

T.C.  
İSTANBUL AYDIN ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



HİBRİT MAKİNA ÖĞRENMESİ ALGORİTMALARIYLA  
VIDEO GÖRÜNTÜLERİNDE ANOMALİ TESPİTİ

DOKTORA TEZİ

Hayati TUTAR

Bilgisayar Mühendisliği Ana Bilim Dalı  
Bilgisayar Mühendisliği Programı

MART, 2024



**T.C.**  
**İSTANBUL AYDIN ÜNİVERSİTESİ**  
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**HİBRİT MAKİNA ÖĞRENMESİ ALGORİTMALARIYLA**  
**VIDEO GÖRÜNTÜLERİNDE ANOMALİ TESPİTİ**

**DOKTORA TEZİ**

**Hayati TUTAR**  
**(Y1913.610003)**

**Bilgisayar Mühendisliği Ana Bilim Dalı**  
**Bilgisayar Mühendisliği Programı**

**Tez Danışmanı: Prof. Dr. Ali GÜNEŞ**

**MART, 2024**

## ONAY FORMU

## ONUR SÖZÜ

Doktora tezi olarak sunduđum “Hibrit Makina Öğrenmesi Algoritmalarıyla Video Görüntülerinde Anomali Tespiti” adlı çalışmanın, tezin proje safhasından sonuçlanmasına kadarki bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Kaynakça’da gösterilenlerden oluştuđunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve onurumla beyan ederim. (18/03/2024)

Hayati TUTAR

## ÖNSÖZ

Doktora tezi çalışmalarım sürecinde, çalışmalarına aktif destek olan, tez danışmanım sayın Prof. Dr. Ali GÜNEŞ hocama, tez izleme süreçlerinde desteklerini esirgemeyen sayın Prof. Dr. Metin ZONTUL ve sayın Prof. Dr. Zafer ASLAN hocalarımıza teşekkürlerimi ve saygılarımı sunuyorum.

Bu doktora tez çalışmamı, tüm süreç boyunca beni aktif olarak destekleyen, değerli eşime ve umut dolu yarınlarımız olan sevgili kızlarımıza ithaf ediyorum.

Mart, 2024

Hayati TUTAR

# HİBRİT MAKİNA ÖĞRENMESİ ALGORİTMALARIYLA VIDEO GÖRÜNTÜLERİNDE ANOMALİ TESPİTİ

## ÖZET

Son yıllarda teknolojinin hızla gelişmesiyle beraber, kamera kullanım alanları ve video görüntüsü üretimi de aynı hızla artmaktadır. Dolayısıyla görüntü işleme tekniklerinin, hız, performans ve kaynak kullanımı açısından maksimum oranda geliştirilmesi ve iyileştirilmesine büyük bir ihtiyaç vardır. Özellikle kalabalık ve hareketli alanlarda anomalileri doğru olarak tespit edebilmek, yanlış tespitleri (false positive) en aza indirerek, başarı oranını artırmak zorlayıcı bir durumdur. Bundan dolayı çalışmamızda, birden fazla makine öğrenmesi algoritması ile Piksel bazlı video anomali tespiti (Piksel Based Video Anomaly Detection (PBVAD) ) ve Frame bazlı video anomali tespiti (Frame Based Video Anomaly Detection (FBVAD)) modelleri birleştirilerek, hibrit bir video anomali tespiti modelinin kullanılması önerilmiştir. PBVAD modelinde ile Spatio-Temporal (ST)'ı referans alan “Motion Influence Map (MIM)” algoritması, FBVAD modelinde ise k-Nearest Neighbor (kNN) ve Support Vector Machine (SVM)” makine öğrenmesi algoritmaları hibrit bir şekilde kullanılmıştır. Çalışmamızın diğer bir önemli özelliği, önceden üzerinde çok fazla çalışma yapılmamış olan, gerçek dünyaya dair 128 saatlik orijinal görüntüler içeren, UCF-Crime veri seti üzerinde, hibrit algoritmalarla başarıyı yüksek anomali tespiti yapılmış olmasıdır. Çalışmamızın başarı oranı, FBVAD-kNN modeli algoritması ile yapılan testlerde ortalama olarak 98.0 %'dir. Bununla beraber, PBVAD-MIM modeli algoritması ile yapılan testlerde ortalama olarak 80.7%'dir. PBVAD-MIM algoritmasıyla yapılan piksel bazlı anomali tespiti çalışmalarımızda, pikseller arasındaki hız ve değişim farkı büyük olan video görüntülerinde, başarı oranlarının daha yüksek, pikseller arasındaki hız ve değişim farkı küçük olan video görüntülerinde ise, başarı oranlarının daha düşük olduğu gözlemlenmiştir. Çalışmamızın, video görüntülerinde, gerçek zamanlıya yakın bir şekilde anomali

durumların tespit edilerek, olası zararlı etkilerinin önlenmesine, önemli düzeyde katkı sağlayacağı öngörülmektedir.

**Anahtar Kelimeler;** Makine Öğrenmesi, Görüntü İşleme, Video Analizi, Video Anomali Tespiti, UCF-Crime Veriseti, k-Nearest Neighbors (kNN); Support Vector Machine (SVM) Motion Influence Map (MIM), Hareket Etki Haritası, Optical Flow, Spatio-Temporal (ST)



# **VIDEO ANOMALY DETECTION WITH HYBRID MACHINE LEARNING ALGORITHMS**

## **ABSTRACT**

With the rapid development in technology in recent years, the use of cameras and the production of video and image data have similarly increased. Therefore, there is a great need to develop and improve video surveillance techniques to their maximum extent, particularly in terms of their speed, performance, and resource utilization. It is challenging to accurately detect anomalies and increase the performance by minimizing false positives, especially in crowded and dynamic areas. Therefore, this study proposes a hybrid video anomaly detection model combining multiple machine learning algorithms with Pixel -based video anomaly detection (PBVAD) and frame-based video anomaly detection (FBVAD) models. In the PBVAD model, the motion influence map (MIM) algorithm based on spatio-temporal (ST) factors is used, while in the FBVAD model, the k-nearest neighbors (kNN) and support vector machine (SVM) machine learning algorithms are used in a hybrid manner. An important result of our study is the high-performance anomaly detection achieved using the proposed hybrid algorithms on the UCF-Crime data set, which contains 128 h of original real-world video data and has not been extensively studied before. The AUC performance metrics obtained using our FBVAD-kNN algorithm in experiments were averaged to 98.0%. Meanwhile, the success rates obtained using our PBVAD-MIM algorithm in the experiments were averaged to 80.7%. In our pixel-based anomaly detection studies carried out with the PBVAD-MIM algorithm, it was observed that the performance rates were higher in video images with a large speed and change difference between pixels, and that the performance rates were lower in video images with a small speed and change difference between pixels. It is anticipated that our study will contribute significantly to preventing possible harmful effects by detecting anomalies in video images in near real time.

**Keywords:** Machine Learning; Computer Vision; Video Surveillance; Video Anomaly Detection; UCF-Crime Data Set; Motion Influence Map; Optical Flow; Spatio–Temporal (ST); k-Nearest Neighbors (kNN); Support Vector Machine (SVM)

# İÇİNDEKİLER

|  | <u>Sayfa</u> |
|--|--------------|
| ONUR SÖZÜ .....  | i            |
| ÖNSÖZ.....   | ii           |
| ÖZET.....  | iii          |
| ABSTRACT .....   | v            |
| İÇİNDEKİLER .....  | vii          |
| KISALTMALAR LİSTESİ.....   | xi           |
| ÇİZELGELER LİSTESİ.....  | xiii         |
| ŞEKİLLER LİSTESİ.....  | xv           |
| <b>I. GİRİŞ .....</b>  | <b>1</b>     |
| <b>II. LİTERATÜR ARAŞTIRMASI .....</b>                                     | <b>3</b>     |
| A. Literatür İnceleme ve Genel Bilgiler .....                              | 3            |
| 1. Kullanılan Yöntemler ve Algoritma Türleri .....                         | 3            |
| 2. Video Anomali Tespiti Veri Setleri .....                                | 7            |
| 3. Literatürdeki Video Anomali Tespiti Teknikleri ve Uygulama Türleri..... | 8            |
| B. Video Anomali Tespiti Hakkında Genel Bilgiler .....                     | 12           |
| 1. Video Anomali Tespiti Örnek Süreç Diyagramı .....                       | 12           |
| 2. Video Anomali Tespitinde Yaygın Kullanılan Modeller.....                | 13           |
| 3. Video Anomali Tespitinde Yaygın Kullanılan Veri Setleri.....            | 14           |
| 4. Video Anomali Tespitinde Özellik Çıkarım Teknikleri .....               | 15           |
| C. Video Anomali Tespitinde Kullanılan Metodolojilerin İncelenmesi .....   | 16           |
| 1. Bidirectional LSTM ile Video Anomali Tespiti Metodu.....                | 16           |

|   |           |
|---|-----------|
| 2. Derin Öğrenme Algoritmalarıyla Video Anomali Tespiti Metodu.....                       | 17        |
| 3. Spatio-Temporal ile Video Anomali Tespiti Metodu .....                                 | 18        |
| 4. SVM ile Video Anomali Tespiti Metodu.....  | 19        |
| 5. Temporal Segment C3D Video Anomali Tespiti Metodu .....                                | 20        |
| D. Video Anomali Tespiti Çalışmalarının Kıyaslama Tabloları ve Grafikleri.....            | 20        |
| 1. Anomali Tespitinin Frame Düzeyinde Performans Karşılaştırması .....                    | 20        |
| 2. Donanım ve Platform Düzeyinde Video Anomali Tespiti Karşılaştırması .                  | 21        |
| 3. Video Anomali Tespitinin Metot Düzeyinde Performans Karşılaştırması ..                 | 22        |
| 4. Video Anomali Tespiti Çalışmalarının Enerji Tüketimi Düzeyinde<br>Karşılaştırması..... | 24        |
| 5. Video Anomali Tespiti Çalışmalarının Sonuç Değerlendirme Grafikleri ...                | 24        |
| E. Literatür Araştırması Genel Sonuç Değerlendirmesi .....                                | 25        |
| <b>III. METODOLOJİ .....</b>  | <b>27</b> |
| A. Modelleme ve Algoritma Seçimi.....   | 27        |
| B. Model Mimari Diyagramı.....  | 28        |
| 1. Giriş Katmanı.....   | 29        |
| 2. Video Analizi ve Anomali Tespit Katmanı .....  | 29        |
| 3. Çıktı Katmanı.....   | 29        |
| C. Özellik Çıkarımı .....   | 29        |
| 1. Framelerin Alınması .....  | 30        |
| 2. Anahtar Frame/Vektörlerin Oluşturulması .....  | 31        |
| 3. Vektörlerin Eşleştirilmesi .....   | 31        |
| 4. İçeriklerin Tespit Edilmesi.....   | 31        |
| 5. İçerik Eşleşme Matrisi .....   | 31        |
| 6. Optik Akışı.....   | 31        |
| 7. İçeriklerin Açıklanması.....   | 31        |

|   |           |
|---|-----------|
| D. Frame Bazlı Anomali Tespiti Metodu .....   | 31        |
| 1. <i>k</i> -En Yakın Komşuluk (kNN) Algoritması İle Anomali Tespiti.....                 | 32        |
| 2. Destek Vektör Makinaları (SVM) Algoritması İle Anomali Tespiti .....                   | 32        |
| E. Piksel Bazlı Anomali Tespiti Metodu.....   | 33        |
| 1. Hareket Etki Haritası (MIM) Algoritması Adımları.....                                  | 33        |
| 2. Hareket Etki Haritasının Çıkarılması.....  | 33        |
| 3. Piksel Bazlı Özellik Çıkarma.....  | 35        |
| 4. Hareket Etki Haritası (MIM) Algoritması ile Video Anomali Tespiti ve<br>Diyagramı..... | 35        |
| 5. Hareket Etki Haritası (MIM) Algoritması Tanımı.....                                    | 36        |
| <b>IV. UYGULAMA VE TEST SONUÇLARININ DEĞERLENDİRİLMESİ .....</b>                          | <b>38</b> |
| A. Uygulama ve Test Ortamı Genel Bilgilendirme .....                                      | 38        |
| B. Veri Seti Seçimi.....  | 38        |
| C. Uygulama İmplementasyonu .....   | 39        |
| D. Test Sonuçlarının Değerlendirilmesi .....  | 40        |
| 1. <i>k</i> -En Yakın Komşuluk (kNN) Algoritması Test Sonuçları.....                      | 40        |
| 2. Destek Vektör Makinaları (SVM) Algoritması Test Sonuçları .....                        | 42        |
| 3. Hareket Etki Haritası (MIM) Algoritması Test Sonuçları .....                           | 44        |
| 4. Video Anomali Tespiti Örnek Görüntüleri .....  | 46        |
| E. Frame ve Piksel Bazlı Algoritmaların Test Sonuçlarının Karşılaştırılması.....          | 49        |
| 1. Abuse Kategorisi Algoritma Bazlı Sonuç Karşılaştırma .....                             | 49        |
| 2. Assault Kategorisi Algoritma Bazlı Sonuç Karşılaştırma .....                           | 50        |
| 3. Burglary Kategorisi Algoritma Bazlı Sonuç Karşılaştırma .....                          | 51        |
| 4. Explosion Kategorisi Algoritma Bazlı Sonuç Karşılaştırma .....                         | 52        |
| 5. Fighting Kategorisi Algoritma Bazlı Sonuç Karşılaştırma .....                          | 53        |
| 6. Road Accidents Kategorisi Algoritma Bazlı Sonuç Karşılaştırma .....                    | 54        |

|  |           |
|--|-----------|
| 7. Tüm Algoritmalar İçin Kategori Bazlı Genel Sonuç Karşılaştırması .....      | 55        |
| F. Test Sonuçlarının Literatürdeki Benzer Çalışmalarla Karşılaştırılması ..... | 59        |
| <b>V. SONUÇ VE ÖNERİLER.....</b>   | <b>60</b> |
| A. Tartışma .....  | 60        |
| B. Sonuç ve Öneriler .....   | 61        |
| <b>VI. KAYNAKÇA .....</b>  | <b>63</b> |
| <b>ÖZGEÇMİŞ.....</b>   | <b>80</b> |

## KISALTMALAR LİSTESİ

|                |  |
|----------------|--|
| <b>AE</b>      | : Auto-encoder (Otomatik kodlayıcı)  |
| <b>AUC</b>     | : Area Under the Curve (Eğri Altındaki Alan)   |
| <b>BD-LSTM</b> | : Bidirectional LSTM (Çift Yönlü LSTM)   |
| <b>BD-RNN</b>  | : Bidirectional RNN (Çift Yönlü RNN)   |
| <b>C3D</b>     | : Convolutional 3-Dimensional ConvNet (Evrışimli 3 Boyutlu ConvNet)                          |
| <b>CFM</b>     | : Confusion Matrix (Karışıklık Matrisi)  |
| <b>CNN</b>     | : Convolutional Neural Networks (Evrışimsel Sinir Ağları)                                    |
| <b>CUDA</b>    | : Compute Unified Device Architecture (Birleşik Cihaz Mimarisi Hesaplayıcı)                  |
| <b>CUHK</b>    | : Chinese University of Hong Kong (Hong Kong Çin Üniversitesi)                               |
| <b>DCT</b>     | : Discrete Cosine Transform (Ayrık Kosinüs Dönüşümü)   |
| <b>DNN</b>     | : Deep Neural Networks (Derin Sinir Ağları)  |
| <b>FBVAD</b>   | : Frame Based Video Anomaly Detection (Görüntü Karesi (Frame) Tabanlı Video Anomali Tespiti) |
| <b>FCN</b>     | : Fast Convolutional Networks (Hızlı Evrışimli Ağlar)  |
| <b>GAN</b>     | : Generative Adversarial Network (Üretken Çekişmeli Ağ)                                      |
| <b>GPU</b>     | : Graphic Processing Unit (Grafik İşlem Birimi)  |
| <b>HOF</b>     | : Histogram of Optical Flow (Optik Akış Histogramı)  |
| <b>HOG</b>     | : Histogram of Oriented Gradient (Yönlendirilmiş Degradenin Histogramı)                      |
| <b>I3D</b>     | : Inflated 3-Dimensional ConvNet (Büyütülmüş 3 Boyutlu ConvNet)                              |
| <b>kNN</b>     | : k-Nearest Neighbor (k-En Yakın Komşu)  |

|               |  |
|---------------|--|
| <b>LSTM</b>   | : Long Short-Term Memory (Uzun Kısa Süreli Bellek)   |
| <b>LTC</b>    | : Long-Term Context (Uzun-Süreli Bağlam)   |
| <b>MIL</b>    | : Multiple Instance Learning (Çoklu Örnek Öğrenme)   |
| <b>MIM</b>    | : Motion Influence Map (Hareket Etki Haritası)   |
| <b>OF</b>     | : Optical Flow (Optik Akış)  |
| <b>ONN</b>    | : One-Class Neural Network (Tek Sınıflı Sinir Ağı)   |
| <b>PBVAD</b>  | : Pixel Based Video Anomaly Detection (Piksel Tabanlı Video Anomali Tespiti)                   |
| <b>RF-KLT</b> | : Refrence Frame with Kanade-Lucas-Tomasi (Referans Frame ile Kanade-Lucas-Tomasi algoritması) |
| <b>RNN</b>    | : Recurrent Neural Network (Tekrarlayan Sinir Ağı)   |
| <b>ROC</b>    | : Receiver Operating Characteristic (Alıcı İşletim Karakteristikleri)                          |
| <b>RTFM</b>   | : Robust Transform Feature Magnitude (Sağlam Dönüşüm Özelliği Büyüklüğü)                       |
| <b>SFM</b>    | : Social Force Model (Toplumsal Güç Modeli)  |
| <b>SIFT</b>   | : Scale-Invariant Feature Transform (Ölçekle Değişmeyen Özellik Dönüşümü)                      |
| <b>SoTA</b>   | : State of the Art (Son Teknoloji)   |
| <b>ST</b>     | : Spatio-Temporal (Uzay-Zamansal)  |
| <b>SVM</b>    | : Support Vector Machine (Destek Vektör Makinesi)  |
| <b>UCSD</b>   | : University of California San Diego (California San Diego Üniversitesi)                       |
| <b>VLLM</b>   | : Video-Based Large Language Models (Video Tabanlı Büyük Dil Modelleri)                        |
| <b>YOLO</b>   | : You Only Look Once (YOLO Algoritması (Yalnızca Bir Kez Bakınız))                             |



## ÇİZELGELER LİSTESİ

### Sayfa

|             |  |    |
|-------------|--|----|
| Çizelge 1.  | Yaygın Kullanılan Video Olay Tespit Modelleri .....                                  | 13 |
| Çizelge 2.  | Video Anomali Tespitinde Özellik Çıkarım Teknikleri Tablosu .....                    | 15 |
| Çizelge 3.  | Anomali tespitinin Frame düzeyinde performans karşılaştırması .....                  | 21 |
| Çizelge 4.  | Anomali Tespitinin Donanım ve Platform Düzeyinde Performans<br>Karşılaştırması ..... | 22 |
| Çizelge 5.  | Anomali Tespitinin Metot Düzeyinde Performans Karşılaştırması.....                   | 23 |
| Çizelge 6.  | Anomali Tespitinin Enerji Tüketimi Düzeyinde Performans<br>Karşılaştırması .....     | 24 |
| Çizelge 7.  | Çalışmamızda Kullanılan UCF-Crime Veriseti Bilgileri Tablosu.....                    | 39 |
| Çizelge 8.  | FBVAD-kNN Algoritması AUC Skor ve Performans Tablosu.....                            | 40 |
| Çizelge 9.  | FBVAD-kNN Algoritması Karmaşıklık Matrisi (CFM) Referans<br>Tablosu.....             | 41 |
| Çizelge 10. | FBVAD-SVM Algoritması AUC Skor ve Performans Tablosu.....                            | 42 |
| Çizelge 11. | FBVAD-SVM Algoritması Karmaşıklık Matrisi (CFM) Referans<br>Tablosu.....             | 43 |
| Çizelge 12. | PBVAD-MIM Algoritması AUC Skor ve Performans Tablosu.....                            | 44 |
| Çizelge 13. | PBVAD-MIM Algoritması Karmaşıklık Matrisi (CFM) Referans<br>Tablosu.....             | 45 |
| Çizelge 14. | UCF-Crime Veriseti Abuse Kategorisi Algoritma Bazlı Sonuç Skor<br>Tablosu.....       | 49 |
| Çizelge 15. | UCF-Crime Veriseti Assault Kategorisi Algoritma Bazlı Sonuç Skor<br>Tablosu.....     | 50 |

|   |    |
|---|----|
| Çizelge 16. UCF-Crime Veriseti Burglary Kategorisi Algoritma Bazlı Sonuç Skor Tablosu.....        | 51 |
| Çizelge 17. UCF-Crime Veriseti Explosion Kategorisi Algoritma Bazlı Sonuç Skor Tablosu.....       | 52 |
| Çizelge 18. UCF-Crime Veriseti Fighting Kategorisi Algoritma Bazlı Sonuç Skor Tablosu.....        | 53 |
| Çizelge 19. UCF-Crime Veriseti Road Accidents Kategorisi Algoritma Bazlı Sonuç Skor Tablosu ..... | 54 |
| Çizelge 20. UCF-Crime Veriseti Algoritma ve Kategori Bazlı AUC Skor Tablosu                       | 55 |
| Çizelge 21. Test Edilen Algoritmalar İçin Özellik Çıkarma ve Anormallik Tespit Süreleri.....      | 56 |
| Çizelge 22. CF-Crime Veriseti Anomali Tespiti AUC Performans Karşılaştırma Tablosu.....           | 59 |

## ŞEKİLLER LİSTESİ

### Sayfa

|           |   |    |
|-----------|---|----|
| Şekil 1.  | Videolarda Anomali Tespiti Yayınlarının Yıllık Frekansı .....                           | 3  |
| Şekil 2.  | Video Anomali Tespiti Örnek Süreç Diyagramı .....                                       | 13 |
| Şekil 3.  | Video Anomali Tespitinde Yaygın Kullanılan Veri Setleri .....                           | 14 |
| Şekil 4.  | Normal ve Anormal (Anomali) Veri Seti Örnek Görüntüleri .....                           | 15 |
| Şekil 5.  | :Bidirectional LSTM Anomali Tespiti Framework .....                                     | 17 |
| Şekil 6.  | Derin Öğrenme Algoritmalarıyla Anomali Tespiti Metodu Örnek<br>Framework Yapısı .....   | 17 |
| Şekil 7.  | Derin Öğrenme Metodu ile Yapılan Video Anomali Tespiti Örnek<br>Görüntüleri .....       | 18 |
| Şekil 8.  | Spatio-temporal Anomali Tespiti Metodu I3D Akış Diyagramı .....                         | 19 |
| Şekil 9.  | SVM Metodu Video Anomali Tespiti Örnek Ekran Görüntüleri .....                          | 19 |
| Şekil 10. | Temporal Segment C3D Anomali Tespiti Metodu Akış Diyagramı .....                        | 20 |
| Şekil 11. | UCF-Crime Veri Setindeki AUC Sonuçlarının Karşılaştırılması.....                        | 24 |
| Şekil 12. | UCSD Ped1 Veri Setinde ROC Karşılaştırması; (a) frame-düzeyi, (b)<br>piksel-düzeyi..... | 25 |
| Şekil 13. | Hibrit Makine Öğrenme Algoritmalarıyla Anomali Tespiti Mimari<br>Diyagramı .....        | 28 |
| Şekil 14. | Video Görüntüsü Özellik Çıkarımı Adımları .....   | 30 |
| Şekil 15. | Hareket Etki Haritası (Motion Influence Map) Algoritması Adımları ....                  | 33 |
| Şekil 16. | Hareket Etki Haritası Algoritması Adımlarının Örnek Uygulaması .....                    | 35 |
| Şekil 17. | Hareket Etki Haritası Piksel Bazlı Özellik Çıkarma Diyagramı .....                      | 35 |

|  |    |
|--|----|
| Şekil 18. Hareket Etki Haritası (Motion Influence Map - MIM) İle Anomali Tespiti<br>Diyagramı .....  | 36 |
| Şekil 19. UCF-Crime Veriseti k-En Yakın Komşuluk (k-Nearest Neighbor -kNN)<br>Algoritması Video Anomali Tespiti Başarım (Accuracy) Oranları.....                   | 41 |
| Şekil 20. PBVAD-KNN Algoritması ile UCF-Crime Veri Seti için Video Anomali<br>Tespiti AUC & ROC Grafiği.....   | 42 |
| Şekil 21. UCF-Crime Veriseti Destek Vektör Makinaları (Support Vector Machine -<br>SVM) Algoritması ile Video Anomali Tespiti Başarım (Accuracy)<br>Oranları ..... | 43 |
| Şekil 22. PBVAD-SVM Algoritması ile UCF-Crime Veri Seti için Video Anomali<br>Tespiti AUC & ROC Grafiği.....   | 44 |
| Şekil 23. UCF-Crime Veri Seti PBVAD-MIM Algoritması ile Video Anomali<br>Tespiti AUC Başarım Oranları Grafiği .....  | 45 |
| Şekil 24. PBVAD-MIM Algoritması ile UCF-Crime Veri Seti için Video Anomali<br>Tespiti AUC & ROC Grafiği.....   | 46 |
| Şekil 25. UCF_Crime Abuse002 veri setinde trafikte suiistimal anomali durum<br>tespiti görüntüleri.....  | 46 |
| Şekil 26. UCF_Crime Assault002 veri setinde saldırı anomali durum tespiti<br>görüntüleri .....   | 47 |
| Şekil 27. UCF_Crime Burglary018 veri setinde hırsızlık anomali durum tespiti<br>görüntüleri .....  | 47 |
| Şekil 28. UCF_Crime Explosion045 veri setinde patlama anomali durum tespiti<br>görüntüleri .....   | 48 |
| Şekil 29. UCF_Crime Fighting006 veri setinde kavga anomali durum tespiti<br>görüntüleri .....  | 48 |
| Şekil 30. UCF_Crime RoadAccidents002 veri setinde trafik kazası anomali tespiti<br>görüntü örnekleri .....   | 48 |
| Şekil 31. UCF-Crime Veriseti Abuse Kategorisi Algoritma Bazlı AUC-ROC Eğrisi<br>Grafiği.....   | 49 |

|  |    |
|--|----|
| Şekil 32. UCF-Crime Veriseti Assault Kategorisi Algoritma Bazlı AUC-ROC Eğrisi Grafiği.....  | 50 |
| Şekil 33. UCF-Crime Veriseti Burglary Kategorisi Algoritma Bazlı AUC-ROC Eğrisi Grafiği .....  | 51 |
| Şekil 34. UCF-Crime Veriseti Explosion Kategorisi Algoritma Bazlı AUC-ROC Eğrisi Grafiği .....                                       | 52 |
| Şekil 35. UCF-Crime Veriseti Fighting Kategorisi Algoritma Bazlı AUC-ROC Eğrisi Grafiği .....  | 53 |
| Şekil 36. UCF-Crime Veriseti Road Accidents Kategorisi Algoritma Bazlı AUC-ROC Eğrisi Grafiği.....                                   | 55 |
| Şekil 37. UCF-Crime Veri Setinde Frame Tabanlı (FBVAD) ve Piksel Tabanlı (PBVAD) Video Anomalisi Tespiti AUC Oranları.....           | 56 |
| Şekil 38. UCF-Crime “Abuse, Assault, Burglary, Explosion, Fighting, Road Accident” Verisetleri Anomali Tespiti AUC-ROC Grafiği ..... | 58 |
| Şekil 39. UCF-Crime Veriseti Anomali Tespiti Başarım Oranları Karşılaştırma Grafiği.....   | 59 |

## I. GİRİŞ

Teknolojinin gelişimi ve hızla yaygınlaşması sonucu, video görüntü üretimi her geçen zaman artmaktadır. Aynı zamanda kamera ve video görüntülerinin kullanım alanları da gittikçe farklılaşmakta ve yaygınlaşmaktadır. Emniyet, güvenlik, askeriye, istihbarat, tıp, yol & trafik yönetimi, şehir ve kamu yönetimi, dijital tarım, endüstriyel üretim, kalite kontrol ve benzeri gibi birçok farklı alanda görüntü işlemeye duyulan ihtiyaç sürekli artmaktadır. Diğer taraftan yakın gelecekte otonom taşıtlar ile kara, hava, deniz otonom araçları gibi, anlık görüntü üreten ve işleyen cihazların kullanımının yaygınlaşmasıyla birlikte, hem görüntü işleme sistemlerinin kritikliği artmakta, hem de gerçek zamanlı görüntü işlemeye olan ihtiyaç yüksek düzeylere çıkmaktadır. Dolayısıyla görüntü işleme tekniklerinin geliştirilmesi, hız, performans ve kaynak kullanımı açısından maksimum oranda optimize edilmesi çok büyük önem arz etmektedir (Xu Z. et al. (2022)).

Tüm bunlarla birlikte, hala birçok alanda görüntü işleme ve analiz çalışmasında insan gözü ile manuel yöntemler etkin olarak kullanılmaktadır. Genel olarak bilindiği üzere insan gözüyle manuel görüntü analizi yapmak, hem çok fazla uzun sürmekte, hem kritik görüntülerin gözden kaçma olasılığı artmakta, hem de insan gücü ve finansal maliyeti çok yüksek olmaktadır. Diğer yandan hızla artan görüntü sayı ve süreleri dikkate alındığında, insan gözüyle analiz yönteminin, her geçen gün daha da zorlaşacağı ve talepleri karşılayamaz hale geleceği anlaşılmaktadır (Yadav R.K. et al. (2022)).

Çalışmamızın temel amacını, “*Video Anomali Tespiti*” oluşturmaktadır. Özellikle uzun süreli görüntülerde, sıra dışı (anomali) durumların tespit edilmesi için, video kaydının baştan sona kadar izlenmesi her zaman mümkün olamamaktadır. Dolayısıyla video görüntülerinin makine öğrenmesi teknikleriyle analiz edilerek, görüntülerin sınıflandırılması büyük bir önem arz etmektedir (Liu Y. et al. (2022)). Görüntülerin analiz ve sınıflandırma çalışması sonrasında, anomali görüntülerin gerçek zamanlıya yakın bir şekilde otomatik olarak tespit

edilmesi ve operatör ya da ilgililerin bu görüntülere yoğunlaşarak aksiyon alması hedeflenmektedir. Böylece sıra dışı durumların hem gözden kaçırılma olasılıkları minimize edilmesi, hem de gerçek zamanlıya yakın bir şekilde anomali durumun tespit edilerek olası zararlı etkilerin önlenmesi ya da en az düzeye indirilmesi sağlanmış olacaktır. Diğer taraftan insan sağlığı ve toplumun güvenliği için çok önemli düzeyde fayda sağlanacaktır. Aynı zamanda bu çalışmamızla, çevrenin korunması, zaman, imkân ve kaynakların verimli kullanılması gibi birçok dolaylı katkının sağlanması da hedeflenmiştir.

