



**VIDEO GÖRÜNTÜLERİNDEN SPERM HAREKETLERİNİN
OTOMATİK TAKİBİ VE ANALİZİ**

İnas ALARABI

Danışman: Dr. Öğr. Üyesi Gülşah TÜMÜKLÜ ÖZYER

Yüksek Lisans Tezi

Bilgisayar Mühendisliği Ana Bilim Dalı

2020

(her hakkı saklıdır.)

T.C.
ATATÜRK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI

VIDEO GÖRÜNTÜLERİNDEN SPERM HAREKETLERİNİN OTOMATİK TAKİBİ VE ANALİZİ
(Automatic tracking and analysis of sperm motion from video images)

YÜKSEK LİSANS TEZİ

İnas ALARABI

Danışman: Dr.Öğr Üyesi Gülşah TÜMÜKLÜ ÖZYER

Erzurum
Eylül, 2020

KABUL VE ONAY TUTANAĞI

İnas ALARABI tarafından hazırlanan “Video Görüntülerinden Sperm Hareketlerinin Otomatik Takibi ve Analizi” başlıklı çalışması .. /09/2020 tarihinde yapılan tez savunma sınavı sonucunda başarılı bulunarak jürimiz tarafından Bilgisaya Mühendisliği Ana Bilim Dalı, Bilgisaya Mühendisliği Bilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir.

Jüri Başkanı: Prof. Dr. Abdulsamet Haşıloğlu

Atatürk Üniversitesi

.....

Danışman: Dr.Öğr Üyesi Gülşah Tümöklü Özyer

Atatürk Üniversitesi

.....

Jüri Üyesi: Prof. Dr. Abdulsamet Haşıloğlu

Atatürk Üniversitesi

.....

Jüri Üyesi: Doç. Dr. Yılmaz Kalkan

Aydın Adnan Menderes Üniversitesi

.....

Enstitü Yönetim Kurulunun
.../.../.... tarih ve
sayılı kararı.

Bu tezin Atatürk Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili maddelerinde belirtilen şartları yerine getirdiğini onaylarım.

Unvan Ad SOYAD

Enstitü Müdürü

Not: Bu tezde kullanılan özgün ve başka kaynaklardan yapılan bildiriş, çizelge, şekil ve fotoğrafların kaynak olarak kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

**FEN BİLİMLERİ ENSTİTÜSÜ**Graduate School of Natural and
Applied Sciences**TEZ BENZERLİK ORANI BEYAN FORMU¹**

Öğrencinin Adı ve Soyadı	İnas Alarabı
Öğrencinin Numarası	16040201015
Ana Bilim Dalı	Bilgisayar Mühendisliği
Bilim Dalı	Bilgisayar Mühendisliği
Öğrencinin Kayıtlı Olduğu Program	Yüksek Lisans
Türü	

Yukarıda bilgileri verilen tezin intihal tespit yazılımıyla (Turnitin) yapılan tarama sonucunda elde edilen benzerlik oranları aşağıdaki gibidir. Sunulan bilgilerin doğru olduğunu, aksi halde doğacak hukuki sorumlulukları kabul ettiğimizi beyan ederiz.

Tez Bölümleri	Tezin Benzerlik Oranı (%)	Maksimum Oran (%)
Giriş	0	30
Kuramsal Temeller	1	30
Materyal ve Yöntem	3	35
Bulgular	2	20
Tartışma	2	20
Tezin Geneli	11	25

Not: Yedi kelimeye kadar benzerlikler ile Başlık, Kaynakça, İçindekiler, Teşekkür, Dizin ve Ekler kısımları tarama dışı bırakılabilir. Yukarıdaki azami benzerlik oranları yanında tek bir kaynaktan olan benzerlik oranlarının %5'den büyük olmaması gerekir.

Tez Yazarı (Öğrenci)	Tez Danışmanı
İnas Alarabı	Dr.Öğr Üyesi Gülşah Tümüklü Özyer
14.8.2020	14.8.2020
İmza:	İmza:

¹ Bu form bilgisayar ortamında doldurulmalı, çıktısı imzalanıp Tez Savunması Jüri Öneri Formu'yla birlikte Ana Bilim Dalı Başkanlığı aracılığıyla ÜBYS üzerinden Enstitüye iletilmelidir.

TEŞEKKÜR

Yüksek lisans eğitimim ve tez çalışmalarım süresince, danışmanım Dr. Gülşah Tümüklü Özyer' e gerek bilimsel desteği ve yol göstermesine, gerekse zor anlarımda beni sürekli motivasyon edip bana destek olduğu için çok teşekkür ederim.

Yüksek lisans tez savunma jürimde yer alan Prof. Dr. Abdulsamet Haşiloğlu ve Doç. Dr. Yılmaz Kalkan'a tezim ile ilgili bana vermiş oldukları öneri ve destekleri için ayrı ayrı teşekkür ediyorum.

Tez çalışmalarım esnasında fikir alış verişinde bulunduğum Ahmad Alhaj Alabdulla ve değerli destekleri ve yardımları için Prof. Dr. Abdulsamet Haşiloğlu'na ayrıca teşekkür ederim.

Tez çalışmalarım esnasında değerli bilimsel desteği için Dr. Barış Özyer' e teşekkür ederim.

Tez çalışmalarım esnasında kullandığım farklı hayvanlara ait sprem video görüntülerinin temininde destek ve yardımları için Atatürk Üniversitesi Veterinerlik Fakültesinden Doç.Dr. Emrah Hicazi Aksu' ya teşekkür ediyorum.

Yüksek lisans eğitiminin tamamlanması için maddi destek sağlayan YTB başkanlığına da teşekkür ederim.

İnas ALARABI

ÖZET
YÜKSEK LİSANS TEZİ
VIDEO GÖRÜNTÜLERİNDEN SPERM HAREKETLERİNİN OTOMATİK TAKİBİ
VE ANALİZİ

İnas ALARABI

Danışman: Dr.Öğr Üyesi Gülşah TÜMÜKLÜ ÖZYER

Amaç: Kısırlığın (infertalite) belirlenmesinde sperm hareketliliğinin analizi önemlidir ancak bu hareketlilik analizinde kullanılacak olan parametreleri otomatik olarak belirlemek oldukça zordur. Uzmanlar mikroskop görüntülerini inceleyerek ve tahlil sonuçlarına göre tanı koyabilmektedir. Bu durum hem zaman açısından maliyetlidir hem de doğrudan uzman hekimin tecrübesine bağlı olarak yanlışlar yapılabilir. Bu motivasyon ile bu tezde amacımız sperm hareketlerini video görüntülerinden otomatik olarak takip eden ve hareketlilik parametrelerini hesaplayan bir sistem geliştirmektir.

Yöntem: Mikroskop video görüntüleri kullanılarak sperm hareketlilik parametreleri çıkartıldı. Video görüntülerinden spermleri ayırtmak için arka plan çıkarma yöntemi kullanıldı. Görüntüde tespit edilen sperm bölgeleri ortak olasılıklı veri ilişkilendirme filtresi ile ayırttırıldı ve etkileşimli çoklu model tekniği ile birleştirilerek sperm hareketleri takip edildi. Spermlerin hareket bilgilerinden hareketlilik parametreleri hesaplandı.

Bulgular: Etkileşimli çoklu model tekniğinin, manevra hareketleri ile spermin takibinde etkili sonuçlar verdiği gözlemlendi. Ortak olasılıklı veri ilişkilendirme filtresi, karmaşık koşullar altında sperm hareketlerinin takibini başarı ile sağladı. Farklı nesne takibi algoritmaları ile karşılaştırıldığında, önerilen algoritma daha doğru sonuçlar verdi, ancak nispeten daha uzun süre aldı.

Sonuç: Kısırlığı belirlemek için dinamik sperm hareketlilik parametrelerini zaman içinde sınıflandırmak için ölçekbilen güçlü bir otomatik çoklu sperm tespit ve izleme algoritması sunuldu. IMM-DA ve DA olmak üzere iki izleme algoritması seti değerlendirildi. Deneysel sonuçlar incelendiğinde, spermlerin takibi için IMM-JPDAF algoritmasının en yüksek doğruluk değerlerini verdiği gözlemlendi.

Anahtar Kelimeler: sperm hareketliliği analizi, arka plan çıkarma, veri ilişkilendirme, çoklu model etkileşim.

Eylül 2020, 97 sayfa

ABSTRACT
MASTER's THESIS
AUTOMATIC TRACKING AND ANALYSIS OF SPERM MOTION FROM VIDEO
IMAGES

İnas ALARABI

Supervisor: Dr.Öğr Üyesi Gülşah TÜMÜKLÜ ÖZYER

Purpose: The analysis of sperm motility is considered one of the most important points, because it has a basic role in to determining male infertility, while it reflects parameters of high importance in medical diagnosis, but it remains very difficult to determine these parameters. The manual process is costly in terms of time and it could be inaccurate. Therefore, this thesis aims to develop an automatic system that evaluates the motility parameters of human sperms to help obtaining an accurate result at a lower time cost.

Method: This system was developed using image processing techniques and tracking algorithms. The system tracks the movement of most spermatozoa then measures all medical parameters to determine the infertility rate at the patient. Background Subtraction method is used to extract the sperms within the video The Joint probabilistic data association filter is combined with interacting multiple model technique and used for tracking it.

Findings: The interacting multiple model technique gave effective results in tracking sperm with manoeuvring motions. The Joint probabilistic data association filter achieved efficient sperm tracking under complex conditions. Comparing to another algorithm the proposed algorithm gave more accurate results but with relatively higher cost of time.

Results: The developed sperm analysis system gave the most accurate results when it applied on semen sample. While the sperms were accurately tracked, the parameters of movement were calculated, the class of each sperm was determined.

Keywords: sperm motility analysis, background subtraction, data association, interacting multiple mode.

September 2020, 97 pages

İÇİNDEKİLER

GİRİŞ	1
1.1 Problem Tanımı.....	2
1.2 Tez Genel Bakış.....	3
KURAMSAL TEMELLER	5
2.1 İnsan Spermatozoası Fizyolojisi	5
2.1.1 İnsan Spermatozoasının Yapısı	5
2.1.2 Sperm Analizi.....	6
2.1.3 Mikroskop ile Sperm Analizi	9
2.1.4 Bilgisayar Destekli Semen Analizi (CASA) Sistemleri	9
2.2 Video Görüntülerinden Sperm Hareketlerinin Analizi.....	10
2.2.1 Nesne Tespiti (Algılama)	11
2.2.2 Nesne Takibi.....	11
2.2.3 Hareket Analizi	12
2.3 Literatür Taraması	12
2.4 Tezin katkısı.....	14
MATERYAL VE METOD	15
3.1 Materyal.....	15
3.2 Metodlar	17
3.2.1 Nesne Tespiti Temelleri	17
3.2.2 Hareketli Nesne Takibi Temelleri:	24
3.2 Önerilen Yöntem.....	41
3.2.1 Sperm Tespiti Algoritması	41
3.2.2 Sperm Takibi Algoritması	42
ARAŞTIRMA BULGULARI VE TARTIŞMA	50
4.1 Sperm Tespit Algoritmalarının Karşılaştırılması	50
4.2 Sperm İzlemesi Karşılaştırması.....	53
4.2.1 Optimal Alt-Desen Ataması (Optimal Subpattern Assignment OSPA) Metriği	54
4.2.2 İzleme Senaryolar:	56

4.3 Analiz Sonuçları.....	67
4.3.1 İlk örnek analizinin sonuçları	68
4.3.2 İkinci örnek analizinin sonuçları	72
4.3.3 Farklı örnekler için analizinin sonuçları	77
<i>SONUÇLAR VE ÖNERİLER.....</i>	82
<i>KAYNAKLAR</i>	83
<i>Ek A: Sperm Tespit Sisteminin Matlab Kodu</i>	88
<i>Ek B: Sperm Takip Sisteminin Matlab Kodu.....</i>	90
<i>Ek C: Sperm Hareketlilik Analiz Sisteminin Matlab Kodu</i>	96
<i>ÖZGEÇMİŞ.....</i>	97

TABLÖLAR DİZİNİ

Tablo 1. Sperm Analiz Sisteminde Kullanılan Spermilerin Örnekleri ve Sentetik Verileri	16
Tablo 2. OSPA Mesafesinin Değerleri	67
Tablo 3. Hareketlilik Parametrelerine Dayalı Sperm Sınıflandırma Sonuçları	72
Tablo 4. Hareketlilik Parametrelerine Dayalı Sperm Sınıflandırma Sonuçları	76
Tablo 5. Koç, Boğa ve Aygır örnekleri için Hareketlilik Sınıflandırma Sonuçları	81



ŞEKİLLER DİZİNİ

Şekil 1. İnsan spermatozoa yapısı	6
Şekil 2. Sperm hareketlilik parametreleri (WHO 2010).....	7
Şekil 3. Video görüntülerinden nesne takibi ve analiz aşamaları.....	10
Şekil 4. Verisetlerinde bulunan a, b) boga, c) koç ,ve d) aygır spermilerin örnek vidoe görüntüleri	17
Şekil 5. Nesne gösterimleri. (a) Merkez, (b) çoklu noktalar, (c) dikdörtgen yama, (d) eliptik yama, (e) parça tabanlı çoklu yamalar, (f) nesne iskeleti, (g) tam nesne çevresi, (h) nesne çevresi üzerindeki kontrol noktaları, (i) nesne silueti. (Yılmaz et al. 2006).....	18
Şekil 6. Dönüşüm modelleri (Yılmaz et al. 2006).....	18
Şekil 7. Nesne tespit tekniklerinin sınıflandırılması	22
Şekil 8. Piksel geçişi ve sonuçta oluşan akış vektörü.....	23
Şekil 9. İzleme tekniklerinin sınıflandırılması (Yılmaz et al. 2006)	26
Şekil 10. Kapı Önü, Ölçüm 1 ve Ölçüm 4, kapının dışında olduğu için reddedilir	27
Şekil 11. Kalman filtresinin temel işlemleri.....	30
Şekil 12. PDAF Algoritması tarafından temsil edilen ilişkilendirme olayları	33
Şekil 13. PDAF algoritmasında işlemler etkileşmesi	36
Şekil 14. PDAF'deki ilişkilendirme olaylarına örnek.....	37
Şekil 15. IMM döngüsü.....	39
Şekil 16. Sperm analiz sistemin diyagramı	49
Şekil 17. Sperm örnek videosunun iki karesine tespit tekniklerinin uygulanmasının sonuçları . a,b) Kare No. 15 ve 50, sırasıyla; c,d) Kare farkı uygulanmasının sonucu; e,f)Arka planın çıkarma sonucu; g,h) Optik akışı uygulamasının sonucu.	52
Şekil.18 Gerçek sperm sayısına kıyasla her yöntem için doğrulanan sperm sayısı	53
Şekil 19. Kusurlu izleme için dört örnek.....	54
Şekil 20. İzleme algoritmalarını 1. senaryoya uygulamanın sonuçları	59
Şekil 21. İzleme algoritmalarını 2. senaryoya uygulamanın sonuçları (a) Önerilen senaryo 2 , (b) Her algoritma için OSPA değerleri.....	60
Şekil 22. İzleme algoritmalarını 3. senaryoya uygulamanın sonuçları (a) Önerilen senaryo 3 , (b) Her algoritma için OSPA değerleri.....	61
Şekil 23. İzleme algoritmalarını 4. senaryoya uygulamanın sonuçları. Önerilen senaryo 4 , (b) Her algoritma için OSPA değerleri.	62
Şekil 24. İzleme algoritmalarını 5. senaryoya uygulamanın sonuçları.	63
Şekil 25. İzleme algoritmalarını 6. senaryoya uygulamanın sonuçları.	64
Şekil 26. İzleme algoritmalarını 7. senaryoya uygulamanın sonuçları	65
Şekil 27. İzleme algoritmalarını 8. senaryoya uygulamanın sonuçları.	66

Şekil 28. Tespit sisteminin uygulanmasının aşamaları. (a) sperm videosunun arka planı, (b) arka plan ile geçerli çerçeve arasındaki fark, (c) morfolojik işlemleri uygulamak, (d) spermleri etiketlemek	69
Şekil 29. IMM_JPDAF kullanarak izleme sonuçları (a), (b), (c) ve (d) 'de video üzerinden sırasıyla 50, 150, 200 ve 252 karelerde sperm izleme sonuçları.	71
Şekil 30. Tespit sisteminin uygulanmasının aşamaları. (a) sperm videosunun arka planı, (b) arka plan ile geçerli çerçeve arasındaki fark, (c) morfolojik işlemleri uygulamak, (d) spermi etiketlemek	74
Şekil 31. IMM_JPDAF kullanarak izleme sonuçları (a), (b), (c) ve (d) 'de video üzerinden sırasıyla 70, 120, 170 ve 250 karelerde boğa sperm izleme sonuçları.....	76
Şekil 32. Koç örnekleri için izleme sonuçları. (a) koç-2 örneği, (b) koç-4 örneği, (c) koç-5 örneği,.....	78
Şekil 33. Boğa örnekleri için izleme sonuçları. (a) boğa-2 örneği, (b) boğa-3 örneği.	79
Şekil 34. Aygır örnekleri için izleme sonuçları. (a) aygır-1 örneği, (b) aygır-2 örneği, (c) aygır-3 örneği.....	80

KISALTMALAR VE SİMGELER DİZİNİ

ALH	: amplitude of lateral head displacement (Yanal kafa yer deęiřtirmesinin genlięi)
DA	: data association (Veri iliřkilendirmesi)
EKF	: extended Kalman filter (geniřletilmiř Kalman filtresi)
FA	: false alarm (yanlıř alarm)
FOV	: field of view(Görüř alanı)
GNNF	: global nearest neighbor filter (küresel en yakın komřu filtresi)
IMM	: interacting multiple model(çoklu model etkileřim)
IMM-JPDAF	: interacting multiple model-joint probabilistic data association filter (çoklu model etkileřim-ortak olasılıklı veri iliřkilendirme filtresi)
JPDAF	: joint probabilistic data association filter (ortak olasılıklı veri iliřkilendirme filtresi)
KF	: Kalman Filter (Kalman filtresi)
LIN	: swimming path linearity (yüzme yolu doęrusallıęı)
MSE	: mean square error (ortalama kare hatası)
NNF	: nearest neighbor filter (en yakın komřu filtresi)
OSPA	: optimal subpattern assignment (optimal alt řablon ataması)
PD	: detection probability (tespit olasılıęı)
PDAF	: probabilistic data association filter (olasılıklı veri iliřkilendirme filtresi)
PG	: gating probability (geçit olasılıęı)
STR	: average straightness (ortalama yol düzlüęü)
VAP	: average path velocity (ortalama yol hızı)
VCL	: curvilinear velocity (eęrisel hız)
VSL	: straight-line velocity (düz çizgi hızı)
WHO	: World Health Organization (Dünya Saęlık Örgütü)
λ	: Ortalama λ ile daęınıklılıęın Poisson daęılımı
$v(k)$	: innovation or residual (k zamanıda ölçüm kullanan yörünge için kalıntı veya yenilik)
m_k	: k zamanındaki ölçüm sayısı
I_{diff}	: çıkıntılı arka plan
d^2	: mahalanobis mesafesi
Z_K	: k zamanındaki ölçümler
γ	: kapı eřięi
$x_{k k}$	: arka nesne durumu
$F_{k-1 k-1}$	: geçiř matrisi
H_k	: ölçüm matrisi
S_k	: yenilik kovaryans matrisi
$\Theta(K)$	: k zamanında ortak iliřkilendirme olayı
β_{jt}	: marjinal olasılık
$\mathcal{L}_{jt}$	: ölçüm olasılık oranı
$\mu_{i j,k-1}$	: karıřık model olasılıkları
p_{ij}	: markov geçiř matrisi
$\mu_{j,k}$	: güncellenmiř model olasılıkları

GİRİŞ

Sperm analizi son yıllarda bilgisayar bilimi ile ilgilenen araştırmacılar ve doktorlar arasında büyük ilgi gören bir konudur. Kısırlığı tespit etmede önemli bir rolü olduğu ve hızlı ve uzman görüşüne bağlı kalmadan erken tespiti tedavisi için önemli bir adım olduğu kabul edilmektedir. Temelde sperm analizi ile sperm başının boyutu, kromozom yüzdesi, başın uzunluğu, genişliği ve diğer ilgili şekil parametreleri incelenir. Spermeler bu analizlerden çıkan yüzdelik oranlara göre normal veya anormal spermelere sınıflandırılır (WHO 2010). Bu analiz türüne Morfoloji Analizi denir (Wang *et al.* 2011). Ayrıca spermanın menide yüzmesi sırasındaki davranışının izlenmesine bağlı olan düz çizgi hızı (VSL), eğrisel hız (VCL), ortalama yol hızı (VAP), ileri ilerlemenin doğrusallığı (LIN), eğrisel yol yalpalaması (WOB) ve diğerleri gibi hareket için özel parametreleri bulunmaktadır (WHO 2010; Hidayatullah 2015). Bu hareketlilik parametrelerinin değerlerine bağlı olarak, sperm hareketleri ileri yönlü hareket eden, ilerlemesiz hareket eden ve hareketsiz olarak üç kategoriye ayrılır. Bu analize ise Hareketlilik Analizi denir. Son olarak, bir mililitre spermada spermatozoa hücrelerinin sayısını ifade eden Spermin Konsantrasyon Analizinde kısırlığın tespitinde kullanılan bir analiz türüdür. Spermatozoa hücresinin hareketliliğinin analizi önemlidir, çünkü tıbbi tanıda yüksek önem taşıyan parametreleri yansıtırken spermin kalitesini belirlemede temel bir role sahiptir. Spermatozoanın sayısı ve şekli, genellikle mikroskop kullanılarak teknisyenler tarafından değerlendirilir. Klinisyenin bir meni örneğindeki sperm sayısını hesaplayabildiği ve aynı zamanda şeklin parametrelerini algılayabildiği, ancak yüzme veya hareketlilik parametrelerini belirlerken zorlandığı bilinmektedir . (Keel 2004; Rothmann *et al.* 2007).

Son yıllarda sperm analizi için bilgisayar destekli sperm analizi (Computer-aided sperm analysis CASA) adında sistemler geliştirilmiştir. Ancak bu cihazlar oldukça pahalı olmasından kaynaklı sadece büyük laboratuvarlarda kullanılabilmektedir (Rothmann *et al.* 2007; Amann *et al.* 2014). Bu nedenle, daha küçük laboratuvarlarda bu analizler klinisyen tarafından manuel yöntemler kullanılarak gerçekleştirilir. Ancak bu durumda, testler kullanılan protokollerin çeşitliliği ve klinisyenin tecrübesi analiz sonuçlarında farklılıklara neden olmakta ve bu analizin doğruluğunu da etkilediği bilinmektedir. Bu nedenle, bu tez çalışmasında klinisyene analiz sürecinde daha doğru ve daha kısa sürede sperm motilite analizi yapmasında yardımcı olmak için CASA'ya alternatif otomatik bir sistem geliştirmeyi amaçlıyoruz. Bu sistem görüntü işleme teknikleri ve izleme algoritmaları kullanılarak geliştirilmiştir. Önerilen sistemimiz iki temel aşamadan oluşmaktadır: 1) mikroskoba bağlı kameradan alınan semen örneğindeki çoğu

spermatozoa hücresinin hareketini izlenmesi 2) kısırlık oranını belirlemek için sperm motilitesi ile ilgili tüm parametreleri doğru bir şekilde ölçülmesi.

1.1 Problem Tanımı

Video görüntülerinden sperm hareketliliğinin analizi temelde üç ana aşamadan oluşmaktadır: 1) hareketli nesneleri tespit etmek, 2) tespit edilen nesneleri takip etmek, 3) son olarak bu hareketlere bağlı olarak sperm aktivitelerinin tanınması (Yilmaz *et al.* 2006; Athanesisious *et al.* 2012). Spermier mikroskop video görüntülerinde hareketli nesne olarak tanımlanmaktadır. Ancak spermierin video görüntülerinden takibi, literatürdeki standart hareketli nesne takibi probleminden daha zor bir problemidir. Bu durumun en temel sebebi, herhangi meni örneğinde milyonlarca sperm bulunmaktadır. Bu spermier birbirine çok yakın ve hızlı hareket ederler. Ayrıca, semendeki spermatozoa hücreleri rastgele hareket eder. Örneğin spermier harekete başlarken bazen düz hareket edebilir, sonra hafif dönme hareketi yapar ve diğer zamanlarda sabit dairesel bir yol izleyebilirler.

Bir diğer problem ise sperm analizi sürecinde kullanılan video, meni örneğinin üç boyutlu alanını iki boyutlu bir boşluğa dönüştüren bir kamera tarafından çekilir. Bu durum anlık sperm konum bilgilerinin kaybolmasına neden olmaktadır. Bu nedenle kamera görüntülerinde üst üste gelen spermierin altında bulunabilecek spermier tespit edilmeyebilir. Son olarak yanlış pozitif veya yanlış alarm (*false positive* FP) neden olan spermierinin tespitindeki zorluklar bulunmaktadır. Bu durumda görüntüde gürültü anlamına gelen var olmayan nesnelerin tespiti gerçekleşir. Örneğin bir çarpışma olduğunda veya nesneyi arka plandan ayıklandığında, hareketli nesneleri tespit etme doğruluk oranı azalmakta ve sistem çoğunlukla yanlış negatif (*false negative* FN) değeri üretmektedir. Bu nedenle, milyonlarca sperm bulunan zor bir ortamda sperm hareketlerinin takibi için yüksek doğrulukla çalışan sistemine ihtiyacımız bulunmaktadır.

Bu çalışmada, video karelerindeki spermier çıkarmak için Arkaplan Çıkarma yöntemi (Piccardi *et al.* 2004; Yilmaz *et al.* 2006) ve spermier izlemek için Bayes tabanlı hareket takibi yöntemler (Athanesisious *et al.* 2012; Ristic *et al.* 2013) kullanılmıştır. Sperm manevra hareketine sahip olduğundan çarpışan spermier tespit etme ve yanlış alarmları azaltmak için etkileşen çoklu model (*interacting multiple model* IMM) (Rachman 2017) yöntemi ile Bayes algoritmaları ile birleştirildi. Bu hareket analizleri ile bir erkekte kısırlığın belirlenmesine katkıda bulunan hareketlilik parametrelerinin değerleri hesaplandı.

1.2 Tez Genel Bakış

Bu tezin temel amacı bir videodan otomatik çoklu sperm takibi için yeni bir yöntem geliştirmek ve kısırlığın belirlenmesinde kullanılan motilite parametrelerini hesaplamaktır. Aşağıda tez de yer alan bölümler ve bu bölümler ile ilgili özet açıklamalar bulunmaktadır.

Bölüm 2. Kuramsal Temeller.

Bu bölüm insan sperm hücrelerinin gelişimini ve fizyolojisini tartışmakta, tipik bir sperm analizini ve sperm motilite parametrelerini hesaplamak için literatürde yapılan çalışmalardan ve metodlardan bahsetmektedir. Ayrıca son yıllarda tezin amacına benzer olarak geliştirilen CASA sistemlerinin avantaj ve dezavantajları gözden geçirilmiştir. Video görüntülerinden hareketli nesne tespiti ve takibi için temel kavramlardan bahsedilerek, sperm hareketlerinin analizi üzerinde yapılan çalışmalardan bahsedilmiştir.

Bölüm 3. Materyal ve Metod.

Bu bölümde hareketli nesne tespiti ve takibi için kullanılan yöntemler ayrıntılı bir şekilde açıklandı. Hareketli nesne tespit etmek için öncelikle görüntüler ön işlemden geçirildi. Daha sonra, videodan hareketli nesneleri çıkarmak için literatürde yaygın olarak kullanılan Optik Akış, Kare Farkı, Arka Plan Çıkarımı yöntemleri açıklandı.

Hareketli nesnenin takibi için Bayesian filtresi tabanlı filtreler Kalman filtresi *KF*, Genişletilmiş Kalman Filtresi (*Extended Kalman filter EKF*), Etkileşimli Çoklu Model yöntemi (*Interacting multiple model IMM*), En Yakın Komşu Filtresi (*Nearest neighbor filter NNF*), Küresel En Yakın Komşu Filtresi (*Global nearest neighbor filter GNN*), Olasılıksal Veri İlişkisi Filtresi (*probabilistic data association filter PDAF*), Ortak Olasılıksal Veri İlişkisi Filtresi (*Joint probabilistic association filter JPDAF*) matematiksel olarak ayrıntılı bir şekilde açıklandı. Hareketli nesne takibi için tezde önerilen yöntem olan *IMM-JPDAF* algoritması ayrıntılı olarak açıklandı. Son olarak, sperm hareketlerinden hareket parametrelerini çıkartıldı.

Bölüm 4. Araştırma Bulguları ve Tartışma

Bu bölümde, çeşitli sentetik senaryolar kullanarak hareketli nesne tespiti ve takibi algoritmaları arasında karşılaştırmalar yapıldı. Hareketli sperm tespiti için MSE ve takibi için bir ölçüm olarak OSPA'ya bağlı sonuçlar tartışıldı. Son olarak, *IMM-JPDAF* algoritmasını uygulayarak elde edilen izleme sonuçları ve motilite parametresi ölçümleri incelendi.

Bölüm 5. Sonuçlar ve Öneriler.

Bu bölümde, tezde elde edilen sonuçlar ve katkıları özetlenerek gelecekte yapılması planlanan çalışmalara yer verildi



KURAMSAL TEMELLER


Bu bölümde, ilk olarak sperminin anatomik yapısını ve interfelitte tespiti için gerçekleştirilen analiz yöntemlerini açıklayacağız. Daha sonra bilgisayarlı görme alanında son yıllarda gerçekleştirilen video görüntülerinde hareketli nesnelerin tespiti (tanımlanması) ve takip edilmesi için önerilen yöntemleri inceleyeceğiz. Son olarak sperm analizi amacıyla geliştirilen çalışmaları tanıtarak, bu tezin katkılarını açıklayacağız.

2.1 İnsan Spermatozoası Fizyolojisi

Testis tüplerinin içinde günlük olarak milyonlarca sperm hücresi üreyebilir ve testislerin normal çalışması için testislerin vücut sıcaklığının en az 3 derece altında olması gerekir. Testislerde sperm üretildikten sonra, testislerin arkasındaki epididimde saklanırlar. Sperm üretimi, birbirini tamamlaması gereken birkaç faktör gerektirir, en önemlisi testosteron üretimidir. Testis içindeki tüm spermatogenez süreci yaklaşık 64 gün sürer (Ayad 2018). Sperm taşıyıcı kanallara hareket etmek için üç aya ihtiyaç duyar. Yetişkin ve sağlıklı bir insanın vücudu genellikle mililitre meni başına yaklaşık 20-300 milyon sperm üretebilir. Bu, yumurtayı dölemek ve hamileliğe neden olmak için uterusu ulaşan tek bir spermin şansını arttırmaktır (Villines 2019).

2.1.1 İnsan Spermatozoasının Yapısı

Spermatozoonun benzersiz yapısal özellikleri, gübreleme sürecindeki rolü için çok önemlidir. Normal olgun spermatozoa ince uzun bir hücredir ve yaklaşık 60 µm uzunluğundadır (Ayad 2018). Şekil 1'de gösterildiği gibi üç ayrı bölgeye ayrılabilir: kafa, orta parça ve kuyruk, hepsi bir plazma membranı ile çevrilidir. Kafa yaklaşık 3-5 µm uzunluğunda ve 2-3 µm genişliğindedir ve genetik materyal içeren bir nüvetten ve spermin dişi oosit içine nüfuz etmesi için gerekli sindirim enzimlerini içeren kapak benzeri bir akrozomdan oluşur. Orta parça spermin motorudur, yaklaşık 7-8 µm uzunluğunda ve 1 µm genişliğindedir. Spiral benzeri mitokondrilerden oluşur ve kırbaç benzeri kuyruk veya flagella yaklaşık 50 µm uzunluğundadır (WHO 2010; Urbano 2014).



Şekil 1. İnsan spermatozoa yapısı²

2.1.2 Sperm Analizi

Erkek doğurganlık potansiyelinin doğru değerlendirilmesi uzun zamandır araştırmacılar ve klinisyenler için büyük ilgi alanı olmuştur. Sperm analizi, erkek faktörü kısırlığını değerlendirmek için ilk ve en önemli laboratuvar araştırması olmaya devam etmektedir. Sperm analizi sonuçları erkek kısırlığı faktöründe tedavi yaklaşımının ve sonraki sperm hazırlama stratejilerinin belirlenmesine yardımcı olur. Sperm analizi parametreleri, semen viskozitesi, pH, hacim, sperm konsantrasyonu, sperm motilitesi, morfoloji ve canlılığı içerir (Ayad 2018). Genel olarak spermin şekli, hareketi ve konsantrasyonu açısından sperm analizine daha önem verilmektedir.

2.1.2.1 Sperm Konsantrasyonu

Spermatozoanın spermden mililitre başına milyon olarak ifade edilen konsantrasyonu, sperm kalitesinin bir göstergesi ve doğurganlık potansiyeli için tahmin edici bir faktördür. Sperm konsantrasyonu, testiküler sperm üretiminin doğru bir ölçüsü olarak önerilmemektedir, çünkü konsantre epididimal spermatozoanın boşalma sırasında seyreltildiği genital bezi salgılarından etkilenmektedir (WHO 2010, Ayad *et al.* 2018).

2.1.2.2 Sperm Morfolojisi

Spermatozoanın morfolojik özelliklerinin semen kalitesinin değerlendirilmesinde büyük önem taşıdığı düşünülmektedir. Morfolojik olarak normal kabul edilmek için, tüm spermatozoon ve üç ayrı alanı; kafa, orta parça ve kuyruk, boyutları ve şekilleri açısından

² www.shutterstock.com

referans değerlere uymalıdır. Kafanın büyüklüğü, uzunluğu, çevresi, kromozom yüzdesi ve diğerleri gibi belirli parametrelerin değerlerine göre normal ya da anormal olmak üzere iki temel tipte sınıflandırılırlar. Morfolojinin analizinin sadece şekil parametrelerinin özelliklerini çıkarmakla ilgili olduğunu söyleyebiliriz.


2.1.2.3 Sperm Motilitesi

Boşalmış spermatozoanın hareketlilik özelliklerinin belirlenmesinin, spermin fonksiyonel yetkinliği hakkında hayati bilgi sağladığı için erkek doğurganlık potansiyelinin belirlemek için çok önemli olduğu gösterilmiştir (Ayad 2018). Boşalmış spermatozoadaki hareketli spermatozoa yüzdesi epididim sperm olgunlaşmasının bir göstergesidir (Fàbrega et al. 2012; Ayad 2018). Semen içindeki sperm motilitesi, dehidrasyon, PH veya sıcaklık değişimlerinin motilite üzerindeki zararlı etkilerini sınırlamak için numunenin sıvılaştırılmasından sonra, tercihen 30 dakika içinde, ancak her durumda, boşalmadan sonra 1 saat içinde değerlendirilmelidir (Gunalp et al. 2001; WHO 2010).

Sperm hareketinin birkaç sınıflandırması vardır, ancak Dünya Sağlık Örgütü'ne (WHO) göre en güvenilir sınıflandırma hızlı, yavaş ve hareketsiz üç temel tiptir (WHO 2010), aşağıdaki gibi:

1. Aşamalı hareket eden (*Progressively moving PR*): hızlı spermatozoa
2. Yavaş ilerleyen (*Non-progressively moving NP*): yavaş spermatozoa
3. Hareketsiz (*Immotile IM*): hareketsiz spermatozoa.

Spermeleri tıbbi olarak değerlendirmek ve sınıflandırmak için, tamamen güvenilir olan ve Şekil 2' de gösterilen motilite veya hareketlilik parametreleri adı verilen parametreler vardır.



Şekil 2. Sperm hareketlilik parametreleri (WHO 2010)

1. Düz çizgi hızı (*Straight-line velocity VSL*), ilk ve son konumu arasındaki düz çizgi bağlantıları boyunca spermin ortalama hızını açıklar ve matematiksel olarak (WHO 2010; Hidayatullah 2015),

$$VSL_i = \frac{\sqrt{(x_m - x_1)^2 + (y_m - y_1)^2}}{(M-1)\Delta t} \quad (2.1)$$

(x_1, y_1) ise başlangıç noktası koordinatları, (x_m, y_m) bitiş noktası koordinatlarını temsil eder. M , spermin yolu boyunca geçtiği nokta sayısı, Δt her nokta ile bir sonraki nokta arasındaki zaman aralığıdır.

2. Eğrisel hız (*Curvilinear velocity VCL*), gerçek eğri yolu boyunca spermin ortalama hızı.

$$VCL_i = \frac{\sum_{j=1}^M \sqrt{(x_{j+1} - x_j)^2 + (y_{j+1} - y_j)^2}}{(M-1)\Delta t} \quad (2.2)$$

3. Ortalama yol hızı (*Average path velocity VAP*), ortalama yol boyunca spermin ortalama hızıdır. Ortalama yol, eğrisel yörüngenin ortalaması alınarak hesaplanır.

$$VAP_i = \frac{\sum_{j=1}^{M-1} \sqrt{(x'_{j+1} - x'_j)^2 + (y'_{j+1} - y'_j)^2}}{(M-1)\Delta t} \quad (2.3)$$

Burda $x'_k = \frac{1}{5} \sum_{i=k-2}^{k+2} x_i$, $y'_k = \frac{1}{5} \sum_{i=k-2}^{k+2} y_i$.

4. Yanal kafa yer değiştirmesinin (*Amplitude of lateral head displacement ALH*) genliği aşağıdaki denklemle veriliyor,

$$ALH_t(k) = \frac{2}{T_s} \sum_{i=k-n_s}^k \|z_t(i) - z_s^t(i)\| \quad (2.4)$$

T_s süre, $z_t(i)$ i zamanında sperm başı pozisyonu, $z_s^t(i)$ hareketli ortalama, $n_s = 5$.

5. Doğrusallık (*Linearity LIN*),

$$LIN_i = \frac{VSL_i}{VCL_i} \quad (2.5)$$

6. Ortalama yol düzlüğü (*Average straightness STR*),

$$STR_i = \frac{VSL_i}{VAP_i} \quad (2.6)$$

7. Eğrisel yol yalpalama (*Curvilinear path wobble WOB*), ortalama yolun gerçek yolunun dalgalanma büyüklüğü,

$$WOB_i = \frac{VAP_i}{VCL_i} \quad (2.7)$$

Yukarıdaki tüm parametreler hastanın durumunu teşhis etmek için kullanılır, ancak sperm sınıflamasında VCL, VSL ve LIN en önemli faktörler arasındadır.

2.1.3 Mikroskop ile Sperm Analizi

Mikroskop ile sperm analizi laboratuvarında teknisyen tarafından gözlem yolu ile gerçekleştirilir. (Rothmann *et al.* 2007). Sonuç olarak, teknisyen deneyimi ve kullanılan protokoller sperm analizinin sonuçlarında farklılıklara neden olabilir. Toplam sperm sayısı ve konstantrasyonu mikroskopta belirlirli bir alanda ölçümü alınan değerlere göre orantısal olarak tahmin edilir. Ancak bu tahmin doğru olduğu varsayılrsa bile hastanın kısırlılığının nedenini açıklamak için anlamlı bir tanısal değere sahip değildir (Urbano 2014). Bunun yerine spermin hareket özelliklerinin tespiti teşhis için daha büyük klinik öneme sahiptir (Mortimer *et al.* 2000).

Bununla birlikte, dinamik sperm motilite parametreleri uzmanlar tarafından görsel olarak ayırt edilebilmek için çok karmaşık ve imkansızdır. Sperm motilitesinin manuel mikroskopik tahmini sübjektiftir ve laboratuvar varyasyonlarıyla yüksek oranda ilişkilidir. Aynı semen örneği içinde, manuel olarak değerlendirilen insan ejakülatlarında % 30-60'lık varyasyonlar olduğu tahmin edilmektedir (Ayad 2018).

2.1.4 Bilgisayar Destekli Semen Analizi (CASA) Sistemleri


CASA, spermatozoayı mikroskop lenslerinden geçirebilen ve sperm hızı, sayımı ve şekli de dahil olmak üzere birçok parametresini ölçebilen ve nihayetinde sınıflara ayıran ve bunları tıbbi değerlendirme için kullanan bir donanım ve yazılım sistemidir (Wang *et al.* 2011). 1980'in ortalarında, bilinen ilk CASA sistemi, sperm motilitesini tespit etmek için kliniklerde kullanılmaya başlandı. Ne yazık ki, bu erken nesil makineler pratik uygulamalar için yeterli doğruluk göstermedi. Bununla birlikte, son yirmi yılda, önceki sistemlerde sınırlı olan

sorunların birçoğu, biyomühendislik ve bilgisayar mühendislerin ilgi odağı haline geldiğinden önemli yenilikler ve iyileştirmeler getirildi (Ayad 2018).

CASA sistemlerinde video görüntülerinden görüntü işleme teknikleri ve algoritmaları kullanılarak spermlerin hareket ve morfoloji analizlerini otomatik olarak gerçekleşmesi amaçlanmıştır. Hareketlilik analizi için kullanılan neredeyse tüm CASA sistemleri iki temel adımda çalışır: 1) kaydedilen video karelerinde spermin saptanması (hareketli nesne tespiti), 2) tespit edilen spermlerin yüzme yörüngeleri bir dizi video karesi üzerinde takip edilmesi (hareketli nesne takibi). Yüzme yörüngeleri çıkarıldıktan sonra, spermlerin motilite parametreleri hesaplanır. Örnek bir popülasyonu karakterize edilerek için istatistiksel olarak spermlerin morfolojik analiz sonuçları çıkarılır (Amann *et al.* 2014). CASA sistemleri manuel (mikroskop) tekniklerden hız açısından üstün olmasına ve sperm örneğinin analizi için birçok detaylı sonuç vermesine rağmen, yüksek maliyeti nedeniyle bir çok klinikte uygulanma şansı bulunmamaktadır. Bildiğimiz kadarı ile mevcut sperm analizlerin <% 2'sinde CASA sistemleri kullanılmaktadır. CASA'nın sınırlı kullanımı, ayrıca cihazlarda kontrol edilmesi gereken birçok ayarı içerdiğinden ve düzenli bakım gerektirdiğinden iyi eğitilmiş teknisyenlere ihtiyaç duymaktadır ki bu durumda sistemin kullanılması için maliyeti oldukça fazla arttırmaktadır (Schleh *et al.* 2013; Sherins *et al.* 1991; Urbano 2014)

2.2 Video Görüntülerinden Sperm Hareketlerinin Analizi

Video görüntülerinden sperm hareketliliğini analizi, bilgisayar bilimi alanında hareketli nesne tespiti, takibi ve analizi alanı altında inceleyebiliriz. Video görüntülerinden hareketli nesne takibi ve analizi, bilgisayar görü alanında uzun yıllardan beri çalışılan ilgi çekici bir konudur. Video görüntülerinden tek veya birkaç hareketli nesnenin tespiti, takibi ve davranışlarının incelenmesi bu alanda yapılan güncel araştırma konularıdır (Yılmaz *et al.* 2006).



Şekil 3. Video görüntülerinden nesne takibi ve analiz aşamaları

Şekil 3 de görüleceği üzere video analiz sistemlerini (Hareketli nesne takibi) üç ana aşamadan meydana gelir (Yılmaz *et al.* 2006; Athanesisious *et al.* 2012): 1) Hareketli nesnelerin tespiti veya algılanması, 2) tespit edilen nesnenin hareketinin izlenmesi, 3) tespit edilen yörüngelerin analizi. Biz bu çalışmada hareketli nesnenin (spermilerin) izlediği yörüngeleri tespit ederek son aşamada bulunan analiz kısmında sperm motilitesi için gerekli hesaplamaları ve değerlendirmeleri yapacağız.

2.2.1 Nesne Tespiti (Algılama)

Nesne tespiti temelde görüntü veya video çerçevesindeki ilgili her nesnenin konum bilgisinin elde edilmesidir. (Beyaz *et al.* 2015). Bu aşama, nesne takibi algoritmalarının ilk adımı olduğundan hareketli nesnenin pozisyonun yüksek doğrulukla hesaplanması takip algoritmalarının başarımını etkileyecektir. Bu aşamanın çıktısı tespit edilen hareketli nesnenin merkezi, sınırlayıcı kutu veya sınırlayıcı elips gibi merkezi bulunan nesnenin sınırları, nesne iskeleti veya nesnenin açı veya histogram gibi diğer özellikleridir (Yılmaz *et al.* 2006). Bu çıktı hareketli nesnenin bulunduğu ortama, hareket hızına ve problem karmaşıklığına göre değişir. Nesne tespitinin doğruluğunu arttırmak için eşikleme, erozyon, dilatasyon, açık, kapat ve etiketleme karesi farkı, arka planı çıkarma ve optik akış gibi görüntü işleme yöntemleri kullanılmaktadır.

2.2.2 Nesne Takibi

Nesne izleme ya da takibi, her video karesindeki tespit edilen nesnenin bir sonraki video karesindeki pozisyonuna bağlantılıdır. Bir başka ifade ile nesne takibi video kareleri boyunca nesnelerin konumlarını temsil eden bir yol verisini içerir. Bu konumlar, nesnelerin tahmini yollarını oluşturmak için birbirine bağlanır. Yol verisi daha sonra, hareketlilik analizi aşamasının girdisini temsil edecektir. Böylece nesne izleme işlemini şu şekilde tanımlayabiliriz: Nesne izleme süreci bilgi kaybı, görüntülerde gürültü, kısmi ve tam nesne tıkanıklıkları, sahne aydınlatma değişiklikleri ve gerçek zamanlı işleme gereksinimleri gibi karmaşık koşullar altında video kareleri boyunca bir nesnenin izini tahmin etme problemidir. Veri ilişkilendirme algoritmaları (DA) en çok hareketli nesne takibinde kullanılır ve nesnenin yolu boyunca birbirleri arasındaki noktalara bağlantı olarak kullanılır. Bu tekniklerden ayrıca bu çalışmada NN, GNN, PDAF ve JPDAF yöntemleri açıklanmıştır. Bu teknikler esas olarak radar sistemlerinde kullanılmaktadır, ancak izleme ilkelerinin benzer olduğu ve videoyu izleme durumunda karşılaştığımız aynı engelleri bulabileceğimiz için de kullanılmıştır.

2.2.3 Hareket Analizi

Hareket eden nesnenin izini analiz etme aşaması elimizdeki konuya bağlıdır. Çalışmamızda, sperm hareketi ile ilgili çeşitli parametreleri ifade etmek için kullanılan (2.1)-(2.7) arasındaki denklemler kullanılacaktır.

2.3 Literatür Taraması

Bu bölümde sperm motilite analizi alanında geliştirilen birçok sistemi ve sperm tespiti ve takibi için önerilen algoritmaları tartışacağız. Bu noktada sperm motilite analizi adımı tüm bu çalışmalar için ortak bir adımdır.

(Hidayatullah 2015) , video görüntülerinden spermlerin tespiti ve video karelerindeki spermleri saymak için bir algoritma (Hidayatullah *et al.* 2014) önerdi. Önerilen yöntem temelde görüntüdeki sperme benzer karakterde olan geometrik şekilleri (elips) tespit etmektedir. Sperm başının elips ile tam olarak aynı olduğunu göz önünde bulundurarak spermin konumunu doğru bir şekilde tespit etmeyi amaçlamıştır. Bir başka ifade ile elips şekillerini arka plandan bölütlemiştir. Spermlerin takibi aşamasında, her sperm için bir sonraki yerleri varsaymak için Kalman Filtresine ve veri ilişkilendirme tekniği olarak *HUNGARIAN* (Jonker *et al.* 1986) algoritmasına dayanan basit ve hızlı bir algoritma olan *SORT* (Jonker *et al.* 1986) tekniği kullanılmıştır. *HUNGARIAN* algoritması ise atama sorununun çözümü olarak kabul edilir. İzleme aşamasında *SORT* tekniği kullanılmıştır. Her iki algoritmanın beraber kullanılması sonuçların performansını ve doğruluğunu arttırdığı gözlemlenmiştir. Bu durumun sebebi spermi tespit etmek için önerilen algoritmanın yüksek başarımıdır. Bilindiği üzere hareketli nesne tespit aşamasının başarımı çok yüksek ise, nesne takibi aşamasının performansının iyileştirilmesine yardımcı olur. Ancak görüntüdeki sperm sayısının fazla olması bu yaklaşımın sperm analizinde mutlaka çok doğru sonuçlar vereceği anlamına gelmez ve nesne takibinde kullanılan algoritmanın yüksek doğrulukta sonuçlar vermesi gerekir.

