



## ANOMALY DETECTION FROM TRAFFIC VIDEO ANALYSIS DATA AND CLASSIFICATION WITH DIFFERENTIAL EVOLUTION ALGORITHM EXTREME LEARNING MACHINE

Derya Avcı<sup>\*1</sup> , Yasin Sönmez<sup>2</sup> 

<sup>1</sup>Technical Vocational School, Fırat University, 23119 Elazığ, Turkey.

<sup>2</sup>Technical Vocational School, Batman University, 72100 Batman, Turkey

### Abstract

Original scientific paper

The process of obtaining meaningful and interpretable information about the object by detecting and tracking moving objects in videos obtained by cameras can be defined as video analysis. The analysis of highway traffic flow videos can be expressed as a detection and warning system of the behavior (anomaly) of moving objects (vehicle and pedestrian) outside the rules determined for the road followed. In this study, the anomaly behaviors of moving objects in highway traffic flow videos have been determined and the data has been classified by machine learning methods. The study consists of three stages. In the first stage, Gaussian Mixing Model, one of the background / foreground segmentation methods, and Kalman Filter-Macac Algorithm methods have been used to track the object on video. In the second step, location, time, velocity and shape data have been obtained by using the coordinate information of the detected object. With the unique algorithm-based feature extraction software, a table of properties including anomaly conditions for objects has been created. In the last stage, the data in the feature table; Classification of the Extreme Learning Machine method has been made with the Differential Evolution Algorithm - Extreme Learning Machine method developed by optimizing the number of neurons in the hidden layer and activation functions with the Differential Evolution Algorithm. The results obtained with the developed method have been compared with the results of other machine learning methods (Naive Bayes, Support Vector Machine and Artificial Neural Network) and the performance was the highest with 100%.

**Keywords:** Intelligent traffic monitoring system, anomaly detection, differential evolution algorithm, optimization, extreme learning machine, classification.

## TRAFİK VİDEO ANALİZ VERİLERİNDEN ANOMALİ TESPİT VE DİFERANSİYEL GELİŞİM ALGORİTMASI UÇ ÖĞRENME MAKİNESİ İLE SINIFLANDIRMA

### Özet

Orijinal bilimsel makale

Kameralar ile elde edilen videolarda hareketli nesne tespit ve takibi ile nesne hakkında anlamlı ve yorumlanabilir bilgi elde edilmesi süreci, video analizi olarak tanımlanabilir. Karayolu trafik akış videolarının analizi ise hareket eden nesnelerin (taşıt ve yaya) izlenen yol için belirlenen kurallar dışında davranış sergilemeleri (anomali) durumunun tespit ve uyarı sistemi olarak ifade edilebilir. Bu çalışmada karayolu trafik akış videolarında hareket eden nesnelerin anomali davranışlarını tespit ederek verileri makine öğrenmesi yöntemleri ile sınıflandırması yapılmıştır. Çalışma üç aşamadan oluşmaktadır. Birinci aşamada hareketli nesnenin tespiti için arka/ön plan bölütleme yöntemlerinden Gauss Karışım Modeli ve nesnenin videoda takibi yapılabilmesi için Kalman Filtre-Macac Algoritması yöntemleri kullanılmıştır. İkinci aşamada tespit edilen nesneye ait koordinat bilgilerini kullanarak konum, süre, hız ve şekil verileri elde edilmiştir. Hazırlanan özgün algoritmaya dayalı özellik çıkarma yazılımı ile nesneler için anomali durumlarını içeren özellikler tablosu oluşturulmuştur. Son aşamada ise özellik tablosundaki veriler; Uç Öğrenme Makine yönteminin, gizli katmandaki nöron sayıları ve aktivasyon fonksiyonları Diferansiyel Gelişim Algoritması ile optimize edilerek geliştirilen Diferansiyel Gelişim Algoritması- Uç Öğrenme Makine yöntemi ile sınıflandırma yapılmıştır. Geliştirilen yöntem ile elde edilen sonuçlar diğer makine öğrenme yöntem (Naive Bayes, Destek Vektör Makinesi ve Yapay Sinir Ağı) sonuçları ile karşılaştırılmış ve başarımları %100 ile en yüksek çıkmıştır.

**Anahtar Kelimeler:** Akıllı trafik izleme sistemi, anomali durum tespit, diferansiyel gelişim algoritması optimizasyon, uç öğrenme makinesi, sınıflandırma.

\* Corresponding author.

E-mail address: [davci@firat.edu.tr](mailto:davci@firat.edu.tr) (D. Avcı)

Received 20 March 2021; Received in revised form 14 May 2021; Accepted 24 August 2021

2587-1943 | © 2021 IJIEA. All rights reserved.

Doi: <https://doi.org/10.46460/ijiea.900251>

## 1 Giriş

Askeri ve yerleşim yeri güvenliği, kişi ya da araç hareketlerini sürekli izleme ve raporlama önceden tanımlanmış olayların tespiti gibi uygulamaların insan gözlem tabanlı sistemler ile yapılmasının çeşitli dezavantajları vardır. Günümüzde bu işlem, çoğunlukla birkaç ekran karşısında oturan güvenlik personeli ile yapılmaya çalışılmaktadır. Kapalı devre izleme merkezlerinde yapılan testlerde; iki veya daha fazla monitörün, 12 dakika sürekli döngü halinde izlenmesi durumunda güvenlik personelinin ekranda olan aktivitelerin %45' ini kaçırdığı, 22 dakika sonra ise aktivite tespit başarımının sadece %5 ile sınırlı olduğu ölçülmüştür. Bu bağlamda insan gözüyle video izleme içeriği hakkında karar vermenin imkânsız olduğu sistemleri bilgisayar ile otomatik duruma getirmek teknolojik olarak bir gerekliliktir. Zira askeri uygulamalar, kent güvenliği, trafik akış düzenleme, tıbbi görüntülerin yorumlanması ve robotik vb. gibi birçok uygulama alanında otomatik çalışan akıllı video analizi sistemlerine ihtiyaç duyulmaktadır. Çünkü otomatik sistemler ile ardışık imge dizileri üzerinde değerlendirmelerin yapılması görsel değerlendirmede insan faktörlü hata payını azaltmakta, bunun yerine bilgisayar kontrolünü ve verinin doğruluğunu artırmaktadır [1]. Akıllı video gözetim sistemlerinde nesne tespit önemli bir görevdir. Bu işlem videoda hareketli nesnenin şekil bilgilerini içerir [2]. Nesne izleme ardışık video karelerinde hareketli nesnelere bulma sürecidir. Hareket analizi algoritmaları genel olarak hareketin varlığının tespiti, hareketli nesnenin yörüngesinin tahmini ile izlenmesi ve son olarak da hareketin tanımlanması kısımlarından oluşmaktadır. Analizin başarısını belirleyen en önemli faktör, ilk kısım olan hareketin varlığının tespitidir. Bu aşamanın doğru ve etkili bir şekilde yapılması, sonraki aşamaların verimini doğrudan etkilemektedir. Gerçek zamanlı videolarda nesne izleme zorlu bir süreç olup bilgisayarlı görme konusudur. Hareketli nesne takibindeki zorluklar nesneden nesneye hareket, hareketli arka plan ve kameranın hareketi olarak gösterilebilir. İzleme, genellikle her video karesinde nesnenin şekil veya konum bilgisine ihtiyaç duyan yüksek seviyeli uygulamalar ile gerçekleştirilen bir işlemdir [3-5]. Genel bir yaklaşım ile güçlü bir arka plan çıkarma yönteminin başarımını etkileyen birkaç ölçüt vardır. İlk olarak, aydınlatma değişikliklerine karşı dayanıklı olmalıdır. İkincisi, durağan olmayan arka plan, sallanan yapraklar, yağmur ve kar gibi hareket belirten zorlu ortam ve doğa olaylarına karşı arka planın güncellenmesi ile efektif olmalıdır. Son olarak tespit edilmesi gereken nesnelere değişimlerine anında tepki verebilmelidir [6, 7]. Video gözetim sistemi zaman, işlemci ve bellek kullanımı gibi ölçütler açısından da basit olmalıdır. Dolayısıyla böyle sistemlerin gömülü işlemciler üzerinde gerçekleştirilmeleri hızlı işlem yapabilmesi açısından önemlidir. Otomatik çalışabilecek bir video gözetim sisteminde problem sadece yukarıda anlatıldığı gibi hareketli nesne tespit ve takip yöntemleri ile ilgili değildir. Tespit ve takibin yanında nesnelere ait büyük miktarlardaki verinin kullanılarak nesnenin özelliklerine göre sınıflandırılması ve şu anki veya geçmişteki verileri kullanarak şimdi veya gelecek için

