

T.C.
ALTINBAŞ UNİVERSİTESİ
Bilişim Teknolojileri

KAMERA GÖRÜNTÜLERİ TEMELLİ İNSAN HAREKETLERİNİN YOĞUNLUĞU HARİTALAMA SİSTEM TASARIMI

Muharrem Uğur ERTEKİN

Yüksek Lisans Tezi

Danışman

Prof. Dr. Oğuz BAYAT

İstanbul, 2020

KAMERA GÖRÜNTÜLERİ TEMELLİ İNSAN HAREKETLERİNİN YOĞUNLUĞU HARİTALAMA SİSTEM TASARIMI

Muharrem Uğur ERTEKİN

Bilişim Teknolojileri

Fen Bilimleri Enstitüsü'ne

Lisansüstü derece

Tezi olarak sunulmuştur.

ALTINBAŞ ÜNİVERSİTESİ

2020

Bu tezi okuduğumuzu; kapsam ve nitelik bakımından Yüksek Lisans tezi olarak yeterli bulduğumuzu beyan ederiz.

Prof. Dr. Oğuz BAYAT

Danışman

Sınav komitesi: (Yazılan ilk isim jüri başkanı, ikinci isim danışman olmalıdır.)

Prof. Dr. Oğuz BAYAT	Mühendislik ve Doğa Bilimleri, Altınbaş Üniversitesi	_____
Dr. Öğr. Üyesi Muhammad ILYAS	Mühendislik ve Doğa Bilimleri, Altınbaş Üniversitesi	_____
Dr. Öğr. Üyesi Adil Deniz DURU	Spor Bilimleri, Marmara Üniversitesi	_____

Bu tezin Yüksek Lisans. tezi olarak bütün şartları sağladığını beyan ederim.

Prof. Dr. Oğuz ATA

Anabilim Dalı Başkanı

Fen Bilimleri Enstitüsü kabul tarihi:

____/____/____

Prof. Dr. Oğuz BAYAT

Enstitü Müdürü

Bu tezdeki tüm bilgilerin akademik kurallara ve etik davranışlara uygun olarak edinildiğini ve sunulduğunu beyan ederim. Ayrıca, bu kuralların ve davranışların gerektirdiği şekilde, bu çalışmada, orijinal olmayan tüm materyalleri ve sonuçları tamamen alıntı yaptığımı ve referans gösterdiğimi de beyan ederim.

Muharrem Uğur ERTEKİN

ÖNSÖZ

Öncelikle yüksek lisans eğitimim boyunca desteği, anlayışı için eşim Binnur ‘a, motivasyon kaynağım canım kızım Can ‘a, tez çalışmasının derlenmesi sırasında her türlü soru ve sorunumda akademik üslubu ve destekleyici yaklaşımları için Doç. Dr. Gökhan Kaçar ve Öğr. Gör. Gülnur Yenilmez Kaçar’ a, maddi manevi destekleri için babam Mehmet Ertekin’e, kardeşim Aysun’a, değişik bakış açılarını ve engin düşüncelerini esirgemeyen fikirlerimin şekillenmesine katkıda bulunan değerli öğretmenim eş danışmanım Doç. Dr. Adil Deniz Duru ‘ya ve Danışmanım Prof. Dr. Oğuz Bayat’a çok teşekkür ederim.

ÖZET

KAMERA GÖRÜNTÜLERİ TEMELLİ İNSAN HAREKETLERİNİN YOĞUNLUĞU HARİTALAMA SİSTEM TASARIMI

Ertekin, Muharrem Uğur,

Yüksek Lisans, Bilişim Teknolojileri, Altınbaş Üniversitesi,

Danışman: Prof. Dr. Oğuz Bayat

Eş Danışman: Doç. Dr. Adil Deniz Duru

Tarih: Şubat, 2020

Sayfa Sayısı: 66

Bu tez çalışmasında kamera görüntüleri ile insan ve nesne hareketlerini takip eden sistemler incelenmiş, kamera sistemleri ile insan yoğunluk (ısı) haritalarının çıkarılması konusunda bilime nasıl katkı sağlanabilir sorusu irdelenmiştir. Çalışmada insan hareketlerini görüntü işleme teknikleri ile algılayan prototip bir sistem tasarlanmış ve bu sistemden insan yoğunluk (ısı haritaları) çıkarılmıştır. Sistemi denemek için yoğun insan giriş çıkışı olan ve bankolardan hizmet verilen bir irtibat ofisi incelenmiş, devamında sistem, spor sahasında bir müsabaka sırasında denenmiş, sporcular egzersiz yaparken veya performans sergilenirken üretilen ısı haritası ile sporcuların zaman içerisinde kapladıkları alanın boyutu görüntülenmiş, irtibat bürosunda da hizmet almaya gelen insanların nerelerde daha yoğun olarak bulundukları ısı haritası ile gösterilmiş ve sonuçlar yorumlanmıştır.

Anahtar kelimeler: Nesne (insan) algılama, İnsan yoğunluk (ısı) haritası

ABSTRACT

DESIGN OF HUMAN MOVEMENT MAPPING SYSTEM USING CAMERA IMAGES

Ertekin, Muharrem Uğur,

M.S., Information Technologies, Altınbaş University,

Supervisor: Prof. Dr. Oğuz Bayat

Co Supervisor: Assoc. Prof. Dr. Adil Deniz Duru

Date: February, 2020

Pages: 66

In this thesis, systems that detect human and object motion are investigated by footage, and the question of how camera systems are used to obtain heat map while contributing to the scientific area. In this work, a prototype system is designed to detect human motion by image processing techniques and human heap map is deduced from this system. To test the system, initially a liaison office is investigated with an extensive human ingoing and outgoing, later the system is executed to generate the heat map to monitor the area that athletes for a sports competition where the heat athletes are training or to identify the occupied space that the people come to the liaison office.

Keywords: Object (human) detection, Human density (heat) map

İÇİNDEKİLER

Sayfa

ÖNSÖZ ..... **v**

ÖZET ..... **vi**

ABSTRACT ..... **vii**

TABLO LİSTESİ ..... **xi**

ŞEKİL LİSTESİ ..... **xii**

1. GİRİŞ **1**

2. GÖRÜNTÜ İŞLEME, NESNE TESPİT VE TANIMA, YOĞUNLUK (ISI) HARİTALARI **3**

2.1 GÖRÜNTÜ İŞLEME 3

2.2 NESNE TESPİTİ VE NESNE TANIMA 4

2.3 YOĞUNLUK (ISI) HARİTASI 6

3. AMAÇ **8**

4. MATERYAL VE METOT **9**

4.1 KAYIT DONANIMI VE YAZILIMI 9

4.1.1 Donanım 9

4.1.2 Yazılım 10

4.1.2.1 Tensorflow 10

4.1.2.2 Imageai 11

4.1.2.3 Opencv 11

4.2 BİLGİ İZLEME DONANIMI 11

4.3 GÖRÜNTÜLERDEN KİŞİ ALGILAMA 12

4.4 VERİ TABANI TASARIMI VE TABLOLARI 14

4.4.1 Veri Tabanı Tablo Alanları 14

4.4.1.1 id 15

4.4.1.2 date_time 15

4.4.1.3 x_min, y_min, x_max, y_max 15
4.4.1.4 percentage_probability 16
4.5 ISI HARİTASI OLUŞTURMA AŞAMALARI 17
4.5.1 Veri Aktarımı ve Hafıza Tahsisi 17
4.5.2 Isı Haritası Oluşturma 18
4.5.3 İmge Yumuşatma İşlemi 18
4.5.4 Görselleştirme 20
5. PROGRAM ÇIKTILARI VE BULGULAR 24
5.1 İRTİBAT OFİSİ BULGULARI 24
5.1.1 Örnek Çıktı 1 24
5.1.1.1 Birinci Resim Örneği Bir Konum Ve Bir İnsan Tespiti 24
5.1.1.2 İkinci resim iki konum ve iki insan tespiti 25
5.1.1.3 Üçüncü resim bir konum ve bir insan tespiti 26
5.1.2 Örnek Çıktı 2 27
5.1.2.1 On konum ve on insan tespiti 27
5.1.2.2 Dokuz konum ve dokuz insan tespiti 28
5.1.2.3 On konum ve on insan tespiti 29
5.1.3 Örnek Çıktı 3 30
5.1.3.1 On sekiz konum ve on sekiz insan tespiti 31
5.1.3.2 On yedi konum ve on yedi insan tespiti 33
5.1.3.3 On beş konum ve on beş insan tespiti 35
5.1.3.4 On yedi konum ve on yedi insan tespiti 37
5.1.3.5 On beş konum ve on beş insan tespiti 39
5.2 İRTİBAT OFİSİ YOĞUNLUK HARİTALARI ÖRNEKLERİ 40
5.3 SPOR SAHASI VOLEYBOL MÜSABAKASI BULGULARI 41
5.3.1 On Lokasyon ve On İnsan Tespiti 42
5.3.2 On Lokasyon ve On İnsan Tespiti 43

5.3.3 Sekiz Lokasyon ve Sekiz İnsan Tespiti 44
5.3.4 Dokuz Konum ve Dokuz İnsan Tespiti 45
5.4 SPOR KARŞILAŞMASI YOĞUNLUK HARİTALARI ÖRNEKLERİ 46
6. SONUÇ VE TARTIŞMA 48
REFERANSLAR 50
EK A GÖRÜNTÜ YAKALAMA PHYTON KODU 54
EK B YOĞUNLUK HARİTASI MATLAB KODU 57
ÖZGEÇMİŞ 58

TABLO LİSTESİ

Tablo 4.1: SQLite DB Browser'dan Alınan Örnek Veri Tabanı Görseli 14

Tablo 4.2: Şekil 4.2 'deki insan tespitinin veri tabanı kaydı 16

Tablo 5.1: Şekil 5.1 için sistemde oluşan veri tabanı kaydı..... 25

Tablo 5.2: Şekil 5.2 için sistemde oluşan veri tabanı kaydı..... 26

Tablo 5.3: Şekil 5.3 için sistemde oluşan veri tabanı kaydı..... 27

Tablo 5.4: Şekil 5.4 için sistemde oluşan veri tabanı kaydı..... 28

Tablo 5.5: Şekil 5.5 için sistemde oluşan veri tabanı kaydı..... 29

Tablo 5.6: Şekil 5.6 için sistemde oluşan veri tabanı kaydı..... 30

Tablo 5.7: Şekil 5.7 için sistemde oluşan veri tabanı kaydı..... 32

Tablo 5.8: Şekil 5.8 için sistemde oluşan veri tabanı kaydı..... 34

Tablo 5.9: Şekil 5.9 için sistemde oluşan veri tabanı kaydı..... 36

Tablo 5.10: Şekil 5.10 için sistemde oluşan veri tabanı kaydı..... 38

Tablo 5.11: Şekil 5.11 için sistemde oluşan veri tabanı kaydı..... 39

Tablo 5.12: Şekil 5.14 için sistemde oluşan veri tabanı kaydı..... 42

Tablo 5.13: Şekil 5.15 için sistemde oluşan veri tabanı kaydı..... 43

Tablo 5.14: Şekil 5.16 için sistemde oluşan veri tabanı kaydı..... 44

Tablo 5.15: Şekil 5.17 için sistemde oluşan veri tabanı kaydı..... 45

ŞEKİL LİSTESİ

Şekil 4.1: Görüntüden İnsan Algılama Programı Akış Şeması..... 13

Şekil 4.2: x_min: 453, y_min: 39, x_max: 541, y_max: 188 olan insanın resimdeki görüntüsü . 16

Şekil 4.3: Veri toplanan sahnenin kameradan alınan 640 piksel x 360 piksel boş resmi 17

Şekil 4.4: Görüntünün yumuşatılması için kullanılan dağılımın tek boyutlu uzaydaki ifadesi. ... 19

Şekil 4.5: Görüntünün yumuşatılması için kullanılan dağılım 2D çekirdek örneği gösterimi. 20

Şekil 4.6: 640 x 360 boyutlarındaki matrise işlenmiş ham veri..... 21

Şekil 4.7: Bir saatlik zaman diliminde 10104 konum bilgisi içeren yoğunluk (ısı) haritası..... 22

Şekil 4.8: Bir saatlik zaman diliminde 10104 konum bilgisi içeren veriden, Gaussian filtresi uygulanarak hazırlanmış yoğunluk (ısı) haritası..... 23

Şekil 5.1: Sistemin 1390493 id si ile %79 oran ile veri tabanına kayıt ettiği resim dosyası 25

Şekil 5.2: İki insan tespiti ile veri tabanına iki kayıt oluşturan resim..... 26

Şekil 5.3: Sistemin 1390496 id si ile %59 oran ile veri tabanına kayıt ettiği resim dosyası 27

Şekil 5.4: On insan tespit edilen resim dosyası..... 28

Şekil 5.5: Dokuz insan tespit edilen resim dosyası..... 29

Şekil 5.6: On insan tespit edilen resim dosyası..... 30

Şekil 5.7: On Sekiz insan tespit edilen resim dosyası..... 31

Şekil 5.8: On Yedi insan tespit edilen resim dosyası..... 33

Şekil 5.9: On Beş insan tespit edilen resim dosyası 35

Şekil 5.10: On Yedi insan tespit edilen resim dosyası..... 37

Şekil 5.11: On Beş insan tespit edilen resim dosyası 39

Şekil 5.12: 08:00-12:30 Saatleri arası 13302 konum bilgisi içeren yoğunluk haritası 40

Şekil 5.13: 13:30-17:30 Saatleri arası 26518 konum bilgisi içeren yoğunluk haritası 40

Şekil 5.14: Beşer kişilik iki takımın oynadığı karşılaşmadan On insan yakalanan örnek çıktı 42

Şekil 5.15: Beşer kişilik iki takımın oynadığı karşılaşmadan On insan yakalanan örnek çıktı 43

Şekil 5.16: Beşer kişilik iki takımın oynadığı karşılaşmadan Sekiz insan yakalanan örnek çıktı 44

Şekil 5.17: Dokuz insan yakalanan örnek çıktı..... 45

Şekil 5.18: 1471138 - 1473053 id leri arası 1915 konum bilgisi ile oluşturulan ısı haritası 46

Şekil 5.19: 1473054 – 1474421 id leri arası 1367 konum bilgisi ile oluşturulan ısı haritası..... 46

Şekil 5.20: 1474422 - 1476143 id leri arası 1721 konum bilgisi ile oluşturulan ısı haritası 47

Şekil 5.21: 1476144 - 1747857 id leri arası 1714 konum bilgisi ile oluşturulan ısı haritası 47

1. GİRİŞ

Internet Protokol (IP) kameralar üzerlerinde taşıdıkları teknoloji sayesinde yakaladığı görüntüyü Ethernet bağlantı noktasından yayın yapabilen kameralardır. Dolayısıyla akan görüntüye, kameranın IP adresine erişim sağlanarak, arada hiçbir aygıta ihtiyaç duymadan ulaşılabilir. Bu özelliği sayesinde güvenlik sistemlerinde, görüntü kayıt sistemleri ile birlikte kullanıldıkları gibi, kayıt ortamına ihtiyaç olmadan bağımsız şekilde de farklı amaçlar için kullanılabilirler.

Bilgisayarların işlemci güçlerinin artması dolayısıyla daha hızlı veri işler hale gelmeleri, IP kameraların uygun fiyatlarla yüksek kaliteye ve teknolojiye sahip olmaları, günümüzde değişik sektör ve alanda kameraların görsel takip aracı olarak kullanılması konusunda araştırmacıların çalışmalar yapmasının önünü açmıştır.

Günümüzde kameralar; mağazalar, marketler, devlet kurumları, eğitim kurumları, sanayi sektörleri, hizmet sektörleri gibi yerlerde kullanılmaktadır. Kameralar, canlıları ve nesneleri izlemek aynı zamanda kayıt altına alma amacıyla, güvenlik sistemleri, otomasyon sistemleri, geçiş sistemleri, kontrol sistemleri gibi sistemlerin ayrılmaz bir parçası ve destekleyicisi haline gelmiştir.

Günümüz teknolojisinde bilgisayar görmesi (bilgisayarın bir nesneyi tanımlayabilmesi/ tanıyabilmesi) büyük bir veriden tanımlanmak istenen nesne ile ilgili özelliklerin çeşitli karşılaştırma yöntemleri ve algoritmalar kullanarak, veri madenciliği yaparak, yapay zekâ algoritmaları gibi yöntemlerle, elinde büyük ve çok örnek barındıran veriler olan bilişim firmaları tarafından kusursuz başarıyla olmasa bile hatırı sayılır başarı oranları ile yapılabilmektedir. Kullanılan donanım teknolojilerinin, algoritmaların her geçen gün gelişmesi ve yeni yöntemlerin keşfedilmesiyle tanıma başarı oranı zaman geçtikçe artmaya devam etmektedir.

Nesne tanıma sistemleri gibi sistemler, Google gibi küresel firmaların ellerindeki verileri yorumlayan yoğun ar-ge çalışmaları ve büyük yatırımları sonucunda geliştirdikleri sistemler ve yöntemler yardımıyla işlevsel hale gelebilmektedir.

Bu çalışmada erişilebilir kaynaklar taranarak, nesne tespit eden, insan hareketlerini algılayan sistemler konuları irdelenmiş, bu doğrultuda nesne tanıma sistemleri konusunda yapılan çalışmalar nesne tanıma için kullanılan program kütüphaneleri ve örnek program kodları incelenerek, nesne hareketlerini kamera görüntüsü/imgesi yardımıyla tespit edebilen prototip bir sistem geliştirilmesi

hedeflenmiştir. Prototip sistem ile tespit edilen görüntülerde özellikle insan nesnesine yoğunlaşarak tespit ettiğimiz insan hareketlerini anlamlı ve yararımıza kullanılır hale getirilmesi konusu çerçevesinde, prototip sistem, bankolardan hizmet verilen bir irtibat bürosunda denenmiş ve geliştirilmiş, sonrasında spor sahalarında sporcuların performans ve egzersizleri sırasındaki yoğunluk / sahnede kapladıkları alanın haritasını çıkarmak için kullanılarak veriler toplanmıştır. Tez çalışması bünyesinde gerçek zamanlı olarak anlamlı ısı haritaları ile insan hareket yoğunluğu haritaları elde edilmesi hedeflenmiştir.

