algoritmanın belirtilen hedeflere ne derece ulaşabildiği yorumlanmıştır. Son bölümde ise tezin geliştirilmesi için gelecek çalışmalar hakkında bilgiler verilmiştir.

2. LİTERATÜR

2.1. Anomali Tipleri

Kalabalık ortamlarda anomali, bir bireyin, grubun veya çevrenin normal davranış kalıplarından veya beklenen hareket dinamiklerinden farklılık göstermesi, durumudur. Geneli etkilemeyen kalabalıkta tek bir bireyin oluşturduğu dolayısıyla görüntünün belirli bölgelerinde gerçekleşen anomalilere yerel anomali denir. Topluluk belirli bir yöne doğru yürürken bir insanın farklı yöne yürümesi örnek olarak gösterilebilir. Fakat birden fazla kişinin ortak bir şekilde gerçekleştirdiği görüntünün büyük bir kısmında gerçekleşen anomalilere genel anomali denir. İnsanların toplu bir şekilde bir olaydan dolayı kaçmaya başlaması örnek olarak gösterilebilir. Bu çalışmada hem genel hem de yerel anomalilerin tespiti üzerine çalışılmıştır.

2.2. Anomali Tespit Çalışmalarının Sınıflandırılması

Literatürde kalabalık ortamlarda anomali tespiti için gerçekleştirilen çalışmalar anomali türüne ve kullanılan yöntemlere göre iki farklı şekilde sınıflandırılmaktadır [8]. Anomali türüne göre sınıflandırma da eğer anomali, görüntünün sadece belirli bölümünde meydana geliyorsa yerel, bütün görüntü de gerçekleşiyorsa global anomali olarak adlandırılır [9]. Anomali tespiti gerçekleştirmek için optik akış, mekânsal – zamansal ve derin öğrenme yöntemlerinin kullanımına göre sınıflandırılır [10]. Literatürde popüler yaklaşım olarak makine öğrenmesi eğitim aşamasında sadece normal görüntüler kullanılırken test aşamasında ise hem normal hem de anomali bulunan görüntüler kullanılır. Son zamanlardaki literatür çalışmalarında derin öğrenme ve optik akış yöntemleri karma bir şekilde kullanıldığı görülmüştür.

2.3. Literatürde Kullanılan Veri setleri

Literatürde anomali tespiti için gerçekleştirilen çalışmalarda en çok UCSD, UMN ve AVENUE veri setleri kullanılmaktadır.

UMN, University of Minnesota Veri seti, 2.1 Bölümü'nde bahsedilen genel anomalilerin tespiti için yapılan çalışmalarda kullanılır. Kalabalığın paniğe kapılarak kaçtığı durumları temsil etmek için oluşturulmuştur. İnsanların yavaşça yürümesi normal, herkesin hızlı bir şekilde koşması anormal durum olarak kabul edilmiştir. Çimenlik alan, Bina için koridorlar ve kapalı otopark olmak üzere 3 farklı alanda çekilen toplam 11 video klibinden oluşmaktadır.

UCSD, University of California, San Diego Pedestrian Veri seti, 2.1 Bölümü'nde bahsedilen yerel anomalilerin tespiti için yapılan çalışmalarda kullanılır. Veri seti yaya yollarında bulunan ve yüksek bir yere monte edilmiş sabit bir kamera ile elde edilmiştir. Yaya yollarındaki kalabalık yoğunluğu, seyrekten çok kalabalığa kadar değişkenlik göstermektedir. Normal durumda videolar yalnızca yayaları içermektedir. Yaya yollarında yaya dışında farklı varlıkların bulunması (golf arabası, küçük araba, kaykay vs.) ve yayaların oluşturduğu anormal hareket örüntüleri (yayaları çimlere basması) anomali olarak kabul edilmiştir. Tüm anormal durumlar doğal olarak meydana gelmiştir. Toplam 50 eğitim ve 48 Test videolarından oluşmaktadır.

AVENUE, 2.1 Bölümü'nde bahsedilen yerel anomalilerin tespiti için yapılan çalışmalarda kullanılır. Veri seti bilgilendirme dokümanında tuhaf hareketler, yanlış yöne yürümek ve farklı nesnelere anomali olarak kabul edildiği belirtilmiştir. 16 eğitim 21 test videosu olmak üzere toplam 37 videodan oluşmaktadır.

2.4. Performans Ölçüm Kriterleri

Literatürde yapılan çalışmalarda önerilen algoritmaların performansını ölçmek için başlıca ROC eğrisi altında kalan alan, accuracy, precision ve recall metrikleri kullanılmaktadır.

ROC eğrisi, ikili sınıflandırma sisteminin ayırt etme eşiği değiştikçe doğru tanımlayabilme yeteneğini gösteren grafiksel bir çizimdir [11]. ROC eğrisi, çeşitli eşik ayarlarında gerçek pozitif oran (TPR) ile yanlış pozitif oran (FPR) arasında

grafik çizilerek oluşturulur. ROC analizi, sınıf dağılımından bağımsız olarak olası en uygun modelleri seçmek ve en uygun olmayanları çıkarmak için ortam oluşturur [11]. ROC bir olasılık eğrisidir AUC ise, ROC eğrisi altında kalan alanı temsil eder. AUC değeri ne kadar yüksek ise model 0 ve 1 sınıfını o kadar iyi tahmin edebilmektedir.

Accuracy (Doğruluk), algoritmanın doğru tahmin ettiği örneklerin, toplam örnek sayısına oranı olarak tanımlanır [12]. Doğruluk Hesaplama formülü Denklem 2.1’de verilmiştir.

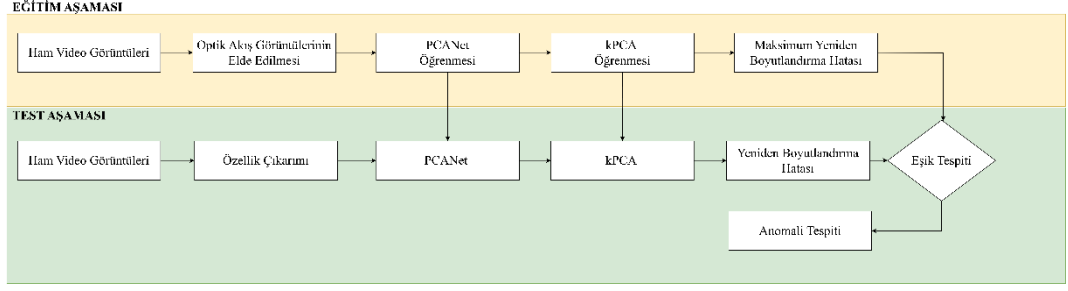
$$\frac{\text{Doğru Pozitif} + \text{Doğru Negatif}}{\text{Doğru Pozitif} + \text{Yanlış Negatif} + \text{Doğru Negatif} + \text{Yanlış Pozitif}} \quad (2.1)$$

Precision (Kesinlik) ve Recall (Duyarlılık), algortmada doğru ve yanlış tahminlerin analizlerini daha detaylı gerçekleştirmek için kullanılır [13]. Kesinlik algoritmanın pozitif olarak tahmin ettiği örneklerin gerçekten pozitif olma oranıdır [13]. Pozitif tahminlerin ne kadar doğru olduğunu gösteren bir metriktir. Duyarlılık ise gerçekten pozitif olan örneklerin ne kadarının algoritma tarafından doğru bir şekilde tespit edilebildiğini gösterir. Duyarlılık hesaplama formülü Denklem 2.2’de verilmiştir.

$$\frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Negatif}} \quad (2.2)$$

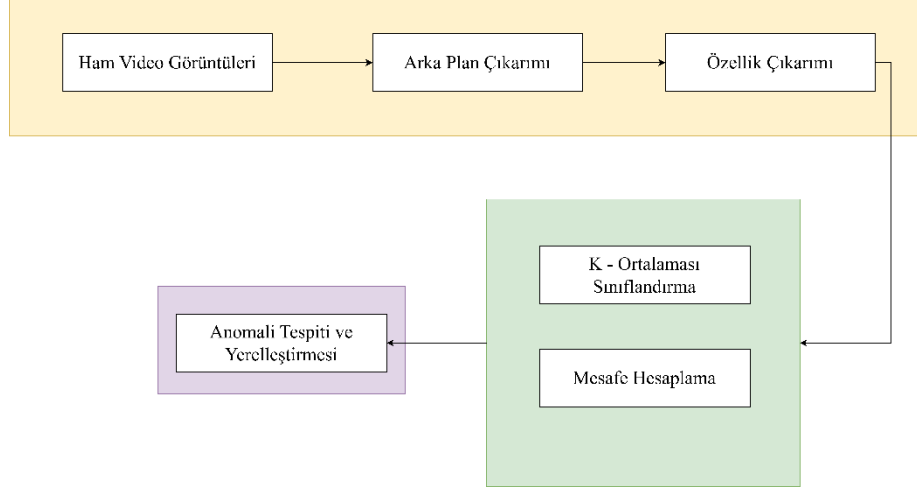
2.5. Önerilen Algoritmalar

Wang’ın çalışması [14] UMN ve UCSD veri setleri kullanılarak gerçekleştirilmiştir. Anomali tespiti için optik akış ve PCA yöntemleri kullanılmıştır. Görüntülerin optik akış haritaları çıkarılıp PCA ile boyut azaltma gerçekleştirilmiştir. Sınıflandırma ise kPCA ile yapılmıştır. Çalışmanın genel blok diyagramı Şekil 2.1’de verilmiştir.



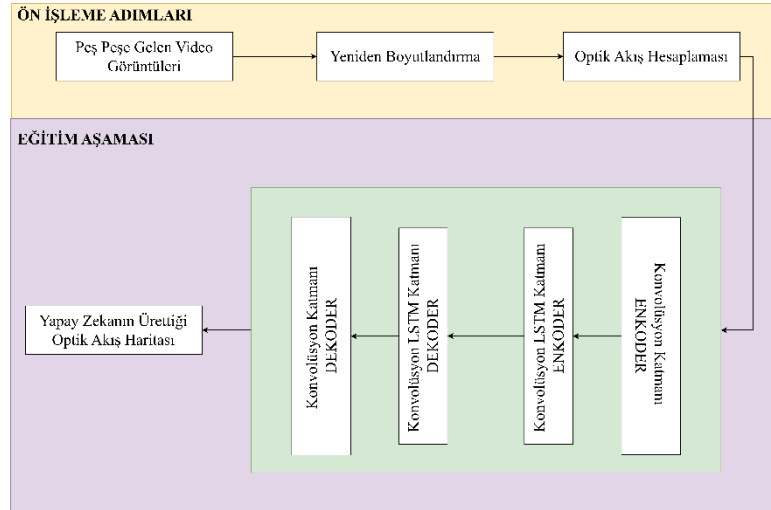
Şekil 2.1: Wang'ın çalışması blok diyagramı.

Anomali durumu; Bansod ve Nandedkar'ın çalışmasında [15], Arka plan kaldırılması, Özellik çıkarımı ve anomali tespiti olmak üzere üç aşamada tespit edilmiştir. UCSD ve UMN veri setleri kullanılmıştır. Hem yerel hem de global anomalilerin tespit edilmesi hedeflenmiştir. Arka plan kaldırılması iki temel adımla gerçekleştirilmiştir. İlk olarak hareketin meydana geldiği durumdan, sabit olarak duran arka plan görüntüsü çıkarılmıştır. İkinci adımda ise görüntülerden optik akış haritaları çıkarılmıştır. Genlik değeri belirlenen eşik değerinden büyük olan pikseller elde edilerek görüntüde sadece hareket eden bölümler belirlenmiştir. Son olarak bu iki adımda elde edilen görüntüler mantıksal “veya” işleminden geçirilmiştir. Özellik çıkarımında, görüntülerin optik akış haritalarından genlik değerleri elde edilmiştir. Genlik değerleri kullanılarak istatistiksel veriler çıkarılmıştır. Bir video sahnesinde objeler hareket ettikçe konumları değişir. Anomali durumlarındaki konum değişiklikleri ile normal durumlarda ki konum değişiklikleri farklıdır. Bu sınıflandırma aşamasında özellik olarak kullanılmıştır. Objelerin görüntüde kapladığı normalize alan ile optik akış genlik değeri çarpılarak elde edilen momentum değeri de özellik vektörüne eklenmiştir. Performans kriteri olarak AUC/ROC kullanılmıştır. Sonuçların analizi hem piksel düzeyinde hem de frame düzeyinde gerçekleştirilmiştir. Çalışmanın blok diyagramı Şekil 2.2’de verilmiştir.



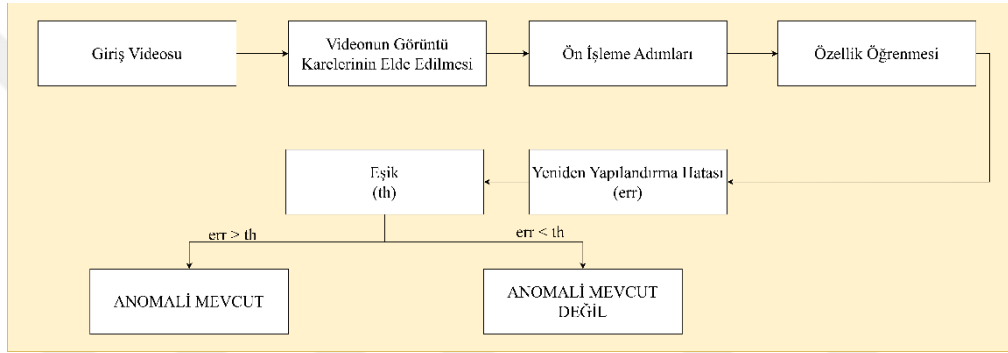
Şekil 2.2: Bansod ve Nandedkar'ın çalışması blok diyagramı.

Duman ve Erdem'in gerçekleştirdikleri çalışmada [4] UCSD ve AVENUE veri setleri kullanılmıştır. Görüntülerin optik akış haritaları çıkarılmış ve LSTM modele girdi olarak verilmiştir. Yapay zekânın ürettiği görüntüler ile gerçek görüntüler arasındaki hata değerleri hesaplanmıştır. Eğitim aşamasında, sadece normal görüntüler kullanılmıştır. Eğitimde karşılaşılan en yüksek hata değeri anomali eşiği olarak kabul edilmiştir. Test aşamasında daha yüksek hata hesaplanan görüntüler anomali olarak belirlenmiştir. Çalışmanın blok diyagramı Şekil 2.3'te verilmiştir.



Şekil 2.3: Duman ve Erdem'in çalışması blok diyagramı.

Hemant'ın çalışmasında [16] UCSD Ped-1 ve UCSD Ped-2 veri setleri kullanılmıştır. Ham görüntüler normalize edilmiştir. LSTM katmanları ile oluşturulmuş otokodlayıcı derin öğrenme modeline girdi olarak verilmiştir. Veri setlerinde eğitim aşamasında sadece normal görüntüler kullanılmıştır. Yapay zekânın ürettiği görüntüler ile gerçek görüntüler arasındaki hata hesaplanmıştır. Eğitimde gözlemlenen en yüksek hata değeri eşik değeri olarak kabul edilmiştir. Test aşamasında hata değeri bu eşikten yüksek olan görüntüler anomali olarak sınıflandırılmıştır. Başarı kıstası doğruluk olarak belirlenmiştir. Çalışmanın blok diyagramı Şekil 2.4'te verilmiştir.

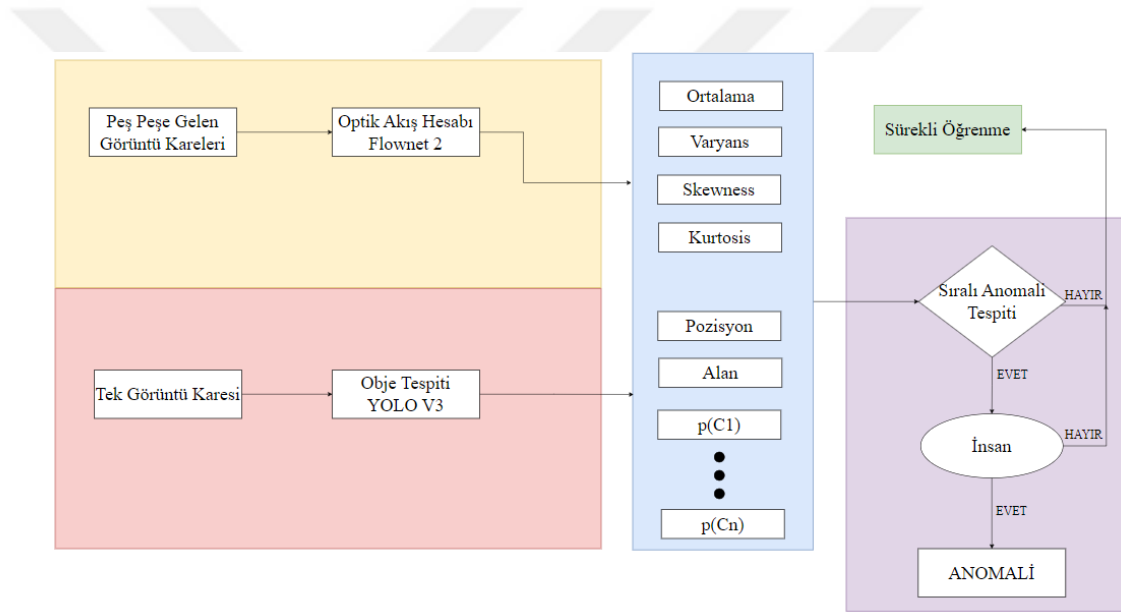


Şekil 2.4: Hemant'ın çalışması blok diyagramı.

Yang ve Yılmaz'ın çalışmasında [17] ilk olarak YOLO ve DeepSORT yöntemleri kullanılarak obje tespiti ve takibi gerçekleştirilmiştir. Ardından perspektif kaymasını engellemek için 3 boyutlu görüntüden kuş bakışı görüntü elde edilmiştir. Kuş bakışı görüntüde bulunan bütün objeler için hareket vektörleri hesaplanmıştır. Hareket vektörleri daha sonra anomali tespit algoritmasında kullanılmıştır. Anomali tespiti, Kernel Density Estimation (KDE) yöntemi ile yapılmıştır. Çalışmada UCSD Ped-1 için gerçek doğru olarak tespit edilen görüntü sayısı 4062 iken UCSD Ped-2 veri setinde ise 1453'tür. Precision ve Recall değerleri her iki veri seti için sırasıyla 0.89, 0.90 ve 0.93, 0.88'dir. 3 boyutlu görüntüden 2 boyutlu görüntü elde etmek için homografi dönüşümü kullanılmıştır.