tahminlerde bulunmak da ayrı bir problemdir. Çözüm için makine öğrenmesi yöntemleri kullanılabilir. Makine öğrenmesi verilen bir problemi, probleme ait veriye göre modelleyen bilgisayar algoritmalarının genel adıdır. Önerilmiş birçok yaklaşım ve algoritma mevcuttur. Bu yaklaşımların bir kısmı sınıflandırma bir kısmı da tahmin ve kestirim yapabilme yeteneğine sahiptir [8]. Bu makalenin organizasyonu şu şekildedir: Bölüm 2'de, Trafik Videolarının Analizinin Önemi ve Anomali Kavramı hakkında bilgi verilmiştir. Bölüm 3'te, çalışmada kullanılan Materyal ve Metot tanıtılmaktadır. Bölüm 4'te deneysel sonuçlar verilmiştir. Son olarak, Bölüm 5'te Tartışma ve Öneriler verilmiştir.

## 2 Trafik Videolarının Analizinin Önemi ve Anomali Kavramı

İnsan gözetlemesine dayalı klasik video izleme yöntemleri ile şehirlerarası ve kent içi karayolu trafik gözetim sistemleri anlık değerlendirme, sürekli bilgi güncellemesi, yüksek miktarda veri ve manuel uyarı gibi nedenlerden dolayı yetersiz kalmaktadır [9, 10]. Günümüz teknolojisinde otomatik çalışan sistemler ile trafik video görüntülerinden anlamlı ve yorumlanabilir veriler elde etme yeteneği; gelişen donanım yapısı ve yazılım sistemleri ile daha kolay ve efektif bir seviyeye ulaşmıştır [9, 11]. Bu gelişim ile şehirlerarası ve kent içi karayolu trafiğinde, gözetlemenin klasik teknikler yerine ileri teknoloji gözetleme sistemleri kullanılmaya başlanmıştır. Bu ileri teknolojik tekniklerin önemli bir bölümü yapay zekâ yöntemleri ile çalışan otomatik sistemlerden oluşturulmuştur. Karayolu trafik akış gözetim görüntülerinin analizi; çeşitli görüntüleme ve kayıt aygıt donanımlarından aktarılan video akışlarındaki hareketli nesne tespit ve takibi ile kural dışı davranış olarak nitelendirilen anomalinin sınıflandırılması ve gelecek durum tahmini olarak tanımlanabilir. Trafik akışının otomatik izlenebilmesini sağlayan donanım ve yazılımdan oluşan sistemler bize değerlendirilebilir ve yorumlanabilir bilgiler sunmaktadır. Bu bilgiler ile trafik akışının güvenliğinin sağlanması hedeflenmektedir. Bu bilgilerin bilgisayar destekli otomatik sistemler tarafından yapılması değerlendirmede insan faktörlü hata payını azaltıp bilgisayar kontrolünü ve verinin doğruluğunu artırmaktadır. Otomatik çalışan sistemler güvenlik amacıyla gözetlenen karayolu trafiğinde başarımı yüksek uyarı sistemlerini sunmaktadır. Trafik videolarında anomali tespiti incelenen verilerde izlenen yol için belirlenen kurallara uymayan veya aykırı davranan nesnelere tespit olarak tanımlanabilir. Bu tanıma göre anomali literatürde "olağandışı", "anormal", "aykırı", "uyumsuz", "istisna" veya "tuhaf" gibi kelimeler ile ifade edilebilmektedir. Anomali durumunun tespiti için videonun analiz verilerinden çıkarımlar yapılarak ilgili anomali durum değerlendirilmesi yapılır. Bu değerlendirme izlenen bir trafik akış videosunda yol şeridinde ters giden(hareket yönü), yol için belirlenen hız limitini(hızı aşan) aşan veya yolda konumu durağan olan araçların davranışları anomaliye örnek gösterilebilir [12-18].

Bu çalışmanın temel amacı, karayolu trafik akış videolarında hareket eden nesnelere anomali davranışlarını(araç anomalileri hareket yönü, yerdeğiştirme, konum ve hız) tespit ederek verileri


makine öğrenmesi yöntemleri ile sınıflandırma yapmaktır. Bu amaç doğrultusunda trafik video analizi için otomatik çalışan sistem problemlerine etkili ve kullanılabilir çözümler sunabilmektir. Bu temel amaç ile aşağıda belirtilen özel ve somut amaçlara ulaşılmıştır.

Bu çalışmanın özellikleri ve yenilikleri aşağıda verilmiştir.

- 1.Hareketli nesne tespitindeki zorlu ortam koşullarından (yağmur, kar, sis düşük ışık vb.) en az etkilenen en uygun ve efektif yöntemin geliştirilmesini sağlamaktır.
- 2.Hareketli nesnelerin takibi esnasında karşılaşılan en önemli zorluklardan olan çoklu nesne izleme problemlerine karşı kullanılacak en uygun ve efektif yöntemin geliştirilmesini sağlamaktır.
- 3.Video analizi ile tespit ve takibi yapılan hareketli nesnelerin gerekli giriş ve çıkış değer verileri oluşturulduktan sonra bu verilere göre sınıflandırılması ile gelecekteki durum tahminleri için Uç Öğrenme Makinesi (UÖM) sınıflandırma yöntemini kullanarak başarımlarını ortaya koymaktır.
- 4.Uç Öğrenme Makinesi yönteminin aktivasyon fonksiyonu ve gizli katmandaki hücre sayılarını Diferansiyel Gelişim Algoritması (DGA) optimizasyon tekniği ile en uygun parametrelerin seçilerek UÖM yönteminin daha iyi sonuç verebilmesini sağlamaktır.

### 3 Materyal ve Metot

Bu çalışmada incelenen probleme ilişkin önerilen üç aşamalı yöntemde kullanılan materyaller bu bölümde incelenmiştir. Bu aşamalardan birincisinde video analizinde arka/ön plan bölütleme ve nesne yörünge tahmin-atama yöntemleri; ikincisinde analiz verilerinden anomali tespiti için özellik çıkarma; üçüncü aşamada ise anomali sınıflandırma için UÖM yöntemi anlatılmıştır. Aşağıda Şekil 1'de önerilen yöntemle ilişkin blok diyagram verilmiştir.



Şekil 1. Önerilen yöntemin blok diyagramı

#### 3.1 Video Analizi

Video; imgelerin saniyede 30 adet olacak şekilde arka arkaya sunulması ile insan gözünde bu imgelerdeki nesnelerin hareketliymiş izlenimi yaratması mantığına dayanan ardışık imge dizisi olarak tanımlanır [20-22]. Video analizi ise görüntüleme donanımları ile elde edilen verilerin çeşitli görüntü işleme teknikleri kullanarak anlamı ve yorumlanabilir bilgi elde edilmesi olarak tanımlanabilir [20, 22]. Video analizindeki amaç görüntüler üzerindeki değerlendirmelerde bilgisayar kontrolünü ve verinin doğruluğunu artırarak insan faktörlü hata payını azaltmaktır. Bu amaçla görüntülerde hareketli nesnelerin tespit ve takip edilmesi video analizi başlığı altında incelenmesi gereken iki konudur. Hareket tespiti ve analizi konusunda yapılmış çok sayıda farklı uygulamalar vardır. Hassas güvenli ortamlardaki hareketli nesne aktivitelerinin otomatik olarak yorumlanabilmesi, nesne algılama ve takip etme yeteneğine sahip görmeye dayalı, sağlam ve güvenilir bir

sistematığın kurulmasıyla sağlanabilir. Dinamik görüntüler ses, olay, yer ve zaman bileşenleri ile tümleşik bir veriyi temsil etmektedir. Bu geniş içeriğin analizinden elde edilecek sonuçların çeşitliliği sayısal imge işlemeye verilen önem ve gösterilen ilgiyi gün geçtikçe arttırmaktadır [3, 20-23].

