T.C.
BİTLİS EREN ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM ENTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

BİLGİSAYARLI GÖRÜ İLE DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK SPOR ANTRENMANLARININ DOĞRULUĞUNUN TESPİTİ

YÜKSEK LİSANS TEZİ

NURETTİN ACI

DANIŞMAN
DR. ÖĞR. ÜYESİ MUHAMMED FATİH KULUÖZTÜRK

KASIM 2023
BİTLİS

T.C.
BİTLİS EREN ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM ENTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

BİLGİSAYARLI GÖRÜ İLE DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK SPOR ANTRENMANLARININ DOĞRULUĞUNUN TESPİTİ

YÜKSEK LİSANS TEZİ

NURETTİN ACI

21530853009

DANIŞMAN
DR. ÖĞR. ÜYESİ MUHAMMED FATİH KULUÖZTÜRK

KASIM 2023
BİTLİS

BİTLİS EREN ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZ ÇALIŞMASI

ETİK BEYANI

Lisansüstü Eğitim Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı Yüksek Lisans öğrencisiyim. Hazırlamış olduğum **"Bilgisayarlı Görü İle Derin Öğrenme Teknikleri Kullanılarak Spor Antrenmanlarının Doğruluğunun Tespiti"** başlıklı tezde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi; tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu; tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi; kullanılan verilerde herhangi bir değişiklik yapmadığımı; bu tezde sunduğum çalışmanın özgün olduğunu bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim. 01/11/2023

İmza

Nurettin ACI

T.C.

BİTLİS EREN ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

TEZ YAZIM KILAVUZU UYGUNLUK BEYANI

"Bilgisayarlı Görü İle Derin Öğrenme Teknikleri Kullanılarak Spor Antrenmanlarının Doğruluğunun Tespiti" başlıklı yüksek lisans tezi Bitlis Eren Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Kılavuzuna uygun olarak hazırlanmıştır. 01/11/2023

Tezi Hazırlayan	**Danışman**
İmza	İmza
Nurettin ACI	Dr. Öğr. Üyesi
	Muhammed Fatih KULUÖZTÜRK

Elektrik Elektronik Mühendisliği Anabilim Dalı Başkanı

İmza

Prof. Dr. Sabir RÜSTEMLİ

T.C.

BİTLİS EREN ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

TEZ ONAY SAYFASI

Bitlis Eren Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı öğrencisi Nurettin ACI tarafından hazırlanan "Bilgisayarlı Görü İle Derin Öğrenme Teknikleri Kullanılarak Spor Antrenmanlarının Doğruluğunun Tespiti" adlı Yüksek Lisans ile ilgili tez savunma sınavı, 01/11/2023 tarihinde yapılmış ve tezin oy birliği ile kabul edilmesine karar verilmiştir.

JÜRİ: **İMZA**

Danışman: Dr. Öğr. Üyesi Muhammed Fatih KULUÖZTÜRK

Bitlis Eren Üniversitesi ……..

Üye: Doç. Dr. Ümit BUDAK

Bitlis Eren Üniversitesi ……..

Üye: Doç.Dr. Zafer CÖMERT

Samsun Üniversitesi ……..

Bitlis Eren Üniversitesi Lisansüstü Eğitim Enstitüsü Yönetim Kurulunun …… tarih ve …… sayılı kararıyla jüri tarafından kabul edilmiş bu çalışmanın yüksek lisans tezi olarak kabulü onaylanmıştır.

…./…../2023

Doç. Dr. Mehmet Bakır ŞENGÜL

Enstitü Müdürü

T.C.

Bitlis Eren Üniversitesi Lisansüstü Eğitim Enstitüsü

Elektrik Elektronik Mühendisliği Anabilim Dalı

BİLGİSAYARLI GÖRÜ İLE DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK SPOR ANTREMANLARININ DOĞRULUĞUNUN TESPİTİ

Nurettin ACI

Yüksek Lisans Tezi

Danışman: Dr. Öğr. Üyesi Muhammed Fatih KULUÖZTÜRK

EKİM 2023

ÖZET

Derin öğrenme tabanlı olarak geliştirilen MediaPipe Poz Tahmin modeli ile gerçek zamanlı görüntülerden elde edilen insan poz tahmini verilerinin makine öğrenme algoritmaları kapsamında spor biyomekaniği açısından spor aktivitelerinin doğruluk oranı üzerine sistematik bir analiz yapılmıştır. Bu çalışmada, MediaPipe Poz Tahmin modelinin farklı spor aktivitelerinde vücut pozisyonuna bağlı olarak biyomekanik parametreleri ışığında nasıl tahmin ettiği incelenmiştir. Ayrıca, modelin performansını değerlendirmek için gerçek zamanlı olarak kameradan elde edilen verilerin farklı makine öğrenme algoritmaları (regresyon, sınıflandırma vb.) ile eğitime tabi tutularak karşılaştırma yapılmıştır. Ayrıca bu çalışma, bilgisayarlı görü destekli derin öğrenme tekniklerinin spor antrenmanlarında ve poz tahminindeki uygulanabilirliği konusunda öncü bir araştırmadır. Mediapipe'nin insan poz tahmini modeli ile elde edilen verilerin makine öğrenme algoritmalarıyla eğitilmesi ile sporcuların pozisyonlarını doğru bir şekilde takip etmek için kullanılabileceği bir uygulama haline getirilmiştir. Ayrıca, bu aracın sporcuların performanslarını artırmak için nasıl kullanılabileceği konusunda da yol gösterici olacaktır. Sonuç olarak, MediaPipe Poz Tahmin modelinin spor biyomekaniği için uygun ve etkili bir araç olduğu gösterilmeye çalışılmıştır.

Anahtar kelimeler: Bilgisayarlı görü, derin öğrenme, spor antrenmanları

Republic of Türkiye

Bitlis Eren University Graduate School

Department of Electrical and Electronics Engineering

DETERMINING THE ACCURACY OF SPORTS TRAINING USING COMPUTER VISION AND DEEP LEARNING TECHNIQUES

Master's Thesis

Nurettin ACI

Supervisor: Dr. Lecturer Muhammed Fatih KULUÖZTÜRK

October 2023

ABSTRACT

A systematic analysis was made on the accuracy of sports activities in terms of sports biomechanics within the scope of machine learning algorithms of human pose estimation data obtained from real-time images with the MediaPipe Pose Estimation model, which was developed based on deep learning. The study examined how the MediaPipe Pose Estimation model predicts biomechanical parameters in different sports activities based on body position. The performance of the model was evaluated by comparing real-time camera data with training using various machine learning algorithms such as regression and classification. In addition, this study is a pioneering research on the applicability of computer vision assisted deep learning techniques in sports training and pose estimation. By training the data obtained with the human pose estimation model of Mediapipe with machine learning algorithms, it has been turned into an application that can be used to accurately track the positions of the athletes. This thesis abstract examines the impact of data from real-time images on the accuracy of sports activities using Medipipe's human pose estimation model. It will also guide how this tool can be used to improve the performance of athletes. Efforts have been made to demonstrate the suitability and efficacy of the MediaPipe Exposure Estimation model as a valuable tool in the field of sports biomechanics.

Keywords: Computer vision, deep learning, sports training

TEŞEKKÜR

Tezim için yardımlarını esirgemeyen birçok kişiye teşekkür etmek istiyorum. İlk olarak, tez çalışması sırasında her türlü bilgi, teşvik ve deneyimleri ile yardımlarını esirgemeyen, çalışmalarımda yardımcı olan ve yüksek lisans eğitimim süresince her türlü desteği ile göstermiş oldukları sabırdan dolayı tez danışmanım Sayın Dr. Öğr. Üyesi Muhammed Fatih KULUÖZTÜRK'e sonsuz teşekkürlerimi sunmak istiyorum. Bana bu tez sürecinde yol gösteren, önerileri ve eleştirileri ile çalışmamı her zaman destekleyen bir danışman olarak bana çok yardımcı oldu.

Son olarak, tez sürecinde beni destekleyen aileme ve arkadaşlarıma minnettarım. Her zaman yanımda oldular, beni cesaretlendirdiler ve motive ettiler.

Bu nedenle tezimde bana yardımcı olan herkese teşekkür etmek istiyorum.

İÇİNDEKİLER DİZİNİ

Sayfa

ÖZET ..... **I**

ABSTRACT ..... **II**

TEŞEKKÜR ..... **III**

İÇİNDEKİLER DİZİNİ ..... **IV**

ÇİZELGELER DİZİNİ ..... **VII**

ŞEKİLLER DİZİNİ ..... **VIII**

1. GİRİŞ **1**

1.1.Biyomekanik Nedir? **3**

1.2. Biyomekanik Analiz **5**

1.3. Biyomekaniksel Açıdan İnsan Hareketlerini Tanımlama **7**

1.3.1. Hareket Düzlemleri Ve Eksenleri Ve Hareketlerin Tanımlandığı Posturlar **7**

1.3.2. Diğer Düzlemlerdeki Ana Hareketler **9**

1.3.3. Bazı Temel Hareketler **12**

1.4. Biyomekaniksel Açıdan Bir Hareketin Kritik Özelliklerini Belirlemek **16**

1.5. Biyomekanik Alanlarından Spor Biyomekaniği Kavramı **17**

1.5.1. Kinematik **17**

1.5.2. Kinetik **17**

1.5.3. Doğrusal Kinematik **18**

1.5.4. Açısal Kinematik **18**

1.6. Bilgisayarlı Görü Nedir? **18**

1.7. Derin Öğrenme Nedir? **19**

1.8. İnsan Poz Tahmini Nedir? **20**

1.8.1. İnsan Poz Tahmin Teknikleri **20**

1.8.2. İnsan Poz Tahmin Model Türleri **21**

1.8.3. İnsan Poz Tahmini Yöntemleri **22**

1.8.4. İnsan Poz Tahmini Nasıl Çalışır? **22**

1.9. Makine Öğrenmesi Kavramı **23**

1.9.1 Denetimsiz Öğrenme **25**

1.9.2 Denetimli Öğrenme **26**

1.10. Sınıflandırma **26**

1.10.1 Makine Öğrenmesi Kavramları **27**

1.11. Boyut İndirgeme 28
1.12. Performans Değerleme 29
1.13. Bazı Önemli Makine Öğrenmesi Algoritmaları 30
1.13.1. K-Means (K-Ortalama) Algoritması 30
1.13.2. K – Nearest Neighbor (K-En Yakın Komşu) Algoritması 31
1.13.3. Decision Trees: DTs (Karar Ağaçları) 32
1.13.4 Naive Bayes Sınıflandırıcı 32
1.13.5. Yapay Sinir Ağları 33
1.13.6. Support Vector Machine: SVM (Destek Vektör Makinesi) 35
1.14. Spor Biyomekaniği Açısından Hareket Analizinin Önemi 36
1.15. Günümüz Hareket Analiz Yazılım ve Türleri 37
1.16. Spor Biyomekaniği Açısından Bilgisayarlı Görü 38
1.16.1. Bilgisayarlı Görünün Kısa Tarihçesi 39
1.16.2. Bilgisayarlı Görünün Kullanım Alanları 39
1.16.3. Bilgisayarlı Görü ile İnsan Poz Tahmini 41
1.17. İnsan Poz Tahmininin Önemi 41
1.17.1. İnsan Poz Tahmini Uygulamaları 42
1.17.2. Poz Tahmini ile Spor Antrenmanlarının Yapılması 43
1.18. Mediapipe Poz Tahmini Kütüphanesi 43
1.18.1. MediaPipe Poz Tahmini Nasıl Çalışır? 44
1.18.2. MediaPipe Kütüphanesi Model Mimarisi 45
1.18.3. Mediapipe Kütüphanesinin Kullandığı Topoloji 46
1.18.4. Mediapipe Kütüphanesinde Kullanılan Veri Seti 47
1.18.5. Mediapipe Avantaj ve Dezavantajları 47

2. MATERYAL VE YÖNTEM 49
2.1. Yöntem 49
2.2. Amaç 50
2.8. Algoritma Oluşturma ve Antrenman Seçimi 50
2.8.1. Ağırlık Kaldırma (Deadlift) 51
2.8.2. Çömelme (Squat) 53
2.9. Veri Seti Oluşturma Aşaması 54
2.10. Sınıflandırma Seçimi ve Modelleme Aşaması 55
2.9.5. Model Test Aşaması 58
2.10. Arayüz Oluşturma 58

3. BULGULAR VE TARTIŞMA 60
3.1. Poz Eklem Noktalarının Hesaplanması 60
3.2. Açı Hesaplama 61
3.3. İnsan Poz Tahmin Modellerinin Karşılaştırılması 62
3.2. Uygulama Performans Değerlendirmesi 71
4. SONUÇ VE ÖNERİLER 73
KAYNAKLAR 76
EKLER 85

ÇİZELGELER DİZİNİ

Çizelge 1.1. Karmaşıklık matrisi durumları 29
Çizelge 2.1. Model eğitim veri seti doğrulama metrik değerleri 57
Çizelge 3.1. İnsan Poz Tahmini Kütüphanelerinin Genel Özellikleri 63
Çizelge 3.2. Tespit edilen eklem yüzdesinin her bir belirli orandaki insan poz tahmini tarafından tespit edilen resim sayısı 66
Çizelge 3.3. Her eylemde Tespit Edilen Eklem Yüzdesi genel ortalaması (%). 68
Çizelge 3.4. Her bir Eylemdeki Tespit Edilen Eklem Yüzdesinin Ortalaması 69
Çizelge 3.5. BlazePose ve OpenPose Karşılaştırılması 70

ŞEKİLLER DİZİNİ

Şekil 1.1. Biyomekanik analizin uygulama alanları 5
Şekil 1.2. Biyomekanik analiz parametrelerinin insan uzvundaki gösterimi. 7
Şekil 1.3. Ana düzlemler ve hareket eksenleri: (a) sagital düzlem ve ön eksen; (b) ön düzlem ve sagital eksen; (c) yatay düzlem ve dikey eksen. 8
Şekil 1.4. Referans duruşlar (pozisyonlar): (a) temel ve (b) anatomik. 8
Şekil 1.5. Ön kolun dirsek eklemi etrafındaki fleksiyon ve ekstansiyon hareketi 9
Şekil 1.6. Kolun omuz eklemi ve uyluğun kalça eklemi çevresinde abduksiyonu ve adduksiyonu. 10
Şekil 1.7. Kolun omuz eklemi etrafında medial (iç) ve lateral (dış) rotasyonu. 10
Şekil 1.8. Kolun omuz eklemi etrafında yatay fleksiyonu ve ekstansiyonu. 11
Şekil 1.9. Biyomekaniksel yürüyüş analizi. 13
Şekil 1.10. Biyomekaniksel açıdan koşma analizi. 14
Şekil 1.11. Ayakta dikey atlamanın biyomekaniksel aşamaları 15
Şekil 1.12. Ayakta geniş veya uzun atlamanın biyomekaniksel aşamaları 15
Şekil 1.13. Fırlatma adımının biyomekaniksel aşamaları 16
Şekil 1.14. Bilgisayarlı görünün nesne algılama ve sınıflandırması 19
Şekil 1.15. Evrişimsel Sinir Ağı Modeli 20
Şekil 1.16. 2B ve 3B poz tahmini 21
Şekil 1.17. İnsan Poz Tahmin Model Türleri 21
Şekil 1.18. Denetimsiz öğrenme örneği 25
Şekil 1.19. Denetimli öğrenme 26
Şekil 1.20. 10-N çapraz doğrulama işlem adımları 28
Şekil 1.21. K-Means algoritması durum aşaması örneği 31
Şekil 1.22. K-En yakın komşu sınıflandırması modeli 32
Şekil 1.23. Bir Karar Ağacı modeli 32
Şekil 1.24. Basit Yapay sinir ağı hücresi 34
Şekil 1.25. Çok katmanlı yapay sinir ağı modeli 35
Şekil 1.26. Support vector machine sınıflandırma işlemi 35
Şekil 1.27. Doğrusal support vector machine sınıflandırma şekli 36
Şekil 1.28. Maksimal marjin ile esnek marjin örneği 36
Şekil 1.29. Nesne Algılama ile ilgili örnek 41
Şekil 1.30. Poz Algılama 43

Şekil 1.31. MediaPipe Kitaplığında belirtilen kilit noktalar 45
Şekil 1.32. Mediapipe Kütüphanesi Isı Haritaları (Heatmaps) kullanımı 46
Şekil 2.1. Kameradan doğru pozisyon algılama uygulaması süreçleri 51
Şekil 2.2. Doğru Deadlift postürü ve açısı 52
Şekil 2.3. Doğru Squat postürü ve açısı 54
Şekil 2.4. Kinematik ölçümler dahilinde veri seti oluşturma 55
Şekil 2.5. Elde edilen modelin test edilmesi 58
Şekil 2.6. Model arayüz tasarım ekranı 59
Şekil 3.1. Belli kamera açısından elde edilen kinematik değerler 60
Şekil 3.2. Ağırlık kaldırma doğru postür geçerliliği için eklem noktaları 60
Şekil 3.3. Çömelme Doğru Postür Geçerliliği İçin Eklem Noktaları 61
Şekil 3.4. Üç nokta arasındaki açı 62
Şekil 3.5. Veri setindeki resimlerin tespit edilen eklem sayısının kutu grafiği 65
Şekil 3.6. Video veri setinde tespit edilen eklemlerin yüzdesi 67
Şekil 3.7. Kinematik açı ölçümleri performansı 72
Şekil 3.8. Makine öğrenmesi performansı 72

1. GİRİŞ

Yorucu fiziksel aktivitelere katılımın sonucu olarak her yıl çok sayıda sporcu yaralanmaktadır. Bu yaralanmaların tedavisi maliyetli olduğu gibi uzun süreli sağlık sorunlarına da yol açabilmektedir [1]. Bu yaralanmaların oluş sıklığını azaltmak, bir sporcuyu yaralanmaya yatkın hale getirebilecek faktörleri belirlemek için uygun eğitim, teknik ve zindelik yoluyla başarılabilir. Ayrıca bu yaralanmaları azaltmaya yönelik çabalar, hem sporcuların uzun vadeli sağlıklarını güvence altına almak hem de tıbbi maliyetleri azaltmak için çabalar gerektirir [2]. İdeal olarak, egzersizin fiziksel ve psikolojik faydalarını optimize etmek ve aşırı yaralanma riskini en aza indirmek için bir sporcunun tam olarak ne sıklıkta, hangi yoğunlukta ve hangi süre boyunca egzersiz yapabileceğini özetleyen basit bir yönerge setine sahip olmak isteriz. Bu tür yönergelerin elde edilmesi güçtür ancak bilim adamlarının ve tıp ile ilgili kişilerin ortak çabalarıyla elde edilebilir [3].

Canlıların hareketleri birçok araştırmacının ilgisini çeker. Bu konuda yapılan çalışmalar arasında biyomekanik analizler, performans analizleri, kişi tanıma, hareket bozukluklarının belirlenmesi ve bilgisayar grafiklerinde sanal insan canlandırmaları yer alır. Bu çalışmaların temeli yürüme, koşma, atlama gibi spor aktivitelerinin biyomekanik özelliklerine dayanır. Biyomekanik, insan hareketlerinin anlaşılması ve analiz edilmesi için yapısal, fiziksel ve matematiksel modellerin kullanılmasıyla ortaya çıkmıştır [4].

Biyomekaniğin ortaya çıkmasında, insan vücudundaki yüksek serbestlik derecesi ile harekete neden olan etmenlerin sayısal olarak ifade edilmesi ve anlam kazandırılmasındaki zorluklar da etkili olmuştur. İnsan hareketlerinin analizi ve tanımlanması oldukça zorlu bir süreçtir. Bu bağlamda biyomekaniğin gelişmesine ihtiyaç duyulmuştur [5].

Biyomekaniğin gelişmesinde, matematik, fizik ilkeleri ve mühendislik metodolojilerinin bir araya gelmesi ve entegrasyonu büyük rol oynamıştır. Bu disiplinlerin birleşimi, biyomekaniğin uygulama alanlarının çeşitlenmesine ve gelişmesine katkı sağlamıştır. Biyomekaniğin temel amacı, insan hareketlerini anlamak, analiz etmek ve optimize etmektir. Bu amaç doğrultusunda basit modeller kullanılarak hareketlerin temsili olarak gösterimi temel bazı mekanik özelliklerin izahatı yapılabilirken, daha karmaşık hareket yapıları için spor biyomekaniği kullanılmaktadır.

Spor biyomekaniği; insan hareket kapasitesini, yaralanma ve önleme mekanikleri prensiplerini değerlendirme ile kas ve iskelet problemlerinin tedavisinin anlaşılabilmesi açısından önemli bir rol oynamaktadır. Spor biyomekaniği ile yapılan hareketlerden en üst düzeyde verim alınabilmesi için teknolojinin nimetlerinden de faydalanılmaktadır [6].

İnsan hareketlerinin incelenmesinde vücut üyelerinin kinematik ve kinetik verilerinden yararlanılmaktadır. Bu amaçla, bilgisayarlı görü ile insan poz tahmini modelleri geliştirilmiştir. İnsan poz tahmini, görüntüler ve videolardan elde edilen verilerle insan vücudu parçalarını bulup, üç boyutlu insan vücut iskeleti oluşturmayı amaçlamaktadır [7].

İnsan hareketlerinin analizi, basit bir biçimde hareket analizi sistemlerinin elde etmiş olduğu büyük veri setlerinin temel istatistiksel yöntemlerle değerlendirilmesiyle sınırlı kalmamaktadır [8]. Araştırmayı yürütenler, değişik teknikler kullanarak insan vücut parçalarını oluşturan eklemlerin yüksek serbestlik derecesi noktasında hareket etmelerine rağmen zaman içerisindeki konumlarının rasgele değişmediği ve düzgün bir davranış gösterdiği gözlemine dayanarak hareket analizini gerçekleştirmektedirler [9]. İnsan hareketleri doğası gereği simetrik olup, yürüyüş ve sıçrama hareketlerinde her bacak ve kolun hareketleri simetrik olarak gerçekleşir. Bu simetrik hareket yapısı, hareketlerin serbestlik derecesinin azaltılabilmesine ve koordinasyonun sağlanabilmesine imkân tanır. Spor bilimlerinde bu özellik koordinasyon olarak değerlendirilir. Ayrıca durum-uzay yaklaşımı, her evredeki duruşu bir durum olarak tanımlar [10].

Konumlar arasındaki yumuşak değişimi iyi tanımlayan doğrusal dönüşümün yakın zamandaki çalışmalarla gösterildiğini belirtmektedir. Bu yaklaşım, insan organizmasında benzer hareketlere sahip durumların yapısal olarak benzediğini ve bu nedenle durumların veya duruşların konum ve zaman uygunluğunu belirli bir mantıkla açıkladığını ifade etmektedir. İnsan hareketi, zaman içinde düzgün bir şekilde değişen ilişkili anlık duruşlarla tanımlanabilir [11].

İnsan-bilgisayar etkileşimi, hareket analizi, artırılmış gerçeklik ve sanal gerçeklik gibi çok çeşitli uygulamalarda kullanılmaya başlanan insan poz tahmini son yıllarda artan bir ilgi görmektedir. Derin öğrenme tabanlı çözümler insan duruşu tahmininde yüksek performans sağlasa da, yetersiz eğitim verileri, derinlik belirsizlikleri ve tıkanıklık gibi zorluklar hala mevcuttur [12].

Evde egzersiz yapmak için YouTube içeriği ve fitness uygulamaları kullanan teknolojiye aşina kişiler vardır. Fakat bu kişiler profesyonel olmayanların yanlış bilgilerine dayanarak egzersiz yapabilirler. Bu da yanlış duruşla veya fiziksel güçleri göz önünde bulundurulmadan egzersiz yaparak yaralanma riskini artırabilir [13]. Evde egzersiz yapmak kolay olsa da, doğru duruşu kontrol etmek zor olduğu için vücuda zarar verebilir. Bu yüzden, bu çalışmada bir egzersiz eğitmenine ihtiyaç duymadan evde egzersiz yaparken kullanıcılara rehberlik edecek bir program önerilmektedir. Bu program, MediaPipe Pose'un dönüm noktası modeli ile vücut duruşunu tahmin ederek, kullanıcının duruş pozisyonunun, doğru egzersiz kriterlerine uymaması halinde ekranda yönergeler göstermektedir. Kullanıcının duruşunun uygun olması durumunda, ekrandaki yönergelere uygun egzersiz sayısı artmaktadır.

Bu tezin amacı, sistematik bir analiz yoluyla insan poz tahmini için en son derin öğrenme tabanlı çözümlerin bilgisayarlı görü aracılığıyla gerçek zamanlı görüntüler aracılığıyla oluşturulan programın spor biyomekaniği açısından yapılan spor aktivitelerinin doğruluk oranları tespit edilmeye çalışılmaktadır. Bu amaç doğrultusunda ele alınan konu ile ilgili olarak bazı terimlerin ne anlama geldiği öncelikle bilinmesi gerektiğinden giriş kısmında spor biyomekaniği ve çalışmada kullanılan teknolojilerle ilgili kavramlar açısından geniş açıklamalar yapılmaktadır.

1.1.Biyomekanik Nedir?

Biyomekanik, bilim tarihinin derinliklerine kök salmış bir alandır ve ilk çağlardan beri matematikçiler, mühendisler, fizikçiler, biyolog ve hekimlerin çalışmalarından etkilenmiştir. Bu disiplinler biyomekaniğin gelişmesinde tek başlarına rol oynamamıştır; aksine, biyomekaniğin ilerlemesini sağlayan güç, bu disiplinlerin matematik, fizik ve mühendislik gibi alanlarda kullandıkları yöntemlerin birleşmesi ve bütünleşmesidir. Biyomekanik, mekaniğin temel yöntemlerini kullanarak, canlı organizmaların her seviyedeki biyolojik sistemlerinin mekanik özelliklerini, yapılarını, işlevlerini ve hareketlerini araştırır [14].

Biyomekanik kavramını daha iyi tanımlamak için öncelikle mekanik nedir onun tanımına bakalım.

Mekanik, fizik biliminin bir dalıdır ve cisimlerin kuvvet altındaki davranışlarını (hareket ve deformasyonlarını) inceler [15].

Biyomekanik ise mekaniğin temel metotlarını kullanarak biyolojik sistemlerin yapılarını, fonksiyonlarını ve hareketlerini inceler. Bu alan, tüm organizmalardan organlara, hücrelere ve hücre organellerine kadar herhangi bir seviyedeki biyolojik sistemlerin mekanik yönlerini araştırmaktadır [16].

Biyomekanik kelimesi etimolojik olarak, antik Yunanca βίος (bios) "hayat" ve μηχανική (mēchanikē) "mekanik" kelimelerinin birleşiminden oluşur ve mekanik prensiplerin canlı organizmalara uygulanmasıdır. Biyomekanik, canlıların kas-iskelet sistemi dinamiklerinin temellerini Rönesans döneminde tanımlayan İtalyan fizyolog ve fizikçi Giovanni Alfonso Borelli'ye kadar uzanmaktadır. 20. yüzyılda ise biyomekanik çok daha yaygın bir şekilde kullanılmaya başlamıştır.

Biyomekaniğin uygulama alanları oldukça geniştir ve bazıları şunlardır:

- Kas-iskelet sistemi ve ortopedik biyomekaniği
- Spor biyomekaniği
- Karşılaştırmalı biyomekaniği
- Hesaplamalı biyomekaniği
- Kinezyoloji (kinetik + fizyoloji)
- Kardiyovasküler biyomekaniği
- Biyoakışkanlar mekaniği
- Biyotriboloji
- Yumuşak doku dinamikleri
- Rehabilitasyon
- Ortez, protez ve implantlar
- Ergonomi ve mesleki biyomekaniği
- Adli biyomekaniği
- Hayvan lokomotor ve yürüyüş analizi
- Allometri.

Biyomekaniğin uygulama alanları oldukça çeşitlidir. Örnekler vermek gerekirse:

- Implante edilebilir yapay protezlerin tasarımında biyomekanik analiz kullanılması, örneğin yapay kalpler ve küçük kan damarları gibi protezlerin tasarımı.
- Canlı dokuların mühendisliğinde kullanımı, örneğin kalp kapakçıkları ve intervertebral diskler gibi dokuların geliştirilmesi.

- Araç kazalarına bağlı yaralanmaları önlemek için biyomekanik analizlerin kullanımı, özellikle düşük hızlı çarpışmalar ve yüksek hızlı çarpışmalardaki ağır ve ölümcül yaralanmaların önlenmesi için.
- Ergonomi ve mesleki biyomekanik gibi insanların işyerlerindeki hareketlerinin ve pozisyonlarının analizi ve iyileştirilmesi için kullanımı.
- Spor performansının artırılması, spor yaralanmalarının önlenmesi ve tedavisi için biyomekanik analizlerin kullanımı.
- Adli tıpta, yani yasal süreçlerde delil olarak biyomekanik analizlerin kullanımı.

Şekil 1.1. Biyomekanik analizin uygulama alanları

Biyomekaniğin teknolojik açıdan gerçekleştirdiği en büyük ilerleme, sistem düzeyinde cihazların geliştirilmesi ve uygulanmasıyla birlikte, birçok alanda olumlu etkileri görülmüştür. Örneğin, spor biyomekaniği sporcuların performansını artırmak ve yaralanmaları önlemek için çalışmalar yaparken, mesleki biyomekaniğin amacı çalışanların çevreleriyle mekanik etkileşimini anlamak ve optimize etmektedir.

Biyomekanik, ayrıca ortez, protez ve ortopedik cerrahi gibi alanlarda da önemli bir rol oynamaktadır. Örneğin, tekerlekli sandalyeler gibi yardımcı cihazların biyomekanik temelli tasarımı ve engellilerin hareket kabiliyetlerini artırmak için çevresel elemanların optimizasyonu gibi çalışmalar yapılmaktadır. Klinik rehabilitasyon, atletik performans ve çalışma ortamı etkileşimi gibi alanlarda da biyomekanik analizler kullanılarak iyileştirmeler yapılmaktadır.

1.2. Biyomekanik Analiz

Biyomekanik analiz teknikleri, kuvvet altındaki cisimlerin davranışlarını (hareket ve deformasyonlarını) inceleyen fizik dalı olan mekaniğin temel ilkelerini kullanarak, insan hareketi sırasında çeşitli dokuların maruz kaldığı kuvvetleri ve deformasyonları

tahmin etmeyi sağlar. Bu tekniklerde kullanılan fiziksel ilkeleri bilmek, yaralanma mekanizmasına etki eden faktörleri belirlemeye yardımcı olur. Vücut ve vücut bölümleri, mekaniğin temel yasalarına göre hareket eder. Newton'un ikinci yasası, katı bir cismin doğrusal ivmesinin (a), cismin kütlesi (m) ile çarpımının (yani, ma), cisime etki eden tüm kuvvetlerin (∑F) toplamına eşit olduğunu söyler (yani, ∑F=ma) [17].

Benzer şekilde, bir cisme etki eden tüm momentlerin (M) veya torkların toplamı, bir dönme ekseni etrafındaki kütlenin dairesel dağılımının bir ölçüsü olan eylemsizlik momenti ile açısal hızını (α) üretmeye eşittir (yani,∑M=I α).

Bir vücut uzuv bölümüne etki eden bileşke kuvvetler ve momentler, vücut uzuv bölümüne uygulanan dış yüklerin yanı sıra segmentle ilişkili kas-tendon birimlerinde, bağlarda ve kemiklerde gelişen kuvvetlerden kaynaklanır.

Bir vücut uzvunun kinematikleri olarak hız, pozisyon ve sürat bilinirse, harekete neden olan uzuva etki eden moment ve bileşke kuvvetler tanımlanabilir.

Bu tür bir analiz ters dinamikler olarak adlandırılır [18].

Bir cisme etki eden bileşke kuvvetler ve momentler, cismin şekil ve boyutlarına, dokuların yapısal özelliklerine ve materyalin özelliklerine bağlı olarak dokular arasında dağılır. Dokuların yapısal özellikleri, dokuları oluşturan hücrelerin türüne, konumuna ve yönüne bağlıdır. Materyalin özellikleri ise dokuların ara maddesinin bileşimine ve liflerine bağlıdır [19].

Bir cismin hareketini belirlemek için, bireysel kasların ürettiği kuvvetleri hesaplayan ve cismin Newton yasalarına uygun olarak nasıl davrandığını bulan ileri dinamikler adlı bir yöntem kullanılır. Bu yöntemle, cismin şekli ve boyutları ile dokuların konumu ve yönü gibi faktörler dikkate alınır. Bu faktörler, cismin bileşke kuvvetler ve momentler altında nasıl deforme olduğunu etkiler [20].

Şekil 1.2. Biyomekanik analiz parametrelerinin insan uzvundaki gösterimi.

Yaralanma mekanizmaları, dokulara uygulanan travma, yük veya zorlanma gibi mekanik kuvvetlerdir. Bu kuvvetler, dokuların toleransını aşarsa, kaslar, tendonlar, bağlar ve kemiklerde hasar ve deformasyona yol açar. Bu nedenle, insan hareketlerinin tanımlanması, bu dokuların yaralanma riskini değerlendirmek için gereklidir [21].

1.3. Biyomekaniksel Açıdan İnsan Hareketlerini Tanımlama

1.3.1. Hareket Düzlemleri Ve Eksenleri Ve Hareketlerin Tanımlandığı Posturlar

Hepsi olmasa da birçok eklem hareketinin meydana geldiği, karşılıklı olarak dik kesişen üç düzlemi tanımlamak için çeşitli terimler kullanılır. Bu üç düzlemin ortak kesişme noktası, en uygun şekilde ya çalışılan eklemin merkezi ya da tüm insan vücudunun kütle merkezi olarak tanımlanır. İkinci durumda, düzlemler, Şekil 1.3'de gösterildiği ve aşağıda açıklandığı gibi ana düzlemler - sagital, ön ve yatay düzlemler - olarak bilinir.

İnsan kas-iskelet sisteminin eklemlerindeki hareketler esas olarak rotasyoneldir ve meydana geldikleri düzleme dik bir çizgi etrafında gerçekleşir. Bu çizgi, dönme ekseni olarak bilinir. Üç eksen - sajital, ön ve dikey (uzunlamasına) - Şekil 1.3'de gösterildiği gibi hareket düzlemi çiftlerinin kesişmesiyle tanımlanabilir. Belirli bir eklem için bu üç eksenle ilgili ana hareketler, ön eksene göre fleksiyon ve ekstansiyon, sagittal eksene göre abdüksiyon ve adduksiyon ve dikey (uzunlamasına) eksenlere göre medial ve lateral (iç ve dış) rotasyondur [22].

- Sagittal düzlem, Şekil 1.3(a)'teki gibi, arkadan (posterior) öne (anterior) doğru geçen, vücudu sol ve sağ yarıya bölen dikey bir düzlemdir. Aynı zamanda ön-arka düzlem olarak da bilinir. Koşma ve uzun atlama gibi neredeyse iki boyutlu olan çoğu spor ve egzersiz hareketi bu düzlemde gerçekleşir.
- Frontal düzlem de dikeydir ve Şekil 1.3(b)'teki gibi vücudu arka ve ön yarılara bölerek soldan sağa doğru geçer. Aynı zamanda koronal veya mediolateral düzlem olarak da bilinir.
- Yatay düzlem, Şekil 1.3 (c)'te olduğu gibi, vücudu üst (üst) ve alt (alt) yarıya ayırır. Enine düzlem olarak da bilinir.
- Sagital eksen (Şekil 1.3(b)) arkadan öne yatay olarak geçer ve sagital ve yatay düzlemlerin kesişmesinden oluşur.

- Ön eksen (Şekil 1.3(a)) soldan sağa yatay olarak geçer ve ön ve yatay düzlemlerin kesişmesinden oluşur.
- Dikey veya uzunlamasına eksen (Şekil 1.3(c)) aşağıdan yukarıya dikey olarak geçer ve sagittal ve frontal düzlemlerin kesişmesinden oluşur.

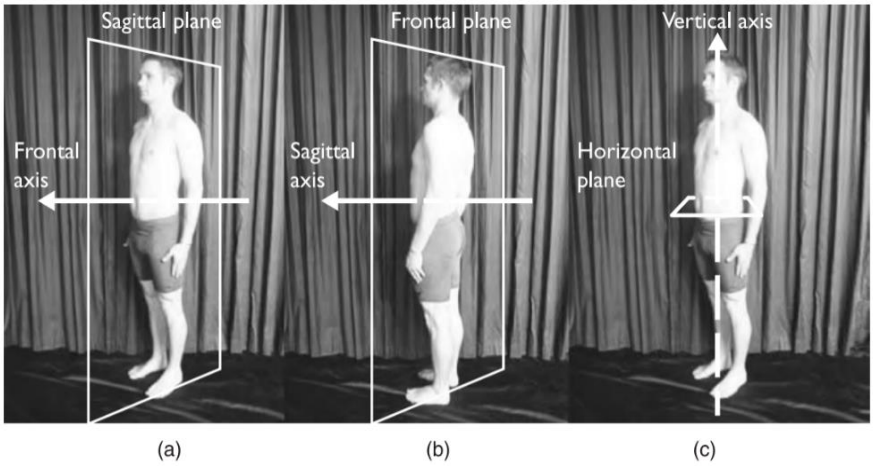

Şekil 1.3. Ana düzlemler ve hareket eksenleri: (a) sagital düzlem ve ön eksen; (b) ön düzlem ve sagital eksen; (c) yatay düzlem ve dikey eksen.

Vücut bölümlerinin hareketleri genellikle sporcu tarafından Şekil 1.4'te gösterilen temel (Şekil 1.4(a)) veya anatomik (Şekil 1.4(b)) referans duruşlardan veya konumlardan tanımlanır. Anatomik pozisyonda olduğu gibi temel pozisyonun "dikkat çekmek için durmaya" benzer olduğuna dikkat edin, tabiki de ikincisinde avuç içlerinin öne bakması haricinde.

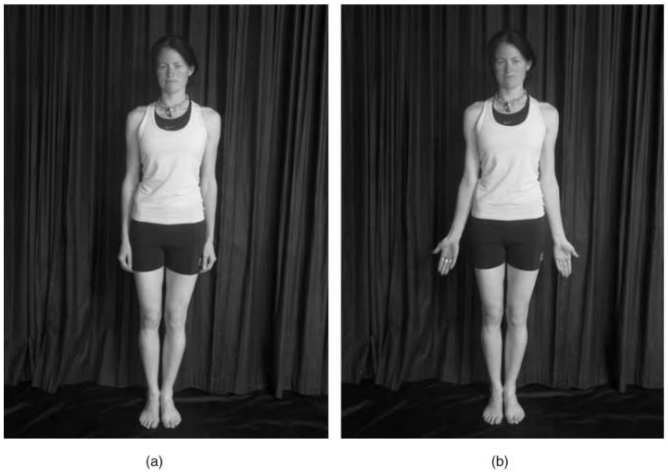

Şekil 1.4. Referans duruşlar (pozisyonlar): (a) temel ve (b) anatomik.

Genel olarak bu bölüm, frontal (veya mediolateral) dönme ekseni etrafındaki sagittal düzlemdeki hareketlere odaklanmaktadır (Şekil 1.3(a)). Şekil 1.4'teki gibi bir

kişiyi yandan görüntülemeyi düşünün; dirseğini büküyor ve sonra düzeltiyor. Bu hareketlere sırasıyla fleksiyon ve ekstansiyon diyoruz ve frontal dönme ekseni etrafında sagittal düzlemde gerçekleşir. Fleksiyon genellikle bir bükülme hareketidir ve vücut bölümü - dirsek söz konusu olduğunda ön kol - öne doğru hareket eder. Diz büküldüğünde, baldır geriye doğru hareket eder. Ayak bileği eklemindeki hareketler, ayak baldırın arkasına doğru aşağı doğru hareket ettiğinde plantar fleksiyon, ayak baldırın önüne doğru yukarı doğru hareket ettiğinde dorsifleksiyon olarak adlandırılır.

Tüm kolun anatomik referans konumundan omuz eklemi etrafındaki hareketine fleksiyon, bu konuma dönüşüne ekstansiyon denir; ekstansiyonun anatomik referans pozisyonunun ötesinde devam etmesine hiperekstansiyon denir. Aynı terminoloji, kalça eklemi etrafındaki uyluk için sagital düzlemdeki hareketleri tanımlamak için kullanılır. Bu kol ve uyluk hareketleri genellikle gövdeye göre tanımlanır.

Spor biyomekanistleri normalde çoğu eklemin tamamen uzatılmış pozisyonunun 180° olduğu kuralını kullanır; çoğu eklem esnediğinde bu açı azalır. Klinik biyomekanistler, tamamen uzatılmış bir eklemin 0° olduğu, böylece esnemenin eklem açısını arttırdığı alternatif bir kural kullanma eğilimindedir [23].

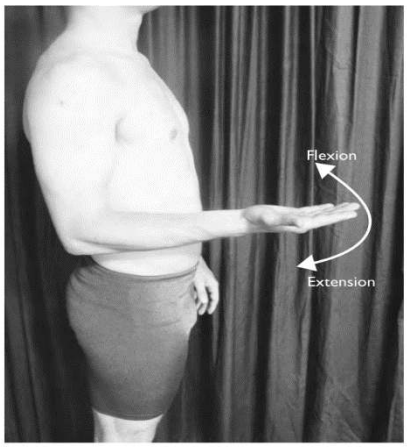

Şekil 1.5. Ön kolun dirsek eklemi etrafındaki fleksiyon ve ekstansiyon hareketi

1.3.2. Diğer Düzlemlerdeki Ana Hareketler

Sagittal bir eksen etrafındaki ön düzlemdeki hareketler, Şekil 1.6'da olduğu gibi, genellikle vücuttan uzağa abduksiyon ve vücuda geri adduksiyon olarak adlandırılır. Dirsek ve diz gibi bazı eklemlerde bu hareketler mümkün değildir veya çok kısıtlıdır. Dikey bir eksen etrafındaki yatay düzlemdeki hareketlere, Şekil 1.7'de olduğu gibi, genellikle uzuvlar için orta (veya iç) ve yanal (veya dış) dönüş ve gövde için sağa veya

sola dönüş denir. Tüm kolun 90° abdüksiyon konumundan öne doğru hareketleri, Şekil 1.8'deki gibi, ileri yönde yatay fleksiyon ve geri yönde yatay ekstansiyon şeklindedir.

Şekil 1.6. Kolun omuz eklemi ve uyluğun kalça eklemi çevresinde abduksiyonu ve adduksiyonu.

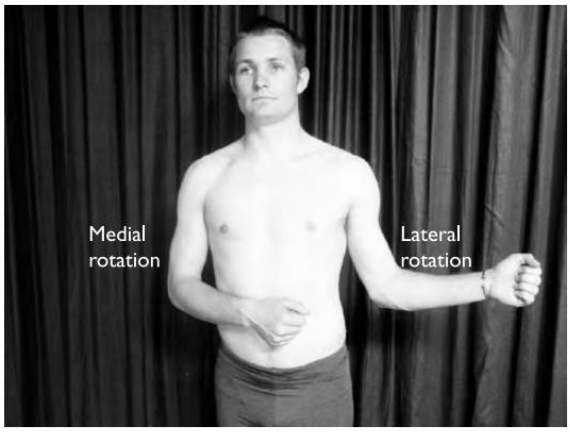

Şekil 1.7. Kolun omuz eklemi etrafında medial (iç) ve lateral (dış) rotasyonu.

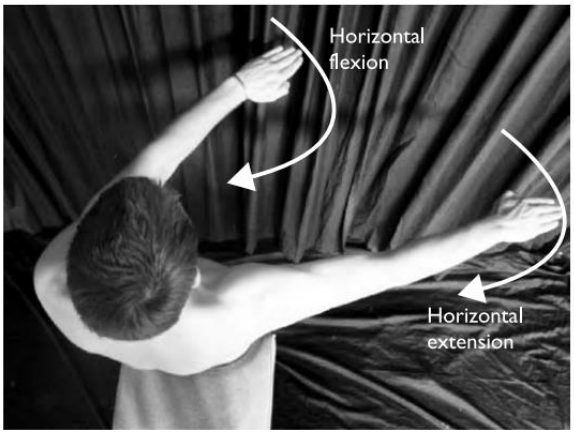

Şekil 1.8. Kolun omuz eklemi etrafında yatay fleksiyonu ve ekstansiyonu.

1.3.3. Bazı Temel Hareketler

Genel de temel hareketler çeşitli koşullarda yürüme, koşma, zıplama ve fırlatma yapan genç ve yaşlı, erkek ve kadınları içerir. Bu kişiler düz ve eğimli koşu bandında ya da yer üstünde farklı ayakkabı ve giysilerde yaptıkları hareketler dikey ve geniş atlama, koltuk altı, yandan ve kol üstü fırlatma gibi hareketleri eklemlerin dönme merkezleri etrafında yapmaktadırlar.

Herhangi bir insan hareketini analiz ederken hareket üzerinde kısıtlamalar doğal olarak ortaya çıkmaktadır. Genel itibari ile kısıtlamalar spor görevi, çevre veya organizma ile ilgili olmaktadır. Bu "kısıtlamalara dayalı" yaklaşım, neden belirli hareket modellerini gözlemlediğimizi anlamak için çok güçlü bir temel oluşturur. Örneğin, maksimum yüksekliğe ulaşmak için dikey olarak zıplamak açıkça bir görev kısıtlamasıdır. Organizma kısıtlamaları temel olarak biyomekaniktir; belirli bir bireyin göreve ve çevresel kısıtlamalara karşı hareket tepkilerini etkileyen vücut özellikleriyle bağlantılı olmasıdır. Bu biyomekanik kısıtlamalar, diğer pek çok şeyin yanı sıra genetik yapı, yaş, biyolojik cinsiyet, zindelik, yaralanma kaydı ve rehabilitasyon aşaması ve patolojik koşullardan etkilenecektir [24].

Şaşırtıcı olmayan bir şekilde, bir kişi belirli bir spor görevini yerine getirdiğinde gözlemlenen hareket modelleri, nadiren başka bir kişininki ile aynı olacaktır; aslında, aynı kişi tarafından aynı görevin tekrarlanmasından elde edilen hareket kalıpları da değişiklik gösterecektir. Bu hareketleri niceliksel olarak analiz ettiğimizde bu daha açık hale gelir ancak birçok hareket modelinde niteliksel olarak görülebilir. Sıklıkla hareket değişkenliği olarak bilinen bu gibi çeşitli tepkiler hareket analistlerinin spor hareketlerine bakışını etkileyebilir. Bu nedenle, nitel tanımlamalar her yetişkin için geçerli olmayacak, ancak pek çok sözde "normal" için geçerli olacaktır [25].

Karmaşık motor becerilerinin analizi için genellikle ilk adım, hareketin bölünebileceği aşamaların belirlenmesidir. Örneğin, fırlatma hareketinin ayrı ama birbirine bağlı aşamalara bölünmesi, karmaşık fırlatma tekniklerinin anlaşılmasına yardımcı olabilir. Her aşama, genel harekette biyomekanik olarak farklı bir rol oynayacak şekilde seçilmelidir. Daha sonra, her aşama açıkça tanımlanmış bir biyomekanik fonksiyona ve genellikle anahtar olaylar olarak adlandırılan kolayca tanımlanan aşama sınırlarına sahiptir. Faz analizi, hareket kalıplarının anlaşılmasına yardımcı olsa da, tüm

spor hareketlerinin temel özelliği onların bütünlüğüdür. Herhangi bir hareket modelinin herhangi bir faz analizi yapılırken bu daima akılda tutulmalıdır [26].

Yürüme: Yürüme, sürekli bir modelde bir adımın diğerini takip ettiği döngüsel bir aktivitedir. Yürüme adımını, bir ayağın yere değmesinden aynı ayağın bir sonraki yere basmasına ya da bir ayak parmak ucunun yerden kalkıp diğer ayak parmak ucunun yere basmasına kadar olarak tanımlarız. Yürürken, bir ayak yerdeyken tek destek aşaması ve her ikisi de yerdeyken çift destek aşaması vardır. Tek destek aşaması, bir ayağın başparmağının yerden kalkmasıyla, çift destek aşaması ise aynı ayağın yere değmesiyle başlar. Tek destek aşamasının süresi, çift destek aşamasının yaklaşık dört katıdır. Alternatif olarak her bacağı ayrı ayrı değerlendirebiliriz. Her bacağın daha sonra koşmadakine benzer işlevleri olan bir duruş ve destek aşaması vardır. Bir kişinin tercih ettiği hızda normal yürüyüşte, tek bacak için duruş aşaması tüm döngünün yaklaşık %60'ını ve sallanma aşaması yaklaşık %40'ını kaplar. Normal yürüyüşte, sol ve sağ taraflar için ortalama duruş ve sallanma süreleri çok benzer olacaktır. Patolojik yürüyüşte, iki taraf arasında aritmik yürüyüş modellerine yol açan belirgin bir fark olabilir.

Yürüme sırasında, sallanma aşaması kalça esnemeye başlar ve ardından kalça, yere değmeden hemen önce genişlemeye başlar. Genişleme, topuk parmak ucundan hemen önce yükselene kadar devam eder. Ardından kalça, diğer ayak yere değdiğinde bir sonraki sallanma aşaması için tekrar esnemeye başlar. Diz normalde inişte hafifçe fleksiyondadır ve bu fleksiyon, yavaş yürümede zorunlu olmamakla birlikte devam eder. Topuk yükseldikten hemen sonra, diz biraz ekstansiyon gelmeden önce keskin bir şekilde esnemeye başlar. Bu fleksiyon, ayak parmağı yere inmeden önce hafifçe esnemeden önce, salınmanın yaklaşık yarısına kadar devam eder. Ayak bileği konma sırasında kabaca nötr bir konumdadır. Daha sonra ayak bileği, tüm ayak yerde olana kadar dorsifleksiyon başladığında plantar fleksiyona gelir. Plantar fleksiyonu daha sonra neredeyse parmak uçlarını takip eder ve ayak bileği öne doğru sallanırken hızla dorsifleksiyon yaparak ayağın zemini temizlemesine izin verir [27].

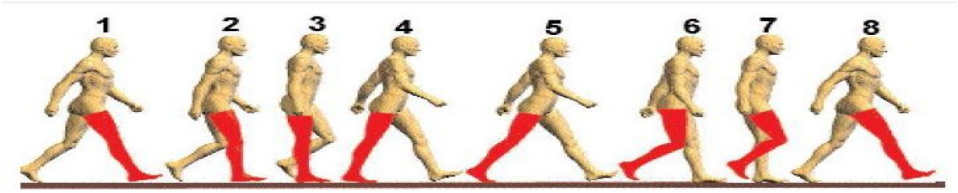

Şekil 1.9. Biyomekaniksel yürüyüş analizi.

Koşma: Koşmak, yürümek gibi döngüsel bir aktivitedir; bir koşu adımı, sürekli bir düzende diğerini takip eder. Koşma adımını, bir ayağın yere değmesinden aynı ayağın bir sonraki yere inmesine veya parmak ucundan parmak ucuna kadar olan adım olarak tanımlarız. Yürümenin aksine, koşma temel olarak bir ayağın yerde olduğu bir destek aşamasına ve her iki ayağın da yerden kesildiği bir toparlanma aşamasına ayrılabilir. Koşucu, yalnızca o aşamanın ana biyomekanik işlevini tanımlayan ve aşamanın başlangıcını, konmayı (veya ayak vuruşunu) ve bitişini, ayak parmağını gösteren temel olayları sağlayan destek aşaması sırasında itme için yere kuvvet uygulayabilir. Destek aşaması, ayağın yerden kesilmesiyle başlar ve ayağın yere değmesiyle sona erer; bu aşamada, ayak işlevinin bir sonraki iniş kalkış için hazırlıkta olduğu düşünülür. Yavaş koşuda veya hızlı tempolu yürüyüşte, toparlanma aşaması çok kısa olacaktır; daha sonra koşma hızı ile artacaktır [28].

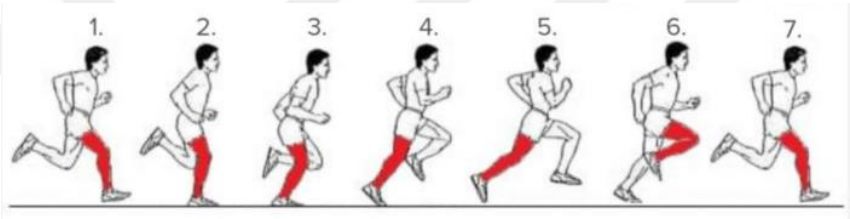

Şekil 1.10. Biyomekaniksel açıdan koşma analizi.

Atlama: Fırlatmalar gibi zıplamalar da genellikle bir kas grubundaki kas aktivitesiyle başlayan, kas aktivasyonu olmadan 'seyir halinde' devam eden ve karşı kas grubu veya bağlar gibi pasif doku yapıları tarafından yavaşlama bir hareketi ile sonlanan hareketler 'balistik' hareketler olarak tanımlanır. Birçok balistik spor hareketi, biyomekanik olarak üç aşamaya ayrılabilir: hazırlık, eylem ve iyileşme. Bu aşamaların her biri belirli biyomekanik işlevlere sahiptir. Hazırlık aşaması, ayakta durma pozisyonundan karşı hareket sıçramalarında, vücudu hareket (yükselme) aşaması için avantajlı bir konuma getirdikten sonra eksantrik olarak büzülen (uzayan) kaslar sırasında elastik enerjiyi depolayan bir alçaltma aşamasıdır. Eylem fazı, tüm bacak eklemlerinin birlikte esnetildiğinden ya da plantar esnetildiğinden ziyade sıralı değil, senkronize bir yapıya sahiptir. İyileşme aşaması hem havada geçirilen süreyi hem de bacak kaslarının eksantrik kasılması yoluyla kontrollü bir inişi içerir. Uzun veya yüksek atlama gibi bir koşu içeren veya üçlü atlama gibi daha karmaşık bir yapıya sahip olan atlamalar, üçten fazla aşamaya bölünmeyi kapsamaktadır. Kol hareketleriyle yapılan sıçramalarda kol hareketlerinin bacak hareketleriyle koordinasyonu performans için çok önemlidir [29].

Ayakta Dikey Atlama: Dikey sıçrama, kalça ve dizlerin ekstