

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**VIDEO GÖRÜNTÜLERİNİN ANALİZİNDE UÇ
ÖĞRENME MAKİNESİ SINIFLANDIRICI
ALGORİTMALARININ KULLANILMASI VE
GELİŞTİRİLMESİ**

Yasin SÖNMEZ

Doktora Tezi
Yazılım Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Engin AVCI

EYLÜL-2018

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**VIDEO GÖRÜNTÜLERİNİN ANALİZİNDE UÇ ÖĞRENME MAKİNESİ
SINIFLANDIRICI ALGORİTMALARININ KULLANILMASI VE
GELİŞTİRİLMESİ**


DOKTORA TEZİ
Yasin SÖNMEZ
(122137201)

Tezin Enstitüye Verildiği Tarih: 22 Mayıs 2018

Tezin Savunulduğu Tarih: 7 Eylül 2018

Tez Danışmanı: Prof. Dr. Engin AVCI (Fırat. Ü) 

Diğer Jüri Üyeleri: Prof. Dr. Asaf VAROL (Fırat. Ü)

Doç. Dr. Alper BAŞTÜRK (Erciyes. Ü) 

Doç. Dr. Muhammed Fatih TALU (İnönü. Ü) 

Dr. Öğr. Üyesi. Mustafa ULAŞ (Fırat. Ü) 

EYLÜL-2018

ÖNSÖZ

Bu tez çalışması, Fırat Üniversitesi Fen Bilimleri Enstitüsü Yazılım Mühendisliği Anabilim Dalı Doktora Programı'nda hazırlanmıştır.

Tez çalışmam boyunca benden desteğini esirgemeyen danışmanım Prof. Dr. Engin AVCI'ya teşekkür ederim.

Tez çalışmasının tamamlanmasında bilgi ve destek veren Sayın Doç. Dr. Ömer Faruk ERTUĞRUL ve Sayın Dr. Abdulkerim ÖZTEKİN'e teşekkür eder minnetlerimi sunarım.

Tez ve makale yazımında her zaman yanımda olan sevgili dostum Yrd. Doç. Dr. Emrah AYDEMİR'e ayrıca doktora çalışma arkadaşlarıma teşekkür ederim.

Bu çalışmamı; zorlu süreçte anlayış ve sabır göstererek hep yanımda olan eşim Ayşe SÖNMEZ'e ithaf ediyorum.

Yasin SÖNMEZ
ELAZIĞ-2018

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖN SÖZ	II
İÇİNDEKİLER.....	III
ÖZET	V
ABSTRACT	VI
ŞEKİLLER LİSTESİ	VII
TABLolar LİSTESİ	VIII
KISALTMALAR LİSTESİ	IX
1. GİRİŞ.....	1
1.2. Tezin Amaç ve Organizasyonu	4
1.3. Önceki Çalışmalar	5
2. MATERYAL VE METOT	10
2.1. Problem Çözüm Süreci.....	10
2.1.1. Problemin Tanımı.....	10
2.1.2. Veri Seti.....	11
2.1.3. Verinin Hazırlanması	11
2.1.4. Modelleme.....	12
2.1.5. Model Performans Değerlendirme Yöntem ve Ölçütleri	12
2.2. Uç Öğrenme Makinesi	16
2.3. Diferansiyel Gelişim Algoritması	18
2.4. Video Analizi	23
2.4.1. Hareketli Nesne Tespiti.....	25
2.4.1.1. Gauss Karışım Modeli.....	25
2.4.2. Hareketli Nesne Takibi.....	27
2.4.2.1. Nokta Tabanlı	28
3. UYGULAMA.....	32
3.1. Uygulama Sonuçları.....	33
3.1.1. UÖM ile Sınıflandırma Sonuçları	36
3.1.2. M-DGA-UÖM ile Sınıflandırma Sonuçları	48
3.1.3. Diğer Sınıflandırma Yöntemlerinin Sonuçları	49

4.	TARTIřMA VE NERİLER	50
	KAYNAKLAR.....	54
	Z GEMİř.....	60



ÖZET

Tıp biliminde video analizi konusu, görüntülerin mikroskobik boyutta yoğun ve hassas bilgiler içermesi açısından kritik öneme sahiptir. Mikroskop kameralar ile elde edilen videolarda hareketli nesne tespit ve takibi ile nesne hakkında anlamlı ve yorumlanabilir bilgi elde edilmesi süreci, video analizi olarak tanımlanabilir. Bu tez çalışmasında, video görüntülerinin analizinde uç öğrenme makinesi sınıflandırıcı algoritmalarının kullanılması ve geliştirilmesi çalışması gerçekleştirilmiştir. Geliştirilen bu Melez (M) - Diferansiyel Gelişim Algoritması (DGA) – Uç Öğrenme Makinesi (UÖM) yönteminin başarımını test etmek için elde edilmiş gerçek sperm videoları üzerinde sperm motilitesinin doğru sınıflandırılması çalışması yapılmıştır. Tıp literatüründe sperm ile dölleme yapan erkek bireylerin, erkek infertilite probleminin başlıca sebebi sperm kalitesinin düşük olmasıdır. Spermin kalitesi, konsantrasyon (sayısı), motilite (hareketliliği) ve morfoloji (yapısı) değerleri ile belirlenir. Problemin tespiti için uzmanlar tanı aşamasında spermiyogram testi yapmaktadırlar. Bu test motilite ve morfoloji analizinden oluşup klasik veya bilgisayar destekli yöntemler ile yapılabilir. Klasik yöntem motilite analizi; uzman kişilerin semen sıvısını mikroskop altında göz ile deneyimlerine dayalı olarak sperm hücre hareketlilik sınıfını belirlemesidir. Bilgisayar destekli yöntemler ise sperm hücre hareketini video analizi ile tespit edip, sınıflandıran yazılım ve donanım ikilisinden oluşan sistemlerdir. Çalışmanın özel amacı sperm hücresinin hareketi ile oluşan öznelik parametrelerini video analiz yöntemleri ile tespit ederek; Uç Öğrenme Makinesi sınıflandırıcı algoritmaları ile sınıflandırmaktır. Bu amaçla tasarım ve uygulaması yapılan sistem üç aşamadan oluşmaktadır. Birinci aşamada sperm hareket videolarında her bir sperm hücresinin tespiti için arka/ön plan bölütleme yöntemlerinden Gauss Karışım Modeli ve takibinin yapılabilmesi için Kalman Filtre-Macar Algoritması yöntemleri kullanılmıştır. İkinci aşamada tespit edilen hareketli her sperm hücresine ait koordinat bilgilerini kullanarak sperm hareket öznelik parametre verileri elde edilmiştir. Son aşamada ise hareket öznelik parametre verileri UÖM ile sınıflandırma yapılarak sonuçları irdelenmiştir. Sonuçlar değerlendirildiğinde UÖM yönteminin başarımı diğer sınıflandırma yöntemlerine (YSA, DVM ve NB) kıyasla en yüksek çıkmıştır. Bu tez çalışmasında yenilik olarak, UÖM'nin gizli katman hücre sayıları ve aktivasyon fonksiyon seçim işlemi geliştirdiğimiz M-DGA-UÖM yöntemi ile optimize edilmiştir. Böylelikle, UÖM'nin sperm motilitesinin doğru sınıflandırma başarımı arttırılmıştır. Ayrıca uygulaması yapılan M-DGA-UÖM yazılım sistemi paket bir program haline getirilerek, yapay öğrenme tabanlı sperm motilite analizi olarak kullanılması hedeflenmiştir. M-DGA-UÖM tabanlı bu yazılım bir taraftan yapay öğrenme tabanlı sistemlerin gelişimine katkı sunarken öbür taraftan da klinik açıdan erkek infertilite probleminin çözümünde etkili olacak teşhis yöntemlerinin gelişmesine katkıda bulunacaktır.

Anahtar Kelimeler: Sperm Motilite Sınıflandırma, Diferansiyel Gelişim Algoritması, Uç Öğrenme Makinesi Sınıflandırma.

ABSTRACT

DEVELOPMENT OF EXTREME LEARNING MACHINE BASED CLASSIFICATION ALGORITHMS FOR ANALYSIS OF VIDEO IMAGES

Video analysis is of critical importance in medical science with regard to the microscopic-size intensive and sensitive data contained by the images. Video analysis can be defined as the process of obtaining meaningful and interpretable information about objects with moving object recognition and monitoring in videos recorded with microscopic cameras. In this thesis study, the use and development of Extreme Learning Machine (ELM) algorithms were performed in the analysis of video images. In order to test the performance of this developed hybrid (Hybrid-Differential Evolution-Extreme Learning Machine) method, the correct classification of sperm motiles was performed on real sperm videos obtained. In medical literature, the primary cause of infertility problem in males who use sperms for fertilization is the low quality of sperms. The quality of sperm is determined with concentration (count), motility (movement) and morphology (structure) values. Specialists implement a spermiogram during diagnosis to detect the problem. This test consists of motility and morphology analysis and can be implemented using conventional or computer-assisted methods. In conventional motility analysis, specialists determine the sperm cell motility class by visual examination of seminal fluid under microscope. Computer-assisted methods, which is made up of software and hardware systems that detect and classify the sperm cell motility by video analysis. The aim of this thesis study is to detect feature parameters resulting from the motility of sperm cells with video analysis methods and to classify them with (ELM) classifier algorithms. To this end, the designed and applied system consists of three stages. In the first stage, Gauss Mixture Model which is one of the background/foreground segmentation methods was used for the recognition of each sperm cell in sperm motility videos and Kalman Filter-Hungarian Algorithm methods were used for monitoring them. In the second stage, sperm motility feature data were obtained by using coordinate information of each recognized motile sperm cell. In the final stage, motility feature data were classified with ELM and results were examined. Assessment of results shows that the performance of ELM method was higher compared to other classification methods (ANN, SVM and NB). What's new in this thesis study is that ELM's hidden layer cell counts and activation function selection process were optimized with the DE-ELM method developed by us, thereby increasing the performance of ELM. Furthermore, the applied software system was developed into a program package and aimed to use as artificial intelligence-based sperm motility. This aim contributes to the development of artificial intelligence-based systems on one hand and of diagnosis methods that will be clinically effective in the solution of infertility problem in men on the other.

Key Words: Sperm Motility Classification, Differential Evaluation, Extreme Learning Machine Classification.

ŞEKİLLER LİSTESİ

Sayfa No

Şekil 1.1. Örnek imge.....	1
Şekil 1.2. Bir sperm hücresinin hareketi ve öznitelik parametreleri	2
Şekil 2.1. Video verisi hazırlama iş akış diyagramı	11
Şekil 2.2. Hold-out veri bölme yöntemi	13
Şekil 2.3. K-kat çapraz geçерleme veri bölme yöntemi	13
Şekil 2.4. AİK uzayının gösterimi.....	15
Şekil 2.5. YSA modeli.....	16
Şekil 2.6. İleri beslemeli tek gizli katmanlı bir YSA modeli	17
Şekil 2.7. Arka plan çıkarma algoritmalarının iş akış diyagramı	24
Şekil 2.8. Hareketli nesne takip yöntemleri	28
Şekil 2.9. Farklı hareket kısıtları A:Yakınlık, B:Maksimum hız, C:Küçük hız değışikliğı, D: Genelleme hareketi, E:Sertlik	29
Şekil 3.1. Önerilen yöntemin blok diyagramı	32
Şekil 3.2. Sistemin donanım düzeneğı	33
Şekil 3.3. Video veri setine ait örnek çerçeveler.....	36
Şekil 3.4. Tüm parametrelere göre UÖM sınıflandırma test başarımlı grafiğı.....	39
Şekil 3.5. Tüm parametrelere göre UÖM sınıflandırıcısına ait AİK grafiğı	39
Şekil 3.6. VCL parametresine göre UÖM sınıflandırma test başarımlı grafiğı.....	40
Şekil 3.7. VCL parametresine göre UÖM sınıflandırıcısına ait AİK grafiğı	40
Şekil 3.8. VSL parametresine göre UÖM sınıflandırma test başarımlı grafiğı	41
Şekil 3.9. VSL parametresine göre UÖM sınıflandırıcısına ait AİK grafiğı.....	41
Şekil 3.10. VAP parametresine göre UÖM sınıflandırma test başarımlı grafiğı.....	42
Şekil 3.11. VAP parametresine göre UÖM sınıflandırıcısına ait AİK grafiğı	42
Şekil 3.12. ALH parametresine göre UÖM sınıflandırma test başarımlı grafiğı	43
Şekil 3.13. ALH parametresine göre UÖM sınıflandırıcısına ait AİK grafiğı.....	43
Şekil 3.14. LIN parametresine göre UÖM sınıflandırma test başarımlı grafiğı.....	44
Şekil 3.15. LIN parametresine göre UÖM sınıflandırıcısına ait AİK grafiğı.....	44
Şekil 3.16. STR parametresine göre UÖM sınıflandırma test başarımlı grafiğı	45
Şekil 3.17. STR parametresine göre UÖM sınıflandırıcısına ait AİK grafiğı.....	45
Şekil 3.18. WOB parametresine göre UÖM sınıflandırma test başarımlı grafiğı	46
Şekil 3.19. WOB parametresine göre UÖM sınıflandırıcısına ait AİK grafiğı.....	46
Şekil 3.20. GB parametresine göre UÖM sınıflandırma test başarımlı grafiğı	47
Şekil 3.21. GB parametresine göre UÖM sınıflandırıcısına ait AİK grafiğı.....	47
Şekil 3.22. M-DGA-UÖM sınıflandırma test başarımlı grafiğı	48

TABLÖLAR LİSTESİ

	<u>Sayfa No</u>
Tablo 2.1. Sınıflandırma yöntemi için giriş çıkış verileri	11
Tablo 2.2. Hata matrisi	14
Tablo 2.3. Diferansiyel Gelişim Algoritması.....	19
Tablo 3.1. Tespit edilen sperm hücre sayısı video analiz başarımları.	34
Tablo 3.2. UÖM parametreleri.	37
Tablo 3.3. UÖM sınıflandırma başarımları.....	37
Tablo 3.4. UÖM sınıflandırma performans metrik değerleri.....	38
Tablo 3.5. M-DGA-UÖM sınıflandırma başarımları.....	48
Tablo 3.6. Diğer sınıflandırma yöntemlerinin başarımları.	49
Tablo 3.7. Diğer sınıflandırıcıların performans metrik değerleri.	49
Tablo 4.1. Sınıflandırma başarımlarının karşılaştırılması.....	52

KISALTMALAR LİSTESİ

AGKM	: Adaptif Gauss Karışım Modeli
AİK	: Alıcı İşletim Karakteristiği
APÇ	: Arka Plan Çıkarma
ÇHİ	: Çoklu Hipotez İzleme
DGA	: Diferansiyel Gelişim Algoritma
DSÖ	: Dünya Sağlık Örgütü
DVM	: Destek Vektör Makineleri
GKM	: Gauss Karışım Modeli
M-DGA-UÖM	: Melez Diferansiyel Gelişim Algoritma Uç Öğrenme Makinesi
NB	: Naive Bayes
OOVİ	: Ortak Olasılık Veri İlişkilendirme
UÖM	: Uç Öğrenme Makinesi
YSA	: Yapay Sinir Ağları

1. GİRİŞ


Bilgisayar görmesi konusu ile ulaşılmak istenen amaç insan görme yeteneği ile çalışan uygulamalarda insan yerine otomatik çalışan bilgisayarlı sistemler geliştirmektir. Şekil 1.1'deki [1] imgede insan gözü tespiti ile daire sayısı üçtür denir [1]. Fakat saniyede 30 tane Şekil 1.1'deki gibi imgenin olduğu bir imge dizisinde daire sayılarının insan gözüyle tespiti imkânsızdır. Video analizinin temel amacı, insan gözüyle video izleme içeriği hakkında karar vermenin zor veya imkânsız olduğu sistemleri bilgisayar ile otomatik duruma getirmektir. 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 [2].



