

**ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

3B MODELLENMİŞ ORTAMDA KİŞİ TESPİTİ

Tahir BÜYÜKBAŞARAN

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**ANKARA
2021**

Her hakkı saklıdır

ÖZET

Yüksek Lisans Tezi

3B MODELLENMİŞ ORTAMDA KİŞİ TESPİTİ

Tahir BÜYÜKBAŞARAN

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Hakkı Gökhan İLK

Bu tez çalışmasında gerçeğe uyarlanabilecek bir senaryonun üç boyutlu (3B) animasyonu oluşturulmuştur. Bu animasyondaki hareketli kişilerin görüntüleri pozitif, ayrıca sonuç performansının etkisinin araştırılması için kişi içermeyen 3B sahneden negatif eğitim verileri hazırlanmıştır. Çalışmalarda sentetik olarak 1747 pozitif ve 1671 negatif ayrıca 6744 sentetik olmayan hazır negatif eğitim görüntüsü kullanılmıştır. Oluşturulan pozitif ve negatif eğitim verilerinin öznelikleri Yönlü Gradyent Histogramı (YGH), Ölçekten Bağımsız Öznelik Dönüşümü (ÖBÖD), Hızlandırılmış Gürbüz Öznelikler (HGÖ) ve Yerel İkili Örüntü (YİÖ) algoritmaları kullanılarak çıkarılmıştır. Öznelikler, sentetik negatif eklentiler varken ve yokken ayrı ayrı oluşturularak Destek Vektör Makinası (DVM) eğitiminde kullanılmış. Eğitim verilerinin % 30'u ile DVM öğrenme testi gerçekleştirilmiştir. Öznelik çıkarma algoritmaları ve eğitilmiş DVM ile 3B modellenmiş animasyon ve canlı ortamlarda analiz testleri gerçekleştirilmiştir.

Çalışmalar sonucunda YGH ve YİÖ algoritmaları yaklaşık % 46 doğruluk oranı ile en iyi değerleri alınmıştır. Bunun yanında algoritmaların toplamının doğruluk oranı ise % 62'dir. Algoritmalar içerisinde YİÖ en hızlı ve % 0,5 oran ile en az hata yapan algoritma olmuştur. Bu değerler sonucunda YİÖ en iyi performansı veren algoritma olarak değerlendirilmektedir. Elde edilen bu sonuç DVM test sonuçları ile de eşleşmektedir.

Yapılan çalışmalarda sentetik negatiflerin analize etkisi de araştırılmıştır. Sentetik negatifler varken algoritmaların tamamının hatalı bulma oranlarının azaldığı ve özellikle HGÖ algoritmasının iyileşme oranının % 38,33 olduğu gözlenmiştir.

3B ve gerçek ortam ilişkisi için F ve T testleri yapılmış olup yapılan çalışmalara göre YGH, HGÖ ve YİÖ algoritmalarının ortalamasının 3B modellenmiş ortamdan yüksek olabileceği, ÖBÖD algoritmasının ise düşük olacağı sonucu bulunmuş olup bütün algoritmaların standart sapma değerlerinin 3B modellenmiş ortamdan yüksek olacağı değerlendirilmiştir.

Ocak 2021, 107 sayfa

Anahtar Kelimeler: 3B Modelleme, Video Analitik, Yönlü Gradyent Histogramı, YGH, Ölçekten Bağımsız Öznelik Dönüşümü, ÖBÖD, Hızlandırılmış Gürbüz Öznelikler, HGÖ, Yerel İkili Örüntü, YİÖ, Destek Vektör Makinesi, DVM

ABSTRACT

Master Thesis

HUMAN CAPTURE ON 3D MODELLED ENVIRONMENT

Tahir BÜYÜKBAŞARAN

Ankara University
Graduate School of Natural and Applied Sciences
Department of Electric and Electrical Engineering

Supervisor: Prof. Dr. Hakkı Gökhan İLK

In this thesis, three-dimensional (3D) animation of a scenario that can be adapted to real world was created. Synthetic people and non-people images has been gathered from this scenario for positive and negative data. 1747 positive synthetic 1671 negative synthetic and 6744 ready non-pedestrian negative training images used in studies. Positive and negative training features were extracted using Histogram of Oriented Gradients (HOG), Scale Invariant Feature Transform (SIFT), Speeded Up Robust Features (SURF) and Local Binary Pattern (LBP) algorithms. Features extracted separately with/without synthetic negatives and used in Support Vector Machine (SVM) training. 30 % of training data was used for testing. The analysis has performed on real and 3D modelled environments The best accuracy were obtained from HOG and LBP algorithms with 46 % and the rate of total algorithms was 62%. LBP has been found the fastest and least error-prone algorithm with 0.5 %. LBP is considered as the best performance algorithm which matches with SVM test results. The effect of synthetic negatives has also been investigated. With synthetic negatives the rate of finding errors in all of the algorithms has decreased and best the improvement rate of the SIFT algorithm was 38.33 %. F and T tests were performed for relationship between 3D-real environment. With the tests the average of HOG, SURF,LBP algorithms may higher than 3D modeled environment, and SIFT algorithm will be low, it was evaluated that the standard deviation values of all algorithms would be higher than 3D modeled environment.

January 2021, 107 pages

Key Words: 3D Modelling, Video Analytic, Histogram of Oriented Gradients, HOG, Scale Invariant Feature Transform, SIFT, Speeded Up Robust Features, SURF, Local Binary Pattern, LBP, Support Vector Machine, SVM

TEŐEKKÖR

Tez alıőmamın Őekillenmesinde ve sonraki aőamalarında gōsterdiđi ilgi ve yol gōstericiliđi ile sonuca ulaőmamda ok bŧyŧk katkısı olan kıymetli danıőman hocam Prof. Dr. Hakkı Gōkhan İLK'e

Blender yazılımının kullanımı konusunda kendisinden aldıđım eđitim ile tez alıőmasının Őnemli bir aőamasını sayesinde gerekleőtirdiđim Berk DEMİR'e

Tez alıőmam konusunda bana verdikleri sonsuz destek ve anlayıő iin sevgili eőim ve ocuklarıma teőekkŧrŧ bor bilirim.

Tahir BŧYŧKBAŐARAN

ANKARA, Ocak 2021

İÇİNDEKİLER

TEZ ONAY SAYFASI

ETİK.....	i
ÖZET.....	ii
ABSTRACT.....	iii
TEŞEKKÜR	iv
KISALTMALAR DİZİNİ	vii
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ	ix
1. GİRİŞ.....	1
2. KURAMSAL TEMELLER.....	7
2.1 Sayısal Görüntü.....	7
2.2 3B Modelleme	8
2.3 Öznitelik Çıkarılması.....	9
2.3.1 Yönlü gradyent histogramı algoritması	10
2.3.2 Ölçekten bağımsız öznitelik dönüşümü algoritması	13
2.3.3 Hızlandırılmış gürbüz öznitelikler algoritması	17
2.3.4 Yerel ikili örüntü algoritması.....	21
2.4 Sınıflandırma	25
2.4.1 Yinelemeli Dikotomizör 3	25
2.4.2 C4.5.....	26
2.4.3 Bayes ağı.....	26
2.4.4 K-En yakın komşu	26
2.4.5 Destek vektör makinesi.....	27
2.5 Maksimum Olmayanın Bastırılması	33
2.6 Görüntü Piramiti.....	34
2.7 Arka Plan Çıkarma.....	36
2.8 Kontur Tespiti	38
2.9 Histogram Eşleme	38
2.10 Hipotez Testi.....	40
3. MATERYAL VE YÖNTEM	44

3.1 Çalışma Aşamaları	44
3.2 3B Modelleme	47
3.2.1 3B modellenecek ortamın ve senaryonun belirlenmesi	47
3.2.2 Ortamın 3B olarak modellenmesi.....	48
3.2.3 Kişilerin 3B olarak modellenmesi.....	50
3.2.4 3B modellenmiş kişilerin ortamda hareketlendirilmesi	54
3.2.5 Hareketlendirilmiş ortamın 3B derleme işleminin yapılması ve kişilerin konularının belirlenmesi.....	58
3.2.6 Eğitim için veri seti oluşturma	61
3.3 Öznitelik Çıkarma.....	65
3.3.1 YGH uygulaması gerçekleştirimi	66
3.3.2 ÖBÖD uygulaması gerçekleştirimi.....	67
3.3.3 HGÖ uygulaması gerçekleştirimi	69
3.3.4 YİÖ uygulaması gerçekleştirimi	71
3.4 DVM Eğitim.....	73
3.4.1 DVM eğitim ve test uygulaması	73
3.5 Video ile Test	76
4. ARAŞTIRMA BULGULARI	82
4.1 Doğru Bulunan Kişiler ve Sentetik Negatiflerin Etkisi	82
4.2 Yanlış Bulma ve Sentetik Negatiflerin Etkisi	84
4.3 Kişi Bulma Süreleri.....	86
4.4 3B Model ile Gerçek Ortamın Karşılaştırılması	88
5. SONUÇ	99
5.1 Öneriler	101
KAYNAKLAR	103
ÖZGEÇMİŞ.....	107

KISALTMALAR DİZİNİ

3B	Üç Boyutlu
2B	İki Boyutlu
3D	Three dimensional
DoG	Difference of Gaussians (Gauss'ların Farkı)
DVM	Destek Vektör Makinesi
GB	Gigabyte
GHz	Gigahertz
HGÖ	Hızlandırılmış Güçlü Öznitelikler
HOG	Histogram of Oriented Gradients
ID3	Yinelemeli Dikotomizör 3
GPL	General Public License (Genel Kamu Lisansı)
GNU	GNU's Not Unix (GNU Unix Değildir)
KNN	K-Nearest Neighbors (K- En Yakın Komşu)
LBP	Local Binary Pattern
LoG	Laplace of Gaussian (Gauss'un Laplace'ı)
MoG	Mixture of Gaussian (Gauss Fonksiyonlarının Karışımı)
NMS	Non Maximum Suppression (Maksimum Olmayanın Bastırılması)
ÖBÖD	Ölçekten Bağımsız Öznitelik Dönüşümü
RBF	Radial Basis Function
SIFT	Scale Invariant Feature Transform
SURF	Speeded Up Robust Features
SVM	Support Vector Machine
YGH	Yönlü Gradyent Histogramı
YİÖ	Yerel İkili Örüntü

ŞEKİLLER DİZİNİ

Şekil 2.1	Sayısal görüntü oluşturma süreci	8
Şekil 2.2	Gradyent yön bölgeleri	11
Şekil 2.3	Gradyentler ve gradyentlerin histogramı	12
Şekil 2.4	Farklı ölçeklerdeki gauss'ların farkı	13
Şekil 2.5	Pikselin kendi ölçeğinde ve diğer ölçeklerdeki komşu pikseller ile karşılaştırılması	14
Şekil 2.6	Birden fazla tepe değerli açı histogramı	16
Şekil 2.7	Görüntü gradyentlerinden anahtar nokta tanımlayıcılarının oluşturulması ...	17
Şekil 2.8	Yoğunluk değerinin bulunması	18
Şekil 2.9	Görüntüyü küçültmek yerine (sol), integral görüntü sayesinde filtre ölçeğinin büyütülmesi (sağ)	20
Şekil 2.10	YİÖ algoritması	21
Şekil 2.11	P örnek sayısı ve R simetrik dairesel yarıçap çeşitleri	22
Şekil 2.12	YİÖ örüntülerinin görüntü içindeki anlamları	24
Şekil 2.13	YİÖ ile histogramın elde edilmesi	24
Şekil 2.14	Destek vektörleri	27
Şekil 2.15	İki sınıflı veri setini ayıran farklı düzlemlere ilişkin örnek	29
Şekil 2.16	İki sınıflı problem için doğrusal ayırlamama durumu	30
Şekil 2.17	Örnek ikinci dereceden polinom çekirdek fonksiyonu DVM uygulaması	31
Şekil 2.18	Gauss çekirdek problemi	32
Şekil 2.19	Örnek hiperbolik tanjant fonksiyonu	33
Şekil 2.20	İki farklı yaklaşım	35
Şekil 2.21	Gauss piramiti	36
Şekil 2.22	Histogram eşleme	39
Şekil 3.1	Çalışma aşamaları	46
Şekil 3.2	Gerçek ortam halı saha ve kişiler	48
Şekil 3.3	Halı saha modeli	50
Şekil 3.4	Mixamo ile eklem tanımlama ekranı	52
Şekil 3.5	Mixamo ile hazırlanmış 3B hareketli model	53
Şekil 3.6	TeamCPlayer	53
Şekil 3.7	Sonuç ortam	56
Şekil 3.8	Birinci ortam kamera görüşü	57
Şekil 3.9	İkinci ortam kamera görüşü	58
Şekil 3.10	İşlem adımları	61
Şekil 3.11	Sentetik negatif veri setinin oluşturulduğu görüntüler	62
Şekil 3.12	Örnek sentetik negatifler	63
Şekil 3.13	Pozitif veri seti oluşturma işlem adımları	64
Şekil 3.14	Örnek pozitif veri seti	65
Şekil 3.15	YGH öznitelik çıkarma işlem adımları	67
Şekil 3.16	ÖBÖD öznitelik çıkarma işlem adımları	69
Şekil 3.17	HGÖ öznitelik çıkarma işlem adımları	71
Şekil 3.18	YİÖ öznitelik çıkarma işlem adımları	73
Şekil 3.19	Video test ortamları	78
Şekil 3.20	Örnek analiz görüntüsü	81

ÇİZELGELER DİZİNİ

Çizelge 3.1 Eğitim verisi için hazırlanan ortam bilgileri	55
Çizelge 3.2 DVM çekirdekleri ve test sonuçları	75
Çizelge 4.1 Sentetik negatifler yokken doğru bulunan kişiler çizelgesi	83
Çizelge 4.2 Sentetik negatifler varken doğru bulunan kişiler çizelgesi	83
Çizelge 4.3 Sentetik negatiflerin doğru bulmaya etkisi	84
Çizelge 4.4 Sentetik negatifler yokken yanlış bulma çizelgesi.....	85
Çizelge 4.5 Sentetik negatifler varken yanlış bulma çizelgesi.....	85
Çizelge 4.6 Sentetik negatifler varken yanlış bulmaya etkisi	86
Çizelge 4.7 Kişi bulma süreleri	87
Çizelge 4.8 Kişi bulma birim süreleri	87
Çizelge 4.9 3B video ile gerçek ortamların YGH T-testi karşılaştırması	90
Çizelge 4.10 3B video ile gerçek ortamların ÖBÖD T-testi karşılaştırması.....	91
Çizelge 4.11 3B video ile gerçek ortamların HGÖ T-testi karşılaştırması	92
Çizelge 4.12 3B video ile gerçek ortamların YİÖ T-testi karşılaştırması.....	93
Çizelge 4.13 3B video ile gerçek ortamların YGH F-testi karşılaştırması	95
Çizelge 4.14 3B video ile gerçek ortamların ÖBÖD F-testi karşılaştırması.....	96
Çizelge 4.15 3B video ile gerçek ortamların HGÖ F-testi karşılaştırması	97
Çizelge 4.16 3B video ile gerçek ortamların YİÖ F-testi karşılaştırması	98

1. GİRİŞ

Zaman içinde gelişen simülasyon sistemleri ve yazılımların kabiliyetleri gerçek dünyadaki pek çok senaryonun modellenmesinde ve istenen amaca uygun olarak oluşturulan verinin işlenerek tekrar gerçek dünyaya sunulmasında oldukça başarılıdırlar.

Artık simülasyonu yapılan ortamlar gerçek dünyadaki eşleniklerine çok yaklaştığı için buralarda yapılan faaliyetler ve elde edilen sonuçlar gerçek dünyada kullanılabilir.

Örneğin günümüzdeki sertifikalandırılmış bazı uçuş simülatörleri ile yapılan uçuşlar gerçek uçuş sayılarak pilotların uçuş saatine yazılmaktadır. Bunun yanında gerçek dünyada yapılması bir hayli zor, riskli ve maliyetli manevralar bu tip simülatör ortamlarında gerçekleştirilerek hem donanım hem de pilot risk almadan yüksek deneyim elde edilmektedir.

Bu tez çalışması da benzer motivasyon ile simülasyonu yapılan bir ortamın gerçek ortama uyarlanması üzerine kurgulanmıştır.

Gerçek dünya ortamında video izleme ve analiz faaliyetlerinin gerçekleştirilmesi için gerekli teçhizatın konumlandırılması ve bu teçhizattan alınan verilere göre analiz işlemlerinin yapılması tek seferlik işlem adımlarıdır. Bu tip ortamların oluşturulmasında kurulum yapan kişi ya da ekibin geçmiş deneyimi üzerine kurulum ve aktivasyon faaliyetleri gerçekleştirilmektedir.

Bir mekanda meydana gelmesi olası olayların tespit ve analizi üzerine video analitik sistemi konumlandırılması için gerçekleştirilen geleneksel işlem adımları;

- Saha gözlem
- Gerekli teçhizatın belirlenmesi
- Kameralar için gerekli altyapının (kamera, direk, elektrik, veri hatları) oluşturulması

- Sistem alıřtırılması (bu noktada kurulması hedeflenen sistem ilk defa alıřtırılır)
- Video analizi alıřmasına bařlanması
- Elde edilen verilere gre iyileřtirme faaliyetlerinin yapılması.
- Kurulmadan sonra ortaya ıkan ışıklandırma gibi ortam deęiřikliklerine gre sistemin uyumlanması faaliyetlerinin yapılması alıřmalarıdır.

Kurulması hedeflenen sistemden beklenti bir video analiz sistemi olarak bařlamasına karřın sistem ancak tamamen kurulduktan sonra gerek performansı ile karřılařılmakta ve iyileřtirme faaliyetleri ise sadece kısıtlı parametreler (kamera yn, yerden ykseklięi, ışık deęiřiklikleri vb.) deęiřtirilerek iyileřtirme yapılmaya alıřılmakta, ayrıca ortamdaki alınan veriler ile eęitim sreci uzun olmaktadır.

Fiziksel ortamı hazırlama maliyeti ve elde edilecek sonucun bilinmezlięini ortadan kaldırmak iin

- Analiz alıřması yapılacak ortama benzer 3B sanal ortam oluřturulabilir.
- Bu ortamda beklenen senaryoya uygun bir animasyon oynatılabilir
- İstenilen her noktaya maliyet olmaksızın sanal iki boyutlu (2B) grnt alan kamera(lar) yerleřtirilebilir
- Oynatılan animasyonun bu kameralar aısından animasyon videoları oluřturulabilir
- Bu videolardan analitik alıřmaları iin gerekli veriler toplanabilir ve video analizi alıřması bařlatılabilir.
- Test iin istenilen her trl animasyon senaryosu ve sanal video kameralar kullanılarak video analizi yapılabilir
- Bu sayede gerek ortam henz kurulmadan daha kontroll bir ortamda gerek ortam kurulduęunda nasıl bir sonu elde edileceęine dair kestirim yapılabilir.

Gerek bir sahnenin 3B olarak modellenmesi ve buradan elde edilen sentetik eęitim verilerinin kullanılması konusunda daha nce yapılmıř alıřmalar bulunmaktadır. Bunlardan biri olan Hattori, Bodetti, Kitani ve Kanade'nin hazırlayarak sunduęu 3B ortam yaratılarak elde edilen sentetik veriler ile genel eęitim setleri kullanılarak yapılan

analitik çalışmalarının karşılaştırıldığı çalışma bu tezin motivasyonunu destekleyen örnek bir çalışmadır. Yapılan çalışmada gerçek ortamdan verileri toplamak için beklemek yerine verilerin sentetik olarak ortama özel, çeşitliliği yüksek ve daha kolay bir yöntem önerilmiştir. (Hattori vd. 2015).

Vazquez, Lopez, Marin ve Ponsa'nın çalışmasında ise yaya tespiti için sanal ortamda oluşturulmuş verilerin faydası üzerine bir çalışma yapmıştır (Vazquez vd. 2014). Bu çalışmada akıllı araç uygulamalarında kullanılan hazır veri setlerinde kişilerin genelde kamera odağında olduğundan ve bu setlerde arka planların bir şehir görüntüsü ile ilgili bilgi içermediğinden bahsedilmiştir. Bu nedenle bu veriler ile yapılacak eğitimler şehir içi akıllı araç uygulamalarında faydalı olamayacağını düşünmüştür.

(Pishculin vd. 2011) benzer şekilde hazır eğitim verilerinin zahmetli hazırlanma sürecinden ve yeterliliğinin eleştirisine karşılık 3B modellemenin bir avantajı olarak az sayıda sentetik model ile nerede ise sayısız kaliteli eğitim verisi oluşturabileceğini savunmuştur (Pishculin vd. 2011).

Bu tez çalışmasında da gerçek ortam senaryosuna uygun bir 3B ortam modellemesi ve bu ortamda doğal insan hareketlerine çok yakın hareketli insan grubu animasyonu oluşturulmuştur. Bu sayede ortam, sanal olarak yaratılmış ve hareketlendirilmiş sanal kişiler ve video analizi konusu ile ilgili bileşenler kontrollü birer değişken olarak tanımlanabilmiştir.

Bu tez çalışmasında hedeflenen; gerçek 3B dünya ortamından elde edilen görüntüler (2B CCD kamera görüntüsü) yerine sanallaştırılmış 3B dünyada gerçekleştirilen kontrollü simülasyonlar ve bu simülasyonlardan elde edilen sanal 2B kamera görüntüleri ile kişi tespiti başta olmak üzere pek çok video analitik çalışmasını zaman ve maliyet açılarından etkin şekilde oluşturmak ve aradaki farklılıkların ortaya koymaktır.

Tez çalışmasının ana konularından biri olan 3B ortam modellenmesi ve bu ortamda kişilerin oluşturulması ve oluşturulan animasyonun video görüntülerinin alınması için Blender yazılımı kullanılmıştır. Blender yazılımı 3B modelleme ve animasyonu ile ilgili

geniş hazır özelliklere sahip açık kaynak kodlu bir yazılımdır. Bunun yanında Blender hazır özelliklerin yetmediği durumda python programlama arayüzü ile ihtiyaca uygun çalışmanın gerçekleştirebileceği esnek bir altyapı sunmaktadır.

3B kişi modeli hazırlanması için MakeHuman yazılımı ve hazırlanan modelin hareketlendirilmesi için ise çevrimiçi bir uygulama olan Mixamo kullanılmıştır.

Hazırlanan animasyonda grup halinde hareket eden kişiler istenilen kamera görüşünde izlenebilmektedir.

Çalışmanın diğer aşaması olan eğitim için pozitif ve negatif sentetik verilerin elde edilmesinde hareket halindeki kişilerin konum bilgileri 3B ortama göre kayıt altına alınmış ve derlenmiş (render) görüntülerden kişiler bu konum bilgilerine göre çıkarılarak elde edilmiştir.

3B modellenmiş ortamdan içinde kişi olmayan görüntüler de alınarak bu görüntülerin video analizi üzerindeki etkisi de araştırılmıştır.

Video analizi çalışmaları esnasında elde edilen sentetik görüntülerin yanında hazır eğitim setinden de faydalanılmıştır.

Çalışma esnasında toplam 1747 adet sentetik içinde kişi bulunan. Bununla beraber 6744 adet hazır ve 1671 adet sentetik içinde kişi olmayan görüntü seti kullanılmıştır.

Modelleme çalışmasından elde edilen sentetik veriler kullanılarak dört farklı öznitelik çıkarma algoritması olan Yönlü Gradyent Histogramı (YGH) , Ölçekten Bağımsız Öznitelik Dönüşümü (ÖBÖD), Hızlandırılmış Gürbüz Öznitelikler (HGÖ) ve Yerel İkili Örüntü (YİÖ) algoritmaları ile yapılan eğitim ve video analizi performansları karşılaştırmalı olarak aynı video çerçevesi üzerinde değerlendirilmesi ile iyileştirme önerileri ortaya konulabilmiştir.

Çalışmanın son aşaması olarak 3B olarak modellenmiş ortamdaki video analizi verilerinin gerçek ortam için bir fikir verip vermeyeceği konusu üzerinde durulmuş olup bunun için istatistiki karşılaştırma yöntemlerine başvurulmuştur.

Tez çalışmasının Bölüm 2’de kullanılan tekniklerin teorik açıklamaları yer almaktadır. Sayısal görüntü, 3B modelleme ve öznitelik çıkarılması konularının tanımlamaları ilk olarak yapılmış olup YGH, ÖBÖD, HGÖ ve YİÖ öznitelik çıkarma algoritmaları sonraki alt bölümlerde anlatılmıştır. Bölüm 2.4’de ilk olarak sınıflandırma ile ilgili temel bilgiler verilmiş olup tezde kullanılan Destek Vektör Makinesi (DVM) üzerinde durulmuştur.

Tez çalışmasında ön görüntü işleme ve çalışmayı destekleyici konular olan maksimum olmayanın bastırılması (NMS), görüntü piramiti, arka plan çıkarma, kontur tespiti ve histogram eşleme konularına yine kuramsal temeller bölümü altında değinilmiştir.

Bölüm 2.10’da ise 3B modellenmiş ortamda yapılan analiz ile gerçek ortamlar arasındaki öngörüm ilişkisini araştırmak için destekleyici istatistiki bilgiyi sunacak olan hipotez testi ve hipotez testi konularından olan T-testi ve F-testi’nden bahsedilmiştir.

Bölüm 3’de gerçekleştirilen çalışmalar işlem sırasına göre aktarılmıştır.

Bölüm 3.1’de yapılan çalışmaların işlem adımları blok diyagram ile beraber sunulmuştur.