Çalışmamızda “*k-Nearest Neighbor (kNN)*, *Support Vector Machine (SVM)*” makine öğrenmesi algoritmaları ile Spatio-Temporal (ST)’ı referans alan “*Motion Influence Map (MIM)*” algoritması hibrit bir şekilde kullanılmıştır. Video görüntülerinin makine öğrenmesi teknikleriyle analiz edilerek sınıflandırılması sonrasında, elde edilen görüntü analiz ve sınıflandırma verileri referans alınarak, yine makine öğrenmesi teknikleriyle anomali görüntülerinin otomatik olarak tespit edilmesi ve sınıflandırılması çalışması yapılmıştır.

Çalışmamızın uygulama ve test aşamalarında, UCF\_Crime veri setine ait “*Kavga, Şiddet, Saldırı, Hırsızlık, Trafik Kazası ve Patlama*” gibi, toplumu ve kamu güvenliğini yakından ilgilendiren önemli olaylarla ilgili, video anomali tespiti üzerinde çalışmalar yapılmıştır.


Çalışmamız sürecinde öncelikle detaylı bir literatür taraması yapılmıştır. Literatür taraması kapsamında, yapılan çalışmalarda kullanılan “*veri setleri, özellik çıkarım teknikleri, geliştirilen modeller, algoritmalar, geliştirme ortamları, analiz sonuçları, başarımlar oranları*” detaylı olarak incelenmiştir. Çalışmamızın ikinci kısmında kullandığımız metodoloji ve teknik yöntemlere yer verilmektedir. Çalışmamızın üçüncü bölümünde geliştirdiğimiz uygulama ve test işlemlerimiz anlatılmaktadır. Son bölümde ise çalışmamızda elde edilen bulgular ve test sonuçları değerlendirilmektedir.

## II. LİTERATÜR ARAŞTIRMASI

### A. Literatür İnceleme ve Genel Bilgiler

Literatür taraması çalışmalarımızda, araştırma alanımızla ilgili olarak, 2017 ve sonrası olmak üzere, mümkün olduğunca güncel çalışmalara odaklanılmıştır.

Literatür taraması sürecinde ilgi alanımız olan Video Anomali Tespiti konusunda, incelediğimiz çalışmaların 2000 ile 2020 yılları arasındaki yıllık bazda yayın frekansı “Şekil 1” de gösterilmektedir. Şekil 1’deki grafiğe göre, özellikle son yıllarda bu alanda yapılan çalışmaların arttığı gözlemlenmektedir (Mu, H. et al. (2021)). Ayrıca bu grafiğin en son 2020 yılı Ağustos ayına ait verileri içerdiği dikkate alındığında, 2020 ve sonrasında, video anomali tespiti alanında yapılan çalışmaların, önceki yıllardaki gibi artarak devam ettiği, kolaylıkla tahmin edilebilir (Mu, H. et al. (2021)).



Şekil 1. Videolarda Anomali Tespiti Yayınlarının Yıllık Frekansı (Mu, H. et al. (2021))

Çalışmamızda Video Anomali Tespiti çalışmalarında kullanılan metodolojiler, algoritma ve modellemeler ile anomali tespit teknikleri analiz edilmiş olup, başarımları sonuçları kıyaslamalı olarak değerlendirilmiştir

### 1. Kullanılan Yöntemler ve Algoritma Türleri

Literatürde video anomali tespiti çalışmaları metodolojik olarak incelendiğinde, “*Spatio-Temporal I3D AE, Temporal Segment C3D, Convolutional*



*LSTM, Deep learning CNN/RNN, U-Net, Two U-Net blocks, LSTM network, Bidirectional LSTM prediction (BD-LSTM), Dual discriminator GAN, Multi-timescale*” gibi her çalışmada birbirinden farklı metodolojiler kullanıldığı görülmüştür (Mu, H. et al. (2021)). Anomali tespiti çalışmalarında farklı metodoloji kullanımlarına örnek olarak, Gianchandani ve arkadaşları “*Spatio-Temporal I3D AE*” anomali tespiti metodunu (Gianchandani, U. et al. (2019)), Sultani ve arkadaşları “*Temporal Segment C3D*” anomali tespiti metodunu (Sultani, W. et al. (2018)), Ullah ve arkadaşları “*Bidirectional LSTM*” anomali tespiti metodunu (Ullah, W. et al. (2020)), Wu ve arkadaşları ise “*Derin Öğrenme (CNN/RNN) Algoritmalarıyla*” anomali tespiti metodunu (Wu, C. et al. (2020)) kullanmışlardır.

Literatürdeki bazı çalışmalarda, *normal olanları öğrenme temelli (learning normality based)* video anomali tespiti tekniği kullanmışlardır (Morais, R. et al. (2019), Nayak, R. et al. (2021), Park, H. et al. (2020), Ramachandra, B. et al. (2020)). Bazı araştırmacılar da, *seyrek kodlama (sparse coding) tekniğini kullanarak* video anomali tespiti çalışmaları yapmışlardır (Luo, W. et al. (2017), Xu, K. et al. (2018), Luo, W. et al. (2021)).

Yu ve arkadaşları ile Zhang ve arkadaşları, zayıf denetimli (*Weakly Supervised*) makine öğrenme temelli olarak geliştirdikleri tekniklerle, video anomali tespiti çalışmaları yapmışlardır (Yu, S. et al. (2021); Zhang, D. et al. (2022)). Gong ile Wang ve arkadaşları ise video anomali tespiti çalışmalarında, denetimsiz anomali tespiti (*Unsupervised Anomaly Detection*) bazlı geliştirdikleri makine öğrenmesi algoritmalarını kullanmışlardır (Gong, D. et al. (2019); Wang, X. et al. (2021)). Liu, Y. ile Park, C. ve arkadaşları ise Uzay-Zamansal (*Spatio-Temporal*) algoritmasını referans alan yöntemlerle video anomali tespiti konusunda çalışmalar yapmışlardır (Liu, Y. et al. (2022), Park, C. et al. (2022)).

Video anomali tespiti alanında, “*Gauss Bileşimi (Gaussian Mixture)*” modelini baz alarak çalışmalar yapmışlardır. Cheng ve arkadaşları, Gaus Bileşimi modeli ile birlikte *hiyerarşik özellik gösterimi (hierarchical feature representation)* yöntemi ile video anomali tespiti üzerine çalışmıştır (Cheng, K.W. et al. (2015)). Erdinç, A. tez çalışmasında, Gaus Bileşimi modeli ile beraber Hiperspektral Görüntülerin Seyrek Ayırıştırılması tekniğini kullanarak video anomalilerin tespit edilmesi konusunu ele almıştır. (Erdinç, A. (2015)). Fan ve arkadaşları Gaus Bileşimi modeli ile *tam evrimsel değişken otomatik kodlayıcı*

(*fully convolutional variational autoencoder*) tekniğini birleştirerek video anormalliği tespiti ve lokalizasyonu çalışması yapmışlardır (Fan, Y. et al.(2020)).

Literatürdeki bazı çalışmalarda, *olasılığa dayalı modeller (probabilistic models)* kullanılarak video anomali tespiti çalışmaları yapılmıştır (Adam, A. et al. (2008), Muhr, D. et al. (2023)). Calderara ile Zhang ve arkadaşları ise *grafik temelli (graph based)* geliştirdikleri *makine öğrenme algoritması teknikleriyle*, video anomali tespiti çalışmaları yapmışlardır (Calderara, S. et al (2011); Markovitz, A. et al. (2020)).

Video anomali tespiti alanında, literatürdeki bazı çalışmalarda, anomali tespiti için *otomatik kodlayıcı teknikleri (Auto-encoder Technical)* kullanmışlardır (Wang, Y. et al.(2018), Chang, Y. et al.(2020), Zerrouki, Y. et al.(2020)). Zaheer, M.Z., Feng, J.C. ile Huang, C. ve arkadaşları, *kendi kendine yani denetimli öğrenme (self-supervised)* makine öğrenmesi bazlı geliştirdikleri algoritmalarla, video anomali tespiti çalışmaları yapmışlardır (Zaheer, M.Z. et al. (2020); Feng, J.C. et al. (2021), Huang, C. et al.(2022)).

Georgescu ve arkadaşları, MS COCO ve ResNet-50 metodolojisi ile 3D CNN ve YOLOv3 algoritmalarını kullanarak kendi kendini denetleyen ve çoklu görevli öğrenme yoluyla videolarda anormallik tespiti konusunu ele almışlardır (Georgescu, M.I. et al. (2021)). Özellikle, nesne düzeyinde kendi kendine öğrenen ve çoklu görevli öğrenme yoluyla videolarda anormal olay tespitine odaklanmışlardır. Öncelikle, nesnelere tespit etmek için önceden eğitilmiş bir detektör kullanmaktadırlar, sonrasında da üçü kendi kendine öğrenen ve birisi de bilginin özünü çıkarmaya dayalı olmak üzere, birden fazla vekalet (proxy) görevini ortaklaşa öğrenerek ayırt edici anomaliye özgü bilgiler üretmek için bir 3D evrişimli sinir ağını eğitmişlerdir. Deneysel sonuçlarında, hafif mimariye sahip, yaygın olarak kullanılan “*Avenue, ShanghaiTech ve UCSD Ped2*” isimli üç kıyaslama veri setine uygulandığında en gelişmiş yöntemlerden daha iyi performans gösterdiğini belirttiler (Georgescu, M.I. et al. (2021)).

Hao ve arkadaşları, Gabor filtreli dokuları (Gabor-filtered texture) ve SVM algoritmalarını kullanarak, uzay-zamansal (spatio-temporal) doku analizleri aracılığıyla etkili kalabalık anormallik tespiti konusunda çalışma yapmışlardır ve iki büyük buluşu tanımlamışlardır (Hao, Y. et al. (2018)). İlk olarak, geliştirilen

uzay-zamansal (spatio-temporal) doku çıkarma algoritması, en yüksek bilgi entropi değerlerine sahip Gabor filtreli (Gabor-filtered) dokuların benimsenmesiyle elde edilen, çok sayıda kalabalık hareket ayrıntısına sahip videolardan dokuları etkili bir şekilde çıkarmayı başarmıştır. İkinci olarak, kalabalıktaki anormal davranışları belirlemek amacıyla, geliştirilmiş gri seviyeli birlikte oluşum matrisi modelini kullanarak, kalabalık hareket modellerini (signatures) tanımlamak için yeni bir şema tasarlamışlardır. Deneylerinde, önerilen yöntemin performansını kıyaslamak için çeşitli klasik sınıflandırıcılar kullanmışlardır (Hao, Y. et al. (2018)).

Le V.T. ve arkadaşları, derin (deep 3D) CNN öğrenme ve ConvLSTM algoritmalarını kullanarak video anormallik tespiti için dikkat temelli artan otomatik kodlayıcılar (residual auto-encoders) üzerinde çalışmışlardır (Le V.T. et al. (2022)). Birleşik bir ağda bir mekansal sınıf (spatial branch) ve bir zamansal sınıf (temporal branch) benimseyen, hem mekânsal hem de zamansal bilgilerin etkili bir şekilde kullanılmasına olanak tanıyan bir sistem önerdiler. Genel kabul görmüş kıyaslama veri setleri ile yaptıkları deneysel çalışmalarda, UCSD Ped2 için %97,4, CUHK Avenue için %86,7 ve ShanghaiTech için %73,6 AUC performans değerlerini elde ettiklerini belirtmişlerdir (Le V.T. et al. (2022)).

Bazı çalışmalarda kalabalık sahnelerde anormallik tespiti, evrimsel sinir ağı (CNN) tabanlı algoritmalar kullanılarak gerçekleştirilmektedir. Örneğin Ravanbakhsh ve arkadaşları mevcut CNN modellerinden miras alınan semantik bilgiyi düşük seviyeli optik akıyla birleştirerek yerel anormallikleri ölçmeye çalıştıkları "*kalabalık hareket analizi için tak ve çalıştır CNN: anormal olay tespitinde bir uygulama*" isimli çalışmalarını yayınlamışlardır (Ravanbakhsh, M. et al.(2018)). Sabokrou ve ark. tam evrimsel sinir ağlarını (FCN'ler) ve zamansal verileri kullanarak kalabalık sahnelerde derin ve hızlı anormallik tespiti üzerinde çalışmışlardır; burada, önceden eğitilmiş, denetlenen bir FCN, denetlenmeyen bir FCN'ye aktarılarak sahnelerdeki (global) anormalliklerin tespit edilmesi sağlanmıştır (Sabokrou, M. et al.(2018)). Başka bir örnek olarak Smeureanu ve arkadaşları, bir dizi evrimsel sinir ağlarına (CNN'ler) dayalı derin öğrenme yöntemi ile, terkedilmiş bagajların video görüntüleri üzerinden gerçek zamanlı olarak tespit edilmesi uygulamasını geliştirmişlerdir (Smeureanu, S. et al.(2018)).

En güncel video anomali tespiti çalışmalarından birisi de Lv H. ve arkadaşları tarafından yapılan “büyük dil modelleri aracılığıyla video anomalisi tespiti” çalışmasıdır (Lv H. et al. (2024)). Söz konusu çalışmada Lv H. ve arkadaşları, “video tabanlı büyük dil modelleri (Video-Based Large Language Models – VLLM)” modellerinin yetersizliklerini azaltmak için, yeni bir ağ modülü olan “Uzun Vadeli Bağlam (Long-Term Context - LTC)” yöntemini önermişlerdir (Lv H. et al. (2024)). Önerilen LTC yönteminde, üç aşamalı eğitim modeli tasarlayarak, yaptıkları deneysel çalışmalarda, UCF-Crime veri setinde +3,86% AUC iyileştirme sonuçları elde etmişlerdir (Lv H. et al. (2024)).

## 2. Video Anomali Tespiti Veri Setleri

Video analizi ve anomali tespiti çalışmalarında genel olarak, “UCSD Ped1 (Li W. et al.(2013)), UCSD Ped2 (Dan X. et al.(2014)), Subway Entrance-Exit (Adam, A. et al.(2008)), UMN (Mehran, R. et al.(2009)), Avenue (Lu, C. et al.(2013)), UCF-Crime (Sultani, W. et al.(2018)), ShanghaiTech (Liu, W. et al.(2018)), XD-Violence (Wu, P. et al.(2020))” veri setlerinin kullanıldıkları gözlemlenmiştir.

Çalışmalarda en çok kullanılan veri seti olarak, UCSD Ped1 ve UCSD Ped2 dikkat çekmektedir. Genel olarak bu veri setleri üzerine çalışmalar yapıldığı için, bu veri setleri üzerinde yapılan son çalışmaların anomali tespiti başarımlarının %97 ve üzerine çıktığı görülmüştür (UCSD ped1 (Ganokratanaa et al.(2020)), UCSD ped2 (Qiang et al.(2021)). Diğer veri setlerinin ortalama başarımlar oranları, söz konusu veri setlerine oranla daha düşüktür. Özellikle de UCF-Crime veri seti üzerinde yapılan çalışmaların başarımlar oranları, diğer veri setleri üzerinde yapılan çalışmalara kıyasla daha düşük olduğu gözlemlenmiştir (Sultani et al.(2018), Tian, Y. et al.(2021)). Dolayısıyla çalışmamızda özellikle UCF\_Crime veri seti üzerine yoğunlaşmıştır.

Xia ve diğerleri, Destek Vektör Makinesi (SVM), derin sinir ağı (DNN), evrişimli sinir ağları (CNN), üretken rakip ağ (GAN) ve tek sınıf sinir ağı (ONN) algoritmalarını kullanarak anormal video olay tespiti üzerinde çalışma yapmışlardır. Deney sonuçlarında, PED1 veri setinde %94,9 ve PED2 veri setinde %94,5 AUC başarı oranı elde etmişlerdir (Xia, X. et al.(2021)).

### 3. Literatürdeki Video Anomali Tespiti Teknikleri ve Uygulama Türleri

Video görüntülerinde anomali tespiti çalışması, çok farklı sektörlerde kullanılabilir. Video görüntülerinde anomali tespiti çalışması, çok farklı sektörlerde kullanılabilir.

En güncel çalışmalardan birisinde, Mehta ve arkadaşları, Endüstri 4.0 bağlamında mobilya imalat süreçlerinde, otomatik kodlayıcılar ile görüntü işleme yöntemlerini kullanarak anomalilerin anlık olarak tespit edilmesi ve böylece yüksek hassasiyetle kalite kontrol süreçlerinin işletilmesi konusunu ele almışlardır (Mehta, D. et al. (2024)).

Yakın zamanlarda yapılan başka bir çalışmada ise, sağlık alanında video görüntülerinin analiz edilmesi için hem Quantum teknolojileri hem de hibrit makine öğrenme algoritmalarının kullanılması ele alınmıştır (Ajlouni, N. et al. (2023)). Klasik olarak CNN makine öğrenme algoritmasıyla Hibrit Quantum CNN (HQCNN) algoritması kullanımı karşılaştırılarak, HQCNN tekniğinin tıbbi görüntülerin analiz edilmesi ve teşhis işleminde daha iyi performans gösterdiği belirtilmiştir (Ajlouni, N. Et al. (2023)).

Son zamanlarda video anomali tespiti alanında yapılan güncel çalışmalardan birisinde, Duong ve arkadaşları, derin öğrenmeye dayanan (deep learning-based) algoritmalar kullanarak, video görüntülerinin analiz edilmesi ve anomali tespiti yapılması konusunu ele almıştır (Duong, H.T., et al (2023)). Diğer bir çalışmada ise Mehta ve arkadaşları, aynı şekilde derin öğrenme tabanlı algoritmalarla *insan davranışı ve aktivitelerini tanımak için* anomali tespiti hususunda araştırma yapmışlardır (Mehta, R., et al (2023)).

Sarikan ve arkadaşları, yol ve trafik konusunu ele alarak, araç trafiği görüntü işleme ve makine öğrenmesi algoritmalarıyla araç trafiğinde anomalilerin tespit edilmesi üzerine çalışma yapmışlardır (Sarikan, S.S. ve ark. (2018)). Başka bir çalışmada anomali olay tespitinin, “*enerji tüketimi*” düzeyinde performans karşılaştırması ele alınarak sonuçları değerlendirilmiştir (Khan, M.U. et al. (2019)).

Kiranyaz ve arkadaşları, gerçek zamanlı fonokardiyogram (PCG) anomali tespiti üzerinde çalışmışlardır (Kiranyaz, S. et al. (2020)). Kayıtlardaki sinyal-gürültü oranının (SNR) oldukça yüksek olduğunu varsayarak, kasıtlı olarak anormallik tespit problemine odaklanmışlardır. Yeni bir veri saflaştırma yaklaşımıyla eğitilmiş 1D Evrişimli Sinir Ağlarını kullanarak, önemli ölçüde daha

düşük gecikme ve hesaplama karmaşıklığıyla en yüksek tespit performansını ve gerçek zamanlı işleme yeteneğini elde etmeyi hedeflemişlerdir. Deneysel bulgularında, küresel fonokardiyogram (PCG) sınıflandırma yaklaşımının önemli dezavantajlarından kaçınmak için daha fazla iyileştirmenin kişiselleştirilmiş (yani hastaya özel) bir yaklaşım gerektireceğini belirtmişlerdir (Kiranyaz, S. et al. (2020)).

Literatürdeki bir çalışmada, gerçek zamanlı video görüntüleri makine öğrenme algoritmalarıyla işlenerek, sürücü uyuklama durumu ve yol güvenliği ele alınmıştır (Akı, M.O. (2017)).

Diğer bir çalışmada tarım üretim sektöründe yapılmıştır. Söz konusu çalışmada, görüntü işleme ve makine öğrenmesi teknikleri kullanılarak elmalarda çürüklük tespiti yapılmıştır (Cömert, O. (2019)).

Sultani ve arkadaşları, çalışmalarında gerçek hayata dair orijinal video görüntülerini içeren, 128 saatlik büyük bir veri seti (UCF-Crime) oluşturarak, insan davranışları ve anomali olayların otomatik olarak algılanması üzerinde araştırmalar yapmışlardır (Sultani, W. et al. (2018)). Eğitim etiketlerinin (yani anormal veya normal) klip düzeyi yerine video düzeyinde ayarlandığı, zayıf şekilde etiketlenmiş eğitim videolarından yararlanarak, derin bir çoklu örnek sıralama çerçevesi kullanarak anormallikleri belirlemeye çalıştılar. Yaklaşımlarında, normal ve anormal videoları çantalar olarak ve video bölümlerini çoklu örnek öğrenmedeki (Multiple Instance Learning - MIL) örnekler olarak değerlendirdiler ve anormal video bölümleri için yüksek anormallik puanları öngören derin bir anormallik sıralama modelinin otomatik öğrenmesini kolaylaştırdılar (Sultani, W. et al. (2018)).

Olay bazlı anomali tespiti alanında yapılan çalışmaların bazıları da incelenerek, sonuç grafikleri değerlendirilmiştir. Söz konusu çalışmaların özellikle toplumsal olaylarda “*kavga, hırsızlık, ateş etme*” vb gibi hususlar daha büyük bir başarı oranı ile tespit edilebilirken, “*patlama ve yol kazası*” gibi olayların tespit edilmesinde başarı oranlarının daha düşük olduğu gözlemlenmiştir (Tian, Y. et al. (2021)). Bu durumda kullanılan veri setlerindeki insan davranışı bazlı öğrenme verilerinin etkisinin de olup olmadığı araştırılması gereken hususlardan bir tanesidir.

Liu ve diğeri, bilgisayarlı görüş teknolojisine ve mevcut güvenlik kameralarına dayalı olarak havalandırıcılarda gerçek zamanlı anormallik tespiti için uzman bir sistem geliştirmişlerdir. Çalışmalarında, sabit bölgelerde hareket özelliği çıkarımı için referans frame ile Kanade-Lucas-Tomasi (RF-KLT) algoritması adı verilen yeni bir algoritma önermişlerdir. Önerilen uzman sistem, hem gerçek video veri setini hem de artırılmış video veri setini kullanarak havalandırıcılarda güçlü ve gerçek zamanlı, anormallik tespiti gerçekleştirmişlerdir (Liu, Y. et al. (2020)).

Literatürdeki bazı çalışmalarda uzaysal-zamansal (spatio-temporal) bazlı algoritmalar referans olarak kullanılmıştır. Bertini ve arkadaşları, bir sahnenin dinamik istatistiklerini görünümüyle birlikte yakalayıp, uzay-zamansal özelliklere dayalı olarak video gözetim uygulamalarında anormallik tespiti ve yerleştirme için bir yaklaşım önermişlerdir (Bertini, M. et al. (2012)). Başka bir örnekte Jiang ve arkadaşları, uzaysal-zamansal bağlamı kullanarak anormal video olayı algılamayı incelediler ve üç farklı uzaysal-zamansal bağlam düzeyinin dikkate alındığı anormallikleri tespit etmek için bağlama duyarlı bir yöntem önerdiler. Gerçek trafik videoları üzerinde yaptıkları deneylerde, ilgili trafik düzenlemelerine göre tehlikeli veya yasa dışı olan video anormalliklerini tespit ettiler (Jiang, F. et al. (2012)). Başka bir örnek olarak Li N. ve arkadaşları anormal olay tespiti ve lokalizasyonu için videolarda uzay-zamansal bağlam analizleri gerçekleştirmişlerdir. Yaklaşımları, sırasıyla kümeleme ve seyrek kodlama yoluyla küresel aktivite modellerini ve yerel göze çarpan davranış modellerini öğrenen, video küpleri içindeki uzay-zamansal video hacmi konfigürasyonlarının analizine dayanan denetimsiz bir istatistiksel öğrenme çerçevesi kullanmışlardır (Li, N. et al. (2015)). Diğer bir örnek olarak Li W. ve arkadaşları, kalabalık sahnelerdeki anormal davranışların tespiti ve lokalizasyonu için bir yöntem önermişler ve zamansal ve uzaysal anomalilerin tespit edilmesi için katılımlı bir detektör geliştirmişlerdir (Li N. et al. (2013)).

Wang ve arkadaşları bir çalışmada, uzun-kısa-dönemli (long short-term) özellik toplama yoluyla videoları sıkıştıran bir yaklaşım kullanarak gerçek zamanlı ve doğru nesne algılamayı incelemişlerdir (Wang, X. et al. (2021)). Anahtar video karesi (frame) özelliklerinde mevcut olan zengin bilgiyi anahtar olmayan video karesi (frame) özelliklerine hızlı bir şekilde yaymak için yeni bir kısa dönemli

(short-term) özellik toplama yöntemi önermişlerdir. Büyük ölçekli ImageNet VID karşılaştırması üzerindeki deney sonuçlarında, Titan X GPU (en son teknoloji doğrulukla eşdeğer) kullanarak 30 FPS hızında %77,2 mAP'ye ulaştıklarını belirtmişlerdir (Wang, X. et al. (2021)).

Literatürdeki bazı çalışmalarda referans olarak GAN algoritmaları kullanılmıştır. Örnek olarak Jiang ve arkadaşları, yalnızca normal olayları içeren eğitim videolarından öğrenen arka plandan bağımsız bir çerçeve önermişlerdir (Jiang F. et al (2011)). Video kareleri (frame) bir nesne detektörü, bir dizi görünüm ve hareket otomatik kodlayıcı ve bir dizi sınıflandırıcıdan oluşmaktadır (Jiang F. et al (2011)). Başka bir örnekte Ravanbakhsh ve arkadaşları, bir sahnenin normalliğinin dâhili bir temsilini geliştirmek için, normal video kareleri (frame) ve karşılık gelen optik akış görüntüleri kullanarak eğittikleri, üretken çekişmeli ağ (GAN) algoritmasına dayalı bir model kullanmışlardır. (Ravanbakhsh, M. et al (2017)).

Zaheer ve arkadaşları bir araştırmalarında, UCF-Crime ve ShanghaiTech veri setlerini kullanarak anormal olay tespiti için normalliği baskılama yöntemiyle, kümeleme destekli zayıf denetimli öğrenme üzerine çalışmışlardır (Zaheer, M.Z. et al.(2020)). Çalışmalarında, üç aşamalı katkılar sunan, zayıf denetlenen bir anormallik tespit yöntemi önermişlerdir. Deneysel sonuçlarında, UCF-Crime ve ShanghaiTech veri setlerinde sırasıyla %83,03 ve %89,67 AUC performans değeri elde ettiklerini belirtmişlerdir (Zaheer, M.Z. et al.(2020)).

Literatürdeki diğer çalışmaların bazılarında video anomali tespit algoritmalarının geliştirilmesine yönelik araştırmalar yapılmıştır. Sikdar ve arkadaşları kalabalık sahnelerde anormallik tespiti için uyarlanabilir, eğitim gerektirmeyen bir algoritma modeli geliştirmişlerdir (Sikdar, A. et al. (2020)). Önerdikleri çözümleri, çoklu nesne tespitine dayalı ilişkilendirme için uyarlanabilir bir 3D-DCT modeli ismiyle üç ana bileşeni içeren bir sistem hattından oluşmaktadır. Geliştirilmiş belirginlik kılavuzlu optik akış aracılığıyla yerel hareket tanımlayıcı üreterek ve Dünya hareket mesafesine dayalı anormallik tespiti yaptıklarını belirtmişlerdir (Sikdar, A. et al. (2020)). Tudor ve arkadaşları, videolardaki anormal olayların maskesini kaldırma girişiminde, videolarda anormal olay tespiti için herhangi bir eğitim dizisi gerektirmeyen yeni bir sistem modeli önermişlerdir (Tudor I. R. et al. (2017)). Xu D. ve arkadaşları



çalışmalarında, görünüm ve hareketin derin temsillerini öğrenerek videolardaki anormal olayları tespit etmeye çalıştılar ve özellik temsillerini otomatik olarak öğrenmeyi amaçlayan, derin sinir ağlarına dayalı yeni bir yaklaşım olan “*Görünüm ve Hareket DeepNet’i (Appearance and Motion DeepNet – AMDN)*” modelini önerdiler (Xu D. et al. (2020)). Ek olarak, öğrenilen özelliklere dayanarak, her bir girişin anormallik puanlarını tahmin etmek için birden fazla tek sınıflı SVM modeli kullanılmıştır. Son olarak, hesaplanan puanları birleştirmek ve anormal olayları tespit etmek için yeni bir geç füzyon stratejisi önerilmiştir (Xu D. et al. (2020)).

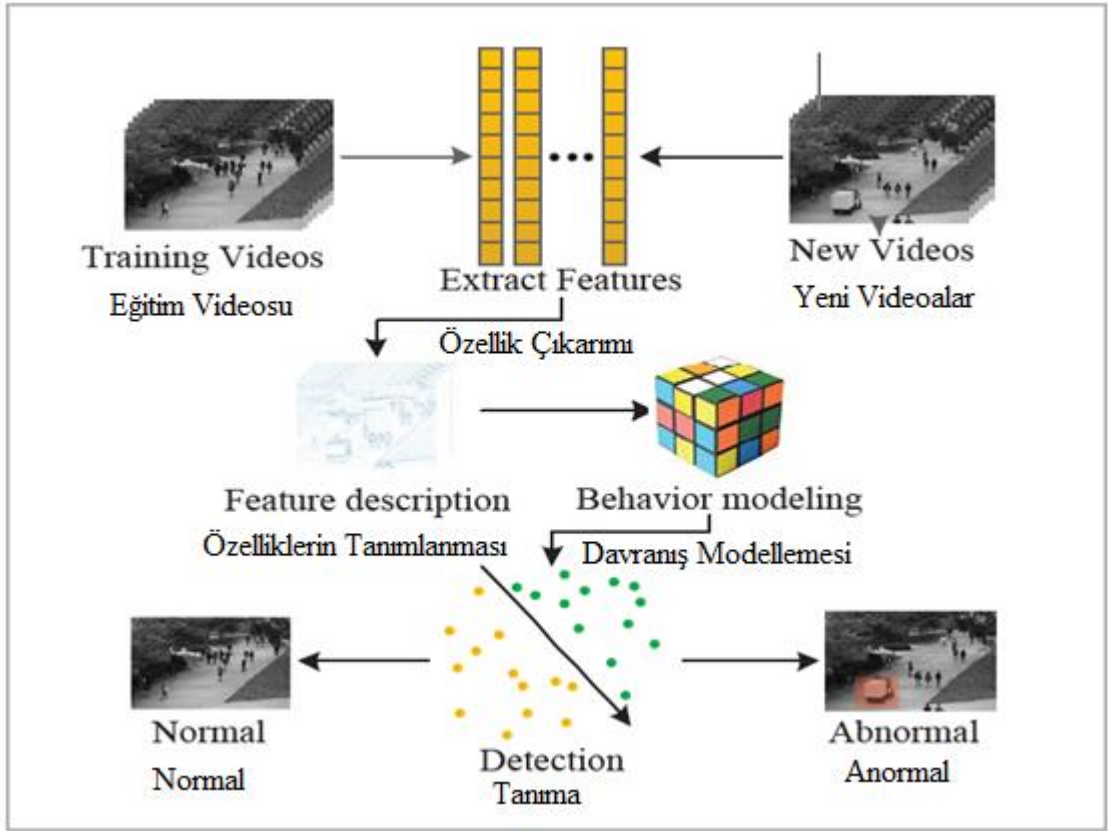
Literatürdeki bazı çalışmalarda, araştırmacılar *video görüntüleri içerisinde nesne (obje) tanıma* konusunda çalışmalar yapmışlardır (Yang, C.L. et al. (2021); Ionescu, R.T. et al. (2019); Perazzi, F. et al. (2017)). Diğer çalışmaların bazılarında ise araştırmacılar, video görüntüleri içerisindeki anomali hareketlerin ve anomali hareketliliklerin tanınması alanında araştırma ve anomali tespiti çalışmaları yapmışlardır ( Liu, T., et al. (2021); Zhang, X., et al. (2020); Nguyen, T.N., et al. (2019); Zhu, Y., et al (2019)).

Tüm bunlarla birlikte, özellikle kalabalık alanlarda anomali tespiti çalışmalarının 2010’lu yıllardan itibaren arttığı da gözlemlenmiştir. (Öngün, C. (2014)).

## **B. Video Anomali Tespiti Hakkında Genel Bilgiler**

### **1. Video Anomali Tespiti Örnek Süreç Diyagramı**

Video Anomali Tespiti sürecini, özet bir şekilde anlatan örnek süreç diyagramı Şekil 2’de gösterilmektedir (Mu, H. et al. (2021)). Şekilde de görüleceği üzere, diyagramdaki süreci kısaca şu şekilde özetleyebiliriz; ilk aşamada eğitim ve test videoları sisteme giriş yapılmakta, sonra özellik çıkarımı (feature extraction) işlemi gerçekleştirilmekte, sonra özelliklerin tanımlanması yapılmaktadır. Daha sonra da davranış modellemesi yapılarak normal ve anomali olan davranışların tespit edilmesi işlemleri gerçekleştirilmektedir.



Şekil 2. Video Anomali Tespiti Örnek Süreç Diyagramı (Mu, H. et al. (2021))

## 2. Video Anomali Tespitinde Yaygın Kullanılan Modeller

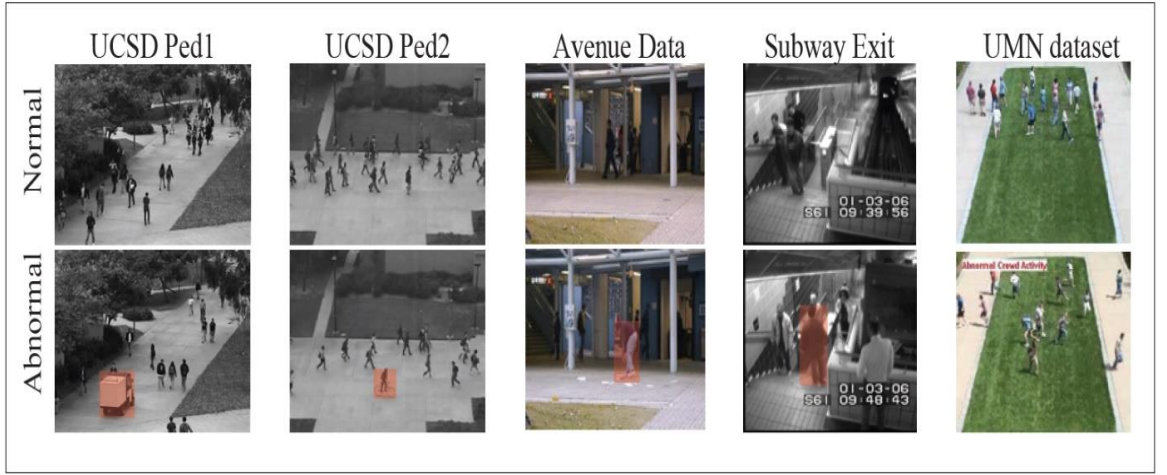
Video anomali tespitinde yaygın kullanılan “*video olay tespit modelleri*”, üç ayrı grup halinde Çizelge 1’de gösterilmektedir (Mu, H. et al. (2021)).

Çizelge 1. Yaygın Kullanılan Video Olay Tespit Modelleri (Mu, H. et al. (2021))

| Model Grubu                           | Model Adı                         |
|---------------------------------------|-----------------------------------|
| Yeniden Oluşturma<br>(Reconstruction) | Hierarchy of MDT models           |
|                                       | Discrete Cosine Transform (DCT)   |
|                                       | Non-negative matrix factorization |
| (Uzmanlık/İlgi Alanı)<br>Domain       | A taxonomy of domain anomalies    |
|                                       | Graph kernel SVM                  |
|                                       | Nonlinear one-class SVM           |
|                                       | Bayesian hierarchical method      |
|                                       | Entropy approach Probabilistic    |
| Noktasal Uzaklık<br>(Distance)        | Motion-field shape description    |
|                                       | Group motion features             |
|                                       | Clustering-driven deep AE         |

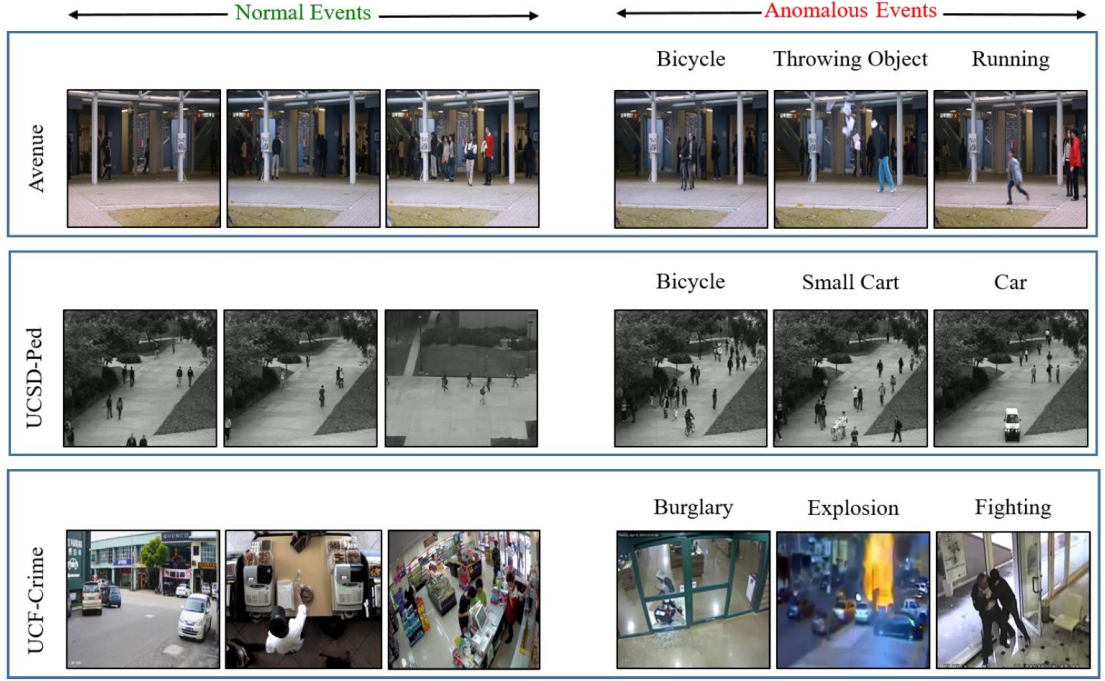
### 3. Video Anomali Tespitinde Yaygın Kullanılan Veri Setleri

Video anomali tespitinde yaygın kullanılan veri setleri, beş farklı grup olarak Şekil 3'te gösterilmektedir (Mu, H. et al. (2021)). Şekildeki örneklerden de anlaşılacağı üzere, “UCSD Ped1, UCSD Ped2, Avenue Data, Subway Exit ve UMN Dataset” isimli veri setleri video anomali tespitinde kullanılmaktadır. Bunların dışında Şekil-4'te görüleceği üzere, UCF-Crime veri seti de son zamanlardaki çalışmalarda kullanılmaktadır. Özellikle UCSD Ped veri setleri en yaygın olarak kullanılan veri setleridir.



Şekil 3. Video Anomali Tespitinde Yaygın Kullanılan Veri Setleri (Mu, H. et al. (2021))

Normal ve anomali veri seti örnek görüntülerinin farklı bir örneği de Şekil 4'te gösterilmektedir (Amin, S.U. et al. (2022)). Şekil 4'te de görüldüğü üzere, UCF-Crime, UCSD-Ped ve Avenue veri setlerine ait farklı kategorilerde normal durum ve anomali olayların görüntü örnekleri gösterilmektedir.



Şekil 4. Normal ve Anormal (Anomali) Veri Seti Örnek Görüntüleri (Amin, S.U. et al. (2022)).

#### 4. Video Anomali Tespitinde Özellik Çıkarım Teknikleri

Video anomali tespitinde yaygın kullanılan “*özellik çıkarım teknikleri*”, iki ayrı grup olarak Çizelge 2’de gösterilmektedir (Mu, H. et al. (2021)).

Çizelge 2. Video Anomali Tespitinde Özellik Çıkarım Teknikleri Tablosu (Mu, H. et al. (2021))

| Özellik Çıkarım Grubu                                       | Özellik Çıkarım Tipi                     |
|---|--|
| Manuel/El Yapımı Özellik Çıkarımı<br>(Handcrafted features) | Optical Flow (OF)                        |
|   | Scale-Invariant Feature Transform (SIFT) |
|   | Histogram of Optical Flow (HOF)          |
|   | Social Force Model (SFM)                 |
|   | Histogram of Oriented Gradient (HOG)     |
| Öğrenme Esaslı Özellik Çıkarımı<br>(Learned features)       | N-Grams                                  |
|   | Spatio-Temporal (ST)                     |
|   | Generative Adversary Nets (GAN)          |
|   | Auto-encoder (AE)                        |

Çizelge 2’de de görüleceği üzere, öğrenme esaslı özellik çıkarımı grubu, “*Spatio-Temporal (ST), Generative Adversary Nets (GAN), Auto-encoder (AE)*” isimli özellik çıkarım tiplerinden oluşmaktadır. Manuel (el yapımı) özellik çıkarım

grubu ise, “*Optical Flow (OF), Scale-Invariant Feature Transform (SIFT), Histogram of Optical Flow HOF, Social Force Model (SFM), Histogram of Oriented Gradient (HOG), N-Grams*” isimli özellik çıkarım tiplerinden oluşmaktadır.

### **C. Video Anomali Tespitinde Kullanılan Metodolojilerin İncelenmesi**

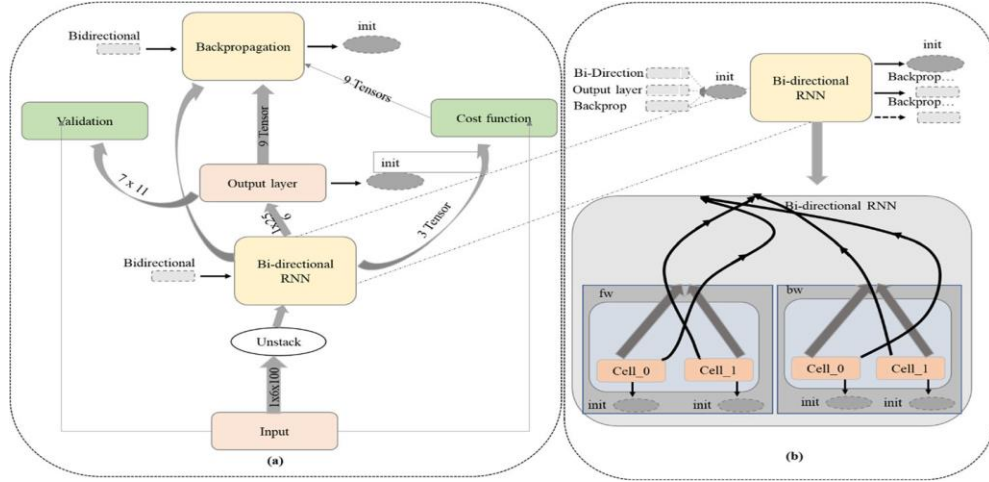
Bu bölümde, incelenen video anomali tespitinde yaygın kullanılan metodolojiler ve örnek çalışmalara ait mimari diyagram ve görüntülere yer verilmiştir.

Video anomali tespitinde yaygın kullanılan metodolojiler aşağıda listelenmiştir (Mu, H. et al. (2021));

- *Spatio-Temporal I3D AE*
- *Temporal Segment C3D*
- *Convolutional LSTM*
- *Deeplearning CNN/RNN*
- *U-Net*
- *Two U-Net blocks*
- *LSTM network*
- *Bidirectional LSTM prediction (BD-LSTM)*
- *Dual discriminator GAN*
- *Multi-timescale*

#### **1. Bidirectional LSTM ile Video Anomali Tespiti Metodu**

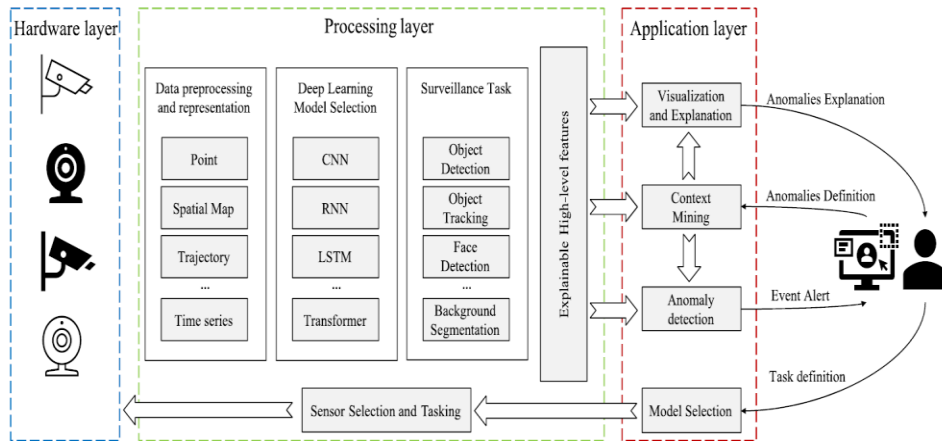
Ullah ve arkadaşlarının video anomali tespiti çalışmalarında önerdikleri “*Bidirectional LSTM ile Anomali Tespiti Metodu*” örnek mimari modeli Şekil 5’te gösterilmektedir (Ullah, W. et.al. (2020)). Bidirectional LSTM video anomali tespiti metodunun örnek mimari modeli şeklinde (Şekil 5) belirtilen (a) dış yapısı (external structure) ve (b) çift yönlü BD-LSTM’nin iç yapısını göstermektedir. Sağ üst kısım, BD-RNN hücresinin dış yapısındaki sıralı veri akışını gösterir (Ullah, W. et.al. (2020)).



Şekil 5. :Bidirectional LSTM Anomali Tespiti Framework (Ullah, W. et.al. (2020))

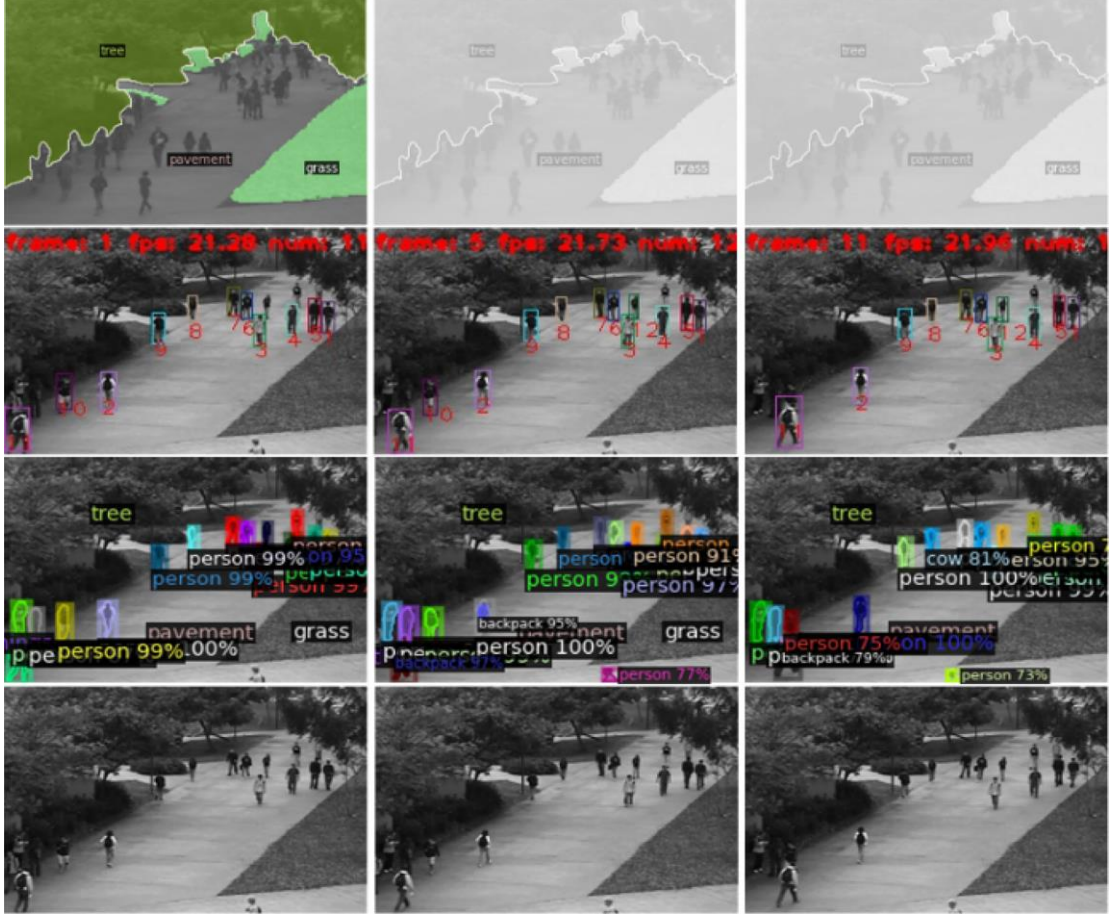
## 2. Derin Öğrenme Algoritmalarıyla Video Anomali Tespiti Metodu

Derin Öğrenme Algoritmalarıyla (CNN/RNN) Anomali Tespiti yönteminde, donanım katmanı, ham veri akışını orta katmana sağlar. Önceden eğitilmiş Derin Öğrenme modeliyle gömülü işleme katmanı, uygulama katmanına açıklanabilir üst düzey özellikler üretir. Uygulama katmanında üst düzey özellikler görselleştirilir. Anomali davranışının tanımına dayalı olarak bağlamsal özellikler üretir. Derin Öğrenme Algoritmalarıyla (CNN/RNN) Anomali Tespiti Metodu örnek mimari modeli yapısı Şekil 6’da gösterilmektedir. Şekilde de görüleceği üzere mimari model, “donanım katmanı (hardware layer), işlem katmanı (processing layer) ve uygulama katmanı (application layer)” olmak üzere, üç temel katmandan oluşmaktadır.



Şekil 6. Derin Öğrenme Algoritmalarıyla Anomali Tespiti Metodu Örnek Framework Yapısı (Wu, C. et al. (2021))

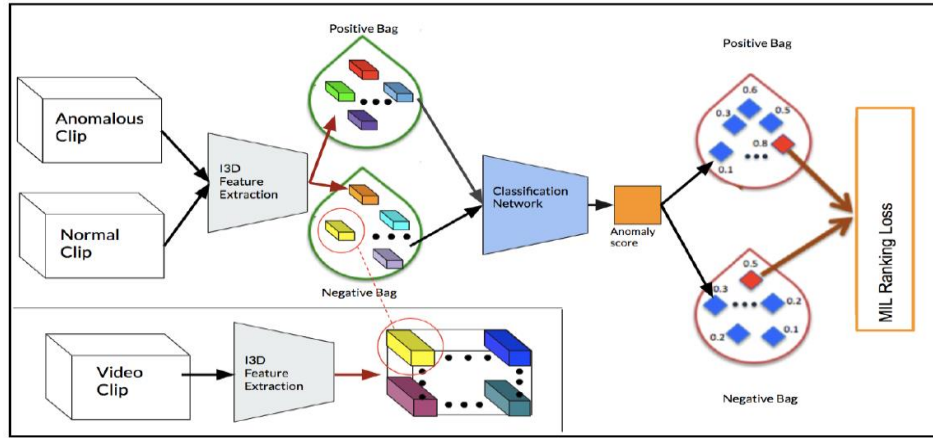
Derin Öğrenme Metodu ile yapılan Video Anomali tespitine ait örnek görüntüler, Şekil 7’de gösterilmektedir (Wu, C. et al. (2021)).



Şekil 7. Derin Öğrenme Metodu ile Yapılan Video Anomali Tespiti Örnek Görüntüleri (Wu, C. et al. (2021))

### 3. Spatio-Temporal ile Video Anomali Tespiti Metodu

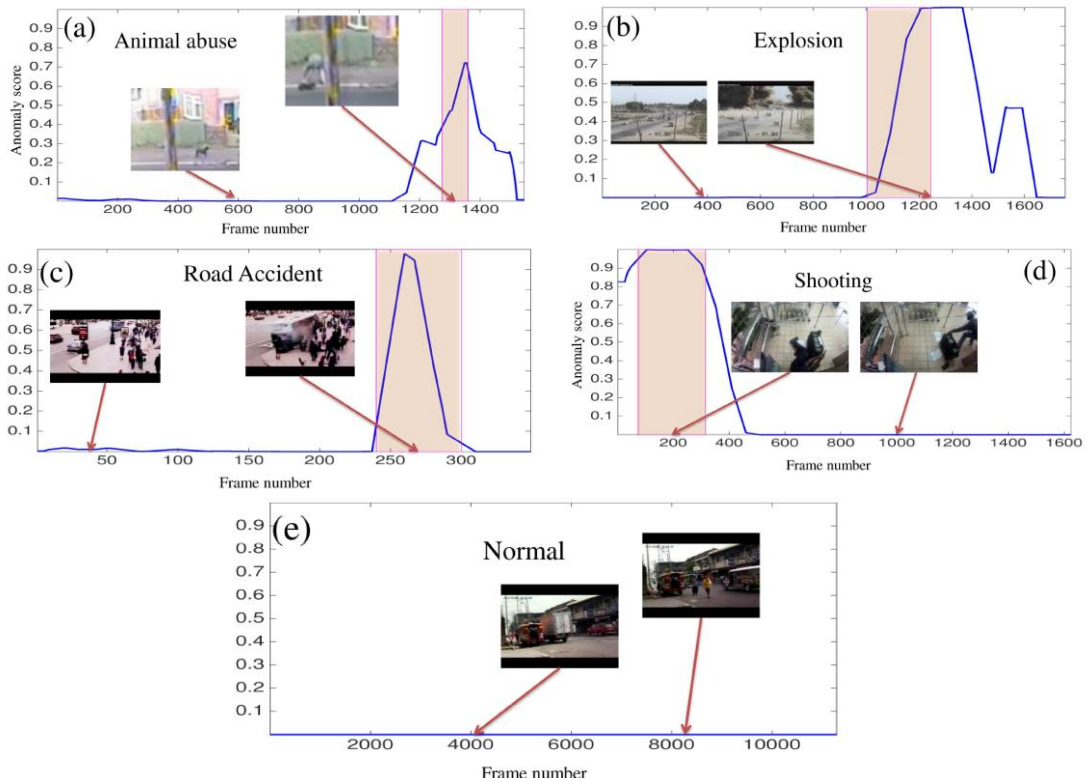
Gianchandani ve arkadaşları tarafından önerilen, Spatio-Temporal ile video anomali tespiti metodu örnek diyagramı Şekil 8’de gösterilmektedir (Gianchandani, U. et al. (2019)). Pozitif (bir yerde anormallik içeren) ve negatif (anormallik içermeyen) video klipler verildiğinde, I3D tekniği ile özellikleri çıkarılır ve özellik temsillerinin her birini çoklu uzay-zamansal (*spatio-temporal*) küboidlere bölünür. Daha sonra, her bir video klip bir küme grubu (bag) olarak temsil edilir ve her uzay-zamansal (*spatio-temporal*) segment, küme grubundaki bir örneği temsil eder. Sıralama kaybı, eğitim için her küme grubundaki (şekilde kırmızı ile gösterilen) en yüksek puanlar arasında hesaplanır (Gianchandani, U. et al. (2019)).



Şekil 8. Spatio-temporal Anomali Tespiti Metodu I3D Akış Diyagramı (Gianchandani, U. et al. (2019))

#### 4. SVM ile Video Anomali Tespiti Metodu

Sultani ve arkadaşlarının, SVM algoritması ile yaptıkları video anomali tespiti sonuçlarına ait görüntüler, aşağıda maddeler halinde sırayla verilmiştir. Görüntülerdeki renkli alanlar, anormal olay ve olay yerlerini ifade etmektedir. Şekil 9’da sırasıyla (a), (b), (c) ve (d) hayvan istismarı (köpek dövme), patlama, trafik kazası ve ateş etme içeren videoları gösterir. (e) ve (f) anormallik içermeyen normal videoları gösterir(Sultani, W. et al. (2018)).

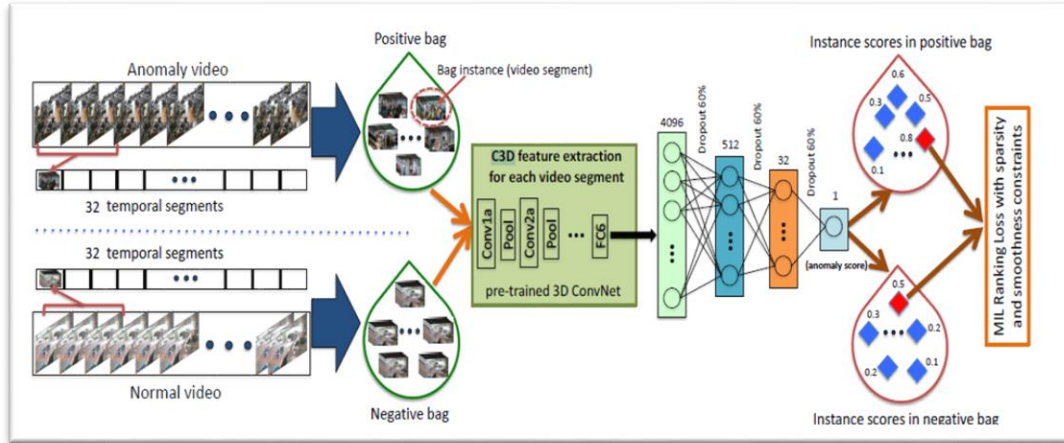


Şekil 9. SVM Metodu Video Anomali Tespiti Örnek Ekran Görüntüleri (Sultani, W. et al. (2018))



## 5. Temporal Segment C3D Video Anomali Tespiti Metodu

Sultani ve arkadaşları, video anomali tespiti çalışmalarında farklı bir yöntem olarak, “*Temporal Segment C3D Video Anomali Tespiti Metodu*”nu önermişlerdir. Önerdikleri modelin akış diyagramını Şekil 10’da gösterilmektedir (Sultani, W. et al. (2018)).



Şekil 10. Temporal Segment C3D Anomali Tespiti Metodu Akış Diyagramı (Sultani, W. et al. (2018))

Pozitif (bir yerde anormallik içeren) ve negatif (anormallik içermeyen) videolar göz önüne alındığında, her birini çoklu geçici video bölümlerine ayırılır. Sonra, her video bir küme grubu (bag) olarak temsil edilir ve her zamansal bölüm, küme grubundaki bir örneği temsil eder. Video segmentleri için C3D tekniği ile özellikleri çıkarıldıktan sonra, pozitif küme grubu ve negatif küme grubundaki en yüksek puanlı örnekler (kırmızı ile gösterilen) arasındaki sıralama kaybını hesaplayan yeni bir sıralama kaybı (ranking loss) fonksiyonunu kullanarak tam bağlantılı bir sinir ağı eğitilerek anomaliler tespit edilir (Sultani, W. et al. (2018)).

## D. Video Anomali Tespiti Çalışmalarının Kıyaslama Tabloları ve Grafikleri

Bu bölümde incelenen Video Anomali Tespiti çalışmalarına ait, veri seti bazlı sonuç verilerine ve AUC başarı oranlarına yer verilmiştir.

### 1. Anomali Tespitinin Frame Düzeyinde Performans Karşılaştırması

Anomali olay tespitinin frame düzeyinde performans karşılaştırması Çizelge 3’te gösterilmektedir. Tablodaki verilere göre, UCSD Ped1 veri setinde en iyi performansı “Optical flow-GAN” (Ravanbakhsh, M. et al. (2017)) gösterirken,

UCSD Ped2 veri setinde ise “STAN” metodu (Lee, S. et al. (2018)) en iyi performansa sahiptir.