Şekil 1.1. Örnek imge

Tıp biliminde video analizi birçok hastalığın teşhisinde etkin kullanılmaktadır. Özellikle uzman kişilerin deneyim ve gözlemlerine dayalı teşhis yapmanın zor veya imkânsız olduğu mikroskobik görüntülerde kritik öneme sahiptir. Bu tarz mikroskobik görüntülerin video analizleri, son 20 yılın popüler araştırma konusu olan erkek bireyde erkek infertilite probleminin tespit ve tanı aşamasında, sperm motilite analizi belirlemek amacıyla yapılmaktadır. Literatürde sperm hücre motilitesi, hareket eden sperm hücrelerinin hızı olarak tanımlanır ve analizleri klasik veya bilgisayar destekli yöntemler ile yapılabilir. Klasik yöntem motilite analizi, uzman kişilerin semen sıvısını mikroskop altında göz ile deneyimlerine dayalı olarak incelemesidir. Bilgisayar destekli yöntemler ise yazılım ve donanım ikilisinden oluşan cihazlar ile otomatik yapılmaktadır [3]. Sperm motilite sınıflandırılması Dünya Sağlık Örgütü'nün (DSÖ) beşinci baskısını yayımladığı semen analiz kitapçığındaki kriterler temel alınarak yapılır. Bu el kitabının önceki baskısında, ileri hareketli spermin hızlı veya yavaş olarak ayrılması gerektiğini ve 37°C'de 25 $\mu\text{m}/\text{sn}$ hızla ileriye doğru hareket edenin "sınıf a" olarak adlandırılması önerilmektedir [4].

Bir uzmanın göz ile deneyimlerine dayanarak, mikroskopik düzeydeki görüntülerde sperm hücrelerinin $25 \mu\text{m/sn}$ eşit veya büyük olanların oranının ne olduğu gibi son derece kritik ve analizin başlıca amacını oluşturan sperm hücrelerinde ileriye doğru hareketin nicel verilere dayalı ve doğru olarak sınıflandırabilmesi zor veya imkânsızdır [5, 6]. Otomasyona dayalı sistemlerde de motilite yüzdesi ile ilgili veriler güvenilir olmayabilir. Çünkü bu sistemlerin performansı, semen örneğinin hazırlanması, sperm konsantrasyonu ve sayma kamarasının derinliği gibi birçok faktör motilite yüzdesinin kantitatif bir değerle ifade edebilmesini güçleştirmektedir. Bir semen örneğinin bu sistemler ile ölçülürken oluşan hareketlerin öznelik parametreleri bazı standart terminolojileriyle Şekil 1.2’de gösterilmiştir [3-5].



Şekil 1.2. Bir sperm hücresinin hareketi ve öznelik parametreleri

1. VSL (Velocity Straight Linear) Doğrusal hız: Bir sperm başının, saptanan ilk konumuyla son konumu arasında çizilen düz çizgi boyunca zamana göre ortalama hızı.
2. VCL (Velocity Curvi Linear) Eğri çizgisel hız: Mikroskopik gözlem altında iki boyutta algılandığı gibi, bir sperm başının gerçek eğri çizgisel yolağı boyunca zamana göre ortalama hızı.
3. VAP (Velocity Average Path) Ortalama yol hızı: Bir sperm başının ortalama yol boyunca zamana göre ortalama hızı.
4. ALH (Amplitude Lateral Head) Sperm başının yanal genişliği: Sperm başının ortalama yola göre dış yana hareketinin boyutu.
5. LIN (LINEarity) Doğrusallık: Eğri çizgisel yolun doğrusallığı.
6. WOB (WOBble) Salınım hareketi: O anki sperm hareket yolunun ortalama yol etrafında salınım hareketinin ölçümü.
7. STR (STRaightness) Doğrusallık: Ortalama hareket yolunun doğrusallık derecesi.

8. **GB Gezdiği Bölge:** Birim zamanda sperm başının iki boyutlu koordinat düzleminde gezdiği bölgenin toplam alanıdır.

$$\text{VSL (Velocity Straight Line } (\mu\text{m/s)). } \quad VSLi = \frac{\sqrt{(X_m - X_1)^2 + (y_m - y_1)^2}}{(m-1)\Delta t} \quad (1.1)$$

$$\text{VCL (Velocity Curvi Linear } (\mu\text{m/s)). } \quad VCLi = \frac{\sum_{j=1}^m \sqrt{(x_{j+1} - x_j)^2 + (y_{j+1} - y_j)^2}}{(m-1)\Delta t} \quad (1.2)$$

$$\text{VAP (Velocity Avarage Path } (\mu\text{m/s)). } \quad VAPi = \frac{\sum_{j=1}^{m-1} \sqrt{(\bar{x}_{j+1} - \bar{x}_j)^2 + (\bar{y}_{j+1} - \bar{y}_j)^2}}{(m-1)\Delta t} \quad (1.3)$$

$$\text{ALH (Amplitude Lateral Head } (\mu\text{m)). } \quad ALH = \frac{2}{T_s} \sum_{i=k-n_s} |z_t(i) - z_8^t(i)| \quad (1.4)$$

$$\text{LIN (Linearity)} \quad LINi = \frac{VSLi}{VCLi} \quad (1.5)$$

$$\text{STR (Straightness)} \quad STRi = \frac{VSLi}{VAPi} \quad (1.6)$$

$$\text{WOB (A magnitude of fluctuation)} \quad WOBi = \frac{VAPi}{VCLi} \quad (1.7)$$

$$\text{GB (Gezdiği Bölge)} \quad GB = (x_{max} - x_{min}) * (y_{max} - y_{min}) \quad (1.8)$$

Bu terminolojideki ilk yedi öznitelik DSÖ'nün kitapçığında var olan ve neredeyse tüm otomasyonlu cihazlarda ve yazılımlarda kullanılan parametrelerdir. Sekizinci özellik ise bu tez çalışması kapsamında sunulan bir yenilik olup diğer yedi parametre gibi kullanılabileceği ispatlanmıştır. Geliştirilen bu terminolojideki ifadeler farklı otomasyon yazılımlarında farklı matematiksel denklemlere dayalı algoritmalar kullanılmasından dolayı tüm sistemlerin ölçüm kriterlerinin denklik düzeyi henüz bilinmemektedir. Ayrıca, yine bu nedenden ötürü farklı cihazların saptadığı değerler karşılaştırabilir düzeyde değildir. Belirlenen bu öznitelikler temel alınarak yumurtaya doğru hareket eden ve hızı bir eşik değerinden yüksek olan sperm sayısına göre dört sınıfa ayrılır [3, 7].

1. Sınıf a ($\geq 25 \mu\text{m/s}$) : Hızlı ileri; spermeler düz bir çizgide hızla ileriye doğru yüzer.
2. Sınıf b ($5 \mu\text{m/s} < \geq 25 \mu\text{m/s}$): Yavaş ileri; spermeler eğri ya da çarpık bir çizgi halinde ileriye doğru yavaş yüzer.

3. Sınıf c ($<5 \mu\text{m/s}$): İleri doğru olmayan hareketlilik; sperm kuyruklarını hareket ettirirler, ama ileriye doğru hareket etmezler.
4. Sınıf d: Hareketsiz; hiç hareket yoktur.

Sperm motilite sınıfının sınıf a, b, c veya d olarak belirlenmesi klasik analiz yönteminde VSL; otomasyonlu analiz sisteminde ise (VSL, VCL, VAP, ALH, LIN, STR, WOB) parametre verilerinin değerlendirilmesi ile yapılır. Otomasyonlu sistemler, kalite kontrolü için veriler sağlamada önemli bir rol oynasalar da klinik açıdan yararlarını göstermek için daha fazla araştırmaya gerek vardır [5]. Dolayısıyla sperm motilite sınıfının belirlenmesinde sperm hareketi ile oluşan öznelik parametrelerini giriş verisi olarak kullanıp yapay öğrenme tabanlı sınıflandırıcılar ile motilite sınıflandırmada verilere dayalı nicel ve anlamlı sonuçlara ulaşılabilir. Sınıflandırıcılar bir sistemin sonucu üzerindeki karmaşık örüntüleri algılayarak, verilerine dayalı akılcı kararlar alıp, belirlenen model ile veri kümesi üzerinde eğitim ve test aşamaları yaparlar. Böylelikle var olan verileri sınıflandırdıktan sonra gruba sonradan eklenen veriyi de en uygun sınıfa atayabilirler [8].

1.2. Tezin Amaç ve Organizasyonu

Bu tez çalışmasının temel amacı, video görüntülerinin analizinde Uç Öğrenme Makinesi (UÖM) sınıflandırıcı algoritmalarının kullanılması ve geliştirilmesidir. Geliştirilen bu Melez (M) - Diferansiyel Gelişim Algoritması (DGA) – (UÖM) yönteminin başarımını test etmek için elde edilmiş gerçek sperm videoları üzerinde sperm motilitesinin doğru sınıflandırılması çalışması yapılmıştır. Bu temel amaç ile aşağıda belirtilen özel ve somut amaçlara ulaşılması hedeflenmiştir:

1. Sperm hücresinin hareketi ile oluşan öznelik parametrelerini elde edebilecek en uygun ve efektif video analiz yöntemlerini tespit edebilmek,
2. Sperm hücresinin hareket sınıfının belirlenmesinde etkili olabilecek yeni öznelik parametreleri bulmak,
3. Sperm hareket öznelik parametrelerini UÖM yöntemini kullanarak sınıflandırıp, yapay öğrenme tabanlı motilitelerinin başarımlarını ortaya koymak,

4. UÖM yönteminin aktivasyon fonksiyonu ve gizli katmandaki hücre sayılarını DGA optimizasyon tekniği ile en uygun seçerek, UÖM yönteminin başarımının artırılmasını sağlamak,
5. Erkek infertilite probleminin çözümünde klinik açıdan etkili olacak yapay öğrenme tabanlı paket yazılımı oluşturmaktır.

Tez çalışması dört bölümden oluşmaktadır. Tez çalışmasının ikinci bölümünde tez süresince kullanılan materyaller ve metotlar anlatılmıştır. Üçüncü bölümde çeşitli örnek video setlerindeki sperm hücrelerinin UÖM ve M-DGA-UÖM sınıflandırıcıları tabanlı motilite sınıflandırma çalışmaları ve bu çalışmalar sonucunda elde edilen başarımları irdelenmiştir. Dördüncü bölümde ise tez çalışmasının sonuçları yorumlanmış ve literatüre olan katkısı tartışılarak önerilerden bahsedilmiştir.

1.3. Önceki Çalışmalar

Video analizi alanında yapılan çalışmalar

Hsia ve Guo [9] çalışmalarında düşük çözünürlüklü görüntünün şekil bilgisini elde etmek için ayrık dalgacık yapısını kullanıp hesaplama maliyetini azaltmak için verimli güvenilir bir yöntem önermişlerdir. Sonuç kısmında önerdikleri yöntemin çoklu nesne hareketi içeren düşük çözünürlüklü gerçek zamanlı iç ve dış ortamlardaki imgelerde başarılı olduklarını ortaya koymuşlardır. Subudhi vd. [10] videolarda hareketli nesne tespiti için hareketli yerlerin arka planını çıkarmada yerel değişiklikleri tespit etmeye yönelik yeni bir yöntem geliştirmişlerdir. Bu yöntemi geliştirirken üçü eski üçü yeni olmak üzere altı yerel özellikten faydalanmışlardır. Arka planın modellenip çıkarılması için benzersiz bir istatistiksel yöntem sunarak arka planın eğitim aşamasında bu istatistiksel yöntemi kullanmışlar. Hanchinamani vd. [11] hareketli nesnelerin tespiti için bir gömülü işlemci kitinde çalıştırılmak üzere hazırlanmış hızlı arka plan çıkarma tekniği önermişlerdir. Bu teknikte birinci aşamada videoyu çerçevelere çevirip yüksek konvülasyon filtresinden geçirerek yüksek frekanslı gürültüleri temizleyip düz imgeler elde etmişlerdir.

Düz imgelere adaptif eşik arka plan çıkarma algoritması uygulanarak hareketli nesneleri tespit etmişlerdir. Tespit edilen nesneler konvülasyon filtresinden geçirilip yapay piksellerden arındırılarak kaliteli imgeler elde edilmiştir. Jaraba vd. [12] dinamik

sahnelerdeki hareketli nesneleri tespit etmek için arka plan çıkarma tabanlı yeni bir yöntem önermişlerdir. Yöntemin temel amacı, değişen koşullar ve çevresel varyasyonlar gibi zorluklara karşı kalıcı bir arka plan görüntüsü tutabilmektir. Bu şekilde bir kalıcı arka plan tutabilmek için bir çift arka plan (uzun ve kısa süreli) kullanımı önermişlerdir. Tasarlanan sistem değişen çevre koşullarında ve hareketli arka plan öğelerinde efektif ve hızlı çalıştığı gözlemlenmiştir. Mahalingam ve Subramoniam [13] video analizinde nesne algılama bilgisayar uygulamaları arasında ilk adımdır. Mevcut nesne izleme yöntemlerinin temel dezavantajları eğer video yüksek hacimli bilgi içeriyorsa işlem kabul edilebilir zamanı aşmaktadır. Bu büyük veri hacmi için en uygun izleme tekniğini seçmede belirli sorunlar ortaya çıkarmaktadır. Ayrıca, izlenen nesne zaman içinde yönelimi değiştirdiğinde aynı anda birden çok nesneyi öngörmek zor olduğundan, durum daha da zor bir hal alır. Bu sorunların üstesinden gelmek için nesne tespiti ve hareket takibi için etkili bir yöntem önermek üzere yaptıkları çalışmalarında; önerdikleri teknik üç faza ayrılmıştır: algılama fazı, izleme fazı ve değerlendirme fazı. Algılama fazı ön plan bölütleme ve gürültü azaltma üzerine değerlendirme fazını içeren aşamadır. Etkin ön plan bölütleme için Adaptif Gauss Karışımı Modeli (AGKM) önerilmiştir. Nesne takibinin hareket ettirilmesi, izleme aşaması altında bulunan ikilik büyük nesne tespitiyle elde edilir. Sınıflandırma için verilen doku bazlı ve kaliteye dayalı özellikler çerçevelerden çıkarılır. Sınıflandırma için karar ağacı tabanlı sınıflandırıcı kullanılmıştır. Önerilen tekniğin performansı, hassaslık, kesinlik, f ölçüsü ve Alıcı İşletim Karakteristiği (AİK) ile analiz edilmiştir.

UÖM ve DGA alanında yapılan çalışmalar

Ertuğrul vd. [14] çalışmalarında elektromiyografi sinyalinin özelliklerini istatistiksel yöntemlerle çıkarmış, lineer ayırma analizi yaparak bu özelliklerin en belirleyici olanlarını tespit etmiş ve özellik vektörleri oluşturmuştur. Bu analitik özellik vektörleri UÖM ile sınıflandırmıştır. Çalışmada 10 normal 10 saldırgan harekete ait sekiz kanal sinyali örnek olarak kullanmıştır. Elde edilen sonuçları farklı özellik belirleme ve sınıflandırma metotları ile karşılaştırarak önerdikleri yöntemin başarısını tespit etmişlerdir. Kaya ve Tekin [15] Ayırık Dalgacık Dönüşümü (ADD) ile elde edilen istatistiksel özellikleri UÖM ile sınıflandırma işlemine tabi tutmuş. İki farklı veri kümesi için %100 başarı elde etmişlerdir. Bu başarı UÖM'nin diğer sınıflandırma yöntemlerine kıyasla hem hız hem de performans açısından üstün olduğunu ispatlamışlardır. Wang ve Li [16] UÖM'den

yararlanarak ürettikleri ve yeni bir yöntem olarak önerdikleri çalışmalarının, UÖM'ye oranla büyük veriler üzerinde daha hızlı öğrenebildiği iddia etmişlerdir. Yöntem UÖM'nin zayıf olarak görülen çıktılarına dinamik Adaboost topluluk algoritması uygular. UÖM'nin aktivasyon fonksiyonu olarak bulanık aktivasyon işlevini kullanır.

Deneyisel sonuçlar algoritmanın eğitim hızını büyük ölçüde artırdığını göstermektedir. Büyük veri kümesi üzerinde UÖM ve Quasi-Newton algoritması ile yapılan öğrenme, UÖM'den daha iyi genelleme performansına sahiptir. Albert ve Gül [17] videolarda eylem tanıma için yaptıkları çalışmalarında sık yörünge özelliklerini Fisher vektör kodlamasıyla birleştirerek yeni bir sınıflandırıcı olan UÖM'yi kullanarak geleneksel sınıflandırma yöntemlerinden çok daha başarılı bir yöntem geliştirmişlerdir. Das ve Suganthan [18] çalışmalarında genel olarak DGA'nın tanımı ve farklılık ve üstünlükleri üzerinde durarak bir araştırma yapmışlardır. Bu araştırmaya göre DGA'nın mevcut kullanımdaki en güçlü stokastik gerçek parametre optimizasyon algoritmalarından biri olduğunu DGA standart bir Gelişimsel Algoritma (GA) tarafından kullanılan benzer hesaplama adımlarıyla çalıştığı. Bununla birlikte geleneksel GA'lardan farklı olarak DGA varyantları mevcut nesil popülasyon üyeleri rastgele seçilmiş ve farklı popülasyon üyelerinin ölçeklenmiş farklılıkları olduğu. Bu nedenle yeni nesil üretmek için ayrı bir olasılık dağılımı kullanılmadığını belirtmişlerdir. Bazi vd. [19] çalışmalarında UÖM yaklaşımına dayalı hiperspektral görüntüler için etkili bir sınıflandırma yöntemi önermişlerdir. Bu yöntem UÖM ile ilişkili model seçim sorununu ele almak için otomatik çözüm tabanlı bir DGA optimizasyonu üzerine kurulmuştur. Basit ama güçlü evrimsel optimizasyon algoritması olan DGA, optimal UÖM parametrelerini belirlemek için çapraz doğrulama doğruluğunu bir performans göstergesi olarak kullanır. Hiperspektral görüntü veri setlerinden elde edilen deneyisel sonuçlar önerilen DGA-UÖM yönteminin üstün özelliklerini sınıflandırma doğruluğu ve hesaplama süresi açısından başarımının üstün olduğunu kanıtlamışlardır. Sönmez vd. [20] karayolu trafik akış gözetim görüntülerinde hareket eden nesnelerin anomali davranışlarını tespit ederek, verilerini sınıflandırma için UÖM yöntemini kullanmış elde ettikleri başarımları diğer sınıflandırma yöntemleri ile karşılaştırdıklarında UÖM'nin başarımları ve hız olarak üstün olduğunu tespit etmişlerdir. Yang vd. [21] çalışmalarında UÖM'nin son yıllarda ortaya atılmış başarımları yüksek bir yöntem olduğunu fakat başarımları sınırlayan etkenlerden biri olan gizli katmandaki hücre sayıları optimize için yeni bir yöntem önermişlerdir. Bu yöntem veriye göre rasgele atanan değerlerin başarımları arttırmak üzere bazı kriterlere göre sabit tutulması önermiştir.

Çeşitli veri setleri üzerinde yaptıkları denemelerde önerdikleri yöntemin başarımının yüksek olduğunu sunmuşlardır. Sönmez vd. [22] çalışmalarında UCI'deki Phishing Websites Data veri tabanında bulunan 30 adet özellik için UÖM tabanlı sınıflandırmasını yapmıştır. Sonuçları diğer yöntemler (DVM, NB) ile karşılaştırma yaparak UÖM'nin başarımı 95.34% ile en yüksek tespit etmişlerdir. Güldoğan vd. [23] çalışmalarında çeşitli çekirdek fonksiyonları ile oluşturulan DVM modellerinin, akut koroner sendromlu hastalarda diabetes mellitusu sınıflandırma performanslarının incelenmesi ve karşılaştırılmasını yapmışlardır. Bu çekirdek değiştirmeleri yine bir çeşit optimizasyon olarak değerlendirilebileceği ve değişik çekirdek fonksiyonları ile oluşturulan modeller arasında söz konusu performans ölçütleri dikkate alındığında, en iyi sınıflama performansı Laplace DVM modelinden elde edildiğini ifade etmişlerdir.

Bilgisayar destekli sperm analizi alanında yapılan çalışmalar

Amann ve Waberski [5] yaptıkları çalışmada otomasyonlu sistemlerinin 40 yıllık süreç içinde gelişimine yer vererek; bu sistemlerde kullanılan yazılım donanım yapıları hakkında bilgi vermişlerdir. Çalışmalarının son kısmında 2014 yılında otomasyonlu sistemin geldiği son durum hakkında ayrıntılı ve açıklamalı bilgilerin yanında modern bir otomasyona ait resimlere yer verilmiştir. Boryshpolets vd. [24] yaptıkları çalışmalarında otomasyonlu sistemlerde videoların alınma kriterlerini değiştirerek bu değişimlerinin sperm hareketliliğinin tespit edilmesinde başarımı nasıl etkilediğini tespit etmişlerdir. Chaudhari ve Pawar [25] Matlab yazılım ortamını kullanarak hibrit bir algoritma yaklaşımı ile sperm tanıma ve kimliklendirme işlemini yapmışlardır. Bu çalışmalarının birinci aşamasında bir videodan arka plan çıkarma işlemi yapmış; ikinci aşamasında ise alan tabanlı sınıflandırma yaparak kimliklendirme işlemini yapmışlardır. Goodson vd. [26] fare spermleri üzerinde yaptıkları çalışmalarında DVM sınıflandırıcısını kullanarak sperm hareketliliğini sınıflandırmışlardır. Kime vd. [27] yaptıkları çalışmalarında balık sperminin otomasyonlu sistem ile değerlendirilmesini ve yazılım sonucunda oluşan değerlerin yumurtayı döllemeleri hakkında yorumlarda bulunmuşlardır. Bu yorumlar için spermin kalitesi hareketi hızlılığı gibi kriterleri dikkate almışlardır.

Nafisi vd. [28] yaptıkları uygulamalı çalışmalarında sperm izleme ve sınıflandırma için bir şablon eşleme algoritması öne sürmüşlerdir. Pascual vd. [29] çalışmalarında basit etkili bir otomasyon programının bilgisayar görmesi yazılımı olarak nasıl ele alınması

gerektiđi hakkında yorumlarda bulunmuř. Bazı istatistiki deđerlerin nasıl kullanılabileceđi hakkında uygulamalı alıřmalar yapmıřtır. Ramon vd [30] iber kırmızı geyiklerinin donmuř spermeleri zerinde sınıflandırma iin yaptıkları alıřmalarında denetimli bir sınıflandırıcı olan DVM kullanmıřlardır. Bu sınıflandırıcının bařarımını diđer sınıflandırıcılara gre yksek bulmuřlardır.

Bu tez alıřmasında, yukarıda verilen konularla ilgili geliřtirilmiř algoritma, yazılım ve yntemler detaylı incelenmiřtir. Sperm motilite znitelik verilenin mikroskobik grntlerdeki videolarda; tespit yntemlerinin en iyisi GKM ve takip yntemlerinin ise genellikle Kalman Filtre-Macar Algoritması ikilisi zerine inřa edildiđi; sınıflandırma ile ilgili UM ynteminin diđer yntemlere kıyasla ok daha bařarılı olduđu gzlemlenmiřtir. Bu gzlemler yeni bir sperm znitelik parametresinin ıkarılabilir; sperm motilite sınıflandırmada yksek bařarıma sahip UM ynteminin kullanılabilir; DGA ile UM'nin bařarımını kısıtlayan gizli katman hcre sayısı ve aktivasyon fonksiyon seim iřleminin optimize edilebilir olduđu tespit edilmiřtir. Bylece sperm motilite analizi yapabilecek yapay đrenme tabanlı otomatik alıřan bir paket yazılım geliřtirilebilir olduđu saptanmıřtır.

2. MATERYAL VE METOT

Bu bölümde, tez çalışmasında incelenen probleme ilişkin önerilen üç aşamalı yöntemde kullanılan materyaller incelenmiştir. Bu aşamalardan birincisinde video analizinde arka/ön plan bölütleme ve nesne yörünge tahmin-atama yöntemleri; ikincisinde analiz verilerinden özellik çıkarma; üçüncü aşamada ise sınıflandırma için UÖM ile optimizasyon yöntemi DGA anlatılmıştır.

2.1. Problem Çözüm Süreci

Bu tez çalışmasının motivasyonunda var olan problemin çözülebilmesi için yaklaşım adımları aşağıdaki gibidir.

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

2.1.1. Problemin Tanımı

Problemin en geniş çerçevede tanımı yapılarak çözüme ilişkin oluşturulacak modelin amaç fonksiyonun ne olduğunu ortaya koymak, hedefin belirlenmesi için gerekli ilk adımdır. Bu tez çalışmasında, sperm hücresinin hareketi ile oluşan öznitelik parametrelerini video analiz yöntemleri ile tespit ederek; UÖM sınıflandırıcı ile sınıflandırmasında amaçlanan faydalar tezin amacı başlığı altında sıralanmıştır. Bu tez çalışması ile sperm hareketliliği içeren video analiz verilerinden elde edilen öznitelik parametrelerine göre sperm motilitesinin hangi sınıfa ait olacağı işlemine ilişkin problem çözülmeye çalışılmaktadır. Problemin ve ulaşılmak istenen çözümün daha iyi anlaşılması için UÖM sınıflandırıcı yöntemimizde kullanmış olduğumuz giriş ve çıkış verileri Tablo 2.1’de verilmiştir.

Tablo 2.1. Sınıflandırma yöntemi için giriş çıkış verileri

Giriş								Çıkış
VSL	VCL	VAP	ALH	LIN	STR	WOB	GB	Sınıf a, b, c, d

2.1.2. Veri Seti

Problemin tanımının anlaşılması ile analiz edilecek verinin türü, özellikleri ve nasıl toplanacağına karar verilmesi gerekmektedir. Veri toplama için üç tür yol olduğundan sözü edilebilir. Birincisi çeşitli amaçlar için kullanılmak üzere hazırlanmış ve açık erişim ile internet üzerinden dağıtılan veriler. İkincisi benzetim yapmak amacıyla sonuçların gerçek değerlere yakın olarak rasgele üretilmesi ile elde edilen sentetik veriler. Üçüncü veri toplama yöntemi ise problem gözlenen gerçek ortamlardan çözüme ulaşabilecek en uygun verilerin elde edilmesidir. Bu tez çalışması süresince kullanılan verilerin toplama biçimi yukarıda bahsedilen ikinci ve üçüncü yöntemlerden oluşmaktadır. Birinci yöntem yapılan veri tabanı taramalarında bu tez çözümünün amacına uygun videolar bulunmadığından elenmiştir. Veriler genellikle üçüncü yöntem ile Fırat Üniversitesi Veterinerlik Fakültesi Suni Tohumlama Laboratuvarından elde edilmiştir. İkinci yöntem de benzetim yapmak amacıyla sentetik veriler oluşturularak hazırlanmıştır.

2.1.3. Verinin Hazırlanması

Verilerin, modelde işlenmeden önce kullanılmak üzere hazır hale getirilmesi için özetlenmesi, temizlenmesi, dönüştürülmesi, indirgenmesi ve ayrıklaştırılması gerekmektedir [31]. Veri hazırlama için standartlaşmış yöntem silsilesi bulunmamaktadır, kullanılacak veri setlerine göre bu adımlar değişmektedir. Şekil 2.1’de mikroskobik kameradan videoların analiz edilmek üzere depolama aygıtlarına aktarıldıktan sonra OpenCV programının işleyebileceği video formatına 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 2.1. Video verisi hazırlama iş akış diyagramı

2.1.4. Modelleme

Veriler işlenmeye hazır hale getirildikten sonra öğrenme algoritması için modelleme aşaması, esas olarak görevin niteliklerine uygun olarak tanımlanmış çıktıya duyulan ihtiyacın mimarilendirilmesidir [31]. Bu tez çalışmasında sperm hücresinin hareketi ile oluşan öznitelik parametrelerini video analiz yöntemleri ile tespit ederek; motilitesinin sınıflandırma yapılmasında, verileri değerlendirmek için UÖM ve yeni bir yaklaşım olarak M-DGA-UÖM model olarak seçilmiştir. Modellerin çalışma algoritmaları ile ilgili bilgiler alt bölümlerde sunulmuştur.

2.1.5. Model Performans Değerlendirme Yöntem ve Ölçütleri

Yapay öğrenme algoritmalarının performans değerlerinin ölçülebilir bir ifade ile tanımlanması başarımlarının karşılaştırılması açısından önemlidir. Bu bölümde incelediğimiz konu iki kısımdan meydana gelir. Bunlar, kurulan modelin ve kullanılan algoritmanın performansına etki eden birinci ölçüt olan veri setinin eğitim ve test verisi olarak bölünmesi, ikincisi ise başarımlı ölçümleyen ifadelerin tanımlanmasıdır.


- *Birinci ölçüt:* Literatürde hold-out ve k-kat çapraz geçişleme gibi çeşitli veri bölme, performans değerlendirme yöntemleri bulunmaktadır [31, 32]. Veri setini eğitim ve test olarak ayırırken aşağıdaki maddeler dikkate alınmalıdır.
- Eğitim veri setindeki örnekler, sayıca test veri setindeki örneklerden fazla olmalıdır.
- Eğitim ve test veri seti ayrımında örneklerin rastgele dağılması gerekir.
- Veri setinin eğitim ve test veri seti olarak bölünmesi sırasında hedef niteliğine ait sınıfın eğitim ve test veri setlerindeki dağılımında hedefe ait verileri içermelidir.

Hold-out yönteminde veri seti eğitim ve test verisi olarak, Şekil 2.2'deki gibi iki eş olmayan parçaya ayrılır. Bu yöntemin bir diğer çalışma şekli ise tekrarlı kullanımdır.



Şekil 2.2. Hold-out veri bölme yöntemi

K-kat yönteminde ise üç aşamalı ayırma ile veri seti, Şekil 2.3'teki [33] gibi eğitim, doğrulama ve test verileri olmak üzere üç parçaya bölünerek model seçimi ve performans durumu aynı zamanda yapılır. Bu tez çalışması kapsamında kullanılan yapay öğrenme modelleri için veri setinin eğitim ve test verisi olarak bölünmesinde K-kat çapraz geçерleme yöntemi tercih edilmiştir.



Şekil 2.3. K-kat çapraz geçерleme veri bölme yöntemi

- *İkinci ölçüt:* Yapay öğrenme algoritmalarında üretilen çözümün başarımının ölçülmesi için performansının ifade edilmesi gereklidir. Bunun için farklı değeriendirme ölçütleri geliştirilmiştir.

Bu ölçütlerden sınıflandırma için geliştirilen ve bu tez çalışmasında kullanılanlar aşağıda açıklanmıştır. Veri setine uygulanacak olan sınıflandırıcı modellerin performans değeriendirilmesinin yapılabilmesi için hata matrisi oluşturarak aşağıdaki başlıklarda açıklanan doğruluk, duyarlılık, belirleyicilik, kesinlik ve f ölçüsü gibi kriterler hesaplanmıştır [31-34].

Tablo 2.2. Hata matrisi

		Gerçek Durum (Tespit)		
		Gerçek Pozitif (Evet)	Gerçek Negatif (Hayır)	Gerçek Toplam
Tahmini Durum	Tahmini Pozitif (Evet)	Doğru Pozitif (D_{poz})	Yanlış Pozitif (Y_{poz})	T_{poz}
	Tahmini Negatif (Hayır)	Yanlış Negatif (Y_{neg})	Doğru Negatif (D_{neg})	T_{neg}
	Tahmini Toplam	poz	neg	Top

Doğruluk değeri, doğru tespit ile algoritmanın doğru tahmin ettiği veri sayısının veri setindeki tüm verilere oranı olarak ölçülür.

$$Doğruluk = \frac{D_{poz} + D_{neg}}{Top} \quad (2.1)$$

Duyarlılık, değeri doğru pozitif tespitin tüm doğru ve yanlış pozitif tespitlere olan oranı olarak ölçülebilir.

$$Duyarlılık = \frac{D_{poz}}{poz} \quad (2.2)$$

Belirleyicilik, negatif tespitleri tahminin sınıflandırma başarımıdır. Değeri doğru negatif tespitlerin tüm negatif tespitlere olan oranı olarak ölçülebilir.

$$Belirleyicilik = \frac{D_{neg}}{neg} \quad (2.3)$$


Kesinlik, doğru tahminleri, tüm pozitif tespit ve tahminlere olan oranı olarak ölçülebilir.

$$Kesinlik = \frac{D_{poz}}{T_{poz}} \quad (2.4)$$

F-ölçüsü, duyarlılık ve kesinlik ölçülerinin uyumlu bir ortalamasıdır

$$F - \text{Ölçüsü} = \frac{2}{\frac{1}{Duyarlılık} + \frac{1}{Kesinlik}} \quad (2.5)$$


Alıcı İşletim Karakteristiği (AİK) eğrisi sınıflandırıcının tüm olası eşikler üzerinde performansını özetleyen, sık kullanılan bir grafikdir. Belirli bir sınıfa gözlem atanması eşiğini değiştirdiğinizde yanlış pozitif orana veya 1 - belirleyicilik değerine karşı gerçek doğru pozitif oranı veya duyarlılık değeri çizerek Şekil 2.4'teki gibi oluşturulur.



Şekil 2.4. AİK uzayının gösterimi


2.2. Uç Öğrenme Makinesi

Yapay sinir ağları (YSA) insanın beyni model alınarak sistemlerin basitleştirilmiş matematik modelleri olarak tanımlanabilir. Matematiksel modeller yeni olayları ve yeni işlemsel bağlantıları öğrenebilir. YSA temel eleman olan işlem veya düğüm denilen sinirlerden oluşurlar. Şekil 2.5'te [37] bir YSA modeli gösterilmektedir.



Şekil 2.5. YSA modeli

UÖM bir tek gizli katmana sahip ileri beslemeli bir YSA modelidir [14, 15, 35, 36]. 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, türevlenemeyen veya kesikli aktivasyon fonksiyonlarda kullanılabilmektedir [14, 15, 35-42]. Şekil 2.6'da UÖM mimarisi olan ileri beslemeli tek gizli katmanlı bir YSA modeli verilmiştir.



Şekil 2.6. İleri beslemeli tek gizli katmanlı bir YSA modeli

$$y(p) = \sum_{j=1}^m \beta_j g\left(\sum_{i=1}^n w_{i,j} x_i + b_j\right) \quad (2.6)$$

Denklem 2.6'daki x_i giriş y_p çıkış vektörlerini (m ve n nöron sayısı) ve $w_{i,j}$ giriş katmanı ile gizli katman arasındaki ağırlıkları, β_j çıkış katmanı ile gizli katman arasındaki ağırlıkları b_j gizli katmandaki nöronların biası $g(.)$ aktivasyon fonksiyonu ifade eder. Eşitlikteki giriş katmanı ağırlıkları ($w_{i,j}$) ve bias (b_j) değerleri rastgele atanır. Aktivasyon fonksiyonu ($g(.)$) giriş katman nöron sayısı (n) ve gizli katman nöron sayısı (m) başlangıç adımıyla atanır. Şimdi bu bilgilere dayanarak eşitlikte bilinen parametreler bir araya getirilip yeniden düzenlenirse çıkış katmanı Denklem 2.8'deki gibi olur.

$$H(w_{i,j}, b_j, x_i) = \begin{bmatrix} g(w_{1,1}x_1 + b_1) & \cdots & g(w_{1,m}x_m + b_m) \\ \vdots & \ddots & \vdots \\ g(w_{n,1}x_n + b_1) & \cdots & g(w_{n,m}x_m + b_m) \end{bmatrix} \quad (2.7)$$

$$y = H\beta \quad (2.8)$$

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 2.8’de bilinmeyen parametre sadece β 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 (β) bulunması problem olacaktır. Bu durumu aşmak için Huang vd. [35, 36] bu problemde olduğu gibi tersi alınamayan 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 [14, 15, 35-42].

2.3. Diferansiyel Gelişim Algoritması

Yüksek boyutlu değişken sayısına bağlı olarak doğrusal olmayan, gürültülü, çok modlu ve değişmeme özelliğine sahip problemlerin çözümüne ilişkin sunulmuş bir gelişimsel optimizasyon algoritması olan DGA genetik algoritma-popülasyon tabanlı optimizasyon tekniğidir [43, 44, 45, 47]. DGA, polinomal uyum problemini çözmek üzere Kenneth Price tarafından geliştirilmiştir [46]. Genetik algoritma optimizasyonu çaprazlama, karşılaştırma ve mutasyon işlemlerini ayrı basamaklarda gerçekleştirir. Dolayısıyla her bir basamakta geçen süre toplamsal olarak değerlendirildiğinde uzun zaman almaktadır. DGA’da temel olarak bu dezavantajın giderilmesi amaçlanmıştır. 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. Özet olarak DGA başlangıç popülasyonundaki en iyi kromozomu 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 [43-47]. Tablo 2.3’de bu dört temel adımın DGA’da ifade edilme biçimi verilmiştir.

Tablo 2.3. Diferansiyel Gelişim Algoritması

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.
2: Başlangıç popülasyonunu oluştur. $\forall i \leq NP \Delta \forall j \leq D : x_{i,j,G=0} = x_j^{(lo)} + rand_j[0,1]. \{ (x_j^{(hi)} - x_j^{(lo)}) \}$ (Durdurma şartı sağlanıncaya kadar)
3: Mutasyon, Çaprazlama $r_1, r_2, r_3 \in \{1,2, \dots, NP\} \ r_1 \neq r_2 \neq r_3 \neq i \quad j_{rand} \in \{1,2, \dots, D\}$ $\forall j \leq D, u_{j,i,G+1} = \begin{cases} x_{j,r_3}G + F(x_{j,r_1}G - x_{j,r_2}G) & \text{eğer } (rand_{j[0,1]} < CR \Delta j = j_{rand}) \\ x_{j,i}G & \text{diğer durumlarda} \end{cases}$
4: Karşılaştırma (Seçim) $\bar{x}_{i,G+1} = \begin{cases} \bar{u}_{i,G+1} & \text{eğer } f(\bar{u}_{i,G+1}) \leq f(\bar{x}_{i,G}) \\ \bar{x}_{i,G} & \text{diğer durumlarda} \end{cases}$

Algoritmada geçen parametreler aşağıdaki gibidir.

NP : Populasyon büyüklüğü (Kromozom sayısı) $NP \geq (1,2 \dots i)$

D : Değişken sayısı (gen sayısı) $(1,2 \dots j)$

CR : Çaprazlama oranı $[0,1]$

G : Jenerasyon $(1,2 \dots G_{max})$

F : Ölçekleme faktörü

$x_{i,j,G}$: G jenerasyonunda, i kromozomunun j parametresi (gen)

$x_j^{(hi)}, x_j^{(lo)}$: değişkenlere ait alt üst sınırları

- *Başlatma*: NP adet (3'ten büyük olmalı) D boyutlu kromozomdan meydana gelen başlangıç popülasyonunun üretimi aşağıdaki gibidir:

$$\forall i \leq NP \Delta \forall j \leq D : x_{i,j,G=0} = x_j^{(lo)} + rand_j[0,1].\{(x_j^{(hi)} - x_j^{(lo)})\} \quad (2.9)$$

- *Mutasyon*: Mutasyon, kromozomun genleri üzerinde rasgele değişiklikler yapmaktır. Bu değişiklikler sayesinde kromozomunun temsil ettiği çözüm noktası, çözüm uzayında hareket etmektedir. Mutasyonun hedefine ulaşabilmesi için, doğru yönde doğru miktarda hareketi sağlayacak değişikliklerin belirlenmesi gerekir. DGA'da mutasyona tabi tutulacak olan kromozom dışında ve birbirlerinden farklı olan üç kromozom seçilir r_1, r_2, r_3 . İlk ikisinin farkı alınır ve F parametresiyle çarpılır. F genellikle 0-2 arasında değerler almaktadır. Ağırlıklandırılmış fark kromozomu ile üçüncü kromozom toplanır.

$$r_1, r_2, r_3 \in \{1,2, \dots NP\} r_1 \neq r_2 \neq r_3 \neq i, j_{rand} \in \{1,2, \dots D\} \quad (2.10)$$

- *Çaprazlama*: Elde edilen fark kromozomu ve $x_{i,G}$ kromozomu kullanılarak yeni deneme kromozomu u_i $G+1$ üretilir. Deneme kromozomuna genler CR olasılıkla fark kromozomundan $1 - CR$ olasılıkla mevcut kromozomdan seçilir. $j = j_{rand}$ koşulu, en az bir tane genin üretilen yeni kromozomdan alınmasını garanti etmek için kullanılmaktadır.


$$\forall j \leq D_{u_{j,i,G+1}} = \begin{cases} x_{j,r_3}G + F(x_{j,r_1}G - x_{j,r_2}G) & \text{eğer } (rand_{j[0,1]} < CR\Delta j = j_{rand}) \\ x_{j,i}g & \text{diğer durumlarda} \end{cases}$$

(2.11)

- *Karşılaştırma (Seçim)*: Seçim operatörü ile mevcut jenerasyon ve üretilen yeni kromozomlar değerlendirilerek yeni jenerasyon oluşturulur. Kromozomların yeni jenerasyonda yer alma olasılıkları uygunluklarına bağlıdır. DGA'da karşılaştırma birebir yapıldığından seçim için karmaşık prosedürü olan seçim operatörlerine ihtiyaç duyulmamaktadır. Karşılaştırılan kromozomlardan uygunluğu yüksek olan kromozom yeni jenerasyonun bireyi olarak atanmaktadır.

$$\bar{x}_{i,G+1} = \begin{cases} \bar{u}_{i,G+1} & \text{eğer } f(\bar{u}_{i,G+1}) \leq f(\bar{x}_{i,G}) \\ \bar{x}_{j,g} & \text{diğer durumlarda} \end{cases} \quad (2.12)$$

- Döngü $G = G_{max}$ olana kadar devam ettirilmektedir. $G = G_{max}$ olduğunda mevcut en iyi birey çözümdür. Algoritmanın durdurulması kriteri olarak, popülasyondaki en iyi ve en kötü uygunluk değerleri arasındaki farkın çok küçük bir rakama ulaşması olarak da belirlenebilmektedir [43-47].