Videoda analiz hareketin tespitiyle başlar. Hareketli nesne tespiti, nesneye ait bölgenin imgedeki diğer (hareketsiz) bölgelerden ayrıştırılması prensibine dayanır [3, 22]. Hareket verilerine doğru ulaşabilmek ise görüntüdeki ilgilenilen nesnenin şekil ve konum bilgilerinin en az hatayla tespit edilmesini gerektirmektedir. Görüntüde aranan nesnenin doğru ve hatasız bulunması ya da cisim hareketinin hassas tespit edilmesi, cismin gerçek şeklini de ortaya çıkarmaya yöneliktir.

Tekli Gaussian modeli dış mekan sahneleri için iyi bir model olmadığından, arka plan çıkarma için [24] ve [25] tarafından önerilip geliştirilen yöntem piksel renginin belli bir renk uzayındaki ağırlıklı Gauss dağılımlarının ağırlıklı toplamı ile ifade edilir. Modelde piksel yoğunluk fonksiyonunun kendisi genel olarak Gauss olasılık fonksiyonlarının doğrusal bir birleşimi olarak değerlendirilebilir. Bu model, aynı sınıfa ait verilerin normal dağılıma uygun bir şekilde sınıf merkezi etrafında dağıldığını öngörür. Önceden belirlenen sınıf sayısı için, örneklerin en az olasılık dağılım fonksiyonu toplandığı sınıf merkezlerini ve bu merkezlere ait örneklerin standart sapmalarını bulur. Bir pikselin arka plana ya da ön plana ait olduğunu belirleyebilmek için olasılık dağılım fonksiyonunun ilgili pikseli izleyip izlemediğine bakılır. Eğer pikselin değeri arka plan bileşeninin standart sapmasının ölçekleme faktörüyle çarpımından küçük veya eşitse bu piksel arka plan bileşeni; diğer durumda ise ön plan bileşenidir. Yöntemi oluşturan matematiksel bileşenler şöyledir. P(j) j . sınıfın dağılımdaki ağırlığı, başka bir deyişle bu sınıftaki elemanların olasılığını gösterirken K sınıf için Denklem 1'deki bağıntı elde edilir.

$$\sum_{j=1}^K P(j) = 1 \quad (1)$$

X elemanının j. sınıfa ait olma olasılığına P(x|j) denilirse, bu olasılığın Gauss dağılımı Denklem 2'deki gibi olur.

$$P(x|j) = \frac{1}{(2\pi)\sigma_j^2} e^{-\frac{(x-\mu)^2}{2\sigma_j^2}} \quad (2)$$

Bu eşitlikte, x sınıflandırılacak veri, j aidiyetine bakılan sınıf,  $\mu$  söz konusu sınıfın ortalaması ve  $\sigma$  ise söz konusu sınıfın varyansını göstermektedir. Bu durumda sınıflandırılmak istenilen bir x parçacığının j sınıfına hangi oranda ait olabileceği Denklem 3'teki gibi bulunabilir.

$$P(x|j) = \frac{P(x|j)P(j)}{\sum_j P(x|j)P(j)} \quad (3)$$

O halde bütün x parçacıklarının söz konusu sınıflara ait olma ihtimali bütün x'ler için Denklem 3'teki olasılıkların toplamıdır. Bu olasılığı en yüksek yapacak sınıf

ortalamalarının ve varyanslarının ne olacağı bulunduğunda sınıflama işlemi yapılmış olur.

O halde bütün  $x$  parçacıklarının söz konusu sınıflara ait olma ihtimali bütün  $x$ 'ler için Denklem 3'teki olasılıkların toplamıdır. Bu olasılığı en yüksek yapacak sınıf ortalamalarının ve varyanslarının ne olacağı bulunduğunda sınıflama işlemi yapılmış olur.

Hareketli nesne takibi görsel gözetim sistemlerinde tespit edilen nesnelerin izlenmesidir. Her izleme yöntemi, nesne videoda ilk görüldüğü andan itibaren bir tespit mekanizması gerektirir. Bu bölümde amaç hareket eden nesnenin videonun her karesinde yer, yön, hız ve yolunu belirleyerek zamansal olarak değişen yörüngesini oluşturmaktır. Nesneyi tespit etme ve çerçeveler arasındaki nesne örnekleri arasında ilgi kurma görevleri ya ayrı ya da ortak olarak gerçekleştirilebilir. Çerçeveler arası kurulan ilişki ile önceki çerçevelerden elde edilen nesne konumu ve bölge bilgilerini bir sonraki çerçeveye tahmin edilerek aktarılır ve bu durum iteratif olarak güncellenir.

Kalman Filtreleme tahmin teorisinde popüler bir yaklaşımdır. Yöntem temelde Saklı Markov modeline dayanmaktadır. Kalman Filtresi karmaşık bir hatanın ortalamasını en aza indirgeyecek şekilde bir sürecin durumunu tahmin etmek için yinelemeli bir dizi matematik denklemdir. Kalman Filtresi geçmiş, şimdiki ve hatta gelecekteki durumların tahminlerini destekler ve modellenen sistemin doğası bilinmediğinde bile tahmin yapabilen güçlü bir yöntemdir. Kalman Filtresinin yinelemeli bir tahmin aracıdır. Bu durum şöyle açıklanabilir, önceki adımda tahmin edilen durum ile o anki durumun ölçümü bir sonraki durumun tahminini yapılabilmesi için yeterli olmalıdır. Zaman güncellemesi (tahmin) mevcut durumu ilerletmekte ve bir sonraki adımda kullanılmak üzere ön durum tahminini elde etmek için hata kovaryansını güncellemektedir. Ölçüm güncellemesi (düzeltme) ise geri bildirim yapmaktadır [3,4, 18, 21, 26]. Hareketli nesnenin algılanmasından sonra, Kalman Filtre nokta tabanlı izleyici olarak kullanılır. Hareketli nesnenin merkez konumu, tahmin edilecek temel nokta olarak kullanılır. Kalman Filtresinin durum vektörü  $x$ ,  $y$  konumları ve birim zaman aralığı başına  $x$ ,  $y$  yönlerinde yer değiştirmeler olarak tanımlanır. Kalman Filtreleme algoritması ölçüm hatalarına dayalı olarak durum vektörünü tahmin eder.  $A$  geçiş matrisidir ve  $\omega$  tahmin hatası vektörüdür. Durum vektörü ve ölçümler arasında doğrusal bir ilişki olduğunu varsayıyoruz.

$$X_k = (x_c \ y_c \ v_x \ v_y) \quad (4)$$

$$X_k = AX_{k-1} + \omega_{k-1} \quad (5)$$

$$A = \begin{bmatrix} 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$


$$Z_k = HX_k + v_k \quad (6)$$

$$H = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}$$

burada  $H$ , gözlem matrisidir ve  $v$ , ölçüm hatasıdır. Geçiş ve gözlem matrisinin bu değerlerini kullanarak, Denklem 4,5,6'da verilen zaman güncelleme ve ölçüm güncelleme denklemleri bir sonraki nesne durumu tahminini verir [23, 27].

### 3.2 Özellik Çıkarma

Özellik çıkarma video analizinin en önemli aşaması olup, doğru ve başarıyı yüksek sınıflandırma yapabilmek için ilk adımdır. Analiz edilen videodan özellik çıkarmanın üç ana amacı; sınıflama süresini azaltarak sınıflandırıcının başarımını artırmak, değerlendirilecek bilgi miktarını en aza indirmek ve sistemin güvenilirliğini sağlamaktır. Birinci aşamanın tamamlanması sonucu elde edilen koordinat ve pencere büyüklüğünün sayısal değerleri kullanılarak oluşturulan özellik tablosu ile anomali durumları sınıflandırma aşamasında özellik vektör olarak kullanılmıştır. Bu çalışmada araçların anomali durumlarına göre öznitelikler belirlenmiştir. Bu öznitelikler araçların hareket yönü, yer değiştirme, konum ve hız bilgilerinden oluşmaktadır. Video analiz sırasında elde edilen değerler izlenen yolun Şekil 2.'de ki gibi bir koordinat düzlemi olarak ele alındığında geçerlidir.



Şekil 2. İzlenen yolun koordinat sistemi temsili gösterimi

Tablo 1'de video analizi ile elde edilen verilerden her nesneye ait karayolundaki hareketine ilişkin çıkarılan özellikler verilmiştir. Oluşturduğumuz veri tabanındaki bir video setinde yapılan analiz sonucu tespit edilen nesnelerin anomali durumu etiketlemesi Tablo 2'de gösterilmiştir. Bu etiketleme Tablo 3'te verilen kurala göre oluşturulmuştur.

Tablo 1. Nesne özellik çıkarma tablosu

Video analizi ile elde edilen veriler	Nesne hareket özelliği
Son koordinat değeri (skd) - İlk koordinat değeri (ikd)	Hareket Yönü (hy) enlem boylam
Anlık koordinat değeri (akd)	Konum (k) enlem boylam
( Son koordinat değeri (skd) - İlk koordinat değeri (ikd) ) / Zaman-(çerçeve sayısı) (Z)	Hız (h) kilometre saat
Toplam piksel alanı(tpa)	Şekil /araç sınıfı (s)

**Tablo 2.** Tespit edilen anomali durum tablosu

Nesne ID	Nesne Türü *	Hareket yönü	Yer değiştirme	Konum	Hız
14	1	İleri	Pozitif	Aktif	77 km/s
21	1	İleri	Pozitif	Aktif	63 km/s
30	1	İleri	Pozitif	Aktif	<b>94 km/s</b>
34	1	<b>Geri</b>	Negatif	Aktif	33 km/s
46	2	İleri	Pozitif	Aktif	<b>81 km/s</b>
53	2	İleri	Pozitif	Aktif	<b>68 km/s</b>

\*Küçük araç:1, Büyük araç:2, Yaya:3, Bilinmeyen:0

**Tablo 3.** Anomali durum tespit için kural tablosu

Nesne Sınıf	Hareket yönü	Yer değiştirme	Konum	Hız
Küçük araç (1)	İleri	Pozitif	Aktif	X < 90 km/s
Büyük araç (2)	İleri	Pozitif	Aktif	X < 51 km/s

Bu aşamanın sonuçlanması ile sınıflandırma için giriş olarak kullanacağımız veri seti elde edilmiş olur. Bu çalışmada araçların anomali durumlarına göre öznitelikler belirlenmiştir. Bu öznitelikler araçların hareket yönü, yer değiştirme, konum ve hız bilgilerinden oluşmaktadır. Elde edilen öznitelikler sınıflandırıcının girişine verilmiştir. Son olarak sınıflandırıcının çıkışında anomali var, anomali yok, araçların hareket yönü, yer değiştirme, konum ve hız bilgileri olmak üzere 5 adet çıkış bulunmaktadır.

### 3.3 Makine Öğrenmesi Süreçleri

Makine öğrenmesi tekniklerini kullanarak bir problemin çözülebilmesi için yaklaşım adımları aşağıdaki gibidir [29].


- Problemin tanımı
- Veri seti
- Verilerin hazırlanması
- Modelleme
- Model performans değerlendirme

Bu çalışmada trafik akış video verilerinden anomali tespiti ve makine öğrenmesi yöntemleri ile sınıflandırma yapılarak amaçlanan faydalar ilgili başlık altında sıralanmıştır. Video analiz verilerinin hangi sınıfa ait olacağı işlemine ilişkin problem çözülmeye çalışılmaktadır.

Veriler Diyarbakır ilinin şehir içi ve şehirler arası yol güzergahlarında, bir akıllı telefonun 16 mega piksel özelliğindeki arka kamerası ve sabit bir noktadan çekim yapmak amacıyla tripod yardımıyla toplanmıştır. Ayrıca benzetim yapmak amacıyla rasgele veriler oluşturularak hazırlanmıştır. Veri seti 32 adet 30'ar saniye 25 FPS 'den (saniyede çerçeve başına düşen görüntü sayısı) oluşmaktadır. Görüntüler 4 farklı bölgeden alınmıştır. Her bir bölgede 8 adet video olmak üzere 4 veri seti oluşturulmuştur. Bu çalışmada araçların durumu analiz edildiği için veri setinde yayalara ilişkin bilgiler gözardı edilmiştir.

Veriler modelde işlenmeden önce kullanılmak üzere hazır hale getirmek için veriye göre özetlenmesi, temizlenmesi, dönüştürülmesi, indirgenmesi, ayrıştırılması gerekmektedir [29]. Şekil 3'te gözetim kamerasından aktarılan videoların analiz edilmek üzere


depolama aygıtlarına aktarıldıktan sonra OpenCV programının işleyebileceği video formatlarına dönüşüm yapılır. Son adımda ise işlenebilecek videolarda süre ve diskte kapladığı yer açısından analiz edilebilecek boyut indirgenmesi yapılarak videolar analiz edilmeye hazır hale getirilir.

**Şekil 3.** Video verisi hazırlama iş akış diyagramı

Veriler işlenmeye hazır hale getirildikten sonra öğrenme algoritması için modelleme aşaması başlar. Model esas olarak görevin niteliklerine uygun olarak tanımlanmış çıktıya duyulan ihtiyacın mimarilendirilmesidir [29]. Bu çalışmada trafik videolarının analizi sonucu hareket eden nesnelerin anomali durumlarının sınıflandırma yapılmasında verileri değerlendirmek için yeni bir yaklaşım olarak UÖM ve DGAUÖM (Diferansiyel Gelişim Algoritması Uç Öğrenme Makinesi) model olarak seçilmiştir. Modellerin çalışma algoritmaları ile ilgili bilgiler alt bölümlerde sunulmuştur.

Uç Öğrenme Makinesi (UÖM) bir tek gizli katmana sahip ileri beslemeli bir yapay sinir ağı (YSA) modelidir [38-40, 79, 80]. YSA'nın başarımı yüksek öğrenme gerçekleştirebilmesi için eşik değeri, ağırlık ve aktivasyon fonksiyonu gibi parametreleri veri için modellenecek sisteme uygun değerde olmalıdır. Gradyan bazlı öğrenme yaklaşımlarında bu parametrelerin tümü iteratif olarak uygun değer için değiştirilir. Dolayısıyla yavaş ve yerel minimuma takılabilme olasılığı nedeniyle başarımı düşük sonuçlar üretebilmektedir. UÖM Öğrenme süreçlerinde parametrelerini gradyan bazlı olarak yenilenen YSA'dan farklı olarak giriş ağırlıkları rastgele seçilirken çıkış ağırlıkları analitik olarak hesaplanmaktadır. Analitik bir öğrenme süreci; hem çözüm zamanını hem de hata değerinin yerel bir minimuma takılabilme olasılığını ciddi oranda azalttığından başarımları artmaktadır. UÖM'nin gizli katmanda bulunan hücreleri aktive etmek için doğrusal bir fonksiyon seçilebileceği gibi doğrusal olmayan (sigmoid, sinüs vb.), türevlenemeyen veya kesikli aktivasyon fonksiyonlarda kullanılabilir [30-38]. Şekil 4'te UÖM mimarisi verilmiştir.





Şekil 4. İleri beslemeli tek gizli katmanlı bir yapay sinir ağı modeli

$$y(p) = \sum_{j=1}^m \beta_j g\left(\sum_{i=1}^n w_{i,j} x_i + b_j\right) \quad (7)$$

Denklem 7’teki  $x_i$  giriş  $y_p$  çıkış vektörlerini ( $m$  ve  $n$  nöron sayısı) ve  $w_{i,j}$  giriş katmanı ile gizli katman arasındaki ağırlıkları,  $\beta_j$  çıkış katmanı ile gizli katman arasındaki ağırlıkları  $b_j$  gizli katmandaki nöronların eşik değeri  $g(\cdot)$  Aktivasyon fonksiyonu ifade eder. Eşitlikteki giriş katmanı ağırlıkları ( $w_{i,j}$ ) ve bias ( $b_j$ ) değerleri rastgele atanır. Aktivasyon fonksiyonu ( $g(\cdot)$ ) giriş katman nöron sayısı ( $n$ ) ve gizli katman nöron sayısı ( $m$ ) başlangıç adımında atanır. Şimdi bu bilgilere dayanarak eşitlikte bilinen parametreler bir araya getirilip yeniden

$$H(w_{i,j}, b_j, x_i) = \begin{bmatrix} g(w_{1,1}x_1 + b_1) & \cdots & g(w_{1,m}x_m + b_m) \\ \vdots & \ddots & \vdots \\ g(w_{n,1}x_n + b_1) & \cdots & g(w_{n,m}x_m + b_m) \end{bmatrix}$$

düzenlenirse çıkış katmanı Denklem 8’deki gibi olur.

(8)

$$y = H\beta \quad (9)$$

Tüm eğitim algoritma modellerinde hedeflenen amaç olabildiğince hatayı minimum yapabilmektedir. UÖM de gerçek çıktı  $\widehat{Y}_o$  değeri ile elde edilen çıktı  $Y_p$  değerinin hata fonksiyonu  $\sum_k^s (\widehat{Y}_o - Y_p)$  ( $s$ : eğitim veri sayısı) veya hata maliyet fonksiyonu  $\|\sum_k^s (\widehat{Y}_o - Y_p)^2\|$  minimum olmasını sağlayabilmektedir. Bunun için her iki fonksiyonda da gerçek çıktı  $\widehat{Y}_o$  değeri ile elde edilen çıktı  $Y_p$  değerinin eşit olması gerekir. Bu eşitlik sağlandığında Denklem 9’da bilinmeyen parametre sadece  $\beta$  ağırlık değeridir.  $H$  Matrisi çok düşük ihtimalle kare bir matris olabilir. Ya da başka bir ifade ile eğitim kümesindeki veri sayısının, her verinin içerdiği özellik sayısına eşit olma olasılığı düşüktür. Dolayısıyla bu matrisin tersinin  $[H^-]$  alınarak ağırlıkların ( $\beta$ ) bulunması problem olacaktır. Bu durumu aşmak için Huang vd. [80] bu problemde olduğu gibi tersi alınmayan matrislerin yaklaşık terslerini hesaplamak için geliştirilmiş olan genelleştirilmiş ters Moore-Penrose matrisi kullanmayı önermişlerdir.  $\hat{\beta}$  yaklaşık çıkış ağırlığı ve  $H^+$ ,  $H$  matrisinin genelleştirilmiş

ters Moore-Penrose matrisi olur. Buna göre çıkış ağırlıkları  $\hat{\beta} = H^+y$  ile bulunabilir [38, 39].

Yüksek boyutlu değişken sayısına bağlı olarak doğrusal olmayan, gürültülü, çok modlu ve değişmeme özelliğine sahip problemlerin çözümüne ilişkin sunulmuş bir gelişimsel optimizasyon algoritması olan Diferansiyel Gelişim Algoritması (DGA) genetik algoritma-popülasyon tabanlı optimizasyon tekniğidir [40-43]. DGA, polinomal uyum problemini çözmek üzere Kenneth Price tarafından geliştirilmiştir [44]. DGA geliştirildiği teknik olan genetik algoritma optimizasyondaki çaprazlama, karşılaştırma ve mutasyon işlemlerini ayrı basamaklarda gerçekleştirir. Dolayısıyla her bir basamakta geçen süre kümülatif olarak değerlendirildiğinde uzun zaman almaktadır. DGA temel olarak bu dezavantajın giderilmesi amaçlamıştır. Özet olarak DGA başlangıç popülasyonundaki en iyi kromozom seçer ve ardından tüm popülasyon, istenilen durdurma şartları sağlanıncaya kadar mutasyon, çaprazlama ve karşılaştırma işlem adımlarını takip eder. Durdurma şartı, adım sayısı veya belirli bir hata değeri olabilir. DGA yeni ve oldukça da etkili bir mutasyon işlemi uygulamaktadır. Gelişim tabanlı algoritmalar ile arasında en temel ve belirgin fark rastgele seçilmiş amaç vektör farklarına dayalı bir mutasyon işlemi uygulamasıdır. Bu durum DGA’nın performansını arttırmaktadır. Bunun yanında hızlı, basit, kolay uygulanabilir, değiştirilebilir, etkili küresel optimizasyon kabiliyetli, kayan nokta formatına bağlı hassasiyet sınırlamalı, matris çarpımları ve sıralama işlemleri olmadığı için güçlü bir algoritma olarak kabul edilir. DGA dört temel adımdan oluşur [40-43]. Aşağıda bu dört temel adımdan oluşan DGA’nın sözde kodu verilmiştir.

**Adım 1:** Kontrol parametrelerinin  $D, Gmax, NP \geq 4 F \in (0,1+), CR \in [0,1]$  değerlerini ve parametre sınırlarını  $x^{(lo)}, x^{(hi)}$  ata.

**Adım 2:** Başlangıç popülasyonunu oluştur.

**Adım 3:** while( $\forall i \leq NP \Delta \forall j \leq D : x_{i,j,G=0} = x_j^{(lo)} + rand_j[0,1].\{(x_j^{(hi)} - x_j^{(lo)})\}$ )

**Adım 4:** for  $i=1$  to  $NP$

**Adım 5:** Mutasyon, Çaprazlama

$r_1, r_2, r_3 \in \{1,2, \dots, NP\} r_1 \neq r_2 \neq r_3 \neq i$   
 $j_{rand} \in \{1,2, \dots, D\}$

for  $i=1$  to  $D$

If ( $rand_j[0,1] < CR \Delta j = j_{rand}$ )

$U_{i,j}^{(G)} = V_{i,j}^{(G)}$

else

$U_{i,j}^{(G)} = X_{i,j}^{(G)}$

end if

end for

**Adım 6:** Seçim

if  $f(\bar{u}_{i,G+1}) \leq f(\bar{x}_{i,G})$

$\bar{x}_i^{(G+1)} = \bar{U}_i^{(G+1)}$

else

$\bar{x}_i^{(G+1)} = \bar{x}_i^{(G)}$

end if

end for

end while


#### 4 Deneysel Sonuçlar

Yapılan çalışmanın sonuçları ve başarımları üç aşamada incelenmiştir. Birinci aşamada arka/ön plan bölütleme yöntemi için kullanılan GKM ve nesne yörünge tahmin-atama için Kalman Filtre-Macarc algoritması yöntemleri kullanılarak videoda tespit edilen nesne sayıları ve toplam piksel değeri ile etiketlenen nesne tespit başarımları Tablo 4’de verilmiştir. Video analiz programının tespit ettiği şekil sayısı ile manuel ölçümler karşılaştırılarak tablo 4’teki başarımlar oranları elde

edilmiştir. İkinci aşamada yazılım ile nesnelerin özellik verileri ile izlenen yol için belirlenmiş kural verileri karşılaştırılarak yapılan anomali durum tespiti başarımları %100 dür. Üçüncü aşamada ise UÖM ve DGAUÖM yöntemleri ile sınıflandırma başarımları verilmiştir. Ayrıca UÖM yönteminin başarımlarının karşılaştırılması amacıyla diğer makine öğrenmesi yöntemlerinden sınıflandırma için Destek Vektör Makinesi (DVM) Naive Bayes (NB) ve Yapay Sinir Ağı (YSA) kullanılarak elde edilen sonuçlar verilmiştir. Bu sonuçlar MATLAB 2016 yazılımı ve Intel i5-6400 CPU, 16 GB RAM’ e sahip bilgisayar ile elde edilmiştir. Şekil 5’te ise oluşturulan video veri tabanındaki video setine ait örnek çerçeveler gösterilmiştir.

**Tablo 4.** Tespit edilen nesne ve türlerine ilişkin video analiz başarımları

Video seti	Videodaki nesne	Adet	Yazılımın tespit ettiği	Adet	Başarımlar
1	Otomobil, SUV	24	Küçük Araç	24	% 100
	Otobüs, Kamyon	24	Büyük Araç	24	% 100
	Hareketli nesne	1	Bilinmeyen	1	% 100
2	Otomobil, SUV	42	Küçük Araç	42	% 100
	Otobüs, Kamyon	13	Büyük Araç	13	% 100
	Hareketli nesne	3	Bilinmeyen	3	% 100
3	Otomobil, SUV	38	Küçük Araç	38	% 100
	Otobüs, Kamyon	11	Büyük Araç	11	% 100
	Hareketli nesne	4	Bilinmeyen	4	% 100
4	Otomobil, SUV	48	Küçük Araç	48	% 100
	Otobüs, Kamyon	16	Büyük Araç	16	% 100
	Hareketli nesne	3	Bilinmeyen	3	% 100



**Şekil 5.** Video veri setine ait örnek çerçeveler

#### 4.1 UÖM ile Sınıflandırma Sonuçları

Tablo 5’de UÖM yöntemi ile video setleri için çıkarılan nesne özellikleri anomali etiketlerine göre sınıflandırma sonuçları verilmiştir. Veri seti bölmede K-kat çapraz performans yöntemi kullanılmıştır. Elde edilen başarımlar sırasında UÖM’nin gizli katmandaki hücre sayısı (2, 5, 10, 20, 25, 50, 75) ve aktivasyon fonksiyonu (sigmoid (sig), sinüs (sin), hard limit (hardlim), triangular basis (tribas), radial basis (radbas) ve linear (lin)) Deneme-Yanılma yöntemi ile denenmiş elde edilen sonuçlardan maksimum (1’e yakın) olan değer verilmiştir.

**Tablo 5.** UÖM sınıflandırma başarımları

Video Seti	Test başarımları / Doğruluk başarımları	Gizli katmandaki hücre sayısı	Aktivasyon fonksiyonu
1	%97,92	50	linear (lin)
2	%97,62	25	linear (lin)
3	%95,83	50	linear (lin)
4	%98,33	10	linear (lin)

Görüntüler 4 farklı bölgeden alınmıştır. Her bir bölgede 8 adet video olmak üzere 4 veri seti oluşturulmuştur. UÖM sınıflandırıcının test verilerine uygulanması ile elde edilen performans metrik değerleri 4 veri seti için Tablo 6’ da gösterilmektedir. Şekil 6’da video setlerine ait UÖM sınıflandırma test başarımlar grafikleri verilmiştir. Şekil 6’da gizli katmandaki hücre sayısı 50 için aktivasyon fonksiyonu linear(lin) iken başarımların %97,92 olduğu gözlenmektedir. Gizli

katmandaki hücre sayısı 25 için aktivasyon fonksiyonu linear(lin) iken başarımların %97,62 olduğu gözlenmektedir. Gizli katmandaki hücre sayısı 50 için aktivasyon fonksiyonu linear(lin) iken başarımların %95,83 olduğu gözlenmektedir. Şekil 7’ de video setlerine ait UÖM sınıflandırma AİK (doğru pozitif yanlış pozitif oranı olarak hesaplanan duyarlılık, belirleyicilik, kesinlik ve F-ölçüsü) grafiği verilmiştir. Şekil 7’de ki AİK grafiğine

göre duyarlılık 1, belirleyicilik 0,96, kesinlik 0,95 ve F-ölçüsünün 0,97 olduğu gözlenmektedir.

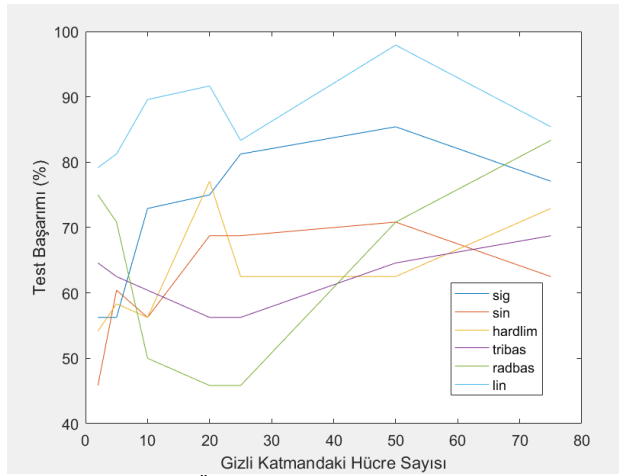
Tablo 7’de 4 farklı video veri seti için duyarlılık belirleyicilik, kesinlik ve F- ölçüsü değerleri verilmiştir.

**Tablo 6.** UÖM sınıflandırma performans metrik değerleri

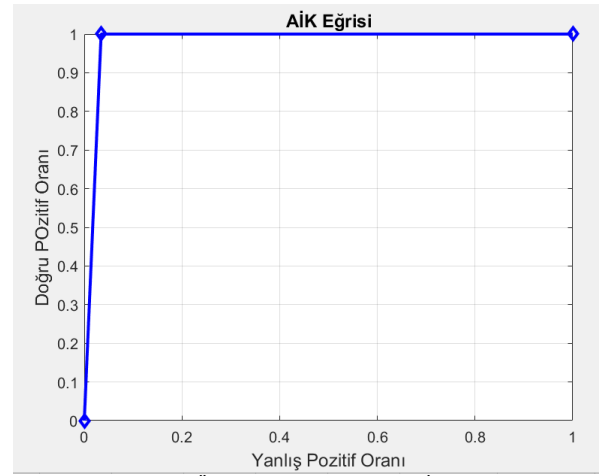
Video Seti	Performans metrik değerleri			
	Duyarlılık	Belirleyicilik	Kesinlik	F- Ölçüsü
1	1	0,96	0,95	0,97
2	1	0,92	0,97	0,98
3	0,96	0,94	0,96	0,96
4	1	0,96	0,97	0,98

**Tablo 7.** UÖM sınıflandırma başarımları

Video Seti	Test başarımları / Doğruluk başarımları	Gizli katmandaki hücre sayısı	Aktivasyon fonksiyonu
1	%97,92	50	linear (lin)
2	%97,62	25	linear (lin)
3	%95,83	50	linear (lin)
4	%98,33	10	linear (lin)



**Şekil 6.** UÖM sınıflandırma test başarımları grafiği



**Şekil 7.** UÖM sınıflandırıcısına ait AİK grafiği

## 4.2 DGAUÖM Sınıflandırma Sonuçları

DGAUÖM yöntemi ile video setleri için çıkarılan nesne özellikleri anomali etiketlerine göre sınıflandırma sonuçları verilmiştir. DGA'nın çaprazlama ve mutasyon adımlarında denenen gizli katmandaki hücre sayısı ve aktivasyon fonksiyonları ve algoritmaya uygun şekilde çalışmıştır. Son adımda ulaşılan en iyi hücre sayısı ve aktivasyon fonksiyonu tablo 8’de verilmiştir. Veri setinin %75’i, eğitim için geri kalan %25’i test için ayrılmıştır. Veri seti bölmede K-kat çapraz performans yöntemi kullanılmıştır. K-kat çaprazlama, veriyi belirlenen bir k sayısına göre eşit parçalara böler, her bir parçanın hem

eğitim hem de test için kullanılmasını sağlar, böylelikle dağılım ve parçalanmadan kaynaklanan sapma ve hataları en aza indirgenir.

Elde edilen başarımlar sırasında UÖM’nin DGA yöntemi ile en iyiye ulaşmak için gizli katmandaki hücre sayısı ve aktivasyon fonksiyonunu mutasyon ve çaprazlama yapılarak en iyi başarımları (1’e yakın) olan değeri verilmiştir. Bu sonuçların test / doğruluk başarımlarının tamamı %100 çıkmıştır. Bu sonuçlar DGAUÖM yönteminin UÖM yönteminden de başarılı sonuç üretebileceğini göstermektedir.

**Tablo 8.** DGA-UÖM sınıflandırma başarımları

Video Seti	Test başarımları / Doğruluk başarımları	Gizli katmandaki hücre sayısı	Aktivasyon fonksiyonu
1	%100	25	Radial basis (radbas)
2	%100	10	Radial basis (radbas)
3	%100	25	Radial basis (radbas)
4	%100	50	Radial basis (radbas)

Tablo 9’da literatürde sık kullanılan diğer makine öğrenmesi sınıflandırma yöntemlerinin aynı veri seti üzerindeki başarımları sonuçları verilmiştir. Yapay sinir ağları modelinde gizli katman sayısı bir ve bu katmandaki gizli düğüm sayısı üç olarak alınmıştır. Katmanlar arasında sigmoid aktivasyon fonksiyonu kullanılmıştır.

Yakınsama kriteri 0.2 maksimum iterasyon sayısı 50 ve her bir çalıştırmada algoritmanın sonlandırılmasında 20 devir alınmıştır. Diğer makine öğrenmesi sınıflandırıcılarının test verilerine uygulanması ile elde edilen performans metrik değerleri gösterilmektedir.



**Tablo 9.** Alternatif yöntem sınıflandırıcıların performans metrik değerleri

Video Seti	Performans metrik değerleri				
		Duyarlılık	Belirleyicilik	Kesinlik	F- Ölçüsü
1	Naive Bayes	0,94	0,81	0,75	0,83
	Destek vektör	0,94	0,79	0,70	0,80
	YSA	0,92	0,96	0,95	0,93
2	Naive Bayes	0,91	0,83	0,94	0,92
	Destek vektör	0,77	1	1	0,87
	YSA	0,94	1	1	0,97
3	Naive Bayes	0,78	0,83	0,93	0,85
	Destek vektör	0,68	1	1	0,81
	YSA	0,96	1	1	0,98
4	Naive Bayes	0,85	0,95	0,97	0,90
	Destek vektör	0,63	1	1	0,77
	YSA	0,89	0,96	0,97	0,93

## 5 Tartışma ve Öneriler

Askeri ve yerleşim yeri güvenliği, kişi ya da araç hareketlerini sürekli izleme ve raporlama önceden tanımlanmış olayların tespiti gibi uygulamalar insan gözlem tabanlı sistemler ile yapılmasının çeşitli dezavantajları vardır. Günümüzde bu işlem, çoğunlukla birkaç ekran karşısında oturan güvenlik personeli ile yapılmaya çalışılmaktadır. Kapalı devre izleme merkezlerinde yapılan testlerde; iki veya daha fazla monitörün, 12 dakika sürekli döngü halinde izlenmesi durumunda güvenlik personelinin ekranda olan aktivitenin %45'ini kaçırdığı, 22 dakika sonra ise aktivite tespit başarımının sadece %5 ile sınırlı olduğu tespit edilmiştir. Karayolu trafiği gözetleme sistemleri anlık değerlendirme, sürekli bilgi güncellemesi, yüksek miktarda veri ve manuel uyarı gibi nedenlerden dolayı klasik izleme sistemleri yetersiz kalmaktadır. Kural dışı davranış olarak nitelendirilen anomalinin sınıflandırılması ve tahmini bilgisayar destekli otomatik sistemler tarafından yapılması insan faktörlü hata payını azaltıp bilgisayar kontrolünü ve verinin doğruluğunu artırarak trafik akışının güvenliğinin sağlanmasında başarımlı yüksek uyarı sistemlerini sağlar. Bu çalışmada akıllı trafik izleme sistemine ilişkin çeşitli yöntemlere dayalı fikirler savunulmuştur. Çalışmanın açık noktaları ve ileride üzerinde çalışma yapılması gereken konular mevcuttur. Bunlar videoların analizi sırasında karşılaşılan (durağan olmayan arka plan: iklim, ışık, kamera kalibre vb.) problemleri; tespit edilen hareketli nesnelere ilişkin özellik çıkarma ve izlenen karayolunun kuralının otomatik olarak çıkarılabilmesi; video gibi yüksek miktardaki verinin makine öğrenmesi yöntemleri ile işlenip gerçek zamanlı otomatik uyarım sistemlerinin oluşturulması olarak sıralanabilir.

Her geçen gün bu problemlerin çözümüne ilişkin yeni çalışmalar sunulmaktadır. Bu çalışmalar ile akıllı şehir ve otomatik araç teknolojilerine katkılar sunulmaktadır. Gelecek birkaç yıl içinde küreselleşen ve her geçen gün nüfusu artan dünyamızda trafik akış güvenliği ve buna bağlı birçok etkenin olumsuz etkileri; gelişen donanım ve yazılım teknolojisi ile aşılabilir hale gelecektir. Trafik

akışı gibi büyük veri içeren ve insan görsel değerlendirilmesine dayalı birçok sistem yerini otomatik çalışıp gerektiğinde uyarı verebilen modeli öğrenip geleceğe yönelik tahminler yapabilen sistemlere bırakacaktır. Özet olarak bu çalışmada bunu yapabilecek bir sistem; yapay öğrenme yöntemi ile trafik akış gözetimi analizinde yeni bir yaklaşım olarak sunulmuştur.

## Bilgilendirme

Gerçekleştirilen bu çalışmada Etik Kurul Onay belgesine gerek yoktur.

## Kaynaklar

- [1] Peker, M., & Zengin, A. (2011, May). Gerçek zamanlı harekete duyarlı bir görüntü tanıma sistemi. *In 6th International Advanced Technologies Symposium (IATS'11)* (pp. 16-18).
- [2] Hsia, C. H., & Guo, J. M. (2014). Efficient modified directional lifting-based discrete wavelet transform for moving object detection. *signal Processing*, 96, 138-152.
- [3] Oral, M., & Deniz, U. (2005, May). Motion detection in moving pictures. *In Proceedings of the IEEE 13th Signal Processing and Communications Applications Conference*, 2005. (pp. 187-190). IEEE.
- [4] Retrieved January 15, 2018, from [www.nuuo.com/enews/201210\\_enews/images/2012010\\_Fl\\_yer\\_IVS\\_V1.0\\_A4\\_en.pdf](http://www.nuuo.com/enews/201210_enews/images/2012010_Fl_yer_IVS_V1.0_A4_en.pdf)
- [5] Borji, A., Cheng, M. M., Hou, Q., Jiang, H., & Li, J. (2019). Salient object detection: A survey. *Computational visual media*, 5(2), 117-150.
- [6] Sen-Ching, S. C., & Kamath, C. (2004, January). Robust techniques for background subtraction in urban traffic video. *In Visual Communications and Image Processing 2004* (Vol. 5308, pp. 881-892). International Society for Optics and Photonics.
- [7] Mahamuni, P. D., Patil, R. P., & Thakar, H. S. (2014). Moving object detection using background subtraction algorithm using Simulink. *IJRET: International Journal of Research in Engineering and Technology*, 3(06).
- [8] Orhan, U. *Makine Öğrenmesi ders notları* [PDF Document], retrieved August 2, 2015, from <http://bmb.cu.edu.tr/uorhan/MLearn.htm>
- [9] Jodoin, J. P., Bilodeau, G. A., & Saunier, N. (2014, March). Urban tracker: Multiple object tracking in urban mixed