Tez çalışmasının 1. Bölümünde konu hakkında genel bir açıklama sunulmuştur. 2. Bölümde nesne tanıma, ısı haritası, görüntü işleme konuları hakkında genel bilgiler ve literatürde konu hakkında yapılan önemli çalışmalar hakkında özet bilgiler derlenmiştir. 3. Bölümde çalışmanın amacımız belirtilmiştir. 4. Bölümde çalışmada kullanılan metot, prototip sistem geliştirilirken kullanılan materyal, yazılım ve yazılım kütüphaneleri, sistemi kurgulanırken, sistemde çalışma yaparken izlenilen yol anlatılmıştır. 5. Bölümde çalışmada elde edilen bulgular, program çıktıları ve örnek görseller derlenmiştir. 6. Bölümde sonuç ve tartışma başlığı altında prototip sistemden elde edilen çıktıların kullanabileceği alanlar konusu irdelenmiştir.

2. GÖRÜNTÜ İŞLEME, NESNE TESPİT VE TANIMA, YOĞUNLUK (ISI) HARİTALARI

2.1 GÖRÜNTÜ İŞLEME

Görüntü işleme olayı, görüntü kaynağından (örneğin kameradan) resmi – görüntüyü sisteme aktardıktan sonra, görüntü içindeki insanları ya da tespit etmek istediğimiz objeyi ayıklama sürecidir. Bu süreç sistemin (bilgisayar) iki boyutlu bir dizi yardımıyla resmi bir fonksiyon olarak algılaması ve işlemi örneğin ses sinyallerini işlediği gibi işleyerek, programda (algoritmada) yorumlaması, nihayetinde bir sonuç, bir çıktı sunması işidir.

Bilgisayar biliminde, dijital görüntü işleme yöntemi dijital görüntülerin bir algoritma kullanarak işlenmesidir [1-2]. Dijital sinyal işlemenin analog görüntü işlemeye nazaran birçok üstünlüğü vardır. Bu yöntemler kullanarak çok farklı algoritmalar türetilebilir ve bunun sonucunda gürültü ve bozulma gibi problemler en aza indirilebilir. Görüntüler en az iki boyutta tanımlanır ve dijital görüntü işleme çok boyutlu sistemler biçiminde düşünülebilir. Dijital görüntü işleme teknikleri temel olarak, güncel bilgisayar altyapısı, matematiksel teorilerin gelişimi, dijital görüntü işlemeye olan talep doğrultusunda şekil alır.

Dijital görüntü işleme yöntemleri 1960'lı yıllarda Bell laboratuvarları, Jet İtiş Laboratuvarı, Massachusetts Teknoloji Enstitüsü, Marylan Üniversitesi tarafından geliştirilmiştir. İlk kullanım alanları, uydu görüntüleme, tıbbi görüntüleme, görüntülü telefon, karakter tanıma ve fotoğraf detaylandırma şeklindedir [3]. İlk başarılı uygulamalar, 1964 yılında Jet İtiş Laboratuvarı'nda Uzay Detektör Gezgini (Space Detector Ranger) tarafından gönderilen ay görüntülerindeki geometrik düzeltme, gürültü azaltma v.b. uygulamalar şeklindedir. Daha sonraları, ayın topografik haritası, renk haritası elde etmek için 100.000'e yakın görüntü işlenmiş ve bu olay insanın aya çıkmasının somut bir hale gelmesine yol açmıştır [4].

Görüntü işleme yöntemlerinin başlıca kullanım alanları arasında, anizotropic difüzyon, görüntü restorasyonu, sinir ağları, kendi-kendine oluşan haritalar, doğrusal filtreleme, temel bileşen analizi bulunur.

Görüntü işlemede kullanılan dönüşüm teknikleri görüntünün farklı dönüşümlerine yol açar. Bu dönüşüm teknikleri arasında özdeşlik (identity), yansıma (reflection), ölçeklendirme (scale), döndürme (rotate) ve kayma (shear) operatörleri mevcuttur [6].

Özdeşlik, tek bir doğruyla gösterilir. Bu geçişte, girdi görüntünün her bir değeri çıktı görüntünün her bir diğer değerine örtüştürülür. Bu yöntemle, girdi görüntüsü ve çıktı görüntüsü eşitlenir. Buna özdeş dönüşüm denir.

Yansıma, yansıma çizgisi üzerine görüntünün katlanması ya da döndürülmesi anlamındadır. Yansıma, örneğin su üzerinde, ayna yüzeyinde görülebilir. Yansıyan obje ve yansıma aynı şekilde ve büyüklükte, fakat farklı yönlerdedir.

Ölçeklendirme, görüntünün görsel görünüşünü ve boyutunu değiştirme odaklı bir işlemdir. Bunda amaç, görüntüde saklanan bilginin miktarını değiştirmedir. Bir vektör grafiği, geometrik dönüşüm kullanılarak görüntü kalitesinde bozulma olmadan ölçeklendirilebilir.

Döndürme, görüntünün bir koordinattan diğerine belirli bir açı ile orijin etrafında döndürülerek gerçekleştirilen geometrik bir transformasyondur. Bu operasyonun dönüşümden farklı elde edilen koordinatların tam sayılar şeklinde olmayabileceğidir.

Görüntünün şeklini belirli bir yönde değiştirme işlemine kayma denir. Kayma, *x*-yönünde ya da *y*-yönünde olabilir. İlki *x*, koordinatlarını sonraki ise *y* koordinatlarını değiştirir. Her iki durumda sadece tek bir yönde koordinatlar değiştirilir ve yamultulmuş bir görüntü elde edilir.

2.2 NESNE TESPİTİ VE NESNE TANIMA

Nesne tespitini; anlamlı hale getirmeyi hedeflediğimiz karmaşık sayısal imgenin içinden, bulmak istediğimiz objenin, bu karmaşık imgenin içinde olduğunu / olmadığını tespit etme işidir şeklinde tanımlayabiliriz. Dolayısıyla eğer imgeyi tespit edersek bu imgenin resmin neresinde / hangi piksellerinde olduğunu da anlayabiliriz.

Nesne tespiti bilgisayarlı görü üzerine çalışmalar yapan araştırmacıların uzun zamandır çalışmalar yaptıkları ve günümüzde oldukça isabetli ve başarılı tespit oranlarına ulaştıkları bir konudur.

Nesne tanıma işlemi sinir ağı modelleri, yapay zekâ ve derin öğrenme metotlarını kullanarak geliştirilen algoritma ve hesaplama teknikleriyle gelişim göstermektedir.

Esas olarak derin öğrenme, insan aklının/beyninin çalışma prensibini anlamaya çalışıp, onu örnekleyen hesaplama metotlarını kendine kılavuz olarak alır.

Yapay Sinir ağı modelinin kayda değer ilk örneği 1943 yılında Warren S. McCulloch ve Walter Pitts 'in beynin düşünme sürecini kopyalamak üzere sinir mantığı denilen algoritmalarla bir hesaplama çeşidi keşfetmeleri ve bu çalışmayı geliştirmelerine dayanır. Çalışmada sinir ağlarının temeli atılmıştır denilebilir. İlk yapay sinir ağı hücresinin yapısını oluşturan sinir ağı modeli bu çalışmada şekil almıştır. Warren S. McCulloch ve Walter Pitts çalışmasında sinir aktivitesinin "ya hep ya hiç" karakteri nedeniyle, sinirsel olaylar ve bunlar arasındaki ilişkiler, önermeli mantık yoluyla ele alınabilir der ve bu doğrultuda bir hesaplama çeşidini anlatırlar. Özetlersek insan beyninin analiz ve hesaplama yönteminden esinlenerek bir yapay sinir ağı hücresi geliştirmişler ve mantıksal ifadelerin bu hücre ile insan beyninin çalışmasına benzer bir yöntemle formulüze edilmesinin mümkün olabileceğini anlatmışlar, sonrasında birden fazla hücrenin paralel olarak çalıştırılmasıyla öğrenme kurallarının belirlenmesi üzerinde durmuşlardır [7].

Yapay Sinir Ağı modeli ile yapılan bir diğer çalışma Navneet Dalal and Bill Triggs tarafından gerçekleştirilmiştir. Bu çalışmada yönelimli gradyen histogramlarının örgülerinin (İngilizce: grid) diğer mevcut örgü yaklaşımlarına göre daha iyi performans gösterdiği belirtilmiştir. Bu yeni yaklaşımla, orijinal MIT yaya veri tabanında mükemmele yakın bir ayrım sağladığı görülmüş ve 1800'e yakın farklı pozlarda ve farklı arka plandaki insan görüntüsünü barındırdığı belirlenmiştir [8].

Derin öğrenme yaklaşımları içerisinde; Konvolüsyonel (Evrişimsel) Sinir Ağları (CNN: Convolution Neural Network) yaklaşımını barındıran Bölge Önerisi (Region Proposals) yaklaşımı bulunmaktadır [9-11]. Bu yaklaşımda, görüntülerin belirli kısımlarını bölüt şekline tanımlayan bir algoritma kullanılmaktadır [9]. Görüntünün her bir bölgesini ayrı şekilde sınıflandırma temel yaklaşımdır. İkinci bir yöntem, Tek Atımlı Çok Kutu Detektörü (SSD: Single Shot MultiBox Detector) [12] olarak adlandırılmaktadır. SSD yaklaşımında, görüntü içinde belirlenmiş nesneler pozitif ve negatif işaretlenir ve bulundukları farklı boyutlardaki karelerin ağırlıklı ortalaması alınır. Diğer yöntemlerden olan Yalnızca Bir Kez Bak (YOLO: You Only Look Once) [13-15] yaklaşımında görüntünün zaman içindeki değişimi gerçek zamanlı olarak takip edilebilmektedir. Son olarak ta, iki-adımlı CNN yaklaşımlarına nazaran daha verimli bir Nesne Tanıma için Tek

Atımlı Sinir Ağı Rafinelendirilmesi (RefineDet: Single-Shot Refinement Neural Network for Object Detection) [16] yöntemi literatüre önerilmiştir.

Kameralardan elde edilen ve dijital ortama aktarılan resim, video gibi materyallerden ilk kez anlamlı ve iş görür hızda, nesne tanıma algoritması geliştiren ve literatüre katkı sağlanan çalışma 2001 yılında Viola ve Jones tarafından yayınlanmıştır. Gerçekleştirdikleri çalışmada Viola ve Jones piksel bloklarının aralarındaki ilişkiyi öğrenme doğrultusunda kurguladıkları bir algoritma ile nesne tanıma / tespit etme yöntemi geliştirmişlerdir. Bu yöntem ile yüksek başarı oranı ile tespit ettikleri nesneleri, daha önceki örneklerine göre çok hızlı bir şekilde tespit etmişler ve bu yöntemi yayınlamışlardır [17].

2.3 YOĞUNLUK (ISI) HARİTASI

Isı haritaları web sayfasını ziyaret eden misafirlerin istatistiklerini renklerle göstermek, coğrafi konularda özet görsel raporlar alınması ya da tez çalışmamızda olduğu gibi çok fazla veri içeren bir bilgi yumağını sade ve anlaşılır şekilde göstermek için kullanılabilir. Isı haritası, ilgilenilen büyük veriyi daha anlaşılır bir hale getirir ve raporlama işleminin sunumunun daha kolay olmasını sağlar. Büyük verilerden süzülmüş, renkli ve tek çıktı halinde alınan özet raporlar, yönetici/karar verici mercilerin zaman kaybetmeden hızlı bir şekilde karar vermelerini sağlar nitelikte görsel özet veriler içerirler.

Yoğunluk haritası bir matristeki bağımsız değerlerin renk olarak gösterildiği; verilerin grafiksel bir temsilidir. Yoğunluk haritası "Isı haritası" (Heat Map) olarak da adlandırılır. Isı haritası günümüzde eskiye nazaran daha sık kullanılmasına rağmen, yüzyılı aşkın bir süredir gölgeleme matrisleri mevcuttur [18].

Yoğunluk haritası bir veri matrisindeki değerlerin sıklığını renk skalası olarak belirten iki boyutlu gösterimdir. Yoğunluk haritasının renk tanımına örnek olarak, daha büyük değerler görülür renk spektrumunda düşük frekanslı kırmızı ve kırmızıya yakın renkler şeklinde, daha küçük değerler ise yüksek frekanslı mavi ve maviye yakın değerler şeklinde temsil edilir. Yoğunluk haritalarına ilk örnekler olarak, Loua (1873) Paris'in ilçelerindeki sosyal istatistikleri karakterize etmek için bir gölgeleme matrisi kullandı [18]. Sneath (1957) ise daha sonraları, elde edilen matrislerin anlamlandırılması için, matrisin küme içerisindeki elemanlara karşılık gelen satırlarının ve sütunlarına birbirine yakın değerler yerleştirerek bir küme analizini gerçekleştirmiştir. Küme

elemanlarını veri matrisinin satırlarına ve sütunlarına birleştirme fikri 1973 yılında Robert Ling ile ortaya çıktı. Yüksek çözünürlüklü renkli grafiklere sahip küme ısı haritaları üreten ilk bilgisayar programını (SYSTAT) 1994 yılında geliştirildi (Leland Wilkinson).

Yoğunluk haritası terimi, 1991 yılında finansal piyasa bilgilerini tasvir eden bir iki boyutlu ekranı tanımlamak için bir ticari marka olarak kullanıldı [19].

Yoğunluk haritalarında birçok farklı renk şeması kullanılabilir. Genellikle, insanların dikkatini daha iyi çekebilmek ve görüntüde algılanabilir ayrıntı miktarını arttırmak adına gökkuşağı renk haritaları sıklıkla kullanılır. Fakat bilimsel camiada birçok kişi tarafından bu yaklaşım önerilmemektedir [20-24]. Bunun sebepleri arasında, ise gökkuşağı renkleri gri tonlamalı veya kara cisim spektrumlu renk haritalarında bulunan doğal algısal sıralamaya sahip değildir [20]. Sıklıkla kullanılan renk haritalarında, basım işlemi için gri tonlamaya çevrildiğinde dönüşüm yanlış sonuçlar verebilmektedir. Örneğin, sarı ve camgöbeği renkleri diğer daha önemli bölgeleri belirten renklere göre daha öne çıkabilmektedir [20].

Renkler arasındaki değişiklikler, gerçekte mevcut olmayan gradyanların görülmesine yol açarak, gerçek gradyanların daha az anlaşılmasına, bu da gökkuşağı renk haritalarının pek çok durumda ayrıntıyı belirtmek yerine gizleyebileceği sonucunu doğurmaktadır [20] [24].

3. AMAÇ

Bu çalışmada insan hareketlerini kamera yardımı ile sayısal verilere dönüştürerek bu verilerden belirlediğimiz bölge ve zaman dilimindeki insan yoğunluğu (ısı) haritasını / haritalarını çıkarmak dolayısıyla büyük veriyi sadeleştirerek anlamlı ve veri toplanan resmi ya da özel kuruluşun yararına kullanılabilir hale getirmek, spor sahasında, egzersiz veya performans sergilenirken elde edilen görüntülerden ısı haritaları üreterek, kişilerin/ spor sahasındaki oyuncuların zaman içerisinde kapladıkları alanın boyutunu görüntülemeye olanak verecek sistem prototipinin üretilmesi hedeflenmiştir.

İnsanların yoğun olarak bulundukları yerleri tespit etmek, ayrıca daha uzun süre kalma eğiliminde olunan ya da verimsiz/aksak kullanımdan dolayı yoğunluğa sebep olan durumlarının belirlenmesi amaç dâhilindedir.

Tasarlanan sistem prototip olup, faklı dijital görüntü tipleri ve farklı ortam / sahne tiplerinde kullanılabilecek şekilde amaca yönelik gelişime açık durumdadır.

4. MATERYAL VE METOT

Çalışmada standart bir masa üstü bilgisayar ve standart bir IP güvenlik kamerası ile prototip bir sistem kurgulanmıştır. Linux, Python, SQLite gibi ücretsiz yazılımlar ve bu yazılımlarda kullanılabilen ücretsiz kütüphaneler yapılandırılarak bilgi toplama işlemi gerçekleştirilmiş, sonrasında bu verilerden Matlab programı yardımıyla yoğunluk (ısı) haritaları çıkarılmıştır.

4.1 KAYIT DONANIMI VE YAZILIMI

Prototip sistem donanımını kurgularken donanım olarak sektörde kolaylıkla bulunabilecek orta kalitede, fiyat / performans oranı iyi olan, sorunsuz olarak bilinen marka ve model bileşenler tercih edilmiştir. Sistemde yazılım olarak ulaşılması kolay ücret ödenmeden elde edilebilen ve akademik dünyada kullanımı, bilgi paylaşımı çok olan işletim sistemi, programlama dili ve kütüphaneleri tercih edilmiştir.

4.1.1 Donanım

Masa üstü bilgisayar kasası olarak, üzerinde Cooler Master Marka B400 Model ATX (Advanced Technology Extended) Bağlantılı 400 Watt Güç Kaynağı bulunan Cooler Master Marka, kasa içerisinde fazladan iki adet soğutma fanları olan bir bilgisayar kasası kullanılmıştır. Bilgisayar bileşenleri proje denemeleri ve geliştirmeleri boyunca yaklaşık beş ay boyunca sorunsuz çalışmıştır. Kasa ve bileşenleri sıcaklık seviyeleri Linux tabanlı PSensor Isı Monitör programıyla sürekli kontrol edilmiş sıcaklık değerleri tüm bileşenlerde sınırlar dâhilinde seyretmiştir. Çalışma ve veri toplama aşamalarında da herhangi bir kapanma, donma, yavaşlama, aşırı ısınma gibi sorunlar gözlemlenmemiş bilgisayar ve bileşenleri istikrarlı bir şekilde proje boyunca hizmet vermiştir. Ana Kart olarak Asus Marka H61M-K Model Intel H61 Express Yonga Setli, üzerinde; 1 x PCIe (Peripheral Component Interconnect Express) 3.0, 4 x SATA (Seri ATA – Seri Attachment) 3Gb/s port, 1 x LAN (Local Area Network)- RJ45 (Registered Jack 45) port ve diğer standart portları bulunan bir ana kart kullanılmıştır. İşlemci olarak Intel Marka i5-3470 Model 3.20GHz × 4 çekirdekli CPU (Central Process Unit) kullanılmıştır. Hafıza olarak Kingston Marka HyperX Model DDR3 (Double Data Rate 3) 1600MHz 8 Gigabayt Kapasiteli iki adet toplam 16 Gigabayt RAM (Random Access Memory**)** hafıza kullanılmıştır. Sabit Disk olarak Seagate Marka Sata3 Standardında Barracuda ST2000DM006 Model 2 Terabayt Sabit Disk ana kartın SATA

portuna takılarak kullanılmıştır. Prototip sitemimizde Nvidia Marka GeForce Model GT740 Yonga Setli ana kartın PCIe portuna takılan 2 Gigabayt Hafızalı harici grafik GPU (Graphics Processing Unit) kullanılmıştır.