SEÇİM:
Mevcut kromozomla yeni
kromozomdan uygunluğu daha
iyi olan yeni popülasyonun bireyi
olarak seçilir

	Kromozom 1	Kromozom 2	Kromozom 3	Kromozom 4	Kromozom 5	Kromozom 6
Uygunluk değeri	29					
Değişken 1	1*					
Değişken 2	3*					
Değişken 3	5*					
Değişken 4	11#					
Değişken 5	9#					


Yukarıdaki şemada DGA optimizasyon yönteminin veri üzerinde başlatma, mutasyon, çaprazlama ve seçim adımları gösterilmiştir. Kromozomlar tek tek ele alınmakta, rasgele seçilen diğer üç kromozomda kullanılarak yeni bir birey elde edilmektedir. Bu işlemler sırasında mutasyon ve çaprazlama operatörleri kullanılmış olmaktadır. Mevcut kromozomla elde edilen yeni kromozomun uygunlukları karşılaştırılarak uygunluğu daha iyi olan, yeni birey olarak bir sonraki popülasyona aktarılmaktadır. Böylelikle seçim operatörü de kullanılmış olmaktadır. Üretilen çözümlerin kalitesi, amaç fonksiyonuna ürettikleri değerle ölçülmektedir [43].

2.4. Video Analizi

Video, imgelerin saniyede 30/60/90 adet olacak şekilde arka arkaya sunulması ile insan gözünde bu imgelerdeki nesnelerin hareketliymiş izlenimi yaratması mantığına dayanan ardışık imge dizisi olarak tanımlanır [49, 50, 53]. Video analizi ise görüntüleme donanımları ile elde edilen verilerin çeşitli görüntü işleme teknikleri kullanarak bilgi elde edilmesi olarak tanımlanabilir [49, 53]. 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 [48, 49, 50, 53, 55].

Videolarda hareketli nesnelerin tespiti için arka plan çıkarma teknikleri genel yaygın kullanılan yöntemlerdir. Tüm algoritmaların başarımını etkileyen ortak özelliği arka plan imgesinin başlatılması ve güncellenmesi işlemidir. Bu adımların hassas olması, sonucu doğrudan etkilemektedir. Başlangıç periyodunda görüntülerin ortalaması alınarak oluşturulan bir referans arka plan görüntüsünden piksel piksel hareketli görüntünün çıkarılmasıyla hareketli bölgelerin tespit edilmesine çalışılır. Belirli eşik değerinin üzerinde olan piksel varyasyonları hareketli nesne olarak kategorize edilir. Bu işlemler yapılırken özellikle gerçek zamanlı uygulamalarda arka plan çıkarma algoritmalarının hesaplamalı olarak ekonomik ve az bellek gereksinimine sahip olmalıdır. Algoritmaların ortak olumsuz yanı değişen çevre şartlarına (hava, ışık değişimi gölge vb.) uyumlu ve duyarlı olmadığıdır. Aşağıdaki Şekil 2.7’de arka plan çıkarma algoritmalarının dört ana işlem adımı gösterilmiştir.



Şekil 2.7. Arka plan çıkarma algoritmalarının iş akış diyagramı

2.4.1. Hareketli Nesne Tespiti

Videoda analiz hareketin tespitiyle başlar. Hareketli nesne tespiti, nesneye ait bölgenin imgedeki diğer (hareketsiz) bölgelerden ayrıştırılması prensibine dayanır [48, 53]. 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. Bu tez çalışması boyunca geliştirilen uygulamada hareketli nesne çıkarma yöntemi Gauss Karışım Modeli (GKM) kullanılmıştır. GKM videoların analizi için iyi performans göstermiş ve oldukça popüler bir Arka Plan Çıkarma (APÇ) algoritmasıdır. Yöntem düşük ışık değişimlerinin üstesinden gelebilse de, ani ışık ve gölgelerdeki hızlı değişimlerde düşük performans göstermektedir. Bu sorunların üstesinden gelmek için birçok araştırmacı, GKM yöntemine dayalı birçok uygulama geliştirmişlerdir. Kaewtrakulpong ve Bowden [69], bu modeldeki güncelleme denklemlerini değiştirerek sistemin ışık değişkenlerine uyumlanmasını iyileştirmeyi önermiştir. Daha sonra Tuzel vd. [70] tarafından katman modeli üç boyutlu olan çok değişkenli Gauss dağılımına dayanan model sunulmuştur. Yöntem öz yinelemeli bir Bayes öğrenme yaklaşımıyla, model ortalamasının değişim dağılımını tahmin edebilmektedir. Chen vd. [66] GKM ile bir karışıklık histogramını birleştiren hiyerarşik ve blok tabanlı bir algoritma önermişlerdir. Zivkovic [67] her piksel için doğru Gauss dağılımı sayısını sabitlemek yerine otomatik olarak hesaplayarak piksellerin içeriklerini tanımlamak için sadece renk kullanmak yerine özelliklerinin bir birleşimini kullanmıştır [49, 54, 58-65].

2.4.1.1. Gauss Karışım Modeli

Tekli Gaussian modeli dış mekan sahneleri için iyi bir model olmadığından dolayı, arka plan çıkarma için [63] ve [64] tarafından önerilip geliştirilen yöntem piksel renginin belli bir renk uzayındaki ağırlıklı Gauss dağılımlarının ağırlıklı toplamı ile ifade edilir. Modelde piksel yoğunluk fonksiyonun 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 fonksiyonunun 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 2.13'teki bağıntı elde edilir.

$$\sum_{j=1}^K P(j) = 1 \quad (2.13)$$

X elemanının j . sınıfa ait olma olasılığına $P(x|j)$ denilirse, bu olasılığın Gauss dağılımı Denklem 2.14'deki gibi olur.

$$P(x|j) = \frac{1}{\sqrt{(2\pi)\sigma_j^2}} e^{-\frac{(x-\mu_j)^2}{2\sigma_j^2}} \quad (2.14)$$

Bu eşitlikte, x sınıflandırılacak veri, j aidiyetine bakılan sınıf, μ söz konusu sınıfın ortalaması ve σ ise söz konusu sınıfın varyansını göstermektedir. Bu durumda sınıflandırılmak istenilen bir x parçacığının j sınıfına hangi oranda ait olabileceği Denklem 2.15'teki gibi bulunabilir.

$$P(x|j) = \frac{P(x|j)P(j)}{\sum_j P(x|j')P(j')} \quad (2.15)$$

O halde bütün x parçacıklarının söz konusu sınıflara ait olma ihtimali bütün x 'ler için Denklem 2.15'teki olasılıkların toplamıdır. Bu olasılığı en yüksek yapacak sınıf ortalamalarının ve varyanslarının ne olacağı bulunduğu sınıflama işlemi yapılmış olur. Yöntemin matematiksel bileşenleri kullanılarak arka plan modelleme için formülleri aşağıdaki gibidir. Herhangi bir t anında, I_m imge dizisi, belirli bir $\{x_0, y_0\}$ pikseline ait geçmiş, Denklem 2.16 ile ifade edilir.

$$\{X_1, \dots, X_t\} = \{I_m \{x_0, y_0, i\} : 1 \leq i \leq t\} \quad (2.16)$$

Her piksel için $\{X_1, \dots, X_t\}$ geçmiş bilgilerinden yararlanılarak her piksel için K adet Gauss dağılımı modellenir. Bir piksel için olasılık değeri Denklem 2.17’de görüldüğü gibi hesaplanır.

$$P(X_t) = \sum_{i=1}^K \omega_{i,t} * \eta(X_t, \mu_{i,t}, \Sigma_i, t) \quad (2.17)$$

Denklem 2.17’de K dağılım sayısını, $\omega_{i,t}$ t zamanındaki i . Gauss dağılımının ağırlığını, $\mu_{i,t}$ t zamanındaki i . Gauss dağılımının ortalamasını, Σ_i, t t zamanındaki i . Gauss dağılımının kovaryans matrisini, η ise Gauss olasılıksal yoğunluk fonksiyonunu ifade eder.

Bu dağılımlardan deneysel olarak belirlenen ilk p adedi arka plan, p ile K arasında kalan adedi de ön plan olarak kabul edilir. Yeni gelen piksel dağılımı hangi sınıfa daha yakınsa, o sınıfa ait olarak kabul edilir. Yönteminde kullanılan değişkenler Denklem 2.17’deki eşitliğe göre adım adım aşağıdaki gibi ifade edilir.


- X_t bir pikselin t zamanındaki piksel yoğunluğunu temsil eder ve pikselin geçmişi $\{X_1, \dots, X_t\}$, Gauss’un K dağılımlarının bir karışımı kullanılarak modellenmiştir.
- K , piksel geçmişini modellemek için Gauss kümelerinin sayısını temsil eder.
- $\omega_{i,t}$ t zamanında küme i ile ilişkili ağırlık faktörü.
- η Gauss piksel yoğunluk fonksiyonu.
- $\mu_{i,t}$, ve Σ_i, t j . Gauss kümesinin ortalama ve kovaryans matrisidir

Başlangıçta her sınıfın ortalama değeri, standart sapmaları ve ağırlıkları rastgele belirlenir. Her adımda bu değerler iteratif olarak güncellendiğinden yöntem işlem yükü ağır olan bir algoritmadır [51-54, 55-59].

2.4.2. Hareketli Nesne Takibi

Hareketli nesne takibi görsel gözetim sistemlerinde tespit edilen nesnelerin izlenmesidir. Her izleme yöntemi, nesne videoda ilk görüldüğü andan itibaren bir tespit mekanizması gerektirir. Bir önceki bölümde bir nesnenin nasıl tespit edileceğine ilişkin çeşitli yöntem ve algoritmalar incelenmiştir. 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. Nesne takip yöntemleri, genel özellikleri bakımından literatürde Şekil 2.8’de gösterildiği gibi nokta tabanlı, çekirdek tabanlı ve silüet tabanlı olmak üzere üç başlık altında toplanmıştır [49, 50, 55-62, 68].




Şekil 2.8. Hareketli nesne takip yöntemleri

2.4.2.1. Nokta Tabanlı

Ardışık çerçevelerde algılanan nesneler noktalarla temsil edilir; yöntem önceki nesne durumunu, konumunu ve hareketini içerecek şekilde noktaların ilişkilendirilmesine dayanır. İlk pozisyon bilgisinin elde edilmesi nesnenin nokta tabanlı ifade edilmesini sağlar. Pozisyon bilgisi genellikle izlenen nesnenin merkezi veya köşe noktalarıdır. Nokta benzerliğinin ilişkisinin kurulabilmesi işlemi; hatalı tespit, nesnenin imgeye giriş çıkışı ve nesne görüntüsünün kaybolması gibi problemler, nesne izlemeyi zorlaştırır. Nokta tabanlı nesne izleme yönteminin önündeki problemlerin çözümü için sunulmuş çözümler Deterministik (belirleyici) ve istatistiksel yöntemler adı altında toplanmaktadır. Deterministik yöntemler, benzerlik problemini sınırlamak için nitel hareket bilgilerini kullanır. İstatistiksel yöntemler ise nesne ölçümlerini kullanarak nokta benzerliğinin kurulmasında belirsizlikleri gidermeye çalışır. Deterministik yöntemler imgede herhangi bir hareketlinin bir nesne ile ilişkilendirilmesinin maliyetini tanımlamaktadır. Maliyetin en aza indirgenmesi bir optimizasyon problemi olarak ele alınır; ve literatürde çözüm için Macar ve Aç Gözlü Algoritma gibi optimizasyon yöntemleri önerilmiştir. Bu işlemi yaparken nesne hareketleri üzerinde aşağıda Şekil 2.9’da gösterilen ve tanımları yapılan sınırlamalar bulunmaktadır [50, 55, 68].

- *Yakınlık*: nesnenin konumunun bir kareden diğerine geçişte değişmeyeceğini varsayar.
- *Maksimum hız*: nesne hızında bir üst sınır tanımlar ve nesne etrafındaki dairesel ortama olası ilişkilendirmeleri sınırlar.
- *Küçük hız değişikliği*: (pürüzsüz hareket-yumuşatma) nesnenin yönünün ve hızının büyük ölçüde değişmediğini varsayar.
- *Genelleme hareketi*: Küçük bir ortamda nesnelerin hızını kısıtlar bu kısıtlama, birden çok noktayla temsil edilen nesneler için uygundur.
- *Sertlik*: Gerçek dünyadaki nesnelerin katı olduğunu varsayar, bu nedenle gerçek nesnedeki herhangi iki nokta arasındaki uzaklık değişmeden kalır.
- *Proksimal tekdüzelik*: Yakınlık ve küçük hız değişim kısıtlamalarının bir kombinasyonudur.



Şekil 2.9. Farklı hareket kısıtları A:Yakınlık, B:Maksimum hız, C:Küçük hız değişikliği, D: Genelleme hareketi, E:Sertlik

Bu kısıtlamaların sadece deterministik yöntemlere özgü olmadığını istatistiksel yöntemlerde de bu kısıtlamaların olabileceği söylenebilir [50]. Video analizi işleminin ilk basamağı olan hareketli nesne tespiti ile ilgili arka plan çıkarma yöntemleri önceki bölümde incelenmiştir. Bu bölümde arka plan çıkarmanın önündeki zorlukların biri de videodaki gürültülerdir. Gürültü: titreşim, sıkıştırma ve sensör gürültüsü olarak sıralanabilir. İstatistiksel yöntemler bu olumsuzluklara rağmen nesnenin durum tahminini gerçekleştirebilmek için güncel ölçüm değerlerini (güncel pozisyon, hız veya ivme) ve model belirsizliklerini kullanabilmektedir. Ölçümler genellikle bir algılama mekanizması tarafından elde edilen görüntüdeki nesne pozisyonundan oluşur. Ölçümlerin yalnızca sahnedeki tek bir nesnenin varlığı nedeniyle ortaya çıkması durumunda, sonraki durum tanımlanan iki adımla kolayca tahmin edilebilir. Eğer sahnede birden çok nesne varsa ölçümlerin ilgili nesne durumlarıyla ilişkilendirilmesi gerekir [50, 68]. İzlenen sahnede tek nesne olması durumunda, sistem fonksiyonları Gauss dağılımına sahip ise en uygun durum

tahmini Kalman Filtresi tarafından verilir. Gauss dağılımına sahip olmayan sistemler Kalman Filtresi yerine Gauss dağılım gerektirmeyen Parçacık Filtresi kullanılır.