Doshi ve Yılmaz'ın çalışmasında [18] sürekli öğrenme yaklaşımı üzerine çalışılmıştır. Mevcut derin öğrenme yöntemleri, mevcut veri kümelerinde iyi performans gösterse de hesaplama ve depolama sorunları nedeniyle sürekli öğrenme çerçevesinde yetersiz kalmaktadır. Ayrıca, çevrimiçi karar verme bu alanda

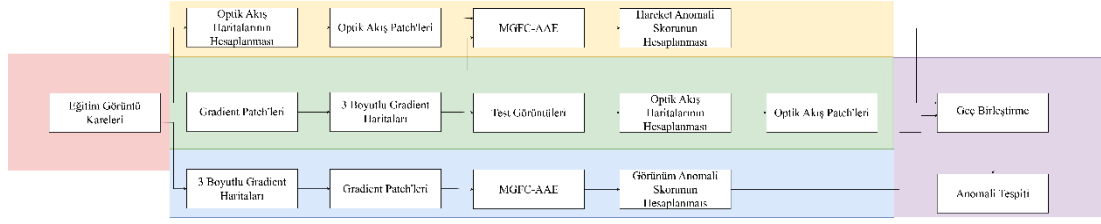
genellikle ihmal edilmektedir. Bu çalışmada transfer öğrenme ve sürekli öğrenmeyi birlikte gerçekleyerek anomali tespiti için yeni bir yöntem önerilmiştir. YOLO kullanarak obje tespiti gerçekleştirilip objeye ait özellikler, aynı zamanda Flownet2 derin öğrenme temelli optik akış algoritması kullanılarak yine objeye ait ortalama, varyans vs. özellikler çıkarılıp özellik vektörü oluşturulmuştur. Eğitim aşamasında KNN yöntemi ile anomali olmayan veriler arasında en uzak mesafe belirlenip eşik değeri olarak belirlenmiştir. Anomali bulunduran görüntüler için bu mesafenin daha fazla olduğu öne sürülmüştür. Başarı kriteri olarak ROC eğrisi altında kalan alan belirlenmiştir. UCSD Ped-2 veri seti için 97.8 değeri elde edilmiştir. Çalışmanın blok diyagramı Şekil 2.5’te verilmiştir.



Şekil 2.5: Doshi ve Yılmaz'ın çalışması blok diyagramı.

Li ve Chang'ın çalışmasında [19] Anomali tespiti iki adet deep learning akışı kullanılarak yapılmıştır. İlk olarak hareketi esas alan optik akış patch'leri elde edilip Multivariate Gaussian Fully Convolution Adversarial Autoencoder (MGFC-AAE) sinir ağına girdi olarak verilmiştir. Aynı zamanda görünümü esas alan local gradient patch'leri MGFC-AAE'ye girdi olarak verilmiştir. Eğitim aşamasında sadece normal davranışların bulunduğu video verileri kullanılmıştır. UMN ve UCSD veri setleri kullanılarak hem yerel hem de global anomali tespiti yapmak hedeflenmiştir. Sonuçların analizi hem frame hem de piksel seviyesinde yapılmıştır. Başarı kriteri

olarak AUC-ROC belirlenmiştir. Çalışmanın genel blok diyagramı Şekil 2.6’da verilmiştir.



Şekil 2.6: Li ve Chang'ın çalışması blok diyagramı.

Babu ve Shannon çalışmasında [20] CNN ve LSTM derin öğrenme algoritmalarını birleştirerek Convolutional LSTM yöntemi ile anomali tespiti gerçekleştirmişlerdir. Çalışmalarında, LSTM ağlarının peş peşe modele verilen görüntülerde zamansal özellikleri öğrenme konusunda başarıyla CNN ağlarının ise tek bir görüntüdeki mekânsal özellikleri öğrenme konusunda iyi olduğunu belirtmişlerdir. Convolutional LSTM model ile iki farklı mimariyi entegre ederek performans artışı hedeflemişlerdir. Ayrıca sistemde akan video verilerinin kaydedildiği bir yapı kurulmuştur. Belleği verimli kullanmak amacıyla normal olaylar düşük kalitede kaydedilmiştir. Anormal bir olay tespit edildiğinde, olayın öncesindeki ve sonrasındaki kareleri orijinal kalite ve çözünürlükte kaydetmeye başlamışlardır. Bu arşivleme süreci ile anomalinin çevresel bağlamını ayrıntılı şekilde belgelemeyi amaçlamışlardır. Genel olarak olaydan 10 ila 20 kare öncesi ve 100 ila 120 kare sonrası depolanmıştır. Başarı kriteri olarak ROC eğrisi altında kalan alan (ROC - AUC) seçilmiştir. UCSD Ped-1 veri seti için %89.9 UCSD Ped-2 için %87.4 ve AVENUE veri seti için %80.3 sonuçları elde edilmiştir.

Rathika'nın çalışmasında [21] kamu güvenliğinin ve akıllı şehirlerin gelişmesinde kalabalık ortamlarda anomalilerin otomatik olarak tespit edilmesinin önemli bir rol oynadığı vurgulanmıştır. Kalabalık ortamlarda bireyleri takip etmek, görüntüde çok sayıda insan bulunması nedeniyle oluşan hareket ve görünüm farklılıklarından dolayı oldukça zordur. Bu zorluklara çözüm bulmak amacıyla, mekânsal - zamansal hareket desen modelleri kullanılarak verimli bir Kernel Support Vector Machine (SVM) yapısı geliştirilmiştir. İlk olarak, video eşik değeri kullanılarak alt karelere bölünmüştür. Nesnelerin hareketlerinin daha doğru sınıflandırılması için genişletilmiş kalman fitresi ile bu hareketler bölütlenmiştir. Textural özellikler ile

nesnenin önde mi yoksa arkada mı olduğu belirlenmiştir. Nesne takibi için geliştirilmiş vektör kuantizasyonu uygulanmıştır. Son adım olarak anomalilerin sınıflandırılması için kernel tabanlı destek vektör makineleri kullanılmıştır. UCSD veri setinde %95.6 kesinlik ile başarı elde edilmiştir.

Literatürde gözlemlenen çalışmalarda temel sorun anomalinin tanımının yapılmasının zor olduğudur. Çocuk parkı içerisinde koşan bir insan anomali oluştururken stadyum da koşan oluşturmaz. Bu durumda öne sürülen algoritmayı eğitim verisine bağlı kılar. Bu çalışmada, tek bir eğitim gerçekleştirerek bütün test verilerini bu eğitime bağlı analiz etmek yerine her test görüntüsü için kısa süreli gözleme dayalı eğitim yapılarak anomali tespiti gerçekleştirilmiştir. Algoritma da eğitimler gerçekleştirilirken herhangi bir parametre değişikliği yapılmamıştır. Bu şekilde algoritmanın eğitim verisine olan bağımlılığı azaltılması hedeflenmiştir.

Gerçek zamanlı çalışabilme özelliği de öne sürülen yöntemin başarısı için göz önünde bulundurulmalıdır. Karmaşık derin öğrenme tabanlı yöntemler kullanılarak başarılı sonuçlar elde edilmesine karşın gerçek zamanlı olma özelliğinden uzaklaşıldığı gözlemlenmiştir. Literatürde gerçekleştirilen çalışmalarda, Video anomali tespiti için spatio-temporal (mekânsal - zamansal) özelliklerin ayrıştırılması ve analizi üzerine yoğunlaşmıştır. Bu tür yöntemler genellikle yüksek hesaplama gücü ve zaman gerektirir, çünkü hem mekânsal hem de zamansal verilerin detaylı bir şekilde işlenmesi gerekir. Özellikle, derin öğrenme modelleri ve otokodlayıcılar gibi karmaşık yapılar kullanıldığında, işlem süresi artar ve bu da gerçek zamanlı uygulamalar için engel oluşturabilir. Bu çalışmada, her test görüntüsü için kısa süreli gözlemler kullanılarak eğitim yapılmıştır. Bu durumda eğitim işlemi için harcanan süre gerçek zamanlı çalışabilmek için önemlidir. Bu sebepten daha az katmanlı derin öğrenme modeli ve hesaplama maliyeti daha düşük olan optik akış yöntemi kullanılmıştır.

3. YÖNTEM

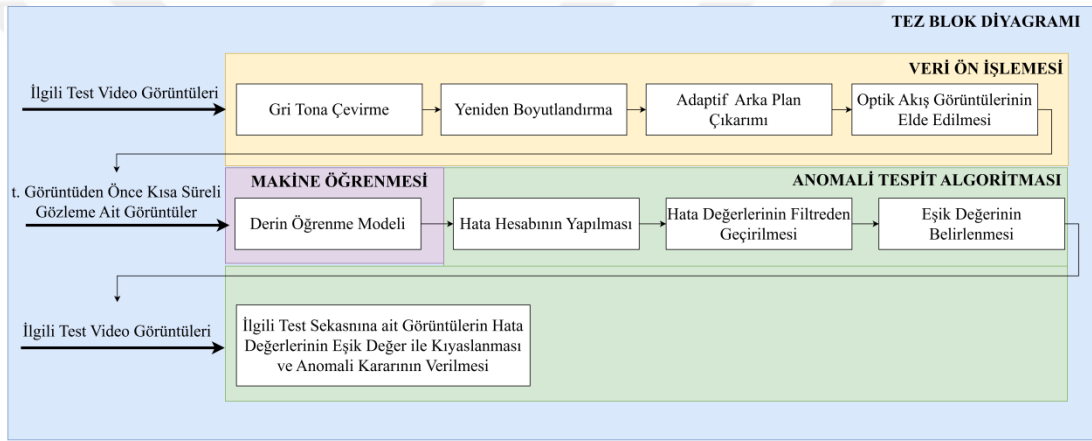
Çalışmada uygulanan ön işleme adımları, Anomali tespiti için geliştirilen derin öğrenme modeli ile kullanılan algoritmaya ilişkin bilgiler bu bölümde verilmiştir. 3.2 bölümünde veri setlerinde bulunan görüntülerin optik akış haritalarının hangi yöntem ile çıkarıldığı ve bu yöntemin neden seçildiği anlatılmıştır. 3.1 bölümünde, 3.2’de anlatılan optik akış harita görüntülerinin elde edilmesi işlemlerinin matematiksel olarak daha az hesaplama yükü ile yapılması için her görüntüye uygulanan ön işlemlerden bahsedilmiştir. Anomali tespit algoritmasını gerçeklemek için derin öğrenme modeli, her test görüntüsü ile ilgili bir optik akış haritası tahmin etmiştir. 3.3 bölümünde ilk olarak genel anlamda derin öğrenmenin tanımı yapılmış ve önemli kavramlar açıklanmıştır. Son olarak kullanılan derin öğrenme modeli hakkında bilgi verilmiştir. 3.4 bölümünde bu çalışmada bir görüntü için anomali kararının nasıl verildiği açıklanmıştır.

Bir test video sekansının her bir görüntü karesi için anomali tespit yönteminin uygulanması şu şekilde olur:

İlk olarak bir test video sekansındaki bütün görüntüler gri tona çevrilip yeniden boyutlandırılır. Ardından sadece görüntünün hareketli kısımları ile işlem yapabilmek için arka plan çıkartımı gerçekleştirilir. Arka plan çıkarılmış görüntülerin daha sonra optik akış harita görüntüleri oluşturulur. Bu ön işlem adımları optik akış hesabının matematiksel yükünü azaltmak için yapılmıştır. Bir test video sekansının tüm görüntülerine bu adımlar uygulanır. Test video sekansında t . görüntü de anomali varlığına karar verilebilmesi için kendisinden önce gelen 10 görüntünün optik akış harita görüntüleri derin öğrenme modeline girdi olarak verilir ($t - 10, t - 9, \dots, t - 1$). Bu şekilde ilgili test görüntüsünün optik akış haritası tahmin edilir. Görüntüye ait gerçek optik akış haritası ile yapay zekânın ürettiği optik akış haritası arasındaki fark ortalama karesel hata yöntemi ile hesaplanır. Test video sekansının her görüntüsü için hesaplanan bu hata değerleri filtreden geçirilerek daha güvenilir gözlemler yapılması sağlanır. Hata değerlerinin ortalaması ilgili test video sekansı için eşik değer olarak kabul edilir. Bu eşik değerinden daha yüksek hata değerine sahip test görüntülerinde anomali varlığına karar verilir. Bir görüntü karesinin anomali bulundurma durumuna karar vermek için kullanılan görüntü sayısı kadar frame’de

bir eşik değeri güncellenir. Gerçekleştirilen çalışmada bu sayı bir test video sekansı kadardır (UCSD için yaklaşık 200, UMN için ortalama 500 görüntü). Literatürde öne sürülen kalabalık ortamlarda anomali tespit algoritmalarından farklı olarak bu çalışmada, sadece normal görüntüler kullanarak bir eğitim yapmak yerine her görüntünün kendinden önce gelen kısa süreli gözleme ait veriler kullanılarak eğitim gerçekleştirilmiştir. Aynı zamanda adaptif eşik (adaptive threshold) yöntemi ile anomali karar mekanizması işletilmesi bu algoritmanın bir diğer farkı olarak söylenebilir.

Bu çalışmanın genel akış diyagramı Şekil 3.1’de verilmiştir.



Şekil 3.1: Genel akış diyagramı.

3.1. Veri Ön İşlemesi

Anomali tespit çalışmaları kısa süreli gözlemlere ait video sekansları kullanarak gerçekleştirilmiştir. Her video sekansındaki görüntülere sırasıyla aşağıdaki adımlar uygulanmıştır.

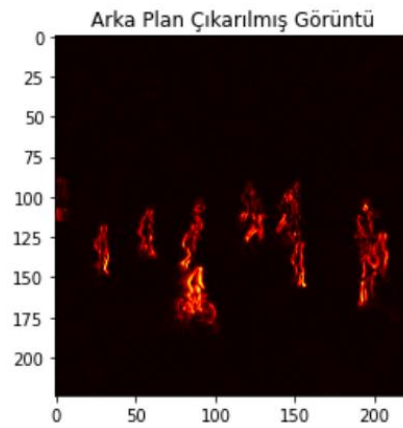
- Gri tona çevrilmiştir.
- 224×224 boyutuna yeniden boyutlandırılmıştır.
- Adaptif arka plan çıkartımı (adaptive background subtraction) yöntemiyle görüntüden arka plan çıkarılmıştır.

Görüntülerin aynı boyutta olması derin öğrenme modellerinde veri uyumluluğu sağlar. Tezin ileriye dönük çalışmalarında transfer öğrenmesi uygulanabileceği öngörüsüyle, bu yöntemde yaygın olarak kullanılan hazır derin öğrenme mimarilerine (örneğin VGG) uyumlu olması açısından [22], ve ayrıca karşılaştırma yapılan çalışmalardan Duman ve Erdem'in çalışmasında da aynı boyut tercih edildiğinden [4], giriş görüntü boyutu olarak 224×224 seçilmiştir. Algoritmada görüntü verilerinin boyutları ciddi derecede büyük veya küçük ise örneğin 5000×5000 veya 50×10 , yeniden boyutlandırma da detay kaybı ve en-boy oranının bozulması gibi potansiyel problemler ortaya çıkabilir. Bu durumda algoritmanın performansı düşer.


Adaptif arka plan çıkarılması, yeni gelen görüntü karesini ve önceki karelere dayalı olarak sürekli güncellenen arka plan görüntüsünü kullanılarak gerçekleştirilir. t Anında ki arka plan, $(t - 1)$ anında hesaplanan arka plan karesi ve t anındaki görüntünün üstel hareketli ortalama filtresinden geçirilmesiyle elde edilir. Her yeni gelen görüntüyü 3.1 kullanarak arka plan güncellenir. 3.1' de verilen f_t , t anında ki görüntüyü $bg_{(t-1)}$, $(t - 1)$ anındaki arka planı temsil eder. α İse yeni gelen görüntünün arka planı ne kadar etkileyeceğini belirten katsayıdır.

$$bg_{(t)} = \alpha \times f_t + (1 - \alpha) \times bg_{(t-1)} \quad (3.1)$$

Arka plan çıkarılması işleminin etkisi Şekil 3.2 ve Şekil 3.3'te gösterilmiştir.



Şekil 3.2: Ham test görüntüsünden arka plan çıkarılmış görüntü.



Şekil 3.3: Test görüntüsünün optik akış haritası.

3.2. Optik Akış

Optik akış, görüntü işleme ve bilgisayarla görme alanlarında hareketin yönü ve hızını tespit etmek için kullanılan bir tekniktir. Özellikle iki ardışık görüntü karesi arasındaki her bir pikselin nasıl yer değiştirdiğini hesaplamak için kullanılır [23]. Lucas-Kanade, Farneback ve Deep Learning farklı optik akış algoritmalarıdır. Lucas-Kanade yöntemi görüntülerde renk ve parlaklık bilgisinin değişmediği ve küçük hareketlerin var olduğu varsayımlarına dayanır. Belirli bir konumdaki parlaklık değeri Δt zaman sonra hesaplanan parlaklık değeri ile aynı olacağı varsayımı Denklem 3.2 ile ifade edilmiştir. 2. Varsayım matematiksel olarak 1. Dereceden Taylor Açılımı ile Denklem 3.3 ve 3.4'te verilmiştir. Belirli bir pencere boyunca her piksel için bu denklemler çözülerek hareket vektörü hesaplanır.

$$I(x, y, t) = I(x + u, y + v, t + 1) \quad (3.2)$$

$$I(x + dx, y + dy, t + dt) = I(x, y, t) + \frac{\partial I}{\partial x} dx + \frac{\partial I}{\partial y} dy + \frac{\partial I}{\partial t} dt \quad (3.3)$$

$$I_x dx + I_y dy + I_t dt = 0 = \frac{\partial d}{\partial x} I_x + \frac{\partial d}{\partial y} I_y + \frac{\partial d}{\partial t} I_t \quad (3.4)$$

Deep learning tabanlı optik akış algoritmaları, geleneksel optik akış yöntemlerinin sınırlamalarını aşmak için derin öğrenme modellerini kullanır. Bu algoritmalar, özellikle karmaşık sahnelerdeki büyük hareketleri ve parlaklık değişimlerini daha doğru bir şekilde algılayabilir. Öğrenme temelli yaklaşımlarda optik akış büyük veri

kümeleri üzerinde eğitim yaparak öğrenir. Derin öğrenme anlamlı özellikler çıkartmak için de kullanılabilir. Bu özellikler pikseller arasındaki ilişkiyi ve hareketi modellemek için kullanılır. Gerçek zamanlı çalışmalarda derin öğrenme temelli algoritmaların yavaş sonuç verdiği gözlemlenmiştir. FlowNet [24] ve PWC-Net [25] en çok kullanılan derin öğrenme tabanlı optik akış hesaplama algoritmalarındandır.

Bu çalışmada Farneback [26] optik akış algoritması kullanılmıştır. Bir pikselin ve onun komşularının parlaklık değerlerini ikinci dereceden polinom ile modeller.

$$f_n(x) = x^T A x + b^T x + c \quad (3.5)$$

A : Simetrik matris, piksellerin yerel ikinci dereceden özelliklerini tanımlar.

b^T : Piksel yer değiştirmesini temsil eden vektör.

c : Sabit terimdir.