- traffic. In *IEEE Winter Conference on Applications of Computer Vision* (pp. 885-892). IEEE.
- [10] Mohan, A. S., & Resmi, R. (2014, December). Video image processing for moving object detection and segmentation using background subtraction. In *2014 First International Conference on Computational Systems and Communications (ICCS)* (pp. 288-292). IEEE.
- [11] Zhu, Y., Nayak, N. M., & Roy-Chowdhury, A. K. (2012). Context-aware activity recognition and anomaly detection in video. *IEEE Journal of Selected Topics in Signal Processing*, 7(1), 91-101.
- [12] Bas, E., Tekalp, A. M., & Salman, F. S. (2007, June). Automatic vehicle counting from video for traffic flow analysis. In *2007 IEEE intelligent vehicles symposium* (pp. 392-397). IEEE.
- [13] Buch, N., Velastin, S. A., & Orwell, J. (2011). A review of computer vision techniques for the analysis of urban traffic. *IEEE Transactions on intelligent transportation systems*, 12(3), 920-939.
- [14] Morris, B. T., & Trivedi, M. M. (2008). Learning, modeling, and classification of vehicle track patterns from live video. *IEEE transactions on intelligent transportation systems*, 9(3), 425-437.
- [15] Öz, K., & Görgünoğlu, S. (2016). Video Gözetim Sistemlerinde Anomali Tespiti Üzerine Bir Derleme. *El-Cezeri Journal of Science and Engineering*, 3(3).
- [16] Çandar, C., & Gerek, Ö. N. (2002) Yol üzerinde trafik ve araç durumunun video analiz yöntemleri ile incelenmesi.
- [17] Nandhini, K., Pavithra, M., Revathi, K., & Rajiv, A. (2017, March). Anomaly detection for safety monitoring. In *2017 Fourth International Conference on Signal Processing, Communication and Networking (ICSCN)* (pp. 1-6). IEEE.
- [18] Batapati, P., Tran, D., Sheng, W., Liu, M., & Zeng, R. (2014, June). Video analysis for traffic anomaly detection using support vector machines. In *Proceeding of the 11th World Congress on Intelligent Control and Automation* (pp. 5500-5505). IEEE.
- [19] Chung, S. C. S., & Kamath, C. (2005). Robust background subtraction with foreground validation for urban traffic video. *EURASIP Journal on Advances in Signal Processing*, 2005(14), 1-11.
- [20] Panchal, P., Prajapati, G., Patel, S., Shah, H., & Nasriwala, J. (2015). A review on object detection and tracking methods. *International Journal for Research in Emerging Science and Technology*, 2(1), 7-12.
- [21] Yilmaz, A., Javed, O., & Shah, M. (2006). Object tracking: A survey. *Acm computing surveys (CSUR)*, 38(4), 13-es.
- [22] Ritika, G. S. S. (2012) Path Estimation and Motion Detection of Moving Object in Videos. *IOSR Journal of Computer Engineering (IOSRJCE)*, 2(4), 01-04.
- [23] Ergezer., H. (2007). *Visual detection and tracking of moving objects* (Master's dissertation, METU).
- [24] Stauffer, C., & Grimson, W. E. L. (1999, June). Adaptive background mixture models for real-time tracking. In *Proceedings. 1999 IEEE computer society conference on computer vision and pattern recognition* (Cat. No PR00149) (Vol. 2, pp. 246-252). IEEE.
- [25] Hayman, E., & Eklundh, J. O. (2003, October). Statistical background subtraction for a mobile observer. In *Computer Vision, IEEE International Conference on* (Vol. 2, pp. 67-74). IEEE Computer Society.
- [26] Talu, M. F. (2010). *İnsan hareketlerinin takibinde karşılaşılan problemlerin çözümüne yeni yaklaşımlar* (Doctoral Dissertation, Fırat University).
- [27] Aydemir, M. S. (2012). *Gerçek zamanlı güvenlik kamerası videolarının insan tabanlı özetlenmesi* (Master's dissertation, Yıldız Teknik University).
- [28] Kartal E., Özen Z., Gezer M., Saylan S. (2017) Mühendislikte yapay zekâ ve uygulamaları *Sakarya Üniversitesi Kütüphanesi Yayınevi-Sakarya*
- [29] Ertam, F. (2016). *Kurumsal bilgisayar ağlarındaki trafik bilgisinin akıllı sistemler ile sınıflandırılması* (Doctoral Dissertation, Fırat University).
- [30] Ertuğrul, Ö. F., Tağluk, M. E., Kaya, Y., & Tekin, R. (2013, April). EMG signal classification by extreme learning machine. In *2013 21st Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- [31] Yılmaz, K. A. Y. A., & TEKİN, R. (2012). Epileptik nöbetlerin tespiti için aşırı öğrenme makinesi tabanlı uzman bir sistem. *Bilişim Teknolojileri Dergisi*, 5(2), 33-40.
- [32] Wang, G., & Li, P. (2010). Dynamic Adaboost ensemble extreme learning machine. In *2010 3rd International Conference on Advanced Computer Theory and Engineering (ICACTE)* (Vol. 3, pp. V3-54). IEEE.
- [33] Kaya, Y., Ertuğrul, Ö. F., & Tekin, R. (2014). An expert spam detection system based on extreme learning machine. *Computer Science and Applications*, 1(2), 132-137..
- [34] ERTUĞRUL, Ö. F. (2016). Aşırı Öğrenme Makineleri ile biyolojik sinyallerin gizli kaynaklarına ayrıştırılması. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 7(1), 41-50.
- [35] Tağluk, M. E., Mamiş, M. S., Arkan, M., & Ertuğrul, Ö. F. (2015). Aşırı Öğrenme Makineleri ile Enerji İletim Hatları Arıza Tipi ve Yerinin Tespiti. In *Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4).
- [36] Ertuğrul, Ö. F., & Kaya, Y. (2014). A detailed analysis on extreme learning machine and novel approaches based on ELM. *American Journal of computer science and engineering*, 1(5), 43-50.
- [37] Ertugrul, Ö. F. (2016). Forecasting electricity load by a novel recurrent extreme learning machines approach. *International Journal of Electrical Power & Energy Systems*, 78, 429-435.
- [38] Ertugrul, F. (2016). Determining the order of risk factors in diagnosing heart disease by extreme learning machine. In *International Conference on Natural Science and Engineering, Kilis* (pp. 10-19).
- [39] Huang, G. B., Zhu, Q. Y., & Siew, C. K. (2006). Extreme learning machine: theory and applications. *Neurocomputing*, 70(1-3), 489-501.
- [40] Keskindürk, T. (2006). Diferansiyel gelişim algoritması. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 5(9), 85-99.
- [41] Aydın, S., & Zeybek, M. S. Diferansiyel Gelişim Algoritması İle Problem Çözme Üzerine Bir Değerlendirme. *Soma Meslek Yüksekokulu Teknik Bilimler Dergisi*, 2(20), 49-55.
- [42] Yılmaz, A. R. (2014). *Genel amaçlı yapay sinir ağlarının diferansiyel gelişim algoritması ile eğitiminin fpga üzerinde gerçekleştirilmesi* (Master's dissertation, Yıldız Teknik University).
- [43] Karaboğa, D. (2017). *Yapay Zeka Optimizasyon Algoritmaları*. Nobel Akademi Yayıncılık.
- [44] Storn, R., & Price, K. (1997). Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces. *Journal of global optimization*, 11(4), 341-359..
- [45] Takma, Ç., Atıl, H., & Aksakal, V. (2012). Çoklu doğrusal regresyon ve yapay sinir ağı modellerinin laktasyon süt verimlerine uyum yeteneklerinin karşılaştırılması. *Kafkas Üniversitesi Veteriner Fakültesi Dergisi*, 18(6), 941-944.
- [46] Ertugrul, Ö. F., & Kaya, Y. (2016). Smart city planning by estimating energy efficiency of buildings by extreme learning machine. In *2016 4th International Istanbul Smart Grid Congress and Fair (ICSG)* (pp. 1-5). IEEE.