(Hidayatullah *et al.* 2016), elips algoritması (Hidayatullah *et al.* 2014) çalışmasını referans alarak yeni bir algoritma önermiştir. Bu çalışmada eşleştirme-tabanlı izleme algoritması olarak kullanılmıştır. Önerilen algoritma, sperm pozisyonlarının tespitine ek olarak sperm hareketini tahmin etmek için sperm kafası hareket yönü ekleyerek daha kararlı sonuçlar elde etmiştir.

(Urbano 2014; Urbano *et al.* 2016) 'da, sperm tespiti ve takibi için tam otomatik entegre bir sistem geliştirmeye çalışmıştır. Sperm tespiti aşamasında gürültüyü gidermek için *Gaussian* filtresi, video karelerinden spermleri çıkarmak için Otsu yöntemi kullanmıştır. Görüntüden sadece spermleri elde etmek için açık, erozyon, dilatasyonu gibi bazı morfolojik işlemleri

kullanmıştır. Bu çalışmada tespit algoritması performansının iyi olmasına rağmen farklı aydınlatmaları olan videolarda doğruluğu azaldığı gözlemlenmiştir. Nesne takibi için *JPDAF* izleme algoritması olarak kullanılmıştır. Özellikle tespit aşamasından kaynaklanabilecek yanlış alarm (*FA*) ve kaçırılan tespitler gibi karmaşık koşullar altında çok iyi bir performansa sahiptir. Çalışmada *JPDAF* algoritması , *GNN* ve *PDAF* gibi diğer algoritmalarla karşılaştırılmıştır. *JPDAF* algoritmasının sonuçları, sperm motilite analizi probleminde uygulanan diğer çalışmalara kıyasla yüksek doğruluk performansına sahiptir. Bu yaklaşım 2 farklı semen örneğine uygulanmıştır.

(Athanesious *et al.* 2012) çalışmasında semen motilite ve morfoloji açısından analiz etmiştir. *JPDAF* algoritması da hareketli nesne takibi için kullanılmış, ancak sperm koordinatlarına ek olarak, durumunu tanımlamak için spermin yönü eklenmiştir. Böylece (Urbano *et al.* 2016)' dan daha yüksek doğru sonuçlar elde etmiştir.

(Jati *et al.* 2016)' da nesne tespiti aşamasında gürültü azaltma ve bölütleme algoritmaları kullanılmıştır. Sperm pozisyonlarını tahmin etmek için kalman filtresi ve sperm pozisyonlarını bağlamak ve sperm yörüngelerini oluşturmak için *HUNGARIAN* atama algoritmaları kullanılmıştır.

(Beya *et al.* 2015)' te, eşikleme ve kontrast germe işlemlerinden oluşan bir ön işleme aşaması gerçekleştirilmiştir. Ön işleme aşamasında görüntülerde potansiyel bölgeler incelenmiştir. Daha sonra bu bölgeden öznitelikler çıkartılarak Destek Vektör Makinesi'ne (*SVM*) girdi olarak kullanılmıştır. *Mean Shift* algoritması takip algoritması olarak kullanılmıştır. Sistem, halihazırda konuma verilerine sahip olan üç koyun sperm videosu örneği üzerinde test edilmiştir. Deneysel sonuçlarda video görüntülerinden sperm algılama ve takibinin yüksek başarımla elde edildiği gözlemlenmiştir.

(Hidayatullah *et al.* 2017)' de, sperm motilite analizi için literatürde yaygın olarak önerilen çoğu algoritmalar ve bu algoritmaların avantajları ve dezavantajları tartışılmıştır. Bu çalışmaya göre en iyi hareketli sperm tespit yöntemi olarak Gaussian Karışımı ve takipte en iyisi *JPDAF* olduğu belirtilmiştir. Bu araştırmada incelenen teknikler ve algoritmalar aynı veri kümelerinde karşılaştırılmadığından hangisinin en iyi performansa sahip olduğunu doğrulamak mümkün olmamıştır.

(Alhajalabdulla 2020)' de, sperm hücrelerini yüksek doğruluk ve verimlilikle tespit eden bir algoritma önermiş ve önerdiği yöntemi takip algoritmaları üzerinde performansların karşılaştırmıştır. Video görüntülerinden sperm hücrelerinin doğru bir şekilde tespit etmek için eşit olmayan ışıklı görüntüler kullanılmıştır. Çakışan spermleri tespit etmek için spermlerin kenar bilgilerini Convex Hull yöntemi kullanarak elde etmiştir. *GNN* algoritmasına benzer bir

yeni bir *Branch and Bound* algoritması geliştirilerek sperm hareketlerini takip etmişlerdir. Önerilen algoritma tezde bizimde kullandığımız koç, boğa ve aygır sperm videolarına uygulanmıştır. Önerilen algoritmanın başarımları NN, GNN, PDAF, JPDAF and ENN-JPDAF takip algoritmalarına uygulanarak performansı karşılaştırılmıştır. Önerilen algoritmanın doğruluk ve zaman açısından performansı diğer takip algoritmalarından çok yüksek olduğunu gözlemlenmiştir.

2.4 Tezin katkısı

Bu tezde öncelikli amacımız, spermleri sınıflandırmada kullanılan motilite parametrelerini belirlemede en iyi ölçümünü elde etmek için video görüntülerinden hareketli spermlerin takibini yüksek doğrulukla gerçekleştiren bir takip algoritması geliştirmektir. Bu amaç doğrultusunda literatürde hareketli nesne tespiti ve tabiki için önerilen farklı algoritmalar tez kapsamında uygulanmış, test edilmiş ve farklı senaryolar ile karşılaştırılmıştır. Spermlerin hareketleri yüksek manevra kabiliyetine sahip olması nedeniyle, hareketli nesneleri takip etmek için *Bayesian* ve *IMM* filtresini birleştiren yeni bir yöntem önerilmiştir.

MATERYAL VE METOD

Bu bölüm iki ana kısımdan oluşmaktadır: Birincisi, video görüntülerinden hareketli nesnelerin tespit edilmesi ve takibi için tez kapsamında kullanılan algoritmaların matematiksel olarak temellerinden bahsedilmiştir. İkinci bölümde, sperm hareketlerinin takibi ve motilitesi parametrelerinin hesaplanması için kullanılacak olan önerdiğimiz yöntem ayrıntılı bir şekilde açıklanmıştır.

3.1 Materyal

Tez kapsamında Atatürk Üniversitesi, Veterinerlik Fakültesi tarafından sağlanan boğa aygır ve koça ait mikroskoptan çekilen video görüntüleri kullanılmıştır. Tablo 1’ de bu video görüntülerine ait teknik veriler gösterilmiştir. Bu video görüntülerinde farklı yoğunlukta ve hızda hareket eden sperm görüntüleri bulunmaktadır. Şekil 4’ de görüleceği üzere üç farklı hayvanlara ait spermlerin kafa ve kuyruk yapılarında da farklılıklar bulunmaktadır. Veri setindeki her bir video *.avi formatında kayıt edilmiştir. Tablo 1 de görüleceği üzere boğa sperm videonun süresi 5.06 saniye, kare sayısı 253, 640*480 piksel boyutunda ve video kare hızı 50 fps'dir. Her kare arasındaki zaman adımı 0.02 saniyedir, az sayıda sperm içerir. Boğa spermi örneğinin ikinci videosu da aynı özelliklere sahip, ancak çok sayıda sperm içeriyor. Veri setinde boğa haricinde aygır ve koç video görüntüleri bulunmaktadır. Boğa için üç farklı, aygır için dört farklı ve koç için beş farklı video örnekleri veri setinde bulunmaktadır. Bu videoların süresi, boğa için 30, aygır ve koç 10 saniyedir. Herbir video 768*576 piksel boyutunda, video kare hızı 25 fps'dir ve her kare arasındaki zaman adımı 0.04 saniyedir. Boğa videolarından biri yüksek yoğunluklu, diğer ikisi az yoğunluklu. Ancak tüm koç ve aygır videoları az yoğunluklu.


Tespit sisteminden elde edilen ölçümleri simüle eden noktalar olan önerilen yöntemin performansını test etmek için sentetik veriler de oluşturulmuş ve sperm hareketini simüle eden sekiz senaryo oluşturulmuştur.

Tablo 1. Sperm Analiz Sisteminde Kullanılan Spermilerin Örnekleri ve Sentetik Verileri


sperm	Adet	Vidoe frames	fps	Süre (saniye)	Yoğunlu
Boğa-1	1	640*480	50	5.06	Az
Boğa-2	1	640*480	50	5.06	Çok
Boğa-3	2	768x756	25	30	Az
Boğa-4	1	768x756	25	30	Çok
Koç	5	768x756	25	10	Az
Ayır	4	768x756	25	10	Az
Sentetik Veriler (Tespit sisteminden üretilen ölçümleri simüle eden noktalar).	8	-	15	6.6	Az




(a)



(b)



(c)



(d)

Şekil 4. Verisetlerinde bulunan a, b) boga, c) koç ,ve d) aygır spermilerin örnek vidoe görüntüleri

3.2 Metodlar

İlk olarak önerdiğimiz yöntemde kullanılan nesne tespiti ve takibi algoritmalarının temel tanımlarını ve matematiksel olarak denklemlerini anlatacağız. Bu iki adım video analiz sistemi diye adlandırdığımız sperm motilite parametrelerinin hesaplanmasının temelini oluşturur. Tespit işlemi, görüntü veya video çerçevesindeki ilgili her bir nesnenin konumunun belirlenmesi olarak tanımlanır. Tespit edilen nesne bir girdi olarak nesne hareket takibi algoritmaları kullanılarak tespit edilen nesnelerin yörüngeleri çıkarılacaktır (Yılmaz *et al.* 2006).


3.2.1 Nesne Tespiti Temelleri

Video görüntülerinden hareketli nesne algılama ya da tespiti, video analiz sisteminin ilk adımı olarak kabul edilir. Bu aşamada nesne video görüntüsünde konumu belirlenir ve tespit edilen nesneden belirli öznelilikler çıkarılır. Sabit arka plandan tespit edilen nesnelerin bölümlere ayrılmasını sağlar (Joshi *et al.* 2012). Tespit edilen nesne farklı şekillerde temsil edilir ve bu temsil takip algoritmasına göre değişir.

3.2.1.1 Nesne Temsili


Nesneler imgelerde **şekilleri** ve **görünüşüyle** temsil edilebilir ve farklı takip problemlerine göre özellikleri belirlenir. Şekil 5'de gösterildiği üzere beş farklı şekil ile kategorize edilir (Yılmaz *et al.* 2006):

1. Noktalar: Genel olarak nokta gösterimi, sperm izleme problemimiz gibi küçük bölgeleri işgal eden nesneleri izlemek için uygundur. Nesnenin merkezi konum noktası Şekil 5 (a) veya bir dizi spesifik nokta Şekil 5 (b) ile gösterilmiştir.



Şekil 5. Nesne gösterimleri. (a) Merkez, (b) çoklu noktalar, (c) dikdörtgen yama, (d) eliptik yama, (e) parça tabanlı çoklu yamalar, (f) nesne iskeleti, (g) tam nesne çevresi, (h) nesne çevresi üzerindeki kontrol noktaları, (i) nesne silueti. (Yilmaz et al. 2006)

2. İlkel geometrik şekiller: Bu gösterim basit katı nesneleri temsil etmek için daha uygundur. Bu yaklaşımda nesne şekli bir dikdörtgen veya elips ile temsil edilir (Şekil 5 (c), (d)). Buradaki odak, döndürme, geçiş veya boyutlarını değiştirme veya projektör gibi zaman içinde değişikliklerin meydana gelebileceği bir nesneyi takip etmektir. Bu hareket türleri Şekil-6 de gösterilmiştir.
3. Nesne silueti ve çevresi: Kontur gösterimi bir nesnenin sınırını tanımlar (Şekil 5 (g), (h)). Kontur içindeki bölgeye Şekil 4 (i) 'nin silueti denir. Siluet ve kontur gösterimleri karmaşık rijit olmayan şekilleri izlemek için uygundur (Balci et al. 2004).



Şekil 6. Dönüşüm modelleri (Yilmaz et al. 2006)

4. Eklemlı şekil modelleri: Mafsallı nesneler, insan vücudu gibi eklemlerle birlikte tutulan nesne parçalarından oluşur. Nesne özellikleri, Şekil 5 (e) 'de gösterildiği gibi silindirler veya elipsler kullanılarak modellenenebilir.
5. İskelet modelleri: İskelet temsili hem eklemlı hem de katı nesneleri modellemek için kullanılabilir Şekil 5 (f).

Ayrıca, bir nesnenin görünüşünü temsil etmek için, genellikle aşağıdaki gibi kategorize edilen bir dizi yol vardır (Yılmaz *et al.* 2006):

- Nesne görünüşünü olasılık yoğunlukları: Nesne görünüşünü olasılık yoğunluğunu temsil etmek için Gaussian (Zhu *et al.* 1996) veya Gaussian Karışımı (Paragios *et al.* 2002), parametrik tip veya histogramlar gibi parametrik olmayan (Comaniciu *et al.* 2003) olarak kullanılabilir. Nesne görünüm özelliğinin olasılık yoğunlukları, nesnenin belirtildiği iç alandan çıkarılabilir ve elbette burada nesne geometrik olarak veya sınırı ile tanımlanabilir.
- Şablonlar: Şablonlar, nesne hakkında hem mekansal hem de görünüm bilgisi taşıırken, basit geometrik şekiller veya silüetler (Fieguth *et al.* 1997) kullanılarak oluşturulur. Ancak şablonlar, nesneyi tek bir bakış açısından modeller.
- Çoklu bakış görünüş modelleri: Şablon modelinin genel durumu olarak düşünülebilir. Bu gösterim türü, nesneyi çoklu ve farklı bakış açısından modeller.
- Aktif görünüm modelleri: Nesnenin şekli ve görünüşünü aynı anda modellenerek oluşturulur.

Nesne tespiti bilgisayarlı görme alanında üzerinde çalışılan güncel bir araştırma konusudur. Bu nedenle bu tez kapsamında tek bir model kullanmaktan ziyade, daha soğru sonuçlar elde etmek için birden fazla yöntemi birleştirdik.

3.2.1.2 Nesne Tespit Yöntemleri

Bu bölümde nesne tespiti yöntemlerinin tanımları ve özellikleri verilmeden önce, sayısal görüntü işleme için tez kapsamında uyguladığımız süreçler hakkında genel bilgiler verilmiştir.

3.2.1.2.1 Ön işleme

Sayısal görüntüler elde edilirken ışık kaynağı, kameranın çözünürlüğü, kullanılan lensin yapısı ve çevresel faktörler nedeniyle çeşitli gürültülere maruz kalırlar. Gürültü, görüntünün piksel kontrastlarında bir hatadır ve gerçek değeri yansıtmaz, aksine başka bir değer verir. Bir

başka ifade ile görüntüler gürültü ile bozulur. Çoğu zaman görüntüleri bu nedenle ön işleme tabi tutması gerekir. Ön işleme aşamasında, gürültüyü kaldırmak için, doğrusal ve doğrusal olmayan iki tipte yumuşatma filtreleri uygulayabiliriz (Hambal *et al.* 2017). En önemli doğrusal filtre türlerinden biri, belirli bir tür gürültüyü gidermek için kullanılan *Gauss* ve *Wiener* filtresidir (bir tür uyarlamalı doğrusal filtre). Doğrusal olmayan filtreler için, Medyan ve Ortalama filtre örnek olarak verilebilir. Medyan Filtresi, ince çizgiler ve köşeler gibi gürültüyü azaltırken görüntü ayrıntılarını kaldırma eğilimindedir (Yang 2014).

3.2.1.2.2 Kenar algılama

Sayısal görüntü işleme uygulamalarında, nesnenin belirgin bir özelliği kenar bilgisidir. Literatürde *Sobel*, *Canny*, *Prewitt*, *Roberts* algoritmaları görüntüde en doğru kenar bulan algoritmalar olarak bilinir (Dharampal 2015).

3.2.1.2.3 Eşikleme

Renk dönüştürmesini gri renge uyguladıktan sonra, arka plan pikselleri nesnenin piksellerinden değerlerine göre ayırt edilir ve nesneyi arka plandan ayırmak için, görüntü piksellerinin iki gruba ayrıldığı durumlarda sözde eşik uygulanır. İlk grup eşik değerinden daha büyük bir değere sahip pikseller ve eşik altında değerlere sahip ikinci pikseller içerir. Tatmin edici sonuçlar vermek için eşik değerini doğru seçmek çok önemlidir. Bu değer manuel olarak ayarlanabilir ve en iyi değer denenerek elde edilebilir. *Otsu* (Otsu 1979) histogram eşik değerini bulmaya dayanan en bilinen algoritmalarından biridir. *Otsu* yöntemi, iki sınıfın arka ve ön planının ağırlıklı varyans toplamı olarak tanımlanan sınıf içi varyansı en aza indiren optimum eşik araştırılmaktadır (Otsu 1979). Bu yöntem etkili ve uygulanması kolaydır, ancak farklı ışık bölgeleri içeren görüntülerde performansı çok azalır. Uyarlanabilir yerel filtre (*Adaptive local filter*), görüntünün belirli alanlarındaki aydınlatma kontrastı problemini çözmek için çok etkili bir tekniktir. Bu yöntem ile görüntünün her bir kısmı için farklı bir eşik değeri uygulanır. Ayrıca, çeşitli alanlarda kullanılan bölütleme için k-ortalamlar (*Kmeans*) tekniği kullanılarak görüntü piksellerini seçilen öge sayısına göre renk alanlarına sınıflandırılır.

3.2.1.2.4 Morfolojik işlemler:

Çoğu zaman, nesneyi arka plandan daha iyi çıkarmak için eşikleme işleminden kaynaklanan görüntüyü iyileştirmemiz gerekir. Elde edilen görüntüyü iyileştirmek için sıklıkla kullanılan erozyon, genişleme, açma ve kapatma gibi morfolojik işlemler kullanılır.

3.2.1.2.5 Bölge etiketleme:

Sayısal görüntüler ön işlemden geçirildikten sonra, siyah rengin arka planı ve beyaz ön planı oluşturduğu siyah beyaz bir görüntü elde ederiz. Ancak ön planı birbirinden ayırmak için, bitişik alanlara bağlı olarak onlara bir adres veya numara verilir. İkili sayısal görüntülerde 4-bağlantı veya 8-bağlantı olduğunu varsayarak bağlı bölgelerin kümesini tespit etmek için kullanılan bağlı bileşen etiketleme (Connected component) tekniği kullanılmaktadır.


3.2.1.3 Tespit Tekniği Sınıflandırması

(Yilmaz *et al.* 2006) 'te nesneyi tespit etmek için algoritmalar dört kategoride sınıflandırılmaktadır:

- Nokta dedektörleri: Görüntünün ilgi çekici noktalarını tanımlamak için kullanılır. Noktalar, aydınlatmadaki değişiklikler gibi çevresel koşullardan etkilenmemelerini sağlayan ayırt edici özelliklerle seçilir. *Harris* noktası , *Kanade Lucas Tomasi KLT* ve *SIFT* dedektörü nokta dedektörü algoritmalarıdır (Harris *et al.* 1988; Shi 1994;).
- Arka Plan Çıkarma: Arka planın belirli teknikler kullanılarak modellenip, video karelerinde bulunan hareketli nesnelerden farkı alınarak ayrıştırılır. En popüler tekniklerden biri, Gauss karışımı (*Mixture of Gaussian*) (Yilmaz *et al.* 2006) yöntemidir.
- Bölütleme: Görüntüleri belirli kriterlere göre benzer parçalara böler. Örneğin, görüntüde benzer şekillere veya eşit renk alanlarına bölütlenmesi verilebilir. Ortalama kayma (*Mean-shift*) (Yilmaz *et al.* 2006) ve grafik-kesme (*Graph-cut*) (Yilmaz *et al.* 2006) yöntemleri en bilinen bölütleme tekniklerindendir.
- Denetimli Öğrenme: Nesne tespitinden sonra tespit edilen nesnenin tanınması denetimli öğrenme algoritmaları kullanılarak gerçekleştirilir. Son yıllarda Destek Vektör Makineleri ve Sinir Ağları bu alanda kullanılan ve bilinen en popüler denetimli öğrenme algoritmalarıdır (Papageorgiou 1998; Rowley *et al.* 1998).

3.2.1.3.1 Tespit Tekniklerinin Önerilen Sınıflandırması

Çeşitli çalışmalara dayanarak (Joshi *et al.* 2012; Nurhadiyatna *et al.* 2014; Yang 2014; Xu *et al.* 2017) Şekil 7'te gösterildiği gibi kullanılan video kareleri sayısına bağlı olarak nesne tespitini iki temel kategoride sınıflandırdık. Birinci kategoride , hareket veya hareket eden nesneleri tespit etmek için birden fazla kare kullanılır. Bu alanda kullanılan yöntemlerden en yaygın olanları arka plan çıkarma, kare farkı ve optik akış algoritmalarıdır. İkinci kategoride ise, nesne ister sabit isterse hareketli olsun, yalnızca bir kareye uygulanan nokta dedektörü



Şekil 7. Nesne tespit tekniklerinin sınıflandırılması

teknikleri de dahil olmak üzere önceki bölümde bahsettiğimiz görüntü işleme teknikleri ve Denetimli Öğrenme kullanılabilir.

- ***Kare Farkı (Frame difference):***

Hareketli nesne iki veya üç ardışık kare (frame) alıp birbirinden çıkartılarak elde edilir (Yang 2014; Srivastav *et al.* 2017). Ancak hareketli nesnenin hızı artınca, saniyedeki kare sayısı azalınca ve görüntüde birden fazla hareketli nesnenin olduğu durumlarda başarımlar azalmaktadır.

- ***Arka plan çıkarma (Background Subtraction):***

Yalnızca bir sabit kameramız olduğu varsayılarak video boyunca statik arka planı bulmaya dayanır. Bu prensibi arka planı temsil etmek için üç veya dört dağılım kullanan Gauss Karışımı gibi çeşitli teknikler kullanılmaktadır. Başka bir basit yol, arka plan ayıklamak için kare piksel değerlerinin ortalamasını kullanmaktır. Bu yöntemde, arka planı ayıklamak için tüm video karelerinin veya belirli bir sayının ortalaması alınır, hareketli nesneler karenin ortalamasını alarak kaldırılır ve yalnızca statik nesneler kalır.

$$I_{avg}(x,y)_{m*n} = 1/f * \sum_{i=1:f} I(x,y)_{m*n} \quad (3.1)$$

$I(x, y)$ kare görüntüsü, $m * n$ videonun kare boyutları, f kare numarası, $I_{avg}(x, y)$ video arka planı.

Ortaya çıkan görüntü, statik nesneleri içeren sabit video arka plan görüntüsüdür. Dolayısıyla, sabit nesneleri de tanımlamak istiyorsak, bazı görüntü işleme seçimleri uygulayabiliriz. Arka planı belirledikten sonra, hareketli nesneleri çıkarmak için her çerçeveden çıkarırız,

$$I_{diff}(x,y)_{m*n} = I_i(x,y)_{m*n} - I_{avg}(x,y)_{m*n} \quad (3.2)$$


Ortaya çıkan görüntü I_{diff} , yalnızca hareketli nesneler içeren arka plan ve çerçeve arasındaki farktır.

- **Optik Akışı (Optical Flow):**

Hareket nesnesini vektörlerle tespit etmek için en iyi ve en doğru tekniktir. Optik akış yöntemi, videonun iki ardışık karesi boyunca gerçekleşen hareketi tespit etmek için akış vektörleri kavramlarını kullanarak hareketin algılanmasını tanımlar (Agarwal *et al.* 2016).

$$f(x, y, t) = f(x + dx, y + dy, t + dt) \quad (3.3)$$

dx iken, dy piksel (x, y) ofsetidir. Burada x, y, t , üç boyut fonksiyonunun t zamanında piksel (x, y) olarak ve bir sonraki seferde $t + dt$ yakınındaki piksele $(x + dx, y + dy)$ bakarak akış yön bilgisi elde edilir. Daha sonra (x, y) 'deki yoğunluk ve $(x + dx, y + dy)$ 'deki yoğunluk arasında bitişik kareden geçerken piksel yoğunluğunun aynı veya çok yakın kaldığını varsayan parlaklık kısıtı altında benzer olacaktır (Şekil 8). Böylece denklem (3.3) yazabiliriz.