$f_n(x)$: n . karedeki piksellerin parlaklık değerlerini temsil eder.

x : Pikselin konumunu temsil eder.

Bir sonraki görüntüdeki yer değiştirmiş pikselin parlaklık değeri ise Denklem 3.6'da ki gibi ifade edilir.

$$f_{n+1}(x + d) = (x + d)^T A (x + d) + b^T (x + d) + c \quad (3.6)$$

" d " yer değiştirme vektörüdür. Piksellerin iki ardışık karede ne kadar şiddette ve hangi yönde hareket ettiğini gösterir.


Farneback algoritmasında parlaklık farkı en aza indirgenmeye çalışılır. İki ardışık karedeki ikinci dereceden polinomların katsayıları eşitlenerek d vektörü hesaplanır. Farneback algoritması, her piksel için optik akışı hesaplar. Yani tüm görüntüdeki her pikselin hareketini bulur. Bu yüzden, Farneback algoritması yoğun bir optik akış algoritması olarak adlandırılır. Farneback optik akış algoritmasının, Nemade'nın yapılan çalışmada [27], Horn-Schunck ve Lucas-Kanade algoritmalarına kıyasla hem daha hızlı çalıştığı hem de daha yüksek performans gösterdiği görülmüştür. Bu nedenle, bu tez kapsamında optik akış hesaplamalarında Farneback algoritması kullanılmıştır.

3.3. Derin Öğrenme

Derin öğrenme, yapay zekânın bir alt dalıdır. İnsan beyninin öğrenme biçiminden esinlenerek geliştirilen yapay sinir ağları kullanılarak gerçekleştirilen bir öğrenme yöntemidir.

3.3.1. Yapay Sinir Ağları

Yapay Sinir Ağları, insan beyin yapısının çalışma prensibinden esinlenerek ortaya çıkmıştır. İnsan beyninde 1000 milyar nöron, her bir nöron 1000 - 100.000 nöron ile bağlantılı olacak şekilde, bulunmaktadır [28]. Sinir hücreleri dış dünyadan gelen sinyalleri (bilgileri) uçlarında bulunan dendritler ile alarak bilgi, sinir hücresinin aksonundan geçirilip sinapsis aracılığı ile bir diğer sinir hücresinin dendritine ulaştırılır. Yapay sinir ağları da birbirlerine nöronlar ile bağlı birçok katmanın bir araya gelmesiyle oluşan bir yapıdır. Örnek yapay sinir ağı Şekil 3.4'te gösterilmiştir.



Şekil 3.4: Yapay sinir ağı katmanları.


Yapay sinir ağları 3 farklı katmandan oluşmaktadır [29]:

Giriş katmanı, probleme bağlı olarak değişen bağımsız değişkenlerin verildiği katmandır. Genellikle kaç adet bağımsız değişken mevcut ise o kadar sayıda nöron bulunur.

Gizli katman, giriş katmanı ve çıkış katmanı arasında bulunur ve bağımlı değişkenlerin elde edilmesi için yapılan işlemleri içerir. Bir yapay sinir ağında birden çok gizli katman bulunması mümkündür.

Çıkış katmanında ise gizli katman sonucu bulunan bağımlı değişkenler mevcuttur. Kaç adet bağımlı değişken mevcut ise genellikle o kadar sayıda nöron bulunur.

Yapay sinir ağıları, geleneksel makine öğrenmesi algoritmaları (SVM, LR vb.) ile kıyaslandığında sistemi kendi başına eğitmesi sebebiyle daha iyi sonuç vermektedir. Bir yapay sinir hücresinin çalışması ile ilgili blok diyagram Şekil 3.5'te gösterilmiştir.



Şekil 3.5: Yapay sinir hücresi.

Geleneksel makine öğrenmesi yöntemlerinde algoritma kurulup işletilerek sonuç elde edilir. Yapay sinir ağlarında algoritma işletildikten sonra hata hesabı yapılır. Hata, belirlenen bir değer üzerindeyse girdi ağırlıkları (W_1, W_2, W_3) tekrar hesaplanarak öğrenme işlemi yeniden gerçekleştirir ve sistem kendini en iyi şekilde eğitmiş hale getirir. Yapay sinir ağının çalışma şekli Şekil 3.5'te belirtilmiştir.

Şekil 3.5'te görüldüğü üzere, her giriş parametresi belirli bir ağırlık ile çarpılır (W_1, W_2, W_3). Daha sonra nörona gelen değerler toplanır. Nöron, aktivasyon fonksiyonu kullanarak karar verme işlemi tamamlayıp bir tahmin veya sınıflandırma gerçekleştirir.


$$\text{Nörona gelen sinyal (bilgi)} = w_1x_1 + w_2x_2 + w_3x_3 \quad (3.7)$$

$$\text{Aktivasyon Fonksiyonu (A.F) uygulanması} = \varphi(w_1x_1 + w_2x_2 + w_3x_3) \quad (3.8)$$

Aktivasyon fonksiyonu nöronun karar vermesini sağlayan fonksiyondur [30]. Matematiksel olarak ifade edilebilen bütün fonksiyonlar aktivasyon fonksiyonu olarak seçilebilir. Sigmoid, Threshold, Rectifier fonksiyonları en çok kullanılan aktivasyon fonksiyonlarından [31]. Aktivasyon fonksiyonu ile oluşan sonuç değeri ve gerçek değer arasındaki farka hata denir. Yapay sinir ağı bu hatayı hesaplayıp sistemin ağırlıklarını güncelleyerek (cezalandırma sistemi) eğitimi yeniden

gerçekleştirir. Gelişmiş yapay sinir ağlarında hangi ağırlığın hatayı daha fazla arttırdığı tespit edilebilir. Bu ağırlık daha fazla cezalandırılarak sistemin yeniden eğitilmesi gerçekleştirilir.

Yapay sinir ağlarında sistemin geri besleme işlemi stokastik ve batch olmak üzere iki yöntem ile gerçekleştirilir. Stokastik yöntem, eğitim setinde bulunan her verinin eğitilmesi sonucunda sistemi geri besler. Batch yöntemi ise eğitim setinde bulunan bütün verilerin eğitilmesi sonucunda sistemi geri besler. Stokastik yöntemin olumsuz yönü yerel uygun (local optimum) sonucu kabul etme potansiyelidir. Hâlbuki bütün veri incelendiğinde evrensel uygun (global optimum) bir sonucun varlığı saptanabilir. Şekil 3.6’da yerel ve global optimum noktaları gösterilmiştir.

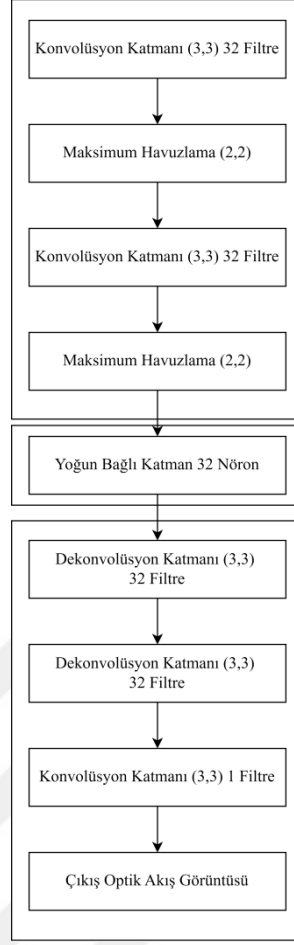


Şekil 3.6: Optimum değerler.

Batch yönteminde bütün eğitim verisine kaç kez bakılacağı bilgisine “çağ” yani epoch denir.

3.3.2. Otokodlayıcılar

Bu çalışmada derin öğrenme yöntemlerinden biri olan Otokodlayıcılar kullanılmıştır. Otokodlayıcılar girdiyi bir gizli uzaya kodlar. Bu sayede girdi de önemli olan özellikleri öğrenir. Çözücü bölümünde ise öğrenilen özelliklerden girdiye yakın bir görüntü oluşturmaya çalışır. Şekil 3.7’de kullanılan otokodlayıcı modeli gösterilmiştir



Şekil 3.7: Derin öğrenme modeli.

Konvolüsyon katmanı, otokodlayıcı modelin ilk katmanıdır. Genellikle görüntü verileri gibi yüksek boyutlu ve yerel özelliklere sahip veriler üzerinde çalışan otokodlayıcılarda kullanılır. Seçilen kernel'in görüntü üzerinde dolaştırılmasıyla anlamlı olan bölgelerin tespit edilmesini sağlar. Birden fazla filtre kullanılarak konvolüsyon işlemi gerçekleştirilir.

Havuzlama katmanı, filtreler kullanarak görüntünün küçültülmesi işlemi yapar.

Şekil 3.8'de 2×2 ' lik maksimum filtresi kullanılarak havuzlama işlemi gerçekleştirilmiştir. Havuzlama işlemi ile sinir ağının doğru karar vermesi için yeterli sayıda bilgi elde edilir. Havuzlama katmanı kullanılmasıyla:

- 1) Veri temsil boyutu ve hesaplama maliyeti azaltılmıştır.
- 2) Verinin önemli özellikleri korunup gereksiz bilgiler çıkarılmıştır
- 3) Modelin farklı veri varyasyonlarına karşı daha dirençli olmasını sağlamıştır.

0	3	2	8
7	4	9	1
5	6	5	8
3	9	0	6

7	9
9	8

Şekil 3.8: Havuzlama katmanı uygulaması.

Dekonvolüsyon katmanı, Gizli uzaydan orijinal veriyi elde etmek için kullanılan yöntemdir. Transpoz konvolüsyon olarak da bilinir ve otokodlayıcıların kod çözücü kısmında kullanılır. X Matrisi için konvolüsyon işlemi yapılırken W çarpım matrisi oluşturulur. X Ve W matrislerinden kaydırmalı nokta çarpımı ile Y çıkış matrisi elde edilir. Dekonvolüsyon işleminde ise bu çarpım matrisinin transpozu kullanılır. Matematiksel denklemler Denklem 3.9’da gösterilmiştir.

$$Y = W \times X \rightarrow X^I = W^T \times Y \quad (3.9)$$

Autoencoder UCSD Ped-1 veri setinin eğitim verileri ile eğitilmiştir. Eğitim verilerinde anomali oluşturan görüntüler bulunmamaktadır. Çağ sayısı 3, yığın boyutu 2 olarak eğitim gerçekleştirilmiştir. Eğitim için kullanılan verilerin sırası önemli olduğu için karıştırma parametresi “false” olarak ayarlanmıştır. Bu eğitim aşaması, sadece autoencoder’a ilk yapay zekâ özelliğini kazandırmak için gerçekleştirilmiştir. Herhangi bir eşik değeri belirlenmemiştir. Autoencoder, diğer iki veri seti için ayrıca eğitilmemiş direkt kullanılmıştır.

3.4. Anomali Tespit Algoritması

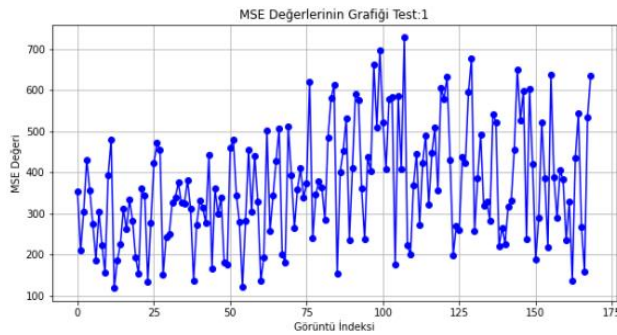
Anomali tespiti için kullanılan eşik değeri Hemant [16] ve Erdem’in [4] gerçekleştirdikleri çalışmada eğitim verisi üzerinden belirlenmiş ve bütün video sekansları için sabit kalmıştır. Bu çalışmada ise hem eğitim verisine olan bağılılığı azaltmak hem de periyodik bir şekilde eşik değerini güncellemek için kısa süreli gözlemlere ait veriler kullanılarak her görüntü ile eğitim gerçekleştirilmiştir. Bir

optik akış harita görüntüsünü modelin tahmin edebilmesi için girdi olarak kendinden önce gelen 10 optik akış harita görüntüsü derin öğrenme modeline verilmiştir. Bu durumda her test videosu sekansında ilk 10 görüntü için bir hesaplama yapılamamıştır. Daha az görüntünün girdi olarak verilmesi derin öğrenme modelinin görüntü tahmin başarısını azalttığı gözlemlenmiştir.


Yapay zekânın ürettiği görüntü ile gerçek görüntü arasındaki fark piksel bazında Denklem 3.10’da verilen ortalama kare hatası yöntemi ile hesaplanmıştır.

$$mse = \frac{1}{n} \sum_{i=1}^n (X_{gercek}(n) - X_{tahmin}(n))^2 \quad (3.10)$$

Denklem 3.10’da n , X görüntüsünün piksel numarasını temsil etmektedir. İlgili test video sekansında bulunan her görüntü için ortalama kare hatası hesaplandıktan sonra değerler hareketli ortalama filtresinden (moving average filter) geçirilmiştir. Optik akış yöntemi hareket hızına karşı çok ani tepkiler verebilmektedir. Kullanılan filtre sayesinde görüntüler arasındaki hareket hızlarının değişimi daha kolay gözlemlenmesi sağlanmıştır. Filtre etkisi Şekil 3.9 ve Şekil 3.10’da gözlemlenmiştir. Ardından filtreden geçirilmiş değerlerin ortalaması alınmıştır. Ortalama değer test videosuna ait “Anomali eşik değeri” olarak belirlenmiştir. Hata değeri eşik değerinden büyük olan görüntüler anomali olarak belirlenmiştir. Her test video sekansında bu işlemler tekrarlanmıştır.



Şekil 3.9: Ucsd ped-2 test-1 filtrelenmemiş mse grafiği.



Şekil 3.10: Ucsd ped-2 test-1 filtrelenmiş mse grafiği.

Hemant'ın çalışmasında [16], yapay zekânın ürettiği görüntüler ve gerçek görüntüler arasında hesaplanan hatanın anomali bulunan görüntüler de normal görüntülere kıyasla daha yüksek olduğu belirtilmiştir. Gerçekleştirilen bu çalışmada da bir test görüntüsü için yapay zekânın ürettiği optik akış haritası ve gerçek optik akış haritası arasındaki hatanın eğer görüntü de anomali mevcut ise daha yüksek olduğu gözlemlenmiştir. Böylelikle her bir test videosu için hesaplanan hata değerlerinin ortalaması adaptif eşik değeri olarak belirlenmiştir. Hata değeri bu eşik değerinden büyük olan görüntüler anomali olarak Kabul edilmiştir. Karar verme mekanizması hep filtrelenmiş değerler üzerinden gerçekleşmiştir. Eşik değeri, bir görüntü karesinin anomali bulundurma durumuna karar vermek için kullanılan görüntü sayısı kadar frame'de bir güncellenir. Gerçekleştirilen çalışmada bu sayı bir test video sekansı kadar seçilmiştir (UCSD için yaklaşık 200, UMN için yaklaşık 500 görüntü).

Bu bölümde, anomali tespiti için önerilen yöntemin adımları anlatılmıştır. 3.1 Bölümü'nde matematiksel işlem yükünü azaltmak için yapılan ön işlem adımlarından bahsedilmiştir. 3.2 Bölümü'nde hareket temelli anomali tespiti için kullanılan matematiksel yöntem, optik akış, anlatılmıştır. 3.3 Bölümü'nde derin öğrenme modeli olarak kullanılan otokodlayıcılar hakkında bilgi verilmiştir. Bu bölümün son alt başlığı olan 3.4 Bölümü'nde ise anomali karar mekanizmasının nasıl işlediği, kararın nasıl verildiği söylenmiştir. 4. Bölümde bu bölümde anlatılan işlemlerin uygulanarak elde edilen sonuçlar detaylı bir şekilde incelenmiştir.

4. TEST VE ANALİZ

Bu bölümde, 3. Bölümde anlatılan ön işleme adımları ve anomali tespit algoritmasının başarısını ölçmek için kullanılan UCSD ve UMN veri setleri tanıtılmıştır. Gözlemlenen test senaryoları tanıtılmış ve değerlendirilmiştir. Diğer çalışmalara göre eksik ve daha başarılı olunan noktalardan bahsedilmiştir. 4.1 bölümünde kullanılan veri setleri tanıtılmıştır. Verilerin nasıl elde edildiği, test ve eğitim ayırımının nasıl yapıldığı, veri seti seçilirken nelere dikkat edildiği ve ilgili veri setlerine ait sayısal ve örnek görüntüler verilmiştir. 4.2 Bölümü'nde sonuçların değerlendirilmesi ve farklı çalışmalar ile kıyaslanması için kullanılan performans kriteri hakkında bilgi verilmiştir. 4.3 bölümünde, Test video sekanslarına 3. Bölümde anlatılan yöntem adımları uygulanarak elde edilen sonuçların değerlendirilmesi yapılmıştır. 4.4 Bölümünde özellikle dikkat edilen test senaryoları tanıtılmış ve bu senaryolarda önerilen algoritmanın nasıl sonuç verdiği incelenmiştir.

4.1. Veri Setleri

4.1.1. UCSD Veri Seti

Bu çalışmada UCSD veri seti kullanılmıştır [32]. UCSD veri seti yaya yollarında bulunan ve yüksek bir yere monte edilmiş sabit bir kamera ile elde edilmiştir. Yaya yollarındaki kalabalık yoğunluğu, seyrekten çok kalabalığa kadar değişkenlik göstermektedir. Normal durumda videolar yalnızca yayaları içermektedir. Yaya yollarında yaya dışında farklı varlıkların bulunması (golf arabası, küçük araba, kaykay vs.) ve yayaların oluşturduğu anormal hareket örüntüleri (yayaları çimlere basması) anomali olarak kabul edilmiştir. Tüm anormal durumlar doğal olarak meydana gelmiştir. Veri seti Ped-1 ve Ped-2 olmak üzere iki bölüme ayrılmıştır. Ped-1'de Kamera doğrultusuna doğru yürüyen, kameradan uzaklaşan insan gruplarını içeren klipler ve bir miktar perspektif bozulması bulunur. 34 eğitim videosu ve 36 test videosu örneği içerir. Ped-2'de yaya hareketlerinin kamera düzlemine paralel olduğu sahneler bulunur. 16 eğitim videosu ve 12 test videosu örneği içerir. Kameradan alınan görüntüler 200, 180 ve 150'lik frame'ler halinde video sekanslarına ayrılmıştır. Hiç anomali bulundurmeyen video sekansları eğitim,

içerisinde bir veya daha fazla anomali bulunduranlar ise test verileri olarak ayrılmıştır. Veri setine ait örnek görüntüler Şekil 4.1, Şekil 4.2, Şekil 4.3 ve Şekil 4.4'te; veri sayıları hakkında bilgiler ise Çizelge 4.1'de verilmiştir. Bütün anomalilerin yerel, doğal olarak meydana gelmesi ve günlük hayatta karşılaşılabilecek türden olması çalışmanın performansını değerlendirmek için bu veri setinin seçilmesinin nedenleri olmuştur.