Kalman ve Parçacık Filtresi yöntemleri herhangi bir t anında sahnede sadece bir nesnenin durumunu tahmin edebilmektedir. Görüntü dizisinde hareket eden nesne sayısının birden fazla olması durumunda çoklu nesnelerin takibi için veri ilişkilendirilmesi ve durum tahmini çözümünü bir arada sunan yöntemlere ihtiyaç vardır. Hedef nesne sayısının ve ölçüm bilgisinin belli olmaması veya zaman içerisinde bu sayının değişime uğraması veri ilişkisi problemini doğurmaktadır. Karayolu trafik akışının izlendiği sabit kamerada görüş açısı içeresine giren çıkan araç sayısı, nesnelerin üst üste binmesi ve hedef nesne sayısının net bilinmemesi veri ilişkisi problemine örnek olarak gösterilebilir. Veri ilişkilendirme problemi, nesne takibi işleminin başarısını doğrudan etkilemektedir. Bu sorunun üstesinden gelmek için Ortak Olasılık Veri İlişkilendirme (OOVİ) filtresi ve Çoklu Hipotez İzleme (ÇHİ), yaygın olarak kullanılan iki yöntemdir. OOVİ, hedefe yönelik bir yaklaşımdır yani bilinen bir dizi hedef için ölçme olasılıklarını değerlendirir ve bunları ilgili durum tahminlerinin tümünü kullanarak gerçekleştirir. OOVİ algoritması, iki karede izlenen sabit sayıda nesnenin veri ilişkisini gerçekleştirdiğinden nesnelerin sayısında bir değişiklik olduğunda hata oluşma ihtimali yüksektir. ÇHİ ise her bir ölçüm değeri, önceden oluşturulan izlerden sadece biri ile ilişkilendirilir; dolayısıyla nesne sayısının artmasında hata olması ihtimalini düşürür [50, 55, 68].

Kalman Filtre yöntemi bu tez çalışması boyunca geliştirilen uygulamalarda çoklu nesne takibi için durum tahmininde kullanılmıştır. 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 tahminin yapılabilmesi için yeterli olmasıdır. 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 [50, 68]. 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 ω tahmin hatası vektörüdür. Durum vektörü ve ölçümler arasında doğrusal bir ilişki olduğunu varsayılmaktadır.

$$X_k = (x_c \ y_c \ v_x \ v_y) \quad (2.18)$$

$$X_k = AX_{k-1} + \omega_{k-1}$$

$$A = \begin{bmatrix} 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (2.19)$$


$$Z_k = HX_k + v_k \quad (2.20)$$

$$H = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} \quad (2.21)$$


Burada H , gözlem matrisidir ve v , ölçüm hatasıdır. Geçiş ve gözlem matrisinin bu değerlerini kullanarak, Denklem 2.20’te verilen zaman güncelleme ve ölçüm güncelleme denklemleri bir sonraki nesne durumu tahminini verir [55, 56].

3. UYGULAMA

Bu tez çalışmasında incelenen probleme ilişkin önerilen yöntemde kullanılan materyaller önceki bölümlerde incelenmiştir. Bu materyaller video analizinde arka/ön plan bölütleme ve hareketli nesne yön tahmin-tespit; sperm video analiz verilerinden hareket öznitelik parametreleri çıkarma ile hareketlilik sınıflandırma yöntemleridir. Bu uygulamada sperm motilitelerinin sınıflandırılmasında, verilere dayalı kantitatif sonuçlar elde etmek için UÖM ve M-DGA-UÖM sınıflandırıcı yöntemleri kullanılmıştır. Sunulan yeni yöntemler ile sperm motilite sınıfının a, b, c veya d olarak belirlenmesinde özgün bilimsel verilere dayalı sonuçlar elde edilerek alternatif bir çalışma yapılmıştır. Çalışmada, gerçek ve sentetik sperm hareket öznitelik parametre verilerinin istatistiksel değerleri giriş olarak kullanılıp, çıkışta sperm motilite sınıflandırması UÖM ve M-DGA-UÖM sınıflandırıcıları ile yapılmıştır. Donanım ve yazılım olarak tasarlanan sisteme ilişkin blok diyagram Şekil 3.1’de verilmiştir. Sistemin donanım düzenek şeması Şekil 3.2’de verilmiştir.



Şekil 3.1. Önerilen yöntemin blok diyagramı



Şekil 3.2. Sistemin donanım düzeneği

Donanım bir mikroskop ve mikroskoba bağlı dijital kameradan oluşmaktadır. Semen örnekleri makler adı verilen ikili optik cam sistemli, üst camın üzerinde kamara derinliği 10μ olan $0,1 \times 0,1$ mm karelik 100 ızgaradan oluşan bir yapıdadır. Işık yada invert kullanılabilen mikroskop ise 20X ile 100X arasında değişen optik yakınlaştırmaya sahiptir. Bu donanım yapısında semen örneği bir pipet yardımı ile makler kamaranın merkezine liküfiye (çözülmüş) homojen olarak konulup kapak camı kapatılır. Mikroskop uygun optik yakınlaştırma değerine getirilerek yüzen sperm hareketleri dijital video kamera yardımı ile bilgisayara aktarılır.


Tez çalışmasının alt bölümlerinde belirtilmiş olan video analiz, özellik çıkarma ve UÖM, M-DGA-UÖM sınıflandırma süreçleri takip edilerek uygulamaların nasıl sonuçlandırıldığı ve başarımlarının ölçütlerinin neler olduğu ayrıntılı olarak irdelenmiştir.



3.1. Uygulama Sonuçları


Tezin bu bölümünde yapılan çalışmaların sonuçları ve başarımları üç aşamada incelenmiştir. Birinci aşamada, arka/ön plan bölütleme için GKM ve nesne yörünge tahmin-atama için Kalman Filtre-Macar algoritması yöntemleri kullanılarak videoda tespit edilen sperm hücre tespit başarımları verilmiştir. Bu başarımların değerleri Tablo 3.1’de verilmiştir. Şekil 3.3’te ise oluşturulan video veri tabanındaki bir video setine ait örnek çerçeveler gösterilmiştir.

Tablo 3.1. Tespit edilen sperm hücre sayısı video analiz başarımları.

Video No	Yazılımın tespit ettiği adet	Göz ile ölçüm adedi	Başarım
1	261	253	%96.84
2	224	231	%96.97
3	269	271	%99.27
4	268	274	%97.82
5	346	355	%97.47
6	198	191	%96.34
7	192	206	%93.21
8	365	362	%99.18
9	356	374	%95.19
10	388	381	%98.17
Toplam	2867	2898	Ortalama Başarım %98.94







Şekil 3.3. Video veri setine ait örnek çerçeveler

İkinci aşamada, özgün formüller kullanılarak oluşturulan yazılım ile sperm hareket öznitelik parametre verileri tespit edilmiştir. Üçüncü aşamada ise incelenen her bir videoya ait giriş, çıkış verileri kullanılarak elde edilen UÖM ve M-DGA-UÖM yöntemleri sınıflandırma başarımları verilmiştir. Ayrıca önerilen UÖM ve M-DGA-UÖM yöntemlerinin başarımlarının değerlendirilmesi için aynı veriler YSA, DVM ve Naive Bayes (NB) sınıflandırıcıları ile de sınıflandırılarak, karşılaştırma işlemi gerçekleştirilmiştir. Bu karşılaştırma işlemi ile elde edilen sonuçlar Tablo 3.6’ da verilmiştir. Bu sonuçlar MATLAB 2016 yazılımı ve Intel i5-6400 CPU, 16 GB RAM’e sahip bilgisayar ile elde edilmiştir.

3.1.1. UÖM ile Sınıflandırma Sonuçları

Tablo 3.3’te UÖM yöntemi ile video setleri için çıkarılan sperm hareket öznitelik parametrelerine göre sınıflandırma sonuçları verilmiştir. Veri seti bölmede K-kat çapraz veri bölme yöntemi kullanılmıştır. UÖM’nin gizli katmandaki hücre sayısı ve aktivasyon fonksiyonu için kullanılan değerler Tablo 3.2’ de verilmiştir. Dene-Yanıl yöntemi ile denenerek elde edilen sonuçlardan maksimum (% 100’ e yakın) olan doğru sınıflandırma başarımları verilmiştir. Veri setindeki sperm öznitelik parametrelerinin tümü veya her

birinin giriş, motilite sınıfının çıkış olması ile test veya doğruluk başarımı UÖM algoritmasında %79.49'dur. Buradan, kullanılan UÖM sınıflandırıcısının her 100 veriden 79 tanesini doğru sınıflandırdığı sonucuna varılır. Tablo 3.3'teki sonuçlardan da görüleceği üzere GB parametresine göre sınıflandırma başarımı en yüksek çıkmıştır. Bu durum, sperm hareket öznelik parametrelerinin terminolojisine bu tez çalışması kapsamında sunulan GB parametresinin tek başına giriş olarak alınması halinde bile diğer parametrelere göre daha doğru bir sınıflandırma yapılabileceğini gözlemlenmiştir. Spermilerin yumurtaya doğru yüzme hareketinin kaynağı sahip oldukları enerjidir. Sperm ister geri-ileri ister yukarı-aşağı yönlü yüzün; gezebileceği alan ve gidebileceği nokta enerjisine bağlıdır. Literatürde var olan tüm parametreler spermin ileri doğru hareketinin varyasyonları ile ölçüm yapmaktadır. GB ise bu hareketin kaynağı olan enerjiyi ve enerjiye bağlı hareketi ölçümleyen bir parametre olduğu düşünülmektedir.

Tablo 3.2. UÖM parametreleri.

Gizli katmandaki hücre sayısı 1, 2, 5, 7, 15, 25, 40, 50, 75, 100
Aktivasyon fonksiyonu: sigmoid (sig), sinüs (sin), hard limit (hardlim), triangular basis (tribas), radial basis (radbas) ve linear (lin)


Tablo 3.3. UÖM sınıflandırma başarımları.

Giriş (Sperm öznelik parametresi)	Gizli katmandaki hücre sayısı	Aktivasyon fonksiyonu	Test başarımı / Doğruluk başarımı
Tümü	40	Linear	%79.49
VCL	40	Linear	%80.77
VSL	7	Linear	%78.21
VAP	5	Hard limit	%69.23
ALH	7	Hard limit	%67.95
LIN	40	Linear	%84.62
STR	15	Sigmoid	%71.79
WOB	50	Hard limit	%70.51
GB	7	Linear	%87.18


UÖM sınıflandırıcısının test verilerine uygulanması ile elde edilen performans metrik değerleri Tablo 3.4' te gösterilmektedir. Şekil 3.4, 3.6, 3.8, 3.10, 3.12, 3.14, 3.16, 3.18 ve 3.20'de her bir öznelik parametresine ait UÖM sınıflandırma test başarımları grafikleri verilmiştir. Şekil 3.5, 3.7, 3.9, 3.11, 3.13, 3.15, 3.17, 3.19 ve 3.21'de her bir öznelik parametresine ait UÖM sınıflandırma AİK grafikleri verilmiştir.

Tablo 3.4. UÖM sınıflandırma performans metrik değerleri


Video Seti	Performans metrik değerleri			
	Duyarlılık	Belirleyicilik	Kesinlik	F- Ölçüsü
Tümü	0.72	0.83	0.72	0.72
VCL	0.75	0.84	0.72	0.73
VSL	0.70	0.83	0.72	0.71
VAP	0.60	0.75	0.60	0.60
ALH	0.58	0.74	0.60	0.59
LIN	0.80	0.87	0.80	0.80
STR	0.63	0.77	0.63	0.63
WOB	0.62	0.75	0.60	0.61
GB	0.85	0.88	0.80	0.82




Şekil 3.4. Tüm parametrelere göre UÖM sınıflandırma test başarımları




Şekil 3.5. Tüm parametrelere göre UÖM sınıflandırıcısına ait AİK eğrisi




Şekil 3.6. VCL parametresine göre UÖM sınıflandırma test başarımları grafiği




Şekil 3.7. VCL parametresine göre UÖM sınıflandırıcısına ait AİK grafiği




Şekil 3.8. VSL parametresine göre UÖM sınıflandırma test başarımları grafiği




Şekil 3.9. VSL parametresine göre UÖM sınıflandırıcısına ait AİK grafiği




Şekil 3.10. VAP parametresine göre UÖM sınıflandırma test başarımları




Şekil 3.11. VAP parametresine göre UÖM sınıflandırıcısına ait AİK grafiği




Şekil 3.12. ALH parametresine göre UÖM sınıflandırma test başarımları




Şekil 3.13. ALH parametresine göre UÖM sınıflandırıcısına ait AİK grafiği




Şekil 3.14. LIN parametresine göre UÖM sınıflandırma test başarımları grafiği




Şekil 3.15. LIN parametresine göre UÖM sınıflandırıcısına ait AİK grafiği




Şekil 3.16. STR parametresine göre UÖM sınıflandırma test başarımları grafiği




Şekil 3.17. STR parametresine göre UÖM sınıflandırıcısına ait AİK grafiği




Şekil 3.18. WOB parametresine göre UÖM sınıflandırma test başarımları grafiği



Şekil 3.19. WOB parametresine göre UÖM sınıflandırıcısına ait AİK grafiği



Şekil 3.20. GB parametresine göre UÖM sınıflandırma test başarımları grafiği




Şekil 3.21. GB parametresine göre UÖM sınıflandırıcısına ait AİK grafiği

3.1.2. M-DGA-UÖM ile Sınıflandırma Sonuçları

Tablo 3.5’te M-DGA-UÖM yöntemi ile tüm parametrelere göre sınıflandırma sonuçları verilmiştir. Burada DGA ile UÖM’nin gizli katmandaki hücre sayısı (1, 2, 3, ...,98, 99, 100) ve aktivasyon fonksiyonları (sig, sin, hardlim, tribas, radbas, lin) üzerinde optimizasyon yapılan uzaydır. Veri seti bölmede K-kat çapraz yöntemi kullanılmıştır. 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 başarımlar (1’e yakın) olan değeri verilmiştir. Bu sonuçların test / doğruluk başarımları %82.67 çıkmıştır. Şekil 3.22’de M-DGA-UÖM test başarımları grafiği verilmiştir. Bu sonuçlar M-DGA-UÖM yönteminin UÖM yönteminden daha başarılı sonuç üretebileceğini göstermektedir.

Tablo 3.5. M-DGA-UÖM sınıflandırma başarımları

Giriş (Sperm öznitelik parametresi)	Test başarımları / Doğruluk başarımları
Tümü	%82.67



Şekil 3.22. M-DGA-UÖM sınıflandırma test başarımları grafiği

3.1.3 Diğer Sınıflandırma Yöntemlerinin Sonuçları

Tablo 3.6’da literatürde sık kullanılan diğer sınıflandırma yöntemlerinin aynı veri seti üzerindeki başarımları verilmiştir. YSA 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.

Tablo 3.6. Diğer sınıflandırma yöntemlerinin başarımları.

Giriş (Sperm öznitelik parametresi)	Yöntem	Test başarımları / Doğruluk başarımları
Tümü	YSA	%77.92
	Destek vektör	%75.32
	Naive Bayes	%53.24

Diğer sınıflandırıcı yöntemlerin test verilerine uygulanması ile elde edilen performans metrik değerleri Tablo 3.7’de gösterilmektedir.

Tablo 3.7. Diğer sınıflandırıcıların performans metrik değerleri.

Giriş (Sperm öznitelik parametresi)	Yöntem	Performans metrik değerleri			
		Duyarlılık	Belirleyicilik	Kesinlik	F- Ölçüsü
Tümü	YSA	0.64	0.86	0.76	0.70
	DVM	0.60	0.86	0.76	0.67
	NB	0.42	0.65	0.53	0.47

4. TARTIŞMA VE ÖNERİLER

İnfertilite probleminin tespiti için yapılan spermiyogram testi, insan gözlem tabanlı veya bilgisayar destekli sistemler ile yapılmaktadır. Her iki yöntemin de kendine özgü çeşitli dezavantajları vardır. Klasik yöntemde bir uzmanın göz ile deneyimlerine dayalı olarak karar vermesinden dolayı motilite hakkında herhangi bir kantitatif değerden söz edilemez. Bilgisayar destekli sistemlerin her birinde farklı yazılım algoritmaları kullanıldığından dolayı, aynı veriler kullanılarak yapılan sperm motilite tespiti için farklı sonuçlar elde edilebilir. Bu problemlerin tespit ve çözümü için tez çalışmamızda sperm motilite sınıfının tespiti için yapay öğrenme tabanlı bilgisayar destekli otomatik sistemin tasarım ve uygulaması yapılmıştır. Bu sistem ile insan veya algoritma faktörlü hata payını azaltıp, bilgisayar kontrolünü ve verinin doğruluğunu artırarak, sınıflandırma başarımı yüksek spermiyogram testi yapılması sağlanmıştır.

Bu tez çalışmasında, video görüntülerinin analizinde uç öğrenme makinesi sınıflandırıcı algoritmalarının kullanılması ve geliştirilmesi çalışması gerçekleştirilmiştir. Geliştirilen bu Melez (M) - Diferansiyel Gelişim Algoritması (DGA) – Uç Öğrenme Makinesi (UÖM) yönteminin başarımını test etmek için elde edilmiş gerçek sperm videoları üzerinde sperm motilitesinin doğru sınıflandırılması çalışması yapılmıştır. Çalışma video analizi, özellik çıkarma ve sınıflandırma başlıkları altındaki materyal ve metotlardan yararlanılarak hazırlanmıştır. Video analizi video kayıt, video hazırlama, hareketli sperm tespit ve takip adımlarından oluşturulmuştur. Bu bölümde literatürde sık kullanılan arka/ön plan çıkarma yöntemlerinin uygulamaları farklı ortam videolarında denenmiş ve başarımları incelenmiştir. Bu irdeleme sonucunda bu tez konusunun içeriği olan sperm hareket videolarında etkin çalışan başarımlı yüksek GKM, arka/ön plan çıkarma yöntemi olarak kullanılmıştır. Hareketli sperm hücrelerinin video çerçeveleri arasında takibinin yapılması için ise bu konuda popüler ve başarımlı yüksek Kalman Filtre-Macar algoritması ikilisi kullanılmıştır. Özellik çıkarma bölümünde video analizi adımından sonra hareketli spermlere ait koordinat bilgilerinden, sperm hareketlilik öznelik parametre değerleri çıkartılmıştır. Bu özellikler daha önce literatürde kullanılmamış özgün algoritmalara dayalı yazılımlar ile oluşturulmuştur. Ayrıca yine ilk kez bu tez çalışmasının bu adımında GB parametresinin sperm enerji ve hareket verilerine göre modellendiğinden başarımlı yüksek bir parametre olacağı düşünülmektedir.

Literatürde, otomasyonlu sistemler alanında incelenen çalışmalarda yöntemler genellikle video analizi ve özellik çıkarma ile sınırlı kalmıştır. Bu tez çalışmasının savunduğu fikirlerden biriside video analiz verilerinin yapay öğrenme yöntemleri ile sınıflandırma yapılabileceği üzerinedir. Bu aşamada video analiz verilerinin yorumlanması için çeşitli yapay öğrenme yöntemleri incelenmiş ve başarımları irdelenmiştir. Son yıllarda bir grup bilim adamı tarafından öne sürülen daha hızlı, yerel minimuma takılmayan ve başarımları yüksek ileri beslemeli YSA modelinden geliştirdikleri UÖM yöntemi çalışmadaki yapay öğrenme yöntemi olmuştur. UÖM'nin başarımlarını kısıtlayan parametrelerden olan gizli katman hücre sayıları ile aktivasyon fonksiyon seçim işlemi bu tez çalışmasında DGA yöntemi ile optimize edilerek başarımlarının artırılması sağlanmıştır.

Çalışmanın başarımları uygulama sonuçlarında üç aşamada irdelenmiştir. Birinci aşamada arka/ön plan bölütleme yöntemi için kullanılan GKM ve nesne yörünge tahmin-atama için Kalman Filtre-Macar algoritması yöntemlerinin, videodaki sperm hücre tespit başarımları, ikinci aşamada geliştirilen parametre çıkarım yazılımı ile sperm öznitelik parametre verilerinin özgün formüller ile tespit başarımları, üçüncü ve son aşamada ise UÖM ve M-DGA-UÖM yöntemlerinin birinci ve ikinci aşamaya bağlı olarak elde edilen sınıflandırma başarımları irdelenmiştir. Birinci aşamada hareketli sperm tespit ve takip başarımları GKM ve Kalman Filtre-Macar Algoritması yöntemlerinin birlikte çalışması ile ortalama %98.94 olarak elde edilmiştir. İkinci aşama öznitelik parametre verilerinin elde edilmesinde yazılımımız %100 başarımları göstermiştir. Üçüncü aşamada ise sperm hareket analizi öznitelik parametre verilerinin sınıflandırılması için kullanılan UÖM yönteminin başarımları video seti üzerinde irdelenmiştir. UÖM'nin sınıflandırma başarımları GB hariç tüm parametreler için %79.49, GB parametresi de ilave edildiğinde ise %87.18 çıkmıştır. Buradan GB parametresinin UÖM'nin sınıflandırma başarımlarını artırdığı görülmüştür.

Ayrıca bu tez çalışması kullanılan UÖM' nin gizli katmandaki hücre sayısı ve aktivasyon fonksiyonlarını optimize etmek için DGA yöntemi kullanılmış, böylelikle en iyi parametre değerleri bulunarak, UÖM yönteminin yukarıda verilen % 79.49'luk doğru sınıflandırma başarımları %82.67'ye yükseltilmiştir. Yapay öğrenme tekniği olarak kullandığımız UÖM ve M-DGA-UÖM'nin başarımlarını daha iyi gösterebilmek için, aynı video veri seti kullanılarak diğer sınıflandırma yöntemlerinin de doğru sınıflandırma başarımları elde edilerek, bu sonuçlar karşılaştırılmıştır. Elde edilen sonuçlar Tablo 4.1' de sunulmuştur.

Tablo 4.1. Sınıflandırma başarımlarının karşılaştırılması.

Giriş (Sperm öznitelik parametresi)	Test başarımları / Doğruluk başarımları				NB
	M-DGA-UÖM	UÖM	YSA	DVM	
Tümü	%82.67	%79.49	%77.92	%75.32	%53.24

Bu tez çalışmasındaki sonuçlar irdelenip başarımları değerlendirildiğinde literatüre yapılan katkılar aşağıda maddeler halinde sunulmuştur.

Tez Çıktılarının Literatüre Katkıları

- Sperm hareketlilik videoları analiz edilerek sperm hücre hareket koordinat verilerinden özgün algoritmalara dayalı hareket öznitelik parametreleri oluşturulmuştur.
- Sperm hücresinin hareket sınıfının belirlenmesinde etkili olabilecek GB parametresinin oluşturulabileceği ve sperm hareketi sınıflandırmada etkisi olabileceği düşünülmektedir.
- Sperm hareket öznitelik parametre verilerinin, yapay öğrenme sınıflandırıcı yöntemler ile motilitesinin sınıflandırılabilmesi gösterilmiştir.
- Sınıflandırıcı yöntemlerden UÖM'nin başarımlarının yüksek olduğu tespit edilmiştir.
- UÖM'nin başarımlarını kısıtlayan gizli katmandaki hücre sayıları ile aktivasyon fonksiyonu seçim işlemi DGA yöntemi ile optimize edilip en uygun parametrelerin seçilmesi ile UÖM yönteminin başarımlarının artırılması sağlanmıştır.
- Geliştirilen M-DGA-UÖM yönteminin büyük verilerin sınıflandırılmasında başarımlarının yüksek, işlem yükünün düşük olduğu tespit edilmiştir.
- Erkek infertilite probleminin çözümünde klinik açıdan etkili olacak yapay öğrenme tabanlı otomasyonun paket yazılımı oluşturulmuştur.

Bu tez çalışmasında spermiyogram test sistemine ilişkin çeşitli yöntemlere dayalı fikirler savunulmuştur. Tezin açık noktaları ve ileride üzerinde çalışma yapılması gereken konular mevcuttur. Bunlar videoların analizi sırasında karşılaşılan problemler; tespit edilen hareketli nesnelere ilişkin öznitelik parametrelerinin çıkarılması, bu parametrelerin motilite sınıflandırmada etkileri olarak sıralanabilir. Her geçen gün bu problemlerin çözümüne

ilişkin yeni çalışmalar sunulmaktadır. Bu çalışmalar ile bilgisayar destekli sperm analiz sistemlerine katkılar sunulmaktadır. Sperm ile dölleme yapan canlılarda infertilite genellikle erkek bireylerden kaynaklanmaktadır. İnfertilite tespiti için yapılan spermiyogram testi, gelişen donanım ve yazılım teknolojisi ile daha anlamlı, yorumlanabilir ve klinik açıdan etkileri gözlenebilir sonuçlar üretilebilecektir. Sperm motilite sınıfının belirlenmesi gibi büyük veri içeren ve uzman kişilerin görsel değerlendirmesine dayalı birçok sistem yerini otomasyon sistemlerine bırakacaktır. Özet olarak bu tez çalışmasında da bunu yapabilecek bir sistem; yapay öğrenme yöntemi ile yeni bir yaklaşım olarak sunulmuştur.

Yayınlar

Bu tez çalışması kapsamında bir adet Science Citation Indexli (SCI) [20], bir adet uluslararası indeksli dergi yayını [73] ile dört adet uluslararası sempozyumda sözlü sunulmuş bildiri çalışması yapılmıştır. Ayrıca bu çalışmalardan iki tanesi en iyi bildiri ödülüne layık görülmüştür.

Uluslar Arası Sempozyumlar

- 1 **Sönmez, Y., Tuncer, T., Avcı, E.** 2018, Object Classification via Extreme Learning Machine. *9th International Conference on Trends in Science, Engineering, Technology and Natural Resources (TSETNR-18)*
- 2 **Sönmez, Y., Tuncer, T., Gököl, H., Avcı, E.** 2018, Phishing web sites features classification based on extreme learning machine. *In Digital Forensic and Security (ISDFS), 2018 6th International Symposium on pp. 1-5*
- 3 **Sönmez, Y., Kutlu, H., Avcı, E.** 2017, Computer Aided Semen Data Analysis Using Extreme Learning Machine. *International Engineering Conference (IEC2017), October 2017 2th International Symposium*
- 4 **Sönmez, Y., Kutlu, H., Avcı, E.** 2017, Traffic Stream Surveillance Videos Analysis. *International Engineering Conference (IEC2017), October 2017 2th International Symposium*

Ödüller

- 1-En İyi Bildiri ve Sunum Ödülü -2016 DUBAI International Conference on “Image Processing, Data Mining and Information Technology” (IPDMIT-16)
- 2-En İyi Bildiri Ödülü -2017 TURKEY International Engineering Conference(IEC2017),

KAYNAKLAR

- [1] **BLOB Analysis**, URL : <http://what-when-how.com/introduction-to-video-and-image-processing/blob-analysis-introduction-to-video-and-image-processing-part-1/>
Erişim Tarihi : 15.01. 2018
- [2] **Peker, M., Zengin, A.** 2011. Gerçek zamanlı harekete duyarlı bir görüntü tanıma sistemi. *In 6th International Advanced Technologies Symposium*. pp. 16-18.
- [3] **Hidayatullah, P., Awaludin, I., Kusumo, R. D., Nuriyadi, M.** 2016. Automatic sperm motility measurement. *In 2015 International Conference on Information Technology Systems and Innovation*,- pp. 1-5.
- [4] **World Health Organisation.** 1999. WHO laboratory manual for the examination of human semen and sperm-cervical mucus interaction. *Cambridge university press*.
- [5] **Amann, R. P., Waberski, D.** 2014. Computer-assisted sperm analysis (CASA): capabilities and potential developments. *Theriogenology*, 81(1), 5-17.
- [6] **Cooper, T. G., Yeung, C. H.** 2006. Computer-aided evaluation of assessment of “grade a” spermatozoa by experienced technicians. *Fertility and sterility*, 85(1), 220-224.
- [7] **Jiang, Y., Zheng, S., Yan, C., Zhang, W.** 2009. The application of computer-assisted semen analysis parameters in semen quality analysis. *In BioMedical Information Engineering*, pp. 256-258
- [8] **Alpaydin, E.** 2014. Introduction to machine learning. *MIT press*.
- [9] **Hsia, C. H., Guo, J. M.** 2014. Efficient modified directional lifting-based discrete wavelet transform for moving object detection. *Signal Processing*, 96, 138–152.
- [10] **Subudhi, B. N., Ghosh, S., Shiu, S. C. K., Ghosh, A.** 2016. Statistical feature bag based background subtraction for local change detection. *Information Sciences*, 366, 31–47.
- [11] **Hanchinamani, S. R., Sarkar, S., Bhairannawar, S. S.** 2016. Design and Implementation of High Speed Background Subtraction Algorithm for Moving Object Detection. *In Procedia Computer Science Vol. 93*, pp. 367–374.
- [12] **Herrero-Jaraba, E., Orrite-Urunuela, C., Senar, J.** 2003. Detected motion classification with a double-background and a Neighborhood-based difference. *Pattern Recognition Letters*, 24(12), 2079–2092.

- [13] **Mahalingam, T., Subramoniam, M .** 2018. A robust single and multiple moving object detection, tracking and classification. *Applied Computing and Informatics xxx (2018) xxx-xxx* (Article in press).
- [14] **Ertuğrul, Ö. F., Tağluk, M. E., Kaya, Y., Tekin, R.** 2013. EMG signal classification by extreme learning machine. *In Signal Processing and Communications Applications Conference* pp. 1-4
- [15] **Kaya, Y., Tekin, R.** 2012. Epileptik Nöbetlerin Tespiti için Aşırı Öğrenme Makinesi Tabanlı Uzman Bir Sistem. *International Journal of Informatics Technologies*, 5(2).
- [16] **Wang, G., Li, P.** 2010. Dynamic Adaboost ensemble extreme learning machine. *In Advanced Computer Theory and Engineering* Vol. 3, pp. V3-54.
- [17] **Varol, G., Salah, A. A.** 2015. Efficient large-scale action recognition in videos using extreme learning machines. *Expert Systems with Applications*, 42(21), 8274-8282.
- [18] **Das, S., Suganthan, P. N.** 2011. Differential evolution: A survey of the state-of-the-art. *IEEE Transactions on Evolutionary Computation*, 15(1), 4–31.
- [19] **Bazi, Y., Alajlan, N., Melgani, F., AlHichri, H., Malek, S., Yager, R. R.** 2014. Differential Evolution Extreme Learning Machine for the Classification of Hyperspectral Images. *IEEE Geoscience and Remote Sensing Letters*, 11(6), 1066
- [20] **Sönmez, Y., Kutlu, H. Avcı, E.,** 2018. A Novel Approach in Analyzing Traffic Flow Surveillance by Extreme Learning Machine Method *Technical Gazette*, XX(X), XXX-XXX. (Article in Press)
- [21] **Yang, Y., Wang, Y., Yuan, X.** 2012. Bidirectional extreme learning machine for regression problem and its learning effectiveness. *IEEE Transactions on Neural Networks and Learning Systems*, 23(9), 1498-1505.
- [22] **Sönmez, Y., Tuncer, T., Gökal, H., Avcı, E.** 2018, Phishing web sites features classification based on extreme learning machine. *In Digital Forensic and Security (ISDFS), 2018 6th International Symposium on* pp. 1-5
- [23] **Güldoğan, E., Arslan, A. K., Yağmur, J.** 2017. Çeşitli Çekirdek Fonksiyonları ile Oluşturulan Destek Vektör Makinesi Modellerinin Performanslarının İncelenmesi: Bir Klinik Uygulama. *Firat Tıp Dergisi*, 22(3).
- [24] **Boryshpolets, S., Kowalski, R. K., Dietrich, G. J., Dzyuba, B., Ciereszko, A.** 2013. Different computer-assisted sperm analysis (CASA) systems highly influence sperm motility parameters. *Theriogenology*, 80(7), 758-765.

- [25] **Chaudhari, N. M., Pawar, B. V.** 2015. New hybrid approach for identification of spermatozoa in human semen sample using microscope image processing techniques. *Advances in Image and Video Processing*, 2(6), 15-24.
- [26] **Goodson, S. G., Zhang, Z., Tsuruta, J. K., Wang, W., O'Brien, D. A.** 2011. Classification of mouse sperm motility patterns using an automated multiclass support vector machines model. *Biology of reproduction*, 84(6), 1207-1215.
- [27] **Kime, D. E., Van Look, K. J. W., McAllister, B. G., Huyskens, G., Rurangwa, E., Ollevier, F.** 2001. Computer-assisted sperm analysis (CASA) as a tool for monitoring sperm quality in fish. *Comparative Biochemistry and Physiology Part C: Toxicology & Pharmacology*, 130(4), 425-433.
- [28] **Nafisi, V. R., Moradi, M. H., Nasr-Esfahani, M. H.** 2005. A template matching algorithm for sperm tracking and classification. *Physiological measurement*, 26(5), 639.
- [29] **Pascual-Gaspar, J. M., Olmedo, H., Exposito, A. I., Exposito, A., Finat, J.** 2008. A simple and effective system for Computer-Assisted Semen Analysis. *In Advances in Medical, Signal and Information Processing, 4th IET International Conference on*, pp. 1-4
- [30] **Ramón, M. et al.** 2012. Taking Advantage of the Use of Supervised Learning Methods for Characterization of Sperm Population Structure Related with Freezability in the Iberian Red Deer. *Theriogenology*. 77(8), 1661-1672
- [31] **Ertam, F.**, 2016. Kurumsal bilgisayar ağlarındaki trafik bilgisinin akıllı sistemler ile sınıflandırılması, *Doktora Tezi, F.Ü. Fen Bilimleri Enstitüsü*, Elazığ.
- [32] **Kartal E., Özen Z., Gezer M., Saylan S.**, 2017 Mühendislikte yapay zekâ ve uygulamaları *Sakarya Üniversitesi Kütüphanesi Yayınevi-Sakarya*
- [33] **Cross-validation** URL [http://www.wiki-zero.net/wiki/en/Cross-validation_\(statistics\)](http://www.wiki-zero.net/wiki/en/Cross-validation_(statistics))
Erişim Tarihi : 15.01.2018
- [34] **Machine Learning** “Introducing Machine Learning 2016” -The MathWorks, Inc. MATLAB
- [35] **Huang, G.-B., Zhu, Q., Siew, C., Å, G. H., Zhu, Q** 2006. Extreme learning machine: Theory and applications. *Neurocomputing*, 70(1–3), 489–501.
- [36] **Huang, G., Zhu, Q., Siew, C.** 2004. Extreme Learning Machine : A New Learning Scheme of Feedforward Neural Networks. *IEEE International Joint Conference on Neural Networks*, 2, 985–990.

- [37] **Yapay Sinir Ağları** URL <http://www.psikolojik.gen.tr/yapay-sinir-aglari.html> Erişim Tarihi : 15.01. 2018
- [38] **Ertuğrul, Ö. F.** 2016. Aşırı Öğrenme Makineleri ile biyolojik sinyallerin gizli kaynaklarına ayrıştırılması. *D.Ü. Mühendislik Dergisi* Cilt: 7, 1, 3-9
- [39] **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
- [40] **Faruk Ertuğrul, Ö., 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.
- [41] **Ertugrul, Ö. F.** 2016. Forecasting electricity load by a novel recurrent extreme learning machines approach. *International Journal of Electrical Power and Energy Systems*, 78, 429–435.
- [42] **Ertugrul, Ö. F.** 2016. Determining the order of risk factors in diagnosing heart disease by Extreme Learning Machine *International Conference on Natural Science and Engineering (ICNASE '16)*, pp.389-396
- [43] **Keskintürk, T.** 2006. Diferansiyel gelişim algoritması. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 5(9), 85-99.
- [44] **Aydın, S., Zeybek, M. S.** 2015. Diferansiyel gelişim algoritması ile problem çözme üzerine bir değerlendirme. *Soma Meslek Yüksekokulu Teknik Bilimler Dergisi* Yıl: 2015 Sayı:20 49-55
- [45] **Yılmaz., A.R.,** 2014. Genel amaçlı yapay sinir ağlarının diferansiyel gelişim algoritması ile eğitiminin fpga üzerinde gerçekleştirilmesi, Yüksek Lisans Tezi, Yıldız.T.Ü. Fen Bilimleri Enstitüsü, İstanbul.
- [46] **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.
- [47] **Karaboğa, D.** 2014. Yapay Zeka Optimizasyon Algoritmaları. ISBN: 978-605-133-764-7
- [48] **Oral, M., Deniz, U.** 2005. Ardışık Görüntülerde Hareket Analizi. In *Signal Processing and Communications Applications Conference*, 2005. Proceedings of the IEEE 13th pp. 187-190.

- [49] **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.
- [50] **Yilmaz, A., Javed, O., Shah, M.** 2006. Object tracking: A survey. *Acm computing surveys (CSUR)*, 38(4), 13.
- [51] **Mohanty, A., Shantaiya, S.** 2015. A Survey on Moving Object Detection using Background Subtraction Methods in Video. *International Journal of Computer Applications*.5-10
- [52] **Barnich, O., Van Droogenbroeck, M.** 2011. ViBe: A universal background subtraction algorithm for video sequences. *IEEE Transactions on Image Processing*, 20(6), 1709–1724.
- [53] **Singh Sekhon, G.** 2012. Path Estimation and Motion Detection of Moving Object in Videos. *IOSR Journal of Computer Engineering*, 2(4), 2278–661.
- [54] **Benezeth, Y., Jodoin, P.-M., Emile, B., Laurent, H., Rosenberger, C.** 2010. Comparative study of background subtraction algorithms. *Journal of Electronic Imaging*, 19(3), 33003.
- [55] **Ergezer., H.,** 2007. Visual detection and tracking of moving objects, Yüksek Lisans Tezi, O.D.T.Ü. Fen Bilimleri Enstitüsü, Ankara.
- [56] **Aydemir., M.S.,** 2012. Gerçek zamanlı güvenlik kamerası videolarının insan tabanlı özetlenmesi, Yüksek Lisans Tezi, Yıldız T.Ü. Fen Bilimleri Enstitüsü, İstanbul.
- [57] **Profitt, B.,** 2009. Background Subtraction Algorithms for a Video based system, Yüksek Lisans Tezi, Stellenbosch University. South Africa
- [58] **Kutlu., H.,** 2013. İnsan bilgisayar etkileşimli görüntü işleme uygulamaları, Yüksek Lisans Tezi, F.Ü. Fen Bilimleri Enstitüsü, Elazığ.
- [59] **Naraghi., N., S.,** 2009. A Comparative Study of Background Estimation Algorithms, Yüksek Lisans Tezi, Eastern Mediterranean University, Gazimağusa, North Cyprus
- [60] **McFarlane, N. J. B., Schofield, C. P.** 1995. Segmentation and tracking of piglets in images. *Machine Vision and Applications*, 8(3), 187–193.
- [61] **Oliver, N., Rosario, B., Pentland, A.** 1999. A Bayesian computer vision system for modeling human interactions. In *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* Vol. 1542, pp. 255–272.

- [62] **Kim, K., Chalidabhongse, T. H., Harwood, D., Davis, L.** 2005. Real-time foreground-background segmentation using codebook model. *Real-Time Imaging*, 11(3), 172–185.
- [63] **Stauffer, C., Grimson, W. E. L.** 1999. Adaptive background mixture models for real-time tracking. In *Computer Vision and Pattern Recognition, 1999. IEEE Computer Society Conference on*. Vol. 2, pp. 246-252
- [64] **Hayman, E., Eklundh, J.-O.** 2003. Statistical background subtraction for a mobile observer. *IEEE International Conference on Computer Vision, (Iccv)*, 67–74
- [65] **Sobral, A., Vacavant, A.** 2014. A comprehensive review of background subtraction algorithms evaluated with synthetic and real videos. *Computer Vision and Image Understanding*. 122, 4-21.
- [66] **Chen, Y. T., Chen, C. S., Huang, C. R., Hung, Y. P.** 2007. Efficient hierarchical method for background subtraction. *Pattern Recognition*, 40(10), 2706–2715.
- [67] **Zivkovic, Z., Van Der Heijden, F.** 2006. Efficient adaptive density estimation per image pixel for the task of background subtraction. *Pattern Recognition Letters*, 27(7), 773–780.
- [68] **Talu., M., F.,,** 2010. İnsan hareketlerinin takibinde karşılaşılan problemlerin çözümüne yeni yaklaşımlar, Doktora Tezi, F.Ü. Fen Bilimleri Enstitüsü, Elazığ.
- [69] **Kaewtrakulpong, P., Bowden, R.** 2001. An Improved Adaptive Background Mixture Model for Real- time Tracking with Shadow Detection. *Advanced Video Based Surveillance Systems*, 1–5.
- [70] **Tuzel, O., Porikli, F., Meer, P.** 2005. A Bayesian Approach to Background Modeling. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)* , 3, 58–58.
- [71] **WEKA**, URL : <http://www.cs.waikato.ac.nz/ml/weka>. Erişim Tarihi : 15.01. 2018
- [72] **MATLAB**, URL : <http://www.mathworks.com/products/matlab>. Erişim Tarihi: 15.01. 2018
- [73] **Sönmez, Y., Kutlu, H. Avcı. E.,** 2016. A New Moving Object Classification and Estimation Based on Extreme Learning Machine (ELM) *International Journal of Computer Science and Electronics Engineering (IJCSEE) Volume 4, Issue 3 (2016) ISSN 2320–4028*,

ÖZ GEÇMİŞ

Yasin SÖNMEZ	
KİŞİSEL BİLGİLER	
ADRES :	Dicle Üniversitesi,Teknik Bilimler MYO 1. Kat 21090 – Diyarbakır
TELEFON :	+90 (5 5 5) 290 96 76
EPOSTA :	yasin.sonmez@dicle.edu.tr
DOĞUM YERİ/TARİHİ:	07.11.1986 -Diyarbakır
MEDENİ HALİ:	Evli
EĞİTİM BİLGİLERİ	
LİSANSÜSTÜ	2012,Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik Bilgisayar Anabilim Dalı, Elazığ
LİSANS :	2010,Fırat Üniversitesi,Teknik Eğitim Fakültesi,Bilgisayar Öğretmenliği, Elazığ
LİSE :	2004, Türk Telekom Anadolu Teknik Lisesi ,Diyarbakır
İŞ DENEYİMİ	
2012 – 2012	Ardahan Üniversitesi/Bilgi İşlem ,Ardahan Uzman
2012 – 2014	Batman Üniversitesi/MYO ,Batman Öğretim Görevlisi
2014 – Devam	Dicle Üniversitesi/MYO ,Diyarbakır Öğretim Görevlisi
BİLDİĞİ YABANCI DİLLER	
	İngilizce