Çizelge 3. Anomali tespitinin Frame düzeyinde performans karşılaştırması (Wu, C. et al. (2021))

| Referans                      | Metot                    | Ped1 [6] |         | Ped2 [6] |         |
|-------------------------------|--------------------------|----------|---------|----------|---------|
|                               |                          | AUC (%)  | EER (%) | AUC (%)  | EER (%) |
| Mahadevan, V. et al. (2010)   | Adam                     | 65       | 38      | 63       | 42      |
| Mehran, R. et al. (2009)      | Social force             | 67.5     | 31      | 63       | 42      |
| Mahadevan, V. et al. (2010)   | MDT                      | 81.8     | 25      | 82.9     | 25      |
| Leyva, R. et al. (2017)       | Compact feature set      | 82       | 21.1    | 84       | 19.2    |
| Turchini, F. et al. (2017)    | Convex polytope ensemble | 78.2     | 24      | 80.7     | 19      |
| Vu, H. et al. (2017)          | RBM                      | 70.3     | 35.4    | 86.4     | 16.5    |
| Chong, Y.S. et al. (2017)     | ST-AE                    | 89.9     | 12.5    | 87.4     | 12      |
| Hasan, M. et al. (2016)       | ConvAE                   | 81       | 27.9    | 90       | 21.7    |
| Luo, W. et al. (2017 - LSTM)  | ConvLSTM-AE              | 75.5     | N/A     | 88.1     | N/A     |
| Yan, S. et al. (2020)         | Two-Stream R-ConvVAE     | 75       | 32.4    | 91.7     | 15.5    |
| Xu, D. et al. (2015)          | AMDN                     | 92.1     | 16      | 90.8     | 17      |
| Lee, S. et al. (2018)         | STAN                     | 82.1     | N/A     | 96.5     | N/A     |
| Li, N. et al. (2020)          | ST-CaAE                  | 90.5     | 18.8    | 92.9     | 12.7    |
| Ravanbakhsh, M. et al. (2017) | Optical flow-GAN         | 97.4     | 8       | 93.5     | 14      |
| Wu, C. et al. (2020)          | SHAP preliminary work    | 84.1     | 23.8    | 92.4     | 14.9    |
| Wu, C. et al. (2021)          | SHAP with Context        | 85.9     | 22      | 92.4     | 13.5    |
| Wu, C. et al. (2021)          | SHAP without Context     | 73.1     | 34.8    | 80.1     | 29.3    |

## 2. Donanım ve Platform Düzeyinde Video Anomali Tespiti Karşılaştırması

Anomali olay tespitinin “Platform ve Donanım” düzeyinde performans karşılaştırması Çizelge 4’te gösterilmektedir (Amin, S.U. et al. (2022)).

Çizelge 4. Anomali Tespitinin Donanım ve Platform Düzeyinde Performans Karşılaştırması

| Referans                   | Method                  | Platform                      | Donanım                           | UCSD ped1 | UCSD ped2 | CUHK Avenue |
|----------------------------|-------------------------|-------------------------------|-----------------------------------|-----------|-----------|-------------|
| Kim and G. (2009)          | Space-Time MRF,MPPCA    | C++                           | 2.4GHz, 2GB RAM                   | 59.0      | 69.3      | -           |
| Mahadevan et al. (2010)    | MRF                     |                               | P. 3GHz 2GB RAM.                  | 81.1      | 82.9      | -           |
| Lu et al. (2013)           | K-means                 | MATLAB 2012                   | 8GB RAM, 3.4GHz                   | 91.8      | -         | -           |
| Ionescu et al. (2017)      | Deeper CNN              | GoogLeNet, ResNet             | i7 2.3 GHz 8 GB                   | 68.4      | 82.2      | 80.6        |
| Xu et al. (2017)           | AMDN                    | Matlab, C++ Cafe framework    | NVIDIA Quadro Ram                 | 92.1      | 90.8      | -           |
| Liu et al. (2018)          | U-Net, ConvLSTM-AE, CNN | Tensorflow                    | GeForce TITAN GPUs                | 83.1      | 95.4      | 84.9        |
| Wu et al. (2020)           | CNN                     | Tensorflow, Keras.            | Google Colaboratory Tesla V4 GPU. | 84.1      | 92.4      | -           |
| Ganokratanaa et al. (2020) | DSTN                    | Matlab Keras                  | GeForce GTX 1080 Ti, CUDA         | 98.5      | 95.5      | 87.9        |
| Wu et al. (2021)           | SHAP                    | Detectron2 Tensorflow, YOLOv3 | Nvidia Titan Xp GPU               | 85.9      | 92.4      | -           |
| Qiang et al. (2021)        | SPyNet, GAN             | TensorFlow                    | GeForce GTX 1080Ti                | 85.2      | 97.1      | 85.8        |
| Madan et al. (2021)        | SoTA                    |                               | Nvidia RTX 2080 Ti                | -         | -         | 86.9        |
| Tian et al. (2021)         | RTFM                    | PyTorch                       | Nvidia 2080Ti                     | -         | 96.5      | -           |
| Amin, S.U. et al. (2022)   | EADN, LW-CNN, LTSM      | Keras Tensor Flow, Python     | NVidia GeForce GTX                | 93.0      | 97.0      | 97.0        |

### 3. Video Anomali Tespitinin Metot Düzeyinde Performans Karşılaştırması

Anomali olay tespitinin “Metot “düzeyinde performans karşılaştırması Çizelge 5’te gösterilmektedir (Amin, S.U. et al. (2022)).

Çizelge 5. Anomali Tespitinin Metot Düzeyinde Performans Karşılaştırması(Amin, S.U. et al. (2022))

| Referans                   | Method                               | UCSD ped1 | UCSD ped2 | CUHK Avenue | UCF-Crime |
|----------------------------|--------------------------------------|-----------|-----------|-------------|-----------|
| Kim and Grauman (2009)     | Space-Time MRF MPPCA model           | 59.0      | 69.3      | -           | -         |
| Mehran et al. (2009)       | Social Force Model (SFM)             | 67.5      | 55.6      | -           | -         |
| Mahadevan et al. (2010)    | MRF                                  | 81.1      | 82.9      | -           | -         |
| Lu et al. (2013)           | K-means, hierarchical clustering     | 91.8      | -         | -           | 65.51     |
| Hasan et al. (2016)        | HOG+HOF                              | 81.0      | 90.0      | 70.2        | 50.6      |
| Ionescu et al. (2017)      | Deeper CNN                           | 68.4      | 82.2      | 80.6        | -         |
| Hinami et al. (2017)       | Fast R-CNN                           | -         | 92.2      | -           | -         |
| Luo et al. (2017)          | sRNN                                 | -         | 92.2      | 81.7        | -         |
| Chong & Tay (2017)         | Spatiotemporal AE                    | -         | -         | 80.3        | -         |
| Xu et al. (2017)           | AMDN                                 | 92.1      | 90.8      | -           | -         |
| Sultani, W. et al. (2018)  | Binary SVM classifier.               | -         | -         | -           | 50.0      |
| Sultani, W. et al. (2018)  | MIL-C3D without constraints          | -         | -         | -           | 74.44     |
| Sultani, W. et al. (2018)  | MIL-C3D with constraints             | -         | -         | -           | 75.41     |
| Liu et al. (2018)          | U-Net, ConvLSTM-AE, CNN              | 83.1      | 95.4      | 84.9        | -         |
| Zhong et al. (2019)        | GCN Anomaly Detection, C3D           | -         | 93.2      | -           | 81.1      |
| Zhong et al (2019)         | TSN-Optical Flow                     | -         | 92.8      | -           | 78.1      |
| Zhou et al. (2019)         | AnomalyNet                           | -         | -         | 86.1        | -         |
| Spatiotemporal (2019)      | Spatiotemporal                       | -         | -         | -           | 63.0      |
| Zhou et al. (2019)         | AnomalyNet                           | 83.3      | 94.9      | 86.1        | -         |
| Lee et al. (2019)          | BMAN                                 | -         | 96.6      | 90.0        | -         |
| Zaheer et al. (2020)       | MIL, C3D, CNN                        | -         | 94.47     | -           | 79.54     |
| Singh et al. (2020)        | Singh et al. (2020)                  | 94.6      | 95.9      | 92.7        | -         |
| Tang et al. (2020)         | Tang et al. (2020)                   | 82.6      | 96.2      | 83.7        | -         |
| Wu et al. (2020)           | CNN                                  | 84.1      | 92.4      | -           | -         |
| Ganokratanaa et al. (2020) | DSTN                                 | 98.5      | 95.5      | 87.9        | -         |
| Maqsood et al. (2021)      | CNN, 3D ConvNets                     | -         | -         | -           | 45.0      |
| Ullah et al. (2021)        | CNN, RNN, Multi-layer LSTM           | -         | -         | -           | 85.53     |
| Wu et al. (2021)           | SHapley Additive exPlanations (SHAP) | 85.9      | 92.4      | -           | -         |
| Qiang et al. (2021)        | SPyNet, GAN                          | 85.2      | 97.1      | 85.8        | -         |
| Madan et al. (2021)        | State-of-the-Art (SoTA)              | -         | -         | 86.9        | -         |
| Tian et al. (2021)         | Robust T. Feature Magnitude L. RTFM  | -         | 96.5      | -           | 84.3      |
| Amin, S.U. et al. (2022)   | EADN, LW-CNN, LTSM, SSBD             | 93.0      | 97.0      | 97.0        | 98.0      |

#### 4. Video Anomali Tespiti Çalışmalarının Enerji Tüketimi Düzeyinde Karşılaştırması


Khan ve arkadaşları, yaptıkları bir çalışmada anomali olay tespitinin “enerji tüketimi” düzeyinde performans karşılaştırması konusunu ele alarak sonuçları değerlendirilmişlerdir. Khan ve arkadaşlarının söz konusu çalışmasına dair veriler, Çizelge 6’da gösterilmektedir (Khan, M.U. et al. (2019)).

Çizelge 6. Anomali Tespitinin Enerji Tüketimi Düzeyinde Performans Karşılaştırması (Khan, M.U. et al. (2019))

| Classifier | P     | FF/<br>269200 | LUT/<br>215360 | Slice/<br>33650 | BRAM/<br>365 | DSP Slice/<br>740 | Max. freq.<br>(MHz) | Max. fps | Energy/<br>pixel (nJ) |
|------------|-------|---------------|----------------|-----------------|--------------|-------------------|---------------------|----------|-----------------------|
| K-means    | P = 5 | 7892          | 38575          | 13853           | 86           | 0                 | 165.8               | 408      | 1.61                  |
|            | P = 9 | 10428         | 39712          | 14239           | 48           | 0                 | 166.6               | 410      | 2.37                  |
| KUGDA      | P = 5 | 7892          | 38521          | 13519           | 87           | 0                 | 168.4               | 415      | 1.45                  |
|            | P = 9 | 10428         | 39725          | 14374           | 49           | 0                 | 163.5               | 403      | 2.52                  |
| SVM        | P = 5 | 7757          | 37796          | 13533           | 37           | 8                 | 162.3               | 400      | 1.59                  |
|            | P = 9 | 10293         | 39001          | 14186           | 27           | 8                 | 166.9               | 411      | 2.43                  |

#### 5. Video Anomali Tespiti Çalışmalarının Sonuç Değerlendirme Grafikleri

UCF-Crime veri setini referans olarak yapılan iki farklı çalışmanın sonuç doğruluk oranları, Şekil 11’deki AUC grafiğinde, standart formatında gösterilmektedir.

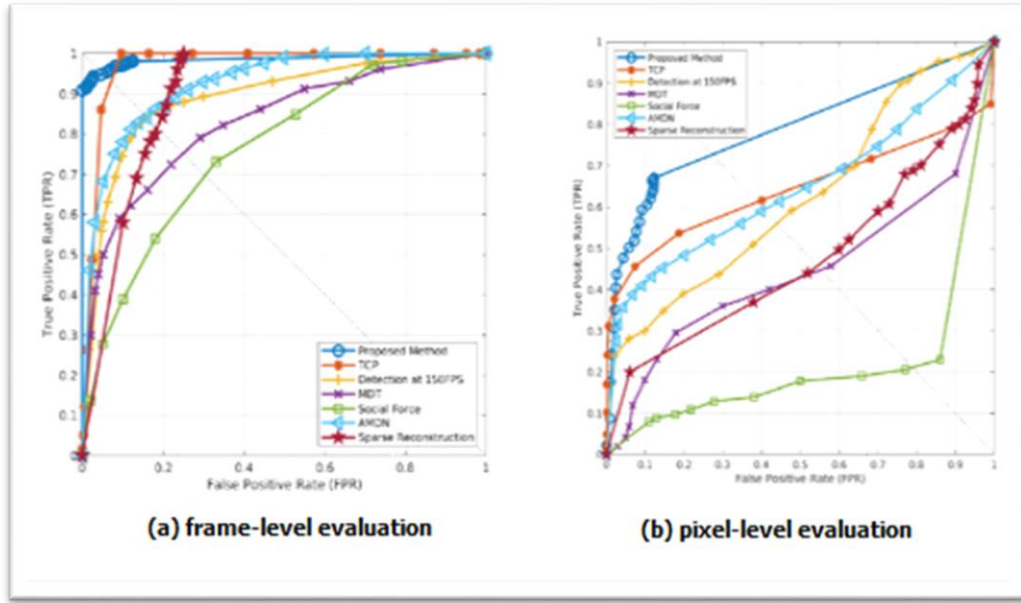


Şekil 11. UCF-Crime Veri Setindeki AUC Sonuçlarının Karşılaştırılması (Tian, Y. et al. (2021))

Çalışmalardaki anomali tespiti sonucu grafikleri değerlendirildiğinde, özellikle toplumsal olaylarda “kavga, hırsızlık, ateş etme” daha büyük bir başarı

oranı ile tespit edilebilirken, “patlama ve yol kazası” gibi olayların tespitinin başarı oranı daha düşük olduğu gözlemlenmiştir. Bu durumda kullanılan veri setlerindeki insan davranışı bazlı öğrenme verilerinin etkisinin de olduğu öngörülmektedir.

Şekil 12’de UCSD Ped1 veri setine ait ROC eğrisi grafiği, karşılaştırma sonuçları gösterilmektedir; (a) grafiğinde frame düzeyinde değerlendirme ve (b) grafiğinde ise piksel düzeyinde değerlendirme yer almaktadır.



Şekil 12. UCSD Ped1 Veri Setinde ROC Karşılaştırması; (a) frame-düzeyi, (b) piksel-düzeyi (Ganokratanaa, T. et al. (2020))

## E. Literatür Araştırması Genel Sonuç Değerlendirmesi

Literatür taramalarımızda, öncelikli tespitlerimizden birisi, görüntü analiz çalışmalarının konu bazında özel ilgi alanları içerisinde yapılmış olması ve genel olarak birçok alana referans teşkil edecek çalışmalar yapılmamış olmasıdır (Tokmakov, P. et al. (2017), Souza, M.R. et al. (2020), Altamimi, A.B. et al. (2020)). Bazı çalışmalarda, gerçek zamanlı görüntü işlemeye duyulan ihtiyaç vurgulanmıştır. Bununla birlikte birden fazla makine öğrenmesi tekniğinin kıyaslamalı olarak kullanıldığı çalışmaların sayısı oldukça azdır (Shao, L. et al. (2017)).

Çalışmalar incelendiğinde, kullanılan algoritma ve öğrenme yöntemleri dışında, Özellik Çıkarımı (Feature Extraction) tekniği ile tüm video karesi (frame) bazlı mı yoksa piksel bazlı mı analiz yapılıp yapılmadığı da anomali tespiti başarımını etkilediği gözlemlenmiştir (Tian, Y. et al. (2021)).

Yapılan çalışmalarda anomali olay tespiti için metot ve veri seti bazlı performans karşılaştırması hususlarının ele alındığı, kullanılan metotların veri setine göre başarı oranlarının farklı olduğu gözlemlenmiştir (Wu, C. et al. (2021); Amin, S.U. et al. (2022)).

Olay bazlı anomali tespiti alanında yapılan çalışmaların bazıları da incelenerek, sonuç grafikleri değerlendirilmiştir. Söz konusu çalışmaların özellikle toplumsal olaylarda “*kavga, hırsızlık, ateş etme*” vb gibi hususlar daha büyük bir başarı oranı ile tespit edilebilirken, “*patlama ve yol kazası*” gibi olayların tespit edilmesinde başarı oranlarının daha düşük olduğu gözlemlenmiştir (Tian, Y. et al. (2021)). Bu durumda kullanılan veri setlerindeki insan davranışı bazlı öğrenme verilerinin etkisinin de olup olmadığı araştırılması gereken hususlardan bir tanesidir.

### III. METODOLOJİ

Bu bölümde geliştirmiş olduğumuz “*Hibrit Makine Öğrenme Algoritmalarıyla Anomali Tespiti*” çalışmamızın mimarisi ve mimari bileşenleri ile uygulamanın metodolojisi ele alınmaktadır.

#### A. Modelleme ve Algoritma Seçimi

Kalabalık alanlarda anomali tespit edebilmek, çok zorlu bir işlemdir. Özellikle de yanlış tespitleri (false positive) en aza indirerek, başarıyı yüksek tespit yapmak zorlayıcı bir durumdur. İşte bu nedenle çalışmamızda, birden fazla algoritma ve teknik yöntemi birleştirilerek hibrit bir anomali tespit modelinin kullanılması önerilmiştir.

Önerdiğimiz modelin algoritma tercihinde, hem gözetimli (supervised), hem de gözetimsiz (unsupervised) öğrenme algoritmaları seçilerek, algoritmaların da hibrit bir şekilde kullanılması sağlanmıştır. Özellikle anomali tespit çalışmalarında, önceden tanımlanmamış sıra dışı durum ve olayların tespit edilmesinde gözetimsiz öğrenme algoritmalarının başarı oranı çok yüksektir. Bununla birlikte yanlış tespitleri (false positive) önlemek ya da en az düzeye indirmek için, gözetimli öğrenme algoritmalarının kullanılması önemli düzeyde avantaj sağlamaktadır. Gözetimli öğrenme algoritmalarında, referans çalışmalarda kullanılan “*Support Vector Machine (SVM)*, *k-Nearest Neighbor (kNN)*” algoritmaları tercih edilmiştir. Bunlarla birlikte insan davranışlarını algılamakta başarılı olan ve Spatio-Temporal (ST)’ı referans alan “*Motion Influence Map (MIM)*” algoritması da çalışmamızda etkin olarak kullanılmıştır (Lee D. G. et al. (2015)).

Video analizi ve anomali tespiti çalışmalarının en önemli aşamasını “*Özellik Çıkarımı (Feature Extraction)*” işlemi oluşturmaktadır. Bu işlem aynı zamanda tüm sürecin en uzun aşamasıdır. Özellik çıkarımı (feature extraction) işleminden sonra video kareleri (frame’ler), hem gözetimli hem de gözetimsiz algoritma proseslerine ayrı ayrı gönderilerek, eş zamanlı bir şekilde analiz işlemi gerçekleştirilmektedir.

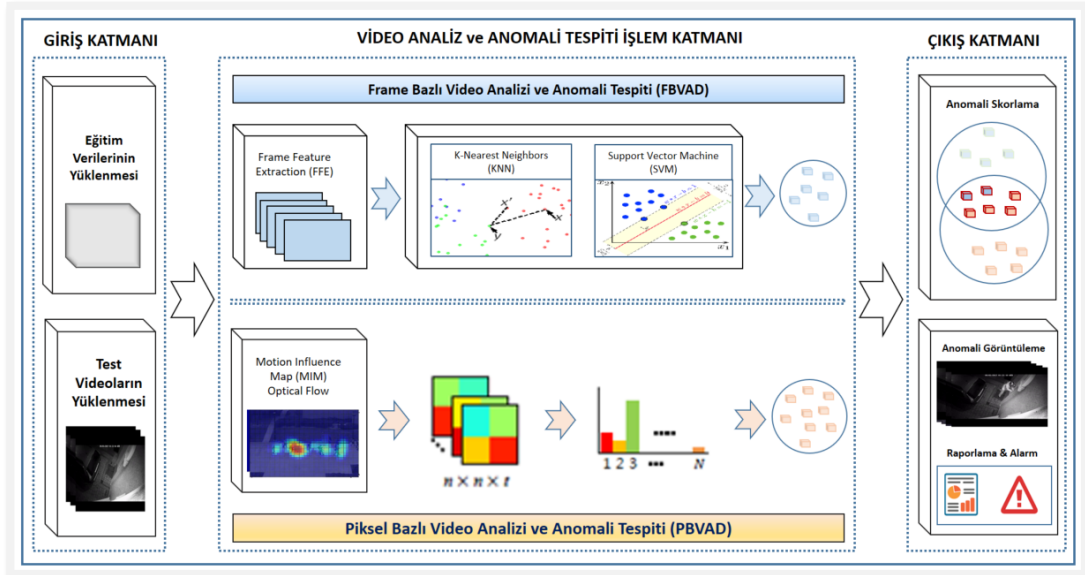


Analiz sonucunda da anomali tespiti işlemi yapılmaktadır. Tespit edilen anomaliler için kendi içerisinde bir skorlama (derecelendirme) ve etiketleme işlemi yapılmaktadır. Her iki proste de ortak anomali olarak tespit edilen video kareleri (frameler) için, yüksek dereceli anomali olarak etiketleme yapılmaktadır.

Kalabalık alanlarda anomali tespit edebilmek, çok zorlu bir işlemdir. Özellikle de yanlış tespitleri (false positive) en aza indirerek, başarıyı yüksek tespit yapmak zorlayıcı bir durumdur. İşte bu nedenle çalışmamızda, birden fazla algoritma ve teknik yöntemi birleştirilerek hibrit bir anomali tespit modeli önerilmiştir. Önermiş olduğumuz bu hibrit model ile, öncelikli olarak üzerinde çalışılan başlıca anomali davranışlar şunlardır: “Saldırı, Şiddet, Hırsızlık, Patlama, Kavga, Trafik Kazası” (Abuse, Assault, Burglary, Explosion, Fighting, Road Accidents). Modelimizin mimari diyagramı Şekil 13’te gösterilmektedir. Önerilen modelin yapısı ve bileşenleri ilerleyen başlıklarda, sırasıyla detaylı olarak anlatılmaktadır.

## B. Model Mimari Diyagramı

Çalışmamızda önerilen modelin mimarisi, temel olarak üç katmandan oluşmaktadır. Önerilen modelin mimari diyagramı Şekil 13’te gösterilmektedir.



Şekil 13. Hibrit Makine Öğrenme Algoritmalarıyla Anomali Tespiti Mimari Diyagramı

Söz konusu mimari diyagramın katmanlarını şu şekilde listeleyebiliriz;

- a) *Giriş Katmanı (Input Layer)*
- b) *Video Analizi ve Anomali Tespit Katmanı (Process Layer)*
- c) *Çıktı Katmanı (Output Layer)*

Mimari diyagramın katmanlarını ve bileşenlerini kısaca şu şekilde özetleyebiliriz;

### **1. Giriş Katmanı**

Analiz sürecine giriş yapılacak bileşenlerin bulunduğu katmandır. “*Eğitilmiş (trained) Model Verileri*” ile “*Test Video Verileri*” bileşenlerinden oluşur.

### **2. Video Analizi ve Anomali Tespit Katmanı**

Analiz sürecinin ana bileşenlerin bulunduğu ve anomali tespiti işleminin yapıldığı katmandır. İki ana bileşenden oluşur;

- i) *Frame bazlı kNN ve SVM algoritmaları ile anomali tespiti*
- ii) *Piksel bazlı MIM algoritma ile anomali tespiti*

### **3. Çıktı Katmanı**

Analiz süreci sonucunda tespit edilen anomali veri ve görüntülerin gösterildiği katmandır. Kullanıcı ile etkileşimli olan bir katmandır. “*Anomali Görselleştirme ve İzletme*” ile “*Anomali Raporlama ve Alarm*” bileşenlerinden oluşur.

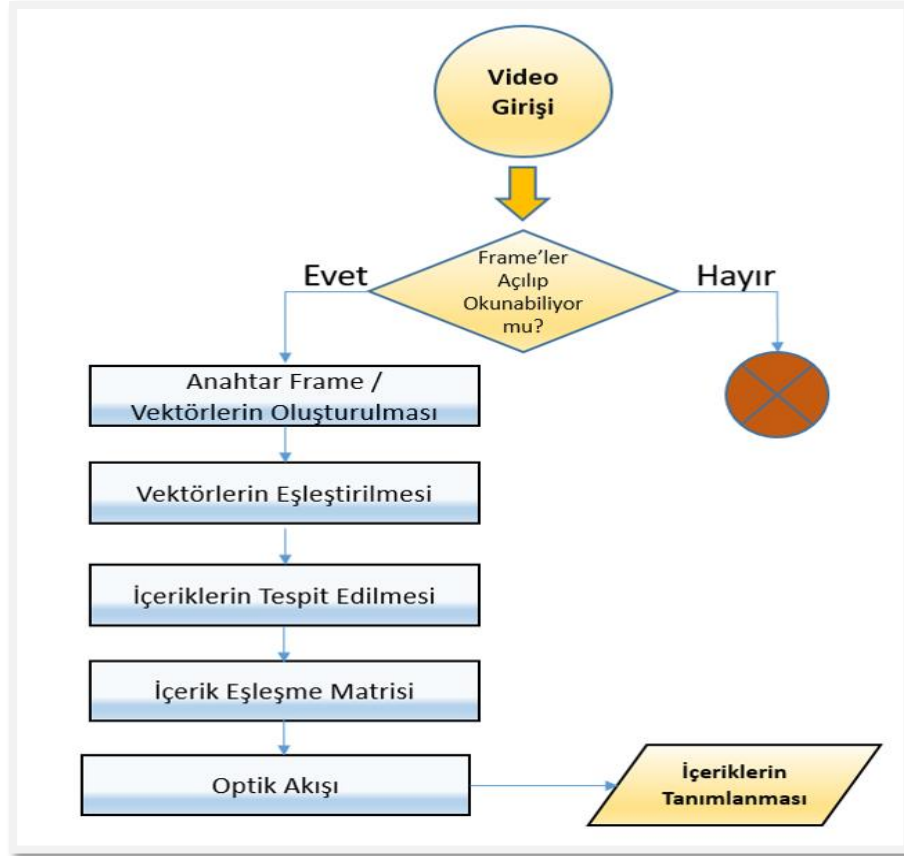
### **C. Özellik Çıkarımı**

Özellik Çıkarım işlemi, Video Analizi ve anomali tespiti çalışmalarının en önemli hususlarından birisidir. Başarı sonucunu doğrudan etkilemektedir. Özellik çıkarımı işlemi şu adımlardan oluşmaktadır;

- *Framelerin Alınması (Get Frames)*
- *Anahtar Frame/Vektörlerin Oluşturulması (Create Key Frames / Vectors)*
- *Vektörlerin Eşleştirilmesi (Vector Matching)*
- *İçeriklerin Tespit Edilmesi (Feature Detector)*
- *İçerik Eşleşme Matrisi (Matched Feature Matrix)*

- *Optik Akışı (Optical Flow)*
- *İçeriklerin Açıklanması (Feature Description)*

Özellik çıkarımı işleminin adımları Şekil 14'te gösterilmektedir. Her bir adım maddeler halinde ayrıca açıklanmaktadır.



Şekil 14. Video Görüntüsü Özellik Çıkarımı Adımları

### 1. Framelerin Alınması

Özellik çıkarımı işleminde, test video verisi yüklenince öncelikle, verinin geçerlilik kontrolü yapılır ve video görüntü karelerinin (framelerin) açılıp açılmadığı belirlenir. Eğer video görüntü kareleri (frameler) açılmıyorsa, uyarı mesajı verilerek işlem sonlandırılır. Eğer video görüntü kareleri (frameler) açılabilirse, video verisine ait ilk görüntü karesinden (frameden) son görüntü karesine (frame) kadar bir döngü içerisinde, her bir görüntü karesi (frame) için tek tek içerik çıkarma işlem adımları başlatılır ve ilerletir. Süreç adımları içerisinde, yeni frame ve bir önceki frame karşılaştırmalı olarak işlemler yapılır.

## 2. Anahtar Frame/Vektörlerin Oluşturulması

Özellik çıkarımı işleminin bu aşamasında, frame görüntüsündeki anahtar vektörler tespit edilir ve anahtar vektör konumu görüntüdeki tanımlayıcılar hesaplanır.

## 3. Vektörlerin Eşleştirilmesi

Özellik çıkarımı işleminin bu aşamasında, frame görüntüsündeki vektörler ile anahtar vektörler arasında eşleştirmeler yapılır.

## 4. İçeriklerin Tespit Edilmesi

Özellik çıkarımı işleminin bu aşamasında, frame içerisindeki özellikler tespit edilir.

## 5. İçerik Eşleşme Matrisi

Özellik çıkarımı işleminin bu aşamasında, tespit edilen özellik ve vektörlerin, anahtar frame / vektörlere göre eşleştirmeler yapılarak, konumları tespit edilir. Bu işlemde aynı zamanda kNN algoritması da kullanılır ve “k” değeri 2 olarak set edilir. Ayrıca benzersizlik eşiği (uniquenessthreshold) değeri “0.80” olarak verilir.

## 6. Optik Akışı

Özellik çıkarımı işleminin bu aşamasında, yinelemeli Lucas-Kanade yöntemini kullanarak seyrek bir özellik kümesi için optik akışı hesaplanır. İşlemler içerisinde “minEigThreshold” değeri “0.0001” olarak referans alınmaktadır.

## 7. İçeriklerin Açıklanması

Özellik çıkarımı işleminin bu aşamasında, tüm özellik çıkarım işlem sonuçları, dizi setleri içerisinde, sürecin başlatıldığı ana işlem noktasına işlenmiş veri olarak döndürülür.

## D. Frame Bazlı Anomali Tespiti Metodu

Video görüntülerinde, frame bazlı anomali tespiti için, “*k-Nearest Neighbor (kNN)*”, *Support Vector Machine (SVM)*” makine öğrenmesi algoritmaları kullanılmıştır. Bu algoritmalar, aşağıda başlıklar halinde kısaca açıklanmıştır.

## 1. *k*-En Yakın Komşuluk (kNN) Algoritması İle Anomali Tespiti

*k*-En Yakın Komşuluk (*k*-Nearest Neighbor - kNN) modeli ile veriler sınıflandırılır, eğitilir ve kaydedilir. Eğitim sürecinde, eğitim ve test verileri ile etiketlerini parametre olarak alır. Eğitimde “*k*” değeri “5” olarak set edilmiştir. Frame bazlı özellik çıkarımı (Feature Extraction) değerleriyle anomali tespiti, sınıflandırma ve skorelama yapılır.

*k*-En Yakın Komşuluk (*k*-Nearest Neighbor - kNN) algoritması tanımı aşağıda ifade edilmektedir.

---

*k*-En Yakın Komşuluk (k-Nearest Neighbor - kNN) Algoritması;

---

$$k^* = \left\lfloor Bn \frac{4}{d + 4} \right\rfloor$$
$$w_{ni}^* = \frac{1}{k^*} \left[ 1 + \frac{1}{2} - \frac{d}{2k^{*2/d}} \{i^{1+2/d} - (i - 1)^{1+2/d}\} \right]$$

*for i = 1, 2, ... k^\* and*  
 $w_{ni}^* = 0$   
*for i = k^\* + 1, ..., n*

---

kNN algoritmasının adımlarını kısaca şu şekilde özetleyebiliriz;

1. Öncelikle “*k*” değeri belirlenir.
2. Noktaların hedef noktaya olan öklit mesafeleri (uzaklıkları) hesaplanır.
3. Uzaklıklar sıralanır ve en minimum uzaklığa bağlı olarak en yakın komşular bulunur.
4. Sınıflandırma yöntemiyle en yakın komşu kategorileri oluşturulur.
5. Her bir nokta için en yakın komşu kategori seçim işlemi gerçekleştirilir.