Şekil 4.1: Ucsd ped-1 test-10.



Şekil 4.2: Ucsd ped-1 test-1.



Şekil 4.3: Ucsd ped-2 test 4.



Şekil 4.4: Ucsd ped-2 test 11.

Çizelge 4.1: Ucsd veri setleri bilgilendirme tablosu.

Veri Seti	UCSD Ped 1		UCSD Ped 2	
	Normal	Anomali	Normal	Anomali
Test	3195	4005	374	1636

4.1.2. UMN Veri Seti

Bu çalışmada UMN veri seti kullanılmıştır [33]. University of Minnesota Veri Seti, kalabalığın paniğe kapılarak kaçtığı durumları temsil etmek için oluşturulmuştur. İnsanların yavaşça yürümesi normal, herkesin hızlı bir şekilde koşması anormal durum olarak kabul edilmiştir. Çimenlik alan, Bina için koridorlar ve kapalı otopark olmak üzere 3 farklı alanda çekilen toplam 11 video klibinden oluşmaktadır. Tüm video kliplerinin benzer bir kalabalıklığa sahip olduğu görülmektedir; her sahnede 10 ila 20 kişi bulunmaktadır. Her videonun başlangıcında, insanlar yürüme veya birbirleriyle konuşma gibi düzenli davranışlar sergilemektedir. Bir süre sonra, insanlar birden koşmaya başlar ve alanı tahliye ederler. Video karelerinin boyutları 240×320 'dir. Video klipleri 30 fps değerine sahiptirler. UMN veri setinde, veriler eğitim ve test olarak ayrılmamıştır. Bu çalışmada da ayrıca bir eğitim bölümü olmadığı için direkt test verisi olarak kullanılıp analiz edilmiştir. Her klip bir test video sekansı olarak değerlendirilmiştir. Veri setine ait örnek görüntüler Şekil 4.5, Şekil 4.6 ve Şekil 4.7'de; veri sayıları hakkında bilgiler ise Çizelge 4.2'de verilmiştir.

Gerçekleştirilen çalışma yerel anomalilerin yanında genel anomalilerin tespitini de gerçekleştirmeyi hedeflediği için ve aynı zamanda eğitim verisine olan bağımlılığın azaldığını daha güvenilir şekilde gözlemlemek adına UMN veri seti kullanılması uygun görülmüştür.



Şekil 4.5: Umn klip 1.



Şekil 4.6: Umn klip 3.



Şekil 4.7: Umn klip 4.

Çizelge 4.2: Umn veri seti bilgilendirme tablosu.

Klip Numarası	Görüntü Karesi Sayısı
Klip-1	599
Klip-2	810
Klip-3	510
Klip-4	630
Klip-5	630
Klip-6	510
Klip-7	840
Klip-8	600
Klip-9	540
Klip-10	600
Klip-11	720

4.2. Performans Kriteri

Bu çalışmada önerilen algoritmanın performansını ölçmek için Accuracy (Doğruluk) performans kriteri kullanılmıştır. Doğruluk, algoritmanın doğru tahmin ettiği örneklerin, toplam örnek sayısına oranı olarak tanımlanır. Makine öğrenmesi ve derin öğrenme temelli çalışmalarda en yaygın kullanılan değerlendirme kriterlerinden birisidir. Algoritmanın tüm tahminlerinde ne kadar doğru olduğunu genel olarak değerlendirmek için seçilmiştir. Kolay hesaplanması ve farklı algoritmalar ile karşılaştırma da kolay yorumlanabildiği için tercih edilmiştir. Daha çok kullanılan veri seti dengeli dağılıma sahip ise tercih edilmelidir. Eğer kullanılan veri setinde bulunan sınıflar dengeli dağılmadıysa doğruluk yanıltıcı sonuçlar verebilir. %95 negatif örneklerin bulunduğu sadece %5 doğru örneklerin bulunduğu bir veri setinde önerilen algoritma bütün test verisine negatif olarak değerlendirme ihtimali yüksektir. Doğruluk parametresi ise %95 oranında algoritmaya başarılı diyecektir. Fakat aslında bir sınıf algoritma tarafından hiç tespit edilememiş olacaktır. Böyle bir durumun bu çalışmada yaşanmaması için sonuçlar daha detaylı incelenmiş, yanlış pozitif ve yanlış negatif sonuçlar hesaplanmıştır.

En yaygın kullanılan performans kriterlerinden birisi de ROC eğrisi altında kalan alandır. ROC eğrisi altında kalan (ROC-AUC) anomali kararının olasılıksal bir sonuç olarak verildiği durumlarda kullanılabilir. Örneğin bir görüntüde anomali olma ihtimali %80'dir gibi. Fakat bu çalışmada olasılıksal karar vermek yerine binary karar verildiği için (anomali veya değil) bu performans kriteri kullanılmamıştır.


4.3. Test Sonuçları

Çalışmada sadece test verileri kullanılmıştır. Eğitim verileri ile ayrıca bir eğitim gerçekleştirilmemiştir. UMN veri setinde bulunan bütün video klipleri test verisi olarak değerlendirilmiştir. UCSD ve UMN veri kümelerinde bulunan test videolarına veri ön işleme bölümünde anlatılan işlemler uygulanmış ardından 3. Bölüm'de anlatılan derin öğrenme modeline girdi olarak verilmiştir. Otokodlayıcılar kullanılarak gerçekleştirilen derin öğrenmede, her bir test görüntüsünün anomali tespiti için kendinden önce gelen kısa süreli görüntülerle eğitim gerçekleştirilmiştir. Test görüntüleri eğilirken döngü sayısı 5 seçilmiş, yığın boyutu 2 olarak ayarlanmıştır. Verilerin eğitim sırası önemli olduğu için karıştırma (Shuffle)

parametresi “False” olarak belirtilmiştir. Yapay zekâ, derin öğrenme sonucunda ilgili test görüntüsü için bir optik akış haritası tahmini üretir. Yapay zekânın ürettiği optik akış görüntüsü için hata değeri 3.4 Bölümü’nde anlatıldığı gibi hesaplanmıştır. Her test video sekansı için hesaplanan hata değerleri, daha güvenilir gözlemler yapabilmek için pencere boyutu 24 olan hareketli ortalama filtresinden geçirilmiştir. Her test video sekansında, filtreden geçirilmiş hata değerlerinin ortalaması ilgili test videosu için anomali eşik değeri olarak belirlenmiştir. Hata değeri eşik değerden yüksek olan görüntüler anomali olarak sınıflandırılmıştır.


UCSD Ped-1’de Test-31, Test-22, Test-19 ve Test-8, UCSD Ped-2’de Test-1, Test-2, Test-5, Test-4, UMN’de ise Klip-1, Klip-6, Klip-7 ve Klip-4 verileri için elde edilen sonuçlar, veri setine uygulanan yöntemin nasıl değerlendirildiğinin örneği olması amacıyla Şekil 4.8, Şekil 4.9, Şekil 4.10, Şekil 4.11, Şekil 4.12, Şekil 4.13, Şekil 4.14, Şekil 4.15, Şekil 4.16 Şekil 4.17, Şekil 4.18 ve Şekil 4.19’da verilmiştir. Grafiklerde x eksenini test videosuna ait frame, y eksenini ise 3.4 Bölümü’nde nasıl hesaplandığı anlatılan hata değerlerini temsil etmektedir. Test videolarına ait anomali eşik değerleri 3.4 Bölümü’nde anlatıldığı gibi belirlenip mavi çizgi ile gösterilmişlerdir. Grafikte kırmızı çizgiler ile işaretlenen görüntüler videolar da anomalinin bulunduğu bölümlerdir.

UCSD Ped-2 Test-2 video sekansında insanlar parkta yürümektedir. 90. görüntüden itibaren bisiklet kullanan insan kamera açısına girmiş video kaydı sonuna kadar kamera açısında kalmıştır. Şekil 4.8 incelendiğinde, 90. görüntüden itibaren y ekseninde belirtilen hata değerleri ortalamasının üstünde kaldığı görülmüştür. Anomali tespiti başarılı şekilde gerçekleşmiştir.



Şekil 4.8: Ucsd ped-2 test-2 verisi grafiği.


UCSD Ped-2 Test-5 video sekansında, ilk görüntüden 110. görüntü karesine kadar bisiklet kullanarak kalabalık arasında giden insan mevcuttur. Şekil 4.9 incelendiğinde, 100. görüntüden sonra bisikletli birey kamera açısından çıkmaya başladığı için hata değerleri de ortalamanın altında kalmaya başladığı görülmüştür.



Şekil 4.9: Ucsd ped-2 test-5 verisi grafiği.


UCSD Ped-1 Test-31 video sekansında, 60. görüntüye kadar kalabalık arasından hızlı şekilde bisiklet kullanılan insan geçmektedir. Bisikletli kamera açısından çıkmadan önce başka bir bisikletli birey kamera açısına girmeye başlamıştır. Fakat algoritma ancak 100. görüntü karesinde ikinci bisiklet kullanan insanı anomali olarak algılayabilmiştir. 60 ile 100. görüntüler arasında algoritmanın her görüntü için hesapladığı hata değerinin sürekli arttığı fakat yine de eşik değerinin altında kaldığı

görülmüştür. Kamera açısında perspektif olması bu görüntü karelerinin anomali tespitinin başarılı şekilde yapılamamasına yol açtığı düşünülmüştür



Şekil 4.10: Ucsd ped-1 test-31 verisi grafiği.


UCSD Ped-1 Test-22 video sekansında, 22. görüntüden itibaren kaykay ile kalabalık arasına giren insan kamera açısına girmiştir. 108. görüntüden itibaren ise kamera açısından tamamen çıkmıştır. Önerilen algoritma 22 ile 108. görüntüler arasında anomali tespitini başarılı şekilde gerçekleştirmiştir. Hesaplanan hata değerleri eşik değerinin her zaman üstünde kalmıştır. 108. görüntüden itibaren yapay zekâ ile gerçek optik akış haritaları arasında hesaplanan hata değerlerinin azaldığı gözlemlenmiştir.



Şekil 4.11: Ucsd ped-1 test-22 verisi grafiği.


UCSD Ped-2 Test-4 video sekansında, 50. görüntüden itibaren kamera açısına 4.1 Bölümü'nde belirtildiği gibi parkta olmaması gereken golf arabası girmeye başlamıştır. İlgili video sekansında kalabalığın az olması hareket eden unsurların az olduğu anlamına gelir. Bu durum optik akış değerlerinin golf arabası girdiğinde ani yükselmesine sebep olmuştur. Hata değerlerinin de ilgili görüntü karesinde arttığı ve

golf arabası kamera açısında kaldığı sürece eşik değerinin üstünde olduğu gözlemlenmiştir. Önerilen algoritmanın en güçlü olduğu anomali tespit senaryosu, hareket hızı kaynaklı olanlardır. Test-4 video sekansında da bu durum görülmüştür. Çok fazla hareket unsurunun görüntüler de bulunduğu video sekanslarında önerilen algoritmanın başarısız kaldığı görülmüştür. Bu durum 4.4.1 Bölümü'nde detaylı bir şekilde incelenmiştir.



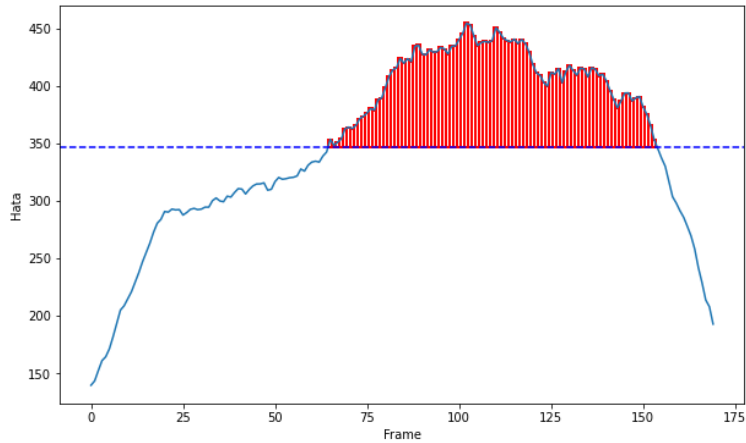
Şekil 4.12: Ucsd ped-2 test-4 verisi grafiği.

UCSD Ped-1 Test-8 video sekansında, ilk görüntüden 94. görüntüye kadar kaykay ile kalabalık arasında giden insan mevcuttur. İlk 25 görüntü karesinde kalabalık içerisinde bulunan kaykaylı algoritma tarafından anomali olarak tespit edilememiştir. Bunun sebebi kalabalık içerisinde geçerken hızını azaltıyor olması olarak düşünülmüştür. Kalabalık içerisinde 34. görüntü karesi itibaren çıktıktan sonra algoritma başarılı şekilde çalışmıştır. 94. görüntü karesinden sonra video sekansında hiçbir anomali oluşturacak unsur oluşmamıştır. Hata değerlerinin de aynı doğrultuda düştüğü görülmüştür. Fakat 6 görüntü karesinde algoritma tarafından anomali tespit edilmiştir. Bu durum görüntü karelerinde çok fazla hareket eden unsurun olduğundan kaynaklandığı düşünülmüştür.



Şekil 4.13: Ucsd ped-1 test-8 verisi grafiği.


UCSD Ped-2 Test-1 video sekansında, 70. görüntüden itibaren bisiklet kullanan insan kamera açısına girmiş video kaydı sonuna kadar kamera açısında kalmıştır. Şekil 4.14 incelendiğinde, 70. görüntüden itibaren y ekseninde belirtilen hata değerleri ortalamasının üstünde kaldığı görülmüştür. Anomali tespiti başarılı şekilde gerçekleşmiştir. Kalabalık oranının bütün video boyunca sabit olması ve kalabalık hızının da ani değişmemesi anomali tespitini kolaylaştırmıştır. Kalabalık arasına aniden giren hızı görece daha yüksek olan bisikletli hata değerlerinde artışa sebep olmuştur.



Şekil 4.14: Ucsd ped-2 test-1 verisi grafiği.


UCSD Ped-1 Test-19 video sekansında, 60. görüntü ile kamera açısına golf arabası girmiş 140. Görüntü karesinden sonra tamamen çıkmıştır. Şekil 4.15 incelendiğinde hata değerleri 60 ve 140. görüntü kareleri aralığında Test-19 video sekansı için belirlenen anomali eşik değerinden yüksek olduğu gözlemlenmiştir. Anomali

oluşturan unsurun kalabalıktan uzak ve kalabalıktan daha hızlı hareket etmesi anomali tespitini kolaylaştırmıştır.




Şekil 4.15: Ucsd ped-1 test-19 verisi grafiği.

UMN Klip-1 video sekansında çimenlik alanda 15-20 kişiden oluşan kalabalık rastgele yürümektedir. Gelişigüzel bir anda meydana gelen anormal bir durumdan dolayı kalabalıktaki insanlar plansız yönlere doğru koşmaya başlamaktadırlar. Anomalinin gerçekleştiği durumda, test video sekansının genelinde ani bir hareket değişimi meydana geldiği için, hesaplanan hata değerlerinin artmaya başladığı görülmektedir. Kalabalığın hareketi yavaşladığı durumda tekrar hesaplanan hata değerleri ortalamaya yakın bir noktaya gelmeye başladığı gözlemlenmiştir. Hareket hızları videonun büyük bölümünde aynı kaldığı için hata değerleri genel de ortalamaya yakın noktalarda hesaplanmıştır. Bu bazı durumlarda algoritmanın hatalı sonuç vermesine sebep olacağı ön görülmüştür.



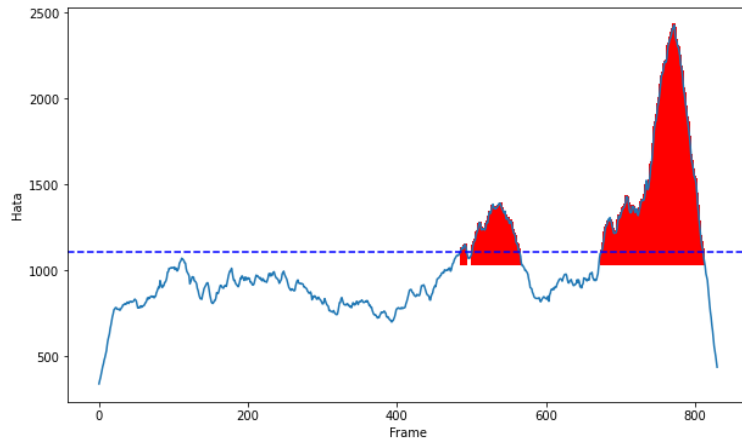
Şekil 4.16: Umn klip-1 verisi grafiği.

UMN Klip-6 video sekansında koridorda; konuşan, rastgele yürüyen ve diğer odaların içerisine girip çıkan insanlar bulunmaktadır. Gelişigüzel bir anda meydana gelen anormal bir durumdan dolayı kalabalıktaki insanlar plansız yönlere doğru koşmaya başlamaktadırlar. Bazı insanlar koridorun farklı taraflarına bazı insanlar ise koridorda bulunan odaların içerisine doğru koşmaya başlamıştır. Test video sekansının genelinde ani bir hareket değişimi meydana geldiği için, hesaplanan hata değerlerinin artmaya başladığı görülmektedir. Kalabalığın hareketi yavaşladığı durumda tekrar hesaplanan hata değerleri ortalamaya yakın bir noktaya gelmeye başladığı gözlemlenmiştir. Video sekansının 60. görüntü karesinde farklı odalardan koridora doğru insanların yürümeye başladığı görülmektedir. Bu durum da hareket eden obje sayısı artıp hata değerlerinin artmasıyla yanlış anomali tespitine sebep olmuştur. Ardından gelen görüntü karelerinde ise koridordan odalara giden insanlar bulunduğu için hareket hata değerlerinin ciddi şekilde azaldığı gözlemlenmiştir.



Şekil 4.17: Umn klip-6 verisi grafiği.