4.1.2 Yazılım

Sisteme Linux Mint 19.2 "Tina" Cinnamon (64-bit) İngilizce işletim sistemi standart yöntemle herhangi bir ayar yapılmadan yüklenmiştir. Bu yükleme sonunda sistemin grafik kartı dışında bütün donanım bileşenlerini tanıdığı gözlemlenmiştir. Ekran kartının sürücüsüde; sistemin sürücü yönetimi kısmından sistemin otomatik olarak oluşturduğu listeden, sistemin tavsiye ettiği ekran kartı sürücüsü seçilerek yükleme internetten otomatik olarak tamamlanmıştır. Programlama dili olarak tümleşik bir Python dağılımı olan Anaconda Python 3.7 Versiyonu kullanılmıştır. Phyton yazılım dilinde kodlanan program ile görüntü işleme işlemlerini yapabilmek için; Tensorflow sürüm: 1.10.0, Imageai sürüm 2.1.4, Opencv sürüm 3.4.2 kütüphaneleri kullanılmıştır. Veri toplama işleminin kodlarının üretilmesini kolaylaştırmak içinde Peewee sürüm 3.10.0 Nesne-İlişkisel Haritalama (ORM-Object Relational Mapper) si Ptyton kodunu oluşturken kullanılmıştır. Python programlama dili yüklendiğinde varsayılan olarak gelen Phyton Shell komut satırıyla kullanılan PyCharm sürüm 2019.2.5 IDE (Integrated Development Environment-Tümleşik Geliştirme Ortamı) sının sunduğu etkileşimli kabuk (interactive shell) den faydalanılmıştır. Verileri toplamak için Anaconda Python ile birlikte varsayılan olarak gelen SQLite veri tabanı tercih edilmiştir. Ayrıca veri tabanı tablosunda toplamak istediğimiz verileri oluşturmak için Python nesneleriyle veri tabanı tablosunda köprü olarak Peewee ORM ‘si kullanılarak veri tabanı işlemlerine esneklik, kullanışlılık ve daha sonraki kod geliştirmelerinde kolay bir kullanım sağlanmıştır. Bunların dışında, SQLite veri tabanına kayıt edilen verileri görüntülemek, dışa aktarma (örneğin tablomuzu excel e aktarma) yapmak gibi işlemleri kolaylıkla yapabilmek için SQLite DB Browser’ın 3.10.1 sürümünden faydalanılmıştır.

4.1.2.1 Tensorflow

2015 yılı Kasım ayında Google Tensorflow makine öğrenme sisteminin kaynak kodlarını herkese açtığını duyurmuştur [25]. Google firmasının kodları paylaşıma açmasından sonra bu konudaki araştırmacıların ulaşabileceği yaygın kullanım örnekleri türemiş, geliştirilebilir ve ulaşılabilir hale gelmiştir. Prototip sistemde Tensorflow’un 1.10.0 sürümü kullanılmıştır. Tensorflow Google

tarafından geliştirilen açık kaynak kodlu bir kütüphanedir. Hesaplamaları yaparken kodda belirtilen GPU yu kullanmaya olanak sağladığı gibi; iki ya da daha çok GPU kullanmaya da imkân sağlayabilecek makine öğrenme ve faklı hesaplamalar içinde kullanılabilen zengin yapıda bir kütüphanedir. Tensorflow görsel tanımanın yanı sıra konuşma ve tercüme gibi alanlarda da kullanılabilecek gelişim gösterecek bir yapıdadır. Prototip sistemde görüntü işleme işlemlerinde GPU (Ekran kartını) kullanabilmek için Tensorflow kütüphanesinden faydalanılmıştır.

4.1.2.2 Imageai

Imageai güçlü ve kullanımı kolay olan işlevsel bir nesne algılama kütüphanesidir. Imageai ile Tensorflow ‘un özellikleri kullanılarak kodlar kolay bir şeklide Phyton koduna eklenmiştir. Prototip sistemde Imageai’nin YOLOv3 Yalnızca Bir Kez Bak (YOLO: You Only Look Once) derin öğrenme algoritması kullanılmıştır. Bu algoritma insan dışında günlük hayatta karşılaşılan seksen farklı türdeki nesneyi tanıyabilir [26]. Program kodunda insan dışındaki nesnelerin tanınması göz ardı edilerek sadece insan objesine odaklanılmıştır. Farklı kullanım alanlarına göre kodda yapılacak değişikliklerle prototip sistem faklı nesneleri de tanır hale getirilebilir.

4.1.2.3 Opencv

Open Source Computer Vision Library yani kısa haliyle OpenCV görüntü işlemede kullanılan açık kaynak kodlu bir kütüphanedir. Bu kütüphaneden dijital görüntü kaynağından (ip güvenlik kamerası) resim almak için faydalanılmıştır. Prototip sistemdeki kameradan akan görüntüden görüntü yakalayarak, yakalanan görüntüyü resim formatına çevirmeye ve resmi işlemek üzere sisteme kayıt etmede OpenCV kullanılmıştır.

4.2 BİLGİ İZLEME DONANIMI

Prototip sistemde, sürekli çalışmaya uygun olarak tasarlandıkları ve dayanıklı ve istikrarlı performans sergiledikleri için standart bir IP güvenlik kamerası kullanılmıştır. Spy Marka Evo SP J4020B Model IP Tabanlı 2 Mega Piksel 3.6 mili metre Lensli Standart Güvenlik Kamerası 12 Volt 2 Amper güç adaptörü ile çalıştırılmış, Yaklaşık yirmi Metre uzunluğunda CAT5 Network kablosu ile Bilgisayarın RJ45 girişine bağlanmıştır.

Prototip sistem sadece bir kamera ile kurgulandığından, kamerayı bilgisayara bağlamak için network switch gibi bir ağ bileşeni kullanılmamış, kamera, bilgisayara arada bir aygıt olmadan

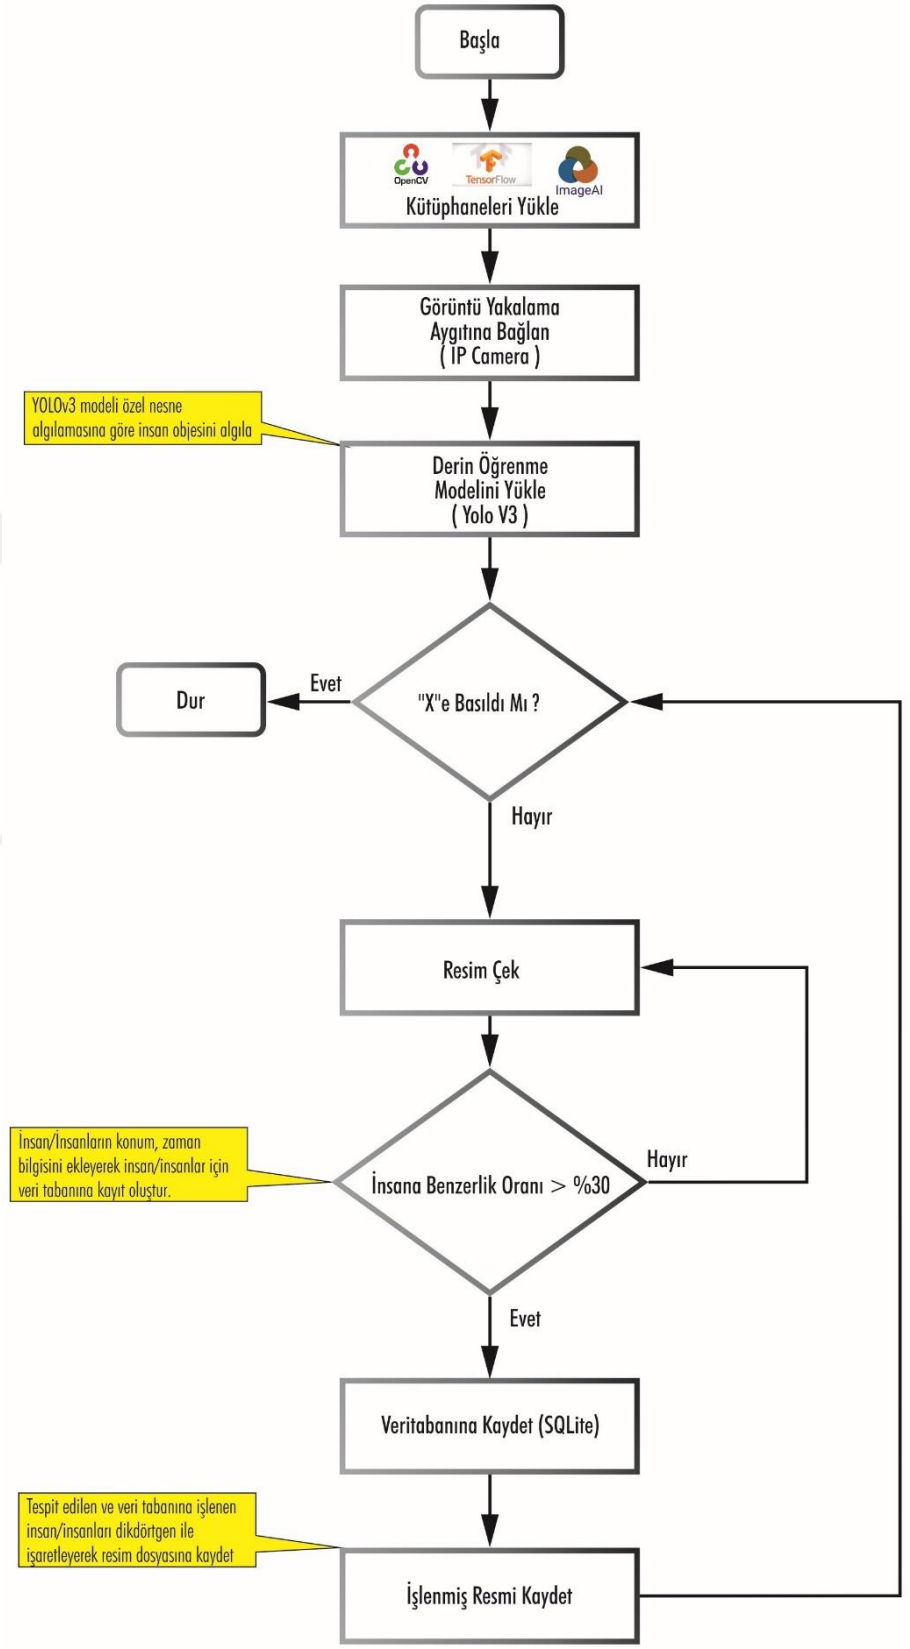
standart CAT5 network veri kablosu ile RJ45 girişinden bağlanarak bilgisayar ile kamera arasında bir yerel alan ağı (LAN) yapılandırılmıştır.

4.3 GÖRÜNTÜLERDEN KİŞİ ALGILAMA

Sistem görüntü işleme döngüsünde, kameradan aldığı resimleri art arda işler, eğer işlediği görüntüde yakaladığı nesne, algoritmanın kararına göre %30 ve daha yüksek oranda insansa, yani yakalanan objelerden, insan objesi sayısı, sıfırdan büyükse veri tabanımıza zaman damgası ile birlikte insanın/insanların resimdeki konumunu yazar. İnsan tespit ederek işlemden geçirdiği görüntüyü, sistemde belirttiğimiz bir depolama alanına her resmi özgün (date_time.bmp) adı ile insan/insanları dikdörtgen kare ile işaretleyip tespit ettiği insan objesinin yüzde kaç oranında insan olma ihtimali olduğu bilgisini de dikdörtgenin üzerine ekleyerek (date_time.bmp) dosya ismi ile sisteme kaydeder; sıradaki resme geçerek döngü çalışmaya devam eder. Programın akış diyagramı Şekil 4.1 de, program kodu da tezin son kısmında ekte verilmiştir.

Sistemde değiştirilecek bir kod ile sistem resim kayıt etmeden de bilgileri veri tabanına kayıt edilebilir. Prototip sistem ile üretilen dataları, görsel olarak incelemek ve yorumlamak için sistemin ürettiği ve veri tabanına konum bilgisi işlenen resimler tek tek kayıt edilmiştir.

Görüntü işleme döngüsünün tamamlanması resmin işlenip işaretlenerek kaydedilmesi ve veri tabanına bilgilerinin işlenmesi (Program Çıktıları ve Bulgular) başlığı altında örneklerini göreceğiniz üzere yaklaşık bir ile üç saniye arasında sürer. Dolayısıyla sistem insan tespit ettiği sürece (sahnede insan %30 oranından küçük ya da hiç insan olmadığı zamanlar dışında) yaklaşık iki saniyede bir işlenmiş ve insan nesneleri işaretlenmiş olarak sisteme resim kaydederek veri tabanına insanların konum bilgisini yazar. Yoğunluk (ısı) haritasında insanların en çok zaman harcadıkları yeri / yerleri tespit etmek amaçlandığından, başka bir deyişle aynı kişiyi takip etmek anlam ifade etmediğinden; sistemde döngü süresinin kısalmasına yönelik iyileştirme çalışması yapılması ihtiyacı duyulmamıştır. Kısaca, prototip sistem için kişi takip etmekten çok, kişinin / kişilerin belirlenen sahnede bulunma verisini görmek önemlidir. Önerilen sistemin donanımında yapılacak iyileştirmeler; daha hızlı bir kamera, daha hızlı bir işlemci, daha hızlı bir sabit disk ve daha hızlı bir grafik kartı ile bu sürenin kısaltılması olanak dâhilindedir.



Şekil 4.1: Görüntüden İnsan Algılama Programı Akış Şeması

4.4 VERİ TABANI TASARIMI VE TABLOLARI

Verileri toplamak için Anaconda Python ile birlikte varsayılan olarak gelen SQLite veri tabanı tercih edilmiştir. Veri tabanı tasarlanırken yoğunluk haritası (ısı haritası) çıktıları oluşturulabilecek verilerin veri tabanına yazılması sağlanmıştır. Veriler bu doğrultuda veri tabanına işlenmiştir.

Belirlenen parametreler dâhilinde sistem tarafından algılanan her obje (insan) için id, zaman, konum ve doğruluk (objenin ve konumunun doğru tespit edilme oranı) veri tabanına kayıt edilir.

4.4.1 Veri Tabanı Tablo Alanları

Veri tabanı tablosuna kayıt ettiğimiz verilere ait örnek veri tabanı çıktısı Tablo 4.1'de örneklenmiştir. Veri tabanı sütunlarımız id, date_time, x_min, y_min, x_max, y_max, percentage_probability sütunlarıdır. Bu sütunlarda toplanan verilerin ayrıntılarına aşağıda sırasıyla değinilmiştir.

Tablo 4.1: SQLite DB Browser'dan Alınan Örnek Veri Tabanı Görseli

id	date_time	x_min	y_min	x_max	y_max	percentage_probability
1	2019-06-11 08:54:25.178264	63.0	184.0	154.0	308.0	99.76
2	2019-06-11 08:56:33.849514	0.0	24.0	129.0	210.0	92.82
3	2019-06-11 08:56:33.849514	68.0	157.0	188.0	324.0	99.79
4	2019-06-11 08:56:36.996331	69.0	154.0	187.0	325.0	99.85
5	2019-06-11 08:56:39.409064	0.0	14.0	67.0	165.0	52.16
6	2019-06-11 08:56:39.409064	69.0	157.0	187.0	322.0	99.79
7	2019-06-11 08:56:41.932951	69.0	153.0	187.0	324.0	99.87
8	2019-06-11 08:56:45.192299	0.0	18.0	73.0	221.0	55.47
9	2019-06-11 08:56:45.192299	68.0	151.0	187.0	326.0	99.80
10	2019-06-11 08:56:46.750441	69.0	152.0	187.0	325.0	99.86

4.4.1.1 id

(id) sütününa 1 den başlayarak ardışık olarak her kayıt için rakam işlenmiştir.

4.4.1.2 date_time

(date_time) sütununa zaman işlenmiştir. Zaman formatı Yıl-Gün-Ay Saat: Dakika: Saniye şeklindedir.