## 2. Destek Vektör Makinaları (SVM) Algoritması İle Anomali Tespiti

Destek vektör makinesi (*Support Vector Machine - SVM*) sınıflandırıcısını kullanarak veriler sınıflandırılır ve modeli kaydedilir. Eğitim sürecinde, eğitim ve test verileri ile etiketlerini parametre olarak alır. Frame bazlı özellik çıkarımı (Feature Extraction) değerleriyle anomali tespiti, sınıflandırma ve skorelama yapılır.

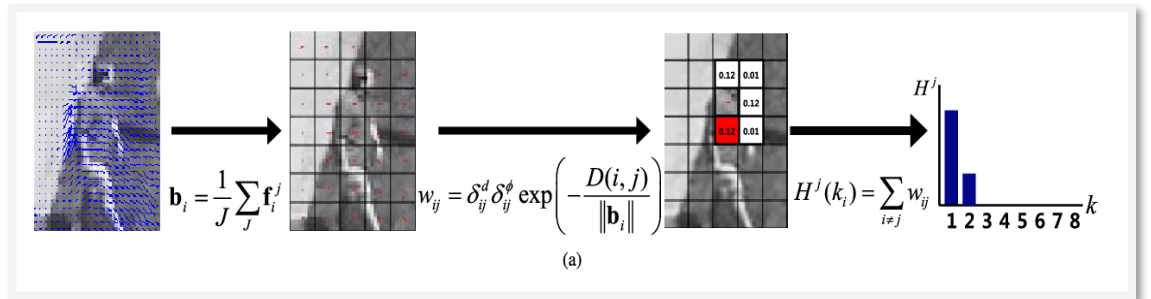
## E. Pksel Bazlı Anomali Tespiti Metodu

Video görüntülerinde, piksel bazlı anomali tespiti için, “*Hareket Etki Haritası (Motion Influence Map - MIM)*” algoritması kullanılmaktadır. Hareket Etki Haritası (MIM) algoritması, çok bilinen bir algoritma olmadığı için, bu bölümde biraz detaylı olarak anlatılmaktadır.

### 1. Hareket Etki Haritası (MIM) Algoritması Adımları

Hareket Etki Haritası (*Motion Influence Map - MIM*) algoritması, temel olarak dört adımdan oluşmaktadır. Bu adımlar aşağıda listelenmektedir. Ayrıca Şekil 15’te diyagram ve formül olarak gösterilmektedir (Lee D. G. et al. (2015));

- 1) *Optik akış.*
- 2) *Bloklar arasındaki hareketin etkisinin hesaplanması.*
- 3) *Her iki blok arasındaki etki ağırlıklarının hesaplanması.*
- 4) *Her blok için hareket ışın (yön) ağırlıklarının hesaplanması.*



Şekil 15. Hareket Etki Haritası (Motion Influence Map) Algoritması Adımları (Lee D. G. et al. (2015))

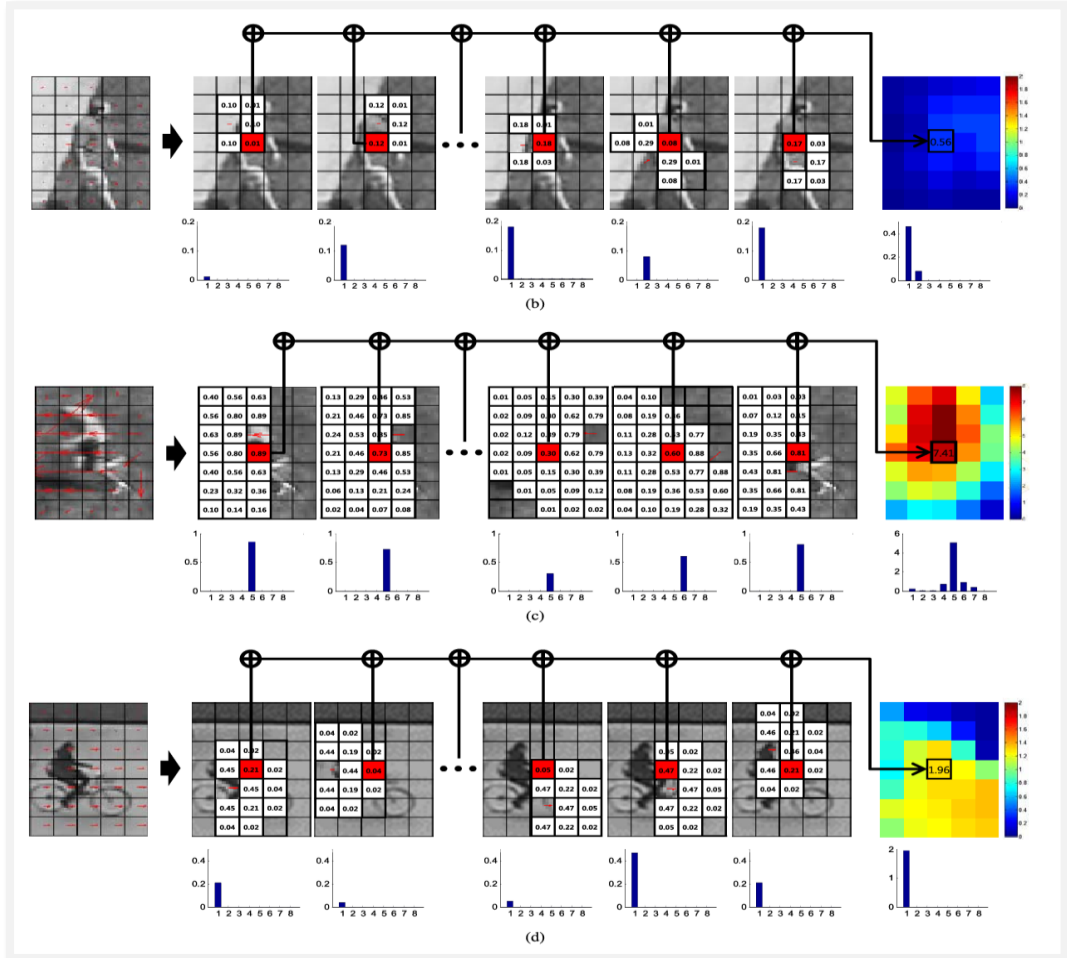
### 2. Hareket Etki Haritasının Çıkarılması

Video görüntü kareleri (frame) içerisindeki hareket bilgileri, dolaylı olarak optik akışlardan tahmin edilebilmektedir. Özel olarak, bir frame içerisindeki her piksel için optik akışları hesapladıktan sonra, frame’in bütünlüğünü kaybetmeden  $n$  blok değeri  $m$  blok değerine bölünür; bu blokların  $\{b_1, b_2, \dots, b_{mn}\}$  ve daha sonra blok içerisindeki piksellerin optik akışlarının ortalaması alınarak, her blok için temsili bir optik akış değeri hesaplanır.

Kalabalık içindeki yaya hareketinin yönü, yoldaki engeller, komşu yayalar ve hareket eden araçlar gibi çeşitli faktörlerden etkilenebilir. Bu karakteristik

reaksiyona “hareket etkisi” denir. Nesneler, “hareket yönü ve hareket hızı” olmak üzere iki faktör tarafından belirlenecek olan başka bir hareketli nesnelerin etkisi altında olduğu düşünülmektedir. Yani nesne ne kadar hızlı hareket ederse, hareketinden etkilenen bitişik blokların sayısı da o kadar fazla olmaktadır. Yakındaki bloklar, uzak bloklardan daha fazla etkilenmektedir. Tüm bloklar için efekt ağırlıklarını hesapladıktan sonra, frame içindeki hareket efekti kalıplarını ifade eden “hareket etkisi haritası” oluşturabilir. Sadece iki blok arasında belirlenen hareket ağırlıklarını hesapladıktan sonra, tüm hareket bloklarının hesaba katılacağı frame içerisinde de her bir blok için hareket merkezi ağırlıkları hesaplanmaktadır.

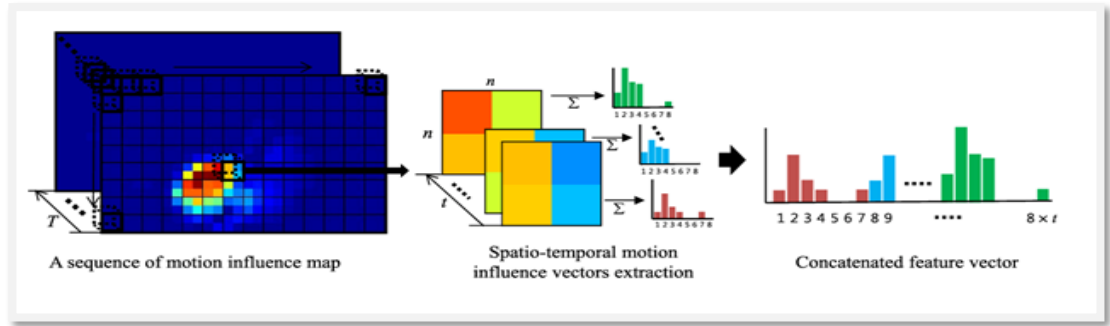
Hareket Etki Haritası (MIM) algoritmasının örnek uygulaması ve hesaplamaları Şekil 16’da farklı görüntü kareleri ile gösterilmektedir (Lee D. G. et al. (2015)). Buna göre (b) görüntüsünde normal durum, (c) görüntüsünde koşan adam yüksek skorlu anomali durum, (d) görüntüsünde ise bisikletli insan düşük skorlu anomali durum olarak hesaplanmıştır.



Şekil 16. Hareket Etki Haritası Algoritmasının Örnek Uygulaması  
(Lee D. G. et al. (2015))

### 3. Piksel Bazlı Özellik Çıkarma

Piksel bazlı özellik çıkarma sürecinde, öncelikle video görüntüsü girilerek, hareket bilgileriyle optik akış hesaplanır ve hareket etkisi haritası oluşturulur. Sonra, karakteristik bir hareket ışımına sahip olan, şüpheli bir olayı içeren küme bulunur. Olay birkaç ardışık frame aracılığıyla izlenir, sonra da bitişik blokların her biri için öznitelik kümesi belirli sayıda frame ile birlikte mega blok aracılığıyla çıkarılır. Böylece her görüntü karesinin (frame) her biri, hareket efektini içeren bir grup mega bloğa bölünebilir. Son olarak, her görüntü karesindeki hareket efektinin ışınları ayrı ayrı toplanarak, görüntü içindeki bloklar için, her bir mega bloğun zamansal ve uzamsal özellikleri çıkarılır. Hareket etki haritası için piksel bazlı özellik çıkarma diyagramı, Şekil 17'de gösterilmektedir (Lee D. G. et al. (2015)).

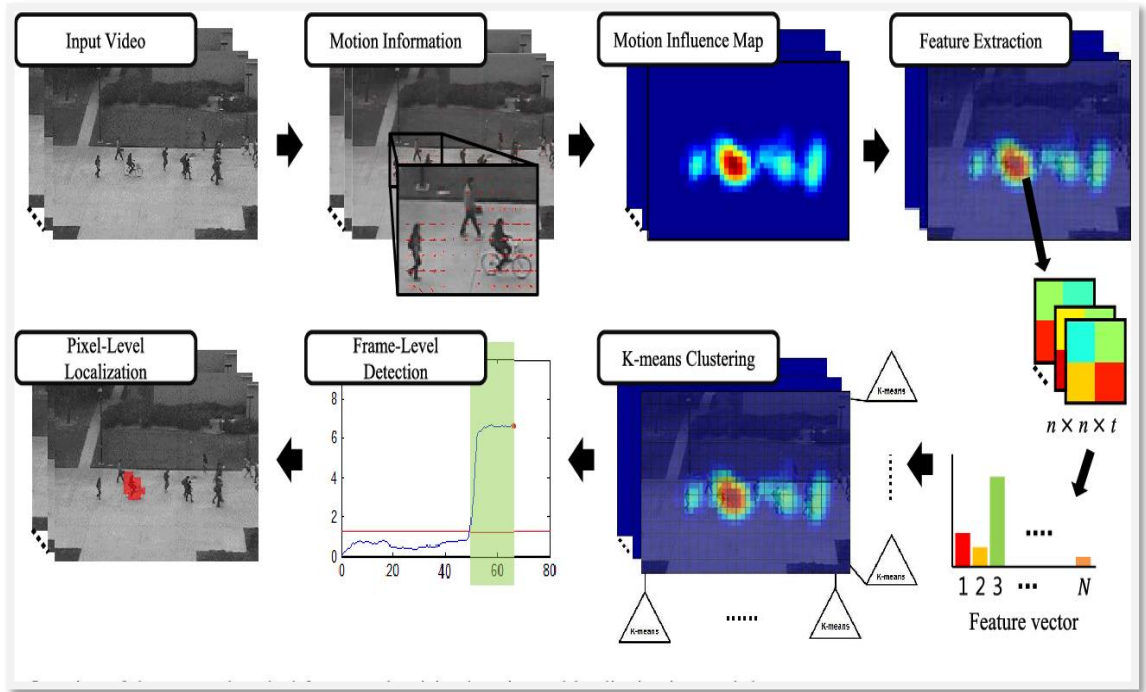


Şekil 17. Hareket Etki Haritası Piksel Bazlı Özellik Çıkarma Diyagramı  
(Lee D. G. et al. (2015))

### 4. Hareket Etki Haritası (MIM) Algoritması ile Video Anomali Tespiti ve Diyagramı

Hareket Etki Haritası (MIM) algoritması ile video anomali tespitinin genel mimari çerçevesi Şekil 18'de gösterilmektedir.





Şekil 18. Hareket Etki Haritası (Motion Influence Map - MIM) İle Anomali Tespiti Diyagramı (Lee D. G. et al. (2015))

Şekil 18’de de görüldüğü üzere, öncelikle video görüntüsü girilerek, hareket bilgisi sırasıyla piksel ve küme düzeyinde hesaplanır. Sonra hareket etkisinin haritasını oluşturmak için her bloğun kinetik enerjisi hesaplanır. Hareket etki haritası oluşturulduktan sonra piksel bazlı özellik çıkarımı işlemi yapılır. Daha sonra ise her bir mega blok için, uzamsal ve zamansal özellikler kullanılarak, “*k-ortalama (k-means) algoritması*” ile sınıflandırma yapılır ve normal olayların merkezi belirlenir. Bu aşamada, eğitim esnasında sadece normal durumların video görüntülerinin kullanıldığı durumu özellikle dikkate alınmalıdır. Bu nedenle, bir mega bloğun eğitim esnasında üretilen model kod sözcükleri (codewords) ile, ilgili alanda meydana gelebilecek olağan durumların kalıpları modellenir. Sonrasında mevcut görüntü karesi ile diğer görüntü karelerinin merkezleri arasında “*öklid mesafe yasası*” uygulanır, böylece şüpheli (anomali) olay tespit edilir. Şüpheli olay, belirli bir eşiği (limiti) aşarsa, “*şüpheli olay yeri*” olarak kabul edilir (Lee D. G. et al. (2015)).

## 5. Hareket Etki Haritası (MIM) Algoritması Tanımı

Hareket Etki Haritası (*Motion Influence Map - MIM*) algoritması, tanımı aşağıda ifade edilmektedir.

---

**Hareket Etki Haritası (Motion Influence Map - MIM) Algoritması;**

---

**INPUT:**  $MV \leftarrow$  motion vector set,  $BS \leftarrow$  block size  $x \ y$ ,  $CB \leftarrow$  a centri of blo

**OUTPUT:**  $MIP \leftarrow$  motion influence map

**for**  $i \in BS(x)$  **do**

**for**  $j \in BS(y)$  **do**

$$b_i = \frac{1}{j} \sum_j OF_i^j$$

$$T_d = \| b_i \| \times BS$$

$$OF_k = \| MV_{ij1} \|$$

$$+TAF_i = \angle OF_k + \frac{\pi}{2}$$

$$-TAF_i = \angle OF_k - \frac{\pi}{2}$$

**for**  $p \in BS(x)$  **do**

**for**  $q \in BS(y)$  **do**

Calculate the Euclidean Distance  $ED(i, j, p, q)$  between  $CB(i, j, p, q)$

**if**  $E(i, j, p, q) < T_d$  **then**

Calculate the Angle  $A_{ij}$  between  $b_i$  and  $b_j$

**if**  $+TAF_i < A_{ij} < -TAF_i$  **then**

$$MIP^{pq} (\angle b_i) = MIP^{pq} (\angle b_i + \exp\left(\frac{ED(i, j, p, q)}{\| MV_{ij0} \|}\right))$$

**end if**

**end if**

**end for** // (q)

**end for** // (p)

**end for** // (j)

**end for** // (i)

---

## IV. UYGULAMA VE TEST SONUÇLARININ DEĞERLENDİRİLMESİ

Bu bölümde uygulama ve test çalışma sonuçları detaylı olarak ele alınacaktır. Bununla beraber kullanılan veri setleri, uygulama implementasyonu, değerlendirme ölçütleri, test sonuçları ve anomali tespiti değerlendirmeleri yer alacaktır.

### A. Uygulama ve Test Ortamı Genel Bilgilendirme

Test uygulaması Windows Visual Studio üzerinde, C# programlama dili kullanılarak geliştirilmiştir. Video analizi ve görüntü işleme çalışmaları için OpenCV kütüphanesinin C# uyumlu versiyonu kullanılmıştır. Alternatif olarak bazı işlemlerin geliştirilmesi ve testlerin yapılması için Python programlama dili de kullanılmıştır. Test ortamında kullanılan bilgisayarın özellikleri şu şekilde özetlenebilir;

- *İşletim Sistemi Windows 10 64 Bit*
- *İşlemci / CPU 4 dual core, 8 Çekirdek,*
- *RAM 32 GB*

### B. Veri Seti Seçimi

Çalışmamızda incelenen ve kullanılan veri setleri şunlardır;

- *UCSD Ped1 (Dan et al(2014) ),*
- *UCSD Ped2 (Dan et al(2014) ),*
- *UCF Crime Anomaly Data (Sultani, W. et al. (2018))*

UCSD ped1 (Ganokratanaa et al. (2020)), UCSD ped2 (Qiang et al. (2021)) gibi, yaygın olan veri setleri ile ilgili son zamanlarda yapılan çalışmaların birçoğunun başarı oranının %97 ve üzerinde olduğu gözlemlenmiştir. Bununla

birlikte UCF-Crime (Sultani, W. et al. (2018)) veri seti üzerinde yapılan çalışmaların başarımlar oranları (Tian, Y. et al. (2021)), diğer veri setleri üzerinde yapılan çalışmalara kıyasla daha düşük olduğu için, çalışmamız özellikle UCF-Crime veri seti üzerine yoğunlaştırılmıştır.

UCF-Crime veriseti, yol, sokak ve iç mekan güvenlik kameralarından olmak üzere, toplam 128 saat süreli, 1900 adet gerçek hayata ait, kesinti yapılmamış video verilerini içeren büyük ölçekli bir anomali tespit veri setidir (Sultani, W. et al. (2018)). ShanghaiTech'teki statik arka planların aksine, UCF-Crime karmaşık ve çeşitli arka planlardan oluşur. Hem eğitim hem de test veri setleri aynı sayıda normal ve anormal video içerir. Veri seti, video düzeyinde etiketlere sahip 1.610 eğitim videosunda ve frame düzeyinde etiketlere sahip 290 test videosunda 13 anormallik sınıfını kapsamaktadır.

Test çalışmamızda kullandığımız UCF-Crime verisetine ait referans veriler, Çizelge 7’de kategori bazında gösterilmektedir.

Çizelge 7. Çalışmamızda Kullanılan UCF-Crime Veriseti Bilgileri Tablosu

| Data Set       | Dosya                      | Frame | Süre         |
|----------------|----------------------------|-------|--------------|
| Abuse          | Abuse002_x264.mp4          | 865   | 00:28 saniye |
| Assault        | Assault002_x264.mp4        | 2,523 | 01:24 saniye |
| Burglary       | Burglary012_x264.mp4       | 1,698 | 00:56 saniye |
| Explosion      | Explosion045_x264.mp4      | 757   | 00:25 saniye |
| Fighting       | Fighting006_x264.mp4       | 944   | 00:31 saniye |
| Road Accidents | Road Accidents002_x264.mp4 | 347   | 00:11 saniye |

### C. Uygulama İmplementasyonu

Uygulama implementasyonu sürecinde, öncelikle kullanılacak algoritmalar belirlenmiştir. Algoritmalar için geliştirme ortamında gerekli kurulum ve konfigürasyonlar yapılmıştır. Veri setleri temin edilerek test ortamında kullanılabilir hale getirilmiştir. Sonrasında test çalışmaları yapılmıştır.

## D. Test Sonuçlarının Değerlendirilmesi

Çalışmamız sürecinde daha önce de belirttiğimiz gibi özellikle UCF-Crime veriseti referans alınmıştır. Söz konusu verisetine ait olan “*Abuse, Assault, Burglary, Explosion, Fighting, Road Accidents*” kategorilerindeki alt veri setleri üzerinde anomali tespiti çalışmaları yapılmıştır. Deneysel çalışmalarımızda, görüntü netliğinin algoritmaların anomali tespiti başarımlarını doğrudan etkileyen temel hususlar olduğu gözlemlenmiştir. Görüntüsü çok net olmayan ve görüntü kalitesi düşük olan kamera verilerinde anomali tespitinin başarımları oldukça düşüktür. Diğer taraftan kameranın mesafesinin olay yerine yakınlık ve uzaklık durumunun, anomali tespiti algoritmalarının başarımlarını doğrudan etkileyen hususlar olduğu tespit edilmiştir.

### 1. *k*-En Yakın Komşuluk (kNN) Algoritması Test Sonuçları

Frame bazlı video anomali tespiti için kullandığımız *k*-En Yakın Komşuluk (FBVAD- kNN) algoritması ile, UCF-Crime veri setine ait “*Abuse, Assault, Burglary, Explosion, Fighting, Road Accident*” isimli kategorilerindeki alt veri setleri üzerinde yaptığımız video anomali tespiti test çalışmasının, AUC başarımları ve performans sonuçları Çizelge 8’de, karmaşıklık matrisi (confusion matrix - CFM) referans verileri ise Çizelge 9’da yer almaktadır.

FBVAD-kNN algoritması ile video anomali tespiti AUC skor ve performans sonuçları, Çizelge 8’de veri seti kategorisi bazlı, “*AUC, Precision, Sensitivity ve F-Score*” değerleriyle birlikte gösterilmektedir.

Çizelge 8. FBVAD-kNN Algoritması AUC Skor ve Performans Tablosu

| Data Set       | AUC   | Precision | Sensitivity | F-Score |
|----------------|-------|-----------|-------------|---------|
| Abuse          | 98.80 | 0.998     | 0.9762      | 0.974   |
| Assault        | 97.90 | 0.996     | 0.9569      | 0.955   |
| Burglary       | 96.60 | 0.993     | 0.9325      | 0.928   |
| Explosion      | 99.30 | 0.999     | 0.9875      | 0.984   |
| Fighting       | 96.80 | 0.994     | 0.9372      | 0.925   |
| Road Accidents | 98.30 | 0.998     | 0.9565      | 0.955   |

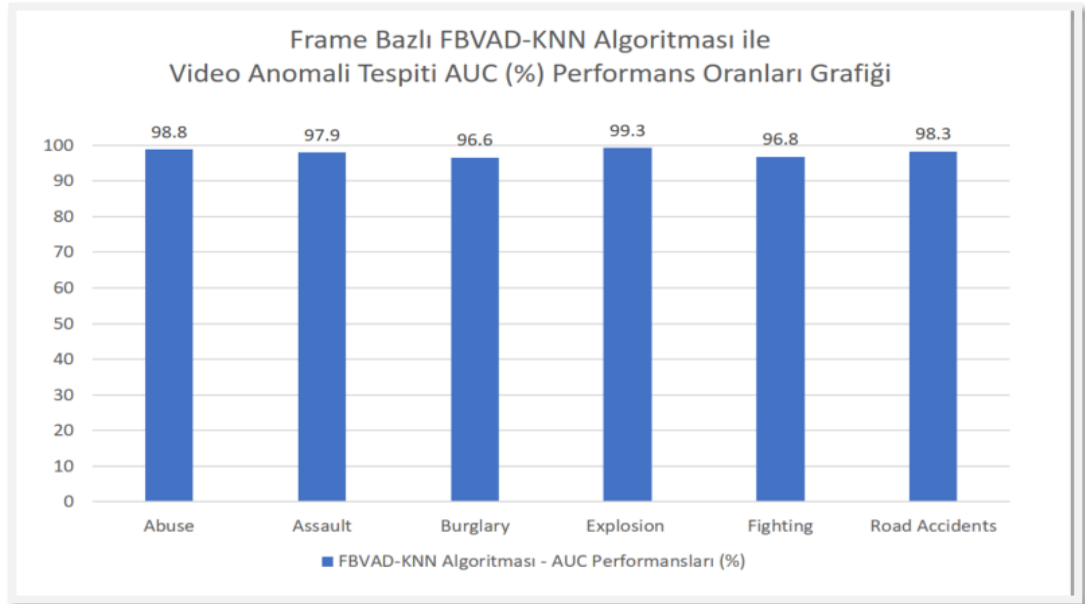
FBVAD-kNN algoritması ile UCF-Crime veri setine ait video anomali tespiti karmaşıklık matrisi (confusion matrix - CFM) referans verileri, Çizelge 9’da veri

seti kategorisi bazlı, "AUC, Precision, Sensitivity ve F-Score" değerleriyle birlikte gösterilmektedir.

Çizelge 9. FBVAD-kNN Algoritması Karmaşıklık Matrisi (CFM) Referans Tablosu

| Data Set       | Samples | Actual Positives | Actual Negatives | True Positives | True Negatives | False Negatives |
|----------------|---------|------------------|------------------|----------------|----------------|-----------------|
| Abuse          | 865     | 194              | 671              | 184            | 671            | 10              |
| Assault        | 2523    | 627              | 1896             | 573            | 1896           | 54              |
| Burglary       | 1698    | 422              | 1276             | 365            | 1276           | 57              |
| Explosion      | 757     | 161              | 596              | 156            | 596            | 5               |
| Fighting       | 944     | 215              | 729              | 185            | 729            | 30              |
| Road Accidents | 347     | 69               | 278              | 63             | 278            | 6               |


k-En Yakın Komşuluk (k-Nearest Neighbor -kNN) algoritması ile UCF-Crime veri setine ait "Abuse, Assault, Burglary, Explosion, Fighting, Road Accident" isimli kategorilerindeki alt veri setleri üzerinde yaptığımız test çalışmalarımızın başarımlar oranları, Şekil 19'da kategori bazında gösterilmektedir.



Şekil 19. UCF-Crime Veriseti k-En Yakın Komşuluk (k-Nearest Neighbor -kNN) Algoritması Video Anomali Tespiti Başarımlar Oranları

k-En Yakın Komşuluk (k-Nearest Neighbor -kNN) algoritması ile UCF-Crime veri setine ait "Abuse, Assault, Burglary, Explosion, Fighting, Road

"Accident" isimli kategorilerindeki alt veri setleri üzerinde yaptığımız test çalışmalarının AUC – ROC grafikleri, Şekil 20’de gösterilmektedir.



Şekil 20. PBVAD-KNN Algoritması ile UCF-Crime Veri Seti için Video Anomali Tespiti AUC & ROC Grafiği

## 2. Destek Vektör Makinaları ( SVM) Algoritması Test Sonuçları

Frame bazlı video anomali tespiti için kullandığımız destek vektör makineleri (FBVAD- SVM) algoritması ile, UCF-Crime veri setine ait "Abuse, Assault, Burglary, Explosion, Fighting, Road Accident" isimli kategorilerindeki alt veri setleri üzerinde yaptığımız video anomali tespiti test çalışmasının, AUC başarı oranı ve performans sonuçları Çizelge 10’da, karmaşıklık matrisi (confusion matrix - CFM) referans verileri ise Çizelge 11’de yer almaktadır.

FBVAD-SVM algoritması ile video anomali tespiti AUC skor ve performans sonuçları, Çizelge 10’da veri seti kategorisi bazlı, "AUC, Precision, Sensitivity ve F-Score" değerleriyle birlikte gösterilmektedir.

Çizelge 10. FBVAD-SVM Algoritması AUC Skor ve Performans Tablosu


| Data Set       | AUC   | Precision | Sensitivity | F Score |
|----------------|-------|-----------|-------------|---------|
| Abuse          | 77.60 | 0.998     | 0.7757      | 0.874   |
| Assault        | 75.13 | 0.992     | 0.7515      | 0.857   |
| Burglary       | 75.11 | 0.992     | 0.7520      | 0.858   |
| Explosion      | 78.70 | 0.995     | 0.7873      | 0.881   |
| Fighting       | 77.20 | 0.994     | 0.7722      | 0.871   |
| Road Accidents | 80.10 | 0.996     | 0.8012      | 0.890   |

FBVAD-SVM algoritması ile UCF-Crime veri setine ait video anomali tespiti karmaşıklık matrisi (confusion matrix - CFM) referans verileri, Çizelge 11’de veri seti kategorisi bazlı olarak gösterilmektedir.