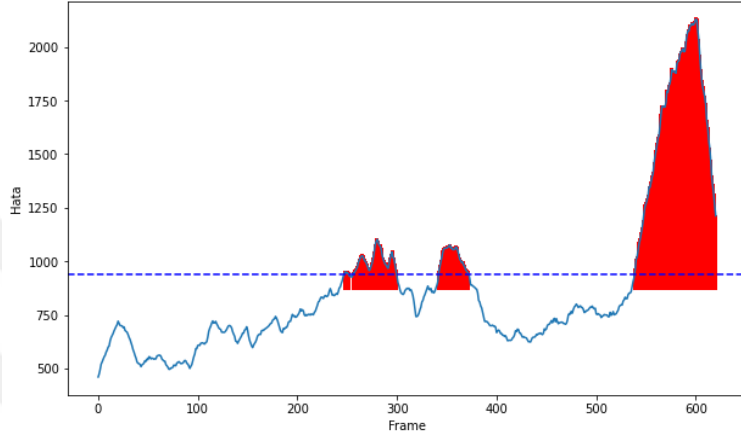
UMN Klip-7 video sekansında Klip-6’da olduğu gibi koridorda; konuşan, rastgele yürüyen ve diğer odaların içerisine girip çıkan insanlar bulunmaktadır. Gelişigüzel bir anda meydana gelen anormal bir durumdan dolayı kalabalıktaki insanlar plansız yönlere doğru koşmaya başlamaktadırlar. 730. görüntü karesinde koridorda bulunan kalabalıktaki insanlar aniden farklı yönlere doğru koşmaya başlamıştır. Bu durum algoritma tarafından başarılı şekilde tespit edilebilmiştir. Fakat anomali öncesinde insanların koridorun yanında bulunan odalardan yürüyerek kamera açısına girmesi algoritmanın yanlış karar vermesine sebep olmuştur.



Şekil 4.18: Umn klip-7 verisi grafiği.

UMN Klip-4 video sekansında, koridorda; konuşan, rastgele yürüyen ve diğer odaların içerisine girip çıkan insanlar bulunmaktadır. 561. görüntü karesinden sonra kalabalıkta bulunan insanlar farklı yönlere doğru koşmaya başlamıştır. Optik akış

hesabında piksel genlik değerlerinin ciddi şekilde yükseldiği görülmüştür. Bu durum yapay zekânın ürettiği optik akış görüntüleri ile gerçek optik akış görüntüleri arasındaki hata miktarının artmasına sebep olmuştur. 200 ile 400. görüntü kareleri arasında koridorda kalabalığın hareketinden bağımsız olarak farklı yönlerde yürüyen insanlar kamera açısına girmiştir. Bu insanlar da algoritma tarafından hatalı şekilde anomali olarak tespit edilmiştir.



Şekil 4.19: Umn klip-4 verisi grafiği.

Önerilen yöntemin performansını ölçmek için “doğruluk” başarı metriği kullanılmıştır. Doğruluk, modelin doğru tahmin ettiği örneklerin, toplam örnek sayısına oranı olarak tanımlanır. UCSD Ped-1 veri setinde %81 UCSD Ped-2 veri setinde %82, UMN veri setinde %91.18 doğruluk ile başarı elde edilmiştir. UCSD veri seti için sadece test verileri kullanılarak çalışma gerçekleştirilmiş ve analiz tablosu Çizelge 4.3’te verilmiştir. UMN veri setinde eğitim ile test ayrımı yapılmamıştır. 11 video klibinde de belirli görüntü karelerinde anomali meydana gelmiştir. 11 video sekansı da test verisi olarak değerlendirmiş ve analiz tablosu Çizelge 4.4’te verilmiştir.

Çizelge 4.3: Ucsd veri seti frame bazında test sonuçları.

Veri Seti	Anomali Yokken Var Denilen	Anomali Varken Yok Denilen
UCSD Ped-1	%5.84	%13.15
UCSD Ped-2	%2.64	%15.34

Çizelge 4.4: Umn veri seti frame bazında test sonuçları.

Klip Numarası	Anomali Yokken Var Denilen	Anomali Varken Yok Denilen
Klip-1	%0	%0
Klip-2	%10.52	%0
Klip-3	%11	%0
Klip-4	%12	%0
Klip-5	%8.87	%0
Klip-6	%8	%0
Klip-7	%7.22	%0
Klip-8	%8.47	%0
Klip-9	%14.33	%0
Klip-10	%4.57	%0
Klip-11	%12.67	%0

Her iki veri setinde de test videolarındaki her görüntü için eğitim yapılırken kendisinden önce bulunan 10 görüntü kullanıldığı için her test videosunun ilk 10 görüntüsü hakkında yorum yapılmamıştır. Bu yüzden performans analizi UCSD Ped-1 veri seti için 6840, UCSD Ped-2 veri seti için 1890, UMN veri seti için 6879 görüntü için yapılmıştır.

Hemant'ın çalışmasında [16] LSTM katmanları ile otokodlayıcı derin öğrenme modeli oluşturulmuştur. Otokodlayıcı modelde, Enkoder - Dekoder katmanlarından önce iki adet konvolüsyon katmanı 11×11 'lik kernel 128 filtre, 5×5 'lik kernel 64 filtreden oluşacak şekilde eklenmiştir. Enkoder - Dekoder katmanının sonrasına iki adet aynı filtre sayısı ve kernel boyutları ile dekonvolüsyon katmanları eklenmiştir. Enkoder - Dekoder katmanı, 3×3 kernel ve 64 filtreli Konvolüsyonel LSTM bloklarından oluşturulmuştur. UCSD veri setinde performans analizi yapılmıştır. Bu çalışmadan farklı olarak eşik değeri eğitim aşamasında, sadece normal görüntüler dikkate alınarak, elde edilen en yüksek hata değeri olarak belirlenmiştir. Bütün test video sekansları için aynı eşik değeri kullanılmıştır. Başarı metriği "kesinlik" olarak belirlenmiştir.

Duman ve Erdem'in gerçekleştirdikleri çalışmada [4] ise LSTM modelde ham görüntüler kullanmak yerine optik akış görüntüleri girdi olarak verilmiştir. Otokodlayıcı modelde, Enkoder - Dekoder katmanlarından önce iki adet konvolüsyon katmanları 10×10 'luk kernel 128 filtre, 6×6 'lık kernel 64 filtreden oluşacak şekilde eklenmiştir. Enkoder - Dekoder katmanının sonrasına iki adet aynı

filtre sayısı ve kernel boyutları ile dekonvolüsyon katmanları eklenmiştir. Encoder - Dekoder katmanı, 3 x 3 kernel ve 64 filtrelili LSTM bloklarından oluşturulmuştur. Yapay zekânın ürettiği optik akış görüntüleri ile gerçek optik akış görüntüleri arasındaki hata değerleri hesaplanmıştır. Hemant çalışmasında [16] olduğu gibi normal görüntüler kullanılarak eğitim yapıp eşik değeri belirlenmiştir. Başarı metriği “kesinlik” olarak belirlenmiştir.

Alarfaj ve Pervaiz’in çalışması [34]; ön işlem adımları, insan silüeti çıkartma, İnsan doğrulama, özellik çıkarımı, optimizasyon ve sınıflandırma olmak üzere 6 ana adımda gerçekleştirilmiştir. Objeye tespiti ve takibi için Gaussian Mixture Model (GMM) ve Kalman filtresi kullanılmıştır. Sistemin performansını en çok etkileyen işlem adımlarının objeye tespit ve takibi olduğu vurgulanmıştır. UMN veri setinde bazı insanların gölgelerinin olması insan silüet tespitini olumsuz etkilediği görülmüştür. Bu yüzden insan silüetlerini tespit etmeden önce gölge kaldırma işlemi uygulanmıştır. Tespit edilen insan silüetlerinin doğruluk oranını arttırmak için fuzzy c-means sınıflandırma yöntemi kullanılmıştır. Çalışmada bir sonraki adım olarak insan silüetlerinin hız ve optik akış özellikleri çıkarılmıştır. Bir objenin hızı iki görüntü karesi arasındaki konum değişikliğinden hesaplanmıştır. Kullanılan matematiksel formüller Denklem 4.1 ve 4.2’de verilmiştir.

$$Hız = \frac{Konum Değişimi}{Kare Hızı (fps)} \quad (4.1)$$

$$Konum = \sqrt{\sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}} \quad (4.2)$$

Nesnenin bir önceki görüntü karesinde x eksenindeki pozisyonu x_1 , y eksenindeki pozisyonu y_1 , şimdiki görüntü karesindeki x eksenindeki pozisyonu x_2 , y eksenindeki pozisyonu y_2 olarak isimlendirilmiştir.

Hareket örüntüsünün tespit etmek için insan silüetlerine Horn-Schunck [35] optik akış algoritması uygulanmıştır. Bu algoritma bir pikselin hızının komşu pikselleri ile ilişkili olacağına dayanır.

İnsan silüetlerinden elde edilen bu özellik vektörleri XG-Boost sınıflandırma algoritmasına girdi olarak verilmiştir. Çalışmanın performansını ölçmek için kesinlik başarı metriği kullanılmıştır.

Mehran'ın çalışmasında [36] Social Force (Etkileşim Kuvveti) model kullanılmıştır. Anomali tespiti için obje tespiti yapmak, kalabalık yoğunluğunun fazla olduğu ve görüntü kalitesinin düşük olduğu görüntülerde zor olacağından bahsedilmiştir. Bunun yerine çalışmada görüntü üzerine parçacıklar yerleştirerek bu parçacıkların zamanla hareketinin incelenmesi sonucu anomali tespiti gerçekleştirilmiştir. Parçacıklar arasındaki kuvvetler hesaplanmıştır. Bir görüntüde, etkileşim kuvvetlerindeki zaman içindeki değişim, kalabalığın devam eden davranışını belirlediği söylenmiştir.

Kalabalık içerisinde bulunan bir bireyin kuvvet vektörü iki ana bileşende incelenmiştir. İlk olarak bireysel bileşeni ikincisi ise kalabalığın onu etkilemesiyle ortaya çıkan kuvvet vektörüdür. Bu yüzden bireyin hareketi kalabalıkta bağımsız düşünülemez. Bu bilgiler Mehran'ın çalışmasında neden anomali tespiti gerçekleştirmek için Social Force modeli kullandığının temel sebebi olarak görülebilir. Parçacıklar için kuvvet değerleri Denklem 4.3 ve 4.4'te hesaplanmıştır.

$$m_i \frac{dv_i}{dt} = F_a = F_p + F_{int} \quad (4.3)$$

$$v_i^q = (1 - p_i) v_i^p + p_i v_i^c \quad (4.4)$$

Denklem 4.3 kalabalık içerisindeki bir objeye uygulanan kuvvetleri göstermek için kullanılan genel bir denklemdir. Objeye üzerindeki net kuvvet F_a , objenin bireysel kuvveti F_p ve kalabalık ile etkileşiminden kaynaklanan kuvvet ise F_{int} olarak gösterilmiştir. Denklem 4.4'te Kuvvet denklemleri hız bileşenleri dâhil edilerek tekrar yazılmıştır. p_i Kalabalığın objeye ne kadar etki ettiğini gösteren bir parametre, v_i^c komşu objelerin ortalama hızı, v_i^p ise objenin bireysel hızını temsil etmektedir.

Bir görüntü karesinde hesaplanan anlık kuvvetler anormallikleri ayırt edemez fakat kuvvetlerin zaman içinde oluşturdukları örüntüden bu tespit gerçekleştirilebilir. M adet pikselden oluşan görüntü karesinde elde edilen kuvvet büyüklüklerinden kuvvet akışı özellik matrisi oluşturulmuştur $S_f(t)$. $S_f(t)$ 'deki olası desenleri tanımlama işlemi "The Bag of Words" yöntemi ile gerçekleştirilmiştir. Çalışmada performans değerlendirmesi farklı çalışmalar da dahil edilip ROC eğrileri incelenerek gerçekleştirilmiştir. Mahren, çalışmada öne sürdüğü Social Force modelin başarısını göstermek için optik akış yöntemini kullanarak da bir çalışma gerçekleştirmiştir. Bag of Words yöntemine girdi parametresi olarak kuvvet akışı matrisi yerine optik akış

blokları verilmiştir. Bloklar 10 adet pikselden oluşturulmuştur. ROC eğrisi altında kalan alan (ROC-AUC) Social Force model için 0.96, optik akış yöntemi için 0.84 olarak elde edilmiştir.

Abhiram'ın çalışmasında [37] LSTM katmanları ile otokodlayıcı derin öğrenme modeli oluşturulmuştur. Derin öğrenme modeline girdi olarak CNN ile elde edilen özellik vektörleri verilmiştir. CNN sonucunda elde edilen özellik vektörlerine PCA yöntemi uygulanarak boyut azaltma yapılmıştır. Otokodlayıcı modelin ürettiği sonuçlar ile girdiler arasında oluşan hatalar hesaplanmıştır. Bu hata değerlerinin görüntü de anomali mevcut ise daha yüksek olduğu öngörülmüştür. Normal görüntüler ile eğitim yapılarak eşik değeri belirlenmiş ve test aşamasında hata değeri bu eşik değerden yüksek olan görüntüler anomali olarak kaydedilmiştir. Başarı metriği "kesinlik" olarak belirlenmiştir.

UCSD ve UMN veri setleri kullanılarak gerçekleştirilen çalışmaların sonuçları Çizelge 4.5'te verilmiştir.

Çizelge 4.5: Karşılaştırmalı kesinlik tablosu.

Çalışma	UCSD-1	UCSD-2	UMN
Duman ve Erdem [4]	%98.25	%95.82	-
Hemant [16]	%81.25	%73.56	-
Mehran [36]	-	-	%87
Alarfaj ve Pervaiz [34]	-	-	%90.6
Abhiram [37]	-	%90	-
Önerilen Algoritma	%81	%82	%91.18

Duman ve Erdem'in gerçekleştirdikleri çalışmada [4] konvolüsyonel LSTM katmanlarının kullanılması performansı arttıran bir etmen olmuştur. LSTM modeller, geçmişteki bilgileri unutmaya veya hatırlamaya karar verebilme yeteneği sayesinde zamana bağlı olan girdilerde iyi bir performans gösterir. Fakat derin öğrenme modelinin karmaşıklığının arttırdıkları için daha yavaş sonuç üretirler. Otokodlayıcı

ile birlikte kullanıldığında, bu geçmiş ve gelecek bağımlılıklarını anlamak için güçlü bir yapı sağlar. LSTM derin öğrenme modeline girdi olarak Farneback algoritması ile oluşturulan optik akış haritaları verilmiştir. Bir görüntünün optik akış hesabının yapılabilmesi için peş peşe gelen 8 görüntü kullanılmıştır.

Tek bir eğitim süreci gerçekleştirildiğinde eğitim süresinin uzun olması kabul edilebilir bir durum olabilir. Fakat bu çalışmada adaptif eşik değeri kullanıldığından dolayı tek bir eğitim yapmak yerine her eşik değer belirlendiği örnek görüntüler için kısa süreli eğitimler gerçekleştirilmiştir. Bu durumda model olabildiğince basit tutulup eğitim süresinin kısa olması hedeflendiğinden LSTM katmanları modele dahil edilmemiştir.

Gerçekleştirilen çalışma ile Hemant çalışması [16] mukayese edildiği durumda UCSD Ped-1 veri setinde performansın aynı olduğu UCSD Ped-2 veri setinde ise önerilen çalışmanın daha başarılı olduğu gözlemlenmiştir. Hemant çalışmasının 'da [16] kullanılan derin öğrenme modelinden daha az karmaşıklıkta bir derin öğrenme ile daha iyi sonuçlar elde edildiği görülmüştür. Derin öğrenme modeline direkt ham görüntüler vermek yerine optik akış görüntülerini vermek performansı arttırdığı söylenebilir.

Alarfaj ve Pervaiz'in çalışmasında [34] insan silüetlerinin tespiti başarılı bir şekilde yapılamadığı veya silüetler de örtüşmelerin meydana geldiği durumlarda anomali tespit başarısının düştüğü söylenmiştir. Aynı zamanda sadece insan silüetleri tespit edilebildiğinden bahsedilmiştir. Bu durumda insan dışında farklı bir nesnenin varlığından dolayı meydana gelebilecek anomalilerin tespiti gerçekleştirilememiştir. Bu iki temel unsur Önerilen bu çalışmaya kıyasla Alarfaj ve Pervaiz'in çalışmasının performansının daha düşük kalmasının sebebi olarak görülmüştür.

Mehran'ın çalışması [36] ile gerçekleştirilen bu çalışma karşılaştırıldığında, görüntü karelerine uygulanan matematiksel işlemlerin performansı dramatik şekilde etkilemediği söylenebilir. Mehran çalışmasında Social Force modelin sadece optik akış yöntemi kullanmaktan daha başarılı olduğunu göstermeyi amaçlamıştır. Social Force model kullanarak performansı arttırmıştır. Bu çalışmada ise anomali tespit algoritması ve kullanılan makine öğrenme yöntemi değiştirilerek Mehran'ın optik akış çalışmasına kıyasla performans arttırılmıştır. Mehran görüntü karesini ızgaralara ayırarak hesaplamaları yaparken bu çalışmada ise görüntü karesi bütün olarak

değerlendirilmiştir. Görüntü karesini bütüncül değerlendirmenin algoritmanın daha basit olmasını sağladığı söylenebilir. Mehran'ın çalışmasında kesinlik sonucu hakkında bilgi bulunmamaktadır. Fakat Alarfaj ve Pervaiz'in çalışmasında Mehran'ın çalışmasının %87 kesinlik değerine sahip olduğu belirtilmiştir. Fakat bu sonucun Mehran'ın çalışmasında [36] sadece optik akışı kullandığı yönteme mi yoksa Social Force model mi ait olduğu hakkında bilgi bulunmamaktadır. Alarfaj ve Pervaiz'in çalışmasının [34] optik akış temelli bir yöntem olduğu için Mehran'ın optik akış yöntemi ile kıyaslandığı düşünülmüştür.

Abhiram'ın çalışmasında [37] otokodlayıcı derin öğrenme modelinde LSTM katmanları kullanmak, performansı ciddi derecede arttırdığı düşünülmüştür. LSTM, zamansal özellikleri ve görüntü kareleri arasındaki uzun vadeli bağımlılıkları tespit etmek amaçlı kullanılır. Bu yüzden beklenen diziyi bozan bir anomali olup olmadığını tespit etmede başarılıdırlar. Aynı zamanda otokodlayıcı modele sadece hareket hızı ve yönü hakkında bilgi veren optik akış özelliğini girdi olarak vermek yerine bir CNN ağı ile elde edilen özellik vektörlerini vermek de başarıyı arttıran unsurlardan biri olarak görülmüştür. Eğitim aşamasında farklı veri setleri kullanılarak eşik değeri belirlense de sabit olması bu çalışmaya göre dezavantaj olarak görülebilir. Eğitim verisine olan bağımlılığı arttıran bir unsurdur.

Eğitim verileri üzerinde model eğitimi yapmak yerine her test verisi için kendisinden önce gelen 10 ardışık görüntü ile eğitim gerçekleştirilmiştir.

- Anomali eşik değeri her test videosunda, görüntüler için hesaplanan ortalama kare hataları kullanılarak belirlenmiştir.

Bahsedilen 2 farklılık algoritmanın hem gerçek zamanlı çalışabilmesini sağlayacak hem de eğitim verisine olan bağımlılığı azaltacak önemli unsurlar olarak görülmüştür.

Çizelge 4.5'te derin öğrenme kullanan [4], [16] ve [37] çalışmalarına kıyasla önerilen algoritmada autoencoder'in katman ve nöron sayıları daha azdır. Uygulanan filtrelerin büyüklüğü de daha küçüktür. LSTM katmanları kullanmamakta karmaşıklığı azaltan etmenlerden biri olmuştur. Fakat sistemin CPU üzerinde çalışması ciddi gecikme getirmiştir.

Yapay zekânın temel eğitimi sadece UCSD Ped1 veri seti ile gerçekleştirilmiştir. Ardından her görüntü için kısa süreli gözlemlere göre eğitim gerçekleştirilerek

sonular elde edilmiřtir. Algoritma 3 veri setinde de herhangi bir parametre deęiřiklięi yapılmadan uygulanmıřtır. [4] ve [16] alıřmalarında her veri seti iin farklı bir eřik deęeri belirlenmiřtir. Bu eřik deęer ilgili veri setinin eęitim kmesi kullanarak gerekleřtirilmiřtir. Bu durumda nerilen algoritma, dięer alıřmalara kıyasla yksek gecikmeye sahip fakat eęitim verisine olan baęımlılıęı daha az denebilir. nerilen algoritma ile derin ęrenme kullanan dięer alıřmaların karmařıklık seviyelerini kıyaslamak iin kullanılan parametreler izelge 4.6’da verilmiřtir.

izelge 4.6: Karmařıklık kıyaslama tablosu.

alıřma	Derin ęrenme Katman Sayısı	Derin ęrenme Filtre Sayısı	Toplam Model Eęitim Sayısı
Duman ve Erdem [4]	7	481	3
Hemant [16]	7	481	3
Abhiram [37]	Belirtilmemiř	Belirtilmemiř	3
nerilen Algoritma	6	128	1


Derin ęrenme de kullanılan katman ve filtre sayısı bu alıřmada daha azdır. izelge 4.6’ya bakılarak nerilen alıřmanın karmařıklılıęının dięer derin ęrenme kullanan alıřmalara gre daha az olduęu sylenebilir. Aynı zamanda tek bir eęitim gerekleřtirip 3 farklı veri setinde test gerekleřtirmek algoritmanın eęitim verisine olan baęımlılıęın az olduęunun bir gstergesidir.

Alarfaj ve Pervaiz’in [34] alıřmasında nerilen algoritma, n iřleme, insan silueti ıkarımı, insan doęrulama gibi adımları ieren altı temel iřlem katmanından oluřmaktadır. Bu katmanlar arasında, GMM (Gaussian Mixture Model) ve Kalman filtresi gibi yntemler, iřlemci zerindeki yk artıracabilecek nitelikte hesaplama aısından yoęun iřlemler barındırmaktadır.

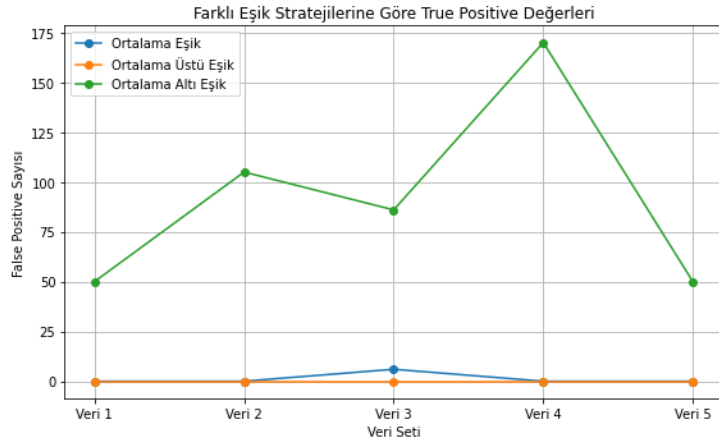
Mehran [36] alıřmasında nerilen saf optik akıř tabanlı yaklařımın hesaplama yk veya algoritmik karmařıklılıęı hakkında detaylı bilgi verilmemiř olup, alıřmada yalnızca yntemin ıktılarına iliřkin nicel sonular sunulmuřtur.

Anomali tespit algoritmasının en kritik noktalarından biri her video sekansı sonunda yeniden hesaplanan eřik deęerinin belirlenmesidir. Eřik deęeri bu alıřmada bir

video sekansı boyunca hesaplanan filtrelenmiş hata değerlerinin ortalaması olarak belirlenmiştir. Bir video sekansında normal olan görüntüler çoğunluktadır. Anomali tanım olarak örüntüyü bozan görüntülere denir ve nadir rastlanılır. Kalabalık ortamlarda bireylerin veya nesnelerin normal hareketleri belirli bir örüntü ve hızda devam eder. Bu yüzden yapay zekânın optik akış haritalarının tahmininde yaptığı hatalar sınırlı aralıkta düşük varyansla seyretmektedir. Dolayısıyla, bu dağılımı en iyi temsil eden ölçütün “ortalama hata değeri” olacağı düşünülmüştür. Farklı test video sekanslarında, değişen eşik değerleri altında elde edilen performans sonuçları, ROC eğrileri biçiminde Şekil 4.20 ve Şekil 4.21’de verilmiştir.



Şekil 4.20: Doğru pozitif roc eğrisi.



Şekil 4.21: Yanlış pozitif roc eğrisi.

Şekil 4.20’de adaptif eşik değeri her test video sekansı için ortalama, ortalamanın üstü ve ortalamanın altı bir değer seçilerek gerçekten anomali olan görüntülerin (doğru pozitif) ne kadar iyi tahmin edebildiğini gösterilmiştir. Grafiğin altında kalan

alan ne kadar büyük ise algoritma ilgili eşik değeri ile o kadar iyi sonuç vermiştir anlamına gelir. Şekil 4.20 incelendiğinde ortalama veya ortalamanın altında bir eşik değeri seçmek performansı arttıracak yönünde yorumlanmıştır.

Anomali, tanımı gereği nadiren gözlemlenen olayları ifade eder. Bu bağlamda, algoritmanın yalnızca doğru şekilde tespit ettiği anomaliler değil, aynı zamanda hatalı biçimde anomali olarak sınıflandırdığı durumların da değerlendirilmesi gerekmektedir. Şekil 4.21 grafiğinde eşik değeri anomalinin altında kaldığı durumda yanlış pozitif sonuçların yüksek olduğu gözlemlenmiştir. Bu algoritmanın sürekli görüntü karelerini anomali olarak işaretlediği anlamına gelmektedir.

Yanlış pozitif sonuçları minimize ederken doğru pozitif sonuçları maksimize eden 'ortalama' hata değeri, diğer eşik değerleri ile kıyaslandığında daha dengeli bir performans gösterdiğinden, her test video sekansında adaptif eşik değeri olarak tercih edilmiştir.

4.4. Gözlemlenen Test Senaryoları

Optik akış yöntemi kullanılarak yerel ve genel anomali tespiti için görüntülerde bulunan piksellerin hareketinin hız ve yön değişimleri hakkında bilgiler elde edilmiştir. Aynı zamanda anomali oluşma sebepleri de incelenmiştir. Hareket, insan ve kalabalıkların davranışlarını anormal bir durum oluşturduğunda doğrudan yansıtır. Aynı zamanda obje tespiti temelli algoritmalar ile bir nesnenin sadece varlığına bakarak anomali olup olmadığına karar vermek yetersiz olabilir. Çünkü nesnenin anomali oluşturup oluşturmama durumu harekete bağlı olarak değişebilir. Bu sebepler dikkate alınarak gözlemlenen test senaryoları: Hareket hızı değişimi, hareket yönü farklılığı, sahneye uygun olmayan nesnenin varlığı ve sahnenin bütününe meydana gelmesi olmak üzere 4 ana başlıkta incelenmiştir. Genel anomali tespitinde görüntü karelerinin bütününde hareket hızı değişimi yaşandığı için ayrı bir test senaryosu olarak incelenmiştir.

4.4.1. Hareket Hızı Etkisi Test Senaryosu

Çalışmada hareket hızı temelli anomalilerin tespiti öncelik olarak belirlenmiştir. Bu yüzden optik akış yöntemi kullanılmıştır. Anomali yaratan varlığın hareket hızı ani olarak değişiyor ve diğer varlıklara göre farklı oluyorsa algoritmanın başarılı

çalışması beklenmiştir. UCSD veri setlerinde hareket hızının ani değiştiği ve bunun sonunda anomali oluşan test videoları gözlemlenmiştir.


UCSD Ped-1 veri setinde Test-4 video sekansının tamamında kaykay ile kalabalık arasında giden insan anomali oluşturmaktadır. Fakat anomali, kalabalık arasında algoritma tarafından tespit edilememiştir. Kalabalık içerisinde çıktuktan sonra tespit gerçekleştirilebilmiştir. Bu durumun sebebi olarak anomalinin kalabalık arasına girdiği zaman hızının düşmesi olarak yorumlanmıştır. Kalabalık arasından çıktıktan sonra tekrar hızını arttırarak yoluna devam etmiştir. Bu durumda optik akış temelli olan algoritma başarılı bir şekilde anomali tespitini gerçekleştirmiştir. Şekil 4.22’de Test-4 video sekansının 87. görüntüsü verilmiştir. Anomali kırmızı çerçeve içerisinde gösterilmiştir. Şekil 4.24 incelendiğinde 87. görüntü de anomali tespitinin yapılamadığı gözlemlenmiştir. Şekil 4.23’te gösterilen 114. Görüntü de ise anomalinin kalabalık arasından çıktığı görülmekte ve yine kırmızı çerçeve ile gösterilmektedir. Bu durumda Şekil 4.22’de incelendiğinde 114. görüntü için anomali tespitinin doğru bir şekilde yapılabildiği görülmüştür.



Şekil 4.22: Ucsd ped-1 test-4 87. görüntü.



Şekil 4.23: Ucsd ped-1 test-4 114. görüntü.



Şekil 4.24: Ucsd ped-1 test-4 verisi grafiği.

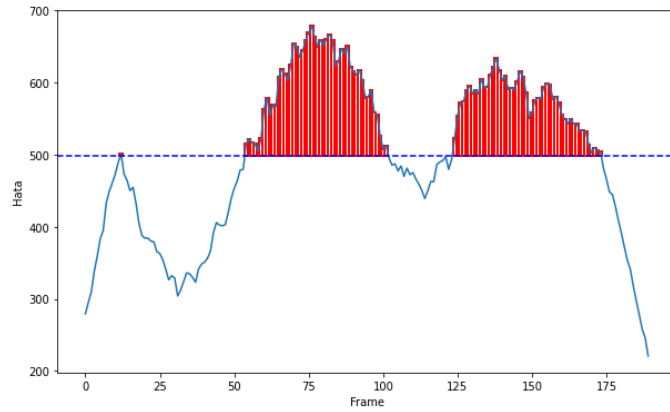
UCSD Ped-1 Test-7 video sekansında 50. görüntüden itibaren kaykaylı insanın sahneye giriş yaptığı gözlemlenmiştir. 115. görüntüden kaykaylı insan kamera açısından tamamen çıkmakta ve hızlı bir şekilde bisiklet süren insan kamera açısına girmektedir. Anomali tespit algoritması her iki anomali yaratan durumu da başarılı şekilde tespit etmiştir. Her iki insanda sahnenin genelindeki ortalama hızdan yüksek hızla hareket ettiği için optik akış temelli algoritma başarılı şekilde çalışmıştır. Şekil 4.25'te kaykaylı insanın kamera açısına giriş yaptığı görüntü, Şekil 4.26'da kaykaylı insanın kamera açısından çıkıp bisikletli insanın kamera açısına girdiği görüntü ve Şekil 4.27'de algoritmanın sonuç grafiği verilmiştir.



Şekil 4.25: Ucsd ped-1 test-7 50. görüntü.



Şekil 4.26: Ucsd ped-1 test-7 150. görüntü.




Şekil 4.27: Ucsd ped-1 test-7 verisi grafiği.

Test-7 video sekansının en başında bir bisikletli insanın gittiği gözlemlenmiştir. Fakat video sekansının ilk görüntüsünden itibaren var olduğu için hız farkı yaratmadığı görülmüştür. Kamera açısından çıktığı görüntü de diğer bisikletli

sahneye giriş yapmıştır. Bu iki sebepten dolayı optik akış temelli algoritma da bu anomali oluşturan bisikletliyi tespit edememiştir. Bu örnek ile optik akış yönteminin bir problemi daha görülmüştür. Eğer video sekanslarının başlangıçlarında hızlı bir şekilde giden anomali yaratan nesnelere varsa bunlar hız değişimi oluşturmayacağı için tespit işlemi zorlaşmaktadır.

UMN veri seti içerisinde genel anomaliler bulunmaktadır. Anomali meydana geldiği anda kalabalık içerisinde bulunan insanlar ani bir şekilde koşmaya başlamaktadır. Bu durumda optik akış hesaplarında elde edilen genlik değerlerinde artışa neden olmuştur. Genlik değerlerinin artmasıyla yapay zekânın elde ettiği optik akış görüntüleri ile gerçek optik akış görüntüleri arasındaki hata artmıştır. Bu da hata grafikleri incelendiğinde anomali meydana geldiği anda yüksek tepelerin olduğu görülmüştür. İnsanların koşması veya yürümesi arasındaki hata değerlerinin farkı hareket hızının anomali tespitinde ne kadar etkili olduğunu göstermiştir. Şekil 4.28'de otoparkta kalabalıkta bulunan insanların yürüdüğü görüntü kareleri siyah, koştukları görüntü kareleri ise mavi çerçeve ile gösterilmiştir.



Şekil 4.28: Umn veri seti klip-11 hareket hızı etkisi.

4.4.2. Nesnenin Varlığı Sebebi ile Olan Anomali Test Senaryosu


Bu çalışmada hareket temelli olmayan, anomali durumlarının performansı düşürdüğü gözlemlenmiştir. UCSD Ped-1 veri setinde Test-26'da kamera açısına hızlı bir şekilde giren bisikletli doğru bir şekilde tespit edilirken yaya ile yürüyen bisikletli hareket hızı fazla olmadığı için tespit edilememiştir. Yaya ile giden bisikletlinin



Şekil 4.30: Ucsd ped-1 test-19 60. görüntü.



Şekil 4.31: Ucsd ped-1 test-19 140. görüntü.



Şekil 4.32: Ucsd ped-1 test-19 verisi grafiği.

4.4.3. Hareket Yönü Kaynaklı Anomali Test Senaryosu

UCSD veri setinde kaykay ile giden insanlar, golf arabası, kamyon gibi anomali oluşturan durumlar hareket hızı temelli oldukları için önerilen optik akışa dayalı algoritma ile başarılı bir şekilde tespit edilebileceği öngörülmüştür. Fakat bu veri setinde “çimlerden yürüme” durumu da anomali olarak değerlendirilmiştir. Bu verilerin anomali olarak değerlendirilmesinin sebebi hareket hızlarının farklı olması değil de hareket yönlerinin diğer verilerden farklı olmasıdır. Optik akışın piksel bazında yön hakkında da bilgi vermesi önerilen algoritmanın bu durumda da başarılı sonuçlar vermesini sağlamıştır.


UCSD Ped-1 veri setinde Test-11’de 120. görüntüden itibaren diğer insanlardan farklı yöne; çimlere doğru yürüyen insan anomali olarak tespit edilmiştir. Kalabalıktan farklı yöne yürüyen insan Şekil 4.33’te, kalabalığın hareket yönünü gösteren görüntü ise Şekil 4.34’te verilmiştir. Test-11 Video sekansına ait sonuçlar Şekil 4.35’te verilmiştir.



Şekil 4.33: Ucsd ped-1 test-11 120. görüntü.



Şekil 4.34: Ucsd ped-1 test-11 68. görüntü.



Şekil 4.35: Ucsd ped-1 test-11 verisi grafiği.


UMN veri seti, genel anomali tespit çalışmaları oluşturulduğu için görüntü karelerinde bireysel olarak insanların hangi yöne doğru yürüdüğü detaylı incelenmemiştir. Aynı zamanda veri seti bu durumu anomali olarak tanımlamamıştır. Fakat 4.3 Bölümü'nde Klip-4 ve Klip-7 verileri için yapılan incelemede kalabalık arasında farklı yönlere doğru yürüyen insanların tespit edilebildiği gözlemlenmiştir.

4.4.4. Görüntünün Tamamında Meydana Gelen Anomali Test Senaryosu

UCSD veri setlerinde meydana gelen bütün anomaliler görüntü karelerinin sadece belirli bölgelerinde meydana gelmiştir. UMN veri setinde ise anomalilerin hepsi görüntünün tamamını etkilemektedir. Bu iki farklı durum hata değerlerinin artış hızlarının farklılığına sebep olmuştur. UCSD test grafiklerinde artış hızı daha

yavaşken UMN test grafiklerinde hata değerlerindeki artış daha ani ve eğiminin yüksek olduğu görülmüştür.

UMN veri seti Klip-5'te insanların koridorda konuştuğu veya yürüdüğü görülmektedir. 420. görüntü karesinden sonra sahnede kalabalıkta bulunan insanların panikle farklı yönlere doğru koşmaya başladığı gözlemlenmiştir. Şekil 4.36 incelendiğinde 420. görüntüden sonra anomali tespitinin başarılı şekilde yapıldığı görülmektedir. Algoritma, 200 ile 400 görüntü karelerinin arasında bulunan bazı görüntülerde anomali yokken anomali tespit etmiştir. Video klibinde ilgili zamanda koridora farklı odalardan insanların yürüyerek girdiği görülmüştür. Bu durum piksel bazında hesaplanan hata değerlerinde artışa sebep olmuştur. İlgili test verisine ait anomali tespit grafiği Şekil 4.36'da verilmiştir.



Şekil 4.36: Umn klip-5 verisi grafiği.

Bu bölümde, 3. Bölümde öne sürülen algoritmanın performansını ölçmek için kullanılan UCSD ve UMN veri setleri anlatılmıştır. Veri setlerinin hangi durumlara anomali olarak tanımladığı ve ne tür anomalileri içerdiği hakkında bilgi verilmiştir. Aynı zamanda neden bu veri setlerinin kullanıldığından bahsedilmiştir. Her iki veri seti için test video sekanslarında elde edilen sonuçların yorumları verilmiştir. Algoritmanın başarısını değerlendirmek için önemli görülen test senaryoları tanıtılmıştır. Bu senaryoların neye göre seçildiği hakkında bilgi verilmiştir. 5. Bölüm 'de yapılan çalışmanın genel değerlendirilmesi gerçekleştirilecektir.