Örneğin: 2019-06-11 08:54:25.178264 datasını ele alırsak;

Yıl : 2019

Ay : 06

Gün : 11

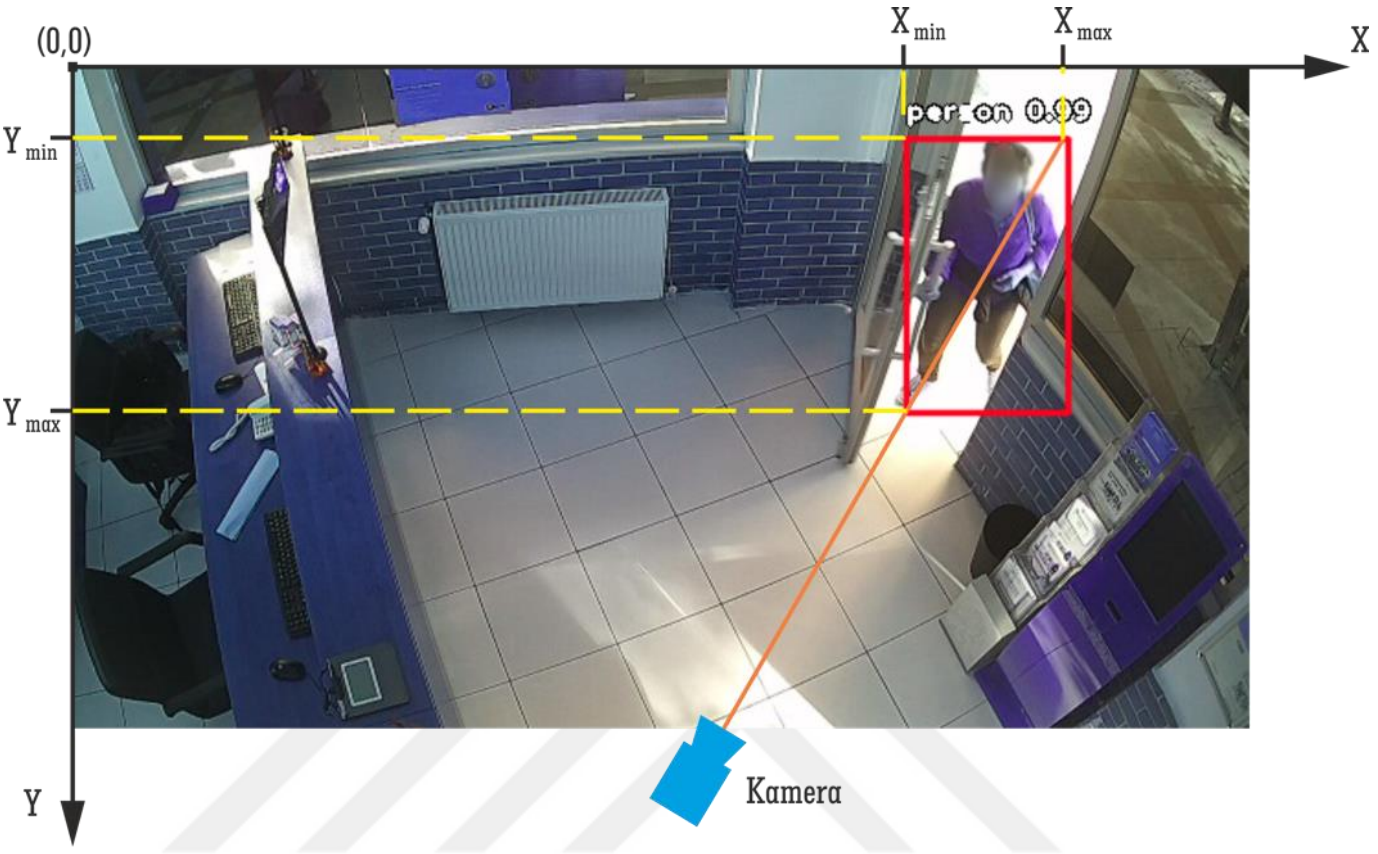
Saat : 08

Dakika :54

Saniye :25.175264 şeklinde zaman bilgisi veri tabanına kayıt edilmiştir.

4.4.1.3 x_min, y_min, x_max, y_max

X (0 dan 640'a) Y (0 dan 360 a) Nesnenin resimde kapladığı alanın koordinatlarını (yerini) belirtir. Sahnemiz 640 piksel x 360 pikseldir. Şekil 4.2 'de koordinat gösterimi örneklenmiştir.



Şekil 4.2: x_min: 453, y_min: 39, x_max: 541, y_max: 188 olan insanın resimdeki görüntüsü

Tablo 4.2: Şekil 4.2 ‘deki insan tespitinin veri tabanı kaydı

id	date_time	x_min	y_min	x_max	y_max	percentage_probability
1390357	2019-11-06 11:10:36.553410	453.0	39.0	541.0	188.0	99.48

4.4.1.4 percentage_probability

Image AI YOLOv3 Modeline göre nesnenin insan olma olasılığı ve etrafındaki kutunun koordinatlarından ne kadar doğrulukla emin olduğunu yüzde değer olarak gösterir.

Örneğin: 99.48

Tespit sistemin de kullanılan modele göre %99 oranında, tespit edilen nesne insandır ve koordinatları bu oranda doğru belirlenmiştir denebilir.

Bu oranı dikkat alarak kodu derlerken veri tabanına kaydetmek istenen insan olma ve koordinatları doğru yakalama oranı belirtebilir. Örneğin %30 ve daha büyük olasılıkla tanımladıklarını kaydet (dikkate al) gibi. Prototip sistemde %30 ve daha büyük oranlar kayıt altına alınmıştır.

4.5 ISI HARİTASI OLUŞTURMA AŞAMALARI

Yoğunluk haritası oluşturulurken, ısı haritasının işleneceği sahneden elde edilen boş (insan olmayan) bir resim üzerine dört işlem uygulanmıştır: 1) Veri aktarımı ve hafıza tahsisi, 2) Isı haritası oluşturma, 3) İmge yumuşatma işlemi, 4) Görselleştirme işlemi.

4.5.1 Veri Aktarımı ve Hafıza Tahsisi

Başlangıç noktası veri toplanan sahneden alınan boş resimdir. Resimde konum verisi olarak, 640 piksel x 360 piksel boyutlarında bir matris tanımlanmıştır. Ayrıca, bu boyutlarda elemanları sıfır olan bir matris oluşturulmuştur. Şekil 4.3'de veri toplanan sahnenin boş resmi gösterilmiştir.



Şekil 4.3: Veri toplanan sahnenin kameradan alınan 640 piksel x 360 piksel boş resmi

4.5.2 Isı Haritası Oluşturma

Veri tabanından alınan yoğunluk haritasının verileri içerisinden istenilen bir zaman dilimine karşılık gelen koordinat bilgileri alınır. Diğer bir değişle, tespit edilen ve dikdörtgen ile işaretletilen insanların koordinat bilgileri. Koordinat bilgisi olarak, tespit edilerek işaretlenen dikdörtgen 'in orta noktasının (x, y) koordinatı kastedilmektedir. (x orta nokta koordinatı, y orta nokta koordinatı) Aldığımız (x, y) koordinat verilerini sahnedeki (resimdeki piksellere) aktardık.

Veriler aktarılırken, sahnede bulunan aynı konum bilgilerine sahip pikselle birden fazla kez karşılaşılması durumunda veri tabanından alınan, değer bir arttırılır. Bu durum denklem 4.1' de gösterilmiştir.

$$f(x, y) = f(x, y) + 1 \tag{4.1}$$

Bu formül döngüye alındığında istenilen zaman dilimindeki veri tabanına işlenen tüm veri piksellere aktarılmaktadır. Böylece çalışma yapılan sahnede toplanan veriden belirli bir pikselde kaç kere insan tespit edilmiş bilgisi resme aktarılmış olur. Nesne bulma sonucunda elde edilen koordinatların ondalık küsuratları yuvarlanarak, koordinatlar tamsayı haline döndürülerek, Denklem 4.3 de konu edilmiştir.

4.5.3 İmge Yumuşatma İşlemi

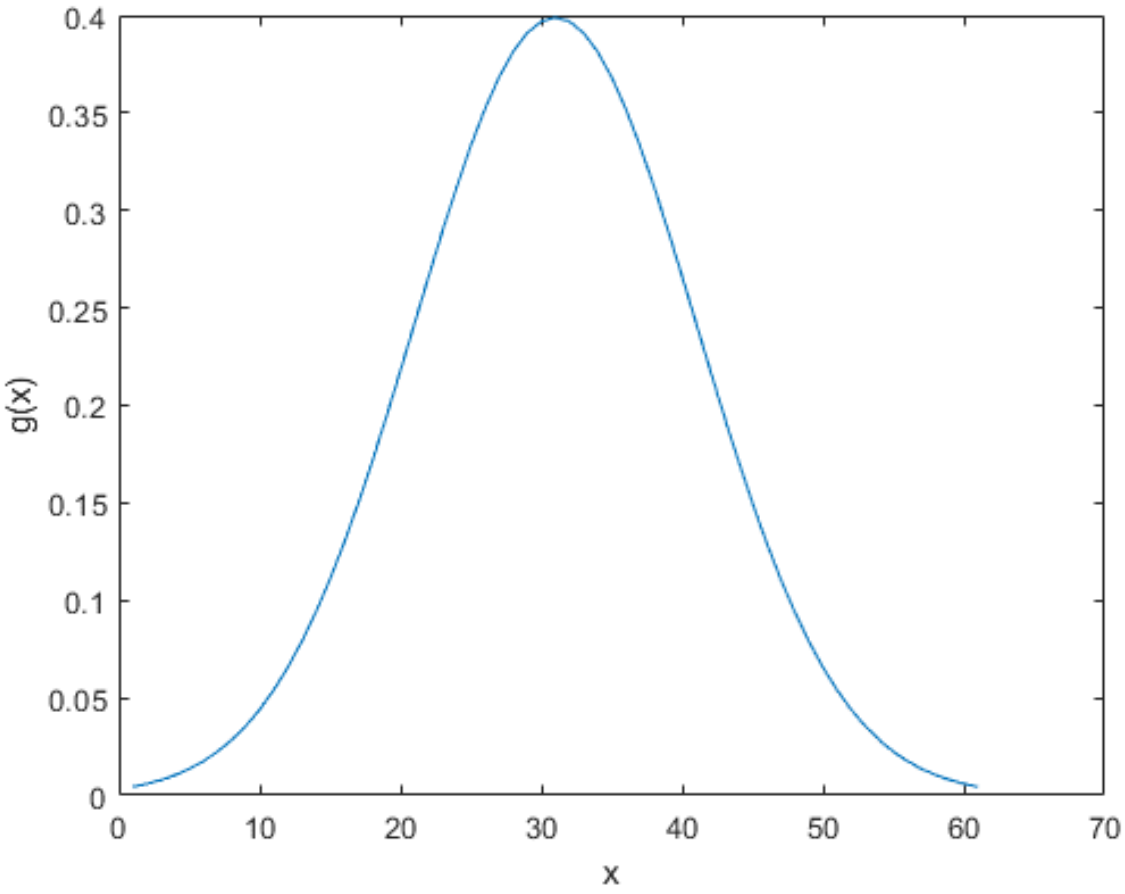
Yoğunluk haritası elde etmek için resme aktarılan veriler bir nokta bilgisi şeklindedir. Obje insan olarak düşünülürse, yoğunluk haritası oluşturmak için insanın aslında bir nokta ile ifade edilmesi çok anlamlı bir çıktı sunmayacaktır. Esasen insan bir dağılım olarak sahnede bulunmaktadır. Bu durumdan yola çıkarak daha anlamlı bir ısı haritası elde edebilmek için Gaussian fonksiyonu ile noktaları bir dağılım halinde yumuşatma işlemi yapılmıştır. Başka bir değişle, Gaussian filtresi kullanarak ısı haritası görseli daha anlamlı bir hale getirilmiştir. Tek boyutlu uzayda Gaussian çekirdek fonksiyonu, Denklem 4.2 kullanılarak, Şekil 4.4 de ise örnek olarak sunulmuştur. Buna karşın, tek boyutlu sinyalin evriğinin kendisiyle çarpılması sonucu elde edilen imge Denklem 4.3 de, resim ise Şekil 4.5 de ifade edilmiştir.

$$g(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} \tag{4.2}$$

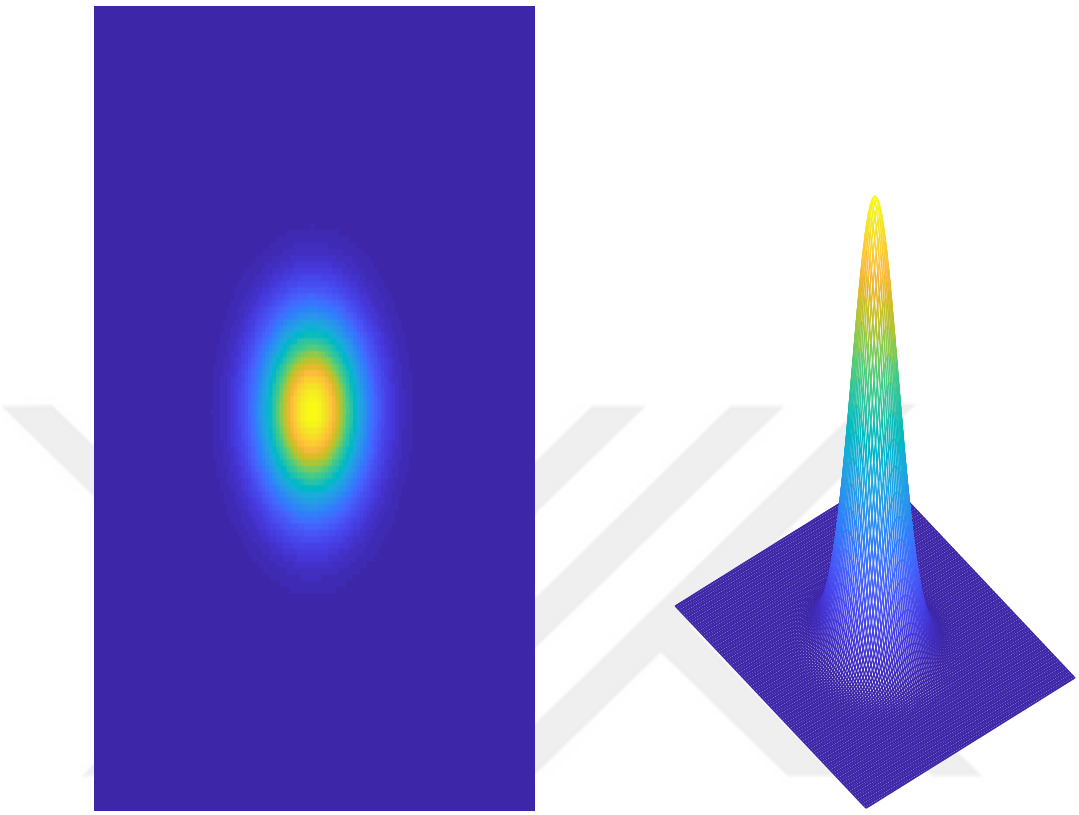
$$G(x,y) = \frac{1}{2\pi\sigma * \sigma} e^{-\frac{1}{2}\left(\left(\frac{x-\mu}{\sigma}\right)^2 + \left(\frac{x-\mu}{\sigma}\right)^2\right)} \tag{4.3}$$

$$G = g'.* g$$

Denklem 4.2 ve 4.3 'de σ^2 varyans, μ ortalama değeri temsil etmektedir. Ham verinin yumuşatılması için kullanılan dağılım Şekil 4.4'de gösterilmiştir.



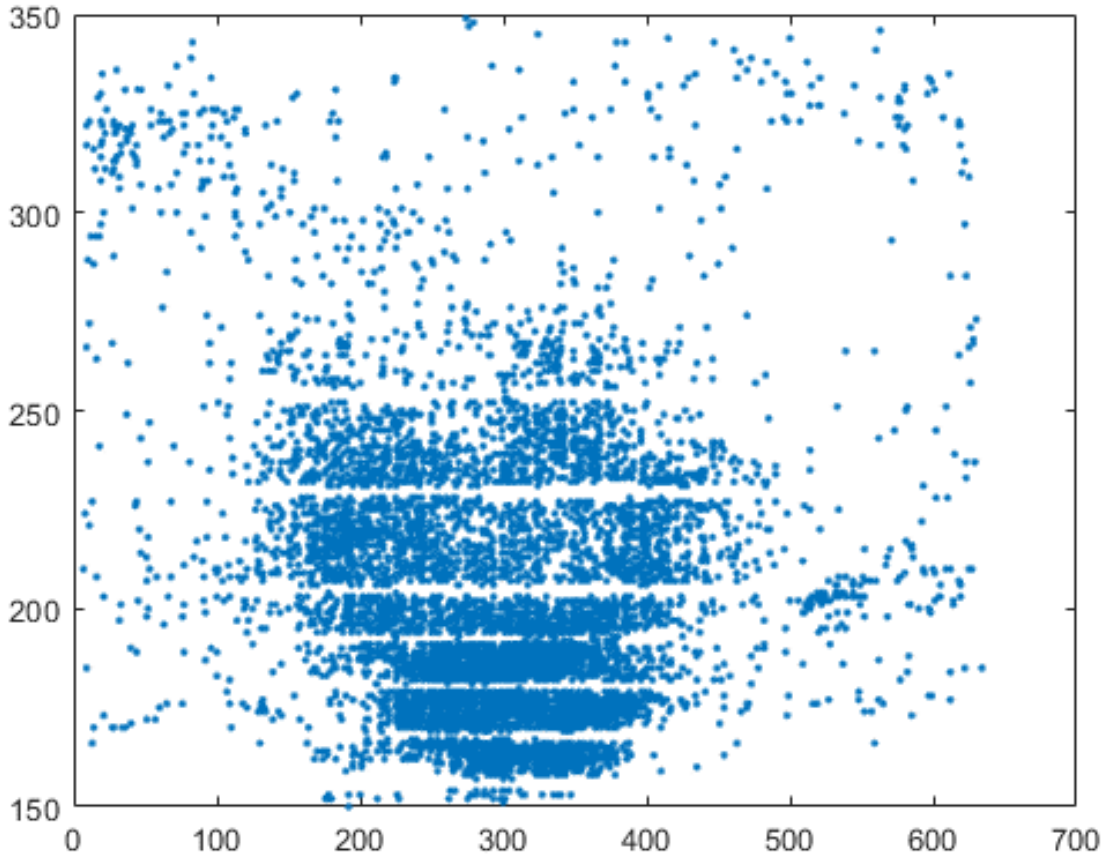
Şekil 4.4: Görüntünün yumuşatılması için kullanılan dağılımın tek boyutlu uzaydaki ifadesi.



Şekil 4.5: Görüntünün yumuşatılması için kullanılan dağılım 2D çekirdek örneği gösterimi.

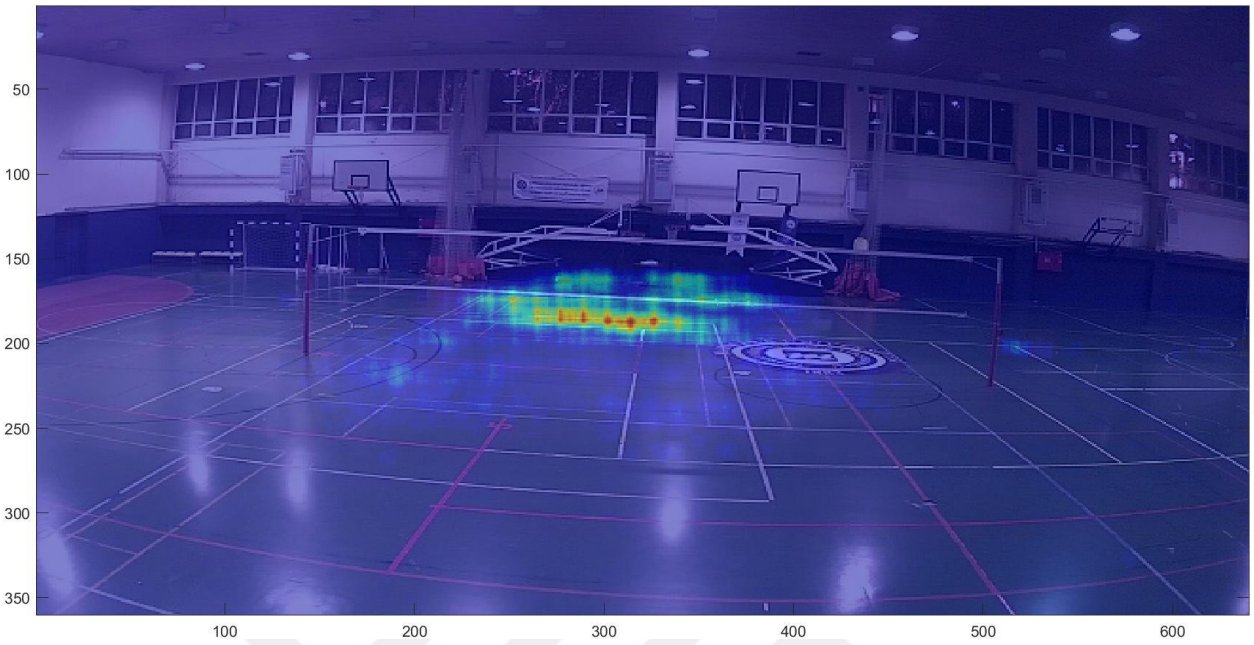
4.5.4 Görselleştirme

Resmi görselleştirmek için MATLAB yazılımı kullanılmıştır. Yukarıda bahsedilen adımlar bir MATLAB kodu şeklinde yazılmıştır. MATLAB kodu tezin son kısmında ekte verilmiştir. İlk olarak, Şekil 4.6 'da 640x360 boyutlarında bir matris üzerine işlenmiş ham veri görülmektedir. Şekil 4.7' deki görünümde bir saatlik zaman diliminde 10104 konum bilgisi verisi içeren durum görüntülenmiştir. Şekildeki yatay ve dikey eksenler, kişilerin bulundukları piksel koordinatları ifade etmektedir.



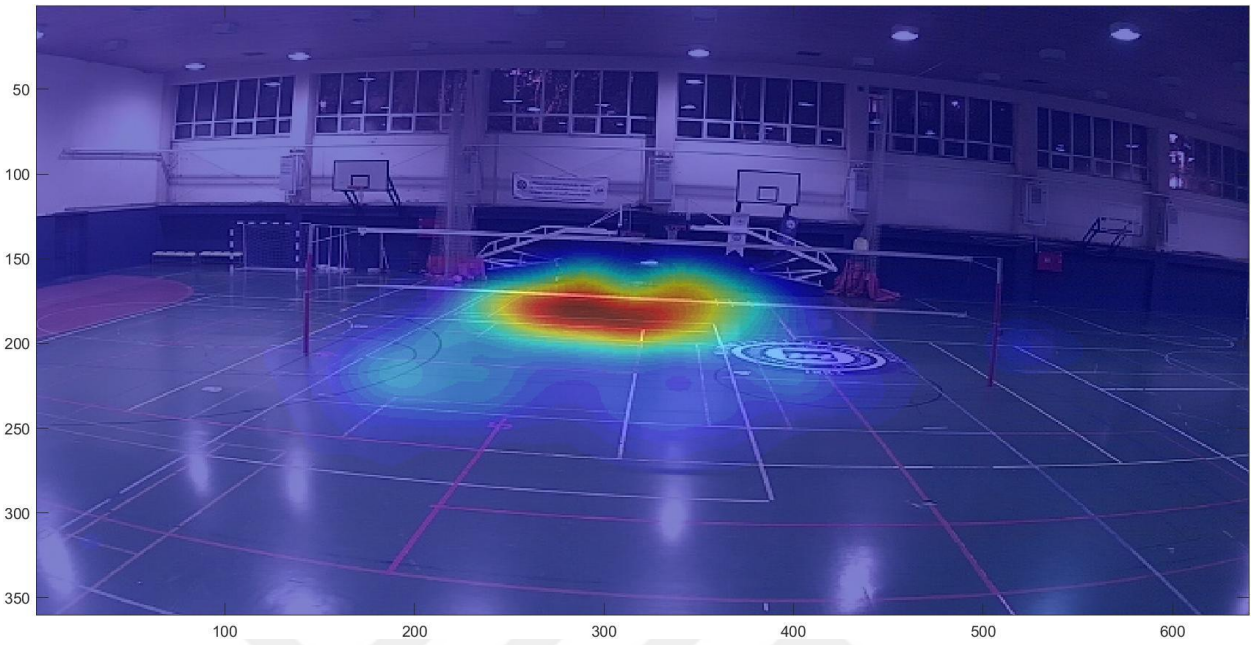
Şekil 4.6: 640 x 360 boyutlarındaki matrise işlenmiş ham veri.

Şekil 4.6'da görüldüğü üzere, veri çok anlaşılır bir halde değildir. Belirli bölgelerde nokta yoğunluğunun fazla olduğu belirgin bir şekilde görülmektedir. Bu ham bilgiyi daha doğru bir şekilde yorumlamak adına, verinin Şekil 4.3'de gösterilen boş resim üzerine işlenmesi gerçekleştirilmiştir. Örneğin, Şekil 4.7'de 18:10 – 19:10 saatleri Aralığında, 1471139 – 1481243 arasına karşılık gelen ID değerleriyle kaydedilen, bir saatlik yoğunluğun resmin piksellerine 10104 konum bilgisi işlenmiş, resim piksellerine aktarılmış, aynı zamanda renklendirilmiş hali mevcuttur.



Şekil 4.7: Bir saatlik zaman diliminde 10104 konum bilgisi içeren yoğunluk (ısı) haritası

Ham verinin boş resim üzerine işlenmesi sonucu ortaya çıkan görüntüyü daha da anlamlı kılmak adına verinin bir dağılım şeklindeki gösterimi Şekil 4.7'de gösterilmiştir. Bu dağılım yukarıda bahsedildiği gibi Gaussian filtresi kullanılarak oluşturulmuş hali Şekil 4.8'de gösterilmiştir.



Şekil 4.8: Bir saatlik zaman diliminde 10104 konum bilgisi içeren veriden, Gaussian filtresi uygulanarak hazırlanmış yoğunluk (ısı) haritası

Verilerin bir dağılım halinde gösterimi ortalama değer etrafında daha düşük istatistiğe sahip bölgeleri daha soğuk renklerle göstermekte, diğer bir değişle sporcuların daha az bulunduğu yerleri mavi, daha çok bulunduğu yerleri ise kırmızı olarak renklendirilmektedir. Buna göre, sporcuların en sık bulunduğu bölge dikey eksende 140-200, yatay eksende 210-380 piksel değerlerine karşılık gelmektedir. Bu piksel aralıkları voleybol müsabakasında fileye yakın konum koordinatlarını ifade etmektedir.

5. PROGRAM ÇIKTILARI VE BULGULAR

5.1 İRTİBAT OFİSİ BULGULARI

Tasarlanan program öncelikle bir irtibat bürosunda test edilmiştir. Test sırasında prototip sistemin kalabalık durumlarda bile başarı ile insan tespit ettiği resimleri işleyip sistem donmadan veri tabanında kayıtlar oluşturduğu gözlenmiştir.

5.1.1 Örnek Çıktı 1

Aşağıdaki örnekte gösterildiği üzere hizmet almayıp, muhtemelen sadece bir şey sorup çıkan (bankoda işi olmayan, hizmet almaya gelmemiş) bir insanın örnek veri tabanı kayıtları ve sistemin veri tabanına dair kayıt altına aldığı resimler aşağıdaki gibidir. Bu örnekte veri tabanına dört kayıt işlenmiş (Birinci resimde: Bir konum ve bir insan, İkinci Resimde: İki insan ve iki konum, Üçüncü Resimde: Bir konum ve bir İnsan) bu üç kaydın oluşması ve resimleri işlenip sisteme kayıt edilmesi toplam beş saniyede tamamlanmıştır.

5.1.1.1 Birinci Resim Örneği Bir Konum Ve Bir İnsan Tespiti

2019-11-06 13.11.01.883521 zaman damgasıyla bir insan (banko çalışanı) %79 oranla tespit edilerek veri tabanına sistem tarafından kayıt bilgileri işlenmiş.



Şekil 5.1: Sistemin 1390493 id si ile %79 oran ile veri tabanına kayıt ettiği resim dosyası

Tablo 5.1: Şekil 5.1 için sistemde oluşan veri tabanı kaydı

id	date_time	x_min	y_min	x_max	y_max	percentage_probability
1390493	2019-11-06 13:11:01.883521	5.0	212.0	103.0	358.0	78.96

5.1.1.2 İkinci resim iki konum ve iki insan tespiti

5.2 Şeklinde gösterilen resimde, bilgi almak isteyen insan %98 ve banko çalışanı %80 oranları ile tespit edilerek her bir insan için zaman, konum bilgisi işlenmiştir. İlk kayıttan (Şekil 5.1) yaklaşık üç saniye sonra 13:11:04 ‘üncü saniyede.



Şekil 5.2: İki insan tespiti ile veri tabanına iki kayıt oluşturan resim

Tablo 5.2: Şekil 5.2 için sistemde oluşan veri tabanı kaydı

id	date_time	x_min	y_min	x_max	y_max	percentage_probability
1390494	2019-11-06 13:11:04.678094	6.0	215.0	100.0	355.0	80.04
1390495	2019-11-06 13:11:04.678094	377.0	67.0	524.0	270.0	98.34

5.1.1.3 Üçüncü resim bir konum ve bir insan tespiti

Şekil 5.2 ‘den iki saniye sonra bilgi almak isteyen insan resimden ayrılmış sadece bankoda çalışan insan %59 oranı ile tespit edilmiştir. Şekil (5.3)’de ki resimde görüldüğü gibi insan çıktıktan sonra kapı henüz tam kapanmamıştır.



Şekil 5.3: Sistemin 1390496 id si ile %59 oran ile veri tabanına kayıt ettiği resim dosyası

Tablo 5.3: Şekil 5.3 için sistemde oluşan veri tabanı kaydı

id	date_time	x_min	y_min	x_max	y_max	percentage_probability
1390496	2019-11-06 13:11:06.147129	2.0	217.0	101.0	356.0	59.27

5.1.2 Örnek Çıktı 2

Yaklaşık 10 kişinin hizmet almak için beklediği Altı saniyelik zaman diliminde (150801- 150829) arasındaki id numaraları ile veri tabanımıza kayıt edilen veriler ve resim çıktıları örneklenmiştir.

5.1.2.1 On konum ve on insan tespiti

Resim 5.4’ de insan gözü ile görebildiğimiz tüm insan objelerinin sistem tarafından tespit edildiği, başarı ile işaretlendiği ve veri tabanına konum bilgilerinin yazıldığı görülüyor.



Şekil 5.4: On insan tespit edilen resim dosyası

Tablo 5.4: Şekil 5.4 için sistemde oluşan veri tabanı kaydı

id	date_time	x_min	y_min	x_max	y_max	percentage_probability
150801	2019-09-09 14:36:58.757136	485.0	177.0	578.0	313.0	31.86
150802	2019-09-09 14:36:58.757136	449.0	213.0	600.0	352.0	35.19
150803	2019-09-09 14:36:58.757136	307.0	5.0	353.0	79.0	53.75
150804	2019-09-09 14:36:58.757136	13.0	274.0	103.0	358.0	53.95
150805	2019-09-09 14:36:58.757136	220.0	23.0	251.0	74.0	90.45
150806	2019-09-09 14:36:58.757136	132.0	238.0	276.0	360.0	97.36
150807	2019-09-09 14:36:58.757136	382.0	26.0	472.0	147.0	97.51
150808	2019-09-09 14:36:58.757136	365.0	92.0	466.0	304.0	97.73
150809	2019-09-09 14:36:58.757136	293.0	47.0	355.0	220.0	99.15
150810	2019-09-09 14:36:58.757136	154.0	38.0	233.0	214.0	99.54

5.1.2.2 Dokuz konum ve dokuz insan tespiti

Şekil 5.5 incelendiğinde sağ alt köşesindeki beyaz gömlekli insan 5.5 Şekil örneğinde %30 olasılığa ulaşamadığı için veri tabanına kayıt edilmemiş ve insan olarak işaretlenmemiştir.



Şekil 5.5: Dokuz insan tespit edilen resim dosyası

Tablo 5.5: Şekil 5.5 için sistemde oluşan veri tabanı kaydı

İd	date_time	x_min	y_min	x_max	y_max	percentage_probability
150811	2019-09-09 14:37:00.835719	443.0	204.0	593.0	350.0	52.16
150812	2019-09-09 14:37:00.835719	306.0	5.0	354.0	82.0	56.76
150813	2019-09-09 14:37:00.835719	40.0	256.0	120.0	360.0	58.88
150814	2019-09-09 14:37:00.835719	220.0	22.0	251.0	74.0	91.54
150815	2019-09-09 14:37:00.835719	376.0	22.0	468.0	149.0	94.07
150816	2019-09-09 14:37:00.835719	108.0	245.0	275.0	354.0	97.50
150817	2019-09-09 14:37:00.835719	373.0	94.0	472.0	303.0	98.26
150818	2019-09-09 14:37:00.835719	292.0	46.0	353.0	222.0	99.49
150819	2019-09-09 14:37:00.835719	152.0	40.0	232.0	213.0	99.57

5.1.2.3 On konum ve on insan tespiti

Şekil 5.6 daki beyaz gömlekli insan 5.6 Şeklindeki resim örneğinde %30 olasılığın üzerine çıktığı için 5.6 şeklindeki resme göre kayıt oluşturmuştur.



Şekil 5.6: On insan tespit edilen resim dosyası

Tablo 5.6: Şekil 5.6 için sistemde oluşan veri tabanı kaydı

id	date_time	x_min	y_min	x_max	y_max	percentage_probability
150820	2019-09-09 14:37:02.964566	443.0	203.0	588.0	349.0	49.00
150821	2019-09-09 14:37:02.964566	509.0	310.0	638.0	359.0	57.05
150822	2019-09-09 14:37:02.964566	48.0	254.0	116.0	359.0	69.63
150823	2019-09-09 14:37:02.964566	309.0	4.0	354.0	71.0	75.80
150824	2019-09-09 14:37:02.964566	220.0	21.0	252.0	76.0	80.26
150825	2019-09-09 14:37:02.964566	372.0	97.0	471.0	299.0	94.18
150826	2019-09-09 14:37:02.964566	378.0	23.0	468.0	145.0	96.63
150827	2019-09-09 14:37:02.964566	108.0	247.0	275.0	352.0	99.01
150828	2019-09-09 14:37:02.964566	130.0	35.0	243.0	219.0	99.19
150829	2019-09-09 14:37:02.964566	277.0	39.0	345.0	235.0	99.71

5.1.3 Örnek Çıktı 3

İnsanların yoğun olarak hizmet aldıkları yaklaşık On saniyelik ardışık veri kayıtlarının oluştuğu zaman diliminde kayıt edilen veriler ve resim çıktıları aşağıda örneklenmiştir. Ardışık veri tabanı

kayıtları ve resim kayıtlarından görüleceği üzere, çok kalabalık olan zaman dilimlerinde de sistem başarılı bir şeklide veri tabanı kayıtlarını oluşturmuş, resim dosyalarını işaretleyerek kayıt altına almıştır.

5.1.3.1 On sekiz konum ve on sekiz insan tespiti

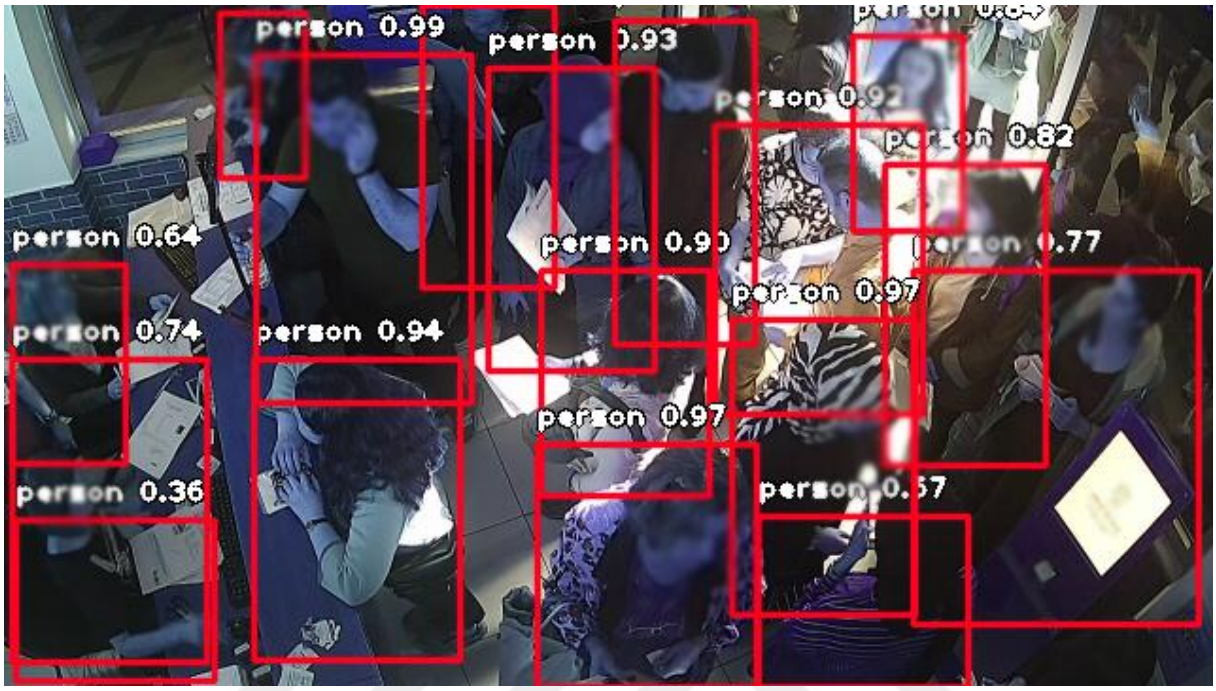


Şekil 5.7: On Sekiz insan tespit edilen resim dosyası

Tablo 5.7: Şekil 5.7 için sistemde oluşan veri tabanı kaydı

id	date_time	x_min	y_min	x_max	y_max	percentage_probability
999910	2019-10-16 16:15:37.350650	362.0	1.0	394.0	49.0	38.76
999911	2019-10-16 16:15:37.350650	493.0	82.0	550.0	165.0	41.75
999912	2019-10-16 16:15:37.350650	221.0	1.0	292.0	148.0	50.30
999913	2019-10-16 16:15:37.350650	477.0	16.0	540.0	113.0	61.60
999914	2019-10-16 16:15:37.350650	114.0	3.0	158.0	95.0	70.71
999915	2019-10-16 16:15:37.350650	2.0	126.0	103.0	262.0	78.12
999916	2019-10-16 16:15:37.350650	258.0	29.0	348.0	161.0	79.49
999917	2019-10-16 16:15:37.350650	537.0	127.0	624.0	257.0	80.98
999918	2019-10-16 16:15:37.350650	460.0	128.0	559.0	302.0	83.65
999919	2019-10-16 16:15:37.350650	273.0	133.0	353.0	265.0	87.89
999920	2019-10-16 16:15:37.350650	1.0	193.0	107.0	344.0	93.10
999921	2019-10-16 16:15:37.350650	400.0	236.0	507.0	360.0	94.91
999922	2019-10-16 16:15:37.350650	376.0	159.0	476.0	325.0	95.60
999923	2019-10-16 16:15:37.350650	130.0	188.0	245.0	351.0	98.09
999924	2019-10-16 16:15:37.350650	260.0	244.0	404.0	360.0	98.36
999925	2019-10-16 16:15:37.350650	385.0	41.0	472.0	191.0	98.45
999926	2019-10-16 16:15:37.350650	133.0	26.0	245.0	206.0	98.80
999927	2019-10-16 16:15:37.350650	326.0	18.0	397.0	224.0	99.54

5.1.3.2 On yedi konum ve on yedi insan tespiti



Şekil 5.8: On Yedi insan tespit edilen resim dosyası

Tablo 5.8: Şekil 5.8 için sistemde oluşan veri tabanı kaydı

id	date_time	x_min	y_min	x_max	y_max	percentage_probability
999928	2019-10-16 16:15:40.474610	6.0	272.0	111.0	357.0	35.68
999929	2019-10-16 16:15:40.474610	4.0	137.0	64.0	242.0	63.51
999930	2019-10-16 16:15:40.474610	221.0	0.0	291.0	149.0	65.67
999931	2019-10-16 16:15:40.474610	399.0	270.0	510.0	360.0	67.49
999932	2019-10-16 16:15:40.474610	4.0	187.0	107.0	347.0	73.72
999933	2019-10-16 16:15:40.474610	114.0	4.0	159.0	91.0	75.90
999934	2019-10-16 16:15:40.474610	481.0	140.0	632.0	327.0	77.04
999935	2019-10-16 16:15:40.474610	466.0	84.0	551.0	243.0	81.85
999936	2019-10-16 16:15:40.474610	449.0	16.0	507.0	119.0	83.76
999937	2019-10-16 16:15:40.474610	284.0	140.0	373.0	259.0	89.90
999938	2019-10-16 16:15:40.474610	376.0	63.0	486.0	216.0	91.65
999939	2019-10-16 16:15:40.474610	256.0	33.0	344.0	193.0	93.47
999940	2019-10-16 16:15:40.474610	132.0	187.0	241.0	346.0	93.85
999941	2019-10-16 16:15:40.474610	323.0	8.0	397.0	179.0	95.73
999942	2019-10-16 16:15:40.474610	282.0	232.0	398.0	360.0	96.76
999943	2019-10-16 16:15:40.474610	385.0	166.0	482.0	322.0	97.12
999944	2019-10-16 16:15:40.474610	133.0	26.0	247.0	210.0	98.66

5.1.3.3 On beş konum ve on beş insan tespiti



Şekil 5.9: On Beş insan tespit edilen resim dosyası

Tablo 5.9: Şekil 5.9 için sistemde oluşan veri tabanı kaydı

id	date_time	x_min	y_min	x_max	y_max	percentage_probability
999945	2019-10-16 16:15:43.392462	410.0	81.0	496.0	257.0	39.73
999946	2019-10-16 16:15:43.392462	528.0	126.0	625.0	258.0	48.11
999947	2019-10-16 16:15:43.392462	8.0	141.0	65.0	244.0	57.62
999948	2019-10-16 16:15:43.392462	372.0	140.0	476.0	298.0	65.20
999949	2019-10-16 16:15:43.392462	221.0	1.0	293.0	150.0	68.77
999950	2019-10-16 16:15:43.392462	115.0	1.0	162.0	93.0	70.92
999951	2019-10-16 16:15:43.392462	378.0	44.0	450.0	201.0	77.47
999952	2019-10-16 16:15:43.392462	261.0	134.0	365.0	292.0	85.42
999953	2019-10-16 16:15:43.392462	457.0	20.0	519.0	125.0	87.89
999954	2019-10-16 16:15:43.392462	258.0	248.0	415.0	360.0	94.02
999955	2019-10-16 16:15:43.392462	439.0	91.0	560.0	294.0	94.28
999956	2019-10-16 16:15:43.392462	4.0	234.0	141.0	356.0	96.70
999957	2019-10-16 16:15:43.392462	256.0	31.0	345.0	195.0	97.38
999958	2019-10-16 16:15:43.392462	131.0	188.0	241.0	353.0	97.39
999959	2019-10-16 16:15:43.392462	132.0	24.0	246.0	213.0	98.07
999960	2019-10-16 16:15:43.392462	331.0	11.0	397.0	187.0	98.26

5.1.3.4 On yedi konum ve on yedi insan tespiti



Şekil 5.10: On Yedi insan tespit edilen resim dosyası

Tablo 5.10: Şekil 5.10 için sistemde oluşan veri tabanı kaydı

id	date_time	x_min	y_min	x_max	y_max	percentage_probability
999961	2019-10-16 16:15:46.076078	389.0	13.0	468.0	94.0	51.64
999962	2019-10-16 16:15:46.076078	400.0	214.0	552.0	354.0	53.09
999963	2019-10-16 16:15:46.076078	383.0	179.0	479.0	344.0	54.10
999964	2019-10-16 16:15:46.076078	113.0	4.0	160.0	89.0	61.54
999965	2019-10-16 16:15:46.076078	222.0	0.0	293.0	152.0	76.64
999966	2019-10-16 16:15:46.076078	463.0	86.0	557.0	240.0	79.13
999967	2019-10-16 16:15:46.076078	541.0	21.0	614.0	161.0	81.89
999968	2019-10-16 16:15:46.076078	530.0	126.0	623.0	259.0	83.46
999969	2019-10-16 16:15:46.076078	456.0	53.0	515.0	143.0	84.75
999970	2019-10-16 16:15:46.076078	9.0	134.0	69.0	251.0	90.48
999971	2019-10-16 16:15:46.076078	285.0	140.0	380.0	257.0	90.63
999972	2019-10-16 16:15:46.076078	258.0	250.0	412.0	360.0	91.67
999973	2019-10-16 16:15:46.076078	0.0	253.0	138.0	360.0	93.07
999974	2019-10-16 16:15:46.076078	332.0	4.0	399.0	148.0	96.89
999975	2019-10-16 16:15:46.076078	128.0	187.0	247.0	354.0	97.74
999976	2019-10-16 16:15:46.076078	258.0	28.0	346.0	214.0	98.03
999977	2019-10-16 16:15:46.076078	372.0	56.0	475.0	221.0	98.33
999978	2019-10-16 16:15:46.076078	128.0	21.0	246.0	215.0	99.06

5.1.3.5 On beş konum ve on beş insan tespiti

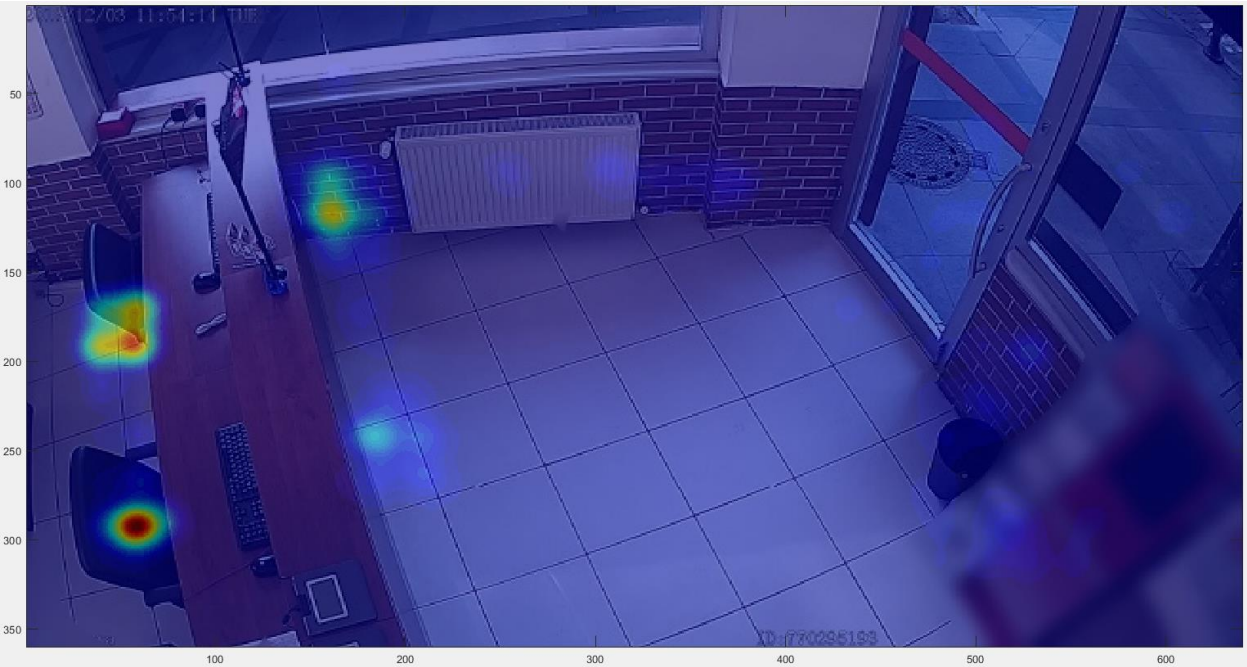


Şekil 5.11: On Beş insan tespit edilen resim dosyası

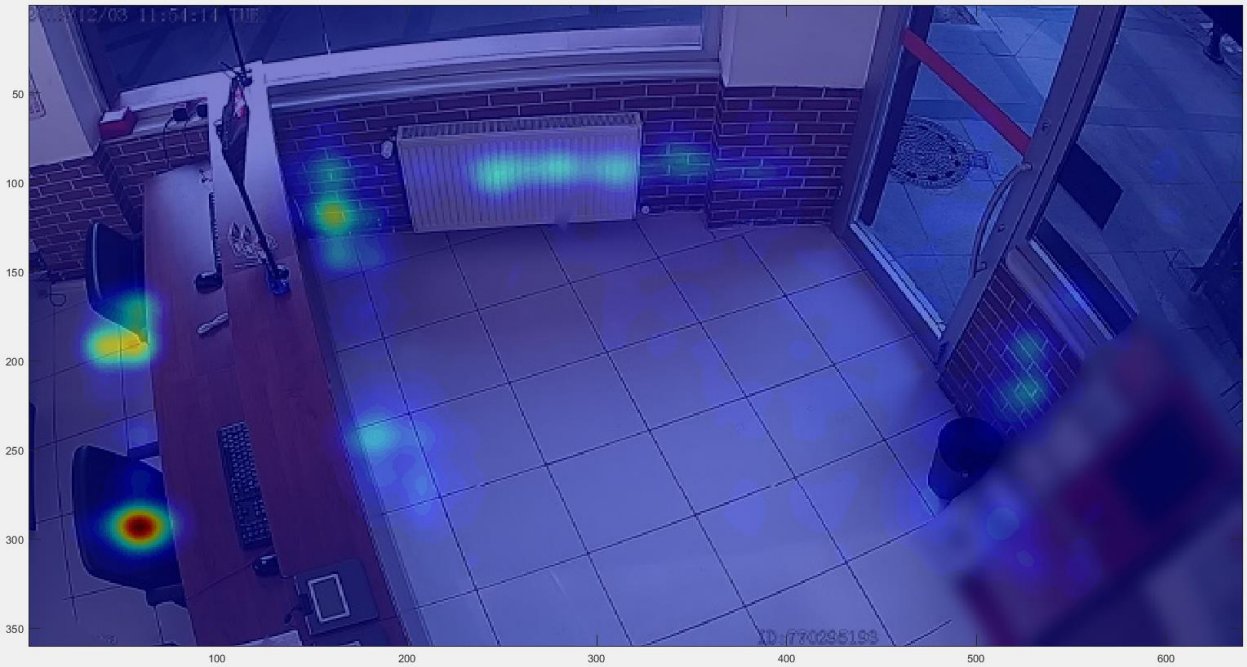
Tablo 5.11: Şekil 5.11 için sistemde oluşan veri tabanı kaydı

id	date_time	x_min	y_min	x_max	y_max	percentage_probability
999979	2019-10-16 16:15:48.929319	571.0	79.0	624.0	156.0	59.04
999980	2019-10-16 16:15:48.929319	2.0	222.0	84.0	359.0	61.56
999981	2019-10-16 16:15:48.929319	577.0	29.0	625.0	110.0	62.32
999982	2019-10-16 16:15:48.929319	107.0	0.0	159.0	89.0	65.27
999983	2019-10-16 16:15:48.929319	528.0	135.0	624.0	235.0	65.93
999984	2019-10-16 16:15:48.929319	222.0	0.0	292.0	153.0	68.06
999985	2019-10-16 16:15:48.929319	482.0	96.0	569.0	234.0	77.18
999986	2019-10-16 16:15:48.929319	258.0	26.0	345.0	166.0	82.31
999987	2019-10-16 16:15:48.929319	456.0	6.0	520.0	117.0	84.81
999988	2019-10-16 16:15:48.929319	7.0	135.0	66.0	243.0	89.14
999989	2019-10-16 16:15:48.929319	130.0	190.0	242.0	343.0	94.12
999990	2019-10-16 16:15:48.929319	370.0	61.0	481.0	220.0	95.43
999991	2019-10-16 16:15:48.929319	257.0	246.0	410.0	360.0	95.46
999992	2019-10-16 16:15:48.929319	262.0	129.0	361.0	249.0	96.39
999993	2019-10-16 16:15:48.929319	128.0	23.0	248.0	213.0	99.16
999994	2019-10-16 16:15:48.929319	322.0	15.0	399.0	221.0	99.33

5.2 İRTİBAT OFİSİ YOĞUNLUK HARİTALARI ÖRNEKLERİ



Şekil 5.12: 08:00-12:30 Saatleri arası 13302 konum bilgisi içeren yoğunluk haritası



Şekil 5.13: 13:30-17:30 Saatleri arası 26518 konum bilgisi içeren yoğunluk haritası

Tespit 1: Şekil 5.12 ve Şekil 5.13 ‘den görüleceği üzere iki bankodan, resmin sol üst köşesindeki bankoda daha fazla bekleme olmuştur.

Tespit 2: Şekil 5.12 deki genele bakıldığında, banko önünde yoğunlaşma Şekil 5.13 de ki dağılıma göre daha az gözüküyor.

Tespit 3: Yoğunluk haritalarına baktığımızda, öğleden sonra, öğleden önceye göre daha yoğun bekleme olmuştur tespitinde bulunabiliriz.

Tespit 4: Sistemin veri tabanına kayıt edilen konum bilgisi sayısına baktığımızda, öğleden sonra daha çok konum bilgisi veri tabanına kayıt edilmiş gözükmektedir. Buda öğleden sonraki yoğunluğun, ısı haritasındaki tespitinin sağlaması olarak kullanılabilir.

5.3 SPOR SAHASI VOLEYBOL MÜSABAKASI BULGULARI

Çalışmanın bu bölümünde tasarlanan prototip sistem spor sahasındaki test örneklerine yer verilmiştir. Test ortamında kullanılan sahnede imkânlar dâhilinde kamerayı en uygun konuma yerleştirilerek müsabaka sırasında gerçek zamanlı bir çalışma yapılmıştır. Veriler prototip sistemde müsabaka sırasında kameradan aldığımız online resim akışından veri tabanımıza eklenmiştir. Voleybol kurallarına göre 6 kişilik 2 takım halinde oynanması gereken karşılaşma birer kişi eksikle beşer kişilik iki takımla oynanmıştır. Sistemimiz çalışırken sahada toplam 10 sporcu bulunmaktadır.