Çizelge 11. FBVAD-SVM Algoritması Karmaşıklık Matrisi (CFM) Referans Tablosu

| Data Set       | Samples | Actual Positives | Actual Negatives | True Positives | False Negatives |
|----------------|---------|------------------|------------------|----------------|-----------------|
| Abuse          | 865     | 865              | 0                | 671            | 194             |
| Assault        | 2523    | 2523             | 0                | 1896           | 627             |
| Burglary       | 1698    | 1698             | 0                | 1276           | 422             |
| Explosion      | 757     | 757              | 0                | 596            | 161             |
| Fighting       | 944     | 944              | 0                | 729            | 215             |
| Road Accidents | 347     | 347              | 0                | 278            | 69              |

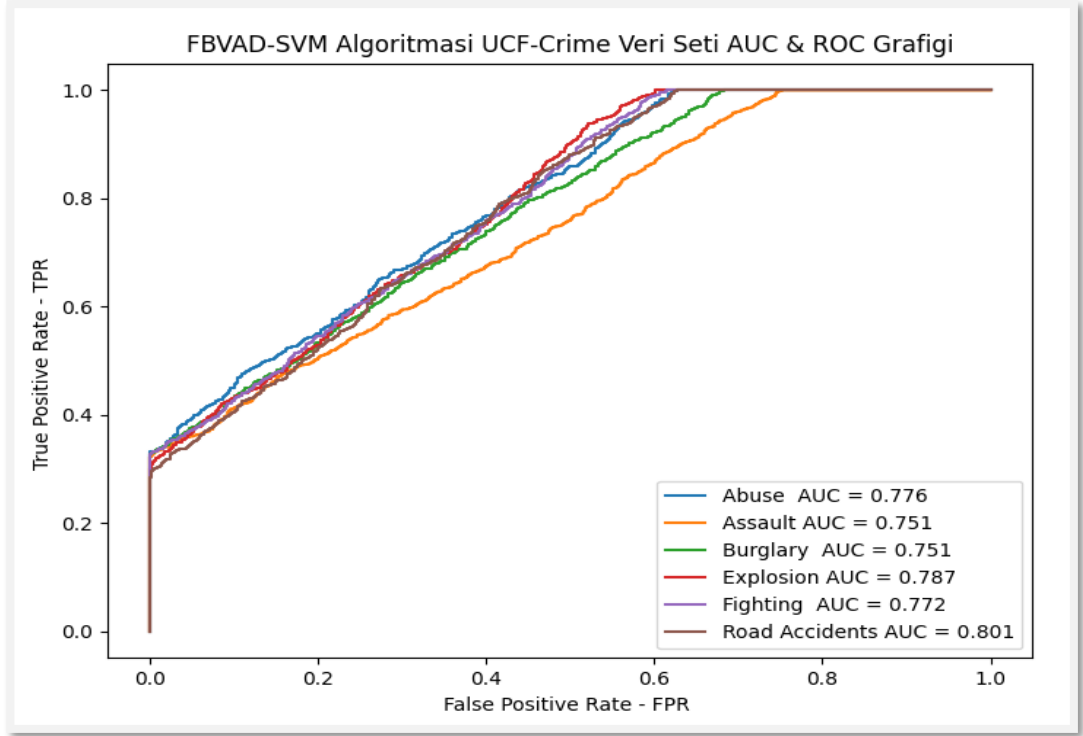
Destek Vektör Makinaları (Support Vector Machine - SVM) Algoritması ile UCF-Crime veriseti üzerinde yaptığımız video anomali tespiti çalışmamızın başarı oranları, Şekil 21’de kategori bazında gösterilmektedir.



Şekil 21. UCF-Crime Veriseti Destek Vektör Makinaları (Support Vector Machine - SVM) Algoritması ile Video Anomali Tespiti Başarım (Accuracy) Oranları

Destek Vektör Makinaları (Support Vector Machine - SVM) Algoritması ile UCF-Crime veri setine ait “Abuse, Assault, Burglary, Explosion, Fighting, Road Accident” isimli kategorilerindeki alt veri setleri üzerinde yaptığımız test çalışmalarının AUC – ROC grafikleri, Şekil 22’de gösterilmektedir.





Şekil 22. PBVAD-SVM Algoritması ile UCF-Crime Veri Seti için Video Anomali Tespiti AUC & ROC Grafiđi

### 3. Hareket Etki Haritası (MIM) Algoritması Test Sonuçları

Piksel bazlı video anomali tespiti için kullandığımız *hareket etki haritası (PBVAD-MIM) algoritması* ile, çalışmamızda elde ettiğimiz video anomali tespiti AUC başarımları ve performans sonuçları Çizelge 12’de, karmaşıklık matrisi (confusion matrix - CFM) referans verileri ise Çizelge 13’te yer almaktadır.

PBVAD-MIM algoritması ile video anomali tespiti AUC skor ve performans sonuçları, Çizelge 12’de veri seti kategorisi bazlı, "*AUC, Precision, Sensitivity ve F-Score*" değerleriyle birlikte gösterilmektedir.

Çizelge 12. PBVAD-MIM Algoritması AUC Skor ve Performans Tablosu

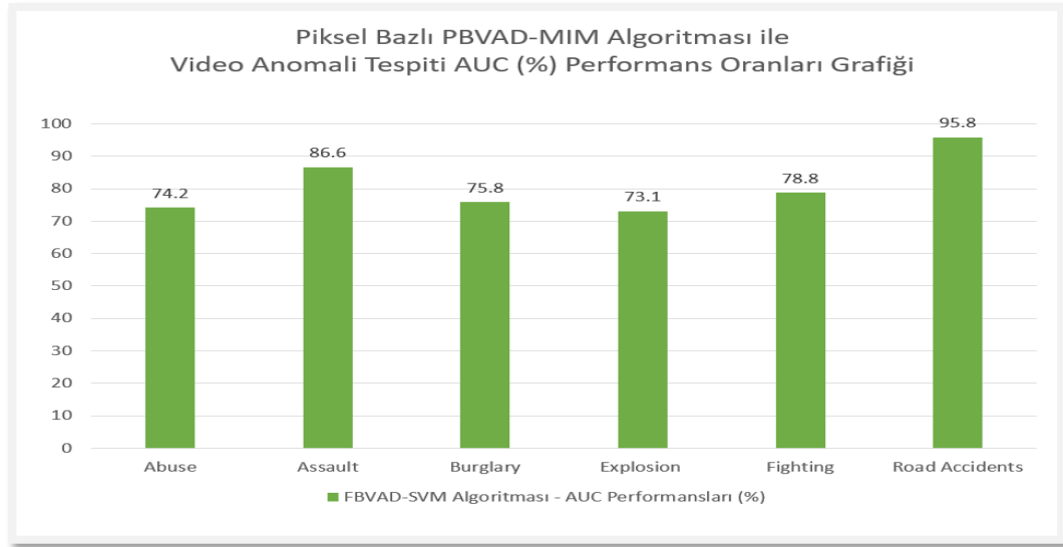
| Data Set       | AUC   | Precision | Sensitivity | F Score |
|----------------|-------|-----------|-------------|---------|
| Abuse          | 74.20 | 0.484     | 0.7419      | 0.652   |
| Assault        | 86.60 | 0.731     | 0.8657      | 0.845   |
| Burglary       | 75.80 | 0.516     | 0.7581      | 0.681   |
| Explosion      | 73.10 | 0.462     | 0.7308      | 0.632   |
| Fighting       | 78.80 | 0.576     | 0.7879      | 0.731   |
| Road Accidents | 95.80 | 0.917     | 0.9583      | 0.957   |

PBVAD-MIM algoritması ile video anomali tespiti karmaşıklık matrisi (CFM) referans verileri, Çizelge 13'te veri seti kategorisi bazlı olarak gösterilmektedir.

Çizelge 13. PBVAD-MIM Algoritması Karmaşıklık Matrisi (CFM) Referans Tablosu

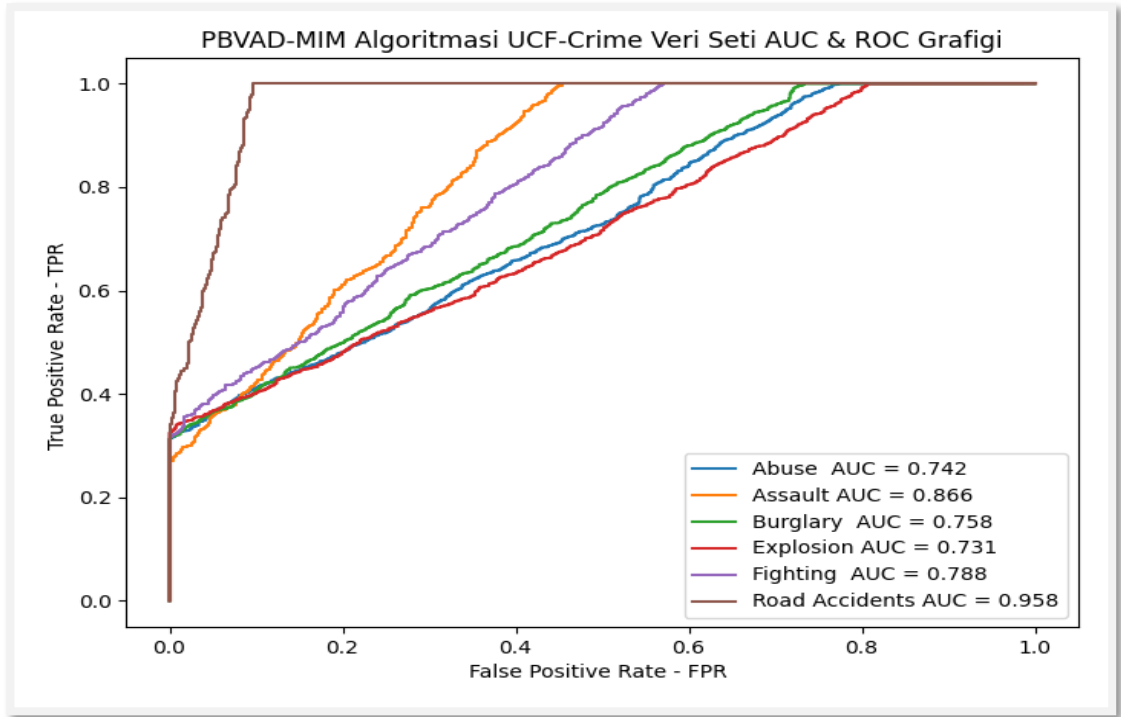
| Data Set       | Samples | Actual Positives | Actual Negatives | True Positives | True Negatives | False Negatives |
|----------------|---------|------------------|------------------|----------------|----------------|-----------------|
| Abuse          | 865     | 31               | 834              | 15             | 834            | 16              |
| Assault        | 2523    | 67               | 2456             | 49             | 2456           | 18              |
| Burglary       | 1698    | 31               | 1667             | 16             | 1667           | 15              |
| Explosion      | 757     | 26               | 731              | 12             | 731            | 14              |
| Fighting       | 944     | 33               | 911              | 19             | 911            | 14              |
| Road Accidents | 347     | 12               | 335              | 11             | 335            | 1               |

PBVAD-MIM algoritması ile UCF-Crime veriseti üzerinde yaptığımız video anomali tespiti çalışmamızın AUC başarımlar oranları, Şekil 23'te kategori bazında gösterilmektedir.



Şekil 23. UCF-Crime Veri Seti PBVAD-MIM Algoritması ile Video Anomali Tespiti AUC Başarımlar Oranları Grafiği

Hareket Etki Haritası (Motion Influence Map - MIM) Algoritması ile UCF-Crime veri setine ait “Abuse, Assault, Burglary, Explosion, Fighting, Road Accident” isimli kategorilerindeki alt veri setleri üzerinde yaptığımız test çalışmalarının AUC – ROC grafikleri, Şekil 24'te gösterilmektedir.



Şekil 24. PBVAD-MIM Algoritması ile UCF-Crime Veri Seti için Video Anomali Tespiti AUC & ROC Grafiği

#### 4. Video Anomali Tespiti Örnek Görüntüleri

Çalışmamızda, UCF-Crime veriseti üzerinde yaptığımız video anomali tespiti testlerinde elde edilen normal ve anomali video görüntü örnekleri, Şekil 25 ile Şekil 30 aralığında veri seti kategorisi bazlı olarak gösterilmektedir.

Test çalışmamızda, akan trafikte suiistimal (abuse) video anomali tespiti örnek görüntüleri Şekil 25’te gösterilmektedir, “a)” normal durumu, “b)” ve “c)” ise anomali durumları göstermektedir.



Şekil 25. UCF\_Crime Abuse002 veri setinde trafikte suiistimal anomali durum tespiti görüntüleri

Test çalışmamızda kapalı alandaki bir güvenlik kamerası görüntülerinde, saldırı (assault) video anomali durum tespiti örnek görüntüleri Şekil 26’da gösterilmektedir. Şekil 6’da “a)” normal durum örneğini gösterirken, “b)” ve “c)” anomali durumları göstermektedir.



Şekil 26. UCF\_Crime Assault002 veri setinde saldırı anomali durum tespiti görüntüleri

Diğer bir test çalışmamızda ise hırsızlık (burglary) video anomali tespiti örnek görüntüleri Şekil 27’de gösterilmektedir, “a)” normal durumu, “b)” ve “c)” anomali durumları göstermektedir.



Şekil 27. UCF\_Crime Burglary018 veri setinde hırsızlık anomali durum tespiti görüntüleri

Başka bir test çalışmamızın, patlama (explosion) video anomali tespiti örnek görüntüleri Şekil 28’de gösterilmektedir, “a)” normal durumu, “b)” ve “c)” anomali durumları göstermektedir.



Şekil 28. UCF\_Crime Explosion045 veri setinde patlama anomali durum tespiti görüntüleri

Test çalışmamızda yine kapalı alandaki bir güvenlik kamerası görüntülerinde, kavga (fighting) video anomali durum tespiti örnek görüntüleri Şekil 29’da gösterilmektedir. Şekil 29’da “a)” normal durum örneğini gösterirken, “b)” ve “c)” anomali durumları göstermektedir.



Şekil 29. UCF\_Crime Fighting006 veri setinde kavga anomali durum tespiti görüntüleri

Başka bir test çalışmamıza ait trafik kazası (road accident) video anomali tespiti örnek görüntüleri Şekil 30’da gösterilmektedir, “a)” normal durumu, “b)” ve “c)” ise anomali durumları göstermektedir.



Şekil 30. UCF\_Crime RoadAccidents002 veri setinde trafik kazası anomali tespiti görüntü örnekleri

## E. Frame ve Piksel Bazlı Algoritmaların Test Sonuçlarının Karşılaştırılması

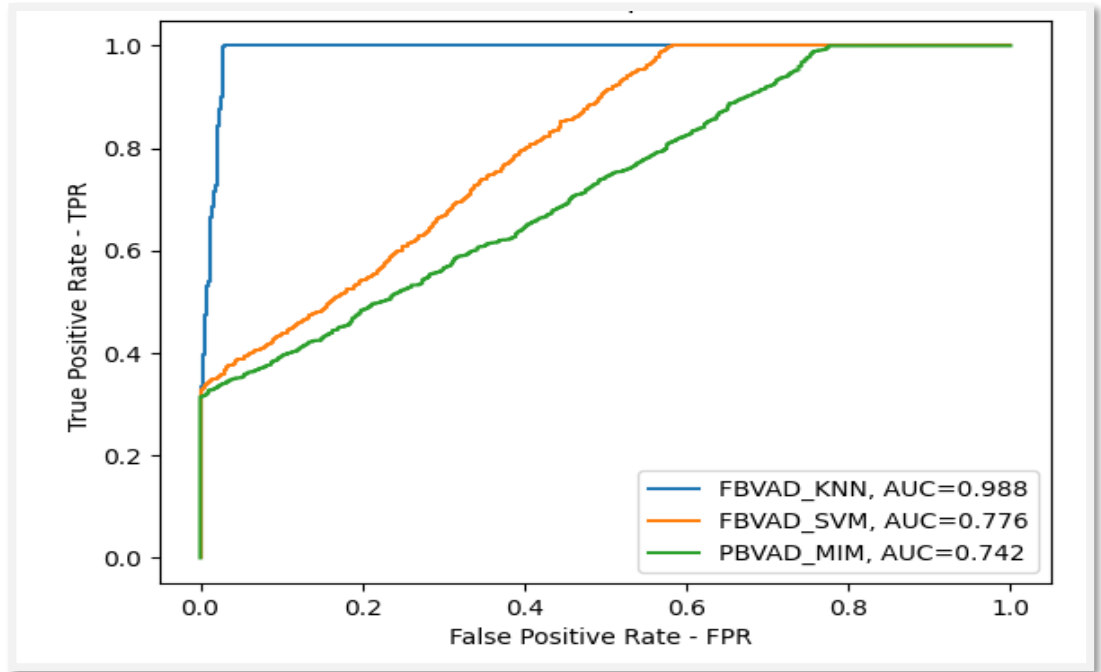
### 1. Abuse Kategorisi Algoritma Bazlı Sonuç Karşılaştırma

UCF-Crime veriseti Abuse kategorisine ait algoritma bazlı sonuç skor tablosu, AUC başarımları ve performans metrikleriyle birlikte, aşağıdaki Çizelge 14’te, algoritma bazlı AUC-ROC eğrisi grafiği ise Şekil 31’de gösterilmektedir. Söz konusu çizelgedeki veriler ve şekildeki AUC-ROC eğrisi grafiğinde de görüleceği üzere, *k*NN algoritması en yüksek başarımlarına sahiptir. SVM ve MIM algoritmalarının başarımları birbirine yakın olmakla birlikte, diğerlerine göre en düşük başarımlarını MIM algoritması göstermiştir.

Çizelge 14. UCF-Crime Veriseti Abuse Kategorisi Algoritma Bazlı Sonuç Skor Tablosu

| Algoritma | AUC (%) | Precision | Sensitivity | Specificity | F-Score |
|-----------|---------|-----------|-------------|-------------|---------|
| kNN       | 98.80   | 1.000     | 0.9742      | 0.948       | 0.974   |
| SVM       | 77.60   | 0.998     | 0.7757      | 0.588       | 0.874   |
| MIM       | 74.20   | 0.484     | 0.7419      | 0.982       | 0.652   |

UCF-Crime veriseti Abuse kategorisine ait algoritma bazlı AUC-ROC eğrisi grafiği, Şekil 31’de gösterilmektedir.



Şekil 31. UCF-Crime Veriseti Abuse Kategorisi Algoritma Bazlı AUC-ROC Eğrisi Grafiği

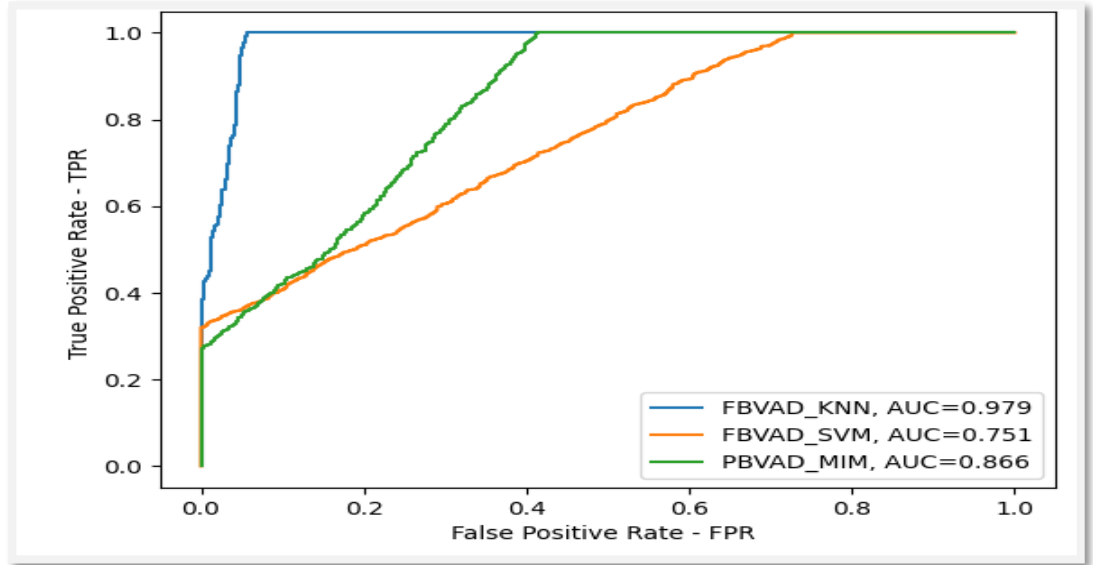
## 2. Assault Kategorisi Algoritma Bazlı Sonuç Karşılaştırma

UCF-Crime veriseti Assault kategorisine ait algoritma bazlı sonuç skor tablosu, AUC başarımları ve performans metrikleriyle birlikte, aşağıdaki Çizelge 15'te, algoritma bazlı AUC-ROC eğrisi grafiği ise Şekil 32'de gösterilmektedir. Söz konusu çizelgedeki veriler ve şekildeki AUC-ROC eğrisi grafiğinde de görüleceği üzere, *k*NN algoritması en yüksek başarımlarına sahiptir. MIM algoritmasının Assault kategorisinde başarımları ise daha önceki Abuse kategorisine göre çok daha iyidir. Bununla birlikte MIM algoritmasının başarımları oranı, *k*NN'e göre düşük olurken, SVM algoritmasına göre daha yüksek bir başarımlar oranına sahiptir. Assault kategorisinde diğer algoritmalara göre en düşük başarımlar oranını ise SVM algoritması göstermiştir.

Çizelge 15. UCF-Crime Veriseti Assault Kategorisi Algoritma Bazlı Sonuç Skor Tablosu

| Algoritma   | AUC (%) | Precision | Sensitivity | Specificity | F-Score |
|-------------|---------|-----------|-------------|-------------|---------|
| <i>k</i> NN | 97.90   | 1.000     | 0.9569      | 0.914       | 0.955   |
| SVM         | 75.13   | 0.992     | 0.7515      | 0.376       | 0.857   |
| MIM         | 86.60   | 0.731     | 0.8657      | 0.993       | 0.845   |

UCF-Crime veriseti Assault kategorisine ait algoritma bazlı AUC-ROC eğrisi grafiği, Şekil 32'de gösterilmektedir.



Şekil 32. UCF-Crime Veriseti Assault Kategorisi Algoritma Bazlı AUC-ROC Eğrisi Grafiği


### 3. Burglary Kategorisi Algoritma Bazlı Sonuç Karşılaştırma

UCF-Crime veriseti Burglary kategorisine ait algoritma bazlı sonuç skor tablosu, AUC başarımları ve performans metrikleriyle birlikte, aşağıdaki Çizelge 16'da, algoritma bazlı AUC-ROC eğrisi grafiği ise Şekil 33'te gösterilmektedir. Söz konusu çizelgedeki veriler ve şekildeki AUC-ROC eğrisi grafiğinde de görüleceği üzere, *k*NN algoritması en yüksek başarımlarına sahiptir. MIM ve SVM algoritmalarının başarımları birbirine çok yakın olmakla birlikte, Burglary kategorisine diğer algoritmalara göre en düşük başarımlarını SVM algoritması göstermiştir.

Çizelge 16. UCF-Crime Veriseti Burglary Kategorisi Algoritma Bazlı Sonuç Skor Tablosu

| Algoritma | AUC (%) | Precision | Sensitivity | Specificity | F-Score |
|-----------|---------|-----------|-------------|-------------|---------|
| kNN       | 96.60   | 1.000     | 0.9325      | 0.865       | 0.928   |
| SVM       | 75.11   | 0.992     | 0.7520      | 0.375       | 0.858   |
| MIM       | 75.80   | 0.516     | 0.7581      | 0.991       | 0.681   |

UCF-Crime veriseti Burglary kategorisine ait algoritma bazlı AUC-ROC eğrisi grafiği, Şekil 33'te gösterilmektedir.



Şekil 33. UCF-Crime Veriseti Burglary Kategorisi Algoritma Bazlı AUC-ROC Eğrisi Grafiği




#### 4. Explosion Kategorisi Algoritma Bazlı Sonuç Karşılaştırma

UCF-Crime veriseti Explosion kategorisine ait algoritma bazlı sonuç skor tablosu, AUC başarımları ve performans metrikleriyle birlikte, aşağıdaki Çizelge 17’de, algoritma bazlı AUC-ROC eğrisi grafiği ise Şekil 34’te gösterilmektedir. Söz konusu çizelgedeki veriler ve şekildeki AUC-ROC eğrisi grafiğinde de görüleceği üzere, Explosion kategorisinde de *k*NN algoritması en yüksek başarımları oranına sahiptir. SVM ve MIM algoritmalarının başarımları oranları birbirine yakın olmakla birlikte, Explosion kategorisinde diğer algoritmalara göre en düşük başarımları oranını MIM algoritması göstermiştir.

Çizelge 17. UCF-Crime Veriseti Explosion Kategorisi Algoritma Bazlı Sonuç Skor Tablosu

| Algoritma | AUC (%) | Precision | Sensitivity | Specificity | F-Score |
|-----------|---------|-----------|-------------|-------------|---------|
| kNN       | 99.30   | 1.000     | 0.9845      | 0.969       | 0.984   |
| SVM       | 78.70   | 0.995     | 0.7873      | 0.394       | 0.881   |
| MIM       | 73.10   | 0.462     | 0.7308      | 0.982       | 0.632   |

UCF-Crime veriseti Explosion kategorisine ait algoritma bazlı AUC-ROC eğrisi grafiği, Şekil 34’te gösterilmektedir.



Şekil 34. UCF-Crime Veriseti Explosion Kategorisi Algoritma Bazlı AUC-ROC Eğrisi Grafiği


## 5. Fighting Kategorisi Algoritma Bazlı Sonuç Karşılaştırma

UCF-Crime veriseti Fighting kategorisine ait algoritma bazlı sonuç skor tablosu, AUC başarımları ve performans metrikleriyle birlikte, aşağıdaki Çizelge 18’de, algoritma bazlı AUC-ROC eğrisi grafiği ise Şekil 35’te gösterilmektedir. Söz konusu çizelgedeki veriler ve şekildeki AUC-ROC eğrisi grafiğinde de görüleceği üzere, *k*NN algoritması en yüksek başarımlarına sahiptir. MIM ve SVM algoritmalarının başarımları birbirine çok yakın olmakla birlikte, Fighting kategorisine diğer algoritmalara göre en düşük başarımlarını SVM algoritması göstermiştir.

Çizelge 18. UCF-Crime Veriseti Fighting Kategorisi Algoritma Bazlı Sonuç Skor Tablosu

| Algoritma | AUC (%) | Precision | Sensitivity | Specificity | F-Score |
|-----------|---------|-----------|-------------|-------------|---------|
| kNN       | 96.80   | 1.000     | 0.9302      | 0.860       | 0.925   |
| SVM       | 77.20   | 0.994     | 0.7722      | 0.386       | 0.871   |
| MIM       | 78.80   | 0.576     | 0.7879      | 0.985       | 0.731   |

UCF-Crime veriseti Fighting kategorisine ait algoritma bazlı AUC-ROC eğrisi grafiği, Şekil 35’te gösterilmektedir.



Şekil 35. UCF-Crime Veriseti Fighting Kategorisi Algoritma Bazlı AUC-ROC Eğrisi Grafiği

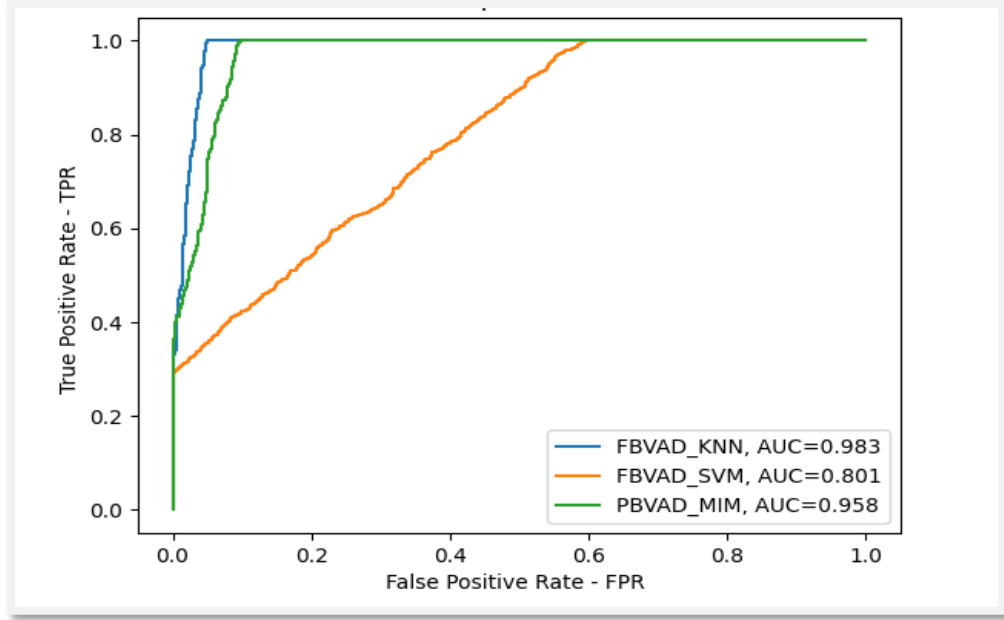
## 6. Road Accidents Kategorisi Algoritma Bazlı Sonuç Karşılaştırma

UCF-Crime veriseti Road Accidents kategorisine ait algoritma bazlı sonuç skor tablosu, AUC başarımları ve performans metrikleriyle birlikte, aşağıdaki Çizelge 19’da, algoritma bazlı AUC-ROC eğrisi grafiği ise Şekil 36’da gösterilmektedir. Söz konusu çizelgedeki veriler ve şekildeki AUC-ROC eğrisi grafiğinde de görüleceği üzere, diğer kategorilerde olduğu gibi *k*NN algoritması, en yüksek başarımlarına sahiptir. MIM algoritması ise diğer tüm kategorilere göre Road Accidents kategorisinde MIM algoritmaları içerisinde en yüksek başarımlarına sahip olduğu kategori, Road Accidents kategorisidir. MIM algoritması ilk defa bu kategoride *k*NN algoritmasına yakın bir başarımlarına sahip olmuştur. Bununla birlikte MIM algoritmasının başarımları, *k*NN’e göre küçük bir farkla düşük olurken, SVM algoritmasına göre çok daha yüksek bir başarımlarına sahiptir. Road Accidents kategorisinde diğer algoritmalara göre en düşük başarımları ise SVM algoritması göstermiştir. SVM algoritması da Road Accidents kategorisinde, diğer kategorilere göre, en yüksek AUC başarımları ve F-Score değerine sahiptir.

Çizelge 19. UCF-Crime Veriseti Road Accidents Kategorisi Algoritma Bazlı Sonuç Skor Tablosu

| Algoritma   | AUC (%) | Precision | Sensitivity | Specificity | F-Score |
|-------------|---------|-----------|-------------|-------------|---------|
| <i>k</i> NN | 98.30   | 1.000     | 0.9565      | 0.913       | 0.955   |
| SVM         | 80.10   | 0.996     | 0.8012      | 0.401       | 0.890   |
| MIM         | 95.80   | 0.917     | 0.9583      | 0.997       | 0.957   |

UCF-Crime veriseti Road Accidents kategorisine ait algoritma bazlı AUC-ROC eğrisi grafiği, Şekil 36’da gösterilmektedir.



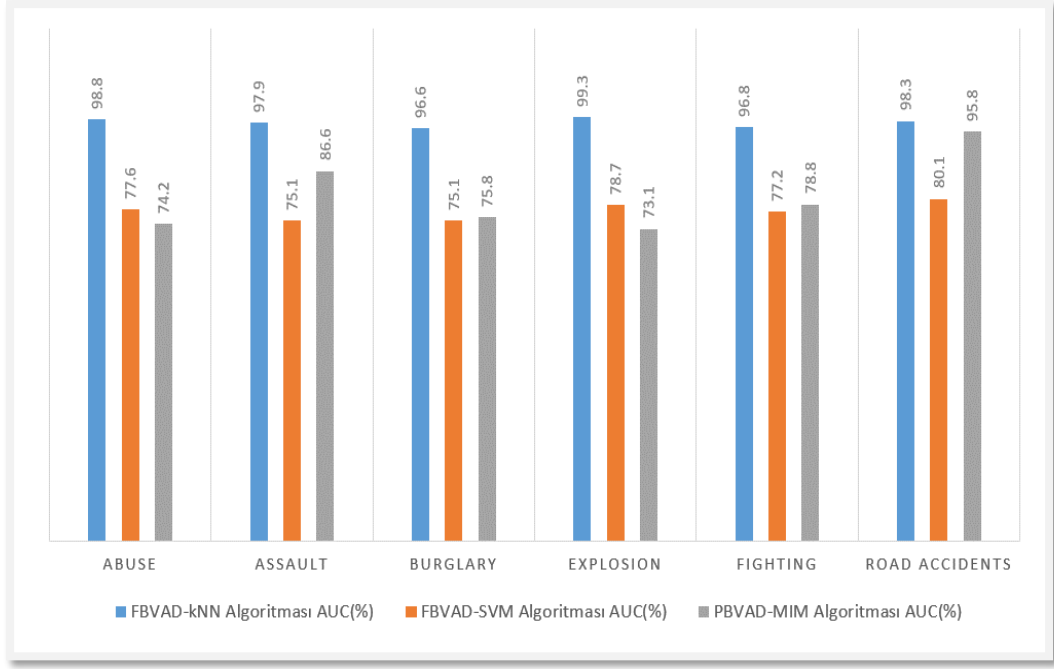
Şekil 36. UCF-Crime Veriseti Road Accidents Kategorisi Algoritma Bazlı AUC-ROC Eğrisi Grafiği

## 7. Tüm Algoritmalar İçin Kategori Bazlı Genel Sonuç Karşılaştırması

Piksel bazlı video anomali tespiti için kullandığımız PBVAD-MIM algoritması ile Frame bazlı video anomali tespiti için kullandığımız FBVAD-kNN ve FBVAD-SVM algoritmalarının, UCF-Crime veri seti içerisinde deney yaptığımız kategorilere ait video anomali tespiti AUC performans sonuçları, Çizelge 20'deki tabloda ve Şekil 37'deki grafikte kategori bazlı gösterilmektedir.

Çizelge 20. UCF-Crime Veriseti Algoritma ve Kategori Bazlı AUC Skor Tablosu

| Data Set       | FBVAD-kNN<br>AUC (%) | FBVAD-SVM<br>AUC (%) | PBVAD-MIM<br>AUC (%) |
|----------------|----------------------|----------------------|----------------------|
| Abuse          | 98.80                | 77.60                | 74.20                |
| Assault        | 97.90                | 75.13                | 86.60                |
| Burglary       | 96.60                | 75.11                | 75.80                |
| Explosion      | 99.30                | 78.70                | 73.10                |
| Fighting       | 96.80                | 77.20                | 78.80                |
| Road Accidents | 98.30                | 80.10                | 95.80                |



Şekil 37. UCF-Crime Veri Setinde Frame Tabanlı (FBVAD) ve Piksel Tabanlı (PBVAD) Video Anomalisi Tespiti AUC Oranları.

Her bir algoritma için testlerimizde kaydedilen özellik çıkarma ve anormallik tespit süreleri Çizelge 21'de gösterilmektedir.

Çizelge 21. Test Edilen Algoritmalar İçin Özellik Çıkarma ve Anormallik Tespit Süreleri

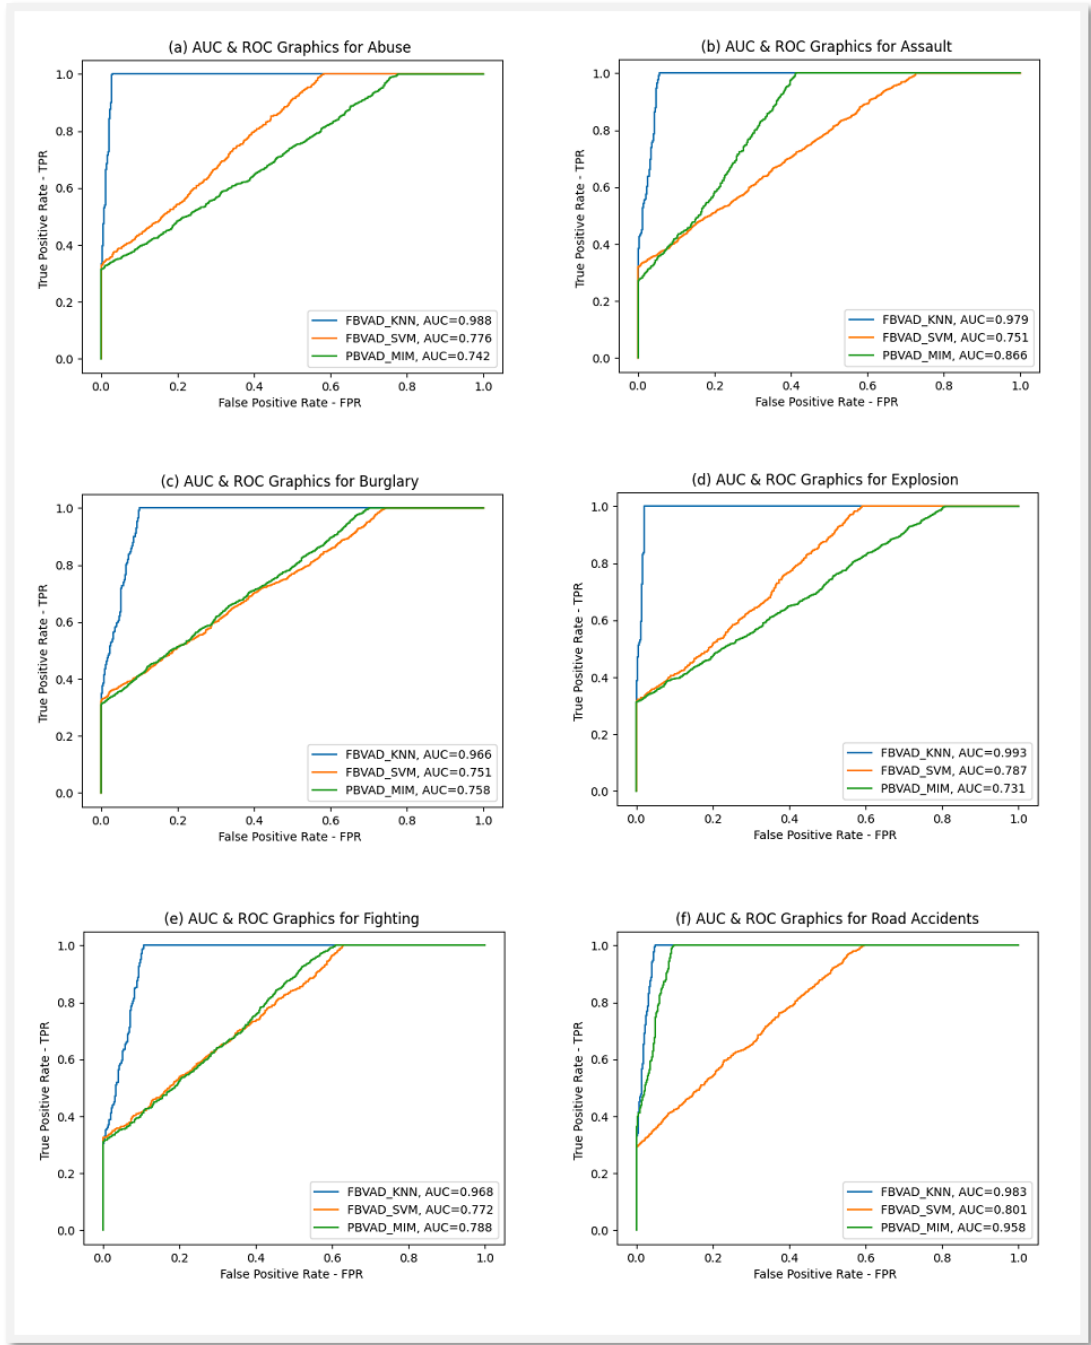
| Data Set       | Frame Sayısı | Video Süresi (dk:sn) | FBVAD -kNN (dk:sn) | FBVAD -SVM (dk:sn) | PBVAD -MIM (dk:sn) |
|----------------|--------------|----------------------|--------------------|--------------------|--------------------|
| Abuse          | 865          | 00:28                | 00:40              | 00:40              | 00:40              |
| Assault        | 2523         | 01:24                | 02:12              | 02:12              | 02:12              |
| Burglary       | 1698         | 00:56                | 01:05              | 01:05              | 00:43              |
| Explosion      | 757          | 00:25                | 00:36              | 00:36              | 00:29              |
| Fighting       | 944          | 00:31                | 00:44              | 00:44              | 00:43              |
| Road Accidents | 347          | 00:11                | 00:13              | 00:13              | 00:17              |

Tablo ve grafiklerde de görüleceği üzere, özellikle “*road accident, assault, explosion*” kategorilerine ait veri setlerinde çalışmamızın başarı oranı, belirtilen diğer çalışmalara göre daha yüksektir. “*assault, burglary, explosion, fighting*” kategorilerine ait veri setlerinde ise başarı oranı diğer çalışmalara yakın olmakla birlikte daha iyi sonuç elde edilmiştir.

UCF-Crime veri setine ait “*abuse, assault, burglary, explosion, fighting*” isimli kategorilerindeki alt veri setleri üzerinde yaptığımız test çalışmaları ile, bu

alanda yapılmış olan diğer çalışmaların karşılaştırmalı başarımları, Şekil 38’de gösterilmektedir.

Diğer taraftan, Frame bazlı algoritmalarda, kategoriler için anomali tespiti başarımları birbirine yakın sonuçlar çıkarken, Piksel bazlı algoritmalarda anomali tespiti başarımlarında kategoriler arasında büyük farklılıklar oluşmaktadır. Piksel bazlı anomali tespitinde, “*assault, fighting, road accident*” gibi daha hareketli olan ve pikseller arasındaki farkların yüksek olduğu video karelerinde, “*abuse, burglary, explosion*” gibi pikseller arasındaki farkları benzer olan video karelerine göre anomali tespiti başarımları daha yüksektir. Anomali tespiti sonuç tabloları ve grafikleri dikkatlice incelendiğinde, Frame bazlı ve Piksel bazlı algoritmaların kategori bazlı başarımları farklılıkları ve yakınlıkları, daha net görülmektedir.



Şekil 38. UCF-Crime “Abuse, Assault, Burglary, Explosion, Fighting, Road Accident” Verisetleri Anomali Tespiti AUC-ROC Grafiği

(a) Abuse, (b) Assault, (c) Burglary, (d) Explosion, (e) Fighting, (f) Road Accident kategorilerindeki veri setleri üzerinde yapılan çalışmaların anomali tespiti AUC-ROC grafikleri her bir kategori için ayrı ayrı hazırlanmıştır.

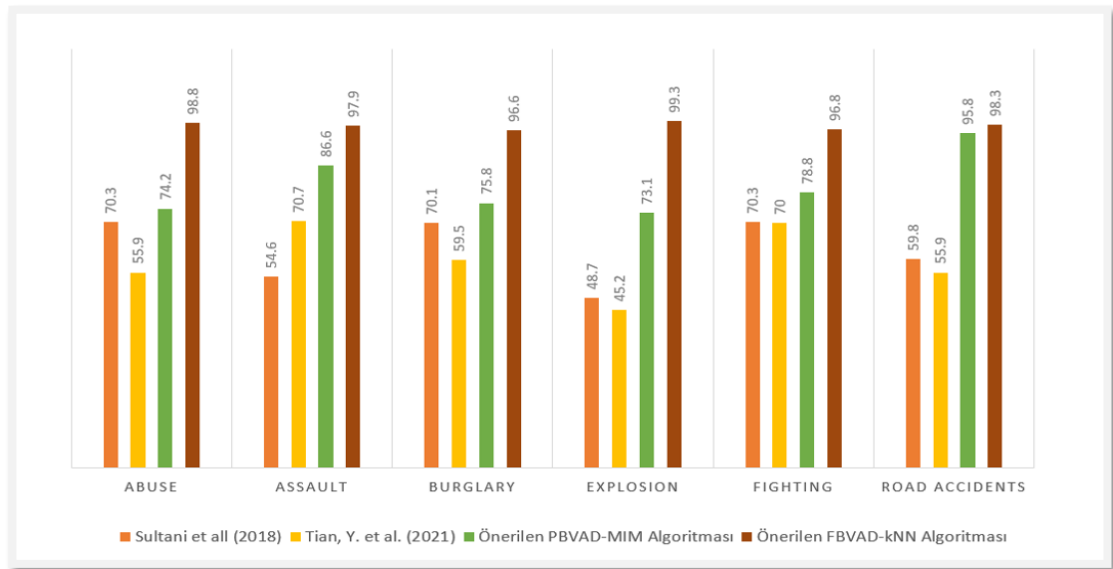
## F. Test Sonuçlarının Literatürdeki Benzer Çalışmalarla Karşılaştırılması

Çalışmamızda kullandığımız UCF-Crime verisetine ait, video anomali tespiti başarımlarını incelediğimizde, bu veriseti ile yapılan daha önceki iki çalışmaya göre (Sultani, W. et al. (2018), Tian, Y. et al. (2021)), tüm kategorilerde daha iyi sonuç elde ettiğimiz gözlemlenmektedir. Testlerimizin başarımları, diğer çalışmalarla karşılaştırmalı olarak Çizelge 22 ve Şekil 39’da gösterilmektedir.

Çizelge 22. CF-Crime Veriseti Anomali Tespiti AUC Performans Karşılaştırma Tablosu

| Data Set       | Sultani, W. et al. (2018) | Tian, Y. et al. (2021) | PBVAD-MIM (Ours) | FBVAD-kNN (Ours) |
|----------------|---------------------------|------------------------|------------------|------------------|
| Abuse          | 70.3                      | 55.9                   | 74.2             | 98.80            |
| Assault        | 54.6                      | 70.7                   | 86.6             | 97.90            |
| Burglary       | 70.1                      | 59.5                   | 75.8             | 96.60            |
| Explosion      | 48.7                      | 45.2                   | 73.1             | 99.30            |
| Fighting       | 70.3                      | 70                     | 78.8             | 96.80            |
| Road Accidents | 59.8                      | 55.9                   | 95.8             | 98.30            |

UCF-Crime Veriseti üzerinde yaptığımız test çalışmaları ile bu alanda yapılmış olan diğer çalışmaların karşılaştırmalı başarımları, Şekil 39’da gösterilmektedir.



Şekil 39. UCF-Crime Veriseti Anomali Tespiti Başarımları Karşılaştırma Grafiği



## V.SONUÇ VE ÖNERİLER

### A. Tartışma

Video anomali tespiti için yaptığımız deneysel çalışmalarımızda, frame bazlı (FBVAD-kNN ve FBVAD-SVM) algoritmaların video anomali tespiti başarımlarının, veri seti kategorisine göre çok yüksek farklılık göstermeyip, benzer değerlere sahip olduğu gözlemlenmiştir. Bununla birlikte piksel tabanlı (PBVAD-MIM) algoritma ile yapılan video anomali tespiti başarımlarında ise, veri seti kategorileri arasında çok çeşitli farklılıklar olduğu gözlemlenmiştir.

Piksel bazlı anomali tespitinde, pikseller arasındaki farkı büyük olan video görüntülerini içeren veri seti kategorilerinde, PBVAD-MIM algoritmasının başarımları daha yüksektir. Örnek olarak “*saldırı (assault), kavga (fighting) ve trafik kazası (road accident)*” kategorilerine ait sonuçları gösterebiliriz. Diğer taraftan piksel bazlı anomali tespitinde, pikseller arasındaki farkı küçük olan video görüntülerini içeren veri seti kategorilerinde ise PBVAD-MIM algoritmasının başarımları daha düşüktür. Bu duruma da örnek olarak “*istismar (abuse), hırsızlık (burglary) ve patlama (explosion)*” kategorilerine ait sonuçları gösterebiliriz. Çizelge 20 ve Çizelge 22’deki sonuç tabloları ile Şekil 38 ve Şekil 39’daki grafikler dikkatle incelendiğinde, Piksel bazlı ve Frame bazlı algoritmaların kategori düzeyinde başarımları arasındaki farklılıkları ve benzerlikleri daha net anlaşılabilir.

Deneysel çalışmalarımızda elde ettiğimiz sonuçlar, aynı şekilde UCF-Crime veri setini kullanan diğer iki çalışma ile karşılaştırıldığında (Sultani, W. et al. (2018), Tian, Y. et al. (2021)), Çizelge 22 ve Şekil 39’da gösterildiği gibi tüm kategorilerde çalışmamızın başarımlarının daha yüksek olduğu görülmektedir. Özellikle kNN algoritması kullanılarak elde edilen frame bazlı video anomali tespiti (FBVAD-kNN) sonuçlarımız, piksel bazlı video anomali tespiti (PBVAD-MIM) algoritması kullanarak elde ettiğimiz sonuçlarımızdan ve diğer çalışmaların sonuçlarından çok daha iyi olduğu gözlemlenmektedir. Diğer taraftan piksel tabanlı

PBVAD-MIM algoritmamızın video anomali tespiti başarımları oranı, “*trafik kazası (road accident), saldırı (assault), patlama (explosion) ve kavga (fighting)*” kategorilerinde, adı geen diğeri iki alıřmanın sonularına gre daha yksektir. Bununla birlikte “*istismar (abuse) ve hırsızlık (burglary)*” kategorilerinde ise sonularımız, sz konusu diğeri iki alıřmanın sonularına daha yakın değeri olmasına rağmen, yine de PBVAD-MIM algoritmamızın başarımları oranları daha yksek değeri sahiptir.

## **B. Sonu ve neriler**

alıřmamızda yaptığımız deneysel sonulara gre başarımları oranlarımız, FBVAD-kNN modeli algoritması ile yapılan testlerde ortalama olarak 98.0 %, PBVAD-MIM modeli algoritması ile yapılan testlerde ise ortalama olarak 80.7%'dir. PBVAD-MIM algoritmasıyla yapılan piksel bazlı anomali tespiti alıřmalarımızda, pikseller arasındaki hız ve değeri farkı byk olan video grntlerinde, başarımları oranlarının daha yksek, pikseller arasındaki hız ve değeri farkı kk olan video grntlerinde ise, başarımları oranlarının daha dřk olduđu gzlemlenmiřtir.

Diğeri taraftan yaptığımız deneysel sonulara gre, “*saldırı (assault), istismar (abuse) ve hırsızlık (burglary), patlama (explosion), kavga (fighting) ve trafik kazası (road accident)*” vb gibi olaylara ait video ve kamera grntlerinde, gerek zamanlıya yakın bir řekilde otomatik olarak anomali tespiti yapılabileceđi gzlemlenmiřtir. Bylece gvenlik grevlisi, operatr ya da ilgililerin bu grntlere yoğunlařarak daha hızlı tespit yapması ve aksiyon alması kolaylařtırılmıř olacaktır. Bununla birlikte anomali durumların gzden kaırılma olasılıkları en minimum seviyeye indirilmıř olacaktır. Diğeri taraftan gerek zamanlıya yakın bir řekilde anomali durumun tespit edilmesiyle, olası zararlı etkileri tamamen nlenebilecektir ya da en az dzeye indirilebilecektir. Ayrıca alıřmamızla, evrenin korunması, zaman, imkn ve kaynakların verimli kullanılması gibi birok dolaylı katkı da sađlanmış olacaktır.

alıřmamızın diğeri bir katkısı da, řehir ve kamu gvenliđini artırmak iin, anomali durumların gerek zamanlı olarak tespit edilerek, alarm ve uyarı sistemleri geliřtirilmesine referans teřkil edecek olmasıdır. Aynı řekilde yine gerek zamanlı

anomali tespiti alıřmaları ile iř kazaları, hırsızlık, kundaklama vb gibi durumlar iin erken uyarı sistemleri de geliřtirilebilir.

Sonraki arařtırmalar iin, ařađıdaki konularda alıřmaların yapılması faydalı olabilir.

- *Başarımı düşük olan alıřmaların metotları, daha güncel platform ve donanımlar kullanılarak yapıldığında, başarımlarında farklılık olup olmadığı araştırılabilir.*
- *Benzer alıřmaların başarımlarını dışında, iřlem sürelerinin kısaltılması ile kaynak ve enerji kullanımlarının azaltılması ve mümkün olan en düşük seviyeli donanım ile alışabilmesi iin gerekli optimizasyon üzerinde alışılabilir.*
- *Gerçek zamanlı anomali tespiti teknikleri kullanarak erken uyarı ve alarm sistemleri geliřtirilebilir, anomali durumların önlenmesi iin katkı sağlanabilir.*

## **VI. KAYNAKÇA**

### **KİTAPLAR**

KIM, K., Davis, L.S. (2011). Object Detection and Tracking for Intelligent Video Surveillance. In: Lin, W., Tao, D., Kacprzyk, J., Li, Z., Izquierdo, E., Wang, H. (eds) Multimedia Analysis, Processing and Communications. Studies in Computational Intelligence, vol 346. Springer, Berlin, Heidelberg. [https://doi.org/10.1007/978-3-642-19551-8\\_9](https://doi.org/10.1007/978-3-642-19551-8_9)

### **MAKALELER**

ADAM, A., Rivlin, E., Shimshoni, I., Reinitz, D. (2008). Robust Real-Time Unusual Event Detection using Multiple Fixed-Location Monitors. IEEE Trans. Pattern Anal. Mach. Intell. 2008, 30, 555–560. <https://doi.org/10.1109/tpami.2007.70825>.

AJLOUNI, N., Özyavaş, A., Takaoğlu, M., Takaoğlu, F., Ajlouni, F. (2023) Medical image diagnosis based on adaptive Hybrid Quantum CNN. BMC Med. Imaging 2023, 23, 126. <https://doi.org/10.1186/s12880-023-01084-5>.

ALTAMIMI, A.B., Ullah, H. (2020). Panic Detection in Crowded Scenes. Eng. Technol. Appl. Sci. Res. 2020, 10, 5412–5418.

AMIN, S.U., Ullah, M., Sajjad, M., Cheikh, F.A., Hijji, M., Hijji, A., Muhammad, K. (2020). EADN: An Efficient Deep Learning Model for Anomaly Detection in Videos. Mathematics 2022, 10, 1555. <https://doi.org/10.3390/math10091555>.

ANTONAKAKI, P., Kosmopoulos, D., Perantonis, S. J. (2009). Detecting abnormal human behaviour using multiple cameras. Signal Processing, Volume 89, Issue 9, 2009, Pages 1723-1738, ISSN 0165-1684. DOI:<https://doi.org/10.1016/j.sigpro.2009.03.016>.

- BAYKARA, H. C., Bıyık, E., Gül, G., Onural, D., Öztürk, A. S., Yıldız, I. (2017). Real-Time Detection, Tracking and Classification of Multiple Moving Objects in UAV Videos. 2017 IEEE 29th International Conference on Tools with Artificial Intelligence (ICTAI), 2017, pp. 945-950, doi: 10.1109/ICTAI.2017.00145.
- BERTINI, M., Del Bimbo, A., Seidenari, L. (2012) Multi-scale and real-time non-parametric approach for anomaly detection and localization. *Comput. Vis. Image Underst.* 2011, 116, 320–329, ISSN 1077-3142. <https://doi.org/10.1016/j.cviu.2011.09.009>.
- BOUGUETTAYA, A., Kechida, A. & Taberkit, A. M. (2019). A Survey on Lightweight CNN-Based Object Detection Algorithms for Platforms with Limited Computational Resources . *International Journal of Informatics and Applied Mathematics* , 2 (2) , 28-44. Retrieved from <https://dergipark.org.tr/tr/pub/ijiam/issue/52418/654318>
- CALDERARA, S., Heinemann, U., Prati, A., Cucchiara, R., Tishby, N. (2013). Detecting anomalies in people’s trajectories using spectral graph analysis. *Comput. Vis. Image Underst.* 2011, 115, 1099–1111, ISSN 1077, 3142. <https://doi.org/10.1016/j.cviu.2011.03.003>.
- CHANDRAJIT, M., Girisha, R., & Vasudev, T. (2016). Multiple objects tracking in surveillance video using color and Hu moments. *Signal & Image Processing : An International Journal (SIPIJ)* Vol.7, No.3, June 2016. DOI: 10.5121/sipij.2016.7302
- CHANG, Y., Tu, Z., Xie, W., Yuan, J. (2020). Clustering driven deep autoencoder for video anomaly detection. In *European Conference on Computer Vision*, Springer: Cham, Switzerland, 2020, pp. 329–345. [https://doi.org/10.1007/978-3-030-58555-6\\_20](https://doi.org/10.1007/978-3-030-58555-6_20).
- CHENG, K.W., Chen, Y.T., Fang, W.H. (2015). Video anomaly detection and localization using hierarchical feature representation and Gaussian process regression. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Boston, MA, USA, 7–12 June 2015, pp. 2909–2917. <https://doi.org/10.1109/CVPR.2015.7298909>.

- COŞAR, S., Donatiello, G., Bogorny, V., Garate, C., Alvares, L. O., Brémond, F. (2016). Toward Abnormal Trajectory and Event Detection in Video Surveillance, in *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 27, no. 3, pp. 683-695, March 2017, doi: 10.1109/TCSVT.2016.2589859.
- DOSHI, K., Yilmaz, Y. (2020). Any-Shot Sequential Anomaly Detection in Surveillance Videos. In *Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, Seattle, WA, USA, 14–19 June 2020, pp. 4037–4042. <https://doi.org/10.1109/CVPRW50498.2020.00475>.
- DUONG, H.T., Le, V.T., Hoang, V.T. (2023). Deep Learning-Based Anomaly Detection in Video Surveillance: A Survey. *Sensors* 2023, 23, 5024. <https://doi.org/10.3390/s23115024>
- FAN, Y., Wen, G., Li, D., Qiu, S., Levine, M.D., Xiao, F. (2020). Video anomaly detection and localization via Gaussian Mixture Fully Convolutional Variational Autoencoder. *Comput. Vis. Image Underst.* 2020, 195, 102920, ISSN 1077-3142. <https://doi.org/10.1016/j.cviu.2020.102920>.
- FENG, J., Liang, Y., Li, L. (2021). Anomaly Detection in Videos Using Two-Stream Autoencoder with Post Hoc Interpretability. *Computational Intelligence and Neuroscience*, vol. 2021, Article ID 7367870, 15 pages, 2021. <https://doi.org/10.1155/2021/7367870>
- FENG, J.C., Hong, F.T., Zheng, W.S. (2021). MIST: Multiple Instance Self-Training Framework for Video Anomaly Detection. In *Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2021, pp. 14004–14013. <https://doi.org/10.1109/CVPR46437.2021.01379>.
- GANOKRATANAA, T., Aramvith, S., Sebe, N. (2020). Unsupervised Anomaly Detection and Localization Based on Deep Spati-otemporal Translation Network. *IEEE Access* 2020, 8, 50312–50329.
- GEORGESCU, M.I., Barbalau, A., Ionescu, R.T., Khan, F.S., Popescu, M., Shah, M. (2021). Anomaly detection in video via self-supervised and multi-task learning. In *Proceedings of the IEEE/CVF Conference on*

Computer Vision and Pattern Recognition, Nashville, TN, USA, 20–25  
June 2021, pp. 12742–12752.  
<https://doi.org/10.1109/CVPR46437.2021.01255>.

GEORGESCU, M.I., Ionescu, R., Khan, F.S., Popescu, M., Shah, M. (2021). A  
Background-Agnostic Framework with Adversarial Train-ing for  
Abnormal Event Detection in Video. *IEEE Trans. Pattern Anal. Mach.  
Intell.* 2022, 44, 4505–4523.  
<https://doi.org/10.1109/TPAMI.2021.3074805>.

GIANCHANDANI, U., Tirupattur, P., Shah, M. Weakly-Supervised  
Spatiotemporal Anomaly Detection, University of Central Florida  
Center for Research in Computer Vision REU: Orlando, FL, USA,  
2019.

GONG, D., Liu, L., Le, V., Saha, B., Mansour, M.R., Venkatesh, S., Hengel,  
A.V.D. (2019). Memorizing Normality to Detect Anomaly: Memory-  
Augmented Deep Autoencoder for Unsupervised Anomaly Detection.  
In *Proceedings of the 2019 IEEE/CVF Inter-national Conference on  
Computer Vision (ICCV)*, Seoul, Korea, 27 October–2 November 2019,  
pp. 1705–1714.

HAO, Y., Xu, Z.-J., Liu, Y., Wang, J., Fan, J.-L. Effective Crowd Anomaly  
Detection Through Spatio-temporal Texture Analy-sis. *Int. J. Autom.  
Comput.* 2018, 16, 27–39. <https://doi.org/10.1007/s11633-018-1141-z>.

HASAN, M., Choi, J., Neumann, J., Roy-Chowdhury, A. K., & Davis, L. S. (2016).  
Learning temporal regularity in video sequences. In *Proceedings of the  
IEEE conference on computer vision and pattern recognition* (pp. 733-  
742).

HILEY, L., Preece, A., and Hicks, Y., (2019). Explainable Deep Learning for  
Video Recognition Tasks: A Framework & Recommendations. 2019.  
DOI: <https://doi.org/10.48550/arXiv.1909.05667>

HOU, J., Wu, X., Chen, J., Luo, J., & Jia, Y. (2018). Unsupervised Deep Learning  
of Mid-Level Video Representation for Action Recognition.  
*Proceedings of the AAAI Conference on Artificial Intelligence*, 32(1).

Retrieved

from

<https://ojs.aaai.org/index.php/AAAI/article/view/12300>

- HOU, J., Wu, X., Chen, J., Luo, J., Jia, Y. (2018). Unsupervised Deep Learning of Mid-Level Video Representation for Action Recognition. Proc. AAAI Conf. Artif. Intell. 2018, 32. <https://doi.org/10.1609/aaai.v32i1.12300>.
- HUANG, C., Wen, J., Xu, Y., Jiang, Q., Yang, J., Wang, Y., Zhang, D. (2022). Self-Supervised Attentive Generative Adversarial Networks for Video Anomaly Detection. IEEE Trans. Neural Networks Learn. Syst. 2022, 34, 9389–9403. <https://doi.org/10.1109/tnnls.2022.3159538>.
- IONESCU, R.T., Khan, F.S., Georgescu, M.I., Shao, L. (2019). Object-Centric Auto-Encoders and Dummy Anomalies for Abnormal Event Detection in Video. In Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, CA, USA, 15–20 June 2019, pp. 7834–7843. <https://doi.org/10.1109/CVPR.2019.00803>.
- JIANG, F., Yuan, J., Tsafaris, S.A., Katsaggelos, A.K. (2011). Anomalous video event detection using spatiotemporal context. Comput. Vis. Image Underst. 2011, 115, 323–333, ISSN 1077-3142. <https://doi.org/10.1016/j.cviu.2010.10.008>.
- KHAN, M.U.K., Park, H.-S., Kyung, C.-M. (2018). Rejecting Motion Outliers for Efficient Crowd Anomaly Detection. IEEE Trans. Inf. Forensics Secur. 2018, 14, 541–556. <https://doi.org/10.1109/tifs.2018.2856189>.
- KIRANYAZ, S., Zabihi, M., Rad, A.B., Ince, T., Hamila, R., Gabbouj, M. (2020). Real-Time Phonocardiogram Anomaly Detection by Adaptive 1D Convolutional Neural Networks. Neurocomputing 2020, 411, 291–301. <https://doi.org/10.1016/j.neucom.2020.05.063>.
- LAURENDIN, O., Ambellouis, S., Fleury, A., Mahtani, A., Chafik, S., Strauss, C., (2021). Hazardous Events Detection in Automatic Train Doors Vicinity Using Deep Neural Networks, 2021 17th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS), 2021, pp. 1-7, doi: 10.1109/AVSS52988.2021.9663863.



- LE, V.T., Kim, Y.G. (2022). Attention-Based Residual Autoencoder For Video Anomaly Detection. *Appl. Intell.* 2022, 53, 3240–3254. <https://doi.org/10.1007/s10489-022-03613-1>.
- LEE, D.G., Suk, H.I., Park, S.K. Lee, S.W.(2015). Motion Influence Map for Unusual Human Activity Detection and Localization in Crowded Scenes. *IEEE Trans. Circuits Syst. Video Technol.* 2015, 25, 1612–1623. <https://doi.org/10.1109/tcsvt.2015.2395752>.
- LEYVA, R., Sanchez, V., Li, C.T. (2017). Video Anomaly Detection with Compact Feature Sets for Online Performance. *IEEE Trans. Image Process.* 2017, 26, 3463–3478. <https://doi.org/10.1109/tip.2017.2695105>.
- LI, N., Wu, X., Xu, D., Guo, H., Feng, W. (2015). Spatio-temporal context analysis within video volumes for anomalous-event detection and localization. *Neurocomputing* 2015, 155, 309–319. <https://doi.org/10.1016/j.neucom.2014.12.064>.
- LI, W., Mahadevan, V., Vasconcelos, N. (2013). Anomaly detection and localization in crowded scenes. *IEEE Trans. Pattern Anal. Mach. Intell.* 2013, 36, 18–32.
- LING, S., Ziyun C., Li L., Ke L. (2017). Performance evaluation of deep feature learning for RGB-D image/video classification, *Information Sciences*, Volumes 385–386, 2017, Pages 266-283, ISSN 0020-0255, <https://doi.org/10.1016/j.ins.2017.01.013>.
- LIU, T., Zhang, C., Wang, L. (2021). Integrated Multiscale Appearance Features and Motion Information Prediction Network for Anomaly Detection. *Comput. Intell. Neurosci.* 2021, 2021, 1–13. <https://doi.org/10.1155/2021/6789956>.
- LIU, W., Luo, W., Lian, D., Gao, S. (2018). Future Frame Prediction for Anomaly Detection-A New Baseline. In *Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, UT, USA, 18–23 June 2018, pp. 6536–6545.
- LIU, Y., Liu, J., Zhu, X., Wei, D., Huang, X., Song, L. (2022). Learning Task-Specific Representation for Video Anomaly Detection with Spatial-

Temporal Attention. In Proceedings of the ICASSP 2022 - 2022 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Singapore, 23–27 May 2022, pp. 2190–2194.

LIU, Y., Yu, H., Gong, C., Chen, Y. (2020). A real time expert system for anomaly detection of aerators based on computer vision and surveillance cameras. *J. Vis. Commun. Image Represent.* 2020, 68, 102767, ISSN 1047-3203. <https://doi.org/10.1016/j.jvcir.2020.102767>.

LU, C., Shi, J., Jia, J. (2013). Abnormal Event Detection at 150 FPS in MATLAB. In Proceedings of the 2013 IEEE International Conference on Computer Vision, Sydney, NSW, Australia, 1–8 December 2013, pp. 2720–2727.

LUO, W., Liu, W., Gao, S. A. (2017). Revisit of Sparse Coding Based Anomaly Detection in Stacked RNN Framework. In Proceedings of the 2017 IEEE International Conference on Computer Vision (ICCV), Venice, Italy, 22–29 October 2017, pp. 341–349. <https://doi.org/10.1109/ICCV.2017.45>.

LUO, W., Liu, W., Lian, D., Tang, J., Duan, L., Peng, X., Gao, S. (2019). Video Anomaly Detection with Sparse Coding Inspired Deep Neural Networks. *IEEE Trans. Pattern Anal. Mach. Intell.* 2019, 43, 1070–1084. <https://doi.org/10.1109/tpami.2019.2944377>.

LV, H., Sun, Q. (2024). Video Anomaly Detection and Explanation via Large Language Models. *arXiv 2024, Computer Vision and Pattern Recognition*, arXiv:2401.05702. DOI:<https://doi.org/10.48550/arXiv.2401.05702>

MADAN, N., Farkhondeh, A., Nasrollahi, K., Escalera, S., Moeslund, T.B. (2021). Temporal Cues from Socially Unacceptable Trajectories for Anomaly Detection. In Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCVW), Montreal, BC, Canada, 11–17 October 2021, pp. 2150–2158. <https://doi.org/10.1109/ICCVW54120.2021.00244>.

MARKOVITZ, A., Sharir, G., Friedman, I., Zelnik-Manor, L., Avidan, S. (2020). Graph Embedded Pose Clustering for Anomaly Detection. In Proceedings of the 2020 IEEE/CVF Conference on Computer Vision

and Pattern Recognition (CVPR), Seattle, WA, USA, 13–19 June 2020, pp. 10536–10544. <https://doi.org/10.1109/CVPR42600.2020.01055>.

MATHUR, G., Somwanshi, D., Bundele, M. M. (2018). Intelligent Video Surveillance based on Object Tracking. 2018 3rd International Conference and Workshops on Recent Advances and Innovations in Engineering (ICRAIE), 2018, pp. 1-6, DOI: 10.1109/ICRAIE.2018.8710421

MEHRAN, R., Oyama, A., Shah, M. (2009). Abnormal Crowd Behavior Detection using Social Force Model. In Proceedings of the 2009 IEEE Conference on Computer Vision and Pattern Recognition, Miami, FL, USA, 20–25 June 2009, pp. 935–942. <https://doi.org/10.1109/CVPR.2009.5206641>.

MEHTA, D., Klarmann, N. (2024). Autoencoder-Based Visual Anomaly Localization for Manufacturing Quality Control. Machine Learning and Knowledge Extraction. 2024, 6, 1-17. DOI: <https://doi.org/10.3390/make6010001>

MEHTA, R., Sharifzadeh, S., Palade, V., Tan, B., Daneshkhah, A., Karayaneva, Y. (2023). Deep Learning Techniques for Radar-Based Continuous Human Activity Recognition. Mach. Learn. Knowl. Extr. 2023, 5, 1493–1518. <https://doi.org/10.3390/make5040075>.

MORAIS, R., Le, V., Tran, T., Saha, B., Mansour, M., Venkatesh, S. Learning Regularity in Skeleton Trajectories for Anomaly Detection in Videos. In Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, CA, USA, 15–20 June 2019, pp. 11988-11996. <https://doi.org/10.1109/CVPR.2019.01227>.

MU, H., Sun, R., Yuan, G., Wang, Y. Abnormal Human Behavior Detection in Videos: A Review. Inf. Technol. Control. 2021, 50, 522–545. <https://doi.org/10.5755/j01.itc.50.3.27864>.

MUHR, D., Affenzeller, M., Küng, J. A Probabilistic Transformation of Distance-Based Outliers. Mach. Learn. Knowl. Extr. 2023, 5, 782–802. <https://doi.org/10.3390/make5030042>.

- NAYAK, R., Pati, U.C., Das, S.K. A comprehensive review on deep learning-based methods for video anomaly detection. *Image Vis. Comput.* 2020, 106, 104078. <https://doi.org/10.1016/j.imavis.2020.104078>.
- NGUYEN, T.N., Meunier, J. (2019). Anomaly Detection in Video Sequence with Appearance-Motion Correspondence. In *Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision (ICCV)*, Seoul, Korea, 27 October–2 November 2019, pp. 1273–1283. <https://doi.org/10.1109/ICCV.2019.00136>.
- PARK, C., Cho, M., Lee, M., Lee, S. (2022). FastAno: Fast Anomaly Detection via Spatio-temporal Patch Transformation. In *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*, Waikoloa, HI, USA, 3–8 January 2022, pp. 2249–2259. <https://doi.org/10.1109/WACV51458.2022.00197>.
- PARK, H., Noh, J., Ham, B. (2020). Learning Memory-Guided Normality for Anomaly Detection. In *Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Seattle, WA, USA, 13–19 June 2020, pp. 14360–14369. <https://doi.org/10.1109/CVPR42600.2020.01438>.
- PERAZZI, F., Khoreva, A., Benenson, R., Schiele, B., Sorkine-Hornung, A. (2017). Learning Video Object Segmentation from Static Images. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017, pp. 3491–3500, Honolulu, HI, USA, 21–26 July 2017, doi: 10.1109/CVPR.2017.372.
- QIANG, Y., Fei, S., Jiao, Y. (2021). Anomaly Detection Based on Latent Feature Training in Surveillance Scenarios. *IEEE Access* 2021, 9, 68108–68117. <https://doi.org/10.1109/access.2021.3077577>.
- RAMACHANDRA, B., Jones, M., Vatsavai, R. (2020). Learning a distance function with a Siamese network to localize anomalies in videos. In *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*, Snowmass, CO, USA, March 1–5, 2020, pp. 2598–2607.

- RAVANBAKHS, M., Nabi, M., Mousavi, H., Sangineto, E., Sebe, N. (2018). Plug-and-Play CNN for Crowd Motion Analysis: An Application in Abnormal Event Detection. 2018 IEEE Winter Conference on Applications of Computer Vision (WACV), Lake Tahoe, NV, USA, 12–15 March 2018, pp. 1689–1698. <https://doi.org/10.1109/WACV.2018.00188>.
- RAVANBAKHS, M., Nabi, M., Sangineto, E., Marcenaro, L., Regazzoni, C.S., Sebe, N. (2017). Abnormal event detection in videos using generative adversarial nets. In Proceedings of the 2017 IEEE International Conference on Image Processing (ICIP), Beijing, China, 17–20 September 2017, pp. 1577–1581. <https://doi.org/10.1109/ICIP.2017.8296547>.
- REDMON, J., Divvala, S., Girshick, R., Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, pp. 779–788, doi: 10.1109/CVPR.2016.91.
- REHMAN, A.U., Tariq, S., Farooq, H., Jaleel, A., Wasif, S.M. Anomaly Detection with Particle Filtering for Online Video Surveillance. IEEE Access 2021, 9, 19457–19468. <https://doi.org/10.1109/access.2021.3054040>.
- RONNEBERGER, O., Fischer, P., Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab, N., Hornegger, J., Wells, W., Frangi, A. (eds) Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. MICCAI 2015. Lecture Notes in Computer Science(), vol 9351. Springer, Cham. [https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28)
- SMEUREANU, S., Ionescu, R. T. (2018). Real-Time Deep Learning Method for Abandoned Luggage Detection in Video, 2018 26th European Signal Processing Conference (EUSIPCO), 2018, pp. 1775–1779, doi: 10.23919/EUSIPCO.2018.8553156.
- SABOKROU, M., Fathy, M., Hoseini, M., Klette, R. (2015). Real-time anomaly detection and localization in crowded scenes, 2015 IEEE Conference

on Computer Vision and Pattern Recognition Workshops (CVPRW), 2015, pp. 56-62, doi: 10.1109/CVPRW.2015.7301284.

- SABOKROU, M., Fayyaz, M., Fathy, M., Moayed, Z., Klette, R. (2018). Deep-anomali: Fully convolutional neural network for fast anomali detection in crowded scenes. *Comput. Vis. Image Underst.* 2018, 172, 88–97. ISSN 1077-3142. <https://doi.org/10.1016/j.cviu.2018.02.006>.
- SANTOS, F.P., Ribeiro, L.S., Ponti, M.A. (2019). Generalization of feature embeddings transferred from different video anomali detection domains. *J. Vis. Commun. Image Represent.* 2019, 60, 407–416. <https://doi.org/10.1016/j.jvcir.2019.02.035>.
- SARIKAN, S.S., Ozbayoglu, A.M. (2018). Anomaly Detection in Vehicle Traffic with Image Processing and Machine Learning. *Procedia Comput. Sci.* 2018, 140, 64–69. <https://doi.org/10.1016/j.procs.2018.10.293>.
- SHAO, L., Cai, Z., Liu, L., Lu, K. (2017). Performance evaluation of deep feature learning for RGB-D image/video classification. *Inf. Sci.* 2017, 385-386, 266–283. <https://doi.org/10.1016/j.ins.2017.01.013>.
- SIKDAR, A., Chowdhury, A.S.(2020). An adaptive training-less framework for anomali detection in crowd scenes. *Neurocomputing* 2020, 415, 317–331. <https://doi.org/10.1016/j.neucom.2020.07.058>.
- SMEUREANU, S., Ionescu, R.T. (2018). Real-Time Deep Learning Method for Abandoned Luggage Detection in Video. In *Proceedings of the 2018 26th European Signal Processing Conference (EUSIPCO)*, Rome, Italy, 3–7 September 2018, pp. 1775–1779. <https://doi.org/10.23919/EUSIPCO.2018.8553156>
- SOUZA, M.R., Maia, H.d.A., Vieira, M.B., Pedrini, H. (2020). Survey on visual rhythms: A spatio-temporal representation for video sequences. *Neurocomputing* 2020, 402, 409–422. <https://doi.org/10.1016/j.neucom.2020.04.035>.
- SREENU, G., Saleem Durai, M.A. (2019). Intelligent Video Surveillance: A Review Through Deep Learning Techniques For Crowd Analysis. *J Big Data* 6, 48 (2019). <https://doi.org/10.1186/s40537-019-0212-5>.

- SULTANI, W., Chen, C., Shah, M. (2018). Real-World Anomaly Detection in Surveillance Videos. In Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, 18–22 June 2018, pp. 6479–6488.
- THAKARE, K.V., Sharma, N., Dogra, D.P., Choi, H., Kim, I.J. (2022). A Multi-stream Deep Neural Network With Late Fuzzy Fusion For Real-World Anomaly Detection. *Expert Syst. Appl.* 2022, 201, 117030. <https://doi.org/10.1016/j.eswa.2022.117030>.
- TIAN, Y., Pang, G., Chen, Y., Singh, R., Verjans, J.W., Carneiro, G. (2021). Weakly-supervised Video Anomaly Detection with Robust Temporal Feature Magnitude Learning. In Proceedings of the 2021 IEEE/CVF International Conference on Computer Vision (ICCV), Montreal, QC, Canada, 10–17 October 2021, pp. 4955-4966. <https://doi.org/10.1109/ICCV48922.2021.00493>.
- TOKMAKOV, P., Alahari, K., Schmid, C. (2017). Learning Video Object Segmentation with Visual Memory. In Proceedings of the IEEE International Conference on Computer Vision (ICCV), Venice, Italy, 22–29 October 2017, pp. 4481–4490.
- TUDOR I. R., Smeureanu, S., Alexe, B., Popescu, M. (2017). Unmasking The Abnormal Events in Video. In Proceedings of the IEEE international conference on computer vision, Venice, Italy, 22–29 October 2017, pp. 2895–2903. <https://doi.org/10.1109/ICCV.2017.315>.
- ULLAH, W., Ullah, A., Haq, I.U., Muhammad, K., Sajjad, M., Baik, S.W. CNN features with bi-directional LSTM for real-time anomaly detection in surveillance networks. *Multimedia Tools Appl.* 2020, 80, 16979–16995. <https://doi.org/10.1007/s11042-020-09406-3>.
- VERMA, K. K. , Kumar, P., Tomar, A. (2015). Analysis of Moving Object Detection And Tracking In Video Surveillance System. 2015 2nd International Conference on Computing for Sustainable Global Development (INDIACom), 2015, pp. 1758-1762.

- WANG, B., Yang, C., Chen, Y. (2022). Detection Anomaly in Video Based on Deep Support Vector Data Description. *Comput. Intell. Neurosci.* 2022, 2022, 5362093. <https://doi.org/10.1155/2022/5362093>.
- WANG, Li & Sng, Dennis. (2015). Deep Learning Algorithms with Applications to Video Analytics for A Smart City: A Survey. X46. DOI:<https://doi.org/10.48550/arXiv.1512.03131>
- WANG, X., Che, Z., Jiang, B., Xiao, N., Yang, K., Tang, J., Ye, J., Wang, J., Qi, Q. (2021). Robust Unsupervised Video Anomaly Detection by Multipath Frame Prediction. *IEEE Trans. Neural Networks Learn. Syst.* 2021, 33, 2301–2312. <https://doi.org/10.1109/tnnls.2021.3083152>.
- WANG, X., Huang, Z., Liao, B., Huang, L., Gong, Y., Huang, C. (2021). Real-time and Accurate Object Detection In Compressed Video By Long Short-Term Feature Aggregation. *Comput. Vis. Image Underst.* 2021, 206, 103188, ISSN 1077-3142. <https://doi.org/10.1016/j.cviu.2021.103188>.
- WANG, Y., Dai, B., Hua, G., Aston, J., Wipf, D. Recurrent Variational Autoencoders for Learning Nonlinear Generative Models in the Presence of Outliers. *IEEE J. Sel. Top. Signal Process.* 2018, 12, 1615–1627. <https://doi.org/10.1109/jstsp.2018.2876995>.
- WANG, Z., Zhang, Y., Wang, G., Xie, P. (2021). Main-Auxiliary Aggregation Strategy for Video Anomaly Detection. *IEEE Signal Process. Lett.* 2021, 28, 1794–1798. <https://doi.org/10.1109/lsp.2021.3107750>.
- WU, C., Shao, S., Tunc, C., Hariri, S. (2020). Video Anomaly Detection using Pre-Trained Deep Convolutional Neural Nets and Context Mining. In *Proceedings of the 2020 IEEE/ACS 17th International Conference on Computer Systems and Applications (AICCSA)*, Antalya, Turkey, 2–5 November 2020, pp. 1–8. <https://doi.org/10.1109/AICCSA50499.2020.9316538>.
- WU, P., Liu, J., Shi, Y., Sun, Y., Shao, F., Wu, Z., Yang, Z. (2020). Not Only Look, but Also Listen: Learning Multimodal Violence Detection Under Weak Supervision. In *Proceedings of the Computer Vision–ECCV 2020: 16th European Conference, Glasgow, UK, 23–28 August 2020*, Springer International Publishing, Part XXX 16, pp. 322-339.



- XIA, X., Gao, Y. (2021). Video Abnormal Event Detection Based on One-Class Neural Network. *Comput. Intell. Neurosci.* 2021, London, UK, 2021, 1955116. <https://doi.org/10.1155/2021/1955116>.
- XU, D., Song, R., Wu, X., Li, N., Feng, W., Qian, H. (2014). Video anomaly detection based on a hierarchical activity discovery with-in spatio-temporal contexts. *Neurocomputing* 2014, 143, 144–152.
- XU, D., Yan, Y., Ricci, E., Sebe, N. (2017). Detecting Anomalous Events in Videos by Learning Deep Representations of Appearance And Motion. *Comput. Vis. Image Underst.* 2017, 156, 117–127. <https://doi.org/10.1016/j.cviu.2016.10.010>.
- XU, K., Jiang, X., Sun, T. (2018). Anomaly Detection Based on Stacked Sparse Coding with Intraframe Classification Strategy. *IEEE Trans. Multimed.* 2018, 20, 1062–1074. <https://doi.org/10.1109/tmm.2018.2818942>.
- XU, Z., Zeng, X., Ji, G., Sheng, B. (2022). Improved Anomaly Detection in Surveillance Videos with Multiple Probabilistic Models Inference. *Intell. Autom. Soft Comput.* 2022, 31, 1703–1717. <https://doi.org/10.32604/iasc.2022.016919>.
- YADAV, R.K., Kumar, R. A (2022). Survey on Video Anomaly Detection. In *Proceedings of the 2022 IEEE Delhi Section Conference (DELCON)*, New Delhi, India, 11–13 February 2022, pp. 1–5. <https://doi.org/10.1109/DELCON54057.2022.9753580>.
- YANG, C.L., Wu, T.H., Lai, S.H. (2021). Moving-object-aware Anomaly Detection in Surveillance Videos. In *Proceedings of the 2021 17th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS)*, Washington, DC, USA, 16–19 November 2021, pp. 1–8. <https://doi.org/10.1109/AVSS52988.2021.9663742>.
- YU, S., Wang, C., Mao, Q., Li, Y., Wu, J. (2021). Cross-Epoch Learning for Weakly Supervised Anomaly Detection in Surveillance Videos. *IEEE Signal Process. Lett.* 2021, 28, 2137–2141. <https://doi.org/10.1109/lsp.2021.3117737>.

- ZAHEER, M.Z., Mahmood, A., Astrid, M., Lee, S.I. (2020). Claws: Clustering assisted weakly supervised learning with normalcy sup-pression for anomalous event detection. In Proceedings of the European Conference on Computer Vision, Springer, Cham, Swit-zerland, 2020, pp. 358–376.
- ZAHEER, M.Z., Mahmood, A., Shin, H., Lee, S.I. (2020). A Self-Reasoning Framework for Anomaly Detection Using Video-Level Labels. *IEEE Signal Process. Lett.* 2020, 27, 1705–1709. <https://doi.org/10.1109/lsp.2020.3025688>.
- ZERROUKI, Y., Harrou, F., Zerrouki, N., Dairi, A., Sun, Y. (2020). Desertification Detection Using an Improved Variational Autoen-coder-Based Approach Through ETM-Landsat Satellite Data. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 2020, 14, 202–213. <https://doi.org/10.1109/jstars.2020.3042760>.
- ZHANG, D., Huang, C., Liu, C., Xu, Y. (2022). Weakly Supervised Video Anomaly Detection via Transformer-Enabled Temporal Re-lation Learning. *IEEE Signal Process. Lett.* 2022, 29, 1197–1201. <https://doi.org/10.1109/lsp.2022.3175092>.
- ZHANG, S., Zhao, C., Sui, Y., Su, Y., Sun, Y., Zhang, Y., Pei, D., Wang, Y. (2021). Robust KPI Anomaly Detection for Large-Scale Soft-ware Services with Partial Labels. In Proceedings of the 2021 IEEE 32nd International Symposium on Software Reliability Engineering (ISSRE), Wuhan, China, 25–28 October 2021, pp. 103–114. <https://doi.org/10.1109/ISSRE52982.2021.00023>.
- ZHANG, X., Yang, S., Zhang, J., Zhang, W. (2020). Video anomali detection and localization using motion-field shape description and homogeneity testing. *Pattern Recognit.* 2020, 105, 107394, ISSN 0031-3203. <https://doi.org/10.1016/j.patcog.2020.107394>.
- ZHU, Y., Newsam, S. (2019). Motion-aware Feature for Improved Video Anomaly Detection. arXiv 2019, arXiv:1907.10211.

**TEZLER**

- ADEM, K. (2017). Görüntü İşleme Ve Makine Öğrenmesine Dayalı Diyabetik Retinopati Hastalığı Teşhisi Ve Sınıflandırılması, Tokat Gaziosmanpaşa Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Tokat, 2017.
- AKI, M.O. (2017). Sürücü Uykululuğunun Gerçek Zamanlı Görüntü İşleme Ve Makine Öğrenmesi Teknikleri İle Tespitine Yönelik Bir Sistem Tasarımı Ve Uygulaması, Trakya Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Edirne, 2017.
- ALMRYAD, A. S. (2020). Identification Of Butterfly Species Using Machine Learning And Image Processing Techniques, Karabük University, Institute Of Graduate Programs, Computer Engineering, Karabük, 2020.
- ARSLAN, E. (2011). Hücresel Sinir Ağı Sistemleri Kullanarak Hareketli Nesnelerin Görüntü İşleme Uygulamaları. İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı, Doktora Tezi, İstanbul, 2011.
- AVUÇLU, E. (2019). Yapay Zekâ Ve Görüntü İşleme 6Teknikleri Kullanarak Diş Röntgen Görüntülerinden Kronolojik Yaş Tayini, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Konya, 2019.
- BOYRAZLI, H.K. (2021). Kalabalık Sahnelerde Makine Öğrenmesi Algoritmalarıyla Anomali Tespiti, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Elazığ. 2021.
- CÖMERT, O. (2019). Görüntü İşleme Ve Makine Öğrenmesi Kullanarak Elmalarda Çürük Tespiti, Tokat Gaziosmanpaşa Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Tokat, 2019.
- DEDEOĞLU, Y. (2004). Moving object detection, tracking and classification for smart video surveillance, Master Thesis, Bilkent University, Department of Computer Engineering, 2004. <http://hdl.handle.net/11693/29543>
- ERDİNÇ, A. (2015). Anomaly Detection with Sparse Unmixing And Gaussian Mixture Modeling of Hyperspectral Images. Master's Thesis, Bilkent

University, The Graduate School of Engineering and Science,  
Computer Engineering, 2015.

GHEDAN, A. K. S. (2019). Görüntü İşleme Yöntemlerini Kullanarak  
Mikroskopik Görüntülerinden Lösemi Hücrelerinin Teşhisi,  
Kastamonu Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi,  
Kastamonu, 2019.

MÜEZZİNOĞLU, T. (2019). Konveyör Üzerindeki Nesnelere Çoklu Anomali  
Tespiti İçin Görme Tabanlı Tanıma Yaklaşımlarının Geliştirilmesi.  
Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Elazığ,  
2019.

ÖNGÜN, C. (2019). Anomaly Detection for Video Surveillance in Crowded  
Environments. Master's Thesis, Middle East Technical University,  
Electrical and Electronics Engineering, Ankara, Turkey, 2019.

## **ELEKTRONİK KAYNAKLAR**

URL-1 “UCF-Crime Dataset, Real-world Anomaly Detection in Surveillance  
Videos”, <https://www.crcv.ucf.edu/projects/real-world/> (Erişim Tarihi:  
1 Aralık 2023)

## ÖZGEÇMİŞ

**Adı-Soyadı: Hayati TUTAR**

### ÖĞRENİM DURUMU:

- **Doktora:** 2024, İstanbul Aydın Üniversitesi, Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Programı
- **Yüksek Lisans:** 2016, İstanbul Aydın Üniversitesi, Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Programı
- **Lisans:** 2009, Anadolu Üniversitesi, İşletme Fakülte, İşletme Bölümü
- **Ön Lisans:** 2002, Sivas Cumhuriyet Üniversitesi, Sivas Meslek Yüksekokulu, Bilgisayar Programcılığı

### MESLEKİ DENEYİM VE ÖDÜLLER:

- **Mesleki Uzmanlık ve İlgi Alanları**
  - **BT Proje ve Mimari Yönetimi:** PMI, Agile Coach, ITIL, COBIT
  - **AI Platform,** Artificial Intelligence, Computer Vision, OpenCV, Tensorflow, PyTorch, Pandas
  - **Yazılım Geliştirme:.**NET, C#, C, Java, Python, PHP, Analysis, Architecture, Development, Integration, SOA, TFS, Github
  - **Veri Yönetimi:** Oracle, MsSQL, PostgreSQL, T-Sql, PL-Sql, HA
- **Mesleki Deneyimler**
  - 2019 –2024: Senior Database Administrator
  - 2016 – 2019: Database Systems Management Supervisor
  - 2013 – 2015: Database Systems Manager (DBA) & Software Consultant

- 2011 – 2013: Database Administrator, DWH and Software Architect
- 2010-2011: Software Project Manager
- 2006- 2010: Software Department Manager and Project Manager
- 2002- 2006: Software Development Specialist / Senior
- **Akademik Araştırma Çalışmaları**
  - Data Analysis Work with Deep Learning Algorithms
  - Data Analysis & Renewable Energy Resources
  - Edge & Grid Computing, Software Development Life Cycles
  - Cryptography & Computer Security, AdHOC – VANET Security
  - Microservices and Monolithic Software Development Architectures
  - Database Security and Disposable Database Access Control Management
  - Face Recognition and Face Replacement with Artificial Intelligence

#### **TEZDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:**

- Tutar, H., Günes, A., Zontul, M., Aslan, Z. (2024). A Hybrid Approach to Improve the Video Anomaly Detection Performance of Pikel - and Frame-Based Techniques Using Machine Learning Algorithms. *Computation* 2024, 12, 19. <https://doi.org/10.3390/computation12020019>

#### **DİĞER YAYINLAR, SUNUMLAR VE PATENTLER**

- Tutar, H. (2016). In-Memory Veritabanı Sistemlerinde Yapay Zeka Algoritmalarıyla Veri Analizi Ve Anomali Tespiti. İstanbul Aydın Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul, 2016.
- Zontul, M., Tutar, H., Sönmez, F., (2016). Anomaly Detection And Data Analysis With Artificial Intelligence Algorithms On In-Memory Database Systems. *Proceedings of 3rd International Management Information Systems Conference*, October 2016, İzmir, Turkey
- Sönmez, F., Zontul, M., Kaynar, O., Tutar, H. (2018). Anomaly Detection Using Data Mining Methods in IT Systems: A Decision Support Application. *Sakarya University Journal of Science*, 22(4), 1109-1123. <https://doi.org/10.16984/saufenbilder.365931>