

**T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**GÜVENLİK KAMERASI GÖRÜNTÜLERİNDEKİ
BÖLGESEL HIZ DEĞİŞİMLERİNİ DEĞERLENDİREREK
KALABALIK ORTAMLARDA PANİK DURUMU TESPİTİ**

HÜRKAL HÜSEM

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ PROGRAMI**

**DANIŞMAN
DOÇ. DR. M. ELİF KARSLIGİL**

İSTANBUL, 2018

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

GÜVENLİK KAMERASI GÖRÜNTÜLERİNDEKİ
BÖLGESEL HIZ DEĞİŞİMLERİNİ DEĞERLENDİREREK
KALABALIK ORTAMLARDA PANİK DURUMU TESPİTİ

Hürkal HÜSEM tarafından hazırlanan tez çalışması 05.06.2018 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Tez Danışmanı

Doç. Dr. M. Elif KARSLIGİL
Yıldız Teknik Üniversitesi

Jüri Üyeleri

Doç. Dr. M. Elif KARSLIGİL
Yıldız Teknik Üniversitesi



Prof. Dr. Çiğdem EROĞLU ERDEM
Marmara Üniversitesi



Doç. Dr. Songül ALBAYRAK
Yıldız Teknik Üniversitesi



ÖNSÖZ

Gecesi ve gündüzüyle yanımda olan eşim Seçil'e;
... hayatım boyunca desteklerini hissettiğim ablama, anneme ve babama;
... ve kıymetli zamanını ayırarak bilgi ve tecrübelerini paylaşan danışman hocam
M. Elif KARSLIGİL'e sonsuz teşekkürler.

Haziran, 2018

Hürkal HÜSEM

İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ.....	vi
KISALTMA LİSTESİ.....	vii
ŞEKİL LİSTESİ.....	viii
ÇİZELGE LİSTESİ	x
ÖZET	xi
ABSTRACT.....	xiii
BÖLÜM 1	
GİRİŞ.....	1
1.1 Literatür Özeti	2
1.2 Tezin Amacı	5
1.3 Hipotez	6
BÖLÜM 2	
PANİK TESPİT SİSTEMİ TASARIMI	8
2.1 Kişi Tespiti	9
2.1.1 Konvolüsyonel Sinir Ağları (KSA)	9
2.1.2 KSA ile Kişi Tespiti	12
2.2 Kişi Takibi	13
2.2.1 Kalman Filtresi ile Muhtemel Konumların Belirlenmesi	15
2.2.2 Macar Algoritması ile En Uygun Konum Tespitinin Eşleştirilmesi ..	17
2.3 Panik Tespiti	20
2.3.1 Referans ve Anlık Değerler	20
2.3.2 Görüntünün Tamamı Değerlendirilerek Panik Durumu Tespiti.....	23
2.3.3 Görüntüyü Bölgelere Ayırarak Panik Durumu Tespiti.....	24
2.3.4 Bölgesel Adaptif Eşik Değerin Belirlenmesi	28
BÖLÜM 3	
PANİK VERİSETLERİ.....	29
3.1 UMN Olağandışı Kalabalık Aktivitesi Veriseti.....	29
3.2 Tez Çalışması için Oluşturulan Panik Veriseti	30

BÖLÜM 4

UYGULAMA	32
4.1 Görüntünün Tamamıyla Yapılan Tespit Sonuçları	34
4.2 Görüntüyü Bölgelere Ayırarak Yapılan Tespit Sonuçları	37
4.2.1 Bölge Sayısının Belirlenmesi	37
4.3 Bölgesel Adaptif Eşik Değer Kullanımı	39
4.4 Sonuçların Karşılaştırılması	41

BÖLÜM 5

SONUÇ VE ÖNERİLER	47
KAYNAKLAR	48
ÖZGEÇMİŞ	51



SİMGE LİSTESİ

A	Durum geiş matrisi
b	Algılayıcının eğilim değeri
B	Kontrol giriş modeli
B_i	Görüntü bölgeleri
c	Çereve
enk	Macar algoritmasında en küçük değeri
f	Aktivasyon fonksiyonu
H	Gözlem modeli
h	Kapsayıcı kutunun yükseklięi
K	Kalman kazancı
k	Durum
n	Maliyet matrisinin boyutu
P	Hata kovaryans matrisi
p_j	Kiři
Q	Gürültü kovaryans matrisi
R	Gürültü kovaryansı
$T(x)$	Algılayıcının toplam fonksiyonu
u	Kontrol giriş vektörü
u	Kapsayıcı kutunun orta noktasının üst kenarına uzaklıęı
v	Kapsayıcı kutunun orta noktasının sol kenarına uzaklıęı
w_i	Algılayıcı girdilerinin aęırlık değeri
x_i	Algılayıcı girdileri
y	Algılayıcının çıktı değeri
θ	En boy oranı
Σ	Toplam fonksiyonu
$\hat{x}$	Kalman filtresine göre tahmini konum

KISALTMA LİSTESİ

AHO	Anlık Hız Ortalaması
AÇS	Anlık Çerçeve Sayısı
FN	False Negative (Yanlış Negatif)
FP	False Positive (Yanlış Pozitif)
KSA	Konvolüsyonel Sinir Ağı
mAP	mean Average Precision (Ortalama Hassasiyet Ortalaması)
RÇS	Referans Çerçeve Sayısı
RHO	Referans Hız Ortalaması
ROC	Receiver Operating Characteristics (Alıcı İşlem Karakteristikleri)
SIFT	Scale Invariant Feature Transform
TN	True Negative (Doğru Negatif)
TP	True Positive (Doğru Pozitif)
UMN	Minnesota Üniversitesi (veriseti)

ŞEKİL LİSTESİ

	Sayfa
Şekil 1.1	Panik tespit sisteminin çalışma adımları 5
Şekil 1.2	Kamera görüş alanının perspektif gösterimi 6
Şekil 2.1	Panik tespit sistemi blok diyagramı 8
Şekil 2.2	Algılayıcının temel yapısı 10
Şekil 2.3	Çok katmanlı sinir ağının katmanları ve temel gösterimi 11
Şekil 2.4	Konvolüsyonel Sinir Ağı mimarisi [19] 11
Şekil 2.5	Konvolüsyon işlemi 12
Şekil 2.6	Tespit edilen kişilerin, tespit bölgesinin orta noktası ile ifade edilmesi .. 13
Şekil 2.7	UMN veriseti 11. senaryoda kişilerin takip edilmesi 14
Şekil 2.8	Kalman Filtresi eşitlikleri [22] 15
Şekil 2.9	Maliyet matrisi 17
Şekil 2.10	Macar algoritması adımlarının örnek üzerinde gösterimi 19
Şekil 2.11	Kesilmelere rağmen kişi yörüngesinin devamlılığı 20
Şekil 2.12	Panik tespit sisteminin akış diyagramı 21
Şekil 2.13	Referans ve anlık değerlerin görüntü akışı üzerindeki kapsamı 23
Şekil 2.14	RÇS ve AÇS ilk çerçevelerinin hız değişim grafiği üzerinde gösterimi 24
Şekil 2.15	Görüntüdeki her bölge için hesaplanan AHO ve RHO değerleri 25
Şekil 2.16	Çerçeve üzerinde bölgesel panik durumlarının gösterimi 27
Şekil 2.17	Mekâna özgü farklılıkları incelemek amacıyla bölünmüş görüntü 27
Şekil 3.1	UMN verisetindeki üç sahnenin normal ve panik durumları 29
Şekil 3.2	Oluşturulan okul veriseti 30
Şekil 4.1	Tasarlanan panik tespit sisteminin ekran görüntüsü 32
Şekil 4.2	Tespit edilen kişiler ve %30'un altında benzerlik gösteren tespitler 33
Şekil 4.3	UMN veriseti 8. senaryodaki RÇS değerinin etkisi 34
Şekil 4.4	UMN veriseti 4. senaryodaki AÇS değerinin etkisi 35
Şekil 4.5	Okul veriseti 500 RÇS ve 25 AÇS değerleri test sonuçları 35
Şekil 4.6	UMN veriseti 500 RÇS ve 25 AÇS değerleri test sonuçları 36
Şekil 4.7	Hız değişim grafiği üzerinde UMN veriseti 1. senaryonun önemli anlarının gösterimi 37
Şekil 4.8	UMN verisetindeki sahnelerin üç bölgeye ayrılmış hali 38
Şekil 4.9	UMN veriseti 4. senaryo üzerinde görüntünün tamamı ve üç bölgesi test sonuçları karşılaştırması 38
Şekil 4.10	UMN veriseti 6. senaryo üzerinde görüntünün tamamı ve üç bölgesi test sonuçları karşılaştırması 39

Şekil 4.11	UMN veriseti 10. senaryo üzerinde üç bölgede sabit ve değişken eşik değer test sonuçları.....	40
Şekil 4.12	Okul veriseti 5. senaryoda bölgelere ayırmadan, üç bölgesi ve adaptif eşik değeri kullanılarak yapılan test sonuçları	40
Şekil 4.13	Hatalı tespit edilen ve Şekil 4.12'de gösterilen panik durumunun adaptif eşik değeri yöntemiyle düzeltilmesi	41
Şekil 4.14	Karmaşıklık matrisi	42
Şekil 4.15	Karmaşıklık matrisi değerlerinin hız değişim grafiği üzerinde karşılıkları	42
Şekil 4.16	UMN veriseti üzerinde bölgesel adaptif eşik değeri test sonuçları	44
Şekil 4.17	Okul veriseti üzerinde bölgesel adaptif eşik değeri test sonuçları	46



ÇİZELGE LİSTESİ

	Sayfa
Çizelge 2.1 Kişi takibi sözde kodu	15
Çizelge 2.2 Referans ve anlık değerler ile panik durumuna karar veren sözde kod ..	24
Çizelge 2.3 Referans ve anlık değerler ile bölgesel panik durumuna karar veren sözde kod	26
Çizelge 2.4 Bölgesel adaptif eşik değer hesaplaması sözde kodu	28
Çizelge 3.1 UMN verisetindeki senaryoların panik durumlarının başlangıç çerçeveleri ve toplam çerçeve sayıları	30
Çizelge 3.2 Okul veriseti senaryolarının örnek çerçevesi, panik durumlarının başlangıç çerçeveleri ve toplam çerçeve sayıları	31
Çizelge 4.1 UMN veriseti üzerinde görüntünün tamamı, üç bölgeli ve adaptif eşik değer kullanılarak yapılan test sonuçlarının hassasiyet ve doğruluk değerleri	43
Çizelge 4.2 Okul veriseti üzerinde görüntünün tamamı, üç bölgeli ve adaptif eşik değer kullanılarak yapılan test sonuçlarının hassasiyet ve doğruluk değerleri	45

**GÜVENLİK KAMERASI GÖRÜNTÜLERİNDEKİ
BÖLGESEL HIZ DEĞİŞİMLERİNİ DEĞERLENDİREREK
KALABALIK ORTAMLARDA PANİK DURUMU TESPİTİ**

Hürkal HÜSEM

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Tez Danışmanı: Doç. Dr. M. Elif KARSLIGİL

Güvenlik kameraları kullanımının yaygınlaşmasıyla güvenlik kamerası görüntülerinden otomatik bilgi çıkarımı, sıkça çalışılan bir konu haline gelmiştir. Tek bir koordinasyon merkezi üzerinden takip edilen şehir güvenlik kameraları yetkili kişiler tarafından izlenmektedir. Özellikle anında müdahale edilmesi gereken durumlarda, durumun tespit edilmesi aşamasında insan faktörünün varlığı hatalara ve zaman kaybına sebep olabilir. İnsan yoğunluğunun yüksek olduğu alanlarda panik durumunun gerçekleşmesinden hemen sonra ilgili konuma acil yardım ekiplerinin bir an önce ulaştırılması çok önemlidir.

Bu çalışmada, güvenlik kamerası görüntülerinden panik durumu tespiti yapan bir sistem tasarlanmış ve gerçekleştirilmiştir. Bir ortamda şüpheli durumun oluşmasından sonra koşarak kaçma gibi durumlarda hız artışı veya yaranma gibi durumlarda da hız azalması görülebilir. İnsanların hızlarında yaşanan bu değişimler değerlendirilerek panik durumu tespit edilmiştir.

Panik tespit sisteminin gerçekleştirilmesi için Konvolüsyonel Sinir Ağı (KSA) kullanılarak kameranın görüş alanındaki kişiler tespit edilmiştir. Ardından bu kişilerin önceki konumlarından yola çıkılarak muhtemel konumları Kalman filtresi ile hesaplanmıştır. Hesaplanan konumlardan görünüş özellikleri bakımından en uygun olanı Macar algoritması ile seçilmiştir. Macar algoritmasının KSA ile birlikte kullanılmasıyla, başka nesnelerin arkasında kalarak takibi kesilen kişilerin tekrar tespit edilmesi sağlanmıştır.

Kişilerin kısa süreli takibiyle yörüngeleri çıkarılmış, ekranda görünen kişilerin her bir bölgedeki ortalama hızları hesaplanmıştır.

Görüntü bütün olarak değerlendirildiğinde kameraya yakın kişilerin hareketleri kameraya uzak kişilerden daha hızlıymış gibi algılanır. Görüntünün bölgelere ayrılmasıyla, bölgelerdeki kişilerin hız değişimleri kendi içlerinde değerlendirilmiştir. Bu sayede görüntüde perspektif açıdan oluşan hız yanılgıları giderilerek bu durumun panik tespitine katkısı incelenmiştir. Panik durumu olan ve olmayan bölgelerde hız değişimlerinin farklı olmasının yanlış pozitif tespitleri artırdığı gözlemlenmiştir. Görüntüyü bölgelere ayırma ve adaptif eşik değer yöntemlerinin birlikte kullanılmasıyla yanlış pozitif tespitlerin azaldığı görülmüş, dolayısıyla koordinasyon merkezinde gereksiz uyarı durumunun oluşması en aza indirilmiştir.

Anahtar Kelimeler: Panik Tespiti, Bölgesel Hız Değişimi, Konvolüsyonel Sinir Ağı, Kalman Filtresi, Macar Algoritması



**PANIC DETECTION BY REGIONAL
VELOCITY CHANGES IN CROWDED AREAS
FROM SURVEILLANCE VIDEO**

Hürkal HÜSEM

Department of Computer Engineering

MSc. Thesis

Adviser: Doç. Dr. M. Elif KARSLIGİL

The automatic extraction of information from the surveillance camera has become a matter of frequent work with the widespread use of surveillance cameras. City surveillance cameras monitored from a single coordination center by authorized personnel. Especially in situations where immediate intervention is required, the presence of a human factor can lead to faults and delays in determining the situation. In areas with a high concentration of human, it is vital that reaching of emergency aid team at the appropriate location immediately after a suspicious situation has occurred.

In this study, a system that detects panic situation from surveillance camera is designed and realized. When a suspicious situation occurs, there may be a velocity increase in situations such as running away, or a velocity decrease in situations such as an injury. Panic states were determined by evaluating these changes at the velocity of people.

People in the field of view of the camera have been identified using CNN (Convolutional Neural Network) for the realization of the panic detection system. Then, from the previous locations of these people, the possible locations are calculated by the Kalman filter. From the calculated positions, the most suitable one in terms of appearance properties was selected by the Hungarian algorithm. The use of the Hungarian algorithm with the CNN makes it possible to find people who have been interrupted by staying behind other objects. Orbits were extracted with a short follow-

up of people, and the average speeds of each person appearing on the screen were calculated.

When the whole image is evaluated, it is perceived that the movements of persons close to the camera are faster than those who are away from the camera. By separating the images into regions, the velocity changes of the people in the regions have been evaluated within themselves. At this point, the speed misalignment which is formed in perspective from the viewpoint is eliminated and the contribution to panic detection is investigated. It has been observed that differences in velocity changes in panic and non-panic regions increase false positive detections. The combination of separating image into regions and adaptive threshold value methods reduced the false positives, so that unnecessary warning situations are minimized in the coordination center.

Keywords: Panic Detection, Change of Regional Velocity, Convolutional Neural Network, Kalman Filter, Hungarian Algorithm



BÖLÜM 1

GİRİŞ

Bu çalışmada kalabalık ortamlarda, kişilerin hız değişimini değerlendirerek panik durum tespiti yapan bir sistem tasarlanmış ve gerçekleştirilmiştir.

Güvenlik kameralarının yaygın kullanımı ile birlikte, alınan görüntülerden otomatik bilgi çıkartılmasına yönelik çalışmalar, görüntülerin çokluğu ve yalnızca insanlar tarafından değerlendirilmesinin zorluğu nedeniyle önem kazanmıştır. Acil müdahale gerektiren durumlarda, olayın yaşandığı konumda alarm oluşturarak ekiplerin yönlendirilmesi zaman açısından önem arz etmektedir. Böyle bir ortamda hücresel iletişimin de bir süre sonra devre dışı kalabileceği göz önüne alınırsa panik durumu gerçekleştiğinde, otomatikleştirilmiş sistemlerle durumun tespit edilerek sistem üzerinde uyarı verilmesi ile zaman kaybının önüne geçilmesi hedeflenmektedir.

Bu çalışma kapsamında panik durumları ele alınmıştır. Panik durumlarında herhangi bir olayın gerçekleşmesinin ardından kişilerin davranışları incelendiğinde genellikle normal hızlarında ve hareket yörüngelerinde değişiklik olduğu gözlenmiştir.

Kameranın baktığı alanda kişilerin yürüdüğü zeminin özellikleri tespit edilerek kamera ile yüzeyin açısı ve kişilerin birbirlerine olan bağlı mesafeleri tespit edilebilir olsa da standart dışı yerleşim ve istisnai durumlar dikkate alınması gereken diğer zorluklardır. Bu zorlukları bertaraf edebilmek için video görüntülerinin bölgelere ayrılarak çalışılması, birbirine yakın hareket eden kişilerin birlikte değerlendirilmesini sağlar. Böylece görüntüdeki nesnelerin perspektif özellikleri bölgesel çalışma ile dolaylı ve daha basit bir yol ile yorumlanabilir.

1.1 Literatür Özeti

Literatürde video görüntülerinde insan tespiti ve kalabalık davranışı değerlendirilmesi ile ilgili yapılmış çalışmalar mevcuttur.

Redmon ve Farhadi tarafından yapılan çalışmada YOLO9000 adında 9.000'in üzerinde nesne kategorisinde, tespit ve sınıflandırma işlemlerini birlikte uygulayan bir sistem geliştirilmiştir. YOLO ismini "You Only Look Once" (sadece bir kere bak) kelimelerinin baş harflerinden almıştır. Tasarlanan sistemde görüntüyü alanlara ayırarak her bir alanda sınıflandırıcıyı binlerce kez etkinleştirmek yerine tüm kapsayıcı kutuların aynı anda oluşturulduğu ve bir yandan sınıf olasılıklarının hesaplandığı bir sistem geliştirilmiştir. Görüntüyü ızgara şeklinde ele alarak her bir ızgara için belirli sayıda kapsayıcı kutu ile görüntü üzerindeki nesneler 73,4 mAP (mean Average Precision – ortalama hassasiyet ortalaması) değeriyle literatürdeki KSA kullanan diğer çalışmalardan geride kalmayacak şekilde daha hızlı tanınmaktadır. COCO ve ImageNet verisetleri ile eğitilen Konvolüsyonel Sinir ağı (KSA - Convolutional Neural Network) kullanılmıştır [1]. İki veriseti arasında ilişki kurmak için ise WordNet'ten yararlanılarak hiyerarşik bir etiketleme yapılmıştır. COCO veriseti 91 kategoriden, 328.000 görselde üzerinde etiketli 2.500.000 örnekten oluşan oldukça geniş bir verisetidir [2]. Kullanılan bir diğer veriseti ImageNet'te 5.247 kategori ve her kategoride ortalama 600 görsel, toplamda yaklaşık 3.200.000 görsel bulunmaktadır [3].

Bera vd. tarafından düşük ve orta yoğunluklu videolarda yörünge temelli yaklaşım kullanılarak yapılan çalışmada doğrusal olmayan hareket modelleri ile Bayesci öğrenme tekniklerinden yararlanılmıştır. Tasarlanan sistem tek bir kamera ile kapalı veya açık alanlarda çalışabilmektedir. Bu çalışmada her bir kişinin yörüngesi çıkartılmıştır. Öğrenilen yörüngelerden yola çıkılarak anomali tespiti gerçekleştirildiği sistemde herhangi bir ön işlem veya çevrim-dışı öğrenmeye, yani tespit işlemi öncesinde bir veriseti ile eğitmeye ihtiyaç duyulmamıştır. Anomali tespiti yapılırken kişilerin yerel ve genel özellikleri arasındaki farka bakılmıştır. Çoklu-kamera kayıtlarını içeren ve 22 senaryodan oluşan, park etmiş bir araç etrafındaki kişileri içeren PETS 2016 ARENA veriseti üzerinde çalışılmıştır. Bu verisetinde kalabalığa karşı yürüme, U-dönüşü yapma gibi anormallik durumları %85 başarı oranıyla tespit edilmiştir. Kişi yörüngesi

çıkarılırken en uygun konumun belirlenmesinde, tez çalışmasında da kullanılan Kalman filtresinden yararlanılmıştır [4].

Chaker vd. tarafından yapılan gözetimsiz öğrenme yaklaşımıyla hazırlanan, anomaliyi ve anomalinin gerçekleştiği konumu tespit eden sosyal ağ modelinin kullanıldığı çalışmada video görüntüsünün uzamsal ve zamansal özellikleri çıkarılarak görüntüdeki nesneler tespit ve takip edilmiştir. Görüntünün bölgelere ayrılarak zaman içinde değişimi incelenmiştir. Tasarlanan hiyerarşik sosyal ağ modelinin alt katmanlarında uzamsal kümeleme yapılarak yerel anomali durumları değerlendirilirken üst katmanlara çıktıkça hiyerarşik kümeleme yapılarak genel bir sosyal ağ modeli oluşturulmuştur. Yerel anomali tespiti yaparken grup halindeki nesnelerin komşularından ayrı bir hareket yapmasına bakılmaktadır. Genel anomali tespitinin ise hem yerel hem de genel davranışı uygun bir şekilde örnekleyen uygun modelin seçilmesine bağlı olduğu ifade edilmiştir. İki adet dış ortam görüntüsünden oluşan 12 ve 15 dakikalık görüntüler içeren, kişilerin iki bina arasında geçişlerini içeren UCD veriseti üzerinde %96,6 seviyesinde doğruluk oranına ulaşılmıştır. Yayaların yürüyüş yollarına yüksek bir açıdan bakan bir diğer veriseti UCSD üzerinde %86,7 başarıya ulaşılmıştır. Çalışmada oluşturulan sosyal ağ üzerinde zamansal kümeleme ile görüntü genelinde yönelim ve hız verileriyle anomali tespiti yapılmaktadır [5].

Hao vd. çalışmasında video görüntüsündeki kalabalığın hareketi üzerinde durarak panik durumu optik akış yöntemiyle tespit edilmiştir. Bu çalışmada da kullanılan ve ayrıntısı “Panik Verisetleri” başlığı altında verilen UMN veriseti üzerinde yapılan testlerde her bir kişi üzerinde ayrıca durulmasına gerek kalmadan video görüntüsünün tamamı üzerinde çalışılmaktadır. Yapılan testlerde UMN verisetinin tüm senaryolarında panik durumları tespit edilmiştir [6].

Raghavendra vd. tarafından kalabalık alanlarda etkileşim kuvvet büyüklüğünde anomali tespiti yapılmıştır. Sosyal kuvvet modeli kullanılarak hesaplanan etkileşim gücünü optimize etmek için parçacık sürü optimizasyon metodu kullanılmaktadır. Önerilen yöntem ile parçacık nüfusu, ana görüntü hareketlerine doğru sürüklenir. Böylece en yaygın ve tipik kalabalık davranışını modellemek için etkileşim kuvvetini en aza indirmeyi amaçlayan parçacık sürü optimizasyonu kondisyon fonksiyonu tarafından

yönlendirilir. UMN, PETS 2009-S3, UCF ve internet videolarından derlenen hapisanede isyan verisetleri üzerinde yapılan çalışmalarda ROC (Receiver Operating Characteristics - Alıcı İşlem Karakteristikleri) eğrisi alt alanı ile ölçülerek sırasıyla %99, %99, %98 ve %89 değerlerine ulaşılmış, kişi takibi gereksinimi olmamakla birlikte herhangi bir öğrenme aşamasına da ihtiyaç duyulmamıştır [7]. Çalışmada yararlanılan UCF veriseti 12 adet video görüntüsünden oluşan bir derlemdir [8].

Almeida vd. yaklaşımında, optik akış yöntemine dayalı iki boyutlu hareket histogramlarını zaman içinde değerlendirerek hareket desenlerindeki genel değişimleri, hız vektörü ve benzer mekânsal konumları kümeleyerek de yerel etkileri tanımlayabilmektedir. İnsanların aniden koşma veya birbirlerinden aniden ayrılma durumlarının incelendiği PETS 2009, UMN ve yapay veriyle oluşturulan verisetleri üzerinde kapalı veya açık alanları da kapsayabilen bu çalışmada hareket eden insan gruplarıyla çalışılmıştır. Önceki literatür çalışmalarıyla karşılaştırabilmek için gerçek değerden kaç saniye gecikmeli tespit yaptıkları çalışmalarında gösterilmiştir. Bahsedilen verisetlerinden seçilmiş beş durum üzerinde en iyi sonuca 0,3 saniye, en kötü sonuca ise 3,3 saniye gecikmeli ulaşılmış, genel etkilerin değerlendirildiği bir durumda ise tespit gerçekleşmemiştir [9].

Haque ve Murshed tarafından yapılan yörünge çıkarımı ve hareket özelliklerine gerek duymadan arka plandan ayrıştırılan bölgelerin zamansal özelliklerinden yola çıkılarak destek vektör makineleri yardımıyla aniden ayrılma, koşma ve kavga gibi anormal sayılabilecek durumların normal hareketlerden ayrılmasının incelendiği çalışmalarında %80 oranında doğruluk değerine ulaşabildikleri bildirilmiştir [10]. Çalışma kapsamında UMN ve CAVIAR verisetleri kullanılmıştır. CAVIAR veriseti kişilerin yalnız ve grup halinde yürümeleri, alışveriş, mağazaya girme ve mağazadan çıkma, kavga etmeleri gibi davranışları örnekleyen video görüntülerinden oluşmaktadır [11].


Bahsedilen çalışmalarda görüntünün bölgesel ve perspektif özellikleri yeterince incelenmemiştir.

1.2 Tezin Amacı

Bu çalışmada kalabalık ortamlarda, kişilerin hız değişimini bölgesel olarak değerlendirilerek panik durum tespiti yapan bir sistem tasarlanmış ve gerçekleştirilmiştir. Literatürde yeterince incelenmemiş olan perspektif özellikler, görüntünün bölgelere ayrılmasıyla bu tez çalışması kapsamında geliştirilen panik tespit sisteminde inceleme konusu olmuştur.

Video görüntülerinde, uzaktaki kişilerin yakındaki kişilere göre daha yavaş hareket ediyor gibi görünmesi, görüntüdeki perspektif özelliklerin de dikkate alınarak yorumlanmasını gerektirmektedir. Bu çalışmada kişilerin hız özelliğine odaklanılmış, güvenlik kamerasının görüntü alanı ile kameranın perspektif özellikleri dolaylı olarak göz önüne alınmış, görüntü bölgelere ayrılarak her bölge kendi içinde değerlendirmeye tabi tutulmuş ve panik durumu ile ilgili genel bir çıkarım yapılmıştır. Hız değişimlerinin bölgesel değerlendirilmesi sayesinde kişilerin yön bilgilerinin kullanılmasına gerek kalmamıştır.

Panik tespit sisteminin çalışma adımları Şekil 1.1’de gösterilmiştir.



Şekil 1.1 Panik tespit sisteminin çalışma adımları

Bu çalışmanın diğer çalışmalardan ayrılan yönü ve önemi ise her bir video çerçevesinin perspektif özelliklerinin dikkate alınabilmesini sağlamak amacıyla görüntünün parçalara bölünerek, takip edilen kişilerin hareket hız değişimlerinin bölgesel olarak yorumlanmasıdır.


Çalışmada, görüntüdeki kişilerin tespiti için KSA kullanılmıştır [1]. Kişilerin önceki konumlarından yola çıkılarak mevcut durumda nerede olabilecekleri Kalman fitresi [12] ile hesaplanmıştır. Kalman filtresi ile üretilen muhtemel konum çıktıları arasından en uygun olanını seçmek için görsel özelliklere odaklanılarak Macar algoritması [13] ile eşleştirme yapılmıştır. Kişi takibinin kesintisiz bir şekilde yapılmasını sağlamak amacıyla

Macar algoritması ile birlikte kapsayıcı kutuların görünüm özelliklerini eşleştirmede KSA kullanılarak kişi takibi ve yörünge çıkarımı yapılmıştır [14]. Kişilerin hızlarını hesaplamak için gerekli olan yörünge çıkarma işleminden sonra, çalışmanın asıl konusu olan perspektif özelliklerin dikkate alınmasıyla kişilerin hız değişimlerinin yorumlanması ve panik durum tespiti gerçekleştirilmiştir.

1.3 Hipotez

Görüntüdeki kişilerin hız verilerine odaklanarak olağandışı değişimlerin yorumlanmasıyla panik durum tespiti mümkün olmaktadır. Herhangi bir panik durumunun yaşanmasıyla insanların doğal bir davranışı olan koşarak kaçmaları sonucu mevcut hızlarında ani bir yükseliş görülmektedir. Benzer şekilde yaralanma gibi durumlarda da hızlarında ani bir düşüş veya hareketlerinde duraklama olmaktadır. Görüntülerin otomatik olarak değerlendirildiği durumlarda bu hız değişimlerinin yorumlanması, panik durum tespitini mümkün hale getirmekle birlikte görüntüdeki perspektif özelliklerin dikkate alınmaması hatalı sonuçların ortaya çıkmasına sebep olabilir.

Görüntünün yalnızca bir bölgesinde yaşanan panik durumunda diğer bölgelerdeki kişiler yavaş hareket ediyorsa, görüntünün tamamı için panik uyarısı verilmeyebilir. Ancak bölgesel çalışma sonucunda her bölgenin kendi içinde değerlendirilmesiyle görüntünün bazı kısımlarında yoğunlaşan kalabalık da yalnızca kendi bölgesini etkileyeceğinden özellikle kişilerin dengesiz dağılım gösterdiği görüntülerde başarı şansı artırılabilir.



Şekil 1.2 Kamera görüş alanının perspektif gösterimi

Şekil 1.2’de görüldüğü gibi, özdeş iki kişinin bulunduğu görüntüde kişilerin büyüklüğü ve hızları perspektif sebebiyle farklı görülmektedir. Perspektif özelliklerin hesaplanabilmesi için kameranın zemin ile yaptığı açının bilinmesi gereklidir. Ancak

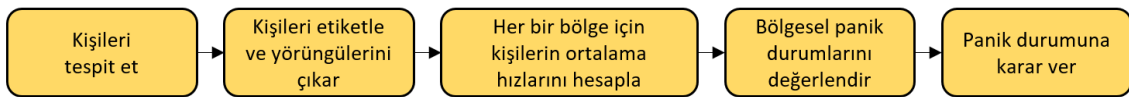
perspektif özelliklerin yorumlanması, kamera yerleşimiyle ilgili bazı kural tanımlamalarını beraberinde getirebilir. Bu gibi zorlukları aşmak adına görüntüler yatay ve dikey bölgelere ayrılarak kişilerin hız değişimleri yorumlanabilir. Böylece birbirine yakın mesafedeki kişilerin birlikte ele alınması sağlanarak panik durumunun önce bölgesel değerlendirilmesi, buradan çıkan sonucun da çerçevenin tamamı için yorumlanmasıyla panik durumu tespiti yapılabilir. Ayrıca bölgesel çalışarak hatalı panik tespitlerinin önüne geçilebilir.



PANİK TESPİT SİSTEMİ TASARIMI

Bu çalışmada, güvenlik kamerası görüntülerinde panik durumunu tespit etmeye yönelik bir sistem tasarlanmış ve gerçekleştirilmiştir. Panik, ansızın gerçekleşen bir olay sırasında kişilerin yaşadıkları korku nedeniyle içine düştükleri durumdur. Genellikle ortamda tehlike yaratan olaylar sonucunda oluşan panik durumlarında kişiler koşarak olay yerinden uzaklaşma davranışı gösterirler. Gerçekleştirilen panik tespit sisteminde yalnızca insan hareketlerine odaklanılmıştır. Ortamda bulunan araç, kedi, köpek vb. diğer hareketli nesneler değerlendirilmemiştir. Bu nedenle, öncelikle her bir çerçevedeki kişilerin tespit edilmesi gerekmektedir. Panik durumu tespiti için, kişilerin hız değişimleri değerlendirilmiştir. Tespit edilen her bir kişinin hızını hesaplayabilmek için bir takip ve yörünge çıkarım işlemi gerçekleştirilmiştir.

Panik tespit sisteminin blok diyagramı Şekil 2.1’de gösterilmiştir. Kişilerin tespit ve takip edilmesinden sonra her bölgedeki kişilerin hızları hesaplanmıştır. Panik durumuna karar verilirken bölgelerde meydana gelen hız değişimlerinden yararlanılmıştır. Bölgesel panik durumlarının sayısı, panik durumuna karar vermede etkili olmaktadır.



Şekil 2.1 Panik tespit sistemi blok diyagramı

Geliştirilen sistemle, görüntülerin tamamından bilgi çıkarılması ve görüntülerin parçalara bölünüp her parçadan ayrı ayrı bilgi çıkarılmasıyla iki farklı şekilde değerlendirilmiştir. Geniş bir alanı izleyen güvenlik kamerası görüntülerinde insan hız değişimlerinin daha tutarlı hesaplanabilmesi için perspektif özelliklerin de dikkate

alınması gereklidir. Şüpheli olayın gerçekleştiği konuma uzak bir alanda kişilerin yoğunlukta olması ve yavaş hareket etmesi de tüm görüntüdeki kişilerin ortalama hızlarını düşük seviyede tutacağından panik durumu tespitini engelleyebilir. Görüntünün bölgelere ayrılmasıyla birbirine yakın konumdaki kişilerin birlikte değerlendirilerek panik durumunun oluşup oluşmadığına karar verilmesi hedeflenmiştir. Tespit edilen her bir kişinin hız bilgileri, o an ait bulundukları bölge içinde hesaplanarak her bir bölgenin ortalama hızı tespit edilmiştir.


Çerçevelerin ortalama hızlarından yola çıkılarak her bir çerçeve için bölgesel panik durumlarının oluşup oluşmadığı belirlenmiştir. Kameranin gördüğü alanda oluşan panik durumu, ne kadar çok bölgeye yayılıyorsa panik durumunun gerçekliği o kadar kesindir. Kişi tespit edilen çerçeveler üzerinde yapılan işlemlerde bölgesel panik durumu oluşan çerçeve sayısı, panik durumu tespit edilmeyen çerçeve sayısından üstün olduğu belirlendiğinde, ilgili çerçeve için panik durumunun olduğu kabul edilmiştir.

2.1 Kişi Tespiti

Panik tespit sisteminin ilk aşamasında kişi tespiti gelmektedir. Görüntüden kişi tespiti yapan yöntemler içinde en yüksek başarı Konvolüsyonel Sinir Ağları (KSA) tabanlı sistemler ile elde edilmiştir [1], [15], [16]. Bunun için bu çalışmada kişi tespiti KSA yöntemi ile yapılmıştır.

2.1.1 Konvolüsyonel Sinir Ağları (KSA)

Yapay sinir ağları, insan beynindeki biyolojik sinir ağı yapısının çalışma prensibini ve dolayısıyla insan öğrenmesini simüle eden bir makine öğrenmesi yöntemidir. Sinir ağları, ilk kez 1958 yılında Frank Rosenblatt tarafından algılayıcı (perceptron) adı verilen olasılıksal modelin tanımlanmasıyla gelişimine başlamıştır [17]. Algılayıcı, yapay sinir ağının en temel hesaplama birimidir ve sinir hücresini ifade eder. Şekil 2.2'de görüldüğü gibi, bir algılayıcıda giriş değerlerinden çıkış değerleri elde edilirken ağırlık ve eğilim değerlerinin öğrenilmesi esastır. Her bir giriş değeriyle birlikte ele alınan ağırlık ve modele ait eğilim değerlerinin toplamı ile elde edilen değer, aktivasyon fonksiyonu sayesinde çıkış değerine dönüştürülür. Dolayısıyla aktivasyon fonksiyonu ile canlının sinir hücresi olan nöronlar taklit edilerek nöronun aktif olup olmadığı anlaşılır.



Şekil 2.2 Algılayıcının temel yapısı


Bir algılayıcıda, ağırlık ve eğilim değerlerinin beklenen çıktıyı verecek değerleri almasıyla öğrenmenin gerçekleştiği kabul edilir. Bir algılayıcının matematiksel ifadesi eşitlik (2.1) ile gösterilmiştir.

$$T(x) = \sum_{i=1}^n w^i x^i + b \quad (2.1)$$

Toplam fonksiyonu, aktivasyon fonksiyonu ile birlikte değerlendirilir ve algılayıcının çıkış değeri eşitlik (2.2) ile bulunur.


$$y = f(T(x)) \quad (2.2)$$

Algılayıcıların bir araya gelmesiyle sinir ağı oluşturulur. Böylesi durumlarda bir algılayıcının çıktısı, diğerinin girdisi olacak şekilde bir yapı oluşturulur. Bir katmanda birçok algılayıcı bulunabilir. Şekil 2.3'te ifade edildiği gibi, katmanların bir araya gelmesiyle oluşan sinir ağında girdi ve çıktı katmanları mutlaka bulunmakla birlikte problemin gereksinimine göre gizli katmanın varlığı ve sayısı değişebilmektedir. Gerçek zaman problemlerini ifade edebilmek için çok katmanlı algılayıcı kullanmak gerekmektedir. Katman sayısı arttıkça sinir ağının da derinliği artar.



Şekil 2.3 Çok katmanlı sinir ağının katmanları ve temel gösterimi


En az bir katmanı üzerinde matris çarpımı yerine konvolüsyon işlemi uygulandığında bu katmana konvolüsyon katmanı, bu ağa da Konvolüsyonel Sinir Ağı denilmektedir [18]. Konvolüsyonel sinir ağının ilk katmanında konvolüsyon işlemi görülür ve ağın yapısına göre, Şekil 2.4'te görüldüğü gibi birçok katmanda da konvolüsyon işlemi yapılır.



Şekil 2.4 Konvolüsyonel Sinir Ağı mimarisi [19]

Giriş görüntüsü, her bir pikselde RGB renk uzayını temsil edecek şekilde g genişliğinde, y yüksekliğinde $g \times y \times 3$ boyutunda bir matristir. Şekil 2.5'te görüldüğü gibi, bu matris üzerinde tanımlı filtreler ile konvolüsyon işlemi gerçekleştirilir ve özellikler üretilir. Kullanılan filtre, bir algılayıcıya karşılık gelirken filtrenin değerleri de ağırlıkları ifade eder. Filtre, giriş görüntüsü üzerinde gezdirilerek özellik çıkarımı yapılır. Çıkarılan özellik haritası üzerindeki en karakteristik verilerin seçilmesi ise örnekleme katmanında

gerçekleşir. Örnekleme, filtre ile en yüksek uyum gösteren alanın seçilmesi için kullanılır.



Şekil 2.5 Konvolüsyon işlemi

2.1.2 KSA ile Kişi Tespiti

Yapay sinir ağlarından en iyi düzeyde yararlanabilmek için eğitim verisinin mümkün olduğunca çok örnekten oluşması gerekmektedir [16]. Bu sebeple bu çalışmada insan tespiti için kullanılan KSA, COCO [2] ve ImageNet [3] verisetleri ile birlikte eğitilen yüksek başarı değerlerine ulaşmış bir model ile gerçekleştirilmiştir. Bu modelde her bir konvolüsyon katmanından sonra yığın normalleştirme işlemi gerçekleştirilmiştir. Ağın kararlılığını artırmak için yapılan bu işlemde bir önceki katmandaki değerler, yığın ortalaması farkının standart sapmasına bölümüyle normalize edilir. Başarıyı artırmak için 224x224 çözünürlükten başlayarak 10 döngü ile 448x448 çözünürlüklü görsellerle eğitilmiştir. Modelde 19 adet konvolüsyon ve beş adet büyük değer örnekleme (max pooling) katmanı kullanılmıştır. Örnekleme katmanı konvolüsyon katmanlarından sonra gelir. Bu katman sayesinde, konvolüsyon katmanlarından sonra çıkarılan özellik haritasının genişlik ve yüksekliği düşürülerek özellik haritası boyutlarında indirgeme yapılır.

Sınıflandırma eğitiminde ImageNet veriseti üzerinde başlangıç eğitiminde 0,1 öğrenme oranı ile 160 döngü, 4'ün katı bir polinomsal eksilme oranı; 0,0005 ağırlık azalım oranı ve 0,9 momentum değerleri ile çalışılmıştır. Eğitim boyunca standart veri artırım teknikleri kullanılmıştır. Yalnızca 10 döngü için 10^{-3} öğrenme oranı ile devam edilmiştir.

Tespit eğitiminde ise son konvolüsyon katmanı yerine her birinin ardında 1x1 konvolüsyon katmanı ile gelen 1.024 filtreli üç adet 3x3 konvolüsyon katmanı kullanılmıştır. Bu modelde 160 döngü ile 60 ve 90. adımlarda 10'a bölünmek suretiyle 10^{-3} öğrenme oranı, 0,0005 ağırlık azalım oranı ve 0,9 momentum değerleri ile çalışılmıştır [1].

Sınıflandırma eğitiminde, eğitilen modelde kullanılan etiketlere göre benzerlik oranları çıkartılarak nesnenin bir sınıfa dahil edilmesi sağlanır. Tespit eğitiminde ise, sınıflandırma için nesnelerin özelliklerini ortaya çıkartmak amaçlanır.



Şekil 2.6 Tespit edilen kişilerin, tespit bölgesinin orta noktası ile ifade edilmesi

Tespit edilen kişiler, panik tespiti aşamasında dikdörtgensel bir bölge olarak ifade edilmek yerine, Şekil 2.6'daki gibi bu dikdörtgensel bölgenin orta noktasının koordinatları ile temsil edilmiştir. Bu sayede tespit edilen kişi konumunun sapması en aza indirgenmiştir. Bu noktadan, bölgesel çalışmada kişinin bulunduğu bölgenin tayin edilmesinde de istifade edilmiştir.

2.2 Kişi Takibi

Bu çalışmada panik tespiti için kişilerin hız değişimlerine odaklanılmıştır. Kişilerin hız bilgilerini elde etmek için bu kişilerin video üzerinde takip edilmesi gereklidir. Her bir görüntü çerçevesinde, tespit edilen kişilerin video içindeki hız bilgilerinin elde edilmesi için görüntüde bulundukları süreler içerisinde izledikleri yörüngenin bilinmelidir. Bunun

için de kişiler, tespit edildikleri çerçeveden itibaren görüntüden çıkana kadar takip edilmektedir.

Kişilerin takibinin yapılabilmesi için önceki konum bilgilerine dayanarak yeni muhtemel konumların elde edilmesi Kalman filtresi ile gerçekleştirilmiştir [20]. Kalman filtresi sayesinde kişi takibinin ilk aşaması gerçekleştirilmektedir.



Şekil 2.7 UMN veriseti 11. senaryoda kişilerin takip edilmesi

Şekil 2.7’de, KSA ile tespit edilen kişilerin takip edilerek her birinin tekil bir etiket ile temsil edildiği görülmektedir. Tespit edilen her yeni kişiye etiket verilirken bu kişinin görüntü içerisinde belirli sayıda çerçevede bulunması gereklidir. Üst üste belirli sayıda çerçevede uygun eşleştirme yapılmadığında ise kişinin takibine son verilir.


Bu tez çalışması kapsamında kişi hareketleri, her bir çerçeve geçişinde kaç piksel hareket ettiğine (piksel/çerçeve) bakılarak ölçülmüştür. Kişi takibinin sözde kodu Çizelge 2.1’de gösterilmiştir. Yörüngeler oluşturulma anına göre sıralanarak mevcut çerçevedeki kişi tespitleri ile mesafeleri hesaplanır. En düşük mesafeye değerine sahip ikili, eşik değerden daha yakın sonuçlar veriyorsa mevcut yörüngeye yeni konum eklenerek bu tespit eşlenmiş olur. Eşlenen tespit listeden kaldırılır. Eğer yörünge, azami takip çerçevesi kadar çerçevede herhangi bir tespit ile eşleşmediyse, kişinin artık görünür olmadığı kabul edilerek bu yörünge de listeden kaldırılır. Eğer tespitler içerisinde yine de eşleşmeyenler varsa yeni bir yörünge tanımlanarak bu yeni yörüngeyle eşleştirilir.

Çizelge 2.1 Kişi takibi sözde kodu

1:	Çerçeve geldiği sürece
2:	Yeni çerçeveyi yakala
3:	Yörüngeleri yaşına göre listele
4:	Eşleşmeyen tespitleri listele
5:	Yörünge ile eşleşmeyen tespitler arasındaki “mesafe”yi hesapla
6:	Eğer en küçük mesafe eşik değerden küçükse
7:	En küçük mesafeye sahip tespit ile yörüngeyi eşleştir
8:	Eşleşen tespiti listeden kaldır
9:	Yörünge “azami takip” kadar eşleşmediyse listeden kaldır
10:	Eşleşmeyen tespitler ile yeni yörünge başlat

2.2.1 Kalman Filtresi ile Muhtemel Konumların Belirlenmesi

Kalman filtresi, akan veri vektörü üzerindeki gürültünün temizlenmesi veya karşılaşılabilecek yeni veriye en yakın tahminin yapılabilmesi için kullanılan matematiksel bir modeldir [12]. Şekil 2.8'de gösterildiği gibi, hatayı en aza indirmeyi hedefleyen özyinelemeli yapısı ile sistemin tüm girdilerinden yararlanır. Ancak her yeni veri ile karşılaşıldığında tüm hesaplamaların yeniden yapılması yerine önceki tahmin ve önceki gerçek değer, yeni veriyle birlikte değerlendirilerek her yeni tahminde daha isabetli sonuçlara ulaşılır [21].



Şekil 2.8 Kalman Filtresi eşitlikleri [22]

Kalman filtresi temelde iki aşamalıdır. Döngüsel biçimde her tahminden sonra düzeltme işlemleri gerçekleştirilir. İlk aşamada başlangıç değerleri verilerek bir tahmin gerçekleştirilir.

$$\hat{x}_k^- = A\hat{x}_{k-1} + Bu_{k-1} \quad (2.3)$$

Kalman filtresinde ulaşılması hedeflenen değer, eşitlik (2.3)'te görülen $\hat{x}_k^-$ değeridir. k durumundaki tahmini konum $\hat{x}_k^-$ ile ifade edilirken bir önceki tahmin $\hat{x}_{k-1}$ ile ifade edilmiştir. Burada A , durum geçiş matrisidir. u_{k-1} kontrol giriş vektörü olarak kullanılmakta, B ise kontrol giriş modelini ifade etmektedir.

$$P_k^- = AP_{k-1}A^T + Q \quad (2.4)$$

P_k^- ile hata kovaryans matrisine ulaşılır. Q ise gürültü kovaryans matrisini ifade eder. (2.3) ve (2.4) eşitliklerinde tahmin üretme söz konusuysen (2.5), (2.6) ve (2.7) düzeltme eşitlikleridir.

$$K_k = P_k^- H^T (HP_k^- H^T + R)^{-1} \quad (2.5)$$

Kalman filtresinin en önemli parametresi, düzeltme için kullanılan K_k olarak ifade edilen Kalman kazancıdır. Ölçülen ve tahmin edilen değerler arasındaki hesaba dayalı olan bu değer her adımda hesaplanır ve önceki değerlerden de beslenir. H matrisi ile gözlem modeli, R matrisi ile gürültü kovaryansı ifade edilir.

$$\hat{x}_k = \hat{x}_k^- + K_k(z_k - H\hat{x}_k^-) \quad (2.6)$$

Ulaşmak istenen değer olan x 'in k anındaki değeri eşitlik (2.6) ile bulunur. z_k ile ölçüm sonucu elde edilen değer temsil edilir.

$$P_k = (I - K_k H)P_k^- \quad (2.7)$$

Eşitlik (2.7)'de I ile kimlik matrisi ifade edilir. Elde edilen P_k değeri, bir sonraki tahmin aşamasında girdi olarak kullanılır [21].

Kalman filtresi hesabında, (2.8)'de gösterildiği gibi 8 boyutlu durum uzayı kullanılır. Bu durum uzayında kapsayıcı kutunun orta noktası (u, v) , en ve boy oranı γ , yükseklik h ile

gösterilmektedir. Doğrusal Kalman filtresi ile her bir değerin hızlarından yola çıkılarak bir sonraki çerçeve için tahmin edilen konumları da bu durum uzayında bulunur.

$$(u, v, \gamma, h, \dot{x}, \dot{y}, \dot{\gamma}, \dot{h}) \quad (2.8)$$

Kalman filtresi ile üretilen birçok konum verisi, önceki konumlardan yola çıkılarak hesaplandığından yörünge oluşturma işleminin ilk aşamasıdır. Ancak tespit edilen kişilerin en uygun konum ile ilişkilendirilmesi Macar algoritmasının kullanılmasıyla yapılmıştır [20].

2.2.2 Macar Algoritması ile En Uygun Konum Tespitinin Eşleştirilmesi

Kişi hızlarının elde edilebilmesi için öncelikle her bir çerçevede tespit edilen kişilerin bir önceki çerçevedekiler ile eşlenmesi gerekmektedir. Eşlemeyi en iyileştirmek için Kalman filtresinden yararlanılmış ve önceki konumlarına bakılarak bulunabileceği yeni konumlardan en uygun olanının seçilmesinde Macar algoritmasından yararlanılmıştır. Macar algoritması ile karar verilirken takip edilen kişiye görsel özellikler bakımından uygunluğuna bakılır [14].

Macar algoritması, bir eşleştirme algoritması olarak geçer. Farklı seçenekleri barındıran mevcut iki olgu arasında en düşük maliyetli eşleşmenin yapılmasını sağlar [13]. Algoritmanın genel çözümünde n adet görevin n adet kişiye en düşük maliyet ile eşlenmesi ele alınacak olursa, Şekil 2.9'da gösterildiği gibi $n \times n$ boyutunda bir maliyet matrisi oluşturulur ve bu matris üzerinde işlemler gerçekleştirilir.


		GÖREV			
		1	2	...	n
KİŞİ	1				
	2				
	...				
	n				

Şekil 2.9 Maliyet matrisi

En düşük maliyet ile eşleme hesabında Macar algoritmasının işlem adımları şu şekildedir:

- 1:** Matris üzerindeki her bir satırdaki en küçük elemanı tespit et.
- 2:** Her satırdaki en küçük elemanı aynı satırdaki tüm elemanlardan çıkar.
- 3:** Her bir sütundaki en küçük elemanı tespit et.
- 4:** Her sütundaki en küçük elemanı aynı sütundaki tüm elemanlardan çıkar.
- 5:** En çok sayıda 0 (sıfır) içeren satır veya sütundan başlamak üzere bu satır ve sütunlardaki elemanları işaretlerle, işaretlenmişleri yok say.
- 6:** İşaretlenen satır ve sütun sayısını say, n' 'e eşit ise Adım 12'ye git.
- 7:** İşaretlenmemiş en küçük eleman seçilir, enk' 'ye atanır.
- 8:** İşaretlenmemiş elemanlardan enk' 'yi çıkar.
- 9:** İşaretli satır ve sütunların kesiştiği elemanları tespit et.
- 10:** Kesişen elemanlara enk' 'yi ekle.
- 11:** Adım 5'e git.
- 12:** Kişi ve görev kesişimi 0 (sıfır) olanları, açıkta eleman kalmayacak şekilde eşleştir.


Macar algoritmasının örnek üzerinde gösterimi Şekil 2.10'da gösterilmiştir. Burada, dört adet kişiye verilmesi düşünülen dört farklı görevin maliyeti, her bir kişi için maliyet matrisi üzerinde verilmiş ve Macar algoritması adım adım uygulanarak en uygun çözüme ulaşılmıştır.



Şekil 2.10 Macar algoritması adımlarının örnek üzerinde gösterimi

İnsan takibindeki en büyük zorluklardan birisi; takip edilen kişinin bir süreliğine çeşitli nesnelerin ardında kalarak veya başka sebeplerle kaybedilmesi ve takibin kesilmesi, görünür olduğunda görüntüde beliren yeni bir kişi olarak algılanması, yani önceki yörüngesiyle olan bağlantısının tamamen kopmasıdır. Kesintisiz insan takibi sorununun üstesinden gelebilmek amacıyla, bu soruna özel olarak geliştirilmiş, sınırlı bir alandaki eşzamanlı kayıt yapan altı kameradan en az ikisinde görünen 1.261 insan içeren ve 1.100.000 görselden oluşan, insanların yeniden tanınabildiği MARS veriseti [23] üzerinde, Kalman filtresi ve Macar algoritmasına ek olarak KSA ile insanların önceki yörüngeleri ile bağlantılarının kopması engellenmeye çalışılmıştır [14]. Bu işlem gerçekleştirilirken takip edilen insanın görünüm özelliklerinden yola çıkılarak eşleştirme yapılır.

Çıkarılan yörüngedeki kopmalara rağmen takibin devam edilmesi Şekil 2.11'de gösterilmiştir.




Şekil 2.11 Kesilmelere rağmen kişi yörüngesinin devamlılığı

2.3 Panik Tespiti

Panik tespiti, bu çalışmanın esas konusudur. Panik tespitinin yapılabilmesi için gerekli olan kişi yörüngelerinin çıkartılmasından sonra normal durumları niteleyen referans ve panik durumlarını niteleyen anlık değerlerin hesaplanması gerekmektedir. Panik tespit sisteminin akış diyagramı Şekil 2.12'de gösterilmiştir.

2.3.1 Referans ve Anlık Değerler

Gerçekleştirilen sistemde panik durumuna karar verirken kişilerin hız değişimleri değerlendirilmektedir. Kişilerin takipleri sonucu elde edilen hız bilgilerinin, kişilerin bulunduğu bölgeler göz önüne alınarak ortalaması hesaplanır. Panik durumunu belli eden ani hız değişimi, kısa ve uzun süreli takip sonucu oluşan hız ortalamaları farkı ile tespit edilir.



Şekil 2.12 Panik tespit sisteminin akış diyagramı

Panik durumunun sağlıklı bir şekilde tespitinin yapılabilmesi amacıyla, her bir bölgedeki kişilerin hızları eşitlik (2.9) ile hesaplanır. $Kişihızı(p, n)$ eşitliği ile her p kişinin en son n çerçevedeki hızı hesaplanacaktır. $Konum(p, c)$ eşitliği kişinin çerçeve üzerindeki konumunu verecek şekilde tanımlı olmak üzere, her bir kişinin c çerçevesindeki konumu ile $c - 1$ çerçevesindeki konumu Öklid mesafesi ile hesaplanır. Ardından her iki çerçeve arasındaki konum değişimleri toplanır. Böylece p kişinin çerçeveler arasında toplamda kaç piksel yer değiştirdiği bulunmuş olur. Değişim toplamı; çerçeve sayısının bir eksiğine, diğer bir deyişle kişinin gerçekleştirebileceği konum değişim sayısına bölünür.

$$Kişihızı(p, n) = \frac{\sum_{c=2}^n (\sqrt{Konum(p, c)^2 - Konum(p, c-1)^2})}{n-1} \quad (2.9)$$

Her bölge için Referans Hız Ortalaması (RHO) ve Anlık Hız Ortalaması (AHO) olmak üzere iki farklı hız değeri dikkate alınmıştır. RHO ve AHO değerleri her bölge için ayrı ayrı hesaplanmaktadır. Eşitlik (2.10)'da p ile bölgedeki kişiler temsil edilmiştir. RHO hesaplanırken kişilerin en son RÇS kadar çerçevedeki hız bilgileri dikkate alınmaktadır.

$$RHO_{B_i} = \frac{\sum_{j=1}^{|p|} Kişihızı(p_j, RÇS)}{|p|} \quad (2.10)$$

Eşitlik (2.11)'deki AHO hesaplaması da eşitlik (2.10)'daki RHO hesaplamasına benzer şekildedir. Ancak burada kişilerin AÇS kadar çerçevedeki hız ortalamaları ile ilgilenilmektedir.

$$AHO_{B_i} = \frac{\sum_{j=1}^{|p|} Kişihızı(p_j, AÇS)}{|p|} \quad (2.11)$$

Şekil 2.13'te gösterildiği gibi, RHO ile kişilerin normal durumlardaki hız değerlerini örneklemek amaçlanırken AHO ile kişilerin en son gerçekleşen hız değerleri elde edilmektedir. Eşitlik (2.14)'de AHO ile RHO karşılaştırılarak panik durumunun oluşup oluşmadığına karar verilmektedir.



Şekil 2.13 Referans ve anlık değerlerin görüntü akışı üzerindeki kapsamı

Bir çerçevedeki bölgelerin hız ortalamaları hesaplanırken daima kendinden önceki belirli sayıda çerçeveye bakarak hesaplama yapılmaktadır. RHO için Referans Çerçeve Sayısı (RÇS) ve AHO için Anlık Çerçeve Sayısı (AÇS) kadar çerçeveye bakılmıştır. RÇS, her zaman AÇS'den büyük olmak kaydıyla RÇS ve AÇS'nin en uygun değerleri deneysel olarak belirlenmiştir.


Bu çalışmada panik durumu tespiti görüntünün tamamı, görüntünün bölgelere ayrılması ve dinamik eşik değer kullanılmasıyla üç farklı şekilde değerlendirilmiştir.

2.3.2 Görüntünün Tamamı Değerlendirilerek Panik Durumu Tespiti

Panik tespiti, video görüntüsünün herhangi bir bölge belirlemeden, diğer bir deyişle görüntünün tamamını tek bir bölge olarak kabul ederek yapılmaktadır. Bu değerlendirme işleminde video görüntüsünde tespit edilen tüm kişilerin hız bilgileri, ardışık iki çerçeve arasında kaç piksel (piksel/çerçeve) hareket ettiğinden yola çıkılarak belirlenir.

Görüntünün tamamıyla yapılan panik tespitinin sözde kodu Çizelge 2.2'de verilmiştir. Her bir kişinin mevcut çerçeveye kadar olan ortalama hızı hesaplandıktan sonra, RÇS değeri kadar son çerçevede görünen tüm kişilerin hız bilgileri ile RHO elde edilir. Benzer şekilde, en son elde edilen AÇS değeri kadar çerçevedeki kişilerin ortalamasından yola çıkılarak AHO elde edilir.

Şekil 2.14'te bir çerçeve değerlendirilirken AÇS kadar çerçevenin hız ortalaması olan AHO'nun RÇS kadar çerçevenin hız ortalaması olan RHO'ya göre değişimi gösterilmiştir.



Şekil 2.14 RÇS ve AÇS ilk çerçevelerinin hız değişim grafiği üzerinde gösterimi

Görüntünün tamamıyla yapılan değerlendirmede görüntünün tamamı için tek bir AHO ve RHO değeri üretilir. Elde edilen AHO ve RHO arasındaki farkın belirli bir eşik değerin üstüne çıkmasıyla, söz konusu çerçeveden itibaren panik durumunun olduğu kabul edilir.

Çizelge 2.2 Referans ve anlık değerler ile panik durumuna karar veren sözde kod

1:	Çerçeve geldiği sürece
2:	Yeni çerçeveyi yakala
3:	EĞER Son gelen RÇS kadar çerçevede kişi tespit edilmediyse 1'e GİT
4:	Son gelen RÇS kadar çerçevede
5:	Kişilerin hızlarını hesapla
6:	RHO'yu hesapla
7:	Son gelen AÇS kadar çerçevede
8:	Kişilerin hızlarını hesapla
9:	AHO'yu hesapla
10:	EĞER AHO, RHO'dan eşik değerden fazla farklıysa
11:	Panik durumu oluştu


2.3.3 Görüntüyü Bölgelere Ayırarak Panik Durumu Tespiti

Görüntünün tamamı değerlendirmeye alındığında kişilerin yalnızca hız verilerine bakmak panik durumu tespitinde yanıltıcı olmaktadır. Bu nedenle kameraya en yakın

ve en uzak iki kişinin hızlarını birlikte değerlendirmek yerine, bu kişileri birbirine yakın diğer kişilerle birlikte değerlendirmek için görüntü bölgelere ayrılmıştır.

Tespit edilen kişinin bulunduğu bölgenin tayin edilmesinde kişinin ayak bastığı yer yerine tespit edildiği alanın orta noktası dikkate alınmıştır.

RHO ve AHO değerlerinin hesaplanması, görüntünün tamamıyla yapılan panik durumu tespiti ile aynıdır. Ancak bölgesel çalışmada, her bir bölgenin sahip olduğu AHO ve RHO değerleri Şekil 2.15'te görüldüğü gibi ayrı ayrı hesaplanmaktadır. Belirli bir eşik değerin üzerinde fark oluşturan AHO ve RHO değerleri sayesinde çalışılan bölgede bölgesel panik durumu tespit edilir.



Şekil 2.15 Görüntüdeki her bölge için hesaplanan AHO ve RHO değerleri

Panik tespit sisteminin hız değerlerine bağlı olarak çalışması Çizelge 2.3'teki sözde kodda gösterilmiştir. Her çerçeve için bu hesap dinamik programlama mantığıyla, her bir bölge için ayrı ayrı hesaplanır. Dolayısıyla her yeni çerçevede, belirlenen bölge sayısı kadar AHO ve RHO değeri hesaplanır.

Çizelge 2.3 Referans ve anlık değerler ile bölgesel panik durumuna karar veren sözde kod

1:	Her bölge için
2:	Çerçeve geldiği sürece
3:	Yeni çerçeveyi yakala
4:	EĞER Son gelen $RÇS$ kadar çerçevede kişi tespit edilmediyse 1'e GİT
5:	Son gelen $RÇS$ kadar çerçevede
6:	Kişilerin hızlarını hesapla
7:	Bölgedeki kişilerin hızlarıyla bölgenin RHO 'sunu hesapla
8:	Son gelen $AÇS$ kadar çerçevede
9:	Kişilerin hızlarını hesapla
10:	Bölgedeki kişilerin hızlarıyla bölgenin AHO 'sunu hesapla
11:	EĞER AHO , RHO 'dan eşik değerden fazla farklıysa
12:	Bölgesel panik durumu oluşt

Bölgesel panik durumunun oluşabilmesi için en son $RÇS$ kadar çerçevede insan tespit edilmesi, RHO 'nun hesaplanabilmesi gerek ve yeter şarttır. n kadar bölge ile çalışıldığında, bir çerçevenin B_i bölgesinde insan olup olmadığı (2.12)'da gösterilen işlev ile tespit edilir.


$$\text{İnsan}(B_i) = \begin{cases} 1, & \text{Son } RÇS \text{ kadar bölgede insan tespit edildi} \\ 0, & \text{diğer} \end{cases} \quad (2.12)$$

Her bir bölgenin kendine ait AHO ve RHO değerleri olacaktır. Buna göre bir bölgedeki RHO 'ya göre AHO hız değişiminin RHO 'ya oranı eşitlik (2.13) ile hesaplanarak AHO 'nun RHO 'ya göre değişimi elde edilir. $\text{İnsan}(B_i)$ fonksiyonu, bir aktivasyon fonksiyonu görevi görmektedir. $RÇS$ kadar çerçevede tespit edilen insan olmadığında eşitlik (2.13)'da belirtilen $HızDeğişimi$ sıfıra eşit olur.

$$HızDeğişimi(B_i) = \text{İnsan}(B_i) \times \frac{|AHO_{B_i} - RHO_{B_i}|}{RHO_{B_i}} \quad (2.13)$$

Hız değişiminden yola çıkılarak bölgesel panik durumunun oluşup oluşmadığı tespit edilir. Eşitlik (2.14) üzerinde yer alan θ , eşik değeri ifade etmektedir.


$$BölgeselPanik(B_i) = \begin{cases} 1, & HızDeğişimi(B_i) \geq \theta \\ 0, & diğer \end{cases} \quad (2.14)$$



Şekil 2.16 Çerçeve üzerinde bölgesel panik durumlarının gösterimi

Bölgesel panik durumunun gerçekleştiği bölge sayısı, kişi tespiti yapılan diğer bölgelere üstünlük kurabiliyorsa görüntünün bu çerçevesinde bir panik durumunun oluştuğu kabul edilir. Diğer bir deyişle, eşitlik (2.15) üzerinde de görüldüğü gibi, bölgesel panik durumu gerçekleşen bölge sayısı, insan tespit edilen bölge sayısının en az yarısı kadar olmasıyla panik durumu tespit edilmiştir. Şekil 2.16 üzerinde, son gelen RÇS kadar çerçeve dikkate alınarak bu çerçevenin beş bölgesinde insan tespit edildiği, bu beş bölgeden dört tanesinde panik durumunun oluştuğu, dolayısıyla bu çerçevede panik tespitinin gerçekleştiği sonucuna ulaşılır.

$$Panik(B) = \begin{cases} 1, & \frac{\sum_{i=1}^n AdayPanik(B_i)}{\sum_{i=1}^n İnsan(B_i)} > 0.5 \\ 0, & diğer \end{cases} \quad (2.15)$$



Şekil 2.17 Mekâna özgü farklılıkları incelemek amacıyla bölünmüş görüntü

Bölgelere ayrılarak yapılan çalışmada yalnızca perspektif özellikler değil aynı zamanda panik durumlarında mekâna özgü farklılıkların da değerlendirmeye alınması mümkündür. Şekil 2.17’de görülen, kişilerin alışveriş yapmak için yavaş hareket ettiği mağaza önleri veya yalnızca bir yere ulaşmak için ortadan yürümeleri gibi mekânsal farklılıkların bulunduğu görüntülerde, “Mağaza önü bu bölgededir, burada kişiler yavaş yürür.” veya “Kişiler görüntünün bu bölgesinde daha hızlı hareket eder.” gibi herhangi bir tanımlama yapmadan sadece bölgeleri belirleyerek değerlendirme yapılabilir.

2.3.4 Bölgesel Adaptif Eşik Değerin Belirlenmesi

Kişi tespiti ve takibi sırasında yaşanabilen hatalı tespitler nedeniyle hız değişimlerinde sapmalar görülebilmektedir. Bu sapmalar nedeniyle de yanlış pozitif panik tespitleri görülmektedir. Bu yanlış panik tespitlerini engellemek için her bir bölgede RHO’nun standart sapması eşitlik (2.16)’da gösterildiği gibi hesaplanır. Bu eşitlikte standart sapma hesabı, sisteme ulaşan en son RÇS kadar çerçeve için gerçekleştirilir.

$$s_{B_i} = \sqrt{\frac{1}{RÇS - 1} \sum_{c=1}^{RÇS} (RHO_{(B_i,c)} - \overline{RHO_{B_i}})^2} \quad (2.16)$$

Standart sapma değerinin RHO’ya oranı alındıktan sonra eşik değeri bu oran kadar yukarıya çekilir. Anlatılan işlemin sözde kodu Çizelge 2.4’te gösterilmiştir.

Çizelge 2.4 Bölgesel adaptif eşik değeri hesaplaması sözde kodu

1:	Çerçeve geldiği sürece
2:	Yeni çerçeveyi yakala
3:	EĞER Mevcut çerçeve sayısı AÇS’nin tam katı değilse 1’e GİT
4:	RÇS kadar çerçevede RHO’ları elde et
5:	RHO’ların standart sapmasını hesapla
6:	Standart sapmanın RHO’ya oranını bul
7:	Bulunan oran kadar eşik değeri artır


Bölgesel eşik değeri hesaplanmasında, eşik değerini her çerçevede hesaplamak yerine AÇS kadar çerçevede bir kez hesaplanmıştır. Bu işlem Çizelge 2.4’ün üçüncü adımında gösterilmiştir.

PANİK VERİSETLERİ

Panik tespit sisteminin performansının değerlendirilebilmesi için normal bir şekilde hareket eden kişilerin, panik durumu gerçekleştikten sonra koşmaya başladığı görüntüler kullanılmıştır.

3.1 UMN Olağandışı Kalabalık Aktivitesi Veriseti

Geliştirilen sistemin başarısını değerlendirmek için Minnesota Üniversitesi'nin UMN olağandışı kalabalık aktivitesi veriseti kullanılmıştır [24]. Verisetinde kapalı ve açık mekânların olduğu 11 senaryodan oluşan üç farklı sahne Şekil 3.1'de gösterilmiştir. Tüm senaryolar 320 x 240 piksel çözünürlükte tek bir video dosyası halinde sunulmuştur.



Şekil 3.1 UMN verisetindeki üç sahnenin normal ve panik durumları

UMN veriseti üzerinde çalışabilmek için her bir senaryo farklı bir video dosyası olarak ayrılmıştır. Ancak bu veriseti üzerinde gerçek panik durumlarının hatalı bir şekilde videoda işaretlenmesi sebebiyle bu verisetinin gerçek panik durumlarını belirten sınırlar yeniden belirlenmiştir [25]. Belirlenen panik durumlarının başlangıç çerçeveleri ile toplam çerçeve sayıları Çizelge 3.1’de verilmiştir.

Çizelge 3.1 UMN verisetindeki senaryoların panik durumlarının başlangıç çerçeveleri ve toplam çerçeve sayıları

Sahne	Senaryo	Panik Durumunun Başlangıcı (çerçeve)	Toplam Çerçeve Sayısı
1	#1	485	625
	#2	676	828
2	#3	316	549
	#4	579	685
	#5	497	768
	#6	457	579
	#7	744	895
	#8	466	667
	#9	547	658
3	#10	580	677
	#11	725	808

3.2 Tez Çalışması için Oluşturulan Panik Veriseti

Bir lisenin orta alanında yapılan çekimde, Şekil 3.2’de görüldüğü gibi, heterojen dağılım gösteren durumların da örneklediği panik verisetinde 16 öğrenci yer almaktadır.




Şekil 3.2 Oluşturulan okul veriseti

Bu verisetinde çoğunlukla heterojen dağılım gösteren kişiler yer almaktadır. Böylece gerçekleştirilen panik tespit sisteminin en büyük zorluklardan birisi olan, kişilerin dengesiz dağılım gösterdiği durumlardaki başarısının da test edilmesi imkânı doğmuştur.

Okul verisetindeki yedi senaryoya ait panik durumlarının başlangıç çerçeveleri ile her bir senaryonun toplam çerçeve sayıları Çizelge 3.2’de gösterilmiştir.


Çizelge 3.2 Okul veriseti senaryolarının örnek çerçevesi, panik durumlarının başlangıç çerçeveleri ve toplam çerçeve sayıları

Senaryo	Örnek	Panik Durumunun Başlangıcı (çerçeve)	Toplam Çerçeve Sayısı
#1		1400	1503
#2		2323	2427
#3		3128	3257
#4		571	708
#5		2465	2582
#6		3290	3427
#7		2273	2345

BÖLÜM 4

UYGULAMA

Bu çalışmada, güvenlik kamerası görüntülerinden panik durumu tespiti yapan bir sistem tasarlanmış ve gerçekleştirilmiştir. Daha isabetli bir panik tespiti yapmak amacıyla, birbirine yakın konumdaki kişilerin birlikte değerlendirilebilmesini sağlamak için görüntü bölgelere ayrılarak incelenmiştir. Buna ek olarak, bölgenin karakteristiğine göre adapte olan adaptif eşik değeri yöntemiyle hatalı tespitlerin önüne geçilmesi hedeflenmiştir. Geliştirilen sistemin başarısı farklı senaryolar ile değerlendirilmiştir.




Şekil 4.1 Tasarlanan panik tespit sisteminin ekran görüntüsü

UMN veriseti üzerinde, en uygun AÇS ve RÇS değerlerinin belirlenebilmesi amacıyla çeşitli testler gerçekleştirilmiştir. Bu değerlerin seçimi, panik durum tespitini doğrudan etkilemektedir. Bu değerler arasındaki ilişkinin daha net ortaya koyulabilmesi amacıyla

önce çerçeveleri bölgelere ayırmadan, ardından da bölgelere ayırarak testler yapılmıştır.

Gerçekleştirilen panik tespit sisteminin ekran görüntüsü Şekil 4.1'de gösterilmiştir. AÇS, RÇS değerleri ile bölge sayıları başlangıçta kullanıcıdan istenen değerlerdir.

Yapılan deneysel çalışmalar sonunda, bir bölge için elde edilen RHO ve AHO değerleri arasındaki fark, AHO değerinin en az %50'si kadar olduğu durumda bu bölgede, bölgesel panik durumunun olduğu kabul edilmiştir. Görüntünün tamamında panik durumu olduğunun kabul edilmesi için ise bölgesel panik durumu içeren bölge sayısının, insan varlığının tespit edildiği bölge sayısının %50'sini geçmesiyle mümkün olmaktadır.



Şekil 4.2 Tespit edilen kişiler ve %30'un altında benzerlik gösteren tespitler


Deneysel çalışmalar sonucunda tüm verisetlerinde için tespit edilen insanların, insan sınıfına benzerlik oranı %30'dan fazla olanlar değerlendirmeye alınmıştır. Bu oran seçilirken özellikle kişi gölgelerinin belirgin olduğu UMN veriseti 11. senaryo üzerinde, tüm çerçevelerde kişi tespitlerinden gölgeler çıkarılırken en az sayıda kişi görüntüsünün etkilenmesine dikkat edilmiştir. Bu sayede, açık ortam çekimlerinde sıkça karşılaşılan ve insan olarak yanlış tespit edilen insan gölgelerinin veya insan silüetine benzer görüntülerin hatalı tespitlerinin azaltılması amaçlanmıştır. Şekil 4.2'de siyah bölge ile çevrelenmiş kısımlar değerlendirme dışı bırakılmış, kırmızı ile çevrelenen kısımlarda insan olduğu kabul edilmiştir. Tek bir çerçeve üzerinde insan olsa da seçilen benzerlik

oranı nedeniyle insan olarak kabul edilmeyen kısımlar, diğer çerçevelerde yakalanıp yörüngesi çıkartıldığından herhangi bir problem oluşturmamaktadır.

4.1 Görüntünün Tamamıyla Yapılan Tespit Sonuçları


Panik tespit sisteminde RÇS ve AÇS değerleri değişiminin panik tespiti üzerindeki farklarının incelenmesi için çeşitli durumlarda testler gerçekleştirilmiştir. En uygun RÇS ve AÇS değerleri seçilmeye çalışılmıştır.

UMN veriseti 8. senaryo üzerinde RÇS değerinin değişimi Şekil 4.3'te görülmektedir. Grafikte AHO ile RHO arasındaki hız değişimleri, gerçek panik durumunun gerçekleştiği bölge ve tespit edilen panik durumları gösterilmiştir. RÇS değeri 500 olarak seçildiğinde, kişilerin normal durumlardaki davranışları daha iyi örneklendiğinden panik durumu meydana geldiğinde kişilerin hız değişimleri daha erken tespit edilebilmektedir. Bu sayede AHO ile RHO arasındaki hız farkı daha fazla önem kazanmaktadır.




Şekil 4.3 UMN veriseti 8. senaryodaki RÇS değerinin etkisi

UMN veriseti 4. senaryo üzerinde AÇS değerinin değişimi Şekil 4.4'te görülmektedir. AÇS değeri yükseldikçe hatalı tespitler azalmaktadır; ancak panik durumu da geç tespit edilmektedir.




Şekil 4.4 UMN veriseti 4. senaryodaki AÇS değerinin etkisi

Testler sonucunda, 500 RÇS ve 25 AÇS değerleri ile en iyi sonuçlara ulaşıldığı görülmüştür. Şekil 4.5'te okul verisetinin, Şekil 4.6'da UMN verisetinin tüm senaryoları üzerinde 500 RÇS ve 25 AÇS değerleri kullanılarak yapılan test sonuçları gösterilmiştir.




Şekil 4.5 Okul veriseti 500 RÇS ve 25 AÇS değerleri test sonuçları



Şekil 4.6 UMN veriseti 500 RÇS ve 25 AÇS değerleri test sonuçları

4.2 Görüntüyü Bölgelere Ayırarak Yapılan Tespit Sonuçları

İnsanların yer aldığı video görüntülerinde, perspektif özellikler nedeniyle videonun her bölgesinde kişi hızları aynı olmayacaktır. Gerçekte aynı hızda da olsalar uzaktaki kişilerin yavaş, yakındakilerin hızlı hareket eder gibi görünmesi bilinen bir gerçektir. Bunun yanında görüntüsü alınan alana bağlı olarak, örneğin insanların alışveriş yaptığı mekânların önlerinde daha yavaş hareket etmeleri de mümkündür. Bu şekildeki alana özgü farklılıkları değerlendirebilmek amacıyla, video görüntüsünü bölgelere ayırarak her bölgenin ortalama kişi hızı değerinin elde edilmesiyle, panik durumunun tespiti gerçekleştirilmiştir.



Şekil 4.7 Hız değişim grafiği üzerinde UMN veriseti 1. senaryonun önemli anlarının gösterimi

Şekil 4.7’de hız değişim grafiği ile UMN veriseti 1. senaryodaki 300. çerçeve, gerçek panik durumunun başlangıç ve bitişi, tespit edilen panik durumunun başlangıç ve bitişleri işaretlenmiş ve verisetinin ilgili çerçeveleri eşleştirilmiştir.

4.2.1 Bölge Sayısının Belirlenmesi

Bölge sayısı, panik tespit sisteminin başarısını doğrudan etkilemektedir. Kurulan algoritma gereği, kişi tespit edilen bölgeler içerisinde panik durumu tespit edilen bölge sayısının, edilmeyenlere sayıca üstünlüğü halinde sistem üzerinde panik durumunun

oluştugu kabul edilmiştir. Bölgesel çalışmanın etkisini net olarak ortaya koyabilmek amacıyla en az üç bölge ile çalışılması olumlu sonuçlar vermektedir.


Panik durumunun oluşabilmesi için belirli sayıda bölgede, bölgesel panik durumunun oluşması gerekmektedir. Bir bölgede panik durumu oluşması için, RHO ve AHO değerleri arasındaki farkın RHO'ya oranının eşik değerin üzerinde olması gereklidir.

UMN veriseti üzerinde video çerçevelerinin bölgelere ayrılmış hali Şekil 4.8'de gösterilmiştir.




Şekil 4.8 UMN verisetindeki sahnelerin üç bölgeye ayrılmış hali

UMN veriseti 4. ve 6. senaryolar üzerinde görüntünün tamamıyla ve görüntüyü üç bölgeye ayırarak yapılan test sonuçlarının karşılaştırması Şekil 4.9 ve Şekil 4.10'da gösterilmiştir.



Şekil 4.9 UMN veriseti 4. senaryo üzerinde görüntünün tamamı ve üç bölge test sonuçları karşılaştırması



Şekil 4.10 UMN veriseti 6. senaryo üzerinde görüntünün tamamı ve üç bölge test sonuçları karşılaştırması

Şekil 4.10'da görüldüğü gibi 6. senaryo üzerinde yanlış pozitif tespitlerin fazlalığı göze çarpmaktadır. Bu durumun sebebi, hareket etmeden bekleyen kişi sayısının fazlalığı sebebiyle yer değiştiren birkaç kişinin anormallığe yol açmasıdır.


Gerçek panik durumunu mümkün olduğunca erken tespit etmek önemlidir. AÇS değeri 25 olarak seçilerek panik durumunun erken tespit edildiği ve görüntünün de üç bölgeye ayrılarak hatalı tespitlerin önüne geçildiği görülmektedir.

Yapılan deneysel çalışmalar sonunda, bir bölge için elde edilen RHO ve AHO değerleri arasındaki fark, AHO değerinin en az %50'si kadar olduğu durumda bu bölgede, bölgesel panik durumunun olduğu kabul edilmiştir. Görüntünün tamamında panik durumu olduğunun kabul edilmesi için ise bölgesel panik durumu içeren bölge sayısının, insan varlığının tespit edildiği bölge sayısının %50'sini geçmesiyle mümkün olmaktadır.

4.3 Bölgesel Adaptif Eşik Değer Kullanımı

Sabit ve her bölge için aynı eşik değerin seçilmesi yerine her bölge için ayrı değişken nitelikte eşik değeri belirlenerek testler gerçekleştirilmiştir.


Üç bölge üzerinde sabit ve adaptif eşik değeri kullanılan test sonuçları Şekil 4.11'de gösterilmiştir. Sonuçlar incelendiğinde, gerçek panik durumu dışında kalan çerçevelerde yanlış tespitlerin önemli ölçüde azaldığı görülmektedir.



Şekil 4.11 UMN veriseti 10. senaryo üzerinde üç bölgede sabit ve değişken eşik değer test sonuçları


Görüntünün tamamı için tek bir eşik değeri belirlemek, her durumu örnekleyecek güçte değildir. Yanlış pozitif durumların artmasında tek ve sabit eşik değeri belirlemenin etkili olduğu tespit edilmiştir. Bu sebeple her bölge için RHO değeri standart sapması oranında eşik değeri üzerinde değişim yapmanın olumlu sonuçları görülmüştür.

Şekil 4.12'de görüldüğü gibi, okul veriseti 5. senaryo üzerinde yapılan testlerde, tek bölgede çalışıldığında birçok yanlış pozitif panik tespitine rastlanmaktadır. Görüntü üç bölgeye ayrıldığında yanlış pozitif durumların neredeyse tamamının üstesinden gelindiği görülmektedirken bölgesel adaptif eşik değeri kullanılmasıyla bu senaryo üzerinde yanlış pozitif tespitlerin tamamının üstesinden gelindiği görülmektedir.



Şekil 4.12 Okul veriseti 5. senaryoda bölgelere ayırmadan, üç bölge ve adaptif eşik değeri kullanılarak yapılan test sonuçları

Şekil 4.12'de üç bölge çalışmaya ek olarak adaptif eşik değeri uygulanmasının, grafik üzerinde gösterilen değerlere etkisi Şekil 4.13'te gösterilmiştir. Şekil üzerinde her bir bölgenin hız değişimi gri, yeşil ve mavi renklerle çizgi grafik olarak belirtilirken bu bölgelerin kendilerine ait adaptif eşik değeri de yine aynı renklerle yatay bir çizgi olarak gösterilmiştir. Burada 0,5 olarak alınan sabit eşik değeri kabul edildiğinde aynı anda eşik değeri aşan Bölge 2 ve Bölge 3 panik durumuna sebep olmaktadır adaptif eşik değeri uygulandığında Bölge 3'teki hız değişimi eşik değeri aşmadığından hatalı panik tespiti engellenmiştir.



Şekil 4.13 Hatalı tespit edilen ve Şekil 4.12'de gösterilen panik durumunun adaptif eşik değeri yöntemiyle düzeltilmesi

4.4 Sonuçların Karşılaştırılması

RÇS ve AÇS değerleri, panik tespit sisteminin ilk aşamasında kullanıcıdan istenen değerlerdir ve bu değerler panik tespit sisteminin panik durumlarına karar vermesinde oldukça etkilidir.

RÇS değeri normal durumları örneklemeyi hedeflemektedir. Dolayısıyla RÇS değerinin büyük tutulmasıyla normal durumlar daha iyi örneklendiğinden panik durumları daha isabetli bir şekilde tespit edilebilmektedir.

AÇS değeri ise panik durumlarını örneklemeyi hedeflemektedir. AÇS'nin artırılması, panik durumlarının daha geç tespit edilmesine sebep olmakta ancak hatalı tespitleri de azalttığı görülmektedir.

Yapılan testlerde, bölgesel çalışmanın yanlış pozitif durumları azaltmada etkili olduğu görülmektedir. Her bir bölgedeki kişilerin birlikte ele alınması ve panik durumuna karar verilirken bu bölgelerdeki bölgesel panik durumlarından yararlanılması sistemin daha isabetli karar vermesinde etkilidir. Bölge sayısı ise kameranın baktığı alanın genişliği ve

büyükliğüne göre değişiklik gösterebilir. UMN ve okul veriseti üzerinde üç bölge ile çalışmanın olumlu sonuçlar doğurduğu görülmüştür.


Sabit eşik değeri kullanılan testlerin hepsinde eşik değeri sabit bir sayı olarak seçilmiş, ancak bu durumun bölgesel farklılıkları göz ardı ettiği görülmüştür. Bu sebeple her bir bölge için adaptif eşik değeri belirleme yaklaşımı kullanılmış ve yanlış pozitif durumların azaltılmasında ek katkısı olduğu görülmüştür.

Panik tespit sisteminin etkisini daha iyi değerlendirebilmek için Şekil 4.14'te görülen karmaşıklık matrisinden yararlanılmıştır.

GERÇEK	TESPİT	
	P	N
	P	N
P	TP	FN
N	FP	TN

Şekil 4.14 Karmaşıklık matrisi

Karmaşıklık matrisi değerlerinin hız değişim grafiği üzerinde karşılıkları Şekil 4.15'te gösterilmiştir.



Şekil 4.15 Karmaşıklık matrisi değerlerinin hız değişim grafiği üzerinde karşılıkları

Doğruluk (accuracy) değeri, yapılan tahminlerin gerçek değerlerle örtüşme oranını veren istatistiksel bir ölçümdür. Doğruluk hesabı eşitlik (4.1) ile gösterildiği gibi hesaplanır.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.1)$$

Doğruluk hesabı, sistem başarısı hakkında iyi bir fikir verirken tasarlanan sistemin amacına göre sistem başarısı farklı ölçümlerle değerlendirilebilir. Panik tespit

sisteminde yanlış pozitif durumların azaltılarak panik durumuna gerçek zaman aralığında karar verilmesi önemli olduğundan eşitlik (4.2)'de gösterilen hassasiyet (precision) değeri ile karşılaştırma yapılması daha uygundur.


$$Hassasiyet = \frac{TP}{TP + FP} \quad (4.2)$$

Şekil 4.10 üzerinde verilen grafikte, standart eşik değeri kullanılarak yapılan testin daha iyi sonuç verdiği görülmektedir. Buna rağmen ilk grafiğin doğruluk değeri 0,8339'dan 0,8218'e düşmüştür. Ancak hatalı tespit edilen panik durumlarının azaltılmasındaki en önemli ölçüt yanlış pozitif (FP) değerinin en aza çekilmesi ve gerçek panik sınırları içinde panik tespitinin yapılmasıdır. Gerçek panik durumu sınırları içinde yapılan tespit doğru pozitif (TP) ile ifade edilir. Bu açıdan bakıldığında hassasiyet değerinin Şekil 4.10'daki ilk grafik için 0,6923 olduğu görülürken daha iyi sonuç veren ikinci grafik için ise bu değer 1,0'a çıktığı görülmektedir.

UMN veriseti üzerinde yapılan testlerde Çizelge 4.1 ve Şekil 4.16'da da görüldüğü gibi bölgesel çalışmanın her zaman olumlu etkisi gözlenmezken adaptif eşik değeri kullanımıyla hassasiyet değerinin en yüksek değerine ulaşılmıştır.

Çizelge 4.1 UMN veriseti üzerinde görüntünün tamamı, üç bölge ve adaptif eşik değeri kullanılarak yapılan test sonuçlarının hassasiyet ve doğruluk değerleri

Senaryo	Görüntünün Tamamı		Üç Bölge		Üç Bölge + Adaptif Eşik Değeri	
	Hassasiyet	Doğruluk	Hassasiyet	Doğruluk	Hassasiyet	Doğruluk
UMN - 1	1,0000	0,9760	1,0000	0,9359	1,0000	0,8958
UMN - 2	1,0000	0,9528	1,0000	0,9081	1,0000	0,9057
UMN - 3	1,0000	0,7573	1,0000	0,6223	1,0000	0,5912
UMN - 4	0,9615	0,9868	1,0000	0,9371	1,0000	0,9137
UMN - 5	1,0000	0,7627	1,0000	0,7523	1,0000	0,7027
UMN - 6	0,8692	0,9273	0,6923	0,8339	1,0000	0,8218
UMN - 7	1,0000	0,8993	1,0000	0,8904	1,0000	0,8837
UMN - 8	1,0000	0,8363	1,0000	0,8273	1,0000	0,8183
UMN - 9	1,0000	0,9528	1,0000	0,9163	1,0000	0,9072
UMN - 10	1,0000	0,9734	0,9318	0,9704	1,0000	0,9778
UMN - 11	1,0000	0,9603	1,0000	0,9554	1,0000	0,9467
ORTALAMA	0,9846	0,9077	0,9658	0,8681	1,0000	0,8513



Şekil 4.16 UMN veriseti üzerinde bölgesel adaptif eşik değer test sonuçları


Okul veriseti üzerinde yapılan testlerde ise Çizelge 4.2 ve Şekil 4.17’de görüldüğü gibi bölgesel çalışmanın hem doğruluk hem de hassasiyet değerleri açısından olumlu sonuçlar verdiği gözlenmiştir. Bölgesel çalışmaya ek olarak adaptif eşik değer kullanımı ile yine yüksek doğruluk değeri elde edilmiş, hassasiyet değeri için en yüksek değerine ulaşılmıştır.

Çizelge 4.2 Okul veriseti üzerinde görüntünün tamamı, üç bölge ve adaptif eşik değeri kullanılarak yapılan test sonuçlarının hassasiyet ve doğruluk değerleri

Senaryo	Görüntünün Tamamı		Üç Bölge		Üç Bölge + Adaptif Eşik Değeri	
	Hassasiyet	Doğruluk	Hassasiyet	Doğruluk	Hassasiyet	Doğruluk
Okul – 1	1,0000	0,9840	1,0000	0,9880	1,0000	0,9880
Okul – 2	0,4649	0,9542	0,8654	0,9732	1,0000	0,9670
Okul – 3	1,0000	0,9742	1,0000	0,9776	1,0000	0,9776
Okul – 4	1,0000	0,9406	0,9579	0,9307	1,0000	0,9095
Okul – 5	0,3004	0,9144	0,9815	0,9954	1,0000	0,9915
Okul – 6	0,8803	0,9918	1,0000	0,9872	1,0000	0,9790
Okul – 7	1,0000	0,9936	1,0000	0,9898	1,0000	0,9898
ORTALAMA	0,8065	0,9647	0,9721	0,9774	1,0000	0,9718

Her iki verisetinde de hassasiyet değerlerine bakıldığında bölgesel çalışmanın yanında adaptif eşik değeri kullanımı, yanlış pozitif sonuçları azaltırken gerçek panik durumlarını sınırları içerisinde tespit etmede olumlu katkı sağlamıştır.

Üç bölge çalışmaya ek olarak adaptif eşik değeri kullanıldığında hassasiyet değerinin yükselmesine rağmen doğruluk değerinin düşmesinin sebebi, RHO’da yaşanan artışın adaptif eşik değeri için hesaplanan standart sapmayı etkilemesidir. Adaptif eşik değeri standart sapma ve RHO’ya göre değişim göstermesi sebebiyle panik durumunu gerçek sınırlar içinde algılamak yaşanan panik durumunun erken sonra erdiği bilgisi üretilmektedir.



Şekil 4.17 Okul veriseti üzerinde bölgesel adaptif eşik değer test sonuçları

SONUÇ VE ÖNERİLER

Bu çalışmada kalabalık ortamlarda bulunan kişilerin zamana bağlı olarak hareket değişimlerinden panik tespiti yapan bir sistem tasarlanmış ve gerçekleştirilmiştir. Panik tespiti için uygun verisetleri üzerinde yapılan testlerde, perspektif özelliklerin dikkate alınmasını sağlamak amacıyla görüntüyü bölgelere ayırarak çalışmanın yanlış pozitif panik durumlarını azaltmada olumlu etkisi olduğu görülmüştür. Bunun yanında görüntünün tamamı için tek bir eşik değeri belirlemek yerine her bölgenin kendi özelliklerine göre adaptif eşik değeri kullanımı da yanlış pozitif tespitlerin büyük ölçüde azaltılmasına katkı sağlamıştır.

Gelecek çalışmalarda perspektif özellikleri daha iyi yansıtabilecek hem gerçek ortamda hem de Unity ortamında geliştirilmesi düşünülen veriseti kullanılması ve görüntüdeki kişilerin büyüklüğüne ve yoğunluğuna bakılarak bölge sayısının adaptif bir şekilde belirlenmesi planlanmaktadır.

KAYNAKLAR

- [1] Redmon, J. ve Farhadi, A., (2017). "YOLO9000: better, faster, stronger", Computer Vision and Pattern Recognition (CVPR), 21-26 Haziran 2017, Honolulu.
- [2] Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P. ve Zitnick, C. L., (2014). "Microsoft COCO: Common objects in context", European Conference on Computer Vision (ECCV), 6-12 Eylül 2014, Zürih.
- [3] Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K. ve Fei-Fei, L., (2009). "Imagenet: A large-scale hierarchical image database", Computer Vision and Pattern Recognition (CVPR), 20-25 Haziran 2009, Florida.
- [4] Bera, A., Kim, S. ve Manocha, D., (2016). "Realtime anomaly detection using trajectory-level crowd behavior learning", Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, 27 Haziran-1 Temmuz 2016, Las Vegas.
- [5] Chaker, R., Aghbari, Z. A. ve Junejo, I. N., (2017). "Social network model for crowd anomaly detection and localization", Pattern Recognition, 61:266-281.
- [6] Hao, Y., Xu, Z., Wang, J., Liu, Y. ve Fan, J., (2016). "An Approach to Detect Crowd Panic Behavior using Flow-based Feature", Automation and Computing (ICAC), 7-8 Eylül 2016, Colchester.
- [7] Raghavendra, R., Bue, A. D., Cristani, M. ve Murino, V. (2011). "Optimizing interaction force for global anomaly detection in crowded scenes", Computer Vision Workshops (ICCV Workshops), 6-13 Kasım 2011, Barselona.
- [8] Mehran, R., Oyama, A. ve Shah, M., (2009). "Abnormal crowd behavior detection using social force model", Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 20-25 Haziran 2009, Miami.
- [9] Almeida, I. R. d., Cassol, V. J., Badler, N. I., Musse, S. R. ve Jung, C. R., (2017). "Detection of Global and Local Motion Changes in Human Crowds", IEEE Transactions on Circuits and Systems for Video Technology, 27(3):603-612.

- [10] Haque, M. ve Murshed, M., (2010). "Panic-driven event detection from surveillance video stream without track and motion features", Multimedia and Expo (ICME), 19-23 Temmuz 2010, Suntec City.
- [11] CAVIAR Test Case Scenarios, CAVIAR Dataset, <https://homepages.inf.ed.ac.uk/rbf/CAVIARDATA1/>, 13 Ocak 2018.
- [12] Kalman, R. E., (1960). "A new approach to linear filtering and prediction problems", Journal of basic Engineering, 82(1):35-45.
- [13] Kuhn, H. W., (1955). "The Hungarian method for the assignment problem", Naval Research Logistics (NRL), 2(1):83-97.
- [14] Wojke, N., Bewley, A. ve Paulus, D., (2017). "Simple Online and Realtime Tracking with a Deep Association Metric", 2017 IEEE International Conference on Image Processing (ICIP), 17-20 Eylül 2017, Pekin.
- [15] Nam , H. ve Han, B., (2016). "Learning multi-domain convolutional neural networks for visual tracking", Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 26 Haziran-1 Temmuz 2016, Las Vegas.
- [16] Simard, P. Y., Steinkraus, D. ve Platt, J. C., (2003). "Best practices for convolutional neural networks applied to visual document analysis", International Conference on Document Analysis and Recognition (ICDAR), 6 Ağustos 2003, Edinburgh.
- [17] Rosenblatt, F., (1958). "The perceptron: a probabilistic model for information storage and organization in the brain", Psychological review, 65(6):386.
- [18] Goodfellow, I., Bengio, Y. ve Courville, A., (2016). Deep Learning, 1. Baskı, MIT Press, Cambridge.
- [19] MathWorks, Convolutional Neural Networks, <https://ch.mathworks.com/fr/discovery/convolutional-neural-network.htm>, 9 Mayıs 2018.
- [20] Bewley, A., Ge, Z., Ott, L., Ramos, F. ve Upcroft, B., (2016) "Simple online and realtime tracking", IEEE International Conference on Image Processing (ICIP), 25-28 Eylül 2016, Phoenix.
- [21] Çayıroğlu, İ., (2012). "Kalman Filtresi ve Programlama," Fen ve Teknoloji Bilgi Paylaşımı, 1:1-6.
- [22] Welch, G. ve Bishop, G., (2006). "An Introduction to the Kalman Filter", https://www.cs.unc.edu/~welch/media/pdf/kalman_intro.pdf, 3 Mayıs 2018.

- [23] Zheng, L., Bie, Z., Sun, Y., Wang, J., Su, C., Wang, S. ve Tian, Q., (2016) "MARS: A Video Benchmark for Large-Scale Person Re-identification", European Conference on Computer Vision, 8-16 Ekim 2016, Amsterdam.
- [24] University of Minnesota, Unusual crowd activity dataset of University of Minnesota, <http://mha.cs.umn.edu/Movies/Crowd-Activity-All.avi>, 28 Ocak 2018.
- [25] Patil, N. ve Biswas, P. K., (2017). "Detection of global abnormal events in crowded scenes", Twenty-third National Conference on Communications (NCC), 2-4 Mart 2017, Piscataway.



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Hürkal HÜSEM
Doğum Tarihi ve Yeri : 13.03.1987 - Polatlı/ANKARA
Yabancı Dili : İngilizce
E-posta : hurkal@hotmail.com

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Lisans	Bilgisayar Mühendisliği	Namık Kemal Üniversitesi	2014
Lisans	Bilgisayar Öğretmenliği	Gazi Üniversitesi	2009
Lise	Fen Bilimleri	Buca Lisesi	2005

İŞ TECRÜBESİ

Yıl	Firma/Kurum	Görevi
2010	Millî Eğitim Bakanlığı	Bilişim Teknolojileri Öğretmeni

YAYINLARI

Bildiri

1. HÜSEM, H. ve KARSLIGİL, M. E., (2017). “Güvenlik Kamerası Görüntülerindeki Bölgesel Hız Değişimlerini Değerlendirerek Kalabalık Ortamlarda Panik Durumu Tespiti”, 26. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı, 2-5 Mayıs 2018, İzmir.