Şekil 8. Piksel geçişi ve sonuçta oluşan akış vektörü

(3.3) 'ün sağ tarafındaki Taylor Serisini (Taylor yaklaşımı) bularak, (3.4) denklemi elde ederiz,

$$f(x + dx, y + dy, t + dt) = f(x, y, t) + df/dx \delta x + df/dy \delta y + df/dt \delta t \quad (3.4)$$

$f(x, y, t)$ 'i ikinci denklemin iki tarafından iptal edilerek,

$$f_x dx + f_y dy + f_t dt = 0 \quad (3.5)$$

Denklemi dt 'ye bölerek aşağıdaki (3.6) nolu denklemi elde ederiz,

$$f_x u + f_y v + f_t = 0 \quad (3.6)$$

Optik Akış denklemi olarak adlandırılan bu denklem (3.6), optik akış denklemini çözmek ve piksellerin yönünü ve hızını ifade eden u , v 'yi bulmak için çeşitli yöntemler kullanılır. x ekseninde $u=dx/dt$ ve y ekseninde $v=dy/dt$ tanımlı optik akış ifadelerinin birinci dereceden türev denklemlerini, Lucas-Kanade, Farneback ve Horn-Schunck yöntemler kullanılarak çözümü gerçekleştirilir. Optik akış algoritması, nesne takibi için görüntüdeki açılarının hesaplanmasında veya hareketli nesneleri tanımlamak için görüntünün tüm piksellerine uygulanabilir.

3.2.2 Hareketli Nesne Takibi Temelleri:

Bu bölümde, genel olarak nesne takibi problemini açıklamak için gerekli temel bilgileri ve bu alanda en çok kullanılan yöntemleri ayrıntılı olarak inceleyeceğiz. Öncelikle görüntüde bulunan tek bir nesneyi takip problemine bir göz atalım. Tek nesne takibi bir filtreleme problemine örnek olarak verilebilir. Bu nedenle, nesne durumunu belirlemek için gürültülü sensör ölçümlerinin sıralı olarak işlenmesi gereklidir. Nesne durumu ile nesnelerin hareketini tanımlayan hız ve yön özellikleri ile birlikte konum bilgisini kastediyoruz. Ayrıca, belirli bir nesne takibi uygulamasında ilgilenilen diğer özellikleri tanımlayan parametreleri de ekleyebiliriz. Örneğin, nesnenin şekli veya boyutu olabilir. Dinamik nesne sayısını ve her dinamik nesne durumunu belirlemek için birden fazla nesne takibinin gürültülü sensör ölçümlerinin sıralı işlenmesi gereklidir. Bu nedenle, birden fazla nesne izlemenin, birincisi, nesne sayısını belirlemekle, diğeri ise nesne durumlarını belirlemekle ilgili, eşit derecede önemli iki parçaya sahip olduğunu ifade edebiliriz.

Birden çok nesne takibi (*Multiple Object Tracking MOT*), görüntüde kaç tane nesne olduğu ve her bir nesnenin yönünü belirlenmesi gereklidir. Bu tez kapsamında olduğu gibi mikroskopta gözlenen spermler veya hücreler çoklu nesne problemi olarak tanımlanır çoklu nesne takibi sensör tespitine dayanır. Bir sensör veya muhtemelen birden fazla sensör olabilir ve bunlardan veri (ölçüm) alınır. Dedektörden aldığımız ölçümler, çoklu nesne izleme sisteminin girdisidir. MOT sisteminin çıktısı, nesne durumlarının arka yoğunluklarıdır. Dikkat edilmesi gereken önemli bir nokta, dedektörlerin, örneğin tek bir kamera görüntüsü olan tek bir radar taraması olan tek bir veri karesi üzerinde çalışmasıdır. Bununla birlikte *MOT* algoritması birden çok kareden gelen algılamalar üzerinde çalışır ve bu algılamalar sırayla işlenir. Çok nesneli izlemede karşılaşılabileceğimiz zorluklar aşağıdaki gibi özetliyebiliriz:

- Görüş Alanında (*Field of view FOV*) bilinmeyen nesne sayısı,
- Nesne durumları bilinmiyor ve nesneler hareket ediyor,
- Nesneler kaybolur (*FOV*' den çıkıyor),
- Yeni nesneler belirir (*FOV*' e giriyor),


- FOV içindeki nesneler birbirini kaplar,
- Dedektörler kusurludur (yanlış tespitler, yanlış tespitler).

Hareketli nesne izlemenin temel amacı, zamanın ötesinde ve kamera ölçümlerine dayanarak nesnenin veya zaman içinde birkaç nesnenin durumunu tahmin etmektir (Yılmaz *et al.* 2006). Tez kapsamında hareketli nesne takibi için elde edilen mikroskop görüntülerinde, görüntünün gerçek dünyada üç boyutlu olmasına rağmen iki boyutlu görüntü uzayına dönüşmesi nedeniyle bilgi kaybı oluşmaktadır. Ayrıca bu mikroskop görüntülerinde mevcut gürültüler ve spermlerin çarpışması olarak adlandırılan nesnelerin birbirine kaplanması da dahil olmak üzere farklılıkları ve zorlukları bulunmaktadır. Ayrıca bu görüntülerdeki her bir spermin hareketi yönü, hızı ve şekilde farklıdır. Örneğin, bazı spermler doğrusal hareket ederken, diğerleri doğrusal olmayan hareketler yapabilir.

3.1.2.1 Hareketli Nesne Takibi Türleri

Bu bölümde beş farklı nesne takibi yaklaşımından bahsedeceğiz. İlk nesne takibi yaklaşımı nokta nesne takibi olarak adlandırılır. Nesne başında zamana bağlı en fazla bir ölçüm gerçekleşir. En fazla bir tanesi ile kast edilen, görüntüde hiçbir algılama veya tek bir algılama olabileceği anlamına gelir. İkinci takip yaklaşımı ise, genişletilmiş nesne takibi olarak adlandırılır. Bu durumda, bir nesne için algılama almamamız mümkündür, ancak nesne başına birden fazla algılama da olabilir. Genişletilmiş nesne takibinde, bir nesne için birden çok ölçüm gerçekleşir ve bu durumda konum ve hareket parametrelerine ek olarak, nesnelerin boyutlarını tahmin etmek için birden çok ölçüm kullanılır. Üçüncü takip yaklaşımında grup nesnesi takibi adı verilir. Bu yaklaşım için tek bir varlık olarak grup nesnesi olarak değerlendirilen birkaç nesnemiz vardır. Genellikle grubun her bir üyesi kamera verilerinde tespit edilebilir ve bu nedenle grup başına çoklu tespit olasılığı vardır. Grup takibi birçok farklı kameraya uygulanabilir ve birçok farklı senaryoda, örneğin, tekil nesneleri takip edebiliyor olabiliriz. Ancak grup davranışlarını incelemekle daha çok ilgileniriz ve bu nedenle tekil nesneler yerine grupları takip ederiz. Dördüncü nesne takibi yaklaşımı ise çok yollu yayılım ile nesne takibi adı verilir. Bu durumda, nesne başına çoklu ölçüm yapma ihtimalimiz vardır. Son yaklaşım ise, çözülmemiş nesnelerle takibi adı verilir. Algılama başına birden çok nesneye sahip olabiliriz, yani tek bir ölçümde birden çok nesnenin olması mümkündür. Bu tezde nokta nesne takibi olan ilk türe odaklanacağız.

3.1.2.2 Nesne Takibi Teknikleri



Şekil 9. İzleme tekniklerinin sınıflandırılması (Yılmaz et al. 2006)

Nesnelerin takibi için, nesnelerin sayısına ve nesneleri temsil etmek için kullanılan yöntemlere göre farklılık gösteren çok sayıda önerilen teknik bulunmaktadır ve bu teknikler (Yılmaz et al. 2006)' de Şekil 9 gibi sınıflandırılmıştır;

Şekil 9' görüleceği üzere, nesne takibi üç ana bölüme ayrılır: Birincisi (*Point*), nesnenin bir nokta olarak temsil edilmesini kullanan teknikleri takip eder. İkincisi, (*Kernel*) geometri tarafından temsil edilen nesnelere ayrılırken, üçüncüsü (*Silhouette*) şeklin çevresiyle temsil edilir. Tezimizde, nokta temsiliinde yer alan ilk türe odaklanacağız. Nokta Nesnesi ise (Yılmaz et al. 2006), video karelerinde algılanan nesneler bu nokta nesnenin merkezi veya köşeler gibi başka bir özellik noktası olabilir. Bu noktalar yolları oluşturmak için ardışık kare arasında birbirine bağlanır ve noktaların ilişkisi bir önceki nesne durumuna bağlıdır. Deterministik veya *Bayes* olmayan tekniklerin, örneğin en yakın komşu filtre *NNF* veya, en güçlü komşu Filtre *SNF* gibi birleşme olasılığı yoktur. Genellikle *Bayes* filtresine dayanan olasılık teknikleri, bu teknik olasılıksal veri ilişkilendirmesi *PDAF* gibi ilişkilendirme olasılıklarını hesaplar. Bu tip, belirlilik veya gürültü içeren kameraların ölçümü için uygundur. Birçok gürültüye neden olan belirsizlik türümüz vardır; i) Ölçüm değerlerindeki belirsizlik ve buradaki gürültülü ölçümler, ii) çoklu hedefler veya yanlış alarmlar nedeniyle ölçümlerdeki belirsizlikler. Nesne izleme tekniklerinin özelliklerine girmeden önce, **geçiş** (*Gating*) kavramını açıklamalıyız.


- Geçiş (*Gating*) veya ölçümlerin doğrulanması:

İzlenecek ölçümleri atamada kullanılan ölçüm sayısını azaltmak ve nesne takibi için kullanılan algoritmaların performansını artırmak için *Gating* tekniği kullanılır. Geçişin (*Gating*) kötü ölçümleri ortadan kaldırmak için bir süreç olduğunu söyleyebiliriz. Başka bir deyişle önceden halihazırda takip edilen nesneleri temsil edebilen eşiğin altında kalan ölçümlerin aksine, tanımlanmış bir mesafeyi veya eşiği aşan ölçümler hariç tutulur ve ilişkilendirilemez(*non-associable*) olarak kabul edilir (Rachman 2017). İlişkilendirilmeyen ölçümler yeni ortaya çıkan nesneler olabilir ve yeni yollar oluşturmak için kullanılabilir. *Gating*, Şekil 10 da görüleceği üzere, öngörülen yolu çevreleyen ölçümlerin, aşağıdaki denklemle verilen *Mahalanobis* mesafesine bağlı olarak, kapı eşiği γ tarafından belirtilen olası bölge içinde olup olmadığının doğrulandığı istenmeyen ölçümleri kaldırmayı amaçlamaktadır (Bar-Shalom *et al.* 2011; Reuter 2014),

$$d^2 = v^T S^{-1} v \quad (3.7)$$

Burada v , tahmin edilen yörünge ile ölçümler arasındaki fark $Z_K - Z_{k|k-1}$ olan ölçümün kalıntısı veya yeniliği, S yenilikçiliğin kovaryansı. Kapı, kapı eşik değerinden daha küçük olan *Mahalanobis* mesafesine sahip gözlenen tüm ölçümleri içerir,

$$v(\gamma) = \{z: d^2 \leq \gamma\} \quad (3.8)$$



Şekil 10. Kapı Önü, Ölçüm 1 ve Ölçüm 4, kapının dışında olduğu için reddedilir

Çoklu nesne takibinde, güncelleme durumunda izlemeye ölçüm (*measurement-to-track*) atamak için doğru ölçümleri seçmemiz gerekir. (Bar-Shalom *et al.* 2009; Athanesious *et al.*

2012; Hidayatullah *et al.* 2016; Urbano *et al.* 2016; Severson 2019) ' de *NNF*, *GNNF*, *PDAF* ve *JPDAF* gibi birçok Veri Birliği (*Data Association*) tekniği önerilmektedir, bunlar bir sonraki bölümde ele alınacaktır.

3.1.2.2.1 Bayes Filtresi:

Bayes filtresi, tahmin ve güncelleme olmak üzere iki temel özyinelemeli adımdan oluştuğu için çoğu izleme algoritmasının temelidir. İlk adım, hareket modelinin bir defalık adımdan bir sonraki sefere ne olacağını tahmin etmek için kullanıldığı tahmindir. Bir başka ifade ile nesneye ne olacak, nesne durumu zaman içinde nasıl gelişir sorularına yanıt verir. İkinci adım ise, nesne durumu yoğunluklarını güncellemek için ölçümlerin ve ölçüm modelinin kullanıldığı güncelleme adımdır. Bu adımda ölçüm bilgilerini nesne durumları hakkındaki bilgilerimizi güncellemek için kullandığımız anlamına gelir. Bayes filtresi, $p(x_k|z_{1:k})$ ile gösterilen durumun yoğunluğu - Olasılık Yoğunluk İşlevi (*probability density function*) - PDF'sini tahmin etmek için yinelemeli çalışır; burada x_k nesne durumu $z_{1:k}$ 1'den k zamana kadar tüm gözlemler veya ölçümlerdir. İlk adım x_k zamanındaki durumun pdf'sini tahmin etmektir, bu $p(x_{k-1}|z_{1:k-1})$ önceki pdf ve $\pi_{k|k-1}$ geçiş fonksiyonunu kullanarak *Chapman-Kolmogorov* denkleminde dayanarak hesaplanır (Ristic *et al.* 2013),

$$p(x_k|z_{1:k-1}) = \int \pi_{k|k-1}(x_k|x_{k-1}) p(x_{k-1}|z_{1:k-1}) dx_{k-1} \quad (3.9)$$

İkinci adım, z_k ölçümünü kullanarak tahmini pdf'yi güncellemek için Bayes kuralını uygular:

$$p(x_k|z_{1:k}) = g_k(z_k|x_k) p(x_k|z_{1:k-1}) / \int g_k(z_k|x_k) p(x_k|z_{1:k-1}) dx_k \quad (3.10)$$

burada $g_k(z_k | x_k)$, durum ve ölçüm arasındaki ilişkiyi tanımlayan ölçüm olabilirlik fonksiyonudur. Böylece, Bayes filtresinden, bir nesneyi izlemek için, iki temel işlemimiz olduğu sonucuna varıyoruz, ilki konumları tahmini ve ikincisi ölçümleri güncellemesin' kullanarak konumları güncelliyorken, izleme algoritmalarının çoğu bu olasılık verilerini kullanır. Bir nesnenin durumunu tahmin etmek için birkaç filtremiz vardır. En önemlisi ve yaygın olarak doğrusal hareket modelleri için kullanılan *Kalman* Filtresidir.

3.1.2.2.2 Kalman Filtresi KF

Hareket ve ölçüm modelini temsil etmek için Gauss dağılımı kullanıldığında Bayes filtresine yakın bir çözüm olarak düşünülür. Kalman Filtresi, basitliği nedeniyle çoğu izleme algoritmasında yaygın olarak kullanılmaktadır. Kalman filtresi, ölçüm belirsizliği varlığında bir durumun gerçek değerini tahmin etmek için ardışık veri girişlerine (Ölçümler) bağlı tekrarlayan

işlemler kümesi olarak tanımlanabilir. *KF* algoritmasının adımlarını şu şekilde özetleyebiliriz (Li *et al.* 2010; Bar-Shalom *et al.* 2011; Reuter 2014),

1. Tahmin,

a) *Durum tahmini state*: $x_{k|k-1} = F_{k-1}x_{k-1|k-1}$ (3.11)

b) *Kovaryans tahmini*: $P_{k|k-1} = F_{k-1}P_{k-1|k-1}(F_{k-1})^T + Q_{k-1}$ (3.12)

2. Güncelleme,

a) *Ölçüm kalıntı*: $z'_k = z_k - H_k x_{k|k-1}$ (3.13)


b) *Kovaryans kalıntı*: $S_k = H_k P_{k|k-1} (H_k)^T + R_k$ (3.14)

c) *Filtre kazancı*: $K_k = P_{k|k-1} (H_k)^T (S_k)^{-1}$ (3.15)

d) *Durum güncellemesi*: $x_{k|k} = x_{k|k-1} + K_k z'_k$ (3.16)

e) *Kovaryans güncellemesi*: $P_{k|k} = P_{k|k-1} - K_k S_k (K_k)^T$ (3.17)

Tahmin aşaması, mevcut durumuna bağlı olarak nesnenin bir sonraki durumunu tahmin etmek için kullanıldığında ve güncelleme aşaması, kameradan alınan yeni ölçümlerle tahmini düzeltmeye gelir. Tahmin adımında, geçiş matrisinin (fonksiyon) F_{k-1} durumun önceki olasılık yoğunluk fonksiyonu $x_{k-1|k-1}$ (bazen başlangıç durumunda x_0) ile çarpılması, bu süreçte denklem (3.11) ile ifade edilen nesnenin yeni durumunu ifade eden k zamanındaki tahmini durumu elde ederiz. K zamanında tahmin edilen kovaryans S_k 'yi elde etmek için, geçiş matrisi F_{k-1} ve önceki kovaryans $P_{k-1|k-1}$ 'e ek olarak Q_{k-1} 'e proses gürültü denkleminin (3.12) kovaryans matrisine ihtiyacımız vardır. Güncelleme aşamasında, tahmini $x_{k|k-1}$ değerine ve sensör ölçümleri z_k 'ye dayanarak tahmini güncelleriz. İlk olarak, beklenen değer $H_k x_{k|k-1}$, ile alınan ölçüm z_k arasındaki farkı gösteren ölçüm kalıntısı z'_k 'in elde edilmesi denklem (3.13) gerekir. Burada H_k , ölçüm matrisine, daha sonra ölçüm kovaryans matrisi R_k kullanarak artık kovaryans denklem (3.14) 'de S_k hesaplanır (ölçüm belirsizliği). S_k , $P_{k|k-1}$ tahmindeki hataya kıyasla R_k ölçüm verilerindeki hataya göreceli önemi açıklayan *Kalman* kazancını hesaplamak için denklem (3.15) kullanılır. Tahminde hata küçükse buna daha fazla önem veririz ve veri ölçümlerindeki hata küçükse buna daha fazla önem veririz. Kalman kazancı bize tahmin ve ölçüme ne kadar güvenebileceğimizi söyler. Daha sonra Kalman kazancı, tahmini durum ve kovaryans (3.16, 3.17) denklemlerini kullanarak önceki pdf olarak daha sonra kullanılan posterior pdf olarak durum ve kovaryansın güncellenmesinde kullanılır. Şekil 11' de Kalman filtre döngüsü gösterilmiştir.



Şekil 11. Kalman filtresinin temel işlemleri

3.1.2.2.3 Genişletilmiş Kalman Filresi (Extended Kalman Filter EKF)

Kalman filtresi doğrusal hareket ve ölçüm modelleri için tasarlanmıştır. Bununla birlikte, çok sayıda izleme uygulamasında doğrusal olmayan hareket modelleri ve kameralar için doğrusal olmayan ölçüm modelleri gereklidir. Genişletilmiş Kalman filtresi (*EKF*) ve Unscented Kalman filtresi (*EKF*), doğrusal olmayan hareket veya ölçüm modellerinde Kalman filtresinin uygulanmasını kolaylaştırır. *EKF*, verilen doğrusal olmayan f ve h fonksiyonlarını doğrusallaştırmak için bir Taylor serisi yaklaşımın ve ölçüm matrislerini kullanarak Kalman filtresinin yapısının korunmasını sağlar. Doğrusal sistem matrisi ve doğrusal ölçüm matrisi *Jacobian* matrisi tarafından verilir, denklem (3.18, 3.19)

$$F^J = \frac{\delta f}{\delta x} = \begin{bmatrix} \frac{\delta f_1}{\delta x_1} & \dots & \dots & \dots & \frac{\delta f_1}{\delta x_n} \\ \vdots & & & & \vdots \\ \frac{\delta f_n}{\delta x_1} & \dots & \dots & \dots & \frac{\delta f_n}{\delta x_n} \end{bmatrix} \quad (3.18)$$

F^J mevcut durum tahmini için değerlendirilir,

$$H^J = \frac{\delta h}{\delta x} = \begin{bmatrix} \frac{\delta h_1}{\delta x_1} & \dots & \dots & \dots & \frac{\delta h_1}{\delta x_n} \\ \vdots & & & & \vdots \\ \frac{\delta h_n}{\delta x_1} & \dots & \dots & \dots & \frac{\delta h_n}{\delta x_n} \end{bmatrix} \quad (3.19)$$

H^J tahmin durumu için değerlendirilir. Standart kalman filtresinde F sistem matrisi ve H ölçüm matrisi doğrusallaştırılmış F^J ve H^J matrisleri ile değiştirilerek, *EKF* 'nin doğrusal olmayan izleme uygulamaları durumunda *Kalman* filtre denklemlerinin uygulanmasını kolaylaştırdığını görüyoruz.

3.1.2.2.4 Veri İlişkilendirme (Data Association DA)

Kalman filtresi ve türevleri EKF ve UKF, yalnızca bir nesne için aşağıdaki nesne durumunu varsaymak için kullanılır ve böylece bir nesneyi izlemek için kullanılabilir. Aynı anda birkaç nesneyi birlikte izlemesi gerekiyorsa, her nesne için bir sonraki durumunu kabul etmek için belirli bir filtre tahsis edilir. Varsayımdan sonra ve kameradan birkaç ölçüm alınırken sorun; varsayılan nesnenin durumunu güncellemek için hangi ölçümü kullanacağımızı nasıl bileceğiz? Diğer bir deyişle, her bir durum veya yörünge bunun için uygun ölçüme nasıl bağlanacaktır - bu duruma DA belirsizliği denir. Burada, ölçümü yörüngeye ilişkilendirmek ve gürültüyü ayırmak için belirli bir yöntemle dayandığı için veri bağlama veya veri ilişkilendirme kavramına ihtiyacımız vardır. Veri ilişkilendirme olarak kullanılan yöntemlerden bazıları NNF, SNF, PDAF, JPDAF'dir. Bu yöntemler veri bağlantılıdır ve aynı zamanda tahmin ve güncelleme aşamalarını içerdikleri için nesne takibi algoritmaları olduğunu söyleyebiliriz.

- En Yakın Komşu Filtre (Nearest Neighbor Filter NNF):

Yörünge en yakın doğrulanmış ölçüme bağlayan en basit izleme algoritmaları veya veri ilişkilendirme tekniklerinden biridir. Tahmin edilen yörünge değeri ile kapı içindeki ölçümler arasındaki farkı karşılaştırmak için Öklid mesafesine veya Mahalanobis mesafesine dayanır. Ölçümü her nesneye en küçük mesafeyle ilişkilendirilir. Ölçümleri, gürültüye veya başka bir nesneye bağlı olup olmamasına bakılmaksızın seçer (Reuter 2014). Gürültülü ölçüm varlığında NNF algoritmasının performansı hızla azalır. NNF zor ilişkilendirme kararları alır, bu zor kararlar bazen doğru, bazen de yanlıştır. İlişkilendirme yanlış olduğunda bu yörünge kaybına yol açabilir. Algoritma aşağıdaki gibi özetlenebilir:

-
1. Kalman filtresi yada EKF kullanarak durum ve kovaryans tahmini (3.11, 3.12)
 2. Tüm ölçümlere Mahalanobis mesafesini hesaplayarak atama matrisinin tanıtılması (3.7)
 3. Kapı ile ölçümlerin doğrulanması (3.8)
 4. Doğrulanmış en yakın ölçümü kabul etmek,,

$$m = \arg \min_{1 < m < m_k} (d) \quad (3.20)$$

5. Yörüngeleri kabul edilen ölçümlerle güncelleme (3.16, 3.17).
-

Bu teknik çok basittir, uygulaması kolaydır ve iyi koşullar sağlandığında tatmin edici sonuçlar verir.