4.4.5. Moving Average Filtresinde Pencere Boyutunun Deęiştirilmesi

Bir video sekansı boyunca hesaplanan hata deęerlerinden oluřan grafik 3.4 Bölümü'nde anlatılan moving average filtresine girdi olarak verilmiřtir. Moving average filtresinde pencere boyutu, bir sinyalde her bir noktanın deęerini hesaplamak için dikkate alınan ardışık veri noktalarının sayısını belirtir. Matematiksel gösterimi Denklem 4.5'te ifade edilmiřtir.

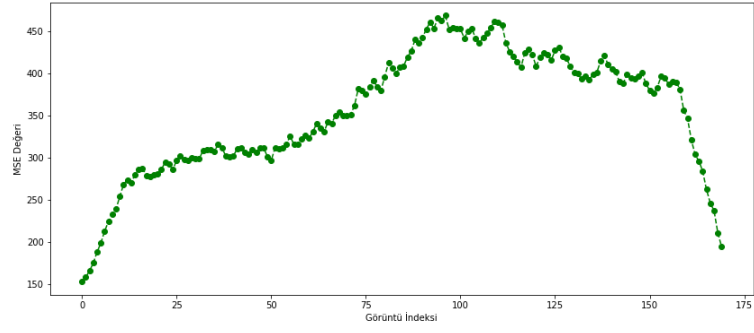
$$y[n] = \frac{1}{w} \sum_{k=0}^{w-1} x[n - k] \quad (4.5)$$

$x[n]$ Filtrelenmemiř hata deęerlerini, w pencere boyutunu, $y[n]$ ise filtrelenmiř sinyali temsil eder.


Filtrenin pencere boyutu hata deęerlerinin üzerindeki dalgalanmaların ne ölçüde bastırılacağını belirleyen önemli bir parametredir. Küçük pencere boyutu ani deęişimlere olan duyarlılığı artırır. Büyük pencere boyutu ise gürültüyü azaltır. Aynı zamanda filtreleme işleminin süresini de etkiler. Pencere boyutu büyürken filtreleme süresi de artar. Farklı pencere boyutları ile oluřturulan filtreler hata deęerlerinden oluřan grafikler üzerinde denenerek optimum pencere boyutu bulunması hedeflenmiřtir. UCSD Ped-2 Test-1 ve UMN Klip-1 verileri için pencere boyutu 12, 24 ve 40 olan filtrelenmiř grafikler Őekil 4.37, Őekil 4.38, Őekil 4.39, Őekil 4.40, Őekil 4.41 ve Őekil 4.42'de verilmiř ve sonuçları incelenmiřtir.




Őekil 4.37: Ucsd ped-2 test-1 pencere boyutu 12.




Şekil 4.38: Ucsd ped-2 test-1 pencere boyutu 24.




Şekil 4.39: Ucsd ped-2 test-1 pencere boyutu 40.



Şekil 4.40: Umn klip-1 verisi pencere boyutu 12.



Şekil 4.41: Umn klip-1 verisi pencere boyutu 24.



Şekil 4.42 Umn klip-1 verisi pencere boyutu 40.

Pencere boyutunun 12 olması durumunda ardışık gelen frame'ler arasında hata değerlerinin dalgalı olduğu görülmüştür. 24 yapıldığında dalgalı sonuçların önemli oranda azaldığı gözlemlenmiştir. 40 olması durumunda 24'e göre dalgalıların biraz daha azaldığı görülmüştür. Pencere boyutunun gereğinden büyük olması ani değişimlerin yakalanamamasına sebep olacaktır. Şekil 4.39'da Şekil 4.38'e göre ve Şekil 4.42'de Şekil 4.41'e göre ardışık gelen optik akış değerlerinin değişimi daha az yakalanabilmiştir. Bu durum algoritmanın anomali tespitini de yavaşlatacak anomali meydana geldiğinde daha geç tepki vermesine sebep olacaktır. UCSD Ped2 Test-2 verisi için yapılan gözlemler UMN veri setinde Klip-1'de de benzerdir. 3 farklı pencere boyutu için filtreleme işleminin süreleri Çizelge 4.7'de verilmiştir.

Çizelge 4.7: Moving average filtrelemede pencere boyutunun süreye etkisi.

Pencere Boyutu	UCSD Ped-2 Test-1	UMN Klip-1
12	0.305 sn	0.278 sn
24	0.274 sn	0.275 sn
40	0.287 sn	0.272 sn

Çizelge 4.7'de UCSD Ped-2 Test-1 ve UMN Klip-1 video sekansları için filtreleme işlemlerinin süreleri verilmiştir. Pencere boyutunun değişmesinin filtreleme işleminin süresine etkisi ihmal edilebilir durumda olduğu görülmüştür. Farklı pencere boyutlarının iki video sekansı için algoritma performansına etkileri Çizelge 4.8 ve Çizelge 4.9'da verilmiştir.

Çizelge 4.8: Ucsd ped-2 test-1 farklı pencere boyutunun performansa etkisi.

Pencere Boyutu	Anomali Yokken Var Denilen
12	%8.57
24	%0
40	%0


Çizelge 4.9: Umn klip-1 farklı pencere boyutunun performansa etkisi.

Pencere Boyutu	Anomali Yokken Var Denilen
12	%6.79
24	%0
40	%0


Pencere boyutunun 12 seçilmesi filtreleme sonucunda gözlemlenen ani dalgalanmaların bazı görüntü karelerinde anomali olmamasına rağmen algoritmanın anomali kararı vermesine sebep olarak performansı düşürdüğü görülmüştür. 40 yapılması ise 24'e göre performansı arttırmadığı için filtreleme işleminde pencere boyutu 24 olarak seçilmiştir.

4.4.6. Derin Öğrenmeye Verilen Frame Sayısının Değiştirilmesi


Bu çalışmada bir görüntü için anomali kararı kendinden önce gelen kısa süreli gözlemler kullanılarak verilmiştir. Gözlem sayısının fazla olması derin öğrenmede işlem yükünü arttıracakken gereğinden az olması yapay zekânın bağlamsal bilgiyi öğrenememesine sebep olabilir. Bu durumda optimum değer belirlenmesi gerekmektedir. Kısa süreli gözlem süresinde kullanılan frame sayısı değiştirilerek grafikler kıyaslanmıştır. Sonuçlar Şekil 4.43, Şekil 4.44, Şekil 4.45 ve Şekil 4.46'da verilmiştir.




Şekil 4.43: Ucsd ped-2 test-4 frame sayısı 10.



Şekil 4.44: Ucsd ped-2 test-4 frame sayısı 20.



Şekil 4.45: Ucsd ped-2 test-8 frame sayısı 10.



Şekil 4.46: Ucscd ped-2 test-8 frame sayısı 20.

UCSD Ped-2 Test-8 ve Test-4 video sekanslarında frame sayısı hem 10 hem de 20 yapılarak performansın nasıl değiştiği incelenmiştir. Frame sayısının artması performansı yükseltmediği Şekil 4.43, Şekil 4.44, Şekil 4.45 ve Şekil 4.46’da verilen grafiklerde gözlemlenmiştir. Frame sayısının değişmesi, tespit edilemeyen anomali bulunduran frame sayısında bir değişiklik oluşturmamıştır. Bu durumda derin öğrenme modelinin görüntü kareleri arasındaki hareket dinamiklerinin bağlamını 10 frame’de öğrenebildiği görülmüştür. Her hareket dinamiğinin bağlamı daha düşük görüntü karesi ile ortaya çıkamayacağı ve benzer çalışmalarda da 8–16 karelik giriş pencerelerinin kullanıldığı [4] görüldüğü için frame sayısı 10 olarak belirlenmiştir.

4.4.7. Düşük FPS ile İnceleme

Algoritmanın düşük fps ile anomali tespitini yapabiliyor olması daha az veri kullanımı ve dolayısıyla daha düşük işlemci maliyeti ile sonuç üretilebileceğini göstermektedir. Bu durum, gerçek zamanlı çalışmayı hedefleyen sistemler için önemlidir. Bu nedenle fps değeri düşürülerek performansın nasıl değişeceği incelenmiştir. Elde edilen sonuçlar Çizelge 4.10 ve Çizelge 4.11’de gösterilmiştir.

Çizelge 4.10: Ucsd ped-2 test-1 fps analiz sonuçları.

Fps Değeri	Anomali Yokken Var Denilen
10	%0
5	%0
2.5	%13.3

Çizelge 4.11: Umn klip-1 fps analiz sonuçları.


Fps Değeri	Anomali Varken Yok Denilen
30	%0
15	%0
7.5	%3.57

UCSD veri seti 10, UMN veri seti ise 30 fps'lik görüntülerden oluşturulmuştur. Her iki veri setinde birer örnek video sekansı kullanılarak fps değeri yarıya ve 4'te 1'ine düşürülerek sonuçlar analiz edilmiştir. Fps değerinin yarıya düşmesi iki video sekansı içinde algoritmanın performansını etkilememiştir. Fakat 4'te 1'ine düşürüldüğünde performansın azaldığı görülmüştür. Fps değeri görüntü kareleri arasındaki zamansal bağlamın anlaşılması açısından önemlidir: Düşük olması bazı video sekanslarında bu bağlamın anlaşılması için yeterli olabilir. Fakat belirli bir değerden sonra bu bağlam anlaşılmasına başlar. İki veri setinde de algoritma fps'in 4'te 1'ine düşürüldüğü durumda görüntü kareleri arasındaki zamansal bağlamı tespit etmekte zorlanmıştır. Bu durumda yanlış karar verme olasılığı artmış ve hatalar meydana gelmiştir. Algoritmanın ilerleyen çalışmalarda farklı veri setlerinde kullanabileceği ve gerçek zamanlı çalışma hedefi bulunması sebepleri göz önünde bulundurularak video sekansları fps değerleri değiştirilmemiştir.


4.4.8. Anomali Bulunmayan Video Sekanslarının İncelenmesi

Bu çalışmada anomali bulunan görüntü karelerinde, algoritmanın tahmin ettiği optik akış haritaları ile gerçek optik akış haritaları arasındaki farkın, hatanın, daha fazla olacağı ileri sürülmüştür. Hiç anomali bulundurmeyen video sekanslarında topluluğun ortalama sabit bir hızla ve belirli bir örüntü ile hareket etmesi beklenir. Bu durumda algoritma gerçek optik akış görüntülerine yakın hata değeri daha düşük sonuçlar üretecektir. UCSD Ped-2 Eğitim-2 ve UCSD Ped-2 Eğitim-3 video

sekansları için algoritma çalıştırılmış elde edilen sonuçlar Şekil 4.47 ve Şekil 4.48’de verilmiştir.



Şekil 4.47: Ucsd ped-2 eğitim-2.



Şekil 4.48: Ucsd ped-2 eğitim-3.

UCSD Ped-2 Eğitim-2 ve UCSD Ped-2 Eğitim-3 video sekanslarının hiçbir karesinde anomali bulunmamaktadır. Fakat buna rağmen bazı görüntü kareleri için hesaplanan hata değerlerinin ortalamanın üzerinde kaldığı görülmüştür. Anomali bulunduran video sekansları ile hiç anomali bulundurmayan video sekanslarında adaptif eşik değerinin üzerinde kalan hata değerlerinin ortalamadan ne kadar saptığı kıyaslanmıştır. Elde edilen sonuçlar Çizelge 4.12’de verilmiştir.

Çizelge 4.12: Hata değerlerinin kıyaslanması.

Hata Değeri	Maksimum	Ortalama
UCSD Ped-2 Test-2	680	550
UCSD Ped-1 Test-27	2400	1650
UCSD Ped-2 Test-4	1200	810
UCSD Ped-2 Eğitim-2	350	345
UCSD Ped-2 Eğitim-3	440	420
UCS Ped-2 Eğitim-16	360	355

Çizelge 4.12 incelendiğinde, hiç anomali bulundurmeyen video sekanslarında hata değerlerinin daha düşük olduğu görülmüştür. Aynı zamanda gözlemlenen maksimum hata değerleri de anomali bulunduran video sekanslarına göre önemli oranda daha düşük olduğu gözlemlenmiştir.

Hiç anomali bulundurmeyen video sekanslarında topluluk belirli bir örüntü ve sabit bir hızla hareket ettiği için hata değerlerinin ortalamaya, eşik değere, yakın olması beklenmiştir. Bununla birlikte hata değerlerinin anomali bulunduran video sekanslarına göre önemli oranla düşük olması algoritmanın bu ayrımı başarılı bir şekilde yapabildiğini göstermiştir. İlerleyen çalışmalarda algoritmanın karar verme mekanizmasında sadece eşik değeri dikkate almasındansa hata değerlerini de göz önünde bulundurmasını sağlayacak geliştirmeler yapılabilir.


4.4.9. Adaptif Eşik Değerinin Farklı Periyotlar ile Değiştirilmesi

Eşik değerinin değiştiği görüntü karelerinde algoritmanın nasıl bir karar verdiği, özellikle karar sınırının yeniden belirlendiği bu geçiş anlarında sistemin kararlılığı ve duyarlılığı açısından kritik bir öneme sahiptir. Farklı periyotlar ile eşik değeri güncellenerek algoritmanın performansı incelenmiştir.

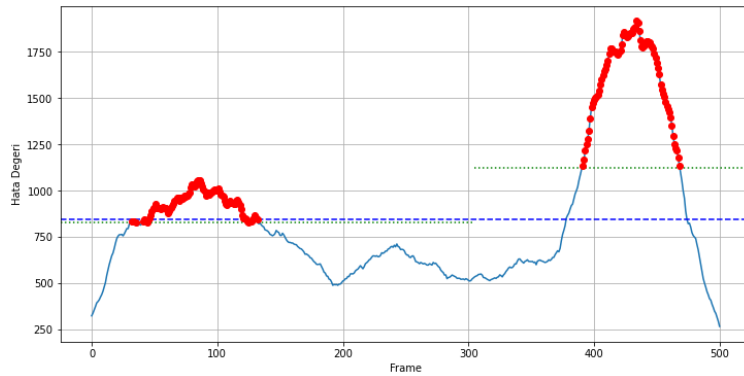
Bu çalışmada adaptif eşik değeri, her test video sekansının sonunda belirlenmiştir. Örneğin: 600 görüntü karesinden oluşan bir video sekansında eşik değeri, tüm sekans

tamamlandıktan sonra hesaplanmış ardından anomali karar mekanizması işletilmiştir. Alternatif olarak, aynı sekansın ortasında (300. görüntü karesinde) eşik değeri güncellenmiş ve ardından ikinci yarının sonunda yeniden hesaplanarak karar verme süreci bu güncel değer üzerinden gerçekleştirilmiştir. Bu iki farklı yöntem ile eşik değerinin belirlenme sıklığının ve konumunun sistem performansına etkisi karşılaştırmalı olarak incelenmiştir.

UMN veri setinde Klip-1 ve Klip-6 video sekanslarında eşik değerler farklı periyotlar ile güncellenip algoritmanın performansı incelenmiştir. Elde edilen sonuçlar Şekil 4.49 ve Şekil 4.50’de verilmiştir.



Şekil 4.49: Umn veri seti klip-1 eşik değeri grafiği.




Şekil 4.50: Umn veri seti klip-6 eşik değeri grafiği.

Şekil 4.49 ve Şekil 4.50’de x eksenini frame numaralarını y eksenini ise hata değerlerini temsil etmektedir. Grafikler üzerinde yer alan mavi çizgi, bir video sekansı boyunca elde edilen tüm hata değerlerinin ortalaması alınarak hesaplanan eşik değerini temsil

etmektedir. İlk yeşil çizgi video sekansının ilk yarısındaki hata değerlerinin ortalamasına, ikinci yeşil çizgi ise ikinci yarısındaki hata değerlerinin ortalamasına karşılık gelmektedir. Grafikler üzerinde kırmızı ile gösterilen çizgiler, yeşil eşik çizgilerine göre eşik değerin üzerinde kalan ve anomali olarak sınıflandırılan görüntü karelerini ifade etmektedir. Anomali bulunmayan video sekanslarının ilk yarısında hesaplanan hata değerlerinin, çoğunlukla eşik değerine yakın dağıldığı ve yalnızca düşük genlikli sapmalar gösterdiği tespit edilmiştir. Anomali bulunan ikinci kısımda ise anomalinin oluşmaya başladığı kısımdan itibaren hata değerleri artış göstermiş ve ortalamanın yükselmesine sebep olmuştur. Bölüm 4.4.8’de anlatıldığı gibi hiç anomali bulunmayan video sekanslarında, video sekansının ilk periyotlarında, yapay zekanın yaptığı hata değerlerinin anomali bulunan video sekanslarına göre, video sekansının ikinci periyotlarında, daha düşük olduğu gözlemlenmiştir.

UCSD Ped-2 Test-2 video sekansı için eşik değerler farklı periyotlar ile güncellenip elde edilen sonuçlar Şekil 4.51’de verilmiştir.



Şekil 4.51: Ucsd ped-2 test-2 farklı eşik değerleri.

Şekil 4.51’de 90 frame’de bir güncellenen eşik değerleri yeşil, 180 frame sonunda belirlenen eşik değeri mavi çizgi ile gösterilmiştir. Grafikte kırmızı çizgiler ile işaretlenen görüntüler yeşil eşik çizgilerine göre videolar da anomalinin bulunduğu bölümlerdir. Test video sekansının ilk yarısında, anomali bulunmamasına rağmen yeşil çizgi ile belirlenen eşik değerin üzerinde olan hata değerlerine sahip frame’ler anomali olarak işaretlenmiştir. Video sekansının ikinci yarısı için hesaplanan yeşil eşik çizgisinin üstünde bulunan hata değerlerini oluşturan frame’ler doğru bir şekilde anomali etiketi ile işaretlenmiştir. Anomali bulunmayan video sekansının ilk yarısında hesaplanan hata değerlerinin, çoğunlukla eşik değerine yakın dağıldığı ve

yalnızca düşük genlikli sapmalar gösterdiği tespit edilmiştir. Anomali bulunan ikinci kısımda ise anomalinin oluşmaya başladığı kısımdan itibaren hata değerleri artış göstermiş ve ortalamanın yükselmesine sebep olmuştur. İkinci kısımda anomalinin varlığı, eşik değerden sapmayı ve hata değerlerini önemli oranda arttırdığı gözlemlenmiştir.

3 farklı video sekansı için farklı eşik değerleri ile yapılan çalışmaların sonuçları Çizelge 4.13 ve Çizelge 4.14'te verilmiştir.

Çizelge 4.13: Sekans sonu eşik değeri ile performans analizi.

Algoritma Kararı	UMN Veri Seti Klip-1	UMN Veri Seti Klip-6	UCSD Ped-2 Veri Seti Test-2
Anomali Varken Yok Denilen	%0	%0	%0
Anomali Yokken Var Denilen	%0	%14.50	%8.33

Çizelge 4.14: Sekans ortasında eşik güncelleme performans analizi.

Algoritma Kararı	UMN Veri Seti Klip-1	UMN Veri Seti Klip-6	UCSD Ped-2 Veri Seti Test-2
Anomali Varken Yok Denilen	%0.83	%5.88	%0
Anomali Yokken Var Denilen	%25.87	%19.60	%23.88

Çizelge 4.13 ve Çizelge 4.14 incelendiğinde eşik değerinin bir video sekansı sonunda belirlenmesinin performansı arttırdığı görülmüştür. Eşik değerin video sekansının yarısında güncellenmesiyle performansının düşmesinin sebebi algoritmanın hiç anomali bulunmayan video sekanslarında sadece eşik değere bakarak karar vermesi olduğu düşünülmüştür. Halbuki hiç anomali bulunmayan video sekanslarında hata değerleri anomali bulunan video sekanslarına göre düşüktür. 4.4.8 Bölümü'nde bahsedildiği gibi ilerleyen çalışmalarda algoritmanın sadece eşik değere bakarak karar vermesinden hata değerlerini de dikkat almasını sağlayacak geliştirmeler yapılabilir.

5. GENEL SONUÇLAR

Bu çalışmanın ilk aşamasında literatür araştırması sonucu kullanılacak açık kaynak veri setleri belirlenmiştir. Veri seti seçiminde, anomali durumlarının doğal bir şekilde meydana gelmesine dikkat edilmiştir. Aynı zamanda yapılan çalışmada hem yerel hem de global anomalilerin tespit edilebilmesi hedeflendiği için veri seti içerisinde global anomalilerin olmasına da dikkat edilmiştir. Verilerin nasıl elde edildiği, hangi durumların anomali olarak tanımlandığı incelenmiştir. Video sekanslarında meydana gelen anomalilerin tespiti için literatürde kullanılan yöntemler araştırılmış ve yapılan çalışmalar incelenmiştir. Yaygın kullanım olarak hareket temelli anomali tespitlerinde “optik akış” yönteminin kullanıldığı görülmüştür. Farklı optik akış algoritmaları incelenmiş ve önerilecek algoritmanın gerçek zamanlı çalışabilme durumu da göz önünde bulundurularak Farneback optik akış yöntemi kullanılmıştır. Optik akış hesabının matematiksel olarak daha kolay yapılabilmesi amacıyla 3.1 Bölümü’nde anlatılan veri ön işleme adımları uygulanmıştır.

Her test video sekansında bulunan görüntülerin anomali tespiti için otokodlayıcı derin öğrenme modeli kullanılmıştır. Anomali tespiti gerçekleştirilecek görüntüden önce gelen kısa süreli gözleme ait optik akış haritaları derin öğrenme modeline girdi olarak verilmiştir. Yapay zekâ ilgili görüntünün optik akış haritasını oluşturmuştur. Anomali tespiti yapılacak görüntünün gerçek optik akış haritası ile yapay zekânın ürettiği optik akış haritası arasındaki ortalama karesel hata piksel bazında hesaplanmıştır. Her test video sekansındaki görüntüler için bu işlemler yapılmış ve o video sekansının adaptif eşik görüntülerin hata değerlerinin ortalaması olarak belirlenmiştir. Eğer ilgili görüntü için hesaplanan hata değeri video sekansı için bulunan adaptif eşik değerinden büyük ise anomalinin var olduğuna karar verilmiştir.

Bir görüntü karesi için algoritma adımlarının 1.12 saniye sürdüğü ölçülmüştür. Bir görüntünün anomali olarak değerlendirilmesi için belirli sayıda görüntü karesi de kullanıldığından, bu çalışmada bir test video sekansı kadar UCSD için ortalama 200 UMN için ortalama 500 frame, anomali kararı gecikmeli olarak verilmektedir. Herhangi bir t . Görüntü karesinin anomali bulundurma durumuna karar vermek için kullanılan görüntü sayısı ne kadar az ise sistemin gerçek zamanlı çalışabilme özelliği de o kadar iyidir. Bu durum veri setlerinin fps değerlerinin düşük olduğu için güvenilir bir şekilde ölçülememiştir. Çünkü ardışık gelen görüntü kareleri arasındaki

zaman farkı fazla olduğu için algoritmanın başarı oranı düşmektedir. Bir görüntünün içerisinde anomali bulundurma kararının verilmesi için gereken görüntü sayısı, Kullanılan veri setlerinde fps düşük olduğu için azaltılmamış ve azaltıldığı durumda da performansın düştüğü görülmüştür. Fps'in yüksek olduğu durumda ardışık gelen görüntü kareleri arasındaki zaman farkı gerçeğe daha yakın olacağı için optik akış hesapları daha doğru ve güvenilir sonuçlar verecektir. Aynı zamanda bir görüntünün içerisinde anomali bulundurma kararının verilebilmesi için gereken görüntü sayısı da düşürülüp karar verme süresi kısaltılabilecektir.

UCSD veri setinde her test video sekansında ortalama 200 görüntü karesi mevcuttur. Örnekleme hızı 10 fps olarak değerlendirildiğinde 20 saniye süren video kayıtları mevcuttur. Her bir görüntü için anomali varlığı kararı, bir test video sekansının ardından verildiği için 200 saniyelik gecikmeyle verilmiştir. Bu gecikme bazı kullanım senaryoları için kabul edilebilirken bazı durumlar için kabul edilemez olabilir. Fps değerinin daha yüksek olduğu veri setlerinde “anomali karar verme periyodu” düşürülerek gecikme süresi azaltılabilir.

UMN veri setinde ise her test video klibinde ortalama 500 görüntü karesi mevcuttur. Örnekleme hızı 30 fps'dir. Video klipleri ortalama 20 saniyeden oluşmaktadır. Bir görüntü karesi için algoritmanın karar verme süresi UCSD veri seti ile aynıdır. Bu durumda UMN veri setinde anomali tespiti için karar verme durumu bir klip için 500 saniye sürmektedir. Anomali tanımı ve fark edilmesi için beklenebilecek süre farklı uygulamalarda değişebileceği için bu gecikmeler bazı durumlar için kabul edilebilirken bazıları için kabul edilemeyecek seviyededir.

Bu tez kapsamında, literatürde gerçekleştirilen çalışmalardan farklı olarak anomali eşik değeri tek bir eğitim gerçekleştirilip bütün test verileri üzerinde değişmeden kullanılmamıştır. Her test verisi için kendisinden önce gelen kısa süreli gözlemler ile eğitim gerçekleştirilip belirli periyotlarla (bir test video klibi) eşik değeri güncellenmiştir. Bu yöntem ile algoritmanın eğitim verisine olan bağımlılığı azaltılmıştır.

Her görüntü karesi için eğitim gerçekleştirmek sisteme ciddi derecede gecikme getirdiği gözlemlenmiştir. Bu da bazı anomali senaryolarında kabul edilebilecek düzeyde olmadığı düşünülmüştür. Algoritmanın hiçbir parametresi değiştirilmeden

iki veri setinde de başarılı sonuç vermesi eğitim verisine olan bağımlılığın azaldığını göstermektedir.

Çizelge 4.5 incelendiğinde algoritmanın UMN veri setinde daha başarılı çalıştığı gözlemlenmiştir. Bu durumun sebebi: UMN veri setinde bulunan anomalilerin genel anomali olmasıdır. Genel anomaliler görüntünün birçok pikselinde optik akış genlik değerinin artmasına sebep olup hata değerini ani şekilde yüksek eğimle artışına sağlamıştır. Oysaki UCSD veri setinde anomali, görüntü karesinin sınırlı bir kısmında meydana geldiği için hata değerlerindeki artışın eğimi daha düşük olduğu görülmüştür. Ani yüksek eğimli artış eşik değerini çok hızlı bir şekilde geçip algoritmanın başarı oranını arttırmıştır. UMN veri setinin başarılı olmasının bir başka sebebi ise kalabalığın hareketinin birbirine çok benzer olmasıdır. Bu birbirine benzerlik anomali gerçekleştiği anda ortadan kalkınca hata değerlerinde ciddi artışa sebep olan bir başka etmendir. Fakat UCSD veri setinde çevrede birbirinden bağımsız birçok insan topluluğu farklı aktiviteler gerçekleştirdiği için hata değerlerindeki artış anomali kaynaklı olmayıp algoritmanın performansının düşmesine sebep olmuştur.

6. GELECEK ÇALIŞMALAR

Bu çalışmanın literatüre katkıları olarak gerçek zamanlı çalışabilen ve eğitim verisine bağıllığı azaltan bir algoritma ortaya koyması olarak belirlenmiştir.

UCSD ve UMN veri setlerinin örnekleme değeri düşüktür. UCSD veri seti bilgilendirme dokümanında video fps değeri 10 olarak belirtilmiştir. UMN veri setinde ise 30 fps'dir. Gerçek zamanlı çalışabilme özelliğinin daha güvenilir bir şekilde çalıştığını gösterebilmek için fps oranının daha yüksek olduğu veri setleri kullanılarak performans ölçülebilir. Aynı zamanda Otokodlayıcı derin öğrenme modelini geliştirmek (katman sayısının artırılması, nöron sayısının artırılması, transfer öğrenmesi vs.) geliştirilen algoritmanın performansını arttıracak unsurlar olarak gelecek çalışmalarda denenebilir. Hâlihazırda elde edilen sonuçlarda anomali tespiti gerçek zamanlı bir şekilde yapılamamıştır. Her test görüntüsü için eğitim yapılması ve periyodik olarak filtreleme işlemi gecikmeyi arttıran unsurlar olduğu görülmüştür. Filtreleme işleminin daha hızlı yapılması için farklı filtrelerin denenmesi veya pencere boyutunun değiştirilmesi gelecekte yapılabilecek çalışmalar arasında olabilir.

Kullanılan 2 veri setinde de algortmada kullanılan bütün parametreler aynıdır. Her iki veri setinde de bulunan anomali tiplerinde farklılıklar mevcuttur. Algoritmanın veri setine olan bağıllığı azaldığı bu şekilde gözlemlenmiştir. Fakat daha güvenilir sonuçlar elde edilmesi açısından veri seti sayısı artırılabilir. Algoritmayı gürültülü verilere karşı daha dayanıklı hale getirmek için optik akış yöntemi özelleştirilebilir.

Günlük hayatta karşılaşılan bütün anomaliler hız değişimi ve yön farklılığı üzerine değildir. Toplum içerisinde kullanılması yasak olan nesnelerin varlığı veya toplumu paniğe sürükleyecek farklı unsurlar da anomali olarak tanımlanır. Bir insanın elinde silah ile gezmesi, toplu alanlarda bir kişinin sağlık sorunu yaşaması, bir doğal afetin meydana gelmesi örnek olarak gösterilebilir. Yapılan çalışmanın bu gibi anomalilerin tespitinde yetersiz kaldığı görülmüştür. YOLO gibi nesne tespit algoritmalarının entegre edilmesi ile çalışmanın farklı tipte anomalileri tespit edebilmesi sağlanabilir.

KAYNAKLAR

- [1] Yasin A., Tahir S., Frnda J., Fatima R., Khan J., Anwar M., (2023), “Anomaly prediction over human crowded scenes via associate-Based data mining and k-ary tree hashing”, International Journal of Intelligent Systems, 2023 (1).
- [2] Sampath D., Kumar K., (2023), “Abnormal crowd behaviour detection in surveillance videos using spatiotemporal inter-fused autoencoder”, International Journal of Intelligent Systems, 16, 470–481.
- [3] Xu F., Wang N., Zhao X., (2023), “Exploring global and local information for anomaly detection with normal samples”, IEEE International Conference on Systems, 3422-3427, Honolulu, Oahu, HI, USA, 01-04 October.
- [4] Duman E., Erdem O., (2019), “Anomaly detection in videos using optical flow and convolutional autoencoder”, IEEE Access, 7, 183914–183923.
- [5] Yılmaz E., (2022) “Makine Öğrenmesi Tabanlı Kullanıcı Davranış Analizi İle Bilgisayar Sistemlerine Giriş Kayıtlarında Anomali Tespiti”, Yüksek Lisans Tezi, Ege Üniversitesi.
- [6] Pitchandi P., Sadu V., Kalaiipoonguzhali V., (2025), “A novel video anomaly detection using hybrid sand cat swarm optimization”, Visual Communication and Image Representation, 108.
- [7] Altowairqi S., Luo S., Greer P., (2023), “A review of the recent progress on crowd anomaly detection”, International Journal of Advanced Computer Science and Applications, 14, 659–669.
- [8] Nie L., Zhao L., Li K., (2020), “Glad: global and local anomaly detection”, International Conference on Multimedia and Expo, 1-6, London, United Kingdom, 6-10 July.
- [9] Direkoglu C., (2020), “Abnormal crowd behavior detection using motion information images and convolutional neural networks”, IEEE Access, 8, 80408–80416.
- [10] Liu W., Luo W., Lian D., Gao S., (2018), “Future frame prediction for anomaly detection – a new baseline”, Conference on Computer Vision and Pattern Recognition, 6539-6545, Lake City, Utah, USA, 18-22 June.
- [11] https://en.wikipedia.org/wiki/Receiver_operating_characteristic
Erişim Tarihi: 05.05.2021.
- [12] Serbe S., Ruocco M., (2024), “Navigating the metric maze: a taxonomy of evaluation metrics for anomaly detection in time series”, Data Mining and Knowledge Discovery, 38, 1027–1068.

- [13] Will Koehrsen, <https://builtin.com/data-science/precision-and-recall>
Erişim Tarihi: 10.05.2025.
- [14] Wang T., Miao Z., Yuxin C., Yi Z., Shan G., Snoussi H., (2019), “Aed-net: an abnormal event detection network”, *IEEE Access*, 5, 930–939.
- [15] Bansod S. D., Nandedkar A. V., (2019), “Crowd anomaly detection and localization using histogram of magnitude and momentum”, *The Visual Computer*, 36, 609–620.
- [16] Dhole H., Sutaone M., Vyas V., (2019), “Anomaly detection using convolutional spatiotemporal autoencoder”, 10th International Conference on Computing, Communication and Networking Technologies, 1719-1730, Kanpur, Uttar Pradesh, Hindistan, 6-8 July.
- [17] Yang Kaizhi, Yilmaz Alper, (2024), “Crowd scene anomaly detection in online videos”, *The Role of Photogrammetry for a Sustainable World*, 443-448, Las Vegas, Nevada, USA, 11-14 June.
- [18] Doshi Keval, Yilmaz Yasin, (2020), “Continual learning for anomaly detection in surveillance videos”, *Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*, 254-255, Seattle, Washington, USA, 14-19 June.
- [19] Li N., Chang F., (2019), “Video anomaly detection and localization via multivariate Gaussian”, *Neurocomputing*, 369, 92–105.
- [20] Babu K., Shannon J., Tanmay T., (2024), “Abnormal event detection using convolutional lstm”, *World Conference on Applied Intelligence and Computing*, 7-12, Gwalior, India, 27-28 July.
- [21] Rathika S., Minhas D., (2024), “Spatio-temporal motion pattern analysis for anomaly recognition in crowded sections using kernel svm”, *International Conference on ICT in Business Industry & Government*, Indore, India, 13-14 December.
- [22] Bansod S. D., Nandedkar A. V., (2019), “Transfer learning for video anomaly detection”, *Journal of Intelligent & Fuzzy Systems*, 36 (3), 1967–1975.
- [23] Tokta A., (2016) “Abnormal behavior detection in surveillance systems”, 24th Signal Processing and Communication Application Conference, Zonguldak, Turkey, 16-19 May.
- [24] Ilg E., Mayer N., Saikia T., (2017) “FlowNet 2.0: evolution of optical flow estimation with deep networks”, *IEEE Conference on Computer Vision and Pattern Recognition*, 1647-1655, Honolulu, HI, USA, 21-26 July.
- [25] Sun D., Yang X., Liu M., (2018), “PWC-Net: CNNs for optical flow using pyramid, warping, and cost volume”, *Computer Vision and Pattern Recognition*, 8934–8943.

- [26] Farnebäck G. (2003), “Two-frame motion estimation based on polynomial expansion”, Scandinavian Conference on Image Analysis, 363-370, Berlin, Germany, June 29 – July 2.
- [27] Nemade N., Gohokar V., (2019) “Comparative performance analysis of optical flow algorithms for anomaly detection measurement”, Proceedings of International Conference on Communication and Information Processing , Chongqing, China, 15-17 November.
- [28] NabiyeV, V, (2016), “Yapay Zekâ”, 5th Edition, Seçkin Yayıncılık San. ve Tic. A.Ş..
- [29] Sharma, S, <https://www.datasciencecentral.com/profiles/blogs/artificial-neural-network-ann-in-machine-learning>.
Erişim Tarihi: 24.12.2024
- [30] <https://www.geeksforgeeks.org/activation-functions-neural-networks/>.
Erişim Tarihi: 10.05.2024
- [31] Ergin T., <https://medium.com/@tuncerergin/convolutional-neural-network-convnet-yada-cnn-nedir-nasil-calisir-97a0f5d34cad>.
Erişim Tarihi: 30.11.2023
- [32] <http://www.svcl.ucsd.edu/projects/anomaly/dataset.html>.
Erişim Tarihi: 15.07.2025
- [33] https://mha.cs.umn.edu/proj_events.shtml#crowd.
Erişim Tarihi: 15.07.2025
- [34] Alarfaj M., Pervaiz M., (2023), “Automatic anomaly monitoring in public surveillance areas”, Intelligent Automation & Soft Computing, 35, 2656–2671.
- [35] I. Akhter, A. Jalal and K. Kim, (2021), “Pose estimation and detection for event recognition using sense-aware features and adaboost classifier”, International Bhurban Conference on Applied Sciences and Technologies, 500 – 505, Islamabad, Pakistan, 12-16 January.
- [36] Mehran R., Oyama A., Shah M., (2009), “Abnormal crowd behavior detection using social force model”, Conference on Computer Vision and Pattern Recognition, 935-942, Miami, USA, 20-25 June.
- [37] Abhiram G., Nitheesha M., (2024), “An advanced autoencoder-based approach to anomaly detection for video surveillance systems”, International Conference on Innovative Computing, Intelligent Communication and Smart Electrical Systems (ICSES), 1-7, Chennai, India, 12-13 December.

ÖZGEÇMİŞ

Ömer CEBECİ Mustafa Saffet Anadolu Lisesi'nden 2017 yılında mezun olup lisans eğitimini Gebze Teknik Üniversitesi Elektronik Mühendisliği Bölümü'nde tamamlamıştır. 2023 yılından beri ERA Haberleşme Teknolojileri şirketinde gömülü yazılım mühendisi olarak çalışmaktadır.



TEZ ÇALIŞMASI KAPSAMINDA YAPILAN YAYINLAR

Cebeci Ö., Hoccoğlu K., (2024) “Kalabalık Ortamlarda Anomali Tespiti”, National Conference on Electrical and Electronics Engineering, Bursa, Turkey, 28-30 November.