5.3.1 On Lokasyon ve On İnsan Tespiti



Şekil 5.14: Beşer kişilik iki takımın oynadığı karşılaşmadan On insan yakalanan örnek çıktı

Tablo 5.12: Şekil 5.14 için sistemde oluşan veri tabanı kaydı

id	date_time	x_min	y_min	x_max	y_max	percentage_probability
1482709	2020-01-02 19:18:22.746453	331.0	151.0	343.0	172.0	51.02
1482710	2020-01-02 19:18:22.746453	318.0	151.0	331.0	170.0	59.77
1482711	2020-01-02 19:18:22.746453	327.0	149.0	344.0	194.0	74.61
1482712	2020-01-02 19:18:22.746453	314.0	164.0	334.0	210.0	85.40
1482713	2020-01-02 19:18:22.746453	296.0	162.0	315.0	215.0	86.40
1482714	2020-01-02 19:18:22.746453	276.0	153.0	296.0	215.0	97.78
1482715	2020-01-02 19:18:22.746453	313.0	189.0	350.0	291.0	99.65
1482716	2020-01-02 19:18:22.746453	164.0	170.0	210.0	261.0	99.67
1482717	2020-01-02 19:18:22.746453	388.0	177.0	425.0	275.0	99.74
1482718	2020-01-02 19:18:22.746453	205.0	189.0	263.0	296.0	99.85

5.3.2 On Lokasyon ve On İnsan Tespiti

Yaklaşık Beş saniyelik ardışık veri tabanı ve resim örneği çıktıları (Tablo: 5.13, 5.14, 5.15)

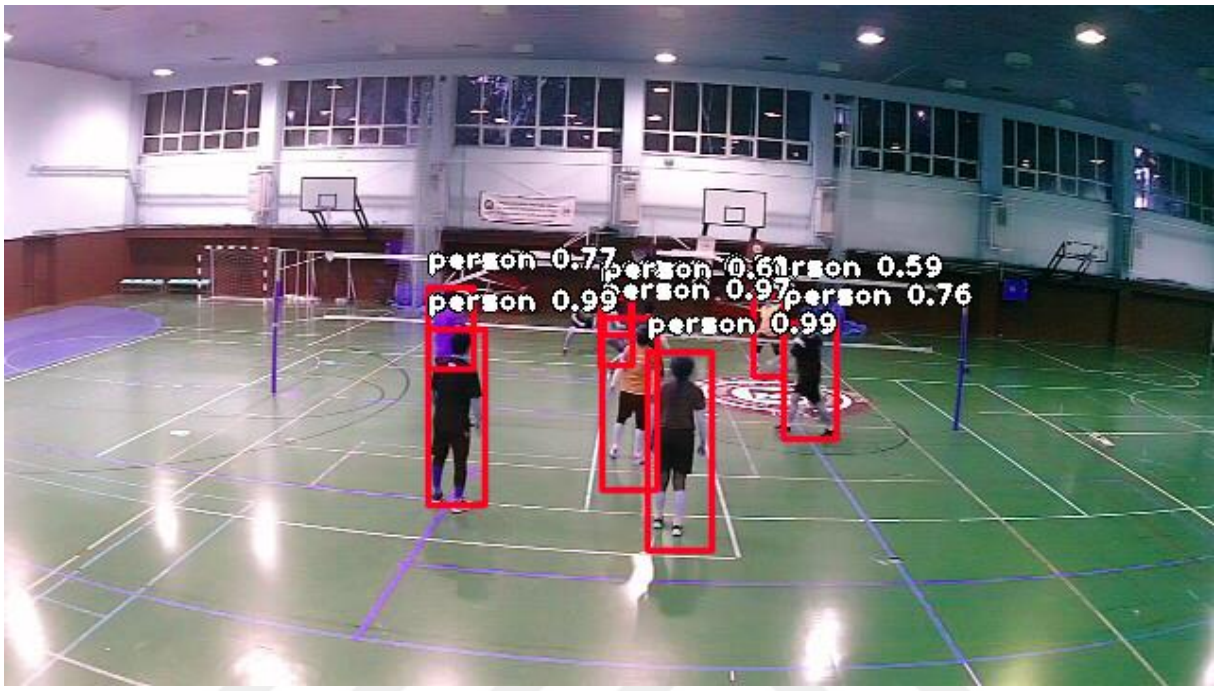


Şekil 5.15: Beşer kişilik iki takımın oynadığı karşılaşmadan On insan yakalanan örnek çıktı

Tablo 5.13: Şekil 5.15 için sistemde oluşan veri tabanı kaydı

id	date_time	x_min	y_min	x_max	y_max	percentage_probability
1482828	2020-01-02 19:19:02.297058	264.0	144.0	282.0	186.0	58.14
1482829	2020-01-02 19:19:02.297058	353.0	152.0	368.0	176.0	64.84
1482830	2020-01-02 19:19:02.297058	350.0	150.0	368.0	197.0	73.26
1482831	2020-01-02 19:19:02.297058	311.0	166.0	332.0	247.0	75.52
1482832	2020-01-02 19:19:02.297058	289.0	160.0	311.0	213.0	95.88
1482833	2020-01-02 19:19:02.297058	340.0	186.0	376.0	291.0	98.54
1482834	2020-01-02 19:19:02.297058	406.0	179.0	445.0	261.0	99.10
1482835	2020-01-02 19:19:02.297058	160.0	159.0	197.0	232.0	99.16
1482836	2020-01-02 19:19:02.297058	235.0	154.0	260.0	211.0	99.27
1482837	2020-01-02 19:19:02.297058	197.0	180.0	242.0	275.0	99.71

5.3.3 Sekiz Lokasyon ve Sekiz İnsan Tespiti



Şekil 5.16: Beşer kişilik iki takımın oynadığı karşılaşmadan Sekiz insan yakalanan örnek çıktı

Tablo 5.14: Şekil 5.16 için sistemde oluşan veri tabanı kaydı

id	date_time	x_min	y_min	x_max	y_max	percentage_probability
1482838	2020-01-02 19:19:04.590991	315.0	153.0	332.0	190.0	58.61
1482839	2020-01-02 19:19:04.590991	396.0	153.0	412.0	196.0	58.72
1482840	2020-01-02 19:19:04.590991	317.0	154.0	331.0	174.0	60.71
1482841	2020-01-02 19:19:04.590991	412.0	168.0	440.0	229.0	76.11
1482842	2020-01-02 19:19:04.590991	224.0	149.0	248.0	192.0	76.61
1482843	2020-01-02 19:19:04.590991	316.0	165.0	345.0	256.0	97.05
1482844	2020-01-02 19:19:04.590991	224.0	171.0	254.0	264.0	98.79
1482845	2020-01-02 19:19:04.590991	340.0	183.0	374.0	288.0	99.00

5.3.4 Dokuz Konum ve Dokuz İnsan Tespiti



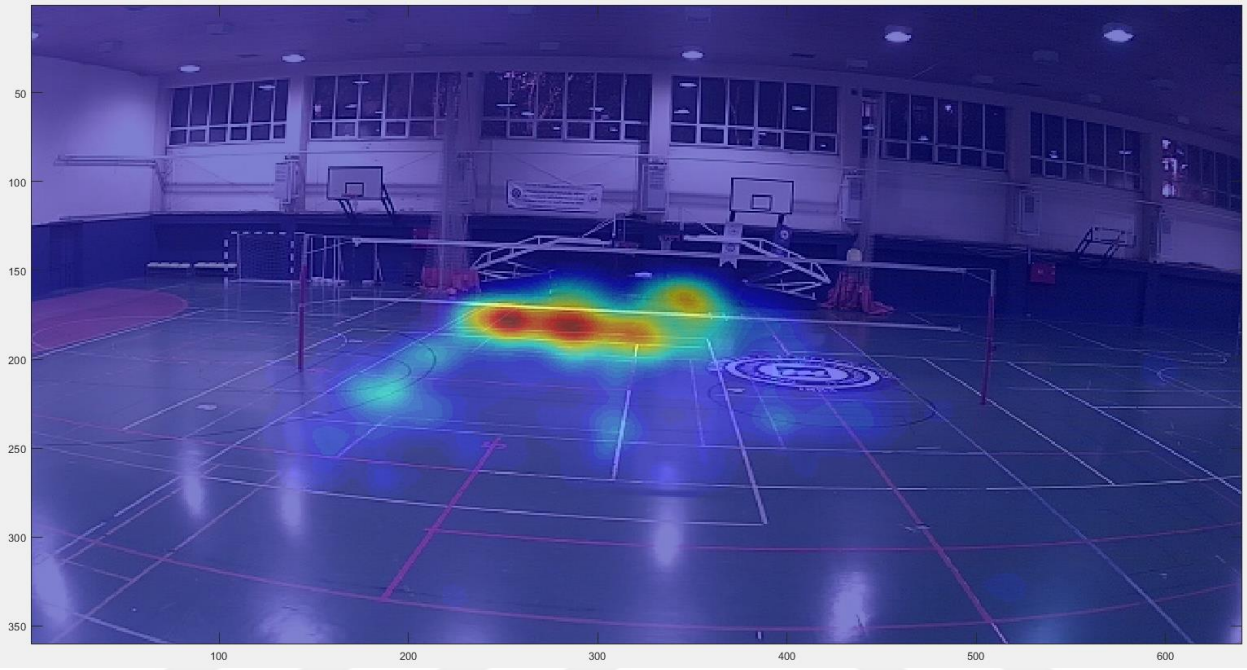
Şekil 5.17: Dokuz insan yakalanan örnek çıktı

Tablo 5.15: Şekil 5.17 için sistemde oluşan veri tabanı kaydı

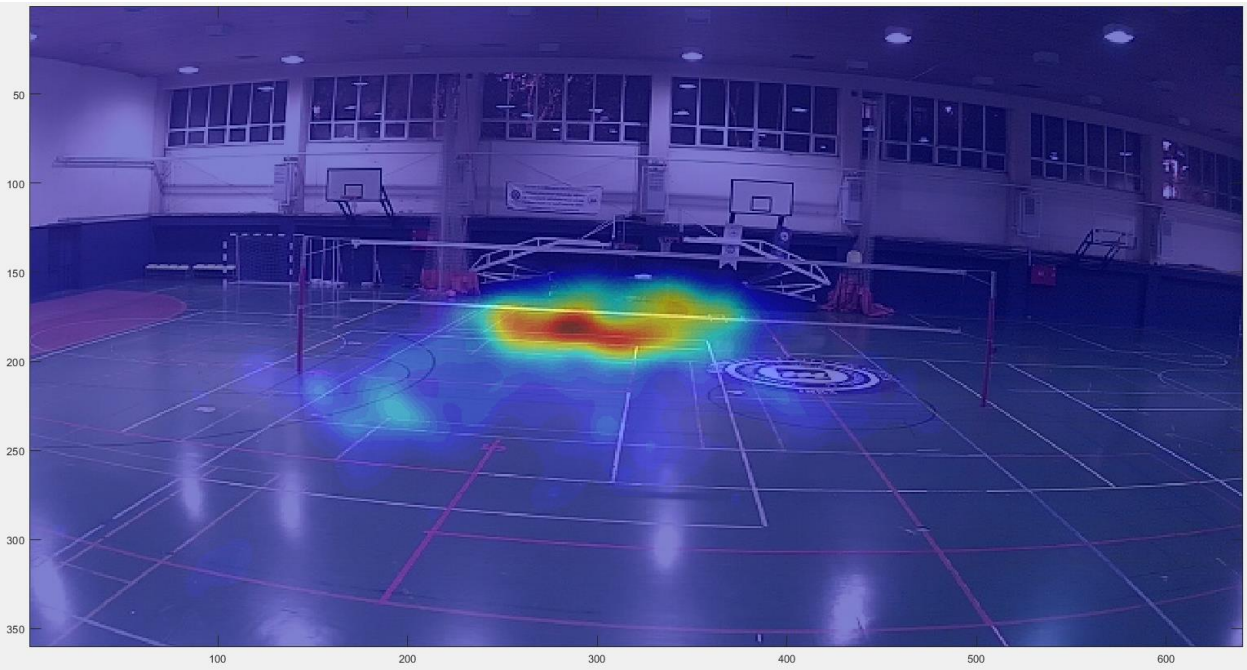
id	date_time	x_min	y_min	x_max	y_max	percentage_probability
1482846	2020-01-02 19:19:06.790406	303.0	152.0	326.0	215.0	72.57
1482847	2020-01-02 19:19:06.790406	363.0	149.0	386.0	198.0	75.47
1482848	2020-01-02 19:19:06.790406	288.0	143.0	305.0	187.0	80.64
1482849	2020-01-02 19:19:06.790406	306.0	167.0	341.0	253.0	86.35
1482850	2020-01-02 19:19:06.790406	194.0	156.0	219.0	225.0	92.72
1482851	2020-01-02 19:19:06.790406	351.0	181.0	384.0	286.0	95.72
1482852	2020-01-02 19:19:06.790406	265.0	151.0	290.0	216.0	98.60
1482853	2020-01-02 19:19:06.790406	404.0	170.0	437.0	267.0	98.66
1482854	2020-01-02 19:19:06.790406	216.0	175.0	251.0	275.0	99.82

5.4 SPOR KARŞILAŞMASI YOĞUNLUK HARİTALARI ÖRNEKLERİ

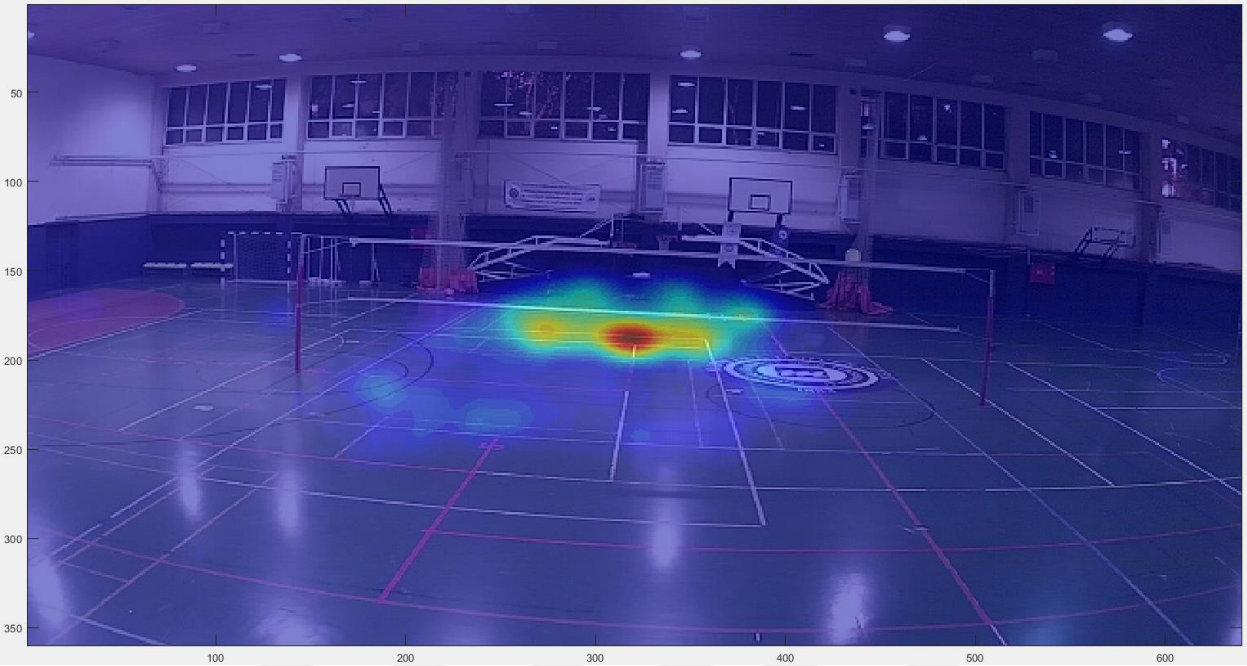
10 ar dakikalık zaman dilimi kesitleri halinde, ardışık ısı haritaları sırasıyla örneklenmiştir.



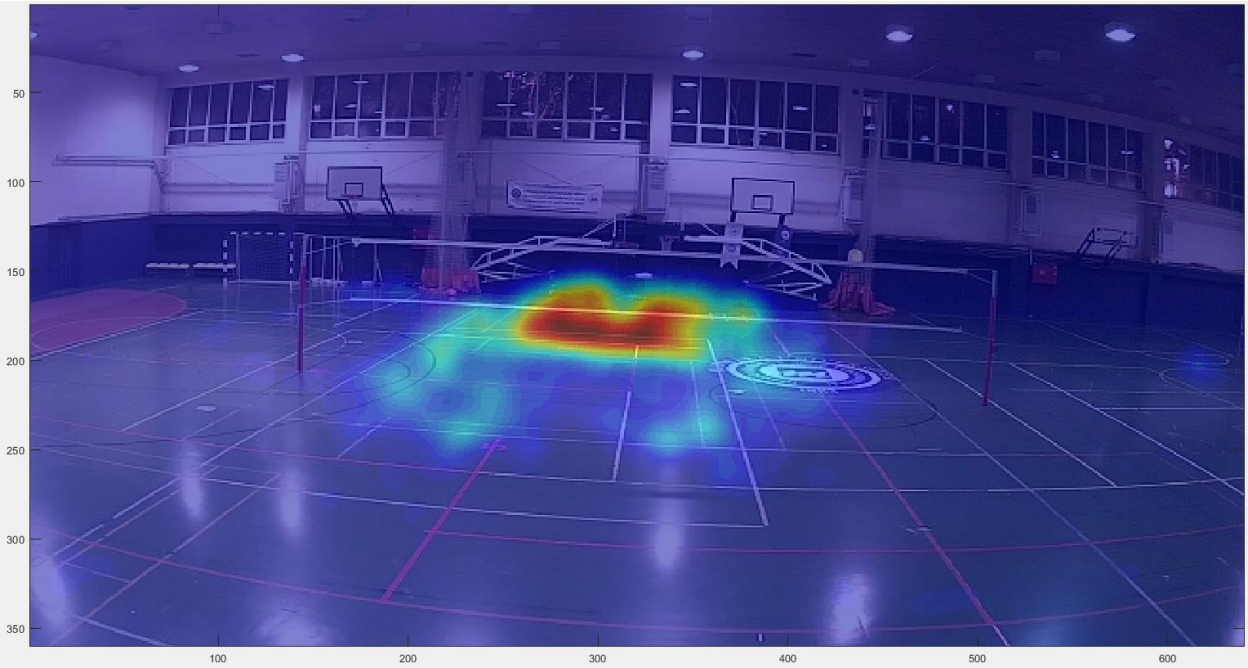
Şekil 5.18: 1471138 - 1473053 id leri arası 1915 konum bilgisi ile oluşturulan ısı haritası



Şekil 5.19: 1473054 – 1474421 id leri arası 1367 konum bilgisi ile oluşturulan ısı haritası



Şekil 5.20: 1474422 - 1476143 id leri arası 1721 konum bilgisi ile oluşturulan ısı haritası



Şekil 5.21: 1476144 - 1477858 id leri arası 1714 konum bilgisi ile oluşturulan ısı haritası

6. SONUÇ VE TARTIŞMA

Prototip sistemimiz ile görüntü işleme teknikleri yardımıyla elde ettiğimiz veri tabanı ile spor sahasındaki bir voleybol karşılaşmasından ve irtibat ofisinden, istediğimiz bir zaman dilimindeki ısı haritaları elde edilmiştir.

Yoğunluk haritaları müsabaka sırasında sporcuların yoğun olarak sahanın neresini kullandığı ve sahanın nerelerini daha yoğun olarak kapladıklarını bilgisini başarıyla vermiştir. İrtibat ofisinde de hizmet almaya gelen insanların hangi saatlerde daha yoğun olarak, hizmet bankolarını meşgul ettikleri yoğunluk haritaları ile raporlanmıştır.

Veri toplanırken kullanılan kayıt donanımının sahnemizdeki konumunu ve açısını daha anlaşılır ve özel amaçlı data toplama işleri için değiştirmek anlamlı olabilir. İmkânlar dâhilinde, sistem amaçladığımız yoğunluk haritası senaryolarına göre konumlandırılmış, veriler bu doğrultuda toplanmıştır.

İnsan hareketlerinin izlenmesi ve algılanması günümüzde çok büyük önem kazanmıştır. Örneğin insansız kara araçları, sürüş sırasında gerçek zamanlı olarak yayaların hareketlerini izleyerek, hareket algılamasını gerçekleştirmektedir. Chen ve ark. Gerçekleştirdikleri çalışmada insan hareketlerini derin öğrenme yardımı ile analiz ederek, MotionNet ve zamansal akış CNN yapılarını kullanmıştır [27]. CNN tabanlı analizlerin eğitim süresi ve donanım ihtiyacı, bu çalışmada kullanılan prototipten daha yüksek olmaktadır. Yine basketbol oyunu özelinde önerilen bir çalışmada ise, ribaunt alan oyuncunun tespit edilmesi hedeflenmiştir [29]. Yakın zamanda gerçekleştirilen bu çalışmalar, spor müsabakalarında oyuncu takibinin önemini ortaya koymaktadır. 2019 yılında Narizuka ve Yamazaki tarafından yayınlanana bir çalışmada ise, futbol oyununda formasyonların kümeleme analizi ile belirlenmesi hedeflenmiştir [30]. Tüm bu çalışmaların başarımı, oyuncuların hareketlerinin yüksek doğrulukla ve zamansal gecikme olmadan belirlenmesine temelden bağlıdır. Yine tez kapsamında elde ettiğimiz ısı haritaları, çeşitli de kompozisyon yöntemlerine konu edilerek, spor oyunlarında formasyon kestiriminin otomatik olarak belirlenmesine yardımcı olabilir. Böylece, rakip analizi, oyun sırasında gerçekleştirilebilir.

Spor müsabakalarında elde edilen görüntülerden analiz çabaları son dönemde ivme kazanan bir araştırma konusu olmuştur. Kamera görüntülerinden bilgi çıkarımına yönelik çalışmalardan, hareket örüntülerinin otomatik elde edilmesi öneren Zhang ve Jiang, Basketbol hareketlerinin

tanımlanmasına yönelik bir ayrıştırma yöntemi geliştirmişlerdir [28]. Bu tür çalışmalar genellikle tek bir spor dalına yönelik uygulamaların gelişmesine olanak sağlasa da, geniş bir kullanım alanına ulaşamamaktadır. Bu tez kapsamında, istenilen zaman aralıklarında elde edebildiğimiz hareket haritaları, hem bir grup oyuncu için elde edilebileceği gibi, hem de istenilen kişinin haritasını elde etmemize olanak sağlamaktadır. Elde ettiğimiz haritaların, neredeyse gerçek zamanlı olması ise, herhangi bir müsabaka sırasında dahi anlık bilgilere ulaşabileceğimizi göstermektedir. Literatürde birçok patente konu olan ısı haritası kullanımı, oyun stratejisi için geçmiş ısı haritalarını temel alınmasını önermektedir (Patent: https://patents.google.com/patent/US20190366189A1/en).

Kurguladığımız prototip sistemimiz, çeşitli donanım ve yazılım eklemeleri yapılarak yoğunluk haritaların kullanılabileceği başka sektör ve olası benzer senaryolara göre uyarlanıp farklı karar destek sistemlerine dönüştürülebilir. Elde edilecek görüntülerin gerçek zamanlı olarak internet üzerinden [31] paylaşımı önerdiğimiz sistemin önemli bir gelişimi olarak düşünülmektedir. Esnek bir yapıdadır ve gelişime açık durumdadır.

Sistemi farklı sahne tiplerine uyarlayarak çalıştırdığımızı düşünürsek; örneğin müşterilerin reyonları gezerek alışveriş yaptıkları, marketler, giyim mağazaları gibi yerlerde kasa yoğunluk durum bilgisi gibi sorun teşkil eden durumları kayıt altına alacağı gibi, insanların / müşterilerin hangi reyon ya da mağaza noktalarında yoğun şeklide zaman geçirdiği gibi satışları iyileştirme çalışmalarında ya da benzer iyileştirme yapılandırmalarında kritik karar destekleme bilgileri de elde edilebilir. Sistemden alınan veriler yardımıyla reyon düzenlemeleri, ya da reyon yeri değiştirme gibi satış ve hizmet artırıcı düzenlemelere gidilebilir.

Bankalar, okullar, müzeler, kütüphaneler gibi devlet kurumları, eğitim kurumları gibi resmî kurumlarda karar destek sistemi olarak çok çeşitli senaryolarda sistem kullanılabilir.

REFERANSLAR

[1] Chakravorty, Pragnan (2018). "What is a Signal? [Lecture Notes]". IEEE Signal Processing Magazine. 35 (5): 175–177. Bibcode:2018ISPM...35.175C. doi:10.1109/MSP.2018.2832195.

[2] Gonzalez, Rafael (2018). Digital image processing. New York, NY: Pearson. ISBN 978-0-13-335672-4. OCLC 966609831.

[3] Azriel Rosenfeld, Picture Processing by Computer, New York: Academic Press, 1969

[4] Gonzalez, Rafael C. (2008). Digital image processing. Woods, Richard E. (Richard Eugene),1954- (3rd ed.). Upper Saddle River, N.J.: Prentice Hall. pp. 23–28. ISBN 9780131687288. OCLC 137312858.

[5] "Space Technology Hall of Fame:Inducted Technologies/1994". Space Foundation. 1994. Archived from the original on 4 July 2011. Retrieved 7 January 2010.

[6] Gonzalez, Rafael (2008). Digital Image Processing, 3rd. Pearson Hall. ISBN 9780131687288.

[7] Warren S. McCulloch & Walter Pitts., A logical calculus of the ideas immanent in nervous activity, The bulletin of mathematical biophysics, 1943, 5(4): 115–133.

[8] N. Dalal, B. Triggs (2015). “Histograms of oriented gradients for human detection” IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)

[9] Ross, Girshick (2014). "Rich feature hierarchies for accurate object detection and semantic segmentation" (PDF). Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE: 580–587. arXiv:1311.2524. doi: 10.1109/CVPR.2014.81. ISBN 978-1-4799-5118-5.

[10] Girschick, Ross (2015). "Fast R-CNN" (PDF). Proceedings of the IEEE International Conference on Computer Vision: 1440–1448. arXiv:1504.08083. Bibcode:2015arXiv150408083G.

[11] Shaoqing, Ren (2015). "Faster R-CNN". Advances in Neural Information Processing Systems. arXiv: 1506.01497.

[12] Liu, Wei (October 2016). SSD: Single shot multibox detector. European Conference on Computer Vision. Lecture Notes in Computer Science. 9905. pp. 21–37. arXiv:1512.02325. doi: 10.1007/978-3-319-46448-0_2. ISBN 978-3-319-46447-3.

[13] Redmon, Joseph (2016). "You only look once: Unified, real-time object detection". Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. arXiv: 1506.02640. Bibcode:2015arXiv150602640R.

[14] Redmon, Joseph (2017). "YOLO9000: better, faster, stronger". arXiv: 1612.08242 [cs.CV].

[15] Redmon, Joseph (2018). "Yolov3: An incremental improvement". arXiv: 1804.02767 [cs.CV].

[16] Zhang, Shifeng (2018). "Single-Shot Refinement Neural Network for Object Detection". Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition: 4203–4212. arXiv: 1711.06897. Bibcode:2017arXiv171106897Z.

[17] Viola P. and Jones M., Rapid object detection using a boosted cascade of simple features, in Computer Vision and Pattern Recognition, CVPR 2001. Proceedings of the 2001 IEEE Computer Society Conference on, vol. 1. IEEE, 2001.

[18] Wilkinson, Leland; Friendly, Michael (May 2009). "The History of the Cluster Heat Map". The American Statistician. 63 (2): 179–184. CiteSeerX 10.1.1.165.7924. doi: 10.1198/tas.2009.0033.

[19] "United States Patent and Trademark Office, registration #75263259". 1993-09-01.

[20] Borland, David; Taylor, Russell (2007). "Rainbow Color Map (Still) Considered Harmful". IEEE Computer Graphics and Applications. 27 (2): 14–7. doi:10.1109/MCG.2007.323435. PMID 17388198.

[21] How NOT to Lie with Visualization – Bernice E. Rogowitz and Lloyd A. Treinish – IBM Thomas J. Watson Research Center, Yorktown Heights, NY

[22] Harrower, Mark; Brewer, Cynthia A. (2003). "ColorBrewer.org: An Online Tool for Selecting Colour Schemes for Maps". In Dodge, Martin; Kitchin, Rob; Perkins, Chris (eds.). The Cartographic Journal. pp. 27–37. doi:10.1179/000870403235002042. ISBN 978-0-470-98007-1.

[23] Green, D. A. (2011). "A colour scheme for the display of astronomical intensity images". Bulletin of the Astronomical Society of India. 39: 289–95. arXiv:1108.5083. Bibcode:2011BASI...39., 289G.

[24] Jump up to:a b Borkin, M.; Gajos, K.; Peters, A.; Mitsouras, D.; Melchionna, S.; Rybicki, F.; Feldman, C.; Pfister, H. (2011). "Evaluation of Artery Visualizations for Heart Disease Diagnosis". IEEE Transactions on Visualization and Computer Graphics. 17 (12): 2479–88. CiteSeerX 10.1.1.309.590. doi:10.1109/TVCG.2011.192. PMID 22034369.

[25] Jeff Dean, Senior Google Fellow, and Rajat Monga, Technical Lead. (2015, Nov.). Google AI Blog [Online]. Available: https://ai.googleblog.com/2015/11/tensorflow-googles-latest-machine.html

[26] Moses Olafenwa and John Olafenwa. (2019.). Video and Live-Feed Detection and Analysis, [Online]. Available: https://imageai.readthedocs.io/en/latest/video/index.html

[27] L. Chen,Nan Ma ; Patrick Wang ; Jiahong Li ; Pengfei Wang ; Guilin Pang ; Xiaojun Shi "Survey of pedestrian action recognition techniques for autonomous driving," in Tsinghua Science and Technology, vol. 25, no. 4, pp. 458-470, Aug. 2020. doi: 10.26599/TST.2019.9010018

[28] Zhang, F.; Jiang, Y. Basketball Action Data Processing Method Based on Mode Symmetric Algorithm. Symmetry 2019, 11, 560.

[29] Motokazu Hojo, Keisuke Fujii & Yoshinobu Kawahara (2019) Analysis of factors predicting who obtains a ball in basketball rebounding situations, International Journal of Performance Analysis in Sport, 19:2, 192-205, DOI: 10.1080/24748668.2019.1582892

[30] Narizuka, T., Yamazaki, Y. Clustering algorithm for formations in football games. Sci Rep 9, 13172 (2019) doi:10.1038/s41598-019-48623-1

[31] Y Çobas, AD Duru, ON Uçan, O Bayat, Dikkat Seviyesinin Gerçek Zamanda İzlenmesi; Bir Web Uygulaması, Aurum-Mühendislik Sistemleri ve Mimarlık Dergisi 1 (1), 67-74

EK A GÖRÜNTÜ YAKALAMA PHYTON KODU

detector.py:

```
import cv2
import time
import os
import tensorflow as tf
from imageai.Detection import ObjectDetection
import requests
import shutil
import uuid
from datetime import datetime
from dbschema import db, Record
detector = ObjectDetection()
execution_path = os.getcwd()
try:
with tf.device('/gpu:0'):
# camera = cv2.VideoCapture('http:// 10.69.97.39:80')
detector.setModelTypeAsYOLOv3()
detector.setModelPath(os.path.join(execution_path, 'yolo.h5'))
detector.loadModel()
custom = detector.CustomObjects(person=True)
counter = 0
while True:
try:
response = requests.get('http://10.69.97.39/snapshot?chn=1&auth=QWRtaW46&q=0&d=1', stream=True)
with open('img.jpeg', 'wb') as out_file:
```

```
shutil.copyfileobj(response.raw, out_file)
returned_image, detections = \
detector.detectCustomObjectsFromImage(custom_objects=custom,
input_image='img.jpeg',
output_type='array',
minimum_percentage_probability=30)
if len(detections) > 0:
date_time = datetime.now()
filename = str(datetime.now())
filename = filename.replace(' ', '_')
if len(detections) != counter:
for person in detections:
try:
x_min, y_min, x_max, y_max = person['box_points']
percentage_probability = person['percentage_probability']
Record.create(date_time=date_time, x_min=x_min, y_min=y_min, x_max=x_max, y_max=y_max,
percentage_probability=percentage_probability)
except Exception as e:
print('Record.create:', str(e))
print(filename, ':', str(detections))
cv2.imwrite('/home/ugur/Desktop/frames/{0}.bmp'.format(filename), returned_image)
counter = len(detections)
del response
except Exception as ex:
print(str(ex))
except Exception as e:
print(str(e))
```

dbschema.py:

```
from peewee import *
db = SqliteDatabase('tracking.db')
class BaseModel(Model):
    class Meta:
        database = db
class Record(BaseModel):
    date_time = DateTimeField()
    x_min = DoubleField()
    y_min = DoubleField()
    x_max = DoubleField()
    y_max = DoubleField()
    percentage_probability = DoubleField()


db.connect()
# db.create_tables([Record])
```

EK B YOĞUNLUK HARİTASI MATLAB KODU

```
A=xlsread('data.xlsx');
x=A(:,8);
y=A(:,9);

q=imread('back.bmp');
resim=zeros(640,360);
x=round(x);
y=round(y);
%figure; plot(x,y,'*')
for i=1:length(x)
   resim(x(i),y(i))=resim(x(i),y(i))+1;
end
resim1=conv2(resim,ones(9),'same')';   %kare fonksiyon
boyut=15;
trans=0.5;
a=(1/(2*pi))*exp(-[-3:1.5/boyut:3].^2);figure;plot(a)
a1=a'*a;
%figure;imagesc(a1);figure;mesh(a1)
resim2=conv2(resim,a1,'same')';   %rbf
figure;imagesc(q);hold on;imagesc(resim1,'AlphaData',trans);colormap(jet(32))
figure;imagesc(q);hold on;imagesc(resim2,'AlphaData',trans);colormap(jet(32))
```

ÖZGEÇMİŞ

Muharrem Uğur Ertekin 1975 ‘de İstanbul’da doğdu. 1986 yılında İstanbul Avcılar Firuzköy ilkokulundan, 1992 Yılında İstanbul Büyükçekmece Esenyurt Lisesi Matematik bölümünden, 2001 yılında Eskişehir Anadolu Üniversitesi İşletme Fakültesi Lisans, 2016 Anadolu Üniversitesi Çalışma Ekonomisi ve Endüstri İlişkileri Lisans bölümlerinden mezun oldu. 2017 yılında İstanbul Kemerburgaz (okulun ismi Altınbaş olarak değişmiştir) Üniversitesi Fen Bilimleri Enstitüsü Bilişim Teknolojileri Bölümünde Tezli Yüksek Lisans eğitimine başladı. 2020 yılında mezun oldu.

1989 yılından beri bilişim dünyasıyla ilgilidir. 1992 yılında Favori Bilgisayar ve Elektronik Sistemleri firmasında teknik servis elemanı olarak çalışmaya başlamış, sonrasında firmanın çözümler sunduğu diğer hizmet konularında (network çözümleri sunma, network kurulum keşif ve mali etlendirme, personel devam takip sistemleri, özel yazılımlar geliştirme… Gibi konularda 1997 yılına kadar bu firmada çeşitli görevlerde bulunmuştur.

1997 – 2002 Tarihleri arasında Tiryakiler firmasında bilgi işlem yöneticisi olarak görev almıştır.

2002 Mart – 2003 Temmuz tarihleri arasında 285. Dönem Asteğmen (yedek subay) olarak İzmir, Ankara ve Mardin illerinde askerlik görevini yerine getirmiştir.

2003 – 2006 Yılları arasında Tiryakiler Firmasına geri dönmüş, Barkod uygulamaları ile, ERP programına firma faaliyetlerini entegre etme görevlerini üstlenmiş, aynı zamanda, firmanın ulusal ve uluslararası fuar organizasyonlarını düzenleme görevlerinde bulunmuştur. Eş zamanlı olarak Microsoft’un sistem mühendisliği eğitimlerini tamamlamıştır.

2006 – 2008 Yılları arasında Ulusal bir Holding olan Sanko Holding’de Sistem Network Uzmanı olarak görev yapmıştır.

2008 – 2009 Yılları arasında Uluslararası Cma - Cgm Lojistik firmasının Türkiye merkez ofisinde Sistem Network yöneticisi olarak görev almıştır. Eş zamanlı olarak Cisco eğitimleri almıştır.

2009’da ilk işe başladığı Favori Bilgisayar ve Elektronik Sistemlerine firma ortağı olarak geri dönmüştür. Halen bu firmada ortaklığı devam etmektedir. Firma, kendi bünyesinde geliştirdiği ve geliştirmeye devam ettiği, kişi sayma sistemleri, güvenli geçiş sistemleri, network çözümleri gibi… Çeşitli takip sistemleri ve ağ çözümleri konusunda faaliyetlerine devam etmektedir.

2015 – 2016 yılları arasında Uydu ve web tabanlı yayın yapan uluslararası bir medya kuruluşunun Türkiye şubesinde bilgi işlem yöneticisi olarak ekibiyle birlikte, yayın ile ilgili sunucuların ve network yapısının bakımı ve işletilmesi konusunun da görev almıştır.

2016 – Halen, uluslararası bir holding bünyesinde, sistem network uzmanı olarak hizmet vermektedir. Aynı zamanda Favori Bilgisayar ve Elektronik Sistemleri’nin sahibi olarak firmasının destek verdiği müşterilerle koordinasyonu kurup, gerekli müdahale planlarının uygulanmasının sağlanması, keşif ve mali etlendirme çalışmalarının yapılması, firma faaliyetlerinin koordinasyonu, yeni pazarlar bulma ve yeni ürünler için ar-ge çalışmalarında bulunma gibi görevleri yürütmektedir. (www.favoribil.com)