- *Küresel En Yakın Komşu Filtre (Global Nearest Neighbor Filter GNNF):*

Bu algoritma, NN'nin genelleştirilmesidir, iyi koşullarda en uygun çözümü verir. GNN, yörüngeye yalnızca bir onaylanmış ölçüm atar ve kalan tüm ölçümleri gürültü (FA) veya daha sonra yörünge yönetimi yönetim algoritmaları tarafından atanan yeni doğmuş yörünge olarak kabul eder. n yörünge ve m ölçümümüz olduğu ve bu ölçümleri beklenen yörüngeye atamak istediğimizde, n satırlı ve m sütunlu atama matrisi oluşturulur ve *Munkres* kullanılarak çözülür (Bourgeois *et al.* 1971). Daha sonra yörüngeyi algoritmanın çıktısına göre güncelenir. GNNF adımları aşağıdaki gibi özetlenmiştir,

-
1. *Kalman filtersi yada EKF kullanarak durum ve kovaryans tahmini (3.11, 3.12)*
 2. *Tüm ölçümlere Mahalanobis mesafesini hesaplayarak atama matrisinin tanıtılması (3.7)*
 3. *Kapı ile ölçümlerin doğrulanması (3.8)*
 4. *atama matrisine Munkres Algoritması uygulama*

$$\min \sum d_{ij}^2 \cdot x_{ij} \quad \text{with } x_{ij} = \{0,1\} ; \sum_i x_{ij} = 1 , \sum_j x_{ij} = 1 \quad (3.21)$$


5. *Yörüngeleri kabul edilen ölçümlerle güncelleme (3.16, 3.17).*
-

Dördüncü adımda, *Munkres* algoritması atama matrisindeki tüm yörüngeler ve ölçümler arasındaki mesafelerin toplamının en uygun minimumunu bulmaya çalışır. Bu iki tabir (3.21), bir ölçümün sadece bir yörüngeye atanmasını garanti eder. x_{ij} değeri atama olmaması durumunda sıfır (0) ve atama durumunda bir (1) dir. NNF'de olduğu gibi, bu algoritmanın performansı optimal koşullarda çok etkilidir. Gürültünün varlığında yörüngeleri kaybedebiliriz.

- *Olasılıksal Veri İlişkisi Filtresi (Probabilistic Data Association Filter PDAF):*

Olasılıksal Veri İlişkisi Filtresi algoritması ilk olarak radar tarafından izlenen hedefleri izlemekte kullanılmıştır (Athanesious *et al.* 2012; Ristic *et al.* 2013). Ancak daha sonra genel olarak ve kameradan izlenen sistemler alanında, yani video sistemlerinde kullanılmaya başlandı (Athanesious *et al.* 2012). Bu algoritma, en yakın komşu algoritmasında bulduğumuz eksiklikleri önler, çünkü algoritmanın performansı gürültü varlığında azalır ve FA noktaları ile doğru ölçümler içeren yörüngeler verebilir. Bu durumda görüntüde nesne takibinde sapmaya ve hataya neden olur. *PDAF* algoritması gürültülü ortamlarda yalnızca bir nesneyi izlemek için kullanılır. Bu filtre esas olarak bir sonraki hedef konumu tahmin etmede ve *PDAF* tarafından üstlenilen kabul edilen ölçüme göre yörüngeleri güncellemede Kalman filtresine dayanır.

PDAF ilişkilendirme olaylarını (Association Events) dikkate alır. NN ve GNN algoritmasındaki temel fark, yörünge güncellemesinin dikkate alınan değerinin tek bir ölçüm olmaması, daha ziyade kapısının içine düşen tüm ölçümlerin ağırlıklı ortalaması olması, yani yörünge-ölçüm ilişkilerinin olasılığını hesaplamasıdır (Bar-Shalom *et al.* 2009). İlişkilendirme olayları, yörünge -ölçüm atamasını temsil eder ve bunu Şekil 12 'da gösterildiği gibi bir ağaç olarak tanımlarız; üçgen işaretiyle temsil edilen dört ölçüm z_1, z_2, z_3, z_4 ve artı işaretiyle temsil edilen üç tahmini yörünge görebiliriz $\hat{z}_1, \hat{z}_2, \hat{z}_3$.



Şekil 12. PDAF Algoritması tarafından temsil edilen ilişkilendirme olayları

Ölçümleri doğrulama işlemini uyguladıktan sonra, z_1 'in $\hat{z}$ yörüngesinin kapısının içine düştüğünü gözlemliyoruz, z_4 , $\hat{z}$ kapısının içine düştüğü, ve z_3 , $\hat{z}_1$ ve $\hat{z}_2$ yörüngelerinin iki kapısına düştüğü varsayılır. z_2 bir gürültü veya yeni ortaya çıkmış bir nesne olarak kabul edilir. Birinci yörünge geçidinin içinde bir ölçüm vardır. Bu nedenle ilişkilendirme olaylarının sayısı ikidir: 1) T_1 yörüngesine atanan z_3 ölçümünün, 2) ölçümün yanlış alarmdan kaynaklandığını tahmin eder. İkinci yörünge T_2 için üç ilişkilendirme etkinliğimiz var;

- 1) z_3 , T_2 parçasına aittir ve z_4 yanlış alarmdır,
- 2) z_4 , T_2 parçasına aittir ve z_3 yanlış alarmdır,
- 3) z_3 ve z_4 yanlış alarmlardır.

Üçüncü yörünge T_3 için z_1 'in ya 1) yörünge T_3 'e ait olduğunu ya da 2) yanlış alarm nedeniyle olabilir. Bu, algoritmanın yalnızca bir ölçüm seçmek için keyfi veya zor bir karar almadığı, ancak seçilen değer bir FA olması olasılığını dikkate aldığı anlamına gelir. PDAF algoritması ilişkilendirme olaylarını aşağıdaki gibi varsayar (Bar-Shalom *et al.* 2009),

$$\theta(k) = \begin{cases} z_j(k) \text{ is the correct measurement } j = 1, 2, \dots, m(k) \\ \text{no correct measurement in gate } j = 0 \end{cases} \quad (3.22)$$

Hedef tarafından en fazla bir onaylanmış ölçümün oluştuğunu ve geri kalanının FA'dan kaynaklandığını varsayar. Matematiksel olarak, Kapı içindeki ölçümleri geçit olasılığı PG ile ifade ederiz. N esne, saptama PD olasılığı ile belirlenir ve dağınıklık veya FA, uzaydaki yanlış alarmların sayısını temsil eden bir Poisson dağılımı λ ile modellenir. İlişkilendirme olaylarının olasılığı, formüle (3.23)'a dayanarak onaylanmış ölçümlere bağlı olarak bulunur (Bar-Shalom *et al.* 2009),

$$P(\theta(k)|Z_k) = \beta_{jt}(k) = \begin{cases} \frac{\mathcal{L}_{jt}(k)}{1-PD.PG+\sum_{j=1}^{m(k)} \mathcal{L}_i(k)} & j = 1, \dots, m(k) \\ \frac{1-PD.PG}{1-PD.PG+\sum_{j=1}^{m(k)} \mathcal{L}_{jt}(k)} & j = 0 \end{cases} \quad (3.23)$$

Doğrulanmış ölçümlerin hiçbirinin doğru ölçüm olmaması durumunda $j = 0$ ' dır. Denklemin (3.23) alt kısmında, dediğimiz gibi PG parametresi geçit olasılığıdır, algılanırsa geçidin gerçek ölçümü içermesi olasılığıdır. $PDPG$, hedefin saptanması ve ölçümünün validasyon kapısına düşme olasılığıdır, bu nedenle $1-PDPG$, hedefin saptanmamış (tespit edilmiş) olması veya ölçümünün validasyon kapısına düşmemesi olasılığıdır. İzlenen nesneden bir ölçüm Z_i üretilmesi durumunda; denklemin (3.23) üst kısmında, payda $\mathcal{L}_{jt}(k)$ ölçüm j 'nin t yörüngesinden mi, yoksa yığından mı üretileceğini belirleyen ölçüm olasılık oranını görürüz. $\mathcal{L}_{jt}$ Gauss dağılımı kullanılarak (3.24)'daki gibi formüle edilmiştir,

$$\mathcal{L}_{jt}(k) = \left\{ \frac{PD.\mathcal{N}_{z_i(k)}(z'(k), S(k))}{\lambda} \right\} \quad (3.24)$$

Burada, $\mathcal{N}_{z_i(k)}(z'(k), s(k))$ ortalama $z'(k)$, ve kovaryans $s(k)$ ile Gauss yoğunluğudur. $\mathcal{L}_{jt}$, yanlış alarm olmaktan ziyade izlenen nesneden kaynaklanan onaylanmış ölçümün olasılık oranıdır. İlişkilendirme olaylarının olasılığı $\beta_{jt}(k)$ daha sonra birleşik yenilik (İnovasyon) $v(k)$ olarak hesaplamak için kullanılır, ve formül (3.25)' ile verilir;

$$v(k) = \sum_{i=1}^{m(k)} \beta_{jt}(k).v_j(k) \quad (3.25)$$


Birleşik yenilik, tahmin edilen yörünge ve ölçümler arasındaki farkların ağırlıklı toplamıdır, burada $v_j(k)$ denklem (3.13) ile verilir. Birleşik yenilik, daha sonra kalman filtresindeki gibi yörünge durumunu ve kovaryansını güncellemek için kullanılır. PDAF'taki kovaryans güncellemesi, kalman filtresinden küçük bir fark gösterirken, yeniliklerin yayılması (*Spread of Innovation*) olarak adlandırılır. Kovaryans güncellemesi aşağıdaki formül ile ifade edilir (Bar-Shalom *et al.* 2009),

$$P_t(k|k) = \beta_{0t}P_t(k|k-1) + (1 - \beta_{0t})P_t(k|k) + P_t'(k) \quad (3.26)$$

Tüm ölçümler FA olduğunda ilk terim, β_{0t} olasılıkla kovaryans güncellemesi yoktur. Bu yüzden denklemde önceki kovaryans $P(k|k-1)$ ifadesini kullanıyoruz. Olasılık 1- β_{0t} olduğunda ikinci terim, ölçümden birinin izlenen hedef tarafından üretildiği anlamına gelir. Bu nedenle denklem (3.17) ile hesaplanan güncelleme kovaryans $P(k|k)$ 'nı kullanırız. Hangi ölçümün hedef kaynaklı olduğu belirsiz bir durumumuz varsa, güncellenmiş durumun kovaryansını arttırmak için yayılan yenilik $P'(k)$ 'yi kullanırız. PDAF adımları aşağıdaki gibi özetlenmiştir:

-
1. *Kalman filtersi yada EKF kullanarak durum ve kovaryans tahmini (3.11, 3.12)*
 2. *Tüm ölçümlere Mahalanobis mesafesini hesaplayarak atama matrisini tanıtır (3.7)*
 3. *Kapı ile ölçümlerin doğrulanması (3.8)*
 4. *İlişkilendirme olaylarını oluşturma (3.22)*
 5. *Marjinal ilişkilendirme olaylarını hesaplayın (3.23)*
 6. *Birleştirilmiş yeniliği hesaplama (3.25)*
 7. *Birleşik yenilik ile durum güncelleme (3.16)*
 8. *Kovaryansı güncelleme (3.26)*
-


Bu algoritma yörüngeyi onaylanmış ölçümlerin ağırlıklı ortalamasıyla güncellediğinden, ortaya çıkan yörünge ne tamamen doğru ne de tamamen yanlıştır. Bu yüzden PDAF tam optimal bir stratejidir. NNF ile karşılaştırıldığında, PDAF yüksek yanlış alarm yoğunlukları olan bölgelerde izlemeyi önemli ölçüde geliştirebilir. Şekil 13, PDAF işlemlerinin birlikte nasıl etkileşime girdiğini gösterir.



Şekil 13. PDAF algoritmasında işlemler etkileşmesi

- Ortak Olasılıksal Veri İlişkisi Filtresi (Joint JPDAF):

PDAF algoritması, tek bir nesneyi izlerken dağınıklık içeren alanlardaki yolu koruduğu için fark edilir bir performansa sahiptir. Ancak birden fazla nesnenin takibi durumunda, takip edilen hedefler birbirine yaklaştığında bir belirsizlik durumu olur. Ölçümlerden hangisinin herhangi bir yörüngeden ve hangisinin gürültüden üretildiği belirsizdir. Çünkü sadece bir nesnenin varlığını göz önünde bulundurulur. Ayrıca, GNN algoritmasının eksikliklerinden kaçınmak için, ölçümlerin gürültüden kaynaklanması olasılığını hesaba katmaz. Bu durumda performansın düşmesine neden olur. JPDAF algoritması, her iki algorithmada da iki sorunu çözen bu iki algoritmanın tamamlayıcısı olarak kabul edilir. PDAF algoritması gibi JPDAF da tahmin ve güncelleme için öncelikle Kalman filtresine dayanır. PDAF ve JPDAF arasındaki fark, ilişkilendirme olaylarının tanımlanmasında ve olasılıklarında yatmaktadır. JPDAF, Şekil (3.10) 'de gösterildiği gibi ortak ilişkilendirme olaylarını dikkate alır. Burada Şekil 14 'de gösterilen on ortak dernek etkinliğimiz vardır. İlk ilişkilendirme olayı, z_1 'in T_3 yörüngesine, z_2 'nin yanlış alarm, z_3 'ün T_1 'e ve z_4 ile T_2 'ye ait olduğunu tahmin eder. İkinci olay tahmini z_1 'in T_3 yörüngesine, z_2 yanlış alarm, z_3 T_1 'e ait ve z_4 yanlış alarmdan kaynaklanmaktadır. Altıncı olay, z_1 'in yanlış alarm, z_2 'nin yanlış alarm olduğunu, z_3 'ün T_1 'e ve z_4 ile T_2 'ye ait olduğunu tahmin eder. Son olay, tüm z_1, z_2, z_3, z_4 ölçümlerinin yanlış alarmdan kaynaklandığını tahmin eder.



Şekil 14. PDAF'deki ilişkilendirme olaylarına örnek

Yörüngelerin geçidinin kesişebileceği yakın yörüngeler ve ölçümler içeren bir bölgede, ölçümler herhangi bir yörüngeden veya belki de dağınıklıktan üretilebilir. Ortak birlikteliklerin olasılığı aşağıdaki formüle verilir (Bar-Shalom *et al.* 2009; Hidayatullah *et al.* 2017)

$$p(\theta(k)|z^k) = \frac{1}{c} \prod_{j=1}^m \{\mathcal{L}_{jt}(k)\}^{\tau_j(\theta)} \prod_{i=1}^n (P_D^t)^{\delta_t(\theta)} (1 - P_D^t)^{1-\delta_t(\theta)} \quad (3.28)$$

Daha sonra marjinal olasılık aşağıdaki formülle hesaplanır,

$$\beta_{jt} = \sum_{\theta} p(\theta(k)|z^k) \omega_{jt}(\theta, k) \quad (3.29)$$


$\mathcal{L}_{jt}$, ölçüm j ve yörünge t olasılığının oranının, $\tau_j(\theta)$ ölçüm ilişkilendirme göstergesi, ve $\delta_t(\theta)$ hedef saptama göstergesidir ve yörüngeye-ölçüm ilişkilendirme gerçekleştiğinde değerleri bire (1) eşittir, aksi takdirde sıfırdır (0) (Urbano 2014). Marjinal olasılık, ortak olayların olasılıklarının toplanmasıyla hesaplanır. Burada ölçüm j olay $\theta(k)$ 'da hedef t ile ilişkiliyse ω_{jt} bire eşittir. Ortak ilişkilendirme olaylarının ağırlık olarak olasılığı göz önüne alındığında, JPDAF yörünge durumunu tüm doğrulanmış ölçümler üzerindeki birleşik yenilikle günceller, ve ölçüm kaynağının belirsizliğini hesaba katan yeniliklerin yayılmasıyla yörünge kovaryansını günceller. Algoritmanın adımları aşağıdaki gibi özetlenmiştir,

-
1. Kalman filtresi yada EKF kullanarak durum ve kovaryans tahmini (3.11, 3.12)
 2. Tüm ölçümlere Mahalanobis mesafesini hesaplayarak atama matrisini tanıtın (3.7)
 3. Kapı ile ölçümlerin doğrulanması (3.8)
 4. İlişkilendirme olaylarını oluşturma (3.22)
 5. Marjinal ilişkilendirme olaylarını hesaplayın (3.26)
 6. Birleştirilmiş yeniliği hesaplama (3.25)
 7. Birleşik yenilik ile durum güncelleme (3.16)
 8. Kovaryansı güncelleme (3.26)
-

JPDAF'ın karmaşık koşullar altında birden fazla nesneyi takip etmede çok etkili bir performansa sahip olduğunu söyleyebiliriz. Ancak çoğunlukla Sabit Hız (*Constant velocity CV*) modeli olan tek hareket modeline sahip bir Kalman filtresi kullanarak, ortaya çıkan yörüngeler çok doğru olmayacak veya takip edilen nesnelerin orijinal yörüngesine çok yakın olmayacaktır. Bu durum özellikle manevra şeklinde hareket eden nesnelerin takibinde gerçekleşir. *IMM* teknolojisi, hedef hareketin en iyi tahminini elde etmek için birbirleriyle etkileşime giren farklı hareket modelleri içeren farklı filtreler içerdiğinden, manevra hareketi yapan nesnesiyi takip etmek için çok iyi bir çözümdür.

3.1.2.2.3 Etkileşimli Çoklu Model teknik (Interacting multiple model IMM)

Bu teknik, nesnenin hareketinin belirsiz veya melez hareketle daha iyi tahmin edilmesini amaçlamaktadır (Rachman 2017). IMM, hedef hareket hakkında en yakın beklentiyi sunar. Bu teknik, her biri sorunun doğasına bağlı olarak belirli bir hareket modelini simüle eden birkaç filtreye dayanır. Birden fazla model kullanarak izleme algoritmaları, hareket belirsizliği olan hedefleri izleme yeteneğine sahiptir. Temel fikir, gerçek modun olası adayları olarak bir dizi model varsaymaktır; daha sonra her biri sette benzersiz bir modele dayanan bir grup temel filtre çalıştırmaktır; ve son olarak, bu temel filtrelerin sonuçlarına dayanan bir süreçle genel tahminler üretmek (Ristic *et al.* 2013).



Şekil 15. IMM döngüsü

Her filtre hareket modeline göre farklı bir tahmin verdiğinde, tahmini durum değerleri daha sonra durumun arka yoğunluğunu ifade eden tek bir değerde birleştirilir. Birleştirme süreci ya daha yüksek bir olasılıkla tahmini seçerek ya da münferit filtrelerin olasılık-ağırlıklı kombinasyonunu alarak yapılır (Mazor *et al.* 1988; Gomes 2008; Rachman 2017). Şekil 15’de IMM filtresinin akış diyagramı gösterilmiştir. Burada, ilk geçiş olasılıkları p_{ij} ve önceki model olasılıkları $M1_{K-1}, Mj_{K-1}$ (bazen ilk model olasılıkları) karıştırma olasılıklarını $Mi|1_{K-1}, Mi|jk-1$,

elde etmek için karıştırılır; bu olasılıklar etkileşimin veya durum karıştırma sürecinin gelirini oluşturur. $X^*1_{k|k}, P^*1_{k|k}$, $X^*1_{k|k}, P^*1_{k|k}$ elde etmek için durumlar olasılıklarıyla karıştırılır. Bu parametreler her filtre için 1'den j'ye bir gelir oluşturulur sonra her filtre modellerin olasılıklarına bağlı olarak belirli bir durumu ve kovaryansı tahmin eder. Daha sonra tüm ortaya çıkan tahminler, ölçüm olasılığı λ_{ij} 'ye bağlı olarak yörüngeyi ve model olasılıklarını güncellemek için kullanılan son durum tahminini oluşturmak için birleştirilir. Model olasılıkları karıştırma adımı önceki model olasılıkları ve Markov geçiş olasılıkları p_{ij} kullanılarak yapılır,

$$\mu_{i|j,k-1} = \frac{p_{ij} \mu_{i,k-1}}{\sum_{i=1}^r p_{ij} \mu_{i,k-1}} \quad (3.30)$$

IMM filtresi geçiş olasılığı p_{ij} tanıtarak modlar veya hareket modelleri arasında atlama yeteneğine sahiptir. $\mu_{i|j,k-1}$ modellerin karıştırma veya koşullu olasılığı, $\mu_{i,k-1}$ i- modu olasılığı, r model sayısı. Etkileşim ve durum karıştırma adımı matematiksel olarak şöyle tanımlanır (Gomes 2008; Rachman 2017),

$$x_{j,k-1}^* = \sum_{i=1}^r \mu_{i|j,k-1} x_{i,k-1}' \quad (3.31)$$

$$P_{j,k-1}^* = \sum_{i=1}^r \mu_{i|j,k-1} x_{i,k-1}' [P_{i,k-1} + (x_{j,k-1}' - x_{j,k-1}^*)(x_{j,k-1}' - x_{j,k-1}^*)^T] \quad (3.32)$$

her filtre için karıştırma durumu ve kovaryans, önceki durum $x_{i,k-1}'$ ile çarpılarak koşullu mod olasılıkları (3.30) kullanılarak hesaplanır. $\mu_{j,k}$ olasılıkları güncellemek için aşağıdaki formülle kullanılır,

$$\mu_{j,k} = \frac{\lambda_{ij} \mu_{i,k}'}{\sum_{i=1}^r \lambda_{ij} \mu_{i,k}'} \quad (3.33)$$

λ_{ij} ölçüm olasılığıdır. Hangi model tahmininin doğru değere en yakın olduğunu belirlemek için çok önemli bir faktördür. Güncellenmiş olasılıklar daha sonra her bir filtreden gelen $x_{i,k-1}'$ ve kovaryansın tahmini durumlarını birleştirmek için kullanılır,

$$x_{j,k}' = \sum_{i=1}^r \mu_{j,k} x_{j,k}' \quad (3.34)$$

$$P_k = \sum_{j=1}^r P_{j,k} + (x_{j,k}' - x_k')(x_{j,k}' - x_k')^T \quad (3.35)$$

Dolayısıyla IMM'nin karıştırma, tahmin etme ve birleştirme işlemlerinin üç temel adımından oluştuğunu söyleyebiliriz. IMM Adımları aşağıdaki gibi özetlenmiştir,

-
1. Olasılıkların karıştırılması (3.30),
 2. Durumların Karıştırılması (3.31), (3.32)
-

-
3. Kullanılan tüm filtreler için Tahmin ve Güncelleme (3.11),... (3.17),
 4. Olasılıkların güncellenmesi (3.33)
 5. Tahmini durumları birleştirme (3.34), (3.35)
-

Bu şekilde, bu bölümde, tespit etme ve izleme alanlarında en önemli ve en çok kullanılan tekniklerin genel ve açıklayıcı bir özetini verdik. Bir sonraki bölümde, videodaki spermi saptamak için yukarıda verilen tekniklerden en iyi performansı veren method seçilecektir. Sperm hareketi analizinde en iyi ve en doğru sonuçları elde etmek amacıyla iki izleme tekniği birleştirilecektir.

3.2 Önerilen Yöntem

Bu bölümde, sperm segmentasyonu kaydedilen video görüntü karelerinde gerçekleştirilebilmesi için gereken video ön işleme dahil olmak üzere, arka plan çıkarma algoritması kullanılarak insan sperminin saptanması ve çıkarılması işlemi açıklanmaktadır. Daha sonra JPDAF-IMM algoritmasını entegre ederek her kareden çıkarılan spermleri nasıl izleyebileceğimizi göreceğiz. İnsan sperminin daha iyi izlenmesini sağlamak için neden seçildiklerini tartışacağız.

3.2.1 Sperm Tespiti Algoritması

Önerilen sperm tespiti algoritması aşağıda verilen adımlara göre;

-
1. video kareleri ayıklanıyor,
 2. Renk alanının RGB'den GRİ'ye değiştirilmesi,
 3. $5 * 5$ çekirdekli Gauss filtresi kullanarak gürültüyü giderme,
 4. Histogramları uyarlayarak görüntünün kontrastını arttırmak,
 5. Karelerin ortalamasını alarak Video Arkaplanını Çıkarma, Denklem (3.1)
 6. Her kareyi çıkarılan arka plandan çıkarma, Denklem (3.2)
 7. Otsu kullanarak eşikleme
 8. Morfolojik işlemlerin uygulanması
 9. Bölgeleri etiketleme ve küçük istenmeyen bölgeyi ortadan kaldırma,
 10. Spermleri temsil eden kalan bölgenin merkezini bulmak.
-

Başlangıçta videodaki tüm kareler okundu, daha sonra renk deseni bir renkten (RBG) gümüş (GRAY) rengine değiştirildi çünkü problemimizde spermi belirlemek için renge güvenilmezdi. Renk değiştirme işlemini uyguladıktan sonra, $5 * 5$ pencere boyutunda bir Gauss

filtresi uygulayarak görüntüde oluşan paraziti giderildi. Sperm nesnelerini görüntünün arka planından daha iyi ayırt etmek için ortaya çıkan görüntü yapısını iyileştirmek için *Matlab* görüntü işleme bir fonksiyonu (*adapthiseteq*) görüntünün histogramına uygulayarak görüntünün kontrastını artırıldı. Sperm çıkarmak için 5. ve 6. adımların arka plan çıkarma (Piccardi *et al.* 2004; Yilmaz *et al.* 2006) algoritması kullanıldı. Otsu eşiği yöntemini (Otsu 1979) kullanarak görüntüyü iki renkli görüntüye dönüştürüldü. İlk renk arka planı, ikincisi spermi ifade eden ön plan oluşturuldu. Daha sonra spermi daha iyi netleştirmek ve bitişik olmaları durumunda yakınlardaki spermden ayırmak için görüntüye elmas penceresi kullanılarak erozyon ve ardından genişleme işlemleri uygulandı. Bundan sonra, *Connected Component* adresleme yöntemini kullanarak son süreçten kaynaklanan alanlara için adresler oluşturuldu. *Matlab* görüntü işleme bir fonksiyonu (*regionprops*) kullanılarak ortaya çıkan bölgelerin boyutunu elde edildi ve spermleri temsil etmeyen küçük alanları ihmal edildi. Aynı fonksiyonu kullanarak, sperm merkezlerinin koordinatlarını temsil eden görüntüdeki ayrı bölgelerin merkezlerini elde edebildi.

Her kare için 6 ile 10 arasındaki işlemleri tekrarlandı ve her yineleme için sadece sperm koordinatlarımız elde edildi. Bazı koordinatların, yanlış bir uyarı FA olduğunu düşündüğümüz bir sistem hatasından kaynaklandı. Sabit spermlere gelince, bunların tespit edilmediğini fark edildi, çünkü kare piksel oranlarını alırken, bu spermler hareket etmediği tespit edildi ve algoritma arka plandan değerlendirdi. Bu durumu tespit etmek için şu görüntü işleme yöntemleri uyguladık: Renk alanı griye çevrildi ve ardından gürültüyü gidermek için Gauss filtresi kullanıldı, ardından spermi arka plandan ayırmak için bir eşik uygulandı ve daha sonra morfoloji işlemleri uygulandı, ardından sabit sperm sayısını elde etmek için adresleme yöntemi kullanıldı. Bu durumda spermler doğrudan hareketsiz olarak sınıflandırılırdı. Bu nedenle, bahsettiğimiz aşamaların uygulanmasından kaynaklanan koordinatlar, bir sonraki bölümde ele alacağımız izleme sisteminin ölçümleri olarak daha sonra kullanılmak üzere bir dosyada saklandı.

3.2.2 Sperm Takibi Algoritması

Üçüncü bölümün ikinci kısmında, nokta izleme kategorisi altında listelenen yaygın olarak kullanılan izleme algoritmalarını sunduk. Kalman filtresinin, sensör ölçümlerine ek olarak, şimdiki zamandaki durumuna bağlı olarak, nesnenin durumunu bir sonraki seferde varsaymak için kullanıldığını tespit ettik. Bu, doğrusal hareket desenli tek bir nesnenin durumunu varsaymaktır. Genişletilmiş Kalman filtresi, bir nesnenin doğrusal olmayan hareketini varsaymak için kullanılır. Ayrıca IMM tekniğinin manevra kabiliyeti olan hareketleri olan nesneleri izlemek için çok etkili olduğu için, önerilen modelin olasılığına bağlı olarak,

nesnenin hareketine göre kendi aralarında etkileşimde bulunabilen ve değiş tokuş edebilen çeşitli hareket kalıpları içerir.

Bağlantı algoritmalarına gelince, NNF Algoritması gürültü olmaması durumunda iyi ilişkilendirme yaklaşımına sahiptir, ancak aksi takdirde yörüngeyi kaybeder. GNN en uygun çözümdür. Fakat aynı zamanda yanlış alarm tipi gürültü olmadan en uygun koşullarında geçerlidir, aksi takdirde hatalar yörüngeyi bir bileşen noktası olarak girilecek ve böylece nesnenin görüncesini kaybedecektir. PDAF, gürültü yoğunluğu olan bölgelerde yalnızca bir nesneyi izlemek için çok iyi bir çözümdür. Birden fazla nesne birbirinden çok uzaksa ve yolları çakışmıyorsa da izleyebilir. Nesneler birbirine oldukça yakınsa, üst üste binen yollar ortaya çıkacak ve bu da büyük izleme sorunlarına neden olacaktır. JPDAF algoritması, tek bir hareket modeliyle Kalman filtresine dayandığı ve çarpışma ve gürültü gibi karmaşık koşullar altında izlemede çok iyi sonuçlar verdiği için, nispeten kısa sürede birden fazla nesneyi izlemek için en iyi algoritmalarından biri olarak kabul edilir. Genellikle, JPDAF algoritması sabit hız hareket modeli Kalman filtresi ile kullanılır ve çok iyi performans verir. Ancak nesneler paralel ve birbirine yakın hareket ediyorsa, üst üste binen veya kaybedilen yörüngeler olabilir. Aynı zamanda manevra hareketlerini benimseyen nesneler için, nesnenin gerçek yolundan uzağa bir hareket tahmini vermeleri de olabilir. Hareket varsayılırken, mutlak doğru bir çözüm ya da mutlak yanlış bir çözüm vermez.

Böylece IMM yöntemini JPDAF algoritması ile kullanmak, orijinal yola çok yakın olan doğru bir yörünge elde etmenize yardımcı olur. Birçok hareket modeli için IMM yöntemini uygulamak için EKF kullandık, ve çalışmamızda iki hareket modeli sabit hız modeli (Constant velocity CV) ve sabit dönüş (Constant turn CT) modelini kullandık. Bu şekilde melez hareketli spermiler için daha doğru izleme elde edebildik. Böylece ortaya çıkan sperm motilite analizinde kullanılabilecek daha iyi sonuçlar elde ettik. Sonuç olarak, İki filtre IMM ve PDAF avantajlarından faydalanarak, ilk izlenecek nesnelerin hibrit hareketini sağlayan, ikincisi ise bu nesneleri gürültü varlığında birlikte takip etmek için, IMM-JPDAF'ı hibrid nesnelerin kötü koşullar altında en iyi varsayımı ve takibi için seçtik. Dolayısıyla, IMM-JPDAF algoritmasının, önceki tekniklerde bulabileceğimiz kusurlara en çok çözüm içeren genel bir yöntem olduğunu söyleyebiliriz. IMM-JPDAF yöntemi önceki çalışmalarda araç hareketini *IMM-JPDAF* olarak izlemek için kullanılmıştır (Rachman 2017).

IMM'nin farklı nesnelerin hibrit hareketini üstlenme yeteneğine sahip olduğu, ve önceki tüm algoritmalar için Kalman filtresini IMM ile birleştirerek **IMM-DA** adı altında tüm algoritmalar için daha iyi performans beklenir.

3.2.2.1 Etkileşimli Çoklu Modeller-Ortak Olasılıksal Veri İlişkilendirme (IMM-JPDAF)

Bu bölümde IMM-JPDAF algoritmanın nasıl çalıştığını ayrıntılı olarak açıklayacağız. Önerdiğimiz takip yöntemimiz temel olarak hareket ve yörünge ölçüm ilişkisindeki belirsizlikle başa çıkmak için JPDAF filtresini, ve manevra yapan nesnelerle başa çıkmak için IMM filtresini kullanır. IMM-JPDAF dört adımdan oluşur: 1) Karıştırma ve Etkileşim, 2) Tahmin ve Ölçüm doğrulaması, 3) Veri ilişkilendirmesi ve 4) Modele özgü filtreleme, Mod Olasılık güncellemesi ve Birleştirme Adımı. Önerilen IMM-JPDAF algoritmasını aşağıdaki gibi özetleyebiliriz,

-
1. *Olasılık ve durumların karıştırılması, denklem (3.30), (3.31), (3.31)*
 2. *Tüm ölçümlere Mahalanobis mesafesini hesaplayarak atama matrisini oluşturmak denklem (3.7)*
 3. *Her mod için (Filtre)*
 - a. *Durumu ve kovaryansı tahmin etme (3.10), (3.11)*
 - b. *Ölçümleri atarak doğrulama (3.8)*
 - c. *Ortak ilişkilendirme olaylarını oluşturma (3.22)*
 - d. *Marjinal ilişki olasılığını hesaplama (3.26)*
 - e. *Birleşik yeniliği hesapla (3.25)*
 - f. *Birleşik yeniliğiyle durumu ve kovaryansı güncelleme, (3.26)*
 4. *Modlerin olasılıkları güncelleme (3.33)*
 5. *Tahmini durumları birleştirme (3.34), (3.35)*
-

Temel olarak, hareketli bir nesneyi takibi için, onun durumunu temsil etmemiz gerekir. Nesne durumu temsili, eldeki soruna bağlı olarak değişir. Nesnenin durumunu bir eksenle hareket ediyorsa bir boyutta, veya iki boyutlu bir alanda hareket ediyorsa iki boyutta, veya üç boyutlu bir alanda hareket ediyorsa üç boyutta temsil edebiliriz. Ayrıca nesnenin her bir boyuta hızını ve ivmesini durumuna ekleyebiliriz. Sperm analiz sistemini geliştirdiğimizde ve mikroskoptan çekilen video bir kameraya bağlı olduğu için, bir düzlem olarak kabul edilir. Bu durumda görüntüdeki spermiller merkezlerinin iki boyutlu x, y 'dir. Spermin hareketini bu iki eksenle inceleyeceğiz ve her birine dx, dy hız bilgilerini ekleyeceğiz. Spermin hareket ettiği dönme hareketi nedeniyle, sapma açısı θ eklenir. Böylece, durumu öncekilerin tümünü içeren X durum vektörü ile temsil edebiliriz:

$$X = \begin{bmatrix} x \\ y \\ dx \\ dy \\ \theta \end{bmatrix} \quad (3.36)$$

3.2.2.1.1 Birleştirme

Bu aşama iki birleştirme işleminden oluşur: birincisi modellerin olasılıklarını birleştirmesi, ikincisi ise ortaya çıkan olasılık değerlerine göre vakaları birleştirmesidir. Burada, Markov matrisi tarafından temsil edilen hareket modelleri arasında bir komütatör olarak durumdan duruma geçişi ifade eden bir matrise ihtiyacımız vardır.

$$P = \begin{bmatrix} P_{1,1} & \dots & \dots & \dots & P_{r,1} \\ \vdots & & & & \vdots \\ \vdots & & & & \vdots \\ P_{1,r} & \dots & \dots & \dots & P_{r,r} \end{bmatrix} \quad (3.37)$$

Burada r hareket modeli sayısıdır. P 'ye bağlı olarak, koşullu mod olasılığını $\mu_{i|j,k-1}$ elde ederiz. Koşullu mod olasılıkları, mod j 'nin şimdiki zaman adımında aktif olduğu göz önüne alındığında, mod i 'nin önceki zaman adımında oluşturulduğu olasılıklara karşılık gelir. Denklem (3.38) ile verilir,

$$\mu_{i|j,k-1} = \frac{p_{ij} \mu_{i,k-1}}{\underbrace{\sum_{i=1}^r p_{ij} \mu_{i,k-1}}_{\mu'_{i,k}}} \quad (3.38)$$

$\mu'_{i,k}$, ile ifade edilen bu denklemdeki payda, geçerli zaman adımında önceki mod olasılıkları olduğunda ve son zaman adımı $P_{i,j}$ 'nin mod olasılıklarının tahmini ile verilir. Bu, model i 'den model j 'ye bir mod geçişinin meydana gelme olasılığını gösterir. Yukarıdakilerin tümüne, ilk birleşme aşamasını temsil eden olasılık birleşme aşaması denir. Durumları birleştirmek ya da sözde etkileşim aşamasına gelince, (3.39) ve (3.40) denklemlerini kullanarak modellerin birleşik olasılık $\mu_{i|j,k-1}$ değerlerine dayanarak ve her filtre için önceki durum $x'_{i,k-1}$, ve kovaryansına $P_{i,k-1}$ dayanarak birleşik durumları $x_{j,k-1}^*$ ve kovaryansı $P_{j,k-1}^*$ elde ederiz. Bu denklemlerin çıktıları her filtre için girdi olarak kullanılır,

$$x_{j,k-1}^* = \sum_{i=1}^r \mu_{i|j,k-1} x'_{i,k-1} \quad (3.39)$$

$$P_{j,k-1}^* = \sum_{i=1}^r \mu_{i|j,k-1} x'_{i,k-1} [P_{i,k-1} + (x'_{j,k-1} - x_{j,k-1}^*)(x'_{j,k-1} - x_{j,k-1}^*)^T] \quad (3.40)$$

3.2.2.1.2 Tahmin

İzlenen her yörünge ve önceki zamandaki varsayılan durumu için, Kalman filtresine bağlı olarak yol hareketi şu anda tahmin edilir. Tahmin için iki tür hareketimiz var: birincisi,

nesnenin sabit bir düz hızda hareket etmesi ve ikincisi, nesnenin sabit bir sapma ile hareket etmesidir. Bu iki filtrenin girdisi, koşullu olasılıklar $\mu_{i|j,k-1}$ ile önceki durumlar $x'_{i,k-1}$ etkileşimi aşamasından kaynaklanan çıktıdır $x^*_{j,k-1}$ ve $P^*_{j,k-1}$. Her filtre belirli bir durumun değerini alacaktır ve ona göre tahmini yapar. Bu nedenle bu aşamadan kaynaklanan çıktının, sperm birliktede iki hareket paterninden kaynaklanan k anda beklendiği durumlarıdır,

$$x_{k|k-1} = F_{k-1}x_{k-1|k-1} \quad (3.41)$$

$$P_{k|k-1} = F_{k-1}P_{k-1|k-1}(F_{k-1})^T + Q_{k-1} \quad (3.42)$$

Her filtre, önceki iki denklemi kapsayan Kalman filtresine dayanarak k anındaki nesnenin durumunu ayrı ayrı tahmin eder.

3.2.2.1.3 Ölçümlerin doğrulanması

Bu aşamada, belirli bir anda k video karelerinden çıkarılan tüm Z_k ölçümler, bir x_{k-1} filtresinden tahmin edilen yörüngelerin değerleri denklem (3.43) kullanılarak arasındaki mesafe hesaplanır,

$$d^2 = v^T S^{-1} v \quad (3.43)$$

$$v = z - z'_k \quad (3.44)$$

$$S_k = H P_{k-1} (H)^T + R_k \quad (3.45)$$

Ancak burada bir yörünge için hareket filtrelerinden kaynaklanan iki varsayımımız ve her birinin kendi kapısı vardır. Bu nedenle iki kapıdan birinden kabul gören denklem (3.46) da kabul edilir.

$$v(\gamma) = \{d_1^2 \leq \gamma_1 \mid d_2^2 \leq \gamma_2\} \quad (3.46)$$

Başka bir deyişle, her iki filtre için de hareket varsayımından kaynaklanan iki kapıdan birinde yer alan bir ölçüm varsa, bu ölçüm iki filtreden birlikte nesnenin yolunun güncellenmesi aşamasında kullanılmak üzere kabul edilir. Ölçüm, yalnızca iki kapıdan herhangi birine düşmemesi durumunda reddedilir. Burada iki olasılığımız vardır: Birincisi, bu ölçümün, tespit aşamasındaki bir hata nedeniyle bir süre sonra ihmal edilen bir gürültü olması veya daha sonra izlenmek üzere bir yolun oluşturulduğu yeni bir nesne olmasıdır.

3.2.2.1.4 Veri ilişkilendirme

Video boyunca sperm yolu ile ilişkili noktaları bağlama yeteneğine sahip en önemli aşamadır. Bu aşamada, NN, GNN, PDAF, JPDAF yöntemleri olsun, bu bağlantı yöntemlerinden herhangi birini kullanabiliriz. Ancak en iyi izleme için ve FA varlığı, sperm

birbirleriyle çarpıştığı ve birbirlerini örtebildiği gibi karmaşık koşullar için, tespit sistemi bu çarpışmayı tespit etme yeteneğine sahip olmadığı ve bunlar tek bir nesne olarak kabul edildiği için, spermelerin hareketi genellikle geçildiği ve birlikte çok yakın yüzdüğü için veri bağlantısı olarak JPDAF algoritmasını seçtik. JPDAF ise bağlantı olaylarının olanaklarını hesaplanır,

$$p(\theta(k)|z^k) = \frac{1}{c} \prod_{j=1}^m \{\mathcal{L}_{jt}(k)\}^{\tau_j(\theta)} \prod_{i=1}^n (P_D^t)^{\delta_t(\theta)} (1 - P_D^t)^{1-\delta_t(\theta)} \quad (3.47)$$

Sonra marjinal olasılığı hesaplanır,

$$\beta_{jt} = \sum_{\theta} p(\theta(k)|z^k) \omega_{jt}(\theta, k) \quad (3.48)$$

3.2.2.1.4 Güncelleme

Bu işlem de iki adımdan oluşur; önce her iki filtre için durumları günceller ve sonra modellerin olasılıklarını geliştirir. 3.49.14)

$$P_t^i(k|k) = \beta_{0t}^i P_t^i(k|k-1) + (1 - \beta_{0t}^i) P_t^i(k|k) + i_{t'}^r(k) \quad (3.50)$$

Her filtre için veri ilişkilendirme işleminden sonra ve birleşik yeniliğini $v(k)$ hesaplamak için kullanılan ilişkilendirme olaylarının olasılıklarını β_{jt} bulduktan sonra, yörünge, her iki filtre için de güncellenir; bu, yalnızca yörüngenin durum tahmini güncellemesine ek olarak kovaryans tahmini de güncellenir. Bu nedenle, bir sperm yörüngesi için, iki varsayımsal durum $x_{k|k}^1, x_{k|k}^2$ ve iki varsayımsal kovaryasyon $P_{t|k}^1, P_{t|k}^2$ da var. Ancak iki filtreden hangisi gerçek sperm yörüngesinin en iyi tahminini veya en yakın tahminini verdi? Bunun cevabı, $\mathcal{L}_{jt}$ ölçüm olasılığında yatıyor ve değeri bize yeni ölçümlerin her iki varsayımsal yola ne kadar yakın olduğunu ifade eder. Her iki filtre için ölçüm olasılığı modellerin $\mu_{j,k}$ olasılıklarını güncellemek için kullanılır.

Daha önce gördüğümüz gibi, model olasılıklarını güncellemek için (3.33) denklemini kullanıyoruz. $\mathcal{L}_{jt}$ ve λ_{ij} her ikisi de bir ölçümün olasılığını ifade eder, ancak birincisi tek bir ölçümün olasılığı ve ikincisi birkaç ölçüm olasılığı içindir. Tüm ölçümler için tüm varsayımlar aşağıdaki gibi verilir,

$$\lambda_{ik} = \sum_{i=x} \mathcal{L}_{jt} \quad (3.51)$$


Son olarak, tek bir sperm durumu değeri elde etmek için $x_{j,k}'$, P_k güncellenen modellerin olasılıklarını her filtrenin varsaydığı değerlerle birleştiririz. Oysa yüksek olasılıklı filtre, son yörünge durumuna varsayımsal durumunun değerinin etkisi büyük, düşük olasılıklı filtreye gelince, son yörünge durumunda önemi azdır.

$$x'_{j,k} = \sum_{i=1}^r \mu_{j,k} x'_{j,k} \quad (3.52)$$

$$P_k = \sum_{j=1}^r P_{j,k} + (x'_{j,k} - x'_k)(x'_{j,k} - x'_k)^T \quad (3.53)$$

IMM-JPDAF, spermleri zorlu ve karmaşık koşullar altında izlemek için önerilen yöntemdir ve video kareleri boyunca spermlerin konumlarını tespit etmek için arka plan çıkarma tekniğini kullanarak ve ortaya çıkan yörüngenin sperm parametrelerini hesaplayarak hepsini Şekil 16 de gösterildiği gibi Sperm Analiz Sistemiyle temsil edebiliriz.





Şekil 16. Sperm analiz sistemin diyagramı

ARAŞTIRMA BULGULARI VE TARTIŞMA

Bu bölümde, arka plan çıkarma algılama tekniği ve IMM-JPDAF izleme algoritması uygulanarak elde edilen algılama ve izleme sonuçlarını yüzme sperm örnekleri videosunun gerçekçi sahnelerine sunacağız ve tartışacağız. Her tespit algoritmasının performansını karşılaştırmak için metrik olarak ortalama kare hatası (MSE) kullandık. İzleme algoritmalarının performansını karşılaştırmak için, bu algoritmaları çeşitli simüle edilmiş senaryolara uyguladık, ardından mükemmel bilinen simüle edilmiş zemin gerçeği yörüngeler kümesi ve, her bir algoritma tarafından üretilen tahmini yörüngeler kümesi arasındaki optimum alt-model ataması (OSPA) mesafesini hesaplandı. Her algoritmanın avantaj ve dezavantajlarını göstermek için basit senaryolar oluşturduk.

4.1 Sperm Tespit Algoritmalarının Karşılaştırılması

Bölüm 4'te, bir görüntüdeki nesneleri algılamakla görevlendirilen çeşitli teknikler sunduk. Bazıları, nesneleri ister hareketli ister sabit olsun, genel olarak tanımlamak için tek bir kareye güvenir. Diğerleri, birden fazla kare kullanarak videodaki yalnızca hareket eden nesneleri algılama özelliğine sahiptir. Ancak bu yöntemlerden hangisi sperm tespiti için en uygundur? Bu sorunun cevabını bulmak için sperm videosuna Kareler farkı, Arkaplan Çıkarma ve Optik Akış algoritması uygulandı ve karşılaştırma sonuçları Şekil 17' da gösterildi.

Sperm formunu çok doğru bir şekilde belirleme açısından en iyi performansın optik akış algoritması olduğunu gözlemledik. Bakınız Şekil 17(g, h). Sadece sperm oluşturan bölgeler değil, görüntüdeki her nokta için bir ışın belirlediği için sonuç, ışınlarda yoğunluk içeren alanların sperm olmasıydı. Gerçekten, görüntüleri incelediğimizde spermin k zamanından $k+1$ zamanına kadar çekilmesini belirlediğini bulduk. Tanımlamadaki yüksek doğruluğa rağmen, diğer algoritmalara kıyasla daha fazla işlem zamanı gerektirir ve bir sperm çarpışması durumunda, iki çarpışan spermi tespit etmek mümkün değildir. Ayrıca, her piksel için ışınların çıkarılmasından sonra, bu ışınları diğer hesaplama işlemlerini gerektiren konuma ve yöne göre sınıflandıran başka bir yaklaşıma ihtiyacımız vardır. Bu da daha uzun uygulama süresine yol açar. Kare farkı yaklaşımı ile ilgili olarak, daha sonra bitişik kareleri birbirinden çıkarmak için kullanılan morfoloji işlemlerine rağmen, ortaya çıkan maske spermin şekline çok benzemez ve ayrıca yanlış alarm hatalarının varlığında tespit ettik, bakınız Şekil 17(c, d). Uygulama süresi, seçimdeki doğruluk ve uygulamadaki basitlik açısından en iyi performans, arka plan çıkarma

algoritması olarak gözlemledik. Deneysel sonuçlarda ortaya çıkan şekil spermlere oldukça benzediği gözlemlendi ve merkezleri doğru ve çok az hata ile çıkarıldı, Şekil 17(e, f).




(a)



(b)



(c)




(d)




(e)



(f)



(g)



(h)

Şekil 17. Sperm örnek videosunun iki karesine tespit tekniklerinin uygulanmasının sonuçları . a,b) Kare No. 15 ve 50, sırasıyla; c,d) Kare farkı uygulanmasının sonucu; e,f)Arka planın çıkarma sonucu; g,h) Optik akışı uygulamasının sonucu.

Algoritma sonuçlarının görselleştirilmesine bakılmaksızın, performansı ifade eden bir değere ihtiyacımız vardır. Tespit sistemini değerlendirmek için kullanılan metrik ortalama kare hatası MSE'dir (*Mean Squared Error*) kullanıldı. MSE, hataların karelerinin ortalamasını, yani tahmini değerler ile gerçek değer arasındaki ortalama kare farkını ölçer ve formül tarafından verilir.


$$MSE = \frac{1}{N} \sum_{i=1}^N (f_i - y_i)^2 \quad (5.1)$$

Burada N veri noktası sayısı, f_i tahmini değerler ve, y_i veri noktalarının gerçek değerleri temsil eder. Burada MSE, algoritma çıkışı ile 50 kare boyunca manuel olarak tespit edilen gerçek sperm sayısı arasındaki farkı belirler.

Şekil 17 (g, h) 'de, Optik Akışı uygularken, bitişik her kareler arasındaki hareketi tespit başarımının yüksek olduğunu gözlemledik. Burada her bir karede tespit edilen ve hareket eden nesne sperm sayısını belirler. Görüntülerde sperm sayısı ve yoğunluğu çok fazladır. Bu nedenle bu yöntemde başarımın yüksek elde edilmesine rağmen çalışma süresinin çok yüksek olduğunu gözlemledik. Bu nedenle, bunların yerine hem (Urbano *et la.* 2016)'da hem de (Alhajalabdulla 2020)'da kullanılan tesspit algoritmaları kullanılmıştır.

Şekil 18 'da gördüğümüz sonuçlar, her algoritma için tespit edilmiş sperm sayısına kıyasla elli çerçeve için her çerçevedeki gerçek sperm sayısını göstermektedir. Her çerçevedeki gerçek sperm sayısı y_i ile temsil edilir. Her yöntem tarafından tespit edilen sperm sayısı f_i olarak ifade edilir. Her algoritma için MSE değerini (5.1) denkleme göre hesaplanabilir. Arka plan çıkarma algoritmasının MSE'nin 1.62 değeri ile doğruluk ve zaman açısından etkili bir

performans verdiğini tespit ettik. Önceki çalışma için (Urbano *et al.* 2016) söz konusu algoritma 3.96 MSE ile iyi bir performansa sahiptir. Ancak temel doğruluk çizgisinin üzerindeki kısım tarafından temsil edilen bazı yanlış alarmlar, altındaki kısım tarafından temsil edilen bazı hareketli nesneleri kaçırdığını tespit ettik.



Şekil.18 Gerçek sperm sayısına kıyasla her yöntem için doğrulanan sperm sayısı

Kare farkı yöntemi, 13.02 MSE ile çıktı hattı ile gerçek değer çizgisi arasındaki büyük farktan fark ettiğimiz gibi en kötüsüdür. (Alhajalabdulla 2020)'da kullanılan algoritmasının MSE'nin 0.86 değeri ile doğruluk ve zaman açısından en iyi bir performans verdiğini tespit ettik. Ancak bu yöntem her seferinde hareketsiz ve hareketli spermleri bir araya getirip takip aşamasına göndererek uygulama süresinin artmasına neden olur. Oysa takip algoritmasının her seferinde hareketsiz sperm ile çalıştırılmasına gerek yoktur. Arka plan çıkarma algoritması, sadece hareketli spermi tespit eder, hareketsiz ise onu görüntünün arka planından çıkarır ve hareket etmeyen sperm olarak doğrudan analiz aşamasına gönderir. Bu nedenle sperm analiz sisteminin ilk aşamasında arka plan çıkarma yöntemini kullandık.

4.2 Sperm İzlemesi Karşılaştırması


Algoritmaların bibrileri ile performansı karşılaştırmak çeşitli kriterlere bağlıdır. Bu nedenle nesneleri algılama başarısızlığını ve algılama durumunda algoritmanın tahmininin ne kadar doğru olduğunu, yani gerçek yörüngenin tahmini yörüngeye ne kadar yakın olduğunu

belirleyen bir metriğe ihtiyacımız var. Bu durumda, algoritmalarından hangisinin en iyi tahmini yaptığını belirlemek için önceki kriterleri temsil eden bir değere ihtiyacımız var. OSPA metriği, üç hata kardinalite (yörünge saptama hatası), lokalizasyon (tahmin doğruluğu) ve etiketleme (yörünge atama takas) tanımlayan, bir değerle ifade edilen en yaygın kullanılan metriklerden biridir ve bu çalışmada biz bu metriği kullandık (Urbano 2014; Urbano *et al.* 2016).

4.2.1 Optimal Alt-Desen Ataması (Optimal Subpattern Assignment OSPA) Metriği

Çok hedefli bir izleme algoritmasının performansı tipik olarak iki yol kümesi kullanılarak değerlendirilir: Birincisi, algoritma tarafından üretilen tahmini yörüngeler kümesidir. İkincisi bilinen yer gerçeği yörüngeler kümesidir. İki yol ya da yörünge kümesini karşılaştırdığımızda karşılaştığımız en önemli sorunlardan biri, hangi yolların birbiriyle karşılaştırılacağıdır. Başka bir deyişle: hangi tahmini yol hangi kesin referans yörünge ile karşılaştırılmalıdır [12]. Takip algoritması mükemmel, tahmin edilen her bir yörünge geçici ve uzamsal olarak her yer gerçeği yörüngeyle aynıdır.

Herhangi bir doğru takip algoritmasının çıktısına bakarken, ortaya çıkan yolların gerçek yollarla aynı olması gerekli değildir. Bu takip algoritmasında bazı kusurları bulabiliriz, örneğin, Şekil 19(a)'de, birbirine yakın bir yol veya yörünge olarak kabul edilen iki yolumuz var.



Şekil 19. Kusurlu izleme için dört örnek

Şekil 19(b)'de birbirine çok yakın olan iki varsayımsal yolumuz var, hangisinin üst uçtaki hangisinin de alt uçtaki yol için olduğu üst ve alt yörüngeye en yakın olanı seçilerek yapılır . Üçüncü duruma gelince, Şekil 19(c) izleyici yolu herhangi bir nedenle izleyemedi ve bir çıktı verdiğini bulunmadı. Şekil 19(d)' de dördüncü durumda, bir yol için iki yolun varsayıldığını

ancak aralıklı olduğunu görüyoruz. Ayrıca, yolun başlangıcını varsaymada bir gecikme ve yolun durdurulmasında bir gecikme olabilir. (Schuhmacher et al. 2008)'da Schuhmacher, zemin gerçekliği ve tahmini yörüngeler arasında optimum alt desen ataması (OSPA) mesafesini tanıttı; bu şekilde, tahmini gerçek yörüngeleri zemin gerçekliği yörüngelerine atama problemi, optimal atama problemi olarak kullanarak çözülür. (Ristic et al. 2011) 'de Ristic, OSPA mesafesi kavramını, yörünge kimlikleri değiştirilirse bir algoritmayı cezalandıran etiketli parkurlara genişletmiştir. Yörüngeler arasındaki OSPA mesafesi, üç izleme hatası, yerelleştirme hatası (Tahmini ve gerçek yörüngeler arasındaki eklenti mesafesi), etiketleme hatası (tahmini parçalar etiketlerini başka bir parçaya kaydırıldığında ortaya çıkar, yani bölünmüş yörünge) ve, kardinalite hatasıdır (tahmini parça sayısı gerçek parça sayısına kıyasla). OSPA mesafesi her k saatinde hesaplanırsa da, ilk önce yer gerçeği yörüngelerini izleme algoritmasının çıktısı olan tahmini yörüngelerle eşleştirmemiz gerekir. Bu, yörünge çiftleri arasındaki mesafelerin toplamını en aza indiren tahmini yollara zemin gerçeği atamalarının küresel olarak optimal permütasyonunu bulmak için çalışan Murty algoritma tarafından yapılır. Bundan sonra etiketli yörüngeler arasındaki OSPA mesafesi hesaplanabilir. k zamanında, q etiketli X_k zemin doğruluk yörüngeleri seti (Urbano 2014) tarafından verilir.

$$X_k = \{(x_{k,1}, l_1^x), \dots, (x_{k,q}, l_q^x)\}, \quad (5.2)$$

ve çok hedefli izleme algoritması tarafından üretilen r etiketli tahmini Y_k seti

$$Y_k = \{(y_{k,1}, l_1^y), \dots, (y_{k,r}, l_r^y)\} \quad (5.3)$$

$x_{k,i}$, yer gerçek yörünge i 'nin l_i^x , $i = 1 \dots q$ etiketli konumudur; $y_{k,j}$, yer gerçek yörünge j 'nin l_j^y , $j = 1 \dots r$ etiketli konumudur. Bir yörüngeyle ilişkili etiketler zamanla değişmez. $q \leq r$ için, OSPA mesafesi (Ristic et al. 2011) tarafından (5.4) denklem ile verilir,

$$d_o(X_k, Y_k) = \left[\frac{1}{r} \left(\min_{\pi \in \Pi_r} \sum_{i=1}^m \left(d_c(X'_{k,i}, Y'_{k,\pi(i)}) \right)^p + (r - q)^{c^p} \right) \right]^{1/p} \quad (5.4)$$

Bu arada, $x'_{k,i} = (l_i^x, x_{k,i})$, $y'_{k,\pi(i)} = (l_{\pi(i)}^y, x_{k,i})$, Π_r , 1 'den r 'ye kadar alınan elemanlarla q uzunluğunun permütasyon kümesidir, ve $1 \leq p \leq \infty$, OSPA sıra parametresidir. $d_c(x', y') = \min(c, d(x', y'))$, k zamanında etiketli iki yörünge arasındaki kesme mesafesi; $C > 0$, kesme parametresidir. Kesim mesafesinin amacı, büyük mesafelere ayrılan atanmış parkurların cezasını sınırlamaktır, k zamanında etiketli iki yörünge arasındaki taban mesafesi bu şekilde verilir,

$$d(x', y') = (d(x, y)^p + d(l^x, l^y)^p)^{1/p}, \quad (5.6)$$

Yerleştirme taban mesafesi (5.5) denklem tarafından verilir,

$$d(x, y) = ||x - y||_p. \quad (5.7)$$

Etiketleme hatası da,

$$d(l^x, l^y) = \begin{cases} \xi, & \text{if } l^x \neq l^y \\ 0, & \text{otherwise} \end{cases} \quad (5.8)$$

burada ξ parametresi, $d(x, y)$ yerleştirme taban mesafesine göre yorumlanan etiketleme hatasına atanan cezayı kontrol eder. $\xi = 0$ değeri, etiketleme hatasına ceza vermez ve $\xi=C$ maksimum cezayı atar.

4.2.2 İzleme Senaryolar:

Sperm hareketliliğini analiz etmek ve IMM-DA'nın önerilen algoritmanın özel bir durumda IMM-JPDAF'ın spermin gerçek durumuna (konumuna) daha yakın bir durumu varsayarak beklenen sonuçları elde edip etmediğini incelemek için kullanılan spermlerinin gerçek izleri yoktur. Objektif karşılaştırma yapabilmek ve önerilen algoritmanın varsayımının geçerliliğini bulmak için çeşitli senaryolar üretilmiştir. Önerilen algoritma, sperm hareketini simüle etmek için nispeten yeterli olan sabit hız ve sabit dönüş modellerini içerir. Sonuçları genellikle sabit hız modeli olan tek bir hareket modeli kullanan (Urbano 2014) 'de kullanılan GNN, PDAF ve JPDAF orjinal veri ilişkilendirme algoritmaları ile karşılaştırıldı.

Önerilen IMM-JPDAF algoritması (Alhajalabdulla 2020) 'de önerilen tespit algoritması ile karşılaştırıldı. Yazarlar çalışmasında optimuma yakın yüksek performanslı bir tespit algoritması önerdiği için, yalnızca spermlerin yörüngelerini kaybetmeye veya başka bir yörüngeye geçmesi nedeniyle karşılaşılabileceği problemlerin çözümüne odaklandılar. Biz bu tez çalışmasında farklı olarak, tespit aşamasında görüntülerde FA tipi bir gürültü olduğu ve ölçümlerin spermin merkezine yakın olabileceği durumunla ele aldık. Bu durumun nedeni, gerçek videolarda farklı örneklerle tek bir tanımlama sistemi uygularken çok kesin hataların olmasıdır. Bu nedenle algoritmamız gürültü varlığına ve bu sözde varsayılan yörüngenin gerçek yörüngeye ne kadar yakın olmasına bakılmaksızın spermin yörüngesini takip etmeyi amaçlar.

Veri noktaları, kullanılan tespit sisteminden kaynaklanan verilere biraz benzer şekilde oluşturulmuştur. Burada tespit algoritmasının bazen gerçek koordinatlarla tam olarak eşleşmeyen, ancak onlara çok yakın olan sperm merkezi koordinatlarını vermesi mümkündür, Bu işlem, gerçek veri noktaları veya gerçek izler üzerinden Gauss dağılımı kullanılarak simüle edildi. Her sperm nesnesi için 0.0667 saniye zaman aralığı ile 100 puan üretildi; bu, saniyede 15 kareye eşdeğerdir. Şekil 20 'de önerilen senaryolarda, izler farklı davranışlarla oluşturulmuştur, Her senaryo altında, 100 senaryo boyunca aynı senaryoya uygulanan her

algoritma için OSPA mesafe değerlerini buluyoruz. Söylediğimiz gibi, sonuçlar iki algoritma grubu arasında karşılaştırılacak: Birinci grup IMM-DA, iki sabit düz hareket ve sabit dönme hareketi modeli içeren IMM teknolojisi ile donatılmıştır ve ikincisi bir hareket modeli içerir DA. OSPA ölçeğine göre elde edeceğimiz sonuçlara dayanarak, hangisinin en iyi performansı gösterdiğini bize açıklayacağız.

Birinci senaryoda Şekil 20 (a) 'da, aynı sabit hızla üç nesnenin 1,2 3 hareket ettiğini görüyoruz. Şekil 20 (b) de görüleceği üzere hareketli nesne takip sonuçları, küçük bir farkla tüm algoritmalar için benzerdir ve iki hareket modeli içeren algoritmalar ise Tablo 1'de görebileceğimiz gibi küçük OSPA değerine sahiptir.

İkinci senaryo, başlangıçta sabit bir hızda hareket eden, daha sonra dairesel bir hareket ve daha sonra sabit bir hızda hareket eden ve ardından bir dönüş yapan tek bir nesnedir. Şekil 21(a)' da görüleceği üzere IMM_DA algoritmaları genel olarak en yakın varsayımı verdi. Çünkü dairesel ve düz hareketli modelleri bu senaryoda birleştirildi. Ancak Şekil 21(b)' de görüleceği üzere ancak en iyi performans, 3.0655 um OSPA değeri ile IMM-GNN ve IMM-JPDAF algoritmasında gözlemlendi.

Şekil 22(a)'de üç yol içeren üçüncü senaryo gösterilmiştir. Birinci ve üçüncü yollar gergin sabit hız hareketi ile birbirine çok yakındır. İkinci nesnenin dairesel bir hareketi vardır. Şekil 22 (b)' de görüleceği üzere en kötü performans, OSPA değeri 29,99'a eşit olan IMM-PDAF algoritması göstermiştir. 22,722 um ile PDAF algoritmasının sonuçları oldukça yüksektir. PDAF'ın temel olarak bir nesneyi izlemek için kullanılmıştır, ancak hareketli nesnelerin birbirinden yeterince uzak olmaları durumunda birçok nesneyi izlemek için de kullanılabilir. Burada bizim durumumuzda, nesneler 0 ve 25 periyodu içinde birbirine çok yakındır, bu da takip edilmemesine ve birbirine bitişik üç yolu tek bir yol olarak görmesine neden olmuştur. Aynı zamanda, GNN, IMM-GNN hariç çoğu algoritma için (ve OSPA'nın büyük değerlerinde yatmaktadır) bu zaman dilimindeki bozulmanın olduğunu gözlemledik. Böylece GNN'nin FA gürültüsünün yokluğunda paralel ve yakın yollarda etkili bir takip algoritması olduğunu söyleyebiliriz. En iyi performans sırasıyla 4.40, 4.85 ve 6.21 um OSPA değerleriyle IMM_GNN ve ardından GNN ve ardından IMM_JPDAF algoritması tarafından elde edildi.


Dördüncü senaryoda, sperm hareketini simüle eden bir fonksiyon (Urbano 2014) kullanıldı. Şekil 23(a)' da görüleceği üzere bu fonksiyon ile farklı davranış ve hızlarda altı spermden oluşan izler üretildi. Şekil 23 (b)' de algoritmaların performanslarını inceledik. Genel olarak IMM_DA algoritmaları DA algoritmalarından çok daha iyi performans gösterdi. Bir hedef izleme için kullanılan IMM_PDAF'ın normal, JPDAF'dan daha iyi sonuçlar verdiğini

belirtmek isteriz. IMM-GNN en yüksek OSPA mesafesini 3.7932 μm verdi. IMM-JPDAF 3.8405 μm OSPA mesafesiyle de en yüksek performans değerini üretti. IMM-PDAF algoritmasında, sperm hareketleri başlangıçta birbirine yakın yüzmesine rağmen JPDAF'dan daha iyi sonuçlar vermiştir. Sonuçta ortaya çıkan OSPA mesafesi sırasıyla 8.4188 ve 12.2547 μm değerleri elde edildi.


Şekil 24(a)' da beşinci senaryo gösterildi ve bu senaryo hareket takibi algoritmaları için oldukça çok zor olan bir senaryo oluşturuldu. Senaryoda öncelikle birçok algılama sisteminin çoğunun dezavantajlarını taklit eden birçok yanlış alarm ve kayıp algılama içeriyor. Dört nesnemiz var; ikisi dairesel bir hareketle, diğerleri düz bir hareketle hareket ediyor. Tüm yörüngeler birbirine çok yakın, ayrıca birkaç çapraz yörünge bulunmaktadır. Geçiş yolları sorunu, sprems hareketlerinde çok fazla bulunur. Şekil 24(b)' de görüleceği üzere en göze çarpan performans, bahsettiğimiz tüm zorlukların varlığında en düşük OSPA mesafesini 2.6243 elde eden IMM-JPDAF algoritmasıdır. IMM_GNN algoritmasının, burada FA ve OSPA'nın dağınıklığı nedeniyle geri çekilirken beklendiği gibi performans gösterdiğini görüldü ve OSPA mesafesi 8.4375 μm olarak elde edildi. Grafikten, başlangıçta IMM-GNN ve GNN'nin, yollar birbirine yakın ve paralel olduğu için OSPA değerlerinin yaklaşık 1,5 civarında düşük olduğunu fark ettik. Ancak, birkaç nesne çarpışmasının kavşağının başlangıcı olduğu ve 38 saniyeden itibaren gürültünün meydana geldiği, bu iki algoritmanın performansını bozduğu ve bu da OSPA değerinin büyümesine neden olduğu gözlemlendi. IMM-PDAF ve PDAF algoritmaları simlasyonun başından beri belli bir gecikme ile takip ediyor. Bu durumun sebebi yörüngeler arasındaki mesafenin 5 μm olduğu için birbirine yakın olmasıdır. Bu gecikme parazit ve gürültünün artması nedeniyle de daha da çoğaldı. En kötü performans 29,8946 withm ile PDAF'den geldi. GNN, JPDAF, IMM-PDAF algoritmaları sırasıyla 16.6748, 21.8778, 23.3467 μm OSPA değerleri elde edildi.

Altıncı, yedinci ve sekizinci senaryolar Şekil 25(a), Şekil 26(a) ve Şekil 27(a) için, rastgele bir şekilde sperm hareketlerini simüle eden on nesne üretildi, sekizinci senaryo ayrıca yanlış alarm tipi gürültü içeriyor. Şekil 25(b), Şekil 26(b) ve Şekil 27(b)' den görüleceği üzere önerilen algoritma IMM-JPDAF algoritması bu zor senaryolar için en iyi performans gösteriyor

Şekillerde OSPA mesafe çizgisi boyunca gözlemlediğimiz titreşimlerin nedeni, Gauss dağılımı tarafından gerçek yolun uçlarından üretilen farklı ölçüm mesafeleri olmasıdır.




(a)




(b)

Şekil 20. İzleme algoritmalarının 1. senaryoya uygulamanın sonuçları
(a) Önerilen senaryo 1 , (b) Her algoritma için OSPA değerleri.




(a)




(b)

Şekil 21. İzleme algoritmalarının 2. senaryoya uygulamanın sonuçları (a) Önerilen senaryo 2 , (b) Her algoritma için OSPA değerleri.




(a)




(b)

Şekil 22. İzleme algoritmalarının 3. senaryoya uygulamanın sonuçları (a) Önerilen senaryo 3 , (b) Her algoritma için OSPA değerleri.




(a)




(b)

Şekil 23. İzleme algoritmalarının 4. senaryoya uygulamanın sonuçları. Önerilen senaryo 4 , (b) Her algoritma için OSPA değerleri.




(a)




(b)

Şekil 24. İzleme algoritmalarının 5. senaryoya uygulamanın sonuçları.
(a) Önerilen senaryo 5 , (b) Her algoritma için OSPA değerleri.





(a)





(b)

Şekil 25. İzleme algoritmalarının 6. senaryoya uygulamanın sonuçları.
(a) Önerilen senaryo 6 , (b) Her algoritma için OSPA değerleri.



Şekil 26. İzleme algoritmalarını 7. senaryoya uygulamanın sonuçları
(a) Önerilen senaryo 7 , (b) Her algoritma için OSPA değerleri.



(b)

Şekil 27. İzleme algoritmalarının 8. senaryoya uygulamanın sonuçları.
 (a) Önerilen senaryo 8 , (b) Her algoritma için OSPA değerleri.

Tablo 2’de yukarıda verilen herbir algoritma ve 8 farklı senaryo için OSPA mesafe değerleri gösterilmiştir. OSPA değeri ne kadar küçük olursa daha iyi performans demektir. Önerilen algoritmaya IMM-JPDAF ek olarak IMM-GNN algoritmanın da iyi sonuçlar verdiğini gözlemledik. Özellikle, birbirine paralel ve birbirine çok yakın hareket eden nesneleri içeren senaryolarda ve karmaşık koşullar içeren durumlarda performansların önemli ölçüde azaldığını gözlemledik. Aynı koşullar altında en iyi performansın önerilen algoritma IMM-JPDAF olduğunu gözlemledik. Genel olarak, spermelerin birbirine çok yakın yüzdüğü ve her zaman aralarında çarpışma meydana geldiği bu nedenle çapraz yollar ürettiği gerçek sperm görüntülerinde bulunmaktadır. Bu yüzden senaryolar oluşturulurken elimizdeki videonun yüksek doğrulukta kesin reerans değerlerinin var olduğunu kabul ettik ve içinde çok fazla safsızlık olmadığını varsaydık. Hareket takibi algoritmalarının başarımı, tespit algoritmalarının başarımına bağlı olması nedeniyle, yanlış alarm FA gürültüsünün yok olduğunu kabul ettik. Ancak bu durumda normal doğrulukta video örnekleri elde edilmesi ve görüntülerin safsızlığa sahip olması yanlış alarm hatalarına neden olabilir. Bu iki durumda da, önerilen IMM-JPDAF algoritmasının başarımı en yüksek olması nedeniyle, sperm hareketliliğini analiz etmek ve sınıflandırmakta kullanıldı.

Tablo 2. OSPA Mesafesinin Değerleri

OSPA Meafesi (μm)	GNN	IMM- GNN	PDAF	IMM- PDAF	JPDAF	IMM- JPDAF
Senaryo 1	5.1051	4.774	5.1054	4.774	5.1051	4.774
Senaryo 2	3.3728	3.0655	3.3727	3.0654	3.3728	3.0655
Senaryo 3	4.8594	4.4039	22.7223	29.9964	11.8933	6.2184
Senaryo 4	13.4655	3.7932	17.9045	8.4188	12.2547	3.8405
Senaryo 5	16.6748	8.4375	29.8946	23.3467	21.8778	2.6243
Senaryo 6	5.7962	8.24	9.6029	8.24	5.9763	4.071
Senaryo 7	10.0119	5.5477	11.2884	10.6161	7.0998	4.8591
Senaryo 8	14.8772	4.516	14.6723	8.4640	14.8792	4.5162

4.3 Analiz Sonuçları


Bu bölümde, nesne tespiti için Arkaplan Çıkarma yöntemi ile nesne takibi için önerilen IMM-JPDAF algoritması gerçek sperm vidoeları üzerinde analiz edilmiştir. Sperm videoları Atatürk Üniversitesi Veterinerlik Fakültesi tarafından mikroskop ile çekilmiştir. Videolarda boğa spermeleri bulunmaktadır. Videonun süresi 5.06 saniyedir, kare sayısı 253, 640*480 piksel çözünürlüğünde, video kare hızı 50 fps'dir ve her kare arasındaki zaman adımı 0.02 saniyedir. İlk önce analiz sisteminin iki ana boğa örneğine uygulanmasını detaylı olarak göstereceğiz. Ardından geri kalan boğa, koç ve aygır örneklerinde izleme sonuçlarını kısaca sunacağız.

4.3.1 İlk örnek analizinin sonuçları


Üçüncü bölümde belirttiğimiz gibi, her karedeki sperm merkezlerini belirlemek için, tüm karelerde görüntü işleme teknikleri (renkleri griye dönüştürme ve parazit giderme ve kontrastı ayarlama gibi) uygulandıktan sonra, tüm video kareleri için ortalama pikselleri alarak video için arka planı çıkardık. Şekil 28(a)' da elde edilen görüntü gösterilmiştir. Şekil 28(b)'de görüleceği üzere video karelerini (bu rönekte beşinci kare olsun) arka plandan çıkarıldı. Şekil 27(c)' de eşikleme ve daha sonra morfoloji işlemler sonucunda elde edilen imge gösterilmiştir. Bu görüntülerdeki beyaz alanlara numara vererek sperm olması muhtemel olmayan küçük alanlar kaldırıldı. Şekil 28(d) ' de görüleceği üzere, sonrasında her bir beyaz alanın merkezleri bulundu. Bazen tespit sisteminden kaynaklanan merkezlerin gerçek sperm merkezleriyle tam olarak uyuşmadığına dikkat çekmek istiyoruz.




(a)



(b)



(c)




(d)


Şekil 28. Tespit sisteminin uygulanmasının aşamaları. (a) sperm videosunun arka planı, (b) arka plan ile geçerli çerçeve arasındaki fark, (c) morfolojik işlemleri uygulamak, (d) spermleri etiketlemek




(a)



(b)



(c)



(d)

Şekil 29. IMM_JPDAF kullanarak izleme sonuçları (a), (b), (c) ve (d) 'de video üzerinden sırasıyla 50, 150, 200 ve 252 karelerde sperm izleme sonuçları.

Şekil 29' de IMM_JPDAF kullanarak takip algorimasının sonuçları gösterilmiştir. Yeşil çizgilerin tahmini sperm yörüngesi ve yanında tahmini yörünge numarası bulunmaktadır. Hareket etmeyen birçok sabit spermin bulunmaktadır. Bu spermilerin tespit algoriması ile sabitlendiğini ihmal edilir ve hareketsiz sperm olarak kabul edilir. Bu nedenle hareketli nesne takibi algoritmaları tarafından izlenmediğini, ancak analiz aşamasında hesaplandığını varsayıyoruz. Belirli yörüngenin LIN değeri 0.6'dan büyükse, *progresif hareketlilik*, 0.2 ile 0.6

arasındaki LIN değeri *progresif olmayan hareketlilik* ve LIN değeri 0.2'den daha düşük ise *hareketsiz* olarak sınıflandırılır.

Uygulanan tespit ve takip algoritmaları, tespitin FA sayısı neredeyse ihmal edilebilir olduğundan iyi sonuçlar verdiği gözlemlendi. Bir çarpışma durumunda, onaylanmış tespit algoritması çarpışmayı belirleme yeteneğine sahip değildir, çünkü çarpışma spermelerini bir nesne anlamına gelen bir bölge olarak görür. Bu nedenle, bir sonraki konumların tahmini üzerinde çalışan izleme sistemi bu sorunu çözebilir. İzleme sonrasında videoyu gözlemleyerek, izleme sisteminin spermelerin çoğunu izlemeyi başardığını söyleyebiliriz, ancak sperm videosunun örneği için gerçek yolu olmadığından, izleme sisteminin gerçek yolu kabul edebileceği doğruluk derecesini belirleyemeyiz. Bu yüzden bu tez çalışmasında önerilen yöntemil performansını analiz etmek için sentetik senaryolar kullandık. Tablo 3'da, WHO'ya göre üç tipte ilerledikleri için motilite analizinin sonuçlarını görmekteyiz.

Tablo 3. Hareketlilik Parametrelerine Dayalı Sperm Sınıflandırma Sonuçları


Sperm Motilite Sınıfı	Oran %
Progresif hareketlilik	69.81
Progresif olmayan hareketlilik	9.43
Hareketsizlik	20.75

4.3.2 İkinci örnek analizinin sonuçları


Burada da önerilen sperm analiz sistemi daha fazla sayıda sperm içeren ikinci boöa örneğe uygulanmıştır. Tespitin sonuçları şekil 30' de, izleme sonuçları Şekil 31' de gösterilmiştir. Hareketli sperm oranı veya sperm hareket analizi aşamasının sonuçları Tablo 4'de gösterilmiştir.




(a)



(b)




(c)




(d)


Şekil 30. Tespit sisteminin uygulanmasının aşamaları. (a) sperm videosunun arka planı, (b) arka plan ile geçerli çerçeve arasındaki fark, (c) morfolojik işlemleri uygulamak, (d) spermi etiketlemek




(a)



(b)



(c)



(d)


Şekil 31. IMM_JPDAF kullanarak izleme sonuçları (a), (b), (c) ve (d) 'de video üzerinden sırasıyla 70, 120, 170 ve 250 karelerde boğa sperm izleme sonuçları.

Tablo 4. Hareketlilik Parametrelerine Dayalı Sperm Sınıflandırma Sonuçları


Sperm Motilite Sınıfı	Oran %
Progresif hareketlilik	82.05
Progresif olmayan hareketlilik	15.81
Hareketsizlik	2.18

4.3.3 Farklı örnekler için analizin sonuçları


Bu bölümde, önerilen algoritmanın da uygulandığı farklı hayvanlardan (Koç, boğa ve aygır) alınan birkaç örnek için önerilen takip algoritmasının sonuçlarını göstereceğiz ve ardından Tablo 5'da tüm bu örnekler için hareket sınıflandırmasının sonuçlarını inceleyeceğiz.



(a)




(b)




(c)

Şekil 32. Koç örnekleri için izleme sonuçları. (a) koç-2 örneği, (b) koç-4 örneği, (c) koç-5 örneği,




(a)




(b)


Şekil 33. Boğa örnekleri için izleme sonuçları. (a) boğa-2 örneği, (b) boğa-3 örneği.



(a)



(b)



(c)

Şekil 34. Aygır örnekleri için izleme sonuçları. (a) aygır-1 örneği, (b) aygır-2 örneği, (c) aygır-3 örneği.

Tablo 5. Koç, Boğa ve Aygır örnekleri için Hareketlilik Sınıflandırma Sonuçları

Sperm Motilite Sınıfı	PR %	NP %	IM %
Örnek 1 / Koç-1	6.3492	3.1746	90.4762
Örnek 2 / Koç-2	8.75	5	86.25
Örnek 3 / Koç-3	11.1111	6.0606	82.8283
Örnek 4 / Koç-4	21.3115	1.6393	77.0492
Örnek 5 / Koç-5	14.2857	2.381	83.3333
Örnek 6 / Boga-1	28.8344	13.1902	59.5092
Örnek 7 / Boga-2	5.4545	6.6667	87.8788
Örnek 8 / Boga-3	18.9135	17.9074	64.1851
Örnek 9 / Aygır-1	7.8947	3.9474	88.1579
Örnek 10 / Aygır-2	5.9524	10.7143	83.3333
Örnek 11 / Aygır-3	10.5263	10.5263	78.9474
Örnek 12 / Aygır-4	4.7619	12.6984	82.5397

SONUÇLAR VE ÖNERİLER

Bu tezde, mikroskop video görüntülerinden dinamik sperm motilite parametrelerini analiz etmek ve çoklu sperm hareketlerini sınıflandırmak için IMM-JPDAF adında yeni bir yöntem önerdik. Önerilen yöntemler daha önce radar verisinde nesne takibi problemlerinde kullanılmış yöntemler olup, tez kapsamında mikroskop video görüntülerinde sperm hareketlerinin takibi için adapte edilmiştir. Önerilen yöntemde kullanılan IMM algoritması manevra şeklinde hareket eden nesnelerin takibinde kullanılan başarılı bir algoritmadır. IMM yöntemi, bir nesnenin durumunun en iyi varsayımını vermek için bileşen hareket modellerini birbiriyle etkileşerek bir nesnenin hareketini algılama yeteneğine sahiptir. Biz bu tez çalışmasında IMM algoritması ile DA algoritmaları ile birleştirerek, sperm hareketlerinin tespiti için yeni bir yöntem önerdik. Önerilen yöntemi IMM-DA ve DA olmak üzere iki farklı takip algoritmasını ile karşılaştırdık. Önerilen yöntemi hem sentetik olarak ürettiğimiz verilerde hemde hayvanlardan alınmış gerçek sperm görüntülerinde inceledik. Deneysel sonuçlarda, sperm hareketlerinin davranışlarına uygun olarak en iyi sonuçların önerilen IMM-JPDAF algoritması ile elde edildiği gözlemlendik.

Spermin doğrusal olmayan bir şekilde hareket etmesi ve kesin referans yörüngesinin belli olmaması durumunda sperm yörüngelerinin hesaplanmasında bir hata oluşur. Bu nedenle, gelecek çalışmalarımızda daha doğru bir sperm yörüngesi elde etmek için Partikül filtresi yada Koksuz Kalman filtresi kullanarak hareket modellerine doğrusal olmayan bir model eklemeyi planlıyoruz. Ayrıca sperm görüntülerinde milyonlara sperm bulunmaktadır. Bu nedenle sperm hareket modellerini arttırılması işlem süresini arttıracaktır. Gelecek çalışmalarımızda paralel programlama algoritmaları kullanarak veri işlem hızını arttırmayı ve örnek sayısının (sperm yoğunluğu) daha fazla olduğu video görüntülerinde analiz yapmayı planlıyoruz.

KAYNAKLAR

- (Alhajalabdulla 2020) Alhajalabdulla A. (2020). Modeling of a new algorithm for following ram, bull and stallion sperm cells. Atatürk University.
- (Agarwal *et al.* 2016) Agarwal, A., Gupta, S., & Singh, D. K. (2016, December). Review of optical flow technique for moving object detection. In *2016 2nd International Conference on Contemporary Computing and Informatics (IC3I)* (pp. 409-413). IEEE.
- (Amann *et al.* 2004) Amann, R. P., & Katz, D. F. (2004). Andrology lab corner: Reflections on casa after 25 years. *Journal of andrology*, 25(3), 317-325.
- (Amann *et al.* 2014) Amann, R. P., & Waberski, D. (2014). Computer-assisted sperm analysis (CASA): capabilities and potential developments. *Theriogenology*, 81(1), 5-17.
- (Athanesious *et al.* 2012) Athanesious, J. J., & Suresh, P. (2012). Systematic survey on object tracking methods in video. *International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)*, 1(8), 242-247.
- (Ayad 2018) Ayad, B. M. (2018). Basic semen parameters assisted by Computer-Aided sperm analysis (CASA) and their correlations with advanced semen parameters in normozoospermic men with different abstinence periods (Doctoral dissertation, Stellenbosch: Stellenbosch University).
- (Ayad *et al.* 2018) Ayad, B. M., Van der Horst, G., & Du Plessis, S. S. (2018). Revisiting the relationship between the ejaculatory abstinence period and semen characteristics. *International journal of fertility & sterility*, 11(4), 238.
- (Bar-Shalom *et al.* 2009) Bar-Shalom, Y., Daum, F., & Huang, J. (2009). The probabilistic data association filter. *IEEE Control Systems Magazine*, 29(6), 82-100.
- (Bar-Shalom *et al.* 2011) Bar-Shalom, Y., Willett, P. K., & Tian, X. (2011). *Tracking and data fusion* (Vol. 11). Storrs, CT, USA:: YBS publishing.
- (Balci *et al.* 2004) Balci, B., & Yilmaz, O. (2004). Atherosclerotic involvement in patients with left or right dominant coronary circulation. *Kardiologia Polska (Polish Heart Journal)*, 60(6), 566-566
- (Beya *et al.* 2015) Beya, O., Hittawe, M., Sidibé, D., & Meriaudeau, F. (2015, November). Automatic detection and tracking of animal sperm cells in microscopy images. In *2015 11th International Conference on Signal-Image Technology & Internet-Based Systems (SITIS)* (pp. 155-159). IEEE.
- (Bewley *et al.* 2016) Bewley, A., Ge, Z., Ott, L., Ramos, F., & Upcroft, B. (2016, September). Simple online and realtime tracking. In *2016 IEEE International Conference on Image Processing (ICIP)* (pp. 3464-3468). IEEE.
- (Bourgeois *et al.* 1971) Bourgeois, F., & Lassalle, J. C. (1971). An extension of the Munkres algorithm for the assignment problem to rectangular matrices. *Communications of the ACM*, 14(12), 802-804.
- (Comaniciu *et al.* 1999) Comaniciu, D., & Meer, P. (1999, September). Mean shift analysis and applications. In *Proceedings of the Seventh IEEE International Conference on Computer Vision* (Vol. 2, pp. 1197-1203). IEEE.

- (Comaniciu *et al.* 2003) Comaniciu, D., Ramesh, V., & Meer, P. (2003). Kernel-based object tracking. *IEEE Transactions on pattern analysis and machine intelligence*, 25(5), 564-577
- (Cooper *et al.* 2006) 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
- (Dai *et al.* 2018) Dai, C., Zhang, Z., Huang, J., Wang, X., Ru, C., Pu, H., ... & Jarvi, K. (2018). Automated non-invasive measurement of single sperm's motility and morphology. *IEEE transactions on medical imaging*, 37 (10), 2257-2265.
- (DAVIS *et al.* 1992) DAVIS, R. O., & KATZ, D. F. (1992). Standardization and comparability of CASA instruments. *Journal of Andrology*, 13(1), 81-86..
- (Dharampal 2015) Dharampal, V. M. (2015). Methods of image edge detection: A review. *J Electr Electron Syst*, 4(2).
- (Fàbrega *et al.* 2012) Fàbrega, A., & Vila, J. (2012). *Yersinia enterocolitica*: pathogenesis, virulence and antimicrobial resistance. *Enfermedades infecciosas y microbiologia clinica*, 30(1), 24-32.
- (Fieguth *et al.* 1997) Fieguth, P., & Terzopoulos, D. (1997, June). Color-based tracking of heads and other mobile objects at video frame rates. In *Proceedings of IEEE computer society conference on computer vision and pattern recognition* (pp. 21-27). IEEE.
- (Gunalp *et al.* 2001) Gunalp, S., Onculoglu, C., Gurgan, T., Kruger, T. F., & Lombard, C. J. (2001). A study of semen parameters with emphasis on sperm morphology in a fertile population: an attempt to develop clinical thresholds. *Human reproduction*, 16(1), 110-114.
- (Gomes 2008) Gomes, J. B. B. (2008). An overview on target tracking using multiple model methods. *Instituto Superior Tecnico*.
- (Hambal *et al.* 2017) Hambal, A. M., Pei, Z., & Ishabailu, F. L. (2017). Image noise reduction and filtering techniques. *International Journal of Science and Research (IJSR)*, 6(3), 2033-2038.
- (Harris *et al.* 1988) Harris, C. G., & Stephens, M. (1988, August). A combined corner and edge detector. In *Alvey vision conference* (Vol. 15, No. 50, pp. 10-5244).
- (Hidayatullah *et al.* 2014) Hidayatullah, P., & Zuhdi, M. (2014, November). Automatic sperms counting using adaptive local threshold and ellipse detection. In *2014 International Conference on Information Technology Systems and Innovation (ICITSI)* (pp. 56-61). IEEE.
- (Hidayatullah 2015) Hidayatullah, P., Awaludin, I., Kusumo, R. D., & Nuriyadi, M. (2015, November). Automatic sperm motility measurement. In *2015 International Conference on Information Technology Systems and Innovation (ICITSI)* (pp. 15). IEEE.
- (Hidayatullah *et al.* 2016) Hidayatullah, P., Awaludin, I., Sukmawati, E., Utami, D., & Nuriyadi, M. (2016, October). Bull sperm motility measurement using improved matching-based algorithm and ellipse detection. In *2016 International Conference on Informatics and Computing (ICIC)* (pp. 55-60). IEEE.
- (Hidayatullah *et al.* 2017) Hidayatullah, P., Mengko, TLER, & Munir, R. (2017). A survey on multisperm tracking for sperm motility measurement. *International Journal of Machine Learning and Computing*, 7 (5), 144-151.
- (Jati *et al.* 2016) Jati, G., Gunawan, A. A., Lestari, S. W., Jatmiko, W., & Hilman, M. H. (2016, October). Multi-sperm tracking using hungarian kalman filter on low frame rate video.

In 2016 *International Conference on Advanced Computer Science and Information Systems (ICACSIS)* (pp. 530-535). IEEE.

- (Jonker *et al.* 1986) Jonker, R., & Volgenant, T. (1986). Improving the Hungarian assignment algorithm. *Operations Research Letters*, 5(4), 171-175.
- (Joshi *et al.* 2012) Joshi, K. A., & Thakore, D. G. (2012). A survey on moving object detection and tracking in video surveillance system. *International Journal of Soft Computing and Engineering*, 2(3), 44-48.
- (Keel 2004) Keel, B. A. (2004). How reliable are results from the semen analysis?. *Fertility and sterility*, 82(1), 41-44.
- (Li *et al.* 2010) Li, X., Wang, K., Wang, W., & Li, Y. (2010, June). A multiple object tracking method using Kalman filter. In *The 2010 IEEE international conference on information and automation* (pp. 1862-1866). IEEE.
- (Lowe 2004) Lowe, D. G. (2004). Distinctive image features from scale-invariant keypoints. *International journal of computer vision*, 60(2), 91-110.
- (Mazor *et al.* 1988) Mazor, E., Averbuch, A., Bar-Shalom, Y., & Dayan, J. (1998). Interacting multiple model methods in target tracking: a survey. *IEEE Transactions on aerospace and electronic systems*, 34(1), 103-123.
- (Mortimer *et al.* 2000) Mortimer, S. T. (2000). CASA—practical aspects. *Journal of andrology*, 21(4), 515-524.
- (Nurhadiyatna *et al.* 2014) Nurhadiyatna, A., Latifah, A. L., Fryantoni, D., Wirahman, T., Wijayanti, R., & Muttaqien, F. H. (2014, November). Comparison and implementation of motion detection methods for sperm detection and tracking. In *2014 International Symposium on Micro-NanoMechatronics and Human Science (MHS)* (pp. 1-5). IEEE.
- (Otsu 1979) Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1), 62-66.
- (Papageorgiou 1998) Papageorgiou, G. (1998). Robust control system design: Hx loop sharing and aerospace applications (Doctoral dissertation, University of Cambridge).
- (Paragios *et al.* 2002) Paragios, N., & Deriche, R. (2002). Geodesic active regions and level set methods for supervised texture segmentation. *International Journal of Computer Vision*, 46(3), 223-247.
- (Piccardi *et al.* 2004) Piccardi, M. (2004, October). Background subtraction techniques: a review. In *2004 IEEE International Conference on Systems, Man and Cybernetics* (IEEE Cat. No. 04CH37583) (Vol. 4, pp. 3099-3104). IEEE.
- (Rachman 2017) Rachman, A. A. (2017). *3D-LIDAR Multi Object Tracking for Autonomous Driving* (Doctoral dissertation, M. Sc. Thesis, Delft University of Technology).
- (Reuter 2014) Reuter, S. (2014). *Multi-object tracking using random finite sets* (Doctoral dissertation, Universität Ulm).
- (Ristic *et al.* 2011) Ristic, B., Vo, B. N., Clark, D., & Vo, B. T. (2011). A metric for performance evaluation of multi-target tracking algorithms. *IEEE Transactions on Signal Processing*, 59(7), 3452-3457.
- (Ristic *et al.* 2013) Ristic, B., Vo, B. T., Vo, B. N., & Farina, A. (2013). A tutorial on Bernoulli filters: theory, implementation and applications. *IEEE Transactions on Signal Processing*, 61(13), 3406-3430.

- (Rowley *et al.* 1998) Rowley, H. A., Baluja, S., & Kanade, T. (1998). Neural network-based face detection. *IEEE Transactions on pattern analysis and machine intelligence*, 20(1), 23-38.
- (Rothmann *et al.* 2007) Rothmann, S. A., & Reese, A. A. (2007). Semen analysis: the test techs love to hate. *MLO: medical laboratory observer*, 39(4), 18-20.
- (Schuhmacher *et al.* 2008) Schuhmacher, D., Vo, B. T., & Vo, B. N. (2008). A consistent metric for performance evaluation of multi-object filters. *IEEE transactions on signal processing*, 56(8), 3447-3457.
- (Sevenson *et al.* 2019) Sevenson, L.; Granstrom, K.; and Xia, Y., "Multi-Object Tracking for Automotive Systems", Course, see <https://www.edx.org/course/multi-object-tracking-for-automotive-systems>
- (Sherins *et al.* 1991) Sherins, R. J. (1991). Clinical use and misuse of automated semen analysis. *Annals of the New York Academy of Sciences*, 637, 424-435.
- (Shi 1994) Shi, J. (1994, June). Good features to track. In 1994 Proceedings of IEEE conference on computer vision and pattern recognition (pp. 593-600). IEEE.
- (Shi & Malik 2000) Shi, J., & Malik, J. (2000). Normalized cuts and image segmentation. *IEEE Transactions on pattern analysis and machine intelligence*, 22(8), 888-905.
- (Sidhu *et al.* 1998) Sidhu, R. S., Sharma, R. K., Lee, J. C., & Agarwal, A. (1998). Accuracy of computer-assisted semen analysis in prefreeze and post-thaw specimens with high and low sperm counts and motility. *Urology*, 51(2), 306-312.
- (Srivastav *et al.* 2017) Srivastav, N., Agrwal, S. L., Gupta, S. K., Srivastava, S. R., Chacko, B., & Sharma, H. (2017, January). Hybrid object detection using improved three frame differencing and background subtraction. In 2017 7th International Conference on Cloud Computing, Data Science & Engineering-Confluence (pp. 613-617). IEEE.
- (Stauffer *et al.* 2000) Stauffer, C., & Grimson, W. E. L. (2000). Learning patterns of activity using real-time tracking. *IEEE Transactions on pattern analysis and machine intelligence*, 22(8), 747-757.
- (Schleh *et al.* 2013) Schleh, C., & Leoni, A. L. (2013). How to optimize the benefits of computer assisted sperm analysis in experimental toxicology. *Journal of Occupational Medicine and Toxicology*, 8(1), 1-4.
- (Urbano 2014) Urbano, L. F. (2014). Robust automatic multi-sperm tracking in time-lapse images. Drexel University.
- (Urbano *et al.* 2016) Urbano, L. F., Masson, P., VerMilyea, M., & Kam, M. (2016). Automatic tracking and motility analysis of human sperm in time-lapse images. *IEEE transactions on medical imaging*, 36(3), 792-801.
- (Wang *et al.* 2011) Wang, Y., Jia, Y., Yuchi, M., & Ding, M. (2011, December). The computer-assisted sperm analysis (CASA) technique for sperm morphology evaluation. In 2011 International Conference on Intelligent Computation and Bio-Medical Instrumentation (pp. 279-282). IEEE.
- (WHO 2010) Edition, F. (2010). Examination and processing of human semen. *World Health [Internet]*.
- (Villines 2019) Villines, Z. What to know about sperm production <https://www.medicalnewstoday.com/articles/325906>
- (Xu *et al.* 2017) Xu, Z., Zhang, D., & Du, L. (2017, December). Moving Object Detection Based on Improved Three Frame Difference and Background Subtraction. In 2017

International Conference on Industrial Informatics-Computing Technology, Intelligent Technology, Industrial Information Integration (ICIICII) (pp. 79-82). IEEE.

(Yilmaz *et al.* 2006) Yilmaz, A., Javed, O., & Shah, M. (2006). Object tracking: A survey. *Acm computing surveys (CSUR)*, 38(4), 13es.

(Yang 2014) Yang, M. (2014, July). A moving objects detection algorithm in video sequence. In 2014 International Conference on Audio, Language and Image Processing (pp. 410-413). IEEE.

(Zhu *et al.* 1996) Zhu, S. C., & Yuille, A. (1996). Region competition: Unifying snakes, region growing, and Bayes/MDL for multiband image segmentation. *IEEE transactions on pattern analysis and machine intelligence*, 18(9), 884-900.



ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı:	İnas Alarabı
Doğum Tarihi:	17 Mayıs 1992
Doğum Yeri:	Halep/Suriye
Uyruğu:	Suriye, T.C
Adres:	Atatürk Üniversitesi Mühendislik Fakültesi
Tel:	05386484055
E-mail:	enas.alarabi16@ogr.atauni.edu.tr
Eğitim	
Lise:	Assad Akil Lisesi
Lisans:	Halep Üniversitesi, Informatic Engineering Fakültesi
Yüksek lisans:	Atatürk Üniversitesi, FEN Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı (2012)
Doktora:	Atatürk Üniversitesi
Yabancı Dil Bilgisi	
İngilizce:	İyi
Türkçe:	İyi
Üye Olunan Mesleki Kuruluşlar	
Tezden Üretilmiş Yayınlar	