Bölüm 3.2’de 3B modelleme ile ilgili ortamın ve senaryonun belirlenmesi, ortamın modellenmesi, kişilerin 3B olarak modellenmesi, 3B modellenmiş kişilerin ortamda hareketlendirilmesi, hareketlendirilmiş ortamın 3B derleme işleminin yapılması ve karakterlerin konumlarının belirlenmesi konularından bahsedilmiş olup yine 3B modelleme başlığı altında yer alan Bölüm 3.2.6 eğitim için veri seti oluşturma alt bölümünde konum bilgileri ile beraber derlenmiş görüntülerin içinden kişilerin eğitim veri görüntüsü olarak kullanılmak üzere nasıl alındığı ve ayrıca negatif sentetik eğitim veri görüntülerinin nasıl hazırlandığı ile ilgili çalışmalar anlatılmıştır.

Bölüm 3.3’de eldeki eğitim veri görüntülerinin kullanılarak YGH, ÖBÖD, HGÖ ve YİÖ öznitelik çıkarma algoritmaları ile yapılan öznitelik çıkarımı uygulamaları gerçekleştirimleri anlatılmıştır.

Bölüm 3.4’de DVM eğitim ve uygulaması anlatılmış olup eğitim testi sonuçları bir tabloda gösterilmiştir.

Bölüm 3.5’de 3B olarak hazırlanmış animasyon ve gerçek ortam videoları üzerinde bütün algoritmaların aynı görüntü çerçevesinde analiz yapabildiği ortamın nasıl hazırlandığı, video analizi işlem adımları ve analiz sonuçlarının nasıl elde edildiğinin detayları anlatılmıştır.

Bölüm 4’de toplanan analiz verilerine göre YGH, ÖBÖD, HGÖ, YİÖ algoritmaları ve bu algoritmaların toplamının doğru bulma ve yanlış bulma analiz performansları sentetik negatifler varken ve yokken karşılaştırmalı olarak değerlendirilmiş olup Bölüm 4.3 kişi bulma süreleri alt bölümünde video analizi çalışmasında harcanan süreler karşılaştırmalı olarak değerlendirilmiştir.

Bölüm 4.4’de 3B animasyon ve gerçek ortamda yapılan video analizi performansları hipotez testi yardımı ile karşılaştırmalı olarak değerlendirilmiş ve 3B ortamdan elde edilen video analizi sonuçlarına bakılarak gerçek ortam sonuçları hakkında öngörü yapıp yapılamayacağına bakılmıştır.

Bölüm 5 sonuç bölümünde elde edilen sonuçlar değerlendirilmekte olup Bölüm 5.1’de yapılan çalışmanın sonuçlarına göre önerilerinden bahsedilmiştir.

2. KURAMSAL TEMELLER

3B modellenmiş bir ortamdan elde edilen verilerin gerçek ortamda kullanılması için sanal animasyon ortamın hazırlanması, sentetik eğitim verilerinin oluşturulması ve YGH, ÖBÖD, HGÖ ve YİÖ algoritmaları ile analitik çalışma sonuçlarının değerlendirilmesine kadar oluşturulan süreçte kullanılan bileşenler ve bu bileşenleri ne amaçlı kullanıldığına dair bilgiler bu başlık altında toplanmıştır.

2.1 Sayısal Görüntü


İki boyutlu bir görüntünün en küçük elemanına piksel adı verilir (Graf 1999).

Bu görüntüyü oluşturan elemanların sonlu sayıda sayısal değer ile oluşturduğu değerler kümesine ise sayısal görüntü adı verilir (Gonzalez ve Woods 2008).

Şekil 2.1’de gerçek dünya ortamından bir sayısal görüntü oluşturulma süreci gösterilmiştir.

Bir aydınlatma kaynağı ile görüntüden yansıyan ışınlar görüntüleme sisteminden geçer ve bu ışınlar bir dahili görüntü düzlemini oluşturan sensör grubuna gelir. Sensör grubu üzerine düşen ışınlar göre elektronik sinyal üretir ve bu sinyaller işlenerek sayısal görüntü oluşturulur.

Sayısal hale getirilen görüntü gerçek görüntünün iki boyutlu (2B) iz düşümü, yakınsamasıdır.



Şekil 2.1 Sayısal görüntü oluşturma süreci (Gonzalez ve Woods 2008)

2.2 3B Modelleme

3B Modelleme, gerçek dünyadaki üç boyutlu bir nesnenin bir yazılım kullanılarak matematiksel olarak temsilinin oluşturulmasıdır. Bu temsilin oluşturulması faaliyeti modellemedir. Modelleme üç boyutlu ortamda olduğu için yapılan işleme de 3B modelleme denir.

3B modelleme için gerçek bir model olmasına gerek de duyulmayabilir. Soyut 3B modelleme de yapılabilir.

3B modelleme eğlence sektöründe geniş bir alanda kullanıldığı gibi, mimari, inşaat, bilim ve tıp alanlarında da kullanımı vardır (Anonymous 2020).

İlk 3B grafik çalışmaları 1960'lı yılların sonunda Ivan Sutherland tarafından yazılan Sketchpad yazılımı ile başlamıştır.

Tez çalışması esnasında 3B modelleme aracı olarak açık kaynak kodlu bir yazılım olan Blender (<https://www.blender.org/>) yazılımı kullanılmıştır. Blender yazılımı açık

kaynak kodlu olması, 3B modelleme ve animasyon yapılabilmesi ve Python programlama dili ile programlanabilmesi nedenleri ile tercih edilmiştir.

Blender yazılımının tez çalışmasındaki katma değerlerinden birisi de doğal insan hareketine çok yakın modellemeye olanak tanınması ve bütün hareketlerin her aşamasında video analizi için gerekli olan veri setinin hazırlanması için program yazmaya müsait bir arayüz sunmasıdır.

Blender, 1988 yılında kurulan NeoGeo olarak başlayan 1998 yılında NaN (Not a Number) olarak devam eden kapalı kaynak kodlu ve ücretli bir yazılım olarak başlamıştır. NaN firmasının 2002 yılında iflas etmesi nedeni ile firma belli bir tutar karşılığında yazılımın kaynak kodlarını açabileceğini açıklamış aynı yıl kurulan Blender vakfının başlattığı bağış kampanyası ile de bu kampanyadan elde edilen gelir ile Blender yazılımını GNU Genel Kamu Lisansı (GPL) ile özgürleştirilerek kamuya açılmış ve yaygın olarak kullanılan 3B modelleme ve tasarım araçlarından biri haline gelmiştir (Blender 2020).

2.3 Öznitelik Çıkarılması

Bir nesnenin, kelimenin veya elyazısı karakterlerinin tanınmasının yani örüntü tanımının arkasında birbiri ile ilişkili farklı süreçler bulunmaktadır (Duda vd. 2000).

Bu süreçleri tanımlamak üzere farklı tipte nesnelere tanıma problemini ele alalım.

Öznitelik çıkarılması, bu nesnelere bir kamera ile kaydı alındıktan sonra bu nesnelere birbiri arasındaki farklılıkların “nasıl” anlaşılacağı sorusunun yanıtını vermek üzere oluşturulmuş algoritmalar (Duda vd. 2000).

Nesneler arasındaki farklılıklar gözle kontrol edilirken bizler doğal olarak nesnelere arasındaki farklılıkları yani öznitelikleri yakalayabiliriz.

Benzer şekilde makineler de bu yeteneğe sahip olmak için bir örüntü tanımaya ihtiyaç duyarlar (Duda vd. 2000).

Bir görüntü içeriğinde aranan örüntü ile bağıntılı ve ölçülebilir bilgi parçasına öznitelik denir.

Eğer nesneye ait öznitelikler ortaya çıkarılırsa ve makinada yeteri kadar öznitelik değeri var ise kendisinden algılanması istenen nesneyi algılayabilir.

Bir nesnenin özniteliklerinin ortaya çıkarılmasının en büyük katma değeri, bu nesnenin tespiti esnasında nesneye ait özellikleri ararken gerek duyulan işlem yükünü büyük oranda azaltmasıdır.

Tez çalışması esnasında öznitelik çıkarma algoritmalarından YGH, ÖBÖD, HGÖ, YİÖ kullanılmıştır.

2.3.1 Yönlü gradyent histogramı algoritması

Bir görüntünün seçilen yerel bölümlerindeki gradyent yönelimlerine bakarak öznitelik çıkarma yöntemi olan bu algoritmanın kullanımı YGH terimini kullanmadan ilk defa Robert K. McConnell tarafından tanımlansa da ilk defa Shashua ve Dalal tarafından 2005 yılında önerilmiştir. Bu algoritma bir görüntüyü yerel histogramların bir dizisi olarak tanımlamaktadır. Bu yerel histogramların her biri, görüntü üzerinde hücre olarak tanımlanan bir alanın hesaplanmasıyla bulunan gradyentlerin, tanımlanmış yönlerde ne kadar oluştuğunun bir dağılımıdır (Acar ve Özerdem 2016).

YGH algoritmasından öznitelik çıkarma işlemi üç safhada gerçekleşir.

- Gradyent hesaplama

Bu safhada görüntünün üzerinde bulunan yatay ve dikey gradyent değerleri hesaplanır.

Görüntü üzerindeki (x, y) koordinatındaki noktanın $f_x(x, y)$ ve $f_y(x, y)$ yatay ve dikey gradyent değerleri olacak halde bu değerlerin hesaplamaları eşitlik (2.1) ve eşitlik (2.2)'de tanımlandığı gibidir. Bu eşitliklerde bulunan $I(x, y)$ ilgili koordinattaki parlaklığı göstermektedir (Acar ve Özerdem 2016).

$$f_x(x, y) = I(x + 1, y) - I(x - 1, y) \quad (2.1)$$

$$f_y(x, y) = I(x, y + 1) - I(x, y - 1) \quad (2.2)$$

Elde edilen gradyent değerlerinden sonra o koordinattaki gradyentinin büyüklük değeri $m(x, y)$ eşitlik (2.3) ile ve yönü $\theta(x, y)$ ise eşitlik (2.4) ile hesaplanır (Acar ve Özerdem 2016).

$$m(x, y) = \sqrt{f_x(x, y)^2 + f_y(x, y)^2} \quad (2.3)$$


$$\theta(x, y) = \arctan \frac{f_x(x, y)}{f_y(x, y)} \quad (2.4)$$

- Histogramların oluşturulması


Bu safhada seçilen yönler eşit aralıklara bölünerek bu yön aralıklarındaki büyüklük değerlerine göre histogramlar oluşturulur.

Bu işlem sırasında ilgilenilen hücre içerisindeki pikselin gradyent büyüklük değeri hangi açı aralığında ise ilgili histogram bölgelerine dağıtım yapılır (Acar ve Özerdem 2016).

Şekil 2.2’de 0-180 derece arasında 20 derecelik aralık ile belirlenmiş toplam dokuz gradyent yön bölgesi gösterilmektedir. Şekil 2.3’de ise hücre içerisindeki gradyentlerin içinde bulunduğu yön bölgesine göre oluşturulmuş histogramlar gösterilmektedir.



Şekil 2.2 Gradyent yön bölgeleri (Acar ve Özerdem 2016)



Şekil 2.3 Gradyentler ve gradyentlerin histogramı

- Blok normalizasyonu

Bu safhada bir blok içerisindeki tüm histogramların birleştirilmesiyle oluşturulan büyük bir histogram elde edilir. YGH algoritmasında blok normalizasyonu için dört farklı yöntem geliştirilmiştir.

v normalize edilmemiş tanımlayıcı vektör, $k = 1, 2$ için v vektörünün k -normu $\|v\|_k$ ve ϵ küçük değerli bir sabit olmak üzere blok normalizasyon tipleri (2.5), (2.6), (2.7), (2.8) eşitliklerinde gösterilmiştir (Dalal ve Triggs 2005).

$$\text{Birinci yöntem L1-norm: } v \rightarrow v / (\|v\|_1 + \epsilon) \quad (2.5)$$

$$\text{İkinci yöntem L2-norm: } v \rightarrow v / \left(\sqrt{\|v\|_2^2 + \epsilon^2} \right) \quad (2.6)$$

$$\text{Üçüncü yöntem L1-karekök: } v \rightarrow \sqrt{v / (\|v\|_1 + \epsilon)} \quad (2.7)$$

$$\text{Dördüncü yöntem L2-Hys: L2-norm'un kırılması (} v \text{ nin maksimum değerinin 0,2 ye sınırlandırılması) ve yeniden normalize edilmesi} \quad (2.8)$$

Daha sonra görüntü bloklara, her blok hücelere bölünür. Yerel histogramların oluşturulmasıyla çalışma tamamlanır.

Tez çalışmasında bir hücrede piksel sayısı (8,8) ve bir blokta (2,2) hücre olacak halde yerel histogram oluşturulmuştur.


2.3.2 Ölçekten bağımsız öznitelik dönüşümü algoritması

ÖBÖD algoritması görüntünün döndürülmesine ve ölçek değişikliğine karşı dayanıklı bir algoritma olarak 2004 yılında David G. ve Lowe tarafından ortaya konmuştur (Lowe 2004).

ÖBÖD öznitelik çıkarılması dört farklı safhada gerçekleştirilmektedir.

- Ölçek uzayı uç noktalarının tespiti

Bu safhada potansiyel anahtar noktaların tespiti yapılır. görüntü öncelikle farklı ölçeklerde iken Gauss filtreden geçirilir ve bu filtrelerin farkı alınır. Bu işlem Gauss'ların farkı (DoG) olarak adlandırılır (Lowe 2004). Yapılan işlem şekil 2.4'de gösterilmiştir.



Şekil 2.4 Farklı ölçeklerdeki gauss'ların farkı (Lowe 2004)

(x, y) yatay ve dikey koordinatlarındaki bir nokta olmak üzere σ sapma değeri ile $G(x, y, \sigma)$ Gauss fonksiyonunun $I(x, y)$ giriş görüntüsü ile konvolüsyonundan üretilen bir görüntünün ölçek uzayında Gauss'un Laplace'ı (LoG) fonksiyonu $L(x, y, \sigma)$ elde edilir. k katsayısı kullanılarak oluşturulan farklı ölçeklerdeki LoG değerlerinin farkı ise $D(x, y, \sigma)$ Gauss'ların farkıdır. Bu tanımlamaya göre $L(x, y, \sigma)$, $G(x, y, \sigma)$, $D(x, y, \sigma)$ eşitlik (2.9), (2.10) ve (2.11)' de gösterilmiştir (Budak ve Şengür 2015).


$$L(x, y, \sigma) = G(x, y, \sigma) * I(x, y) \quad (2.9)$$

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-(x^2+y^2)/2\sigma^2} \quad (2.10)$$

$$\begin{aligned} D(x, y, \sigma) &= (G(x, y, k\sigma) - D(x, y, \sigma)) * I(x, y) \\ &= L(x, y, k\sigma) - L(x, y, \sigma) \end{aligned} \quad (2.11)$$

DoG değerleri bulunduktan sonra yerel uç nokta değerleri araştırılır. Bu değer araştırılırken incelenen pikselin kendi ölçeğindeki komşu sekiz pikseline bakıldığı gibi bakılan ölçeğin bir önceki ve bir sonraki dokuzar komşu pikseline de bakılır. Eğer bakılan piksel bir yerel uç nokta ise bu piksel bir aday anahtar noktadır (Lowe 2004).

Yapılan işlem şekil 2.5'de gösterilmiştir.



Şekil 2.5 Pikselin kendi ölçeğinde ve diğer ölçeklerdeki komşu pikseller ile karşılaştırılması (Lowe 2004)

- Anahtar nokta yerelleştirilmesi

Bu safhada potansiyel anahtar noktalarından bazılarının elenerek gerçek anahtar noktaların tespiti yapılmaktadır. Bu işlem temel olarak düşük kontrasta sahip olan veya kenar noktalarda zayıf olarak tespit edilmiş anahtar noktaların elenmesi işlemidir (Lowe 2004).

Eleme işleminde yerel uç noktalarına ikinci dereceden Taylor serisi açılımı yardımı ile tekrar bakılır. Eğer bulunan uç nokta bir sınır değerinden küçük ise bu değer elenir. Bu sınır değeri (Lowe 2004)'e göre 0,03 olarak belirlenmiştir. Eşitlik (2.12)'de x, y, σ noktanın yatay, dikey ve ölçek değerleri $\mathbf{x} = (x, y, \sigma)^T$ olmak üzere \hat{x} aday yerel uç nokta konumları hesaplanır. Daha sonra eşitlik (2.13)'de ifade edildiği üzere \hat{x} aday noktası üzerinden ikinci dereceden Taylor serisi açılımı yapılır, sonraki aşamada $|D(\hat{x})| < 0,03$ ise bu nokta elenir (Lowe 2004) (Özgen ve Sarıtaş 2008).

$$\hat{x} = - \frac{\partial^2 D^{-1} \partial D}{\partial x^2} \frac{\partial D}{\partial x} \quad (2.12)$$

$$D(\hat{x}) = D + \frac{1}{2} \frac{\partial D^T}{\partial x} \hat{x} \quad (2.13)$$

- Yönelim ataması

Bu safhada tespit edilmiş olan anahtar nokta ve komşu pikselleri için gradyent büyüklüğü ve yönü hesaplanır ve bu değerler kullanılarak dögüsel bir histogram oluşturulur.

$I(x, y)$ giriş görüntüsünün σ ölçeğindeki Gauss filtresinden geçirilmiş olan giriş $L(x, y, \sigma) = G(x, y, \sigma) * I(x, y)$ için gradyent büyüklüğü $m(x, y)$ ve açısı $\theta(x, y)$ hesaplanması eşitlik-(2.15) ve eşitlik-(2.16)'de belirtilmiştir (Lowe 2004).

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-(x^2+y^2)/2\sigma^2} \quad (2.14)$$


$$m(x, y) = \sqrt{(L(x + 1, y) - L(x - 1, y))^2 + (L(x, y + 1) - L(x, y - 1))^2} \quad (2.15)$$

$$\theta(x, y) = \tan^{-1} \left(\frac{L(x, y+1) - L(x, y-1)}{L(x+1, y) - L(x-1, y)} \right) \quad (2.16)$$

Büyüklik ve yön hesaplamaları anahtar noktaların bütün komşu noktaları için yapılır.

Yön ve büyüklik hesaplamasından sonra bu değerler kullanılarak 10 derecelik dilimler ile 36 bölgesi olan histogram içine yerleştirilir. Dahil olduğu yön bölgesine yerleştirilen her nokta grandyan büyüklüğü değeri ile ağırlıklandırılır (Özgen ve Sarıtaş 2008).

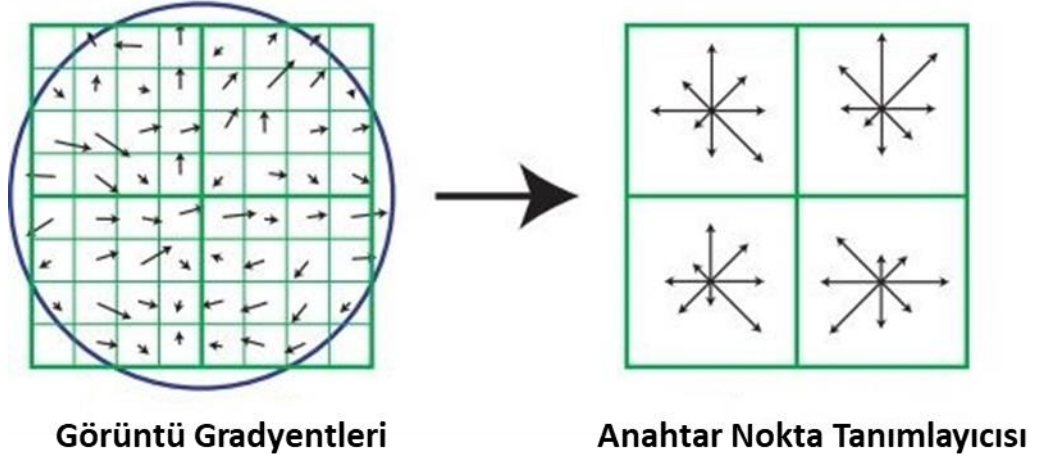
Bu duruma göre anahtar nokta; histogram içerisindeki % 80 ve üstü değerlerin elde edildiği noktalar olarak değerlendirir (Lowe 2004). Şekil 2.6'da birden fazla tepe değerli açı histogramı gösterilmiştir.



Şekil 2.6 Birden fazla tepe değerli açı histogramı (Demirel 2009)

- Anahtar Nokta Tanımlayıcılarının Oluşturulması:

Şekil 2.7'de gösterildiği üzere, anahtar noktanın etrafındaki alan içindeki kalan gradyent büyüklük ve açı değerleri kullanılarak anahtar nokta tanımlayıcıları oluşturulur (Lowe 2004).



Şekil 2.7 Görüntü gradyentlerinden anahtar nokta tanımlayıcılarının oluşturulması (Lowe 2004)

2.3.3 Hızlandırılmış gürbüz öznitelikler algoritması

HGÖ Algoritması ÖBÖD algoritmasının nesnenin dönmesinden etkilenmeyen ve ölçekten bağımsız olma özelliklerine sahip ancak aynı zamanda daha hızlı çalışmaya odaklı öznitelik çıkarımı algoritmasıdır (Bay vd. 2008) (Demirel 2019).

HGÖ algoritmasında özniteliklerin çıkarılması safhaları aşağıda açıklanmıştır.

- Özniteliklerin çıkarılması

Bu safhada anahtar noktalarının daha hızlı ve daha yüksek doğruluklu olarak belirlenmesi için Hessian Matrisi kullanılmıştır (Bay vd. 2008).


HGÖ algoritmasında integral görüntü kullanılmıştır.

İntegral görüntü yaklaşımı, verilen bir görüntünün toplam piksel değerlerinin hızlıca hesaplanması için etkili bir metottür.

Eşitlik (2.17)'ye göre giriş görüntüsü I 'nin (x, y) konumunda bulunan noktası için, bu konum ve onun merkezinde olduğu dikdörtgen bölgenin piksel değerlerinin toplamı $I_{\Sigma}(\mathbf{x})$ integral görüntüsü olarak gösterilmiştir (Bay vd. 2008).

$$I_{\Sigma}(\mathbf{x}) = \sum_{i=0}^{i \leq x} \sum_{j=0}^{j \leq y} I(i, j) \quad (2.17)$$

İntegral görüntü bir kere hesaplandıktan sonra sadece üç hesaplama ve dört hafıza erişimi ile ilgilenilen alanın büyüklüğünden bağımsız olacak halde dikdörtgen bir alanın içindeki yoğunluk değerine ulaşılır (Bay vd. 2008).



Şekil 2.8 Yoğunluk değerinin bulunması (Bay vd. 2008)

Fast-Hessian algılayıcısı:

HGÖ algoritmasında anahtar noktasını yakalamak için Fast-Hessian algılayıcısı kullanılmaktadır. Hessian matrisi Bay'e göre hesaplama hızı açısından daha iyi performans ve daha yüksek doğruluk sunmaktadır. Hessian matrisi determinanti kullanılarak hem konum hem de ölçek tek metotta ifade edilebilmektedir (Bay vd. 2006) (Karakuş ve Karabörk 2014).

$I = (x, y)$ konumundaki görüntü noktası için Hessian matrisi $H(I(x, y))$ eşitlik-(2.18)'de tanımlanmıştır (Karakuş ve Karabörk 2014).

HGÖ algoritmasında Hessian matrisinin determinanti, görüntünün ikinci dereceden türevi yardımı ile görüntüdeki maksimum ve minimum noktaları araştırılır. Hessian matrisi determinanti $\det(H(I(x, y)))$ $I = (x, y)$ için eşitlik-(2.19)'de tanımlandığı gibidir (Karakuş ve Karabörk 2014).

$$H(I(x, y)) = \begin{bmatrix} \frac{\partial^2 I}{\partial x^2} & \frac{\partial^2 I}{\partial y \partial x} \\ \frac{\partial^2 I}{\partial x \partial y} & \frac{\partial^2 I}{\partial x y^2} \end{bmatrix} \quad (2.18)$$

$$\det(H(I(x, y))) = \frac{\partial^2 I}{\partial x^2} \frac{\partial^2 I}{\partial y^2} - \left(\frac{\partial^2 I}{\partial x \partial y} \right)^2 \quad (2.19)$$

LoG yöntemi ile görüntünün 2. Dereceden türevi alınarak belirlenen ölçek için ilgi noktaları elde edilir (Karakuş ve Karabörk 2014).

Eşitlik (2.18) ve (2.19)'un Bay'in çalışmasına göre ifade edilmesine bakılacak olursa.

I görüntüsünün σ ölçeğindeki $P(x, y)$ noktası için Hessian matrisi eşitlik (2.20)'de tanımlanmıştır. Bu eşitlikte $L_{xx}(P, \sigma)$, $L_{xy}(P, \sigma)$ ve $L_{yy}(P, \sigma)$, ayrı ayrı I görüntüsündeki P noktasının ikinci dereceden Gauss türevi $\frac{\partial^2}{\partial x^2} g(\sigma)$ ile konvolüsyonudur. Bu türevler LoG olarak da bilinmektedir (Bay vd. 2008) (Karakuş ve Karabörk 2014).


$$H(P, \sigma) = \begin{bmatrix} L_{xx}(P, \sigma) & L_{xy}(P, \sigma) \\ L_{xy}(P, \sigma) & L_{yy}(P, \sigma) \end{bmatrix} \quad (2.20)$$

Eşitlik (2.21)'de yaklaşık Gauss lar kullanılarak Hessian determinatının elde edilmesi gösterilmiştir. Eşitlik (2.21)'e göre w ağırlık katsayısı ve LoG ile elde edilen x, y, xy yönlerindeki ikinci derece Gauss kısmi türevlerinin kutu filtre yaklaşımları D_{xx} , D_{yy} , D_{xy} olarak gösterilmiştir (Bay vd. 2008).

$$\det(H_{yaklaşık}) = D_{xx}D_{yy} - (wD_{xy})^2 \quad (2.21)$$

Ölçek uzayı gösterimi:

İntegral görüntüler ile beraber kutu filtre uygulaması tekrar eden filtre uygulamalarına ihtiyaç duymadığı için görüntünün farklı boyutlara getirilerek yeniden işlenmesine ihtiyaç duyulmamaktadır (Demirel 2019). Bu sayede HGÖ algoritması çalışmasında işlem maliyeti daha az olmaktadır.



Şekil 2.9 Görüntüyü küçültmek yerine (sol), integral görüntü sayesinde filtre ölçeğinin büyütülmesi (sağ) (Bay vd. 2008)

İlgi noktası yerelleştirilmesi:

İlgi noktası yerelleştirilmesi işlemi üç safhadan oluşmaktadır.

İlk safhada önce belirlenen eşik değerinin altında kalan değerler elenir (Karakuş ve Karabörk 2014).

İkinci safhada 3x3x3 komşuluğunda maksimum olmayan noktalar elenir. Eleme işlemi sonucunda aday ilgi noktaları elde edilir. İncelenen nokta merkezde olmak üzere kendi ölçeğindeki sekiz komşu nokta ve kendi ölçeğinin altındaki ve üstündeki dokuzar komşu nokta olmak üzere toplam yirmialtı komşu ile karşılaştırma yapılır (Karakuş ve Karabörk 2014).

Üçüncü safhada noktaların konumlarının görüntü ve ölçek uzaylarında tespiti için Hessian matrisinin determinantı ölçek ve görüntü uzayında enterpole edilir (Karakuş ve Karabörk 2014).

Bu aşamada ilgilenilen pikselin komşu pikselleri ile mutlak fark değerleri hesaplanır ve türevi alınır daha sonra belirlenen eşik değere göre dögüsel olarak değerlendirilerek güçlü ilgi noktalarının konumları belirlenir. (Dihkan 2019)

İlgi noktası tanımlama ve eşleme:

HGÖ tanımlayıcısı Fast-Hessian algılayıcısı ile belirlenmiş olan ilgi noktalarının bir ölçüğe bağlı komşuluk dahilindeki piksel yoğunluk dağıtımını tanımlar. Bu yöntem ÖBÖD algoritmasına benzerdir ancak Haar dalgacık filtrelerinin kullanılması ile elde edilen tanımlayıcı görüntüler işlem maliyetini azaltmaktadır (Bay vd. 2008) (Karakuş ve Karabörk 2014).

İlgi noktası tanımlayıcılarının bulunması iki safhalı işlemdir.


İlk safhada ilgi noktası çevresindeki dairesel bölgeden alınan bilgi kullanılarak tekrar edilebilir bir yön tayini işlemi yapılır.

İkinci safhada HGÖ tanımlayıcıları bu yöne tayin edilmiş kareden elde edilir. İkinci aşamadan sonra elde edilen özellikler ile görüntü eşlemesi yapılır (Bay vd. 2008) (Karakuş ve Karabörk 2014).

2.3.4 Yerel ikili örüntü algoritması


İlk YİÖ uygulaması 1996 yılında Ojala, Pietikainen ve Harwood'un beraber çalışması ile ortaya konulmuştur (Ojala vd. 1996).

Bu algoritmanın temel olarak bir görüntünün içindeki 3x3'lük pencere bölgesinde bu pencerenin ortasındaki piksel referans değer olarak sayılacak halde merkezdeki pikselin komşu pikselleri ile karşılaştırması, bu karşılaştırma sonucu 3x3 olan olan pencerenin YİÖ kodu adı verilen ikili değerinin oluşturulması işlemidir (Kızrak 2014).



Şekil 2.10 YİÖ algoritması

YİÖ ile öznelik çıkarılması çalışması bu YİÖ algoritmasından türetilmiştir. Öznelik çıkarılması çalışmasında 3x3'lük bir pencerenin görüntü üzerindeki belirleyici özelliklerin bulunmasında yeterli olmadığı düşüncesi ile komşu pikseller kavramına uzaklık R ve komşu piksel sayısı P değerleri de eklenmiş bu sayede araştırılacak alanın uyarlanabilir hale getirilmesi sağlanmıştır (Kızrak 2014). Şekil 2.11'de iki farklı P örnek sayısı ve R simetrik dairesel yarıçap çeşitleri gösterilmektedir.



Şekil 2.11 P örnek sayısı ve R simetrik dairesel yarıçap çeşitleri

$LBP_{P,R}$ olarak tanımlanan YİÖ operatörü ile R yarıçaplı P adet değere sahip olacak halde toplam 2^P çıkış değeri tanımlanabilir.

(x_c, y_c) görüntü noktası için YİÖ değerinin oluşturulması işlemi eşitlik (2.22)'de ifade edilmiştir (Nabiyev ve Günay 2011).

$$LBP_{P,R}(x_c, y_c) = \sum_{p=0}^{P-1} s(i_p - i_c) 2^p \quad (2.22)$$

Eşitlik (2.22)'de kullanılan;

(x_c, y_c) : Merkezdeki pikselin konumu

i_c : Merkez pikselin gri seviyesini

i_p : Komşu pikselin gri seviyesini

P : Komşuluk sayısını

ifade etmektedir

$s(x)$ fonksiyonu ise eşitlik (2.23)' deki gibidir.

$$s(x) = \begin{cases} 1, & \text{eğer } x \geq 0 \\ 0, & \text{eğer } x < 0 \end{cases} \quad (2.23)$$

Elde edilen YİÖ kodundaki 1'den 0'a ve 0'dan 1'e geçişlere bakılarak bu kodun bir biçimli olup olmadığı bilgisine de ulaşılabilmektedir. Eğer iki veya daha az ikili kodda değişiklik sergileniyor ise buna bir biçimli YİÖ denilir. Örneğin 11000111 bir biçimli YİÖ kodudur (Nabiyev ve Günay 2011).


YİÖ kodunun oluşturulmasından sonraki aşama olan histogramın oluşturulmasında bir biçimli olan ikili kodların herbiri ayrı, bir biçimli olmayan diğerleri ise bir tane "bir biçimli olmayanlar" grubu içinde toplanır. Örneğin 8 bit değerinde YİÖ kodu için oluşturulan kodların 58'i bir biçimli bir tanesi de bir biçimli olmayan toplam 59 farklı değer ortaya çıkar (Nabiyev ve Günay 2011).

$I(x, y)$ giriş görüntüsünün (x, y) noktası için R uzaklığındaki P komşu nokta için histogram hesaplaması eşitlik (2.24) ile ifade edilmektedir (Nabiyev ve Günay 2011).

$$H_i = \sum_{x_c \in I(x, y)} f\{LBP_{P, R}(x_c) = U(i)\}, i = 0, 1, \dots, n - 1, f\{y\} = \begin{cases} 1, & y \text{ yanlış ise} \\ 0, & y \text{ doğru ise} \end{cases} \quad (2.24)$$

Eşitlik (2.24)'e göre n bir biçimli olan kod adedini, $U(i)$ bir biçimli olan kodun tutulduğu diziyi, x_c ise incelenen merkez noktayı ifade etmektedir.

Bir YİÖ histogramına bakıldığında üzerinde çalışılan görüntü üzerine yerel örüntüler hakkında da bilgi sahibi olunabilir ve bu şekilde görüntünün karakteristik özellikleri istatistiksel olarak ortaya çıkarılabilmektedir (Kızrak 2014). Şekil 2.12'de bazı yerel örüntülerin görüntü içindeki anlamları gösterilmiştir.



Şekil 2.12 YİÖ örüntülerinin görüntü içindeki anlamları (Kızrak 2014)


Görüntünün özelliklerinin daha iyi ifade edilebilmesi için bölgesel YİÖ histogramları kullanılmaktadır. Bunun yapılması için giriş görüntüsü, R_j olarak ifade edilen m adet bölgeye bölümlenir ve her bölge için ayrı ayrı YİÖ histogramları eşitlik (2.25)'de belirtildiği üzere oluşturulur (Nabiyev ve Günay 2011).

$$H_{i,j} = \sum_{x_c \in R_j} f\{LBP_{P,R}(x_c) = U(i)\}, \quad LBP_{P,R}(x_c) = \sum_{p=0}^{P-1} s(i_p - i_c)2^p, \\ i = 0, 1, \dots, n-1, \quad j = 0, 1, \dots, m-1, \quad P \text{ komşu nokta sayısı } R \text{ uzaklık değeri,} \\ i_c \text{ merkez pikselin gri seviyesi, } i_p \text{ komşu pikselin gri seviyesi} \quad (2.25)$$

Eşitlik (2.25)'e göre $H_{i,j}$, j . bölgenin YİÖ histogramının i . değerini, x_c incelenen merkez noktayı, n bir biçimli kod adedi, m ise bölge bölüm adedini ifade etmektedir.

YİÖ algoritmasında son sahfa olarak üretilen bütün histogramlar birleştirilerek tek bir histogram elde edilmesi işlemi yapılır.

Şekil 2.13'de bu halde bölgelere ayrılarak oluşturulmuş yerel histogramlar ve toplam histogram gösterilmiştir.



Şekil 2.13 YİÖ ile histogramın elde edilmesi (Shan vd. 2009)

2.4 Sınıflandırma

Makina öğrenme, bilgisayar bilimleri, istatistik, bilişsel bilim gibi pek çok farklı disiplinden gelen kavramlara dayanan disiplinler arası geniş bir alandır (Soofi ve Arshad 2017).

Makina öğrenme, denetimli ve denetimsiz olmak üzere iki ana kategoriye ayrılır.

Denetimsiz makina öğrenme tekniğinde etiketlenmemiş veri setlerinden bir sonuca ulaşım vardır. Bir başka deyişle denetimsiz öğrenmede beklenen sonuç bilgisi verilmez (Soofi ve Arshad 2017).

Denetimli makina öğrenme tekniğinde ise girdi öznitelikleri ile hedef öznitelik arasındaki ilişki araştırılır denetimli teknikler de kendi içinde regresyon ve sınıflandırma olarak ik ayrı gruba ayrılırlar. Regresyon tekniğinde çıktı sürekli değerler alırken sınıflandırmada çıktı değişkeni sınıf etiketleri almaktadır (Soofi ve Arshad 2017).

Makine öğrenimi için pek çok farklı teknik olmasına karşın sınıflandırma en yaygın kullanılanıdır.

Sınıflandırıcı algoritmaları da kendi içinde farklı uzmanlık alanlarına ayrılmış olup her birinin ayrı güçlü ve zayıf yönleri bulunmaktadır.

Bu sınıflandırıcılardan Yinelemeli Dikotomizör 3 (ID3), C4.5, Bayes Ağı, K-En Yakın Komşu (KNN) ve DVM yaygın olarak kullanılanlardır. Tez çalışmasında sınıflandırma performansı ve gerçek dünya problemlerine uyarlama için pek çok ayar parametresine sahip olması nedeni ile DVM kullanılmıştır.

2.4.1 Yinelemeli Dikotomizör 3

Bir karar ağacı algoritması olan ID3 bilgi kazancı temeli üzerine kurgulu olup kolay anlaşılabilirliği ve karar vermede tüm eğitim örneklerini kullanması güçlü yönleridir.

Bunun yanında geriye dönük arama yapılamaması, eksik değerleri ele alamıyor olması ve evrensel optimizasyon yapılamaması zayıf yönü olarak değerlendirilebilir (Soofi ve Arshad 2017).

2.4.2 C4.5

Bilinen karar ağacı algoritmalarından biri olan C4.5, ID3 algoritmasının geliştirilmiş hali olarak düşünülebilir. Güçlü yönleri olarak eksik özellik verilerinin değerlendirebilmesi, hem ayrık hem de sürekli özellikleri ele alabilmesi sayılabilir (Soofi ve Arshad 2017).

2.4.3 Bayes ağı

Bayes ağı, bir dizi değişken arasındaki olasılık ilişkilerinin grafiksel modeli olarak tanımlanabilir. Güçlü yönleri olarak, ağ modelindeki yapılan küçük değişikliklerden etkilenmemesi, esnek uygulanabilirliği, hem regresyon hem sınıflandırma problemlerinin çözümünde kullanılabilmesi, eksik verilerden etkilenmemesi sayılabilir. Bunun yanında sürekli olan özniteliklerin ayrık özniteliklere dönüştürülmesine gerek duyması zayıf yönü olarak sayılabilir (Soofi ve Arshad 2017).

2.4.4 K-En yakın komşu


KNN algoritması, örnek veri noktasının sınıfının tespit edilmesi için gerekli olan ve k değeri ile tanımlanan kaç adet en yakın komşuya ihtiyaç duyulduğunu tanımlayan algoritmadır. Yapısal ve yapısal olmayan olmak üzere iki farklı kategoriye ayrılır. KNN'nin en güçlü yanı büyük miktardaki eğitim verilerinde etkin olması ve veri içindeki gürültüye dayanıklı olmasıdır. Bunun yanında zayıf yönleri olarak alan ihtiyacı, sınıflandırma zamanı, yüksek bilgi işleme maliyeti ve özellikle büyük veri setlerinde düşük hız performansı sayılabilir (Soofi ve Arshad 2017).

2.4.5 Destek vektör makinesi

Çok çeşitli sınıflandırma problemlerinde başarıyla kullanılabilen, doğrusal olarak birbirinden ayrılamayan sınıfları tanımda başarılı olan DVM, veri sınıflandırılması, öğrenme ve tahmin ile ilgili problemlerin çözümünde kullanılan önde gelen bir sınıflandırıcıdır.

DVM istatistiksel öğrenme teorisine dayalı bir algoritma olarak 1960'lı yıllarda Vapnik ve Chervonenkis tarafından temelleri atılsa da 1995 yılında Vladimir Vapnik, Bernhard Boser ve Isabelle Guyon tarafından geliştirilmiştir (Ülgen 2017).

DVM, verilen sınıfları birbirinden ayırmak üzere en uygun hat, düzlem veya hiperdüzlemi elde etmeyi amaçlamaktadır, bu işlem yapılırken iki grup arasındaki birbirine en yakın farklı grup elemanlarının bulunduğu hatlar kullanılır (Ayhan ve Erdoğan 2014).



Şekil 2.14 Destek vektörleri

Şekil 2.14'e göre A sınıfı ve B sınıfından birbirine en yakın p, q, r, s vektörlerine destek vektörleri denir, p ve q vektörlerinden benzer şekilde r ve s vektörlerinden geçen düzlemlere ise sınır düzlemi denir (Kumar 2019).

DVM birden fazla sınıf için de kullanılabilmekte ayrıca doğrusal ve doğrusal olmayan ayırıcıların tanımlanmasına da olanak tanımaktadır.

DVM sınıfları birbirinden ayıran hiper düzlemin yapısına göre doğrusal ve doğrusal olmayan DVM olarak iki ana gruba ayrılmaktadır.

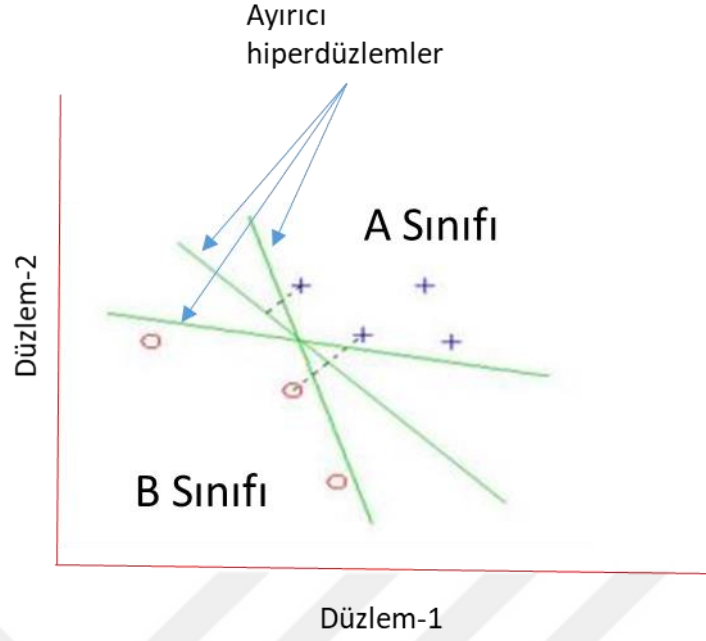
- Doğrusal DVM

Elimizde p farklı niteliği olan x_i örnekleri girdisi ve bu girdilere göre $y_i \in \{1, -1\}$ 'de bu örneklerin hangi sınıfa ait olduğu bilgisi olsun.

x çok boyutlu bir girdi vektörü olmak üzere, (x_i, y_i) ikililerinden oluşan bir eğitim kümesi S verildiğinde, birbirinden ayrı sınıfları birbirinden en iyi ayıracak olan doğrusal hiper düzlemin bulunmasına destek olan makina öğrenim algoritmasıdır (Ayhan ve Erdoğan 2014).

$$K(x) = w \cdot x + b \quad (2.26)$$

Eşitlik (2.26)'de w , hiper düzlemin normali ve ağırlık vektörü b ise sabittir (Ayhan ve Erdoğan 2014).



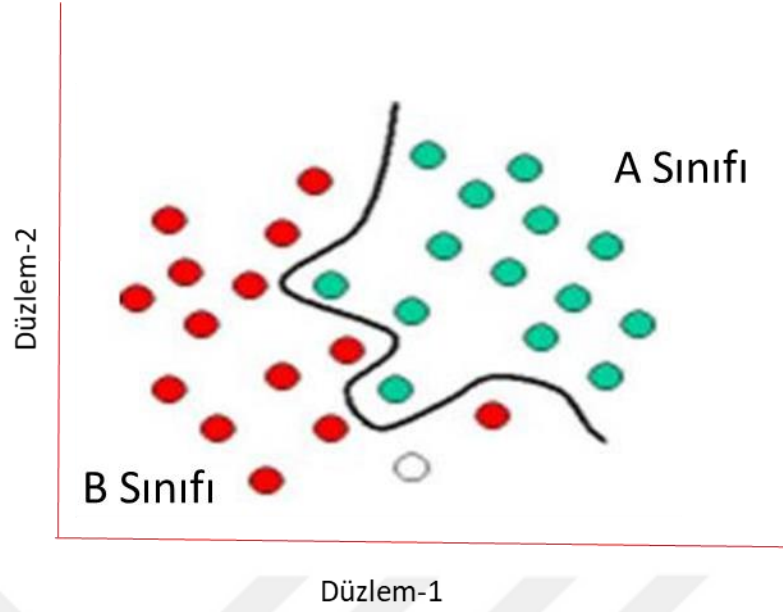
Şekil 2.15 İki sınıflı veri setini ayıran farklı düzlemlere ilişkin örnek (Ayhan ve Erdoğan 2014)

Şekil-2.15'e göre ayrı sınıfları birbirinden ayıran birçok doğrusal düzlem oluşturabilir.

DVM bu aşamada ayrı sınıflara ait destek vektörlerinin arasındaki mesafenin en fazla olduğu ayırıcı bir hiper düzleminin bulunmasını amaçlamaktadır (Ayhan ve Erdoğan 2014).

- Doğrusal olmayan DVM

Gerçek dünya problemlerinde genellikle farklı gruplar birbirinden doğrusal olarak ayrılamaz. Bu durumda bir ayırma eğrisi oluşturulması gerekir, buradaki problem ise bu eğrinin tahminin zor olmasıdır. Doğrusal olmayan eğrinin bulunması için farklı çekirdek tipleri bulunmaktadır. Destek vektör makinalarında bu çekirdek tipleri arasında en iyi sonucu veren bir tanesi kullanılabilir.




Şekil 2.16 İki sınıflı problem için doğrusal ayrılamama durumu (Ayhan ve Erdoğan 2014)

En çok kullanılan doğrusal olmayan çekirdek yöntemleri olarak polinom çekirdek, Gauss radyal tabanlı fonksiyon çekirdeği ve sigmoid çekirdek sayılabilir.

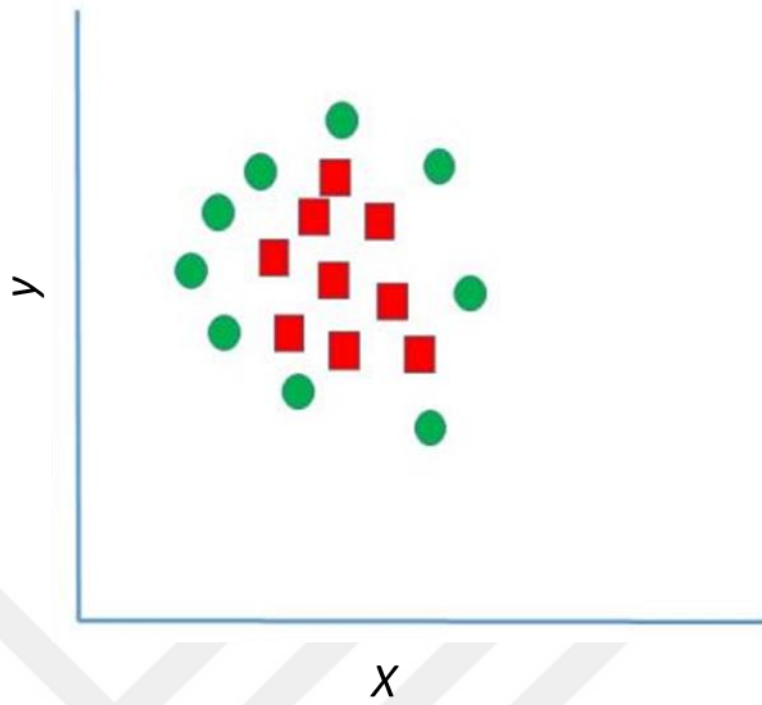
Polinom çekirdeği tanımlamak için elimizde x_1 ve x_2 olmak üzere iki vektör c sabit, d polinom derecesi olmak üzere $K(x_1, x_2)$ fonksiyonu eşitlik (2.27)'de tanımlandığı gibidir (Kumar 2019).

$$K(x_1, x_2) = (x_1 \cdot x_2 + c)^d \quad (2.27)$$



Şekil-2.17 Örnek ikinci dereceden polinom çekirdek fonksiyonu DVM uygulaması (Kumar 2019)

Her ne kadar polinom çekirdek fonksiyonu uygun bir sınır hattı oluştursa da Şekil 2.18'deki gibi bir senaryoda yetersiz kalmaktadır.



Şekil 2.18 Gauss çekirdek problemi (Kumar 2019)

Bu gibi problemlerin çözümü için radyal temelli bir fonksiyon veya gauss çekirdeği kullanılır.

Gauss çekirdek fonksiyonu, x ve y vektör, σ serbest bir parametre olmak üzere $\gamma = \frac{1}{2\sigma^2}$ olacak şekilde eşitlik (2.28)'de gösterilmiştir.


$$K(x, y) = e^{(-\gamma\|x-y\|^2)} \quad (2.28)$$

Hiperbolik tanjant (sigmoid) çekirdek fonksiyonu ise yapay sinir ağlarında aktivasyon fonksiyonu olarak da kullanılmaktadır ve eşitlik (2.29)'de gibi ifade edilmektedir (Güldoğan 2017).

$$k(x, y) = \tanh(\alpha x^T y + c) \quad (2.29)$$

Eşitlik (2.29)'e göre x ve y vektör, α eğim ve c kesme sabitidir (Güldoğan 2017).

Hiperbolik Tanjant Fonksiyonu



Şekil 2.19 Örnek hiperbolik tanjant fonksiyonu

DVM ile eğitim gerçekleştirildikten sonra öğrenme durumu için test edilir. DVM testinde üç farklı kriter eğitimin seviyesini belirler. Bunlar doğruluk (accuracy), pozitif verilerin negatif olarak işaretlenmemesinin ölçütü olan hassasiyet (precision) ve pozitif verileri bulabilme ölçütü olan geri çağırma (recall) değerleridir. DVM eğitiminde bu değerlerin en iyi olduğu en uygun çekirdek ve regülasyon parametresi olan C parametresi araştırılır. C parametresi, sınıflar arasındaki en uygun sınır düzlemi ile ilgili bir parametredir, bu değer çok küçük seçilirse yanlış bulmalar artabilir, çok büyük seçilirse doğru ayırım oranı doyuma ulaşır.

Tez çalışmasında iki sınıflı DVM kullanılmış olup öznitelik çıkarma algoritmalarından elde edilen eğitim verilerinden en iyi test sonuçlarını elde edebilmek için doğrusal ve polinom çekirdek tipleri seçilmiştir. Benzer şekilde C parametresi de her algoritma için ayrı ayrı en iyi test sonucunun elde edilebileceği değere getirilmiştir.

2.5 Maksimum Olmayanın Bastırılması

Eğitilmiş bir makineye bir görüntü verildiği ve makinenin, daha önce eğitildiği bir nesneyi bu görüntü içinde tespiti ve işaretlenmesi problemi düşünüldüğünde, görüntüde küçük parçalar halinde hedef nesne aranır. Araştırılan bölgelerde aranan nesneye ait olduğu düşünülen bazı özelliklere rastlanıldığında makine tarafından “bulunan alan”

olarak işaretlenir. Fakat işaretlenen bu alan aranan nesnenin bir kısmını işaret etmekte ve bu nesnenin etrafındaki pek çok uygun özellikteki alan bulundu olarak işaretlenir. Sonuç olarak gerçekte bir tane nesne için birden fazla bulundu bilgisi geri döner. Bu problemin çözümü için kullanılan tekniğe NMS denilmektedir.

NMS bilgisayarlı görüntü işleme aşamalarının temel bir parçası olarak kullanılmaktadır (Rothe vd. 2015).

Bilgisayarlı görüntü işleme aşamalarının temel bir parçası olarak kullanılan NMS aynı desen etrafında oluşmuş pek çok pencereyi aranan desen etrafını çevreleyecek tek pencere hale getirmektedir (Rothe vd. 2015).

NMS olarak en yaygın yaklaşım açgözlü (greedy) NMS'dir (Rothe vd. 2015). Bu yaklaşımda nesneyi çevrelediği düşünülen en iyi skora sahip olan pencere seçilir ve bu pencereye yakın olan diğer pencereler ortamda yakın başka pencere kalmayana kadar bastırılır (Rothe vd. 2015). Bu algorithmada pencereler arasındaki benzerlik ölçüsü ve pencere bastırma için eşik değeri belirlenmesi gereklidir (Rothe vd. 2015).

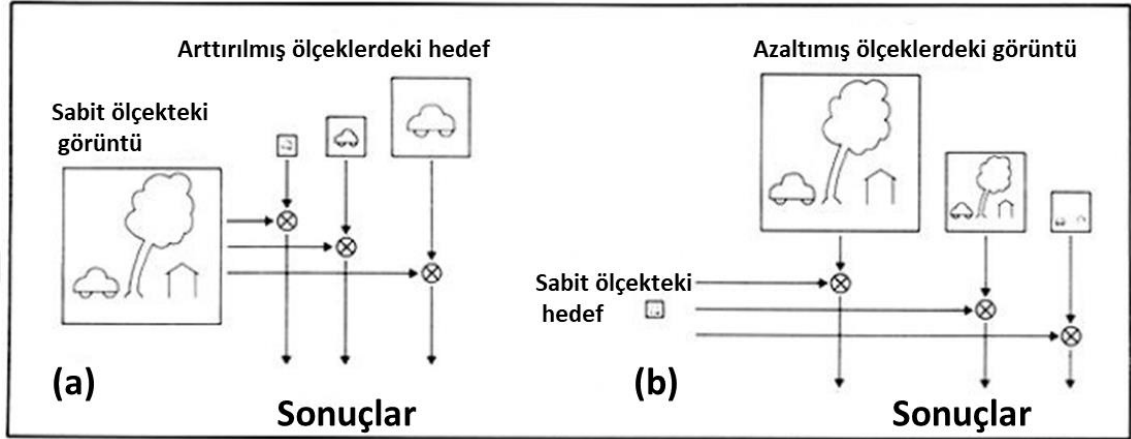
2.6 Görüntü Piramiti

Öznitelik çıkarımı ve eğitim ne kadar çok veri ile yapılırsa bir görüntü içindeki nesnenin doğru olarak bulunması olasılığı artacaktır; ancak ideal bir eğitim verisi oluşturmak için aranan nesnenin karşılaşılabileceği her türlü olasılığı içeren veri seti yaratmak nerede ise imkansızdır. Eldeki eğitim veri setlerinin sınırlı olduğu gerçeği gözönünde bulundurularak bir görüntü içerisinde nesne varlığı ya da yokluğu değerlendirilirken görüntü farklı boyutlara getirilerek tekrar öznitelik çıkarımı ve nesne arama faaliyeti gerçekleştirilir. Bu çalışmadaki düşünce görüntü içinde aranan nesne farklı boyuta geldiğinde nesnenin makina tarafından bulunabileceğidir. Görüntünün bu amaç ile yeniden boyutlandırılması tekniği görüntü piramiti tekniğidir.

Bir görüntü üzerinde aranılan hedef örüntü farklı boyutlarda karşımıza çıkabilir. Aranılan örüntüyü bulabilmek için iki farklı yaklaşım sergilenebilir (Adelson vd. 1984).

Birinci yaklaşımda üzerinde örüntü aranılan görüntü sabit kalır aranılan örüntünün farklı boyutları ile konvolüsyon uygulanabilir (Adelson vd. 1984).


İkinci yaklaşımda aranılan örüntü sabit kalabilir, üzerinde örüntüyü aradığımız görüntünün farklı boyutları ile konvolüsyon uygulanabilir (Adelson vd. 1984).



Şekil 2.20 İki farklı yaklaşım (Adelson vd. 1984)

İki yaklaşım da aynı sonuca erişimi sağlasa da ikinci yaklaşım daha verimlidir. Birinci yaklaşımda hedef örüntüyü s faktörü ile büyüttüğümüzde ikinci yaklaşımdaki hedef görüntüyü küçülterek yapılan çalışmaya göre s^4 daha fazla aritmetik operasyon yapılmaktadır (Adelson vd. 1984).

Görüntü piramiti küçültülmüş görüntü ile verimli konvolüsyon gerçekleştirilmesi için tasarlanmış bir veri yapısıdır. Sabit basamaklar ile yoğunluk ve çözünürlüğün azaltılmasıyla oluşturulmuş orjinal görüntünün kopyalarıdır. Şekil 2.21’te gösterildiği üzere azaltılmış çözünürlük seviyelerindeki görüntüler yinelemeli bir algoritma ile oluşturulmuştur (Adelson vd. 1984).



Şekil 2.21 Gauss piramiti (Adelson vd. 1984)

Başlangıç seviyesi, sıfır seviyesi olan G_0 orijinal görüntüdür. Piramitin bir sonraki seviyesi için düşük geçiren filtreden geçirilmiş ve alt örneklenmiş G_1 takip eder ve benzer şekilde G_2 oluşturulur (Adelson vd. 1984).

Bir başka piramit yöntemi olarak bandgeçiren filtre uygulanarak yapılan Laplace piramiti bulunmaktadır (Adelson vd. 1984).

Laplace piramitinin önemli bir avantajı görüntü piramit faaliyeti gerçekleştirildikten sonra orijinal görüntüye olduğu gibi geri dönülebilmesidir (Adelson vd. 1984).

2.7 Arka Plan Çıkarma

Bir video görüntüsünde hareketin tespiti temel video analizi tekniklerinden biridir. Hareket tespiti güvenlik uygulamaları gibi ortamlarda genelde tek başına yeterli olmakla beraber hareketli nesnenin tespitinin yanında nesnenin tanımlanması gibi uygulamaları da destekleyen bir ön işlem olarak da görülebilir. Bu tez çalışmasında da kişilerin tespiti için öncelikle hareketlerine göre arka plan çıkarılması uygulanmıştır.

Hareket tespiti için video görüntüsünde araştırılan kısımlar arka plan ve ön plan ayrımlarıdır.

Arka planın çıkarılmasında dört ana işlem adımı bulunmaktadır (Buğday 2010).

Birinci adım önışleme adımında video verisi sonraki aşama için uygun hale dönüştürölür.

İkinci adım arka plan modellemesinde uygun hale getirilen veriler kullanılarak arka plan hesaplamaları gerçekleştirilir ve bir model oluşturulur.

Üçüncü adım ön planın saptanması aşamasında arka plan modeli ile uyuşmayan pikseller tespit edilir ve ön plan maskesi oluşturulur.

Dördüncü ve son aşamada ise elde edilen ön plan maskesine uymayan pikseller ayrılır ve ön plan ayrımı için kullanılacak maske elde edilir (Buğday 2010).

Bu tez çalışmasında arka plan modellemesi için Gauss fonksiyonlarının karışımı (MoG) yöntemi kullanılmıştır.

MoG yöntemi birden fazla çevresel faktörün etkisini süzebilen ve nesnelerin hareket izlerini yok edebilen etkili bir yöntemdir (Buğday 2010).

MoG yönteminde parametrik olarak ele alınan arka modelin ilgilendiğı her pikselin konumu bir grup Gauss fonksiyonu ile belirlenmektedir.

Bu algoritmada her bir pikselin Gauss bileşeni diğere piksellerden bağımsız olarak ayrı ayrı güncellenmektedir. İlk olarak pikselin Gauss bileşenlerinin eşleşen-eşleşmeyen sınıflandırması yapılır. Eğer bileşenin ortalaması mevcut piksel değerinin önceden belirlenmiş aralığı içinde ise bu eşleşmiş bir bileşendir. Sonraki aşamada Gauss parametreleri uygun sınıflar ile eşleştirilir. Eğer eşleştirilecek uygun bir sınıf yok ise algoritma en küçük ağırlığa sahip yeni bir Gauss bileşeni oluşturur. Daha sonra bileşenler ağırlık derecesi ile beraber standart sapma oranına göre sıralanır. En yüksek dereceli bileşen öncelikli olacak halde mevcut değerle eşleşmede sıra ve yakınlığına göre bir pikselin arka plan olup olmadığına bakılır eğer eşleşme bileşeni yoksa bu piksel ön plan olarak belirlenir (Tabhki vd. 2013).

2.8 Kontur Tespiti

Kontur, bir nesnenin biçimini temsil eden veya sınırlayan bir anahat olarak tanımlanabilir (Gong vd. 2018).

Kontur algılama, nesne tanıma sahne algılama gibi çalışmalarda kullanılan temel işlem adımlarından biridir. Kontur algılama tekniği, görüntü içindeki bir nesneyi temsil eden kapalı eğrileri ortaya çıkarmaya çalışır. Kontur çalışması, görüntülerdeki nesnelerin fotometrik, geometrik ve fiziksel özelliklerindeki süreksizliklerine karşılık gelen kenar ve sınır kavramları ile ilgilenir.

Sınır, görüntüdeki bir nesnenin veya yüzeyin birinden diğerine geçerken ortaya çıkan değişiklik olarak tanımlanabilir (Gong vd. 2018).

Kenar ise görüntüdeki parlaklık veya renk yoğunluğu fonksiyonundaki alt seviyeli değişimler olarak tarif edilebilir. Kenar algılama, kontur algılama için kullanılan alt seviye bir çalışmadır.

Bu tez çalışmasında saha içindeki kişilerin tespitinde arka planı çıkarılmış, ön plan olarak tanımlanmış görüntülerin konturleri oluşturulmuş ve bu kontur çevresinde belirlenen alanda kişi arama çalışması gerçekleştirilmiştir.

2.9 Histogram Eşleme

Histogram eşleme ya da histogram spesifikasyonu olarak adlandırılan kavram, bir görüntünün histogramının belirlenen bir histogram ile eşleştirilerek dönüştürülmesidir (Gonzalez ve Woods 2008)

Siyah-beyaz bir görüntü olan X için r gri seviyesi ve $p_r(r)$ bu değer olasılık değeri olsun. Bu olasılık değeri, görüntünün histogramına bakılarak eşitlik (2.30) ile hesaplanabilir. Eşitlik (2.30)' da n_j değeri r_j gri seviyesinin frekansı ve n görüntüdeki piksel sayısıdır.

$$p_r(r_j) = \frac{n_j}{n} \quad (2.30)$$

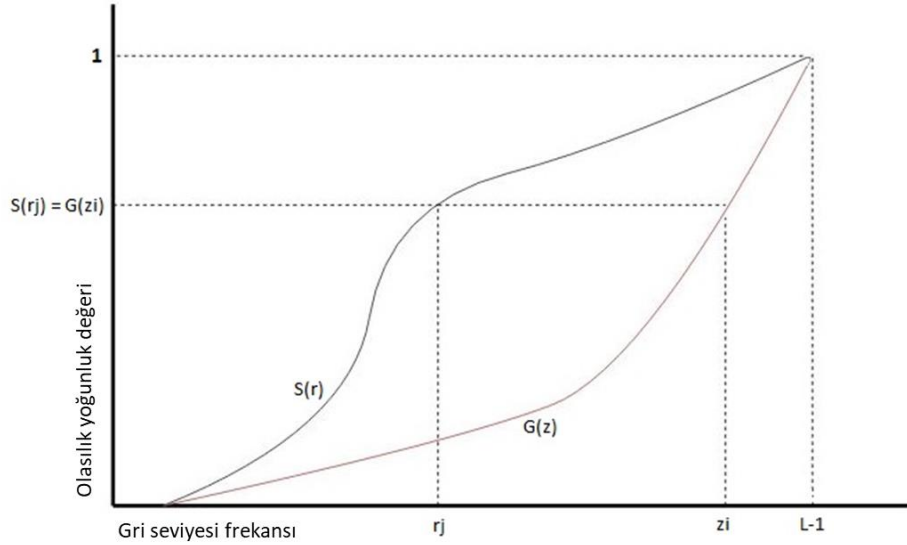
$p_r(r)$ 'yi dönüştürmek istediğimiz olasılık yoğunluk fonksiyonumuz $p_z(z)$ olsun.

Her bir olasılık yoğunluk fonksiyonu, L toplam gri seviyesi olmak üzere kümülatif dağılım fonksiyonuna eşitlik (2.31) ve (2.32) ile eşlenebilir.

$$S(r_k) = \sum_{j=0}^k p_r(r_j), \quad k = 0, 1, 2, 3, \dots \quad (2.31)$$

$$G(Z_k) = \sum_{j=0}^k p_z(z_j), \quad k = 0, 1, 2, 3, \dots, L \quad (2.32)$$

Bu çalışmadaki hedef, şekil 2.22 de gösterildiği üzere X görüntüsündeki her r gri seviyesi değerini istenen olasılık yoğunluğundaki aynı olasılığa sahip z değeri ile eşleştirmektir (Gonzalez ve Woods 2017).



Şekil 2.22 Histogram eşleme

Histogram eşleme çalışması sadece gri seviyesi için değil görüntü renk kanalları için de uygulanabilir.

Bu tez çalışmasında 3B olarak oluşturulan ortamın ışık ve renk koşullarının gerçek ortam ile benzerliğinin sağlanması için histogram eşleme uygulaması yapılmıştır.

2.10 Hipotez Testi

Hipotez testi, bir çalışma sonucunda elde edilen değerlerin istatistiksel olarak anlamlı olup olmadığının test edilmesi için kullanılan ve değerlendirilen çalışmadan bir sonuç veya karar oluşturulmasına yardımcı olan yöntemlerdir (Yüksel vd. 2015).

Bu tez çalışmasında çalışmasının motivasyon noktalarından biri olan 3B modellenmiş ortamdan edilen analiz sonuçlarına bakarak gerçek ortam hakkında yorum yapabilmek için eldeki verilerin akademik olarak da uygun bir yöntemle karşılaştırılması ve değerlendirilmesi için hipotez testi teknikleri kullanılmıştır.

Hipotez testleri, ortaya konulan bir hipotezin kesinlikle doğru veya yanlış olduğu sonucunu vermez eldeki verileri kullanarak belirli bir ölçüde hata oranını da kabul ederek hipotezin doğruluğu veya yanlışlığı oranını ortaya koyar. Eldeki sınırlı bilginin veya sonuçlar kümesinin hata payına sahip olduğu gerçekliğine uygun olarak hipotez testlerinde $\alpha = 0,01 \sim 0,05$ lik hata payı olasılığı bir parametre olarak yer almaktadır (Yüksel vd. 2015).

Hipotez testinin ilk aşamasında hipotezin ifade edilmesi yer alır. İstatistiksel bir çalışmada “*eşittir, arasında fark yoktur veya en az veya en fazla ... kadardır*” biçiminde kurulan hipotezlere yokluk veya sıfır hipotezi denir ve H_0 olarak ifade edilir. Bu hipotezin karşı test edilen alternatif seçeneğe ise “karşıt hipotez” adı verilir ve H_1 olarak ifade edilir (Yüksel vd. 2015).

Hipotez testinde parametrenin önceden belirlendiği ve etkinin beklenmediği H_0 hipotezinin test edilebilmesi için alternatifinin yani H_1 hipotezinin de ifade edilmesi gereklidir. H_0 hipotezinin belirli bir olasılıkla red edilmesi durumunda H_1 hipotezi kabul edilmektedir. H_0 hipotezi farksızlığı esas olarak kurulduktan sonra, farklılık üzerine kurgulanmış olan H_1 hipotezi üç farklı şekilde ifade edilir (Yüksel vd. 2015).

İlk durum olan μ_1 ve μ_2 birinci ve ikinci grupların populasyon ortalaması olmak üzere $H_1 = \mu_1 \neq \mu_2$ durumunda H_0 hipotezi, verilecek kararın anakütle parametre değerinden hem küçük hem de büyük yöndeki anlamlı farklılıklardan etkilenir.

İkinci durum olan $H_1 = \mu_1 > \mu_2$ 'ye göre sadece büyük yöndeki anlamlı sapmadan etkilenme vardır.

Üçüncü durumda ise $H_1 = \mu_1 < \mu_2$ sadece küçük yöndeki anlamlı sapmadan etkilenme vardır.

H_1 hipotezi tezin yönünün ya da başka deyişle H_0 hipotezinin red edileceği alanın yerini belirleyen hipotezdir . Kabul bölgesi, H_0 hipotezinin kabul edildiği alanlar, hipotezin kabul edilmesini sağlayan istatistiki değerler aralığıdır.

Hipotez tesinin ikinci aşamasında H_0 ve H_1 belirlendikten sonra bu iki karar arasında seçim yaparken oluşabilecek hatalı kara verme riskine karşın bir anlamlılık düzeyi olan α değeri belirlenir. Bu değer genellikle 0,01 ya da 0,05 olarak seçilir (Yüksel vd. 2015).

Hipotez testinin üçüncü aşamasında ilgili anakütleden belirlenen miktarda rastgele örneklem seçilerek veriler derlenir.

Hipotez testinin dördüncü aşamasında test istatistiği çalışması yapılır. Test istatistiği, örneklem sifir hipotezine uygunluk seviyesini göstermektedir.

Hipotez testinin son aşamasında ise karar verilir, bu aşamada α anlamlılık seviyesinde H_0 hipotezi kabul ya da red kararı verilir. Kabul veya red kararında karşılaşılabilecek dört farklı durum vardır (Yüksel vd. 2015).

Birinci durumda H_0 hipotezinin doğru olduğu kabul edildiği durumdur.

İkinci durum H_0 hipotezinin doğru olduğu ancak reddeldiği durumdur. Buna "I. tip hata" denir.

Üçüncü durum H_0 hipotezinin yanlış olduğu ancak kabul edildiği durumdur. Buna "II. tip hata" denir.

Dördüncü ve son durumda ise H_0 hipotezi yanlıştır ve reddilir bu duruma ise “testin gücü (power of test)” adı verilir.

Bir istatistiksel testte kullanılan test istatistiğine ait bir P (*Probability, Olasılık*) değeri hesaplanır. Bu değer, “yapılan hipotez testinin neticesindeki fark anlamlıdır“ kararına varıldığı takdirde bunun hatalı bir karar olma olasılığını ifade eder.

Tez çalışmasında hipotez testi 3B modellenmiş ortamdan elde edilen analiz ortalama değerleri için T-testi ve standart sapmalarının karşılaştırmaları için F-testi uygulanmıştır.

T-testlerinden standart sapmaların benzerliği veya benzemezliği durumlarına göre iki örneklili havuzlanmış varyans ve Welch T-testleri uygulanmıştır.

İki örneklili havuzlanmış varyans T-testi için \bar{x}_i , \bar{S}_i ve n_i sırası ile i grubunun örnek ortalaması, örnek standart sapması ve örnek sayısı, d ise iki grubun ortalamasının farkı olmak üzere test istatistik formülleri eşitlik (2.33) ve eşitlik (2.34)’ de belirtildiği gibidir (Statskingdom 2021).

$$t = \frac{\bar{x}_1 - \bar{x}_2 - d}{S \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \quad (2.33)$$

$$S^2 = \frac{(n_1 - 1)S_1^2 + (n_2 - 1)S_2^2}{n_1 + n_2 - 2} \quad (2.34)$$

Welch T-testi için \bar{x}_i , \bar{S}_i ve n_i sırası ile i grubunun örnek ortalaması, örnek standart sapması ve örnek sayısı, d ise iki grubun ortalamasının farkı olmak üzere test istatistik formülleri eşitlik (2.35) ve (2.36)’ da belirtildiği gibidir. Eşitlik (2.36)’da ifade edilen df serbestlik derecesidir (Statskingdom 2021).

$$t = \frac{\bar{x}_1 - \bar{x}_2 - d}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}} \quad (2.35)$$

$$df = \frac{\left(\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}\right)^2}{\frac{S_1^4}{n_1^2(n_1-1)} + \frac{S_2^4}{n_2^2(n_2-1)}} \quad (2.36)$$

F-testi için S_i i grubunun standart sapması olmak üzere eşitlik (2.37) ile hesaplanır.

$$F = \frac{S_1^2}{S_2^2} \quad (2.37)$$



3. MATERYAL VE YÖNTEM

3.1 Çalışma Aşamaları

Tez çalışmasında belirlenen işlem adımları (Hattori vd. 2015) 'e benzer şekilde öncelikle 3B modelleme aşaması ile başlamakta sonra oluşturulan 3B modellenmiş ortamdan eğitim verilerinin alınması, öznitelik çıkarılması ve DVM eğitim, test ve gerçek ortam denemelerini içermektedir.

Tez çalışma aşamaları altı ana konu altında toplanmaktadır.

Birinci aşama olan 3B modelleme aşamasında öncelikle ortam senaryosu belirlenmiştir. Ortam senaryosu belirlendikten sonra Blender yazılımı kullanılarak senaryosu belirlenen gerçek ortamın modellenmesi gerçekleştirilmiş sonrasında bu ortam içerisinde 3B kişi modelleri MakeHuman ve Mixamo yazılımları kullanılarak verilen hareket senaryosu ile hareketlendirilmiştir. Hareketlendirilmiş sanal kişilerin bulunduğu her bir görüntü Blender yazılımındaki sanal kamera görüşü ile 2B olarak derlenerek (rendering) kişilerin konum ve sanal çerçeve koordinat bilgileri eğitim verisi olarak kullanılmak üzere kayıt altına alınmıştır.

İkinci aşamada pozitif eğitim verisi oluşturmak üzere birinci aşamada oluşturulan derlenmiş görüntülerde bulunan kişiler, koordinat ve sanal çerçeve bilgileri kullanılarak görüntülerden kırılmış ve eğitim verisi haline getirilmiştir. Negatif eğitim olarak hazır eğitim görüntü seti kullanılmıştır. Bunun yanında ortam senaryosuna uygun olacak halde halde sentetik negatif eğitim görüntüleri hazırlanmıştır.

Üçüncü aşamada elde edilen pozitif ve negatif eğitim görüntüleri kullanılarak YGH, ÖBÖD, HGÖ, YİÖ öznitelik çıkarım algoritmaları kullanılarak her bir algoritma için ayrı pozitif ve negatif olarak etiketlenmiş öznitelikler oluşturulmuştur. Çalışmalarda sentetik negatiflerin eklendiği ve eklenmediği eğitim verileri ayrı ayrı oluşturulmuştur.

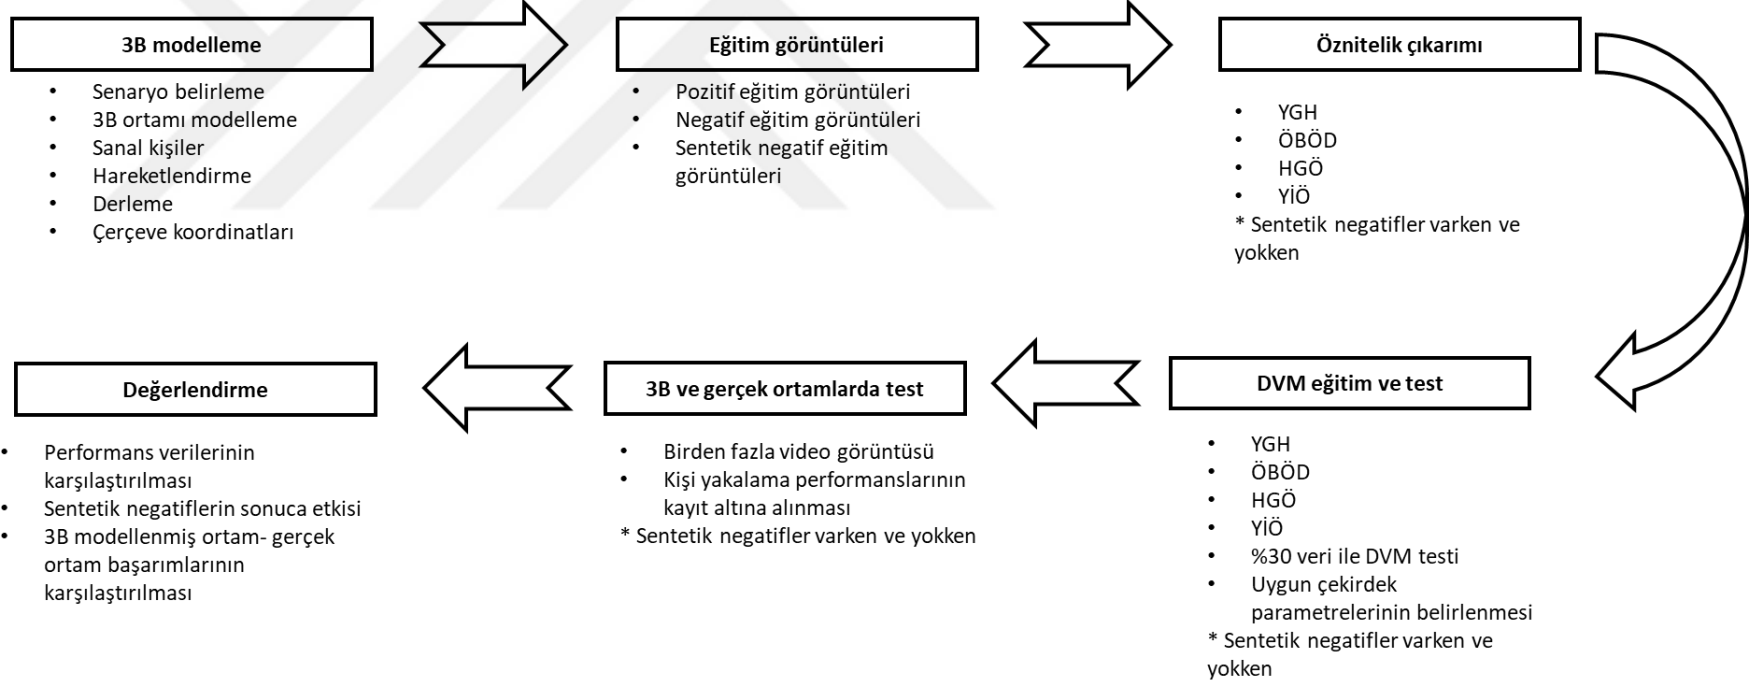
Dördüncü aşamada elde edilen her bir öznitelik için ayrı ayrı DVM eğitimleri yapılmıştır. Bu aşamada eğitim verilerinin % 30' u DVM eğitim testi için kullanılmış

olup en yüksek eğitim oranını yakalamak için en uygun çekirdek modeli ve DVM parametre ayarlamaları bu aşamada yapılmıştır.

Beşinci aşamada eğitimi yapılmış DVM'ler ile gerçek ortamda kişi tespit çalışmaları yapılmış olup YGH, ÖBÖD, HGÖ, YİÖ algoritmalarının her birinin aynı video çerçevesinde değerlendirildiği bir ortamda farklı gerçek ortam videoları ile kişi yakalama performansları kayıt altına alınmıştır.

Altıncı ve son aşamada ise kayıt altına alınan performans verilerinin karşılaştırmaları yapılmıştır. Yapılan karşılaştırmalarda doğruluk oranı, hız, sentetik negatiflerin sonuca etkisi değerlendirilmiş olup ayrıca 3B ortamda elde edilen başarımla gerçek ortamdaki başarımlar arasındaki ilişki hipotez testi teknikleri kullanılarak değerlendirilmiştir.

Şekil 3.1' de çalışma aşamaları gösterilmiştir.



Şekil 3.1 Çalışma aşamaları

3.2 3B Modelleme

3.2.1 3B modellenecek ortamın ve senaryonun belirlenmesi

Çalışma senaryosu için sadece kişilerin olduğu, 3B modellenebilir sadelikte ve değiştirilebilir parametrelere uygun ortamlar araştırılmış ve halı saha ve halı sahada oynayan kişiler çalışma senaryosu olarak seçilmiştir.

Halı saha ortamının seçilme nedenleri olarak:

- Halı saha ortamında sadece kişiler ve sahne bulunduğu için çalışmanın performansı hem 3B model ortamında hem de gerçek ortamda kontrollü bir şekilde değerlendirilebilecektir.
- Halı sahada bulunan kişi sayısı belirlenebilmektedir.
- Ortam parametreleri gözönünde bulundurulduğunda 3B modellenmiş senaryo gerçek dünyada da değerlendirilebilmektedir.
- Gerçek ortam halı sahalarda da gün ışığının yanında yapay ışıklandırma da kullanılmıştır.
- Halı saha, futbol kalesi ve kale filesi , saha etrafı tel örgü deseni, saha çizgileri, saha aydınlatmaları, kişi modelleri 3B olarak ölçeklendirilebilecek halde modellenebilmektedir.
- Halı saha üzerinde koşan kişi karakteri 3B olarak modellenebilmektedir.
- Gerçek ortam testleri için halı saha videoları edinilebilmektedir.



Şekil 3.2 Gerçek ortam halı saha ve kişiler

Şekil 3.2’de tipik bir halı saha örneği gösterilmektedir. Bu ortamda bütün saha ortamını görecektek halde tek bir kamera konumlandırılmış olup kameraya yakın olan yarı sahadaki kişiler gözle daha seçilebilir haldeyken yarı sahanın diğer tarafındaki kişilerin gözle seçimi oldukça zordur. Saha ortamında yapay aydınlatma kullanılmakta ve saha etrafında tel örgüler ile örgüleri birbirine bağlayan direkler bulunmaktadır. Kameraya yakın olan kalede ise kale filesi bulunmaktadır. Halı saha zemini iki farklı ton yeşil renk içeren, orta saha ve ceza sahası çizgileri bulunan bir ortamdır.

Halı saha içerisindeki kişilerin özellikle kameraya yakın yarı saha bölgesinde kafa, gövde ve bacaklar gözle rahatlıkla ayırt edilebilmektedir.

3.2.2 Ortamın 3B olarak modellenmesi

Blender ile 3B ortam modelleme çalışmaları için Magevio Studio Youtube Kanalının “Making an Urban Street Soccer Court in Blender 2.81” video kayıdı işlem adımları takip edilmiştir (Studio 2020).

Halı saha zeminin 2B bir düzlemin üzerine futbol sahası çizgilerinin bindirilmesi, sahanın renklendirilmesi ve gerçek ortama benzeyecek halde hafif pürüzlü görüntüsü Blender yazılımının “shader editor” özelliği kullanılarak verilmiştir.

Shader editor, Blender yazılımının derleme işlemi için kullanılacak olan yapay materyalleri ekleyen, niteliklerini belirleyen ve materyalleri istenilen özellikler ile değiştirebilen modülleri içeren ve bu modülleri birbiri ile ilişkilendirebilen görsel bir editördür.

Halısaha duvarları, tel örgü direkleri ve kale direkleri temel Blender şekilleri olan 2B düzlem, 3B silindir ve 3B küp modellerinin işlenmesi ile oluşturulmuştur.

Desen içeren tel örgü ve kale filesi ise yine Blender temel modelleri olan 2B düzlem ve küp şekillerinden türetilmiş olup Blender içinde bir değiştirici (modifier) olan tel kafes çeviricisi (wireframe modifier) uygulanarak tel örgü ve kale filesi oluşturulmuştur.

Blender yazılımı kullanılarak oluşturulan ortamın özellikleri:

- Halı saha en 13m, boy 22,5 m
- Tel örgü yüksekliği yaklaşık 1,8 m
- Kale yüksekliği 2 m, genişliği 3 m
- Işıklandırma dört adet 5000 W noktasal ışık kaynağı
- Işıklandırma yerden yüksekliği 10,3 m
- Yeşil saha ve saha çizgileri

Oluşturulan halı saha modeli şekil 3.3 de gösterilmiştir.



Şekil 3.3 Halı saha modeli

Şekil 3.3, şekil 3.2'ye benzer halde yapılandırılmış 3B sanal halı saha modelidir. Bu modelde de Şekil 3.2'deki ortama benzer şekilde iki farklı yeşil tenk tonunda ve saha çizgileri olan zemin, kale direkleri, kale filesi, saha kenarındaki tel örgü, tel örgüleri taşıyan destek direkleri ve yapay ışıklandırma oluşturulmuştur.

3.2.3 Kişilerin 3B olarak modellenmesi

Sanal olarak sahadaki kişilerin modellenmesi birbiri ile ilişkili çok aşamalı ve zahmetli bir çalışmadır. 3B sanal kişi karakterinin oluşturulmasının yanında bu karakterin uygun bir şekilde hareket ettirilmesi de analitik çalışmalarında en uygun verinin alınması için çok önemlidir.

3B kişi modellemesi esnasında üç temel esas yer almaktadır bunlar;

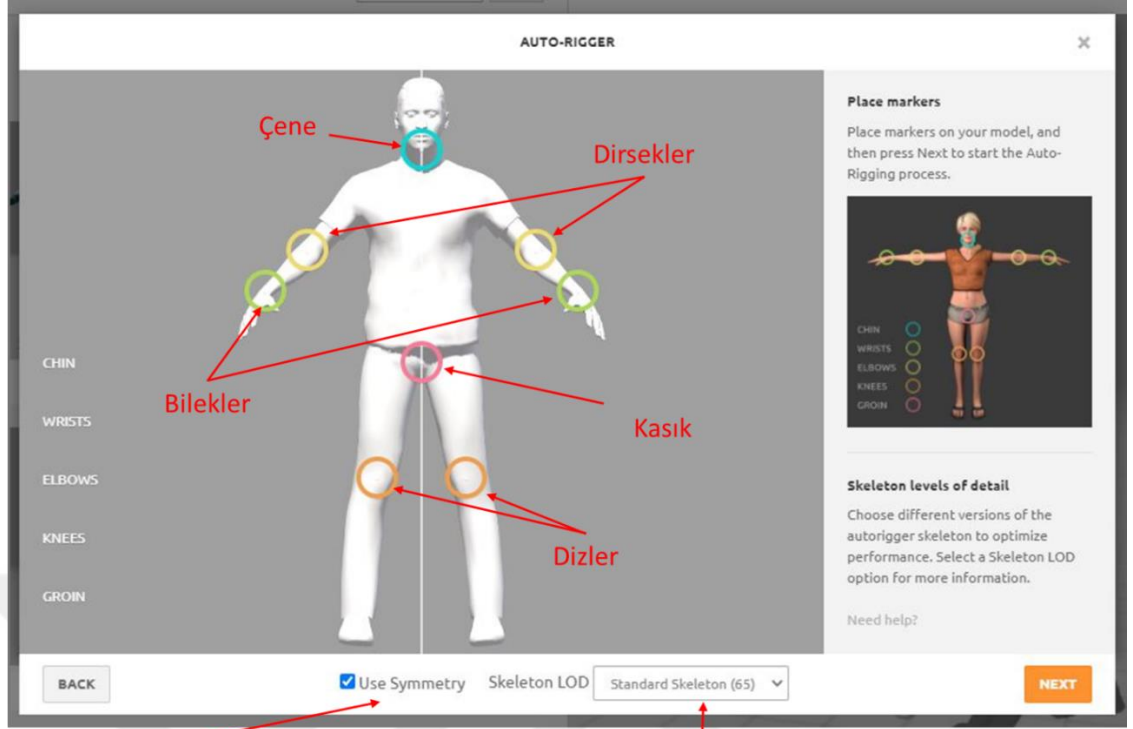
- Gerçek ortama benzeyen bir kişi karakterinin 3B modellenmesi
- Karakterin hareketlendirilmesi için sanal kemik ve eklem (armature) yapısının oluşturulması. Sanal kemik ve eklemler bir 3B modelin hareketlendirilmesi için gerekli olan temel bileşenlerdir. Sanal kemikler, içine yerleştirildiği 3B modelin

hareketlerini sağlar ve kendisine bağılı bulunan diğerk kemiklerin bağılandığı eklemler ile diğerk kemiklerin de hareketini tetikler. Örneğın sanal modelin el sallaması, el, dirsek ve hatta omuz eklemlerine kadar zincirleme hareket reaksiyonu gösteren çoklu hareketler silsilesidir.

- 3B modellenmiş karaktere istenilen temel hareketin kazandırılması. 3B olarak modellenmiş, kemik ve eklem ilişkileri oluşturulmuş olan modelin istenen vücut hareketlerinde video çerçevelerine göre pozisyonlanması işlemidir.

3B kişi modelleme konusunda genel kullanıma açık iki hazır ürün kullanılmıştır. Bunlardan birincisi MakeHuman açık kaynak kodlu yazılımıdır. MakeHuman yazılımında boy, kilo, yaş , ten rengi, cinsiyet, vücut yapısı, saç, kıyafet gibi fiziksel özellikler ayarlanarak oluşturulan 3B kişi modeli istenirse eklemleri ile beraber hazırlanabilmektedir.

Diğerk yazılım ise Adobe firmasının mixamo çevrimiçi uygulamasıdır. www.mixamo.com uygulamanın çalıştığı internet sitesidir. Bu sitede MakeHuman ya da benzeri bir şekilde hazırlanmış bir kişinin diz-kasık-el bilekleri-dirsek-çene noktaları belirtilerek kemik ve eklem eklenmesi sağlanabildiğı gibi sitede hazır bulunan bir karakter de kullanılabilir. Şekil 3.4’de tez çalışmasında kullanılan, MakeHuman yazılımı ile oluşturulmuş 3B kişi modelinin mixamo yazılımı ile eklemlerinin tanımlanma ekranı gösterilmiştir.



Diz-Dirsek-Bilek için simetri kullan

İskelet detay seviyesi (Level of Detail)

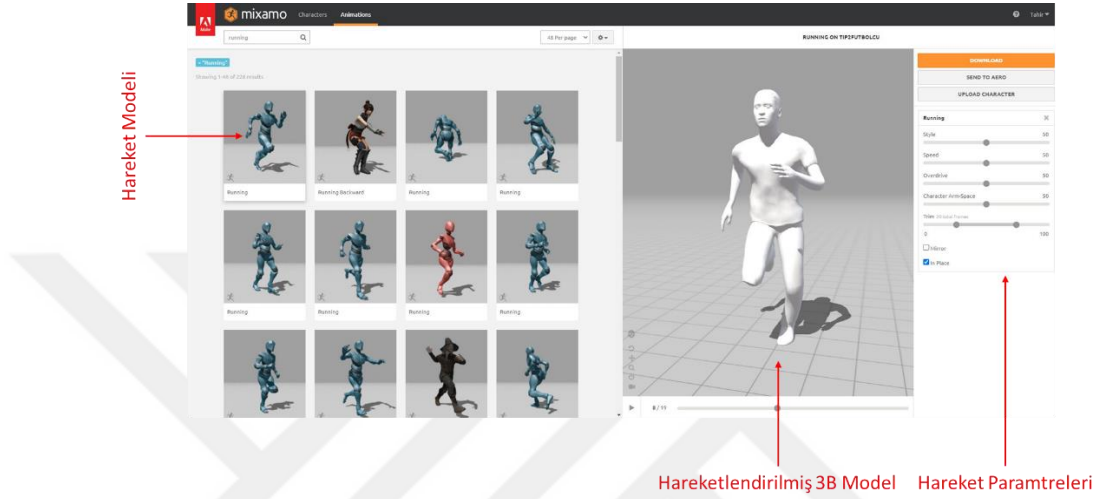
Şekil 3.4 Mixamo ile eklem tanımlama ekranı

Daha sonra seçilen bu karakter yine mixamo sitesinde bulunan koşu hareket modeli ile hareketlendirilmiştir. 3B kişi modelininin hareketlendirilmesinde kişinin yerinde veya yol katederek hareketi, hareket biçimi, hareket hızı, kol açıklığı ve harekette kaç video çerçevesinin kullanılacağı da yazılımda ayarlanabilmektedir. Hareket biçimi modelin koşu rahatlığını belirtmektedir, küçük değer daha sıkı ve aceleci, büyük değer ise rahat koşu biçimidir.

Oluşturulan ve hareketlendirilen kişinin tam bir döngü hareketi ve istenilen koşu formunda olduğu için mixamo uygulamasındaki değişkenler ilk değerlerinde bırakılmıştır. Bu değerler;

- Hareket biçimi: 50
- Birinci hız parametresi (speed) : 50
- İkinci hız parametresi (overdrive) : 50
- Karakter kol açıklığı (character arm space) : 50
- 20 video çerçevesi ile hareket

Modelin koşu hareketi bir döngüde yapılması gereken bütün vücut hareketlerini yapacak halde arka arkaya eklenmiş 20 çerçeve olarak belirlenmiştir. Bu bir döngüdeki hareketleri arka arkaya eklendiğinde koşu yapan bir insan animasyonu oluşturulabilmektedir. Şekil 3.5’de mixamo yazılımının 3B modelin hareketlendirme ekranı ve parametreleri gösterilmiştir.



Şekil 3.5 Mixamo ile hazırlanmış 3B hareketli model

Oluşturulan hareketli model Blender yazılımında kullanılmak üzere Bölüm 3.2.2 ‘ de anlatılan sahneye eklenmiş ve TeamCPlayer olarak adlandırılmıştır. Şekil 3.6’da modelin Blender yazılımındaki görüntüsü gösterilmektedir.



Şekil 3.6 TeamCPlayer

Blender programına eklenmiş olan modelin istenen animasyon süresi boyunca koşmasını sağlamak için yazılımın animasyon ekranından 3B kişi modelinin koşu hareketi uç uca kopyalanarak 610 video çerçevesi kadar devamlı koşması sağlanmıştır.

Deneme yolu ile belirlenen 610 video çerçevesi ile senaryo gereği bir grup kişinin beraberce koşu yaparak futbol sahasının tamamını kullanabilmesi sağlanmıştır.

Video çerçevesi sayısının belirlenmesini etkileyen faktörlerden bir diğeri ise derleme esnasında kaç video çerçevesi ihtiyaç olacaktır. Yapılan çalışmada kamera konumu ve kişilerin kamera görüşünde olmaları süresi kadar derleme işlemi yapılmıştır.

3.2.4 3B modellenmiş kişilerin ortamda hareketlendirilmesi

Bu işlem adımı bir grup kişinin istenen senaryoya göre 3B halı saha üzerinde koşturulmasıdır.

Bu çalışmada Blender yazılımının animasyon özelliklerinden parçacık sistemi (Blender particle system) özelliğinden faydalanılmıştır. Parçacık sistemi, bir parçacık üreticiden üretilen parçacıklar ve bunların hareket özelliklerini tanımlayan bir sistem olarak tanımlanabilir. Bu parçacıkların sayısı, hızı, hareket düzeni ve parçacıkların şekli Blender yazılımının ayar ekranları ile düzenlenmiştir.

Tez çalışmasında halı saha modeli içerisine konumlandırılmış bir adet 2B düzlem parçacık üretici olarak kullanılmıştır. Eğitim verisi oluşturulması için bu parçacık üreticiden çıkan parçacıklar Bölüm 3.2.3’ de oluşturulan 3B kişi modeli şeklinde ve bu kişi modelinin koşu hareketini taklit etmektedir. Oluşturulan yerinde koşan kişiler, ortama eklenmiş görünmez bir küreyi liderleri olarak takip edecek şekilde ayarlanmıştır. Görünmez kürenin hareketi , Blender yazılımın animasyon özelliği olan anahtar görüntü çerçevesi (keyframe) ile sahanın etrafında bir tur gezecek halde ayarlanmıştır. Halı sahanın etrafında gezen görünmez küreyi takip eden kişiler bu halde iken sahada koşu yapan grup senaryosunu tamamlamaktadır. Senaryonun bir başka bileşeni ise Blender yazılımında koşan kişilerin “sınırlı” serbestliğinin sağlanmasıdır. Sınırlı serbest hareketlilik, koşan kişilerin belirli kurallara göre rastgele hareketliliğidir . Bu kurallar,

koşan grubun sanal küreyi bir “sürü” halinde takip etmesi ve aynı zamanda belirlenmiş sosyal mesafe içinde kişilerin kendi hareketlerini bireysel olarak yapabilmesidir. Bu sayede ortamda koşan bir grup varken her bir birey kendi rastgele hareketini yapabilmektedir.


Tez çalışmasında eğitim verilerinin alınması için beş adet kişi çizelge 3.1’ de özellikleri belirtilen iki farklı ortamda koşturulmuştur.

Video ile test aşaması için ise aynı sahnede iki farklı ortam daha oluşturularak sekiz ve onüç kişilik gruplar koşturulmuştur. Oluşturulan test ortamlarından ilkinde sekiz kişilik grup kameraya doğru ilerleyen küreyi takip ederken diğer senaryodaki onüç kişilik grup iki farklı yarı sahaya dağılacak halde pozisyonlanmıştır.

Çizelge 3.1 Eğitim verisi için hazırlanan ortam bilgileri

	Birinci ortam	İkinci ortam
Kişi sayısı	5	5
Koşan grup sayısı	1	1
Hareket modeli	Mixamo erkek koşu modeli	
Hareket hızı	Lider küre hızına göre	
Hareket rotası	Kamera görüşüne göre uzak yarı sahanın sol köşesinden başlayarak kameraya yaklaşma, kamera önünde sağa dönüş, sahanın sağ kenarından uzaklaşma, sola dönüş ve karşı yarı saha kalesinin önünde bekleme	
Kişiler arası mesafe	0,55 m	0,55 m
Işık kaynağı sayısı	4	4
Işık tipi	Noktasal	Noktasal
Işık şiddeti	5000 W	5000 W
Kamera sayısı	1	1
Kamera konum (x,y,z)	x= 10,09 m y= -3,85 m z= 1,98 m	x= 12,284 m y= 6,69 m z= 4,12 m
Kamera açısı (x,y,z) °	x= 63,6° y= 0° z= 90,4°	x= 63,6° y= 0° z= 124°
Kamera lens açısı	23 mm	23 mm
Alınan toplam görüntü çerçevesi	610	600

Şekil 3.7’de eğitim verileri için hazırlanan birinci ortamın kamerasından, kameraya doğru ilerleyen lider küre ve bu küreyi takip eden beş adet koşu formundaki kişiler, bu kişilerin şekil ve hareketlerinin model olarak alındığı model kişi, ışık kaynakları ve parçacık üreticinin sahnedeki konumu gösterilmektedir. Derleme esnasında model kişi ve parçacık üretici gözükmeyecek halde ayarlama yapılmıştır.



Şekil 3.7 Sonuç ortam

Şekil 3.8'deki eğitim verileri için hazırlanan birinci ortam kamera görüşüne göre, kişiler sahanın başlangıç ucundan kameraya doğru koşarak yaklaşmakta bu esnasında kişilerin önden görüntüleri alınabilmektedir. Sağa dönüş yaparak kameranın önünden geçerken kişilerin yan görünüşleri elde edilebilmekte ve kameradan uzaklaşırken arka görüntüleri de alınabilmektedir.



Şekil 3.8 Birinci ortam kamera görüşü

Şekil 3.9'daki eğitim verileri için hazırlanan ikinci ortam kamera görüşüne göre, kişiler birinci kamera görüşüne göre biraz daha yüksekte ve koşan kişileri daha çok çapraz görüntülerini almaktadır.



Şekil 3.9 İkinci ortam kamera görüşü

(Hattori vd. 2015) çalışmasında oluşturulan çok sayıda 3B kişi modeli ön planda tutulmuş ancak model hareketlendirilmesi yapılmamış olup farklı açılarda ve yürüyüş modellerindeki heykel karakterler 3B sahnedeki önceden belirlenmiş konumlara yerleştirilmesi işlemleri yapılmıştır.

Bu tez çalışmasında grup halindeki kişilerin animasyonu ve belirlenen istikamette hareket ettirilmesi ön planda tutularak hareket halindeki modellerin olası her vücut hareketi durumu tespit edilebilir bir ortam oluşturulmuştur.

3.2.5 Hareketlendirilmiş ortamın 3B derleme işleminin yapılması ve kişilerin konumlarının belirlenmesi

(Hattori vd. 2015) çalışmasında da belirtildiği üzere 3B ortam üzerinde yapılan her işlem matematiksel olarak tanımlanabilmekte ve sahnedeki bütün kişilerin konumları net olarak bilinmektedir. Kişilerin konumlarının bilinmesi eğitim verilerinin kolaylıkla elde edilmesi açısından çok önemli bir konudur. Genel amaçlı eğitim setlerinde bu gibi

verilerin elde edilmesi oldukça zahmetlidir ve elde edilen eğitim verilerinin hassasiyeti 3B modellemeden elde edilen veriler kadar hassas olmayabilir.

Blender yazılımı, hazır menü fonksiyonları kullanılarak modelleme/animasyon işlemlerinin yapılmasını sağladığı gibi Python programlama dilinin kullanılmasına da olanak sağlamaktadır.

Çalışmanın bu safhasında DVM öğrenme için gerekli olan pozitif eğitim veri setinin hazırlanması amacıyla kişilerin sahnedeki konumlarının belirlenmesi ve bu işlem sırasında da derleme işleminin yapılması için ihtiyaca yönelik bir program yazılmıştır.

(Hattori vd. 2015) çalışmasında sahnedeki sabit lokasyonlara farklı kişi modelleri konumlandırılmış ve bu modeller saha sonra eğitim verisi olarak ayıklanmıştır. Bu tez çalışmasında hareketli kişi modellerinin hangi görüntü çerçevesinde nerede olduğu tespit edilmiş ve buradan eğitim verisi oluşturmak için çevreleyen kutu konum bilgileri oluşturulmuştur.

Hazırlanan yazılımda hareket halindeki kişilerin 3B uzayda konumları tespit edilmekte, kamera görüşüne göre 3B kişiyi çevreleyen bir kutunun 2B izdüşümünü alınabilmekte ve ve bu kutunun 2B kamera görüşüne göre konumları kayıt altına alınabilmektedir.


Derleme faaliyeti; her bir video görüntüsünü ayrı birer görüntü olarak kayıt edilecek halde ayarlanmıştır. Sonraki aşamada bu görüntülerde bulunan kişiler pozitif eğitim seti oluşturmak üzere kırılmaktadır.

Her bir görüntü içerisinde bulunan kişilerin konumuna göre çevreleyen kutu konum bilgileri, kişinin bulunduğu görüntünün dosya adı bilgisi ile beraber bir dizi halinde ayrı bir dosyaya kaydedilmiştir.

3B modellenmiş ortamdaki kişilerin konumlarının belirlenmesi ve bunların 2B ekran görüntüsü üzerindeki izdüşümlerinin elde edilmesi için blender.stackexchange.com sitesindeki iki çalışmadan faydalanılmıştır (Blender 2020) (Blender 2020).

Bir görüntü çerçevesi üzerinde yapılan işlemler Şekil 3.10'da gösterilen işlem maddeleri ile beraber aşağıda belirtilmiştir;

- Parçacık üreticini seç.
- Parçacık üretici nesnesindeki “parçacık sistemi” ni aktif et.
- Parçacık grubu içerisindeki bir kişinin konumunu belirle (Şekil 3.10 bir numaralı işlem).
- Kişiyi çevreleyecek halde geçici bir 3B çevreleyen kutu oluştur. Çevreleyen kutu, bağımsız ve tek parça bir bileşen olduğu için bu nesnenin konum bilgisi alınabilmekte 2B kamera izdüşümü elde edilebilmektedir.
- Çevreleyen kutuyu kişinin tam olarak bulunduğu yere yerleştir (Şekil 3.10 iki numaralı işlem).
- Sahne bilgisi, kamera nesnesi ve çevreleyen kutu bilgilerini kullanarak kutunun kamera görünümündeki 2B izdüşümü yani çevreleyen çerçeve bilgilerini kutunun sol üst köşesi konumu (x,y) , x noktasından sağa doğru uzaklık (*genişlik*), y noktasından aşağıya doğru uzaklık (*yükseklik*) formatında al ve bir dosyaya yaz. (Şekil 3.10 üç numaralı işlem).
- Geçici kutuyu sil (Şekil 3.10 dört numaralı işlem).
- Göründeki bütün kişilerin 2B çevreleyen çerçeve bilgilerini aldıktan sonra görüntüyü derle ve kayıt et. (Şekil 3.10 beş numaralı işlem).
- Kayıt edilmiş görüntünün dosya ismini bir dosyaya yaz.
- Bir sonraki görüntüye geç.



Şekil 3.10 İşlem adımları

3.2.6 Eğitim için veri seti oluşturma

Eğitim safhasında DVM için gerekli olan pozitif eğitim seti yani eğitmek istediğimiz kişilerin görüntülerini içeren görüntü seti, bunu yanında pozitif eğitim setinden daha fazla sayıda olan negatif eğitim seti kullanılmıştır.

Pozitif eğitim setinde kişi modelleri, negatif eğitim setinde ise içinde kişi bulunmayan görüntüler kullanılmıştır.

Pozitif eğitim veri setini oluşturmak için Bölüm 3.2.5' de anlatılan işlem adımları neticesinde elde edilmiş görüntüler ve görüntüde yer alan her bir kişiyi çevreleyen çerçeve konumları bilgisini içeren ayrı bir dosya bulunmaktadır. Pozitif eğitim görüntülerinin oluşturulması için temel olarak her bir görüntü içindeki kişi karakteri

görüntü içinden kırılarak 64x128 piksel boyutuna getirilmiş içinde kişileri barındıran görüntüler hazırlanmıştır. Elde edilen görüntülerden uygun olanları seçmek için en boy oranı (aspect ratio) 1:2 olan ve çevreleyen çerçevenin kapsadığı alan 400 pikselden büyük olan görüntüler seçilmiştir. Eleme işleminden sonra gözle kontrol yapılarak uygun gözükmeyen görüntüler tekrar elenmiştir.


Negatif eğitim seti ise Daimler yaya eğitimi için hazırlanmış olan “NonPedestrians” veri seti (Anonymous 2020) ve 3B ortamda bulunan ve içinde kişi karakteri bulunmayan sentetik futbol sahası görüntüleri kullanılmıştır.

Negatif veri seti görüntülerinin her biri 64x128 piksel olarak yeniden boyutlandırılmıştır.

Şekil 3.11’de sentetik negatif veri seti için kullanılan üç farklı açıdan alınmış halı saha görüntüleri gösterilmiştir. Şekil 3.12’de ise bu halı saha görüntülerinden elde edilmiş 64x128 negatif veri seti örnekleri gösterilmektedir. Sentetik negatif veri imgelerinin oluşturulması için kayan pencere ve görüntü piramiti teknikleri kullanılmıştır.



Şekil 3.11 Sentetik negatif veri setinin oluşturulduğu görüntüler




Şekil 3.12 Örnek sentetik negatifler

Pozitif eğitim veri setinin oluşturulması için hazırlanan yazılımın işleyişi aşağıdaki gibidir;


- Çevreleyen kutu konum bilgisinin olduğu dosyayı aç bilgileri diziye aktar
- Derlenmiş görüntü bilgilerinin olduğu dosyayı aç bilgileri diziye aktar
- Konum bilgisini barındıran dizinin uzunluğu kadar bir döngü oluştur
- Görüntüyü yükle
- Kutu konum bilgisine göre görüntünün ilgili bölgesini kırp
- Kırpılan görüntü parçasını siyah-beyaz olarak değiştir
- Geçişleri yumuşatmak için bulanıklaştırma filtresi uygula
- Kırpılan görüntüyü 64x128 piksel boyutlarına getir
- Kırpılan görüntüyü farklı isimle kaydet
- Bir sonraki görüntü bilgisi ve konum bilgisine göre yukarıdaki işlemleri tekrarla

işlem adımları şekil 3.13’de belirtilmiştir.



Şekil 3.13 Pozitif veri seti oluşturma işlem adımları

Şekil 3.14'den de görüldüğü üzere iki farklı kamera görüşünden elde edilen ve sahanın farklı bölgelerinde koşan kişilerin görüntüleri bütün vücut hareketlerini içerecek şekilde elde edilmiştir.



Şekil 3.14 Örnek pozitif veri seti

3.3 Öznitelik Çıkarma

Öznitelik çıkarma aşamasında YGH, ÖBÖD, HGÖ ve YİÖ algoritmaları kullanılmıştır. Öznitelik çıkarma aşamasında her bir algoritmanın gereklerine göre ayrı yazılımlar hazırlanmıştır. Her bir algortmada aranan öznitelikler, eğitim veri seti için kullanılan görüntülerin sayısı ve veri setindeki görüntülerin özelliklerine uygun olarak optimizasyonlar yapılmıştır. ÖBÖD ve HGÖ algoritmalarında dikkate alınan anahtar noktaların sayısı için farklı denemeler yapılmış olup eldeki eğitim veri setlerinden en üst seviyede faydalanılacak halde anahtar nokta sayısı deneme yolu ile belirlenmiştir. Az sayıda anahtar noktaya göre öznitelik çıkarımı çok eğitim verisi ile eğitim imkanı tanınmasına rağmen hatalı bulma sayısını arttırmıştır. Çok sayıda anahtar noktaya göre yapılan çalışmada ise daha az sayıda eğitim verisinden faydalanılmasına neden olmuştur. Yapılan çalışmada eğitim verisi sayısı ve doğruluk dengesine göre uygun anahtar nokta sayısı belirlenmiştir.

Sentetik negatiflerin katkısının ölçümlenebilmesi için sentetik negatiflerin dahil edildiği ve edilmediği durumlar için ayrı öznitelikler oluşturulmuştur.

Öznitelik çıkarılması için 1747 adet pozitif, 6744 adet hazır negatif ve 1671 adet sentetik negatif görüntü kullanılmıştır.

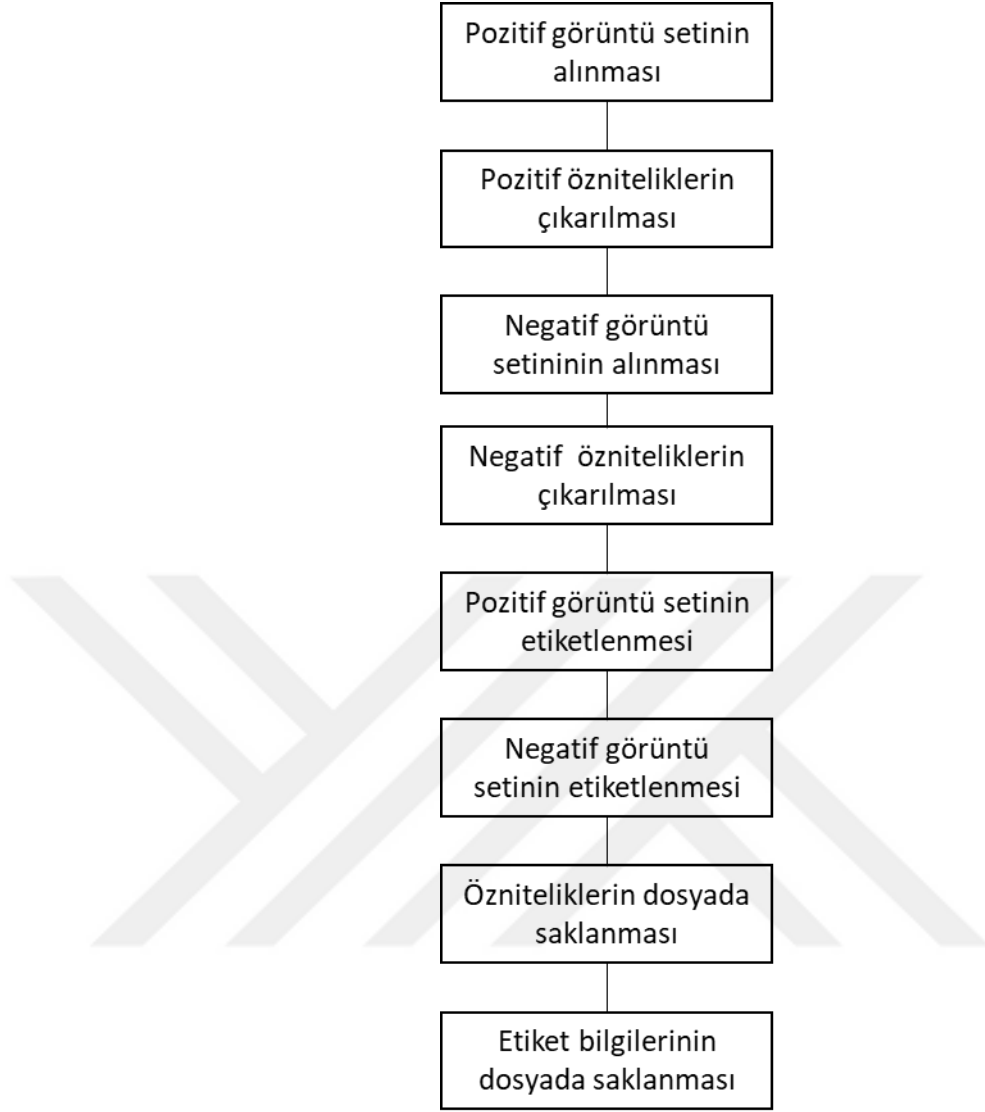
3.3.1 YGH uygulaması gerekleřtirimi

YGH 6zniteliklerinin ıkarılması uygulaması iin bu konu ile ilgili yapılmıř olan alıřma (Fazel ve Vo 2016) ve bu alıřmada kullanılan yazılım baz alınmıřtır (Fazel 2016).

řekil 3.15’de de g6sterildiđi 6zere YGH 6zniteliklerinin ıkarılması iin takip edilen iřlem adımlarının detayları ařađıda tanımlandıđı gibidir;

- Pozitif eđitim setindeki g6r6nt6y6 al.
- G6r6nt6y6 siyah-beyaz formata evir.
- YGH algoritması iin python yazılımında kullanılan skimage k6t6phanesinin 9 y6nelimli, bir h6crede (8,8) yani toplam altmıřd6rt piksel ve bir blokta (2,2) yani toplam d6rt h6cre olacak halde g6r6nt6n6n YGH 6zniteliklerinin ıkartı.
- ıkarılan 6znitelikleri bir diziyeye ekle.
- Yukarıdaki iřlemleri negatif eđitim seti iin de yap.
- Pozitif ve negatif eđitim setlerinin etiketlenmesi iin 6nce pozitif g6r6nt6 seti dizisi uzunluđu kadar artı bir sonra negatif g6r6nt6 seti dizisi uzunluđu kadar eksi bir deđerini vererek bir etiket dizisi oluřtur.
- 6znitelik ve etiket dizilerini eđitim safhasında kullanılmak 6zere dosyaya yazdır.

YGH 6zniteliklerin ıkarılması ařamasında 1747 pozitif ve sentetik ierik yokken 6744, sentetik ierik varken toplam 8415 negatif g6r6nt6n6n 6znitelikleri ıkarılabilmifitir.



Şekil 3.15 YGH öznitelik çıkarma işlem adımları


3.3.2 ÖBÖD uygulaması gerçekleştirimi

Şekil 3.16'da da gösterildiği üzere ÖBÖD özniteliklerinin çıkarılması için takip edilen işlem adımlarının detayları aşağıda tanımlandığı gibidir. Hazırlanan yazılımda python programlama dilinde ÖBÖD öznitelik çıkarılması için gerekli fonksiyonların kullanımı için (Kaggle 2016)'dan ve ortak yazılım althığı oluşturmak için (Fazel 2016)'dan faydalanılmıştır.

- Pozitif eğitim setindeki görüntüyü al.
- Görüntüyü siyah-beyaz formata çevir.

- ÖBÖD öznitelikleri bilgisini alan yazılım nesnesini oluştur.
- Yazılım nesnesi kullanılarak görüntünün anahtar noktalarını (keypoint) ve tanımlayıcılarını (descriptor) çıkar.
- Anahtar nokta sayısı 15'den küçük olan görüntüleri dikkate alma.
- Anahtar nokta sayısı 15 veya 15'den fazla olan görüntülerin ilk 15 değerini al.
- Vektör verisini 1920 elemanlı tek boyutlu dizi haline getir.
- Vektör verisini eğitim veri seti dizisine ekle.
- Aynı çalışmayı negatif eğitim seti için de yap.
- Çıkarılan öznitelikleri bir diziye ekle.
- Pozitif ve negatif eğitim setlerinin etiketlenmesi için önce pozitif görüntü seti dizisi uzunluğu kadar artı bir sonra negatif görüntü seti dizisi uzunluğu kadar eksi bir değeri vererek bir etiket dizisi oluştur.
- Öznitelik ve etiket dizilerini eğitim safhasında kullanılmak üzere dosyaya yazdır.

ÖBÖD özniteliklerin çıkarılması aşamasında 1747 pozitif ve sentetik içerik yokken 6686 negatif, sentetik içerik varken toplam 7134 negatif görüntünün öznitelikleri çıkarılabilmektedir.




Şekil 3.16 ÖBÖD öznitelik çıkarma işlem adımları

3.3.3 HGÖ uygulaması gerçekleştirimi

Şekil 3.17'de de gösterildiği üzere HGÖ özniteliklerinin çıkarılması için takip edilen işlem adımlarının detayları aşağıda tanımlandığı gibidir. Hazırlanan yazılımda python programlama dilinde HGÖ öznitelik çıkarılması için gerekli fonksiyonların kullanımı için (Canu 2018)'den ve ortak yazılım altlığı oluşturmak için (Fazel 2016)'dan faydalanılmıştır.

- Pozitif eğitim setindeki görüntüyü al.
- Görüntüyü siyah-beyaz formata çevir
- HGÖ öznitelikleri bilgisini alan yazılım nesnesini oluştur.
- Yazılım nesnesi kullanılarak görüntünün anahtar noktalarını ve tanımlayıcılarını çıkar.
- Anahtar nokta sayısı 14'den küçük olan görüntüleri dikkate alma.
- Anahtar nokta sayısı 14 veya 14'den fazla olan görüntülerin ilk 14 değerini al.
- Vektör verisini 896 elemanlı tek boyutlu dizi haline getir.
- Vektör verisini eğitim veri seti dizisine ekle.
- Aynı çalışmayı negatif eğitim seti için de yap.
- Çıkarılan öznitelikleri bir diziye ekle.
- Pozitif ve negatif eğitim setlerinin etiketlenmesi için önce pozitif görüntü seti dizisi uzunluğu kadar artı bir sonra negatif görüntü seti dizisi uzunluğu kadar eksi bir değeri vererek bir etiket dizisi oluştur.
- Öznitelik ve etiket dizilerini eğitim safhasında kullanılmak üzere dosyaya yazdır.

HGÖ özniteliklerin çıkarılması aşamasında 1747 pozitif ve sentetik içerik yokken 6632 negatif, sentetik içerik varken toplam 6973 negatif görüntünün öznitelikleri çıkarılabildiği görülmüştür.




Şekil 3.17 HGÖ öznitelik çıkarma işlem adımları

3.3.4 YİÖ uygulaması gerçekleştirimi

Şekil 3.18'de de gösterildiği üzere YİÖ özniteliklerinin çıkarılması için takip edilen işlem adımlarının detayları aşağıda tanımlandığı gibidir. Hazırlanan yazılımda python programlama dilinde YİÖ öznitelik çıkarılması için gerekli fonksiyonların kullanımı için (Rosebrock 2015)'den ve ortak yazılım altlığı oluşturmak için (Fazel 2016)'dan faydalanılmıştır.

- Pozitif görüntü eğitim setindeki görüntüyü al.
- 24 (P) nokta 8 (R) yarıçap değerinde bir biçimli yönteminde YİÖ tanımlayıcı yazılım nesnesini yarat
- Görüntüyü siyah-beyaz formata çevir.
- Görüntünün histogramlarını oluştur.
- Histogram verisini eğitim veri seti dizisine ekle.
- Aynı çalışmayı negatif eğitim seti için de yap.
- Pozitif ve negatif eğitim setlerinin etiketlenmesi için önce pozitif görüntü seti dizisi uzunluğu kadar artı bir sonra negatif görüntü seti dizisi uzunluğu kadar eksi bir değeri vererek bir etiket dizisi oluştur.
- Öznitelik ve etiket dizilerini eğitim safhasında kullanılmak üzere dosyaya yazdır.

YİÖ özniteliklerin çıkarılması aşamasında 1747 pozitif ve sentetik içerik yokken 6744 negatif, sentetik içerik varken toplam 8415 negatif görüntünün öznitelikleri çıkarılabildiği görülmüştür.



Şekil 3.18 YİÖ öznitelik çıkarma işlem adımları

3.4 DVM Eğitim

3.4.1 DVM eğitim ve test uygulaması

DVM eğitimi için her algoritma için en iyi test sonuçlarının elde edildiği çekirdek tipi araştırılmıştır. Bu çalışmada sentetik negatiflerin eklendiği ve eklenmediği durumlar da gözlemlenmiştir.

En uygun çekirdeğin ve çekirdek parametrelerinin araştırılması için Bölüm 3.3’de elde edilen öznitelik ve etiket dosyaları kullanılarak yapılan testler için eğitim verilerinin % 30’u kullanılmıştır.

Test sonucu olarak kontrol edilen deęerler doęruluk (accuracy) deęeri, pozitif verilerin negatif olarak iřaretlenmemesi ölçütü olan hassasiyet (precision) deęeri ve bütün pozitif verileri bulabilme ölçütü olan geri çağırma (recall) deęerleridir.

DVM eğitimi için python programlama dilinin sklearn kütüphanesi altındaki svm uygulaması kullanılmıştır (Fazel 2016).

DVM testi için python programlama dilinin sklearn kütüphanesi altındaki train_test_split ve metrics uygulamaları kullanılmıştır.

Çizelge 3.2’de yapılan çalışma ile elde edilen en iyi DVM eğitim test sonuçları gösterilmiştir. Test sonuçlarında elde edilen doęruluk, hassasiyet ve geri çağırma deęerlerinde bir en iyi deęer, sıfır en kötü deęerdir. En uygun çekirdeęi bulma çalışmasında doęruluk, hassasiyet ve geri çağırma deęerlerinde bir deęerine en yakın çekirdek tipi ve regülasyon (C) parametresi araştırılmıştır.

YGH ve YİÖ için en uygun deęerlerin elde edildięi çekirdek türü doğrusal iken ÖBÖD ve HGÖ için üçüncü dereceden polinom çekirdek türü ile en iyi test deęerleri elde edilmiştir.

Çizelge 3.2’ ye bakıldığında YGH algoritması verileri ile yapılan DVM eğitim en yüksek deęerleri vermiştir. YGH algoritmasını takiben sıra ile YİÖ, HGÖ ve ÖBÖD algoritmaları ile yapılan DVM eğitim sonuçları yer almaktadır. Bunun yanında eklenen sentetik negatifler YGH algoritması dışındaki algoritmalar için doęruluk, hassasiyet ve geri çağırma deęerlerinin azalmasına neden olmuştur.

Çizelge 3.2 DVM çekirdekleri ve test sonuçları

		Çekirdek türü	Regülasyon	Doğruluk değeri	Hassasiyet değeri	Geri çağırma değeri
Sentetik negatifler yokken	YGH	Doğrusal	100,0	1,0	1,0	1,0
	ÖBÖD	3. derece polinom	20,0	0,946245059288537	0,892929292929292	0,8419047619047619
	HGÖ	3. derece polinom	20,0	0,9542561654733492	0,9076305220883534	0,8675623800383877
	YİÖ	Doğrusal	5,0	0,9976452119309263	0,998046875	0,9903100775193798
Sentetik negatifler varken	YGH	Doğrusal	100,0	1,0	1,0	1,0
	ÖBÖD	3. derece polinom	20,0	0,9474671669793621	0,8813905930470347	0,8401559454191033
	HGÖ	3. derece polinom	20,0	0,950688073394495	0,8872950819672131	0,854043392504931
	YİÖ	Doğrusal	5,0	0,9967202361429977	0,995975855130784	0,9840954274353877

3.5 Video ile Test

Video ile test aşaması;

- Sentetik ortamdan elde edilen verilerle eğitim yaparak gerçek ortamda kişi bulunabiliyor mu?
- YGH, ÖBÖD, HGÖ ve YİÖ algoritmalarının karşılıklı performansları nasıldır?
- Sentetik negatiflerin dahil edilmesinin analize etkisi var mıdır?
- 3B ortamda gerçekleştirilen video analizine bakılarak gerçek ortam analizi ile ilgili çıkarım yapılabilir mi?

sorularına yanıt bulabilmek için gerçekleştirilen çalışmadır.

Video ile test aşamasında iki adet 3B modellenmiş ortam ve üç adet gerçek ortam video kayıtları kullanılmıştır.

Test edilen video kayıtlarının herbiri 150 video çerçevesidir.

Kişilerin tespit edilmesi için izlenen temel aşamalar Bölüm 3.5.1, Bölüm 3.5.2 ve Bölüm 3.5.3’de belirtildiği gibidir. Test aşaması için (Fazel 2016)’dan faydalanılmıştır.

Video ile test çalışmasında iyi sonucu elde etmek için saha üzerindeki hareketli kısımlar üzerinde analitik çalışmalar yapılmıştır, bunun için arka plan çıkarılması ve kontur uygulamalarından faydalanılmıştır. yapılan işlem detayları ise aşağıdaki gibidir;

- Video dosyasının açılması.
- Video çerçevesinden arka planın MoG tekniği kullanılarak çıkarılması.
- Arka planı çıkarılmış görüntüde benzerlik gösteren noktaları dikdörtgen olarak birleştirmek için kontur uygulamasının yapılması.
- Kontur uygulaması yapılan her yerde merkezinde kontur dikdörgeinin bulunduğu alan olmak üzere (64,128) piksel boyutlarındaki görüntü alanının analiz için kırılması.

- Kırpılan alanın YGH, ÖBÖD, HGÖ ve YİÖ algortması kullanılarak özniteliklerinin çıkarılması ve çıkarılan özniteliklere göre DVM öngörüsünün gerçekleştirilmesi
- YGH, ÖBÖD, HGÖ, YİÖ ile bulma sürelerinin kayıt edilmesi.
- DVM öngörüsü ile bulunan alanların diziye aktarılması.
- Yukarıdaki işlemlerin video çerçevesindeki bütün konturlar için uygulanması
- Bulunan alanların sadeleştirilmesi için NMS uygulamasının yapılması ve görüntüde işaretlenmesi.
- İşaretlemeleri ve toplam bulma adet bilgilerini içeren sonuç görüntüsünün ve diğer analiz sonuçlarının kayıt altına alınması.
- Bu işlemlerin 150 video çerçevesi için tekrarlanması.

Kayıt altına alınan veriler içeriğinde, her bir algoritmanın video çerçevesinde bulunduğu kişi sayısı ve video çerçevesinde harcanan zaman bulunmaktadır. Bu veriler karşılaştırmalı performans değerlendirmesi için kullanılmıştır.


Video ile test çalışmaları için üç farklı aydınlatma ve saha ortamına sahip gerçek ortam ve bu ortamlara benzer olarak hazırlanmış iki farklı 3B animasyon kullanılmıştır. Şekil 3.19'da da gösterildiği üzere her bir algoritmanın bulunduğu sonuçlar aynı video çerçevesinde gösterilmiş ve kayıt edilmiştir. Şekil 3.19.a' da gösterilen 3B ortamında sekiz kişinin kameraya doğru rastgele koştuğu bir senaryo hazırlanmıştır. Hazırlanan ortamda kamera konumu gerçek ortam görüntülerine benzer şekilde her iki kaleyi gören ancak kameranın bulunduğu yerdeki saha köşesi görüşte olmayacak halde ayarlanmış olup hazırlanan animasyonda sahanın dört köşesinde 5000 W gücünde noktasal ışık kaynakları bulunmakta olup gölgelendirme özelliği uygulanmamıştır. Şekil 3.19.b' de gösterilen ikinci 3B animasyonda ise onüç kişi sahanın daha çok ortasında ve rastgele koşacak halde ayarlanmıştır. İkinci 3B ortamında ayrıca birinci gerçek ortama göre histogram eşleme işlemi yapılmıştır. Şekil 3.19.c birinci gerçek ortamda onüç, Şekil 3.19 d ikinci gerçek ortamda onüç ve şekil 3.19.e üçüncü gerçek ortamda onbir kişi video analizinde bulunması beklenen kişilerdir. Gerçek ortam görüntülerinde kameraya göre uzakta olan kaleci video analizi kapsamı dışında tutulmuştur.




(a) 3B modellenmiş birinci ortam



(b) 3B modellenmiş ikinci ortam



(c) Birinci gerçek ortam



(d) İkinci gerçek ortam



(e) Üçüncü gerçek ortam

Şekil 3.19 Video test ortamları

Yazılım aracılığı ile elde edilen kayıt sonuçları için ayrıca bir kayıt tablosu da oluşturulmuştur. Kayıt tablosu içeriğinde;

- Video çerçeve numarası
- YGH ile bulunan kişi sayısı
- ÖBÖD ile bulunan kişi sayısı
- HGÖ ile bulunan kişi sayısı
- YİÖ ile bulunan kişi sayısı
- YGH ile bulma süresi
- ÖBÖD ile bulma süresi
- HGÖ ile bulma süresi
- YİÖ ile bulma süresi

bilgileri bulunmaktadır.

Video analizi esnasında yazılım sonuçları ile elde edilen bilgilerin yanında çalışmada kullanılan video örneklerinde her bir algoritma için;

- Doğru bulunan kişi sayısı
- Yanlış bulunan kişi sayısı
- Doğru bulma oranı
- Hata oranı

ve bütün algoritmaların toplamının performansının aynı görüntü karesinde değerlendirdiği ve toplam olarak isimlendirildiği sonuçların değerlendirilmesi için;

- Toplam bulunan kişi sayısı
- Toplam yanlış bulunan kişi sayısı
- Toplam kişi bulma oranı
- Toplam kişi bulma hata oranı

bilgileri de gözle kontrol yapılarak her bir video görüntüsü için eklenmiştir.

Çerçevenin çevrelediği alan içerisinde kişinin olmaması veya işaretli alan içerisinde kişinin gölgesinin büyük oranda görüldüğü alanlar ise yanlış bulma olarak kabul edilmiştir.


Yapılan değerlendirme çalışmasının bir örneği olarak şekil 3.20 örnek analiz görüntüsüne göre elde edilen işaretlemelere göre YGH algoritmasının sonuçları şöyledir;

- Toplam bulunan kişi sayısı: 9
- Yanlış bulunan kişi sayısı: 2
- Doğru bulunan kişi sayısı: toplam bulunan kişi (9) – yanlış bulunan kişi (2) = 7
- Doğru bulma oranı: % (doğru bulunan kişi (7) / toplam kişi sayısı (13)) = % 69
- Hata oranı: % (yanlış bulunan kişi (2) / toplam bulunan kişi (9)) = % 22
- YGH zaman: 0,589580535888671 sn

video çerçevesine bakıldığında elde edilen toplam değerler;

- Toplam bulunan kişi sayısı: 10
- Toplam yanlış bulunan kişi sayısı: 2
- Toplam kişi bulma oranı: % (doğru bulunan kişi (10) / toplam kişi sayısı (13)) = % 77
- Toplam kişi bulma hata oranı: % (yanlış bulunan kişi (2) / toplam bulunan kişi (10)) = % 20

YGH Yanlıř Bulunanlar



řekil 3.20 rnek analiz grnts

4. ARAŞTIRMA BULGULARI

Bölüm 3.5 video ile test başlığı altında anlatılan ortamın hazırlanması ile YGH, ÖBÖD, HGÖ ve YİÖ öznitelik çıkarma algoritmalarının sonuçları aynı video görüntüsü üzerinde bulunduğu, yanlış bulunduğu veya bulamadığı kişiler ortaya çıkmaktadır. Buradan elde edilen verilere göre her bir algoritmanın;

- Doğru bulunduğu kişi sayısı
- Yanlış bulunduğu kişi sayısı
- Doğruluk oranı
- Yanlış bulma oranı
- Karşılaştırmalı hız değerlendirmesi
- Sentetik negatiflerin analize etkisi
- 3B model ile gerçek ortamlar arasındaki ilişki durumu

analizleri yapılmıştır.

Hazırlanan yazılımlarda hız artırma odaklı bir çalışma yapılmadığı için elde edilen hız değerleri karşılaştırmalı değerler olarak düşünülmelidir.

4.1 Doğru Bulunan Kişiler ve Sentetik Negatiflerin Etkisi

Doğru bulunan kişi, ilgili algoritmanın bir görüntüde bulunduğu toplam kişi sayısından yanlış bulmaların çıkarılması ile elde edilen değerdir.

Buna göre çizelge 4.1' de sentetik negatiflerin dahil edilmediği durumda sahadaki kişilerin ortalama olarak doğru bulunma adetleri ve bunların yüzde değerleri, çizelge 4.2'de ise sentetik negatifler dahil edildiği durumda iken kişi bulma adet ve yüzde değerleri ve son olarak çizelge 4.3'de 4.1 ve 4.2 çizelgelerinden elde edilen veriler doğrultusunda sentetik negatiflerin doğru bulmaya etkisi gösterilmiştir.

Çizelge 4.1 Sentetik negatifler yokken doğru bulunan kişiler çizelgesi

	Sentetik negatifler yokken doğru bulunan kişiler										
	3B		İkinci 3B		Birinci video		İkinci video		Üçüncü video		Ortalama
	Kişi	Yüzde	Kişi	Yüzde	Kişi	Yüzde	Kişi	Yüzde	Kişi	Yüzde	Yüzde
Sahadaki kişi sayısı	8		13		13		13		11		
YGH	3,423	% 42,79	6,201	% 47,70	6,174	% 47,50	6,705	% 51,57	4,671	% 42,46	% 46,40
ÖBÖD	2,772	% 34,65	5,369	% 41,30	4,081	% 31,39	3,356	% 25,81	3,195	% 29,04	% 32,44
HGÖ	1,772	% 22,15	3,758	% 28,91	4,007	% 30,82	4,329	% 33,30	3,282	% 29,84	% 29,00
YİÖ	3,322	% 41,53	5,611	% 43,16	6,497	% 49,97	6,067	% 46,67	5,557	% 50,52	% 46,37
Toplam	5,121	% 64,01	8,027	% 61,74	7,342	% 56,48	7,973	% 61,33	6,940	% 63,09	% 61,33

8

Çizelge 4.2 Sentetik negatifler varken doğru bulunan kişiler çizelgesi

	Sentetik negatifler varken doğru bulunan kişiler										
	3B		İkinci 3B		Birinci video		İkinci video		Üçüncü video		Ortalama
	Kişi	Yüzde	Kişi	Yüzde	Kişi	Yüzde	Kişi	Yüzde	Kişi	Yüzde	Yüzde
Sahadaki kişi sayısı	8		13		13		13		11		
YGH	3,443	% 43,04	6,174	% 47,50	6,255	% 48,12	6,772	% 52,09	4,550	% 41,37	% 46,42
ÖBÖD	2,705	% 33,81	5,148	% 39,60	4,107	% 31,60	3,389	% 26,07	3,107	% 28,25	% 31,86
HGÖ	1,752	% 21,90	3,658	% 28,14	3,893	% 29,94	4,302	% 33,09	3,107	% 28,25	% 28,26
YİÖ	3,275	% 40,94	5,987	% 46,05	6,537	% 50,28	6,094	% 46,88	5,523	% 50,21	% 46,87
Toplam	5,141	% 64,26	8,121	% 62,47	7,805	% 60,04	8,181	% 62,93	7,027	% 63,88	% 62,72

Çizelge 4.3 Sentetik negatiflerin doğru bulmaya etkisi

Sentetik negatiflerin doğru bulmaya etkisi						
	3B	İkinci 3B	Birinci video	İkinci video	Üçüncü video	Ortalama
YGH	% 0,25	-% 0,21	% 0,62	% 0,52	-% 1,10	% 0,02
ÖBÖD	-% 0,84	-% 1,70	% 0,21	% 0,26	-% 0,79	-% 0,57
HGÖ	-% 0,25	-% 0,77	-% 0,88	-% 0,21	-% 1,59	-% 0,74
YİÖ	-% 0,59	% 2,89	% 0,31	% 0,21	-% 0,31	% 0,50
Toplam	% 0,25	% 0,72	% 3,56	% 1,60	% 0,79	% 1,39

Çizelge 4.1'e bakıldığında sahadaki kişileri doğru bulma oranlarının en iyiden başlayarak sırası ile YGH, YİÖ, ÖBÖD ve HGÖ olduğu görülmektedir.

Çizelge 4.2'de YİÖ algoritması en iyi bunu takiben YGH, ÖBÖD ve HGÖ algoritmaları yer almaktadır.

Bunun yanında bütün algoritmaların aynı görüntüdeki toplam sonucu ise en iyi algoritma olan YGH'dan sentetik negatifler yokken % 14,93 sentetik negatifler varken % 16,3 daha iyidir.

Çizelge 4.3'e bakıldığında test verilerinin 150 video çerçevesinden oluştuğu düşünüldüğünde sentetik negatiflerin etkisinin YGH algoritması için ihmal edilebilecek kadar az olduğu gözlenmekle beraber ÖBÖD ve HGÖ algoritmalarında sentetik verilerin olmadığı durumdaki performans değişikliği % 0,57 ve % 0,74 düşük performans sergilediği görülmüştür. Bunun yanında YİÖ ve bütün algoritmaların oluşturduğu toplam bulmalar sırası ile % 0,5 ve % 1,39 daha iyidir.

4.2 Yanlış Bulma ve Sentetik Negatiflerin Etkisi

Yanlış bulma, ilgili algoritmanın hatalı bulmalarını ifade etmektedir. Analiz yapılan video çerçevesinde işaretlenen bölge içinde kişi yoksa veya çoğunlukla kişi gölgesi varsa bu yanlış bulma olarak değerlendirilmiştir.

Buna göre çizelge 4.4’ de sentetik negatiflerin dahil edilmediği durumda yanlış bulma adetleri ve bunların yüzde değerleri, çizelge 4.5’ de ise sentetik negatifler dahil edildiği durumda iken yanlış bulma adet ve yüzde değerleri ve son olarak çizelge 4.6’ da 4.4 ve 4.5 çizelgelerinden elde edilen veriler doğrultusunda sentetik negatiflerin yanlış bulmaya etkisi gösterilmiştir. 3B ortamlarda yapılan video analizi çalışmalarında yanlış bulmaya rastlanılmadığı için değerlendirmeye alınmamıştır.

Çizelge 4.4 Sentetik negatifler yokken yanlış bulma çizelgesi

Sentetik negatifler yokken yanlış bulma							
	Birinci video		İkinci video		Üçüncü video		Ortalama
	Kişi	Yüzde	Kişi	Yüzde	Kişi	Yüzde	Yüzde
Toplam kişi	13		13		11		
YGH	0,893	% 6,87	0,785	% 6,04	0,732	% 6,65	% 6,52
ÖBÖD	0,369	% 2,84	0,604	% 4,65	0,074	% 0,67	% 2,72
HGÖ	0,362	% 2,79	0,497	% 3,82	0,644	% 5,86	% 4,16
YİÖ	0,168	% 1,29	0,047	% 0,36	0,020	% 0,18	% 0,61
Toplam	1,309	% 10,07	1,242	% 9,55	0,966	% 8,79	% 9,47

Çizelge 4.5 Sentetik negatifler varken yanlış bulma çizelgesi

Sentetik negatifler varken yanlış bulma							
	Birinci video		İkinci video		Üçüncü video		Ortalama
	Kişi	Yüzde	Kişi	Yüzde	Kişi	Yüzde	Yüzde
Toplam kişi	13		13		11		
YGH	0,799	% 6,14	0,785	% 6,04	0,732	% 6,65	% 6,28
ÖBÖD	0,295	% 2,27	0,530	% 4,08	0,054	% 0,49	% 2,28
HGÖ	0,087	% 0,67	0,436	% 3,36	0,403	% 3,66	% 2,56
YİÖ	0,128	% 0,98	0,020	% 0,15	0,007	% 0,06	% 0,40
Toplam	1,000	% 7,69	1,148	% 8,83	0,893	% 8,11	% 8,21

Çizelge 4.6 Sentetik negatifler varken yanlış bulmaya etkisi

	Sentetik negatiflerin yanlış bulmaya etkisi				
	Birinci video	İkinci video	Üçüncü video	Ortalama	İyileşme oranı
YGH	-% 0,72	% 0,00	% 0,00	-% 0,24	% 3,70
ÖBÖD	-% 0,57	-% 0,57	-% 0,18	-% 0,44	% 16,17
HGÖ	-% 2,12	-% 0,46	-% 2,20	-% 1,59	% 38,33
YİÖ	-% 0,31	-% 0,21	-% 0,12	-% 0,21	% 34,78
Toplam	-% 2,37	-% 0,72	-% 0,67	-% 1,26	% 13,27

Çizelge 4.4 ve çizelge 4.5'e bakıldığında sahadaki yanlış oranı en düşük yani en iyiden başlayarak sırası ile YİÖ, ÖBÖD, HGÖ ve YGH algoritmaları yer almaktadır.

Sentetik negatiflerin yanlış bulma oranlarının araştırıldığı çizelge 4.6' ya bakıldığında sentetik negatiflerin bütün algoritmalarda hatalı bulmayı azalttığı, bunun yanında en iyi iyileşmeyi veren algoritmaların sırası ile HGÖ, YİÖ, ÖBÖD, toplam ve YGH algoritmaları olduğu gözlenmiştir.

4.3 Kişi Bulma Süreleri

Kişi bulma süreleri çalışması bütün algoritmaların aynı video görüntüsünü tarayarak yakaladığı doğru ve yanlış bütün kişilerin bulunması sırasında geçen süredir ve birim kişi bulma sürelerinin bulunduğu çalışmadır.

Test için hesaplama verilerinin alındığı bilgisayar Intel i5-5200U 2,20 GHz işlemci ve 8 GB Bellek özelliklerine sahiptir.

Yapılan zaman ölçümlerinde elde edilen değerler tek başına referans olarak kabul edilmemelidir.

Test değerlendirmesinde algoritmaların birbiri ile karşılaştırılması gereklidir.

Çizelge 4.7'de beş adet video için sentetikli negatifler yokken, varken ve ortalama bulma süreleri karşılaştırılmıştır. Algoritmaların bir bulma için harcadığı birim süre ise çizelge 4.8'de gösterilmiştir.

Çizelge 4.7 Kişi bulma süreleri

	Kişi bulma süreleri (sn)										Ortalama
	3B		İkinci 3B		Birinci video		İkinci video		Üçüncü video		
	Sentetik negatif yok	Sentetik negatif var	Sentetik negatif yok	Sentetik negatif var	Sentetik negatif yok	Sentetik negatif var	Sentetik negatif yok	Sentetik negatif var	Sentetik negatif yok	Sentetik negatif var	
YGH	0,8173	0,7869	1,1303	0,9683	1,2923	1,1435	1,2615	1,1504	0,6496	0,6288	0,9829
ÖBÖD	0,2303	0,2165	0,4096	0,4271	0,3331	0,3578	0,1484	0,1416	0,1183	0,1221	0,2505
HGÖ	0,0595	0,0654	0,2002	0,1989	0,2243	0,2244	0,2735	0,2724	0,1434	0,1358	0,1798
YiÖ	0,1258	0,1205	0,1840	0,2156	0,2505	0,2616	0,2345	0,2315	0,1059	0,1093	0,1839

87

Çizelge 4.8 Kişi bulma birim süreleri

	Kişi bulma birim süreleri (sn)										Ortalama
	3B		İkinci 3B		Birinci video		İkinci video		Üçüncü video		
	Sentetik negatif yok	Sentetik negatif var	Sentetik negatif yok	Sentetik negatif var	Sentetik negatif yok	Sentetik negatif var	Sentetik negatif yok	Sentetik negatif var	Sentetik negatif yok	Sentetik negatif var	
YGH	0,2669	0,2579	0,1837	0,1581	0,1862	0,1656	0,1689	0,1531	0,1229	0,1216	0,1785
ÖBÖD	0,0924	0,0916	0,0783	0,0831	0,0894	0,0980	0,0369	0,0361	0,0366	0,0392	0,0682
HGÖ	0,0304	0,0339	0,0540	0,0570	0,0581	0,0617	0,0574	0,0586	0,0356	0,0393	0,0486
YiÖ	0,0420	0,0412	0,0337	0,0362	0,0384	0,0398	0,0378	0,0374	0,0196	0,0205	0,0347

Çizelge 4.7'ye göre elde edilen video çerçevesi içerisindeki ortalama toplam bulma süreleri karşılaştırıldığında en hızlı algoritmanın HGÖ algoritması, bunu takiben sırası ile YİÖ, ÖBÖD ve YGH algoritmaları olduğu görülmektedir.

Çizelge 4.8'e göre en hızlı algoritma YİÖ, bunu takiben sırası ile HGÖ, ÖBÖD ve YGH algoritmaları gelmektedir.

4.4 3B Model ile Gerçek Ortamın Karşılaştırılması

Bu bölümde tezin araştırma ve motivasyon konularından biri olan 3B modellenmiş ortamdan elde edilen sonuçlara bakılarak gerçek ortamda yapılacak video analizi başarımları ile ilgili öngörüle bulunulması için elde edilen verilerin istatistiksel olarak karşılaştırmaları ve çıkan sonuca göre yorum yapılmıştır.

3B ile hazırlanmış sanal ortam ile gerçek ortam arasında yapılan karşılaştırmada algoritmaların kişi bulma oranlarının (bulunan kişi sayısının toplam kişiye oranı) ortalamalarına bakıldığı gibi bakılan ortalamalardaki standart sapmanın da karşılaştırmasına bakılmıştır.

Bu çalışmada 3B ikinci ortam ile diğer üç gerçek ortamlardan elde edilen doğru bulma oranlarının karşılaştırmaları T-test ve F-test uygulamaları ile gerçekleştirilmiştir.

T-test uygulaması ile sonuçların ortalama değerleri karşılaştırılmıştır. T-testi karşılaştırmaları iki farklı şekilde kontrol edilmiştir. Bunlar, varyansların benzer olduğu kabul edilerek yapılan havuzlanmış varyans T-testi ve varyansların benzemediği kabul edilen Welch T-testidir.

F-test ile de sonuçların standart sapmalarına bakılmıştır.

Her iki testte anlamlılık seviyesi olan α değeri 0,01 olarak belirlenmiştir.

T ve F-testlerinde ortaya konan hipotez 3B modellenmiş ortamdan elde edilen sonuçların ortalama ve standart sapma değerlerinin gerçek ortamlardan küçük veya eşit

olması yani tek kuyruklu durumu araştırılmıştır. Bu hipoteze göre H_0 değerinin uygunluđuna bakılmıştır.

Çalışmalar için (Statskingdom 2021) çevrimiçi uygulaması kullanılmıştır.

T-test çalışması sonuçları çizelge 4.9-4.12' de sırası ile YGH, ÖBÖD, HGÖ ve YİÖ algoritmalarının 3B ikinci ortam ile gerçek ortamların karşılaştırmaları şeklinde gösterilmiştir.

Karşılaştırma tablolarına göre YGH algoritmasında 3B video ortalama değerlerinin birinci ve ikinci gerçek ortam videolarına göre küçük ancak üçüncü videoda ortalama değerinin büyük olduğu görülmektedir.

HGÖ ve YİÖ algoritmaları karşılaştırmalarında ise 3B video ortalama değerlerinin bütün gerçek ortam videolarına göre küçük olduğu değerlendirildiği ortaya çıkmıştır.

ÖBÖD algoritması için yapılan karşılaştırmalarda ise 3B videonun ortalama değeri diğer üç video ortalama değerinden büyük olduğu sonucu ortaya çıkmıştır.

Çizelge 4.9-4.12 sonuçları değerlendirilecek olursa. Gerçek halı saha ortamı ve benzer senaryo ile yapılan analiz çalışmalarında YGH, HGÖ ve YİÖ algoritmaları 3B modellenmiş ortama göre daha yüksek bulma ortalaması verebilir. Ancak ÖBÖD algoritmasının en yüksek bulma ortalaması 3B ortamındadır yani gerçek ortamdan elde edilecek değerler 3B ortamından elde edilen değerlerin altında olacaktır.

Çizelge 4.9 3B video ile gerçek ortamların YGH T-testi karşılaştırması

	YGH			
	3B İkinci video	Birinci video	İkinci video	Üçüncü video
Örnek ortalaması	0,474961	0,481156	0,520909	0,413667
Örnek standart sapması	0,0649346	0,0942766	0,0885771	0,0779714
İstatistik		$T = -0,660576$ (kabul aralığı içinde) Ortalamalar farkı = $-0,0062$ (kabul aralığı içinde)	$T = -5,106729$ (kabul aralığı içinde) Ortalamalar farkı = $0,046$ (kabul aralığı içinde)	$T = 7,373539$ (kabul aralığı içinde değil) Ortalamalar farkı = $0,061$ (kabul aralığı içinde değil)
p-değeri		(Havuzlanmış varyans $0,745301$) (Welch $0,254732$)	(Havuzlanmış varyans: 1) (Welch: 1)	(Havuzlanmış varyans $8,38E-08$) (Welch $8,97E-08$)
Yorum		$p > \alpha$ olduğu için 3B değerleri ortalamasının birinci videodan küçük veya eşit olarak değerlendirilmektedir.	$p > \alpha$ olduğu için 3B değerleri ortalamasının ikinci videodan küçük olduğu değerlendirilmektedir.	$p < \alpha$ olduğu için 3B değerleri ortalamasının üçüncü videodan büyük olduğu değerlendirilmektedir.
H_0 hipotezi		Kabul	Kabul	Red

Çizelge 4.10 3B video ile gerçek ortamların ÖBÖD T-testi karşılaştırması

ÖBÖD				
	3B İkinci video	Birinci video	İkinci video	Üçüncü video
Örnek ortalaması	0,395973	0,315953	0,260712	0,282489
Örnek standart sapması	0,0873293	0,123628	0,0837469	0,0916072
İstatistik		$T = 6,453219$ (kabul aralığı içinde değil) Ortalamalar farkı = 0,080 (kabul aralığı içinde değil)	$T = 13,645704$ (kabul aralığı içinde değil) Ortalamalar farkı = 0.14 (kabul aralığı içinde değil)	$T = 10,945100$ (kabul aralığı içinde değil) Ortalamalar farkı = 0.11 (kabul aralığı içinde değil)
p-değeri		(Havuzlanmış varyans 2,23E-05) (Welch 2,57E-05)	(Havuzlanmış varyans 0) (Welch 0)	(Havuzlanmış varyans 0) (Welch 0)
Yorum		$p < \alpha$ olduğu için 3B değerleri ortalamasının birinci videodan büyük olduğu değerlendirilmektedir.	$p < \alpha$ olduğu için 3B değerleri ortalamasının ikinci videodan büyük olduğu değerlendirilmektedir.	$p < \alpha$ olduğu için 3B değerleri ortalamasının üçüncü videodan büyük olduğu değerlendirilmektedir.
H_0 Hipotezi		Red	Red	Red

Çizelge 4.11 3B video ile gerçek ortamların HGÖ T-testi karşılaştırması

	HGÖ			
	3B ikinci video	Birinci video	İkinci video	Üçüncü video
Örnek ortalaması	0,281363	0,299432	0,330924	0,282489
Örnek standart sapması	0,0919657	0,0863001	0,0982433	0,087236
İstatistik		$T = -1,748860$ (kabul aralığı içinde) Ortalamalar farkı = $-0,018$ (kabul aralığı içinde)	$T = -4,495528$ (kabul aralığı içinde) Ortalamalar farkı = $-0,050$ (kabul aralığı içinde)	$T = -0,108431$ (kabul aralığı içinde) Ortalamalar farkı = $-0,0011$ (kabul aralığı içinde)
p-değeri		(Havuzlanmış varyans 0,959324) (Welch 0,959322)	(Havuzlanmış varyans 0,999995) (Welch 0,999995)	(Havuzlanmış varyans 1) (Welch 1)
Yorum		$p > \alpha$ olduğu için 3B değerleri ortalamasının birinci videodan küçük olduğu değerlendirilmektedir.	$p > \alpha$ olduğu için 3B değerleri ortalamasının ikinci videodan küçük olduğu değerlendirilmektedir.	$p > \alpha$ olduğu için 3B değerleri ortalamasının üçüncü videodan küçük olduğu değerlendirilmektedir.
H_0 hipotezi		Kabul	Kabul	Kabul

Çizelge 4.12 3B video ile gerçek ortamların YİÖ T-testi karşılaştırması

	YİÖ			
	3B ikinci video	Birinci video	İkinci video	Üçüncü video
Örnek ortalaması	0,422303	0,502839	0,468766	0,502135
Örnek standart sapması	0,0707601	0,071829	0,123045	0,0971931
İstatistik		$T = -9,749889$ (kabul aralığı içinde) Ortalamalar farkı = $-0,081$ (kabul aralığı içinde)	$T = -3,995715$ (kabul aralığı içinde) Ortalamalar farkı = $-0,046$ (kabul aralığı içinde)	$T = -8,105574$ (kabul aralığı içinde) Ortalamalar farkı = $-0,080$ (kabul aralığı içinde)
p-değeri		(Havuzlanmış varyans 1) (Welch 1)	(Havuzlanmış varyans 0,999959) (Welch 0,999957)	(Havuzlanmış varyans 1) (Welch 1)
Yorum		$p > \alpha$ olduğu için 3B değerleri ortalamasının birinci videodan küçük olduğu değerlendirilmektedir.	$p > \alpha$ olduğu için 3B değerleri ortalamasının ikinci videodan küçük olduğu değerlendirilmektedir.	$p > \alpha$ olduğu için 3B değerleri ortalamasının üçüncü videodan küçük olduğu değerlendirilmektedir.
H_0 hipotezi		Kabul	Kabul	Kabul

F-test çalışması sonuçları çizelge 4.13-4.16' da sırası ile YGH, ÖBÖD, HGÖ ve YİÖ algoritmalarının 3B ortam ile gerçek ortamların karşılaştırmaları şeklinde gösterilmiştir.

Karşılaştırma tablolarına göre bütün algoritmaların 3B video standart sapmalarının gerçek ortam videolarına göre küçük olduğu görülmektedir.

Bu duruma göre benzer senaryo için 3B modellenmiş ortamdaki bulma sonuçlarının standart sapma değerinin olası en küçük değer olarak kabul edilerek gerçek ortamdaki standart sapmaların daha yüksek olabileceği düşünülebilir.



Çizelge 4.13 3B video ile gerçek ortamların YGH F-testi karşılaştırması

	YGH			
	3B ikinci video	Birinci video	İkinci video	Üçüncü video
Örnek ortalaması	0,474961	0,481156	0,520909	0,413667
Örnek standart sapması	0,0649346	0,0942766	0,0885771	0,0779714
İstatistik		$F = 0,4744$ (kabul aralığı içinde) Standart sapmalar oranı = 0,69 (kabul aralığı içinde)	$F = 0,5374$ (kabul aralığı içinde) Standart sapmalar oranı = 0,73 (kabul aralığı içinde)	$F = 0,6936$ (kabul aralığı içinde) Standart sapmalar oranı = 0,83 (kabul aralığı içinde)
p-değeri		1	0,9999	9,87E-01
Yorum		$p > \alpha$ olduğu için 3B standart sapmasının birinci videodan küçük olduğu değerlendirilmektedir.	$p > \alpha$ olduğu için 3B standart sapmasının ikinci videodan küçük olduğu değerlendirilmektedir.	$p > \alpha$ olduğu için 3B standart sapmasının üçüncü videodan küçük veya eşit olduğu değerlendirilmektedir.
H_0 hipotezi		Kabul	Kabul	Kabul

Çizelge 4.14 3B video ile gerçek ortamların ÖBÖD F-testi karşılaştırması

	ÖBÖD			
	3B ikinci video	Birinci video	İkinci video	Üçüncü video
Örnek ortalaması	0,395973	0,315953	0,260712	0,282489
Örnek standart sapması	0,0873293	0,123628	0,0837469	0,0916072
İstatistik		$F = 0,499$ (kabul aralığı içinde) Standart sapmalar oranı = 0,71 (kabul aralığı içinde)	$F = 1,0874$ (kabul aralığı içinde) Standart sapmalar oranı = 1,04 (kabul aralığı içinde)	$F = 0,9088$ (kabul aralığı içinde) Standart sapmalar oranı = 0,95 (kabul aralığı içinde)
p-değeri		1	0,3055	0,7193
Yorum		$p > \alpha$ olduğu için 3B standart sapmasının birinci videodan küçük olduğu değerlendirilmektedir.	$p > \alpha$ olduğu için 3B standart sapmasının ikinci videodan küçük veya eşit olduğu değerlendirilmektedir.	$p > \alpha$ olduğu için 3B standart sapmasının üçüncü videodan küçük veya eşit olduğu değerlendirilmektedir.
H_0 hipotezi		Kabul	Kabul	Kabul

Çizelge 4.15 3B video ile gerçek ortamların HGÖ F-testi karşılaştırması

	HGÖ			
	3B İkinci video	Birinci video	İkinci video	Üçüncü video
Örnek ortalaması	0,281363	0,299432	0,330924	0,282489
Örnek standart sapması	0,0919657	0,0863001	0,0982433	0,087236
İstatistik		$F = 1,1356$ (kabul aralığı içinde) Standart sapmalar oranı = 1,07 (kabul aralığı içinde)	$F = 0,8763$ (kabul aralığı içinde) Standart sapmalar oranı = 0,94 (kabul aralığı içinde)	$F = 1,1114$ (kabul aralığı içinde) Standart sapmalar oranı = 1,05 (kabul aralığı içinde)
p-değeri		0,2201	0,7886	0,2607
Yorum		$p > \alpha$ olduğu için 3B standart sapmasının birinci videodan küçük veya eşit olduğu değerlendirilmektedir.	$p > \alpha$ olduğu için 3B standart sapmasının ikinci videodan küçük veya eşit olduğu değerlendirilmektedir.	$p > \alpha$ olduğu için 3B standart sapmasının üçüncü videodan küçük veya eşit olduğu değerlendirilmektedir.
H_0 hipotezi		Kabul	Kabul	Kabul

Çizelge 4.16 3B video ile gerçek ortamların YİÖ F-testi karşılaştırması

	YİÖ			
	3B ikinci video	Birinci video	İkinci video	Üçüncü video
Örnek ortalaması	0,422303	0,502839	0,468766	0,502135
Örnek standart sapması	0,0707601	0,071829	0,123045	0,0971931
İstatistik		$F = 0,9705$ (kabul aralığı içinde) Standart sapmalar oranı = 0,99 (kabul aralığı içinde)	$F = 0,3307$ (kabul aralığı içinde) Standart sapmalar oranı = 0,58 (kabul aralığı içinde)	$F = 0,53$ (kabul aralığı içinde) Standart sapmalar oranı = 0,73 (kabul aralığı içinde)
p-değeri		0,5722	1	0,9999
Yorum		$p > \alpha$ olduğu için 3B standart sapmasının birinci videodan küçük veya eşit olduğu değerlendirilmektedir.	$p > \alpha$ olduğu için 3B standart sapmasının ikinci videodan küçük olduğu değerlendirilmektedir.	$p > \alpha$ olduğu için 3B standart sapmasının üçüncü videodan küçük olduğu değerlendirilmektedir.
H_0 hipotezi		Kabul	Kabul	Kabul

5. SONUÇ

Bu tez çalışmasında, sentetik ortamdan elde edilen veriler ile gerçek ortamda kişi tespiti yapılabilirliği, YGH, ÖBÖD, HGÖ ve YİÖ algoritmalarının karşılıklı performans değerlendirmeleri, oluşturulan sentetik negatiflerin dahil edilmesinin analiz çalışmalarına etkisi ve 3B ortam animasyon videosu analizine bakılarak gerçek ortam analizi hakkında çıkarım yapma konuları araştırılmıştır.

Bu konular için öncelikle bir senaryo belirlenmiş ve bu senaryoya uygun 3B modelleme ve animasyon ortamı hazırlanmıştır. Bu animasyon ortamında elde edilen pozitif ve negatif görüntüler ile öznelikler çıkarılarak DVM için eğitim verileri hazırlanmış ve eğitim verilerinin % 30' u kullanılarak DVM testi yapılmıştır. DVM testlerine göre en iyi öğrenme YGH ve buna çok yakın değerlere sahip YİÖ algoritmaları, bunları takiben HGÖ ve ÖBÖD algoritmaları kendi arasında birbirine yakın DVM test değerleri ortaya koymuştur. DVM test değerlerine bakarak YGH ve YİÖ algoritmalarından elde edilecek sonuçların ÖBÖD ve HGÖ algoritmalarına göre daha iyi olacağı düşünülmüştür.

Video ile yapılan testlerde de DVM eğitimi tesleri sonucuna benzer sonuçlar göstermiştir. İki farklı 3B modellenmiş animasyon ve üç adet farklı gerçek ortam videoları ile gerçekleştirilen bütün test senaryolarında YGH ve YİÖ algoritmaları yaklaşık % 46 oranı ile sahadaki kişileri bulurken, ÖBÖD ve HGÖ algoritmalarının bulma oranları yaklaşık olarak % 30 seviyesindedir. Bu sonuçlar DVM eğitimi sonuçları ile benzerlik göstermektedir.

Yapılan çalışmalarda gözlemlenen bir başka konu ise bütün algoritmaların toplamının yaptığı kişi tespitidir ki bu değer yapılan testlere göre ortalama % 62'dir. Bu değer en iyi değerlere sahip YGH ve YİÖ algoritmalarından %16 daha yüksektir. Bu sonuca göre analiz yapılırken birden fazla algoritmanın aynı ortamda analiz yapabileceğinin daha iyi sonuç üreteceği değerlendirilmektedir.

En iyi performanslı algoritmaya karar verilmesi için bakılması gereken başka bir nokta ise algoritmaların yaptığı hataların değerlendirilmesidir.

Yapılan çalışma sonucunda sentetik negatif eğitim verileri yokken en çok hatayı YGH algoritmasının yaptığı bunu takiben HGÖ, ÖBÖD ve en az hatayı yapan algoritmanın ise YİÖ algoritması olduğu bulunmuştur. Sentetik negatif eğitim verileri varken sonuç ise, yine en yüksek YGH algoritması, bunu takiben HGÖ ve yakın değer ile ÖBÖD ve yine en az hata yapan algoritma olarak YİÖ bulunmuştur. Algoritmaların toplamının yaptığı hatalar ise sentetik negatifler yokken % 9,47, sentetik negatifler varken % 8,21 olarak ölçülmüştür.

Doğru ve yanlış bulmalar beraber değerlendirildiğinde ortalama en yüksek % 46 doğruluk oranı ve ortalama en düşük % 0,5 hata oranı ile YİÖ algoritması çalışma sonucunda en iyi performansa sahip algoritma olarak değerlendirilmektedir.

Algoritmaların hızları karşılaştırmalarında ise yine YİÖ algoritması en hızlı bunu takiben sırası ile HGÖ, ÖBÖD ve YGH algoritmaları olduğu görülmüştür.

Sanal ortamdan negatif eğitim verilerin alınmasına benzer bir çalışma daha önce de yapılmıştır (Vazquez vd. 2014) yaptığı çalışmada pozitif eğitim verisine sanal görüntülerle katkıda bulunmuştur. Bu tez çalışmasında sentetik negatiflerin de analiz çalışmasına etkisi araştırılmıştır.

Sentetik negatiflerin etki analizinde ise özellikle HGÖ algoritmasındaki hatalı bulma değeri % 4,16'dan % 2,56 ya düşmüş bir başka deyişle % 38,33 yanlış bulmada iyileşme olmuştur. Hatalı bulmada gözlemlenen iyileşme oranı diğer algoritmalarda dolayısı ile toplam bulunanlarda da pozitif yöndedir. Buradan elde edilen değerlere göre analiz yapılan ortama özel hazırlanmış sentetik veriler analiz doğruluğunu arttırmıştır.

Araştırılan konulardan diğeri ise tezin motivasyon konularından biri olan “3B modellenmiş ortam analizlerine bakılarak gerçek ortam analizi hakkında bilgi sahibi olunabilir mi?” sorusuna yanıt arayışıdır. Bu çalışma için ise eldeki veriler kullanılarak hipotez testi yürütülerek algoritmaların sonuçlarının ortalama değerleri ve standart sapma değerlerine bakılarak 3B modellenmiş ortam ile gerçek ortamlar arasındaki bir bağıntı var mı araştırılmıştır.

Bağıntı araştırmasına göre benzer senaryo ve ortamda YGH, HGÖ ve YİÖ algoritmaları gerçek ortamda 3B modellenmiş ortama göre daha yüksek bulma ortalaması verebilir. Ancak ÖBÖD algoritmasının en yüksek bulma ortalaması 3B ortamındadır yani gerçek ortamdan elde edilecek değerler 3B ortamından elde edilen değerlerin altında olacaktır. Bunun yanında benzer senaryo ve ortamda 3B modellenmiş ortamdaki bulma sonuçlarının standart sapma değerinin olası en küçük değer olarak kabul edilerek gerçek ortamdaki standart sapmaların daha yüksek olabileceği düşünülmektedir.

(Hattori vd. 2015) çalışmasında da benzer şekilde ortama özel olarak oluşturulan sentetik verilerin kullanılması ile elde ettiği sonuçları değerlendirmiş ve değerlendirme sonucunda sanal ortamların eğitim verileri oluşturulmasındaki kolaylık doğruluk ve sunduğu çeşitliliğin avantajlarından bahsetmiştir.

Bu tez çalışmasında da sentetik eğitim verileri, geleneksel eğitim verisi oluşturulması yöntemine göre daha kolay ve sonuç odaklı olarak elde edilmiştir. Blender içerisinde oluşturulan kontrollü ortam ile her bir kişinin yeri net olarak belirlenmiş ve gerekli eğitim verileri alınabilmektedir.

Bunun yanında (Hattori vd. 2015) çalışmasında karakter çeşitliliğine önem verirken bu tez çalışmasına vücut hareketleri ve animasyon ön planda tutulmuş ve hatta Blender parçacık özelliği ile oluşturulan kişi karakterlerine ayrı ayrı rastgele özgünlük hareketi verilerek her bir video çerçevesindeki kişi hareketi, farklı kamera görüşleri içerisinde yakalanmış ve eğitim verisi olarak değerlendirilmiştir. (Hattori vd. 2015) eğitim verisi hazırlamak için 3B karakter heykellerinden faydalanmış ve bunları önceden belirlenmiş olan sahne konumlarına yerleştirmiştir.

5.1 Öneriler

Tez çalışmasında oluşturulan sanal ortam altyapısı; pek çok farklı tipte senaryonun çalıştırılabildiği ve bu senaryolara uygun analiz çalışmalarının gerçekleştirilebildiği bir ortam sağlamaktadır. Örneğin aydınlatma hareketli hale getirilerek gün doğumu ve gün batımı senaryoları çalıştırılabilir, kar veya yağmur ortama eklenebilir ve parametrik olarak değiştirilebilir. Örneğin sağanak yağmur veya yoğun kar altında kişi animasyonu

gerçekleştirilebilir, kişi sayısı, kişi kıyafetleri değiştirilebilir, ortama hareketli bir futbol topu eklenerek futbol topunun algılanması istenmiyor ise negatif eğitim verisine eklenebilir, saha aydınlatması sonucu oluşan gölgelerin bulunmaması için negatif eğitim verisine bu eklentiler yapılabilir, özel olarak kaleci ve sakatlanmış futbolcu hareketleri de eklenerek çeşitli eğitim verileri oluşturulabilir.

Bu tez çalışmasında oluşturulan karakterlerin hareketlendirilmeleri bir lideri izle modeli ile gerçekleştirilmiştir yani yarı zeki bir çalışma modeli oluşturulmuştur. Blender uygulamasında hareketlendirilen modellerin her biri bulunduğu koşula, karşılaştığı engelle veya diğer hareketlendirilmiş objelere göre kendini pozisyonlayabileceği veya hareket kararı verebileceği hale de getirilerek sanal ortamdaki hareket doğallığı arttırılabilir. Örneğin bir kalabalık simülasyonu kullanılarak gerçekleştirilebilir.

Bunun yanında sanal olarak hazırlanan ortamda 2B sanal kamera konumu da dinamik hale getirilerek oluşturulacak animasyonlardan hem daha çeşitli eğitim verileri toplanabilir hem de gerçek ortam uyarlaması ile ilgili daha çok sayıda test ortamı yaratılabilir.

Sanallaştırılmış ortamın hazırlanmasında gerçek ortamdan alınan görüntülerden de faydalanılabilir. Bu ortamdan alınan görüntüler kullanılarak hazırlan 3B modellemelerde gerçeğe daha yakın sahne ve kişiler oluşturulabilir bu sayede gerçek ortama daha yakın bir sanal sahnede video analizi faaliyetleri gerçekleştirilebilir.

KAYNAKLAR

- Acar, E. ve Özerdem, M. S. 2016. Tarımsal İmge Dokularından HOG Algoritması ile Öznitelik Çıkarımı ve Öznitelik Tabanlı Toprak Neminin Tahmini. Bilgisayar Bilimleri Dergisi, 1(1), 1-7.
- Adelson, E. H., Anderson, C. H., Bergen, J. R., Burt, P. J. and Ogden, J. M. 1984. Pyramid methods in image processing. RCA Engineer, 29(6), 33-41.
- Anonymous. 2020. Web Sitesi: <http://www.lookingatpeople.com/data/Daimler/pami09-enzweiler-gavrila/TrainingData.tar.gz>, Erişim Tarihi: 20.09.2020.
- Anonymous. 2020. Web Sitesi: <https://www.autodesk.com.tr/solutions/3d-modeling-software>, Erişim Tarihi: 19.09.2020.
- Ayhan, S. ve Erdoğan, Ş. 2014. Destek Vektör Makineleriyle Sınıflandırma Problemlerinin Çözümü İçin Çekirdek Fonksiyonu Seçimi. Eskişehir Osmangazi Üniversitesi İİBF Dergisi, 9(1), 175-198.
- Bay, H., Ess, A., Tuytelaars, T. and Gool, L. V. 2008. Speededup robust features (SURF). Computer Vision and Image Understanding, 110(3), 346-359.
- Blender. 2020. Web Sitesi: <https://blender.stackexchange.com/questions/143039/get-particle-location-using-python>, Erişim Tarihi: 20.09.2020.
- Blender. 2020. Web Sitesi: <https://blender.stackexchange.com/questions/7198/save-the-2d-bounding-box-of-an-object-in-rendered-image-to-a-text-file>, Erişim Tarihi: 20.09.2020.
- Blender. 2020. Web Sitesi: https://docs.blender.org/manual/en/latest/getting_started/about/history.html, Erişim Tarihi: 19.09.2020.
- Blender. 2020. Web Sitesi: <https://docs.blender.org/manual/en/latest/physics/particles/emitter/physics/boids.html>, Erişim Tarihi: 19.09.2020.
- Blender. 2020. Web Sitesi: <https://docs.blender.org/manual/en/latest/physics/particles/introduction.html>, Erişim Tarihi: 19.09.2020.
- Brown, M. and Lowe, D. 2002. Invariant features from interest point groups. BMVC.
- Burges, C. J. C. 1998. A tutorial on support vector machines for pattern recognition, data mining and knowledge discovery. Kluwer Academic Publishers, 2(2), 121-167.

- Budak, Ü. ve Şengür, A. 2015. Ölçekten Bağımsız Özellik Dönüşümü ve Kelime Çantası Yöntemleri ile Doku Sınıflandırması. SİU-2015 Sinyal İşleme ve İletişim Uygulamaları Kurultayı, 56-59.
- Buğday, A. 2010. Gerçek zamanlı videolarda ön ve arka plan ayrımı. Yüksek Lisans Tezi, Ankara Üniversitesi, Elektrik Elektronik Mühendisliği Anabilim Dalı, 76, Ankara.
- Canu, S. 2018. Web Sitesi: <https://pysource.com/2018/03/21/feature-detection-sift-surf-obr-opencv-3-4-with-python-3-tutorial-25/>, Erişim Tarihi: 20.09.2020.
- Cortes, C. and Vapnik, V. 1995. Support vector networks. Machine Learning, 20, 1-25.
- Dalal, N. and Triggs, B. 2005. Histograms of oriented gradients for human detection. 2005 Proc. IEEE Computer Soc. Conf. Comput. Vis. Pattern Recognit., 886-893.
- Demirel, E. 2019. Görsel Navigasyon İçin Bilgisayarlı Görme Yöntemleri. Yüksek Lisans Tezi, Hacettepe Üniversitesi, Elektrik ve Elektronik Mühendisliği Ana Bilim Dalı, 116, Ankara.
- Dihkan, M. 2019. Uzaktan Algılanmış Görüntülerin SURF Özellik Verileri ve RANSAC Algoritması ile Otomatik Çakıştırılması. GÜFBED, 9(3), 425-432.
- Duda, R. O., Peter, E. Hart, P. E. and Stork, D. G. 2000. Pattern classification. Wiley-Interscience, 738, United States
- Fazel, A. and Vo, V. 2016. Pedestrian Detection and Tracking in Images and Videos. CS231A Project, Stanford University, 6, United States.
- Fazel, A. 2016. Web Sitesi: https://github.com/afazel/CS231A_Project, Erişim Tarihi:20.09.2020.
- Gonzalez, R. G. and Woods, R. E. 2008. Digital Image Processing Third Edition. Prentice Hall, 954, United States
- Gonzalez, R. G. and Woods, R. E. 2017. Digital Image Processing 4th Edition. Pearson, 1168, United States
- Graf, F. G. 1999. Modern Dictionary of Electronics Seventh Edition. Newnes, 882, United States
- Gong, X., Su, H., Xu, D., Zhang, Z., Shen, F. and Yang, H. 2018. An Overview of Contour Detection Approaches. International Journal of Automation and Computing, 15(6), 656-672

- Güldoğan, E. 2017. Çeşitli Çekirdek Fonksiyonları İle Oluşturulan Destek Vektör Makinesi Modellerinin Performanslarının İncelenmesi: Bir Klinik Uygulama. Doktora Tezi, İnönü ve Mersin Üniversitesi, Biyoistatistik ve Tıp Bilişimi Anabilim Dalı, 103, Malatya.
- Hattori, H., Bodetti, V. N., Kitani, K. and Kanade, T. 2015. Learning scene-specific pedestrian detectors without real data. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 3819–3827.
- Huang, D. Shan, C., Ardabilian, M., Wang, Y. and Chen, L. 2011. Local Binary Patterns and Its Application to Facial Image Analysis: A Survey. IEEE Transactions on Systems, Man and Cybernetics, Part C: Application and Reviews, 42(6).
- Kaggle. 2016. Web Sitesi: <https://www.kaggle.com/tonypoe/svm-implementation-for-nature-conservatory>, Erişim Tarihi: 20.09.2020.
- Karakuş, P. ve Karabörk, H. 2014. SURF algoritması kullanılarak uzaktan algılama görüntülerinin geometrik kaydı. 5. Uzaktan Algılama-Cbs Sempozyumu. 14-17 Ekim 2014. Uzal-Cbs 2014; İstanbul.
- Kızrak, M. A. 2014. Local Binary Pattern Yöntemi ile Yüz İfadelerinin Tanınması. Şekil Tanıma Proje Raporu, Yıldız Teknik Üniversitesi, 10, İstanbul
- Kumar, R. 2019. Machine Learning Quick Reference. Packt, 377, UK
- Lowe, D. G. 2004. Distinctive image features from scale-invariant keypoints. International Journal of Computer Vision, 60(2), 91-110.
- Nabiyev, V. V. ve Günay, A. 2011. LBP Yardımıyla Görüntüdeki Kişinin Yaşının Bulunması. Çankaya University Journal of Science and Engineering, 8(1), 27-41.
- Ojala, T. Pietikainen, M. and Harwood, D. 1996. A Comparative Study of Texture Measures with Classification Based on Feature Distributions. Elsevier Science, Pattern Recognition, 29(1), 51-59.
- Özgen, N. ve Sarıtaş, M. 2008. SIFT Metodu ile Hedef Takibi, Elektrik - Elektronik, Bilgisayar Mühendisliği Sempozyumu ve Fuarı, ELECO 2008, Bursa
- Pishchulin, L., Jain, A. Wojek, C., Andriluka, M., Thormahlen, T. and Schiele, B. 2011. Learning people detection models from few training samples. 2011 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 1473-1480.

- Rosebrock, A. 2015. Web Sitesi: <https://www.pyimagesearch.com/2015/12/07/local-binary-patterns-with-python-opencv/>, Erişim Tarihi: 20.09.2020.
- Rothe, R., Guillaumin, M. and Gool, L. V. 2014. Non-Maximum Suppression for Object Detection by Passing Messages between Windows. Asian Conference on Computer Vision (ACCV 2014). 1-5 November 2014, Singapore.
- Shan, C., Shaogang, G. and McOwan, P. W. 2009. Facial expression recognition based on Local Binary Patterns: A comprehensive study. Image and Vision Computing, 27(6), 803-816.
- Statskingdom. 2021. Web Sitesi: <https://www.statskingdom.com>, Erişim Tarihi: 05.01.2021.
- Soman, K.P., Loganathan, R. and Ajay, V. 2011. Machine learning with SVM and other Kernel methods. PHI Learning Pvt. Ltd., 486.
- Soofi, A. and Arshad, A. 2017. Classification Techniques in Machine Learning: Application and Issues. Journal of Basic & Applied Sciences, 13, 459-465.
- Studio, M. 2020. Web Sitesi: <https://www.youtube.com/watch?v=sllH9OnbjOg&list=WL&index=5&t=0s>, Erişim Tarihi: 20.09.2020.
- Tabhki, H., Bushey, R. and Schirner, G. 2013. Algorithm and Architecture Co-Design of Mixture of Gaussian (MoG) Background Subtraction for Embedded Vision. 2013 Asilomar Conference on Signals, Systems and Computers, USA
- Ülgen, K. 2017. Web Sitesi: <https://medium.com/@k.ulgen90/makine-%C3%B6%C4%9Frenimi-b%C3%B6%C3%BCm-4-destek-vekt%C3%B6r-makineleri-2f8010824054>, Erişim Tarihi: 20.09.2020.
- Vazquez, D., Lopez, A., Marin, J., Ponsa, D. and Geronimo, D. 2014. Virtual and Real World Adaptation for Pedestrian Detection. PAMI, 36(4), 797-809.
- Yüksel, A., Yanık, A. ve Ayazlar, R. A. 2015. Bilimsel Araştırma Yöntemleri, 272, Türkiye

ÖZGEÇMİŞ

Adı Soyadı : Tahir BÜYÜKBAŞARAN

Doğum Yeri : Ankara

Doğum Tarihi : 24/12/1975

Medeni Hali : Evli

Yabancı Dili : İngilizce

Eğitim Durumu (Kurum ve Yıl)

Lise : Ankara Aydınlikevler İnönü Lisesi (1991)

Lisans : Ankara Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik
Mühendisliği (1996)

Yüksek Lisans : Ankara Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik
Mühendisliği Anabilim Dalı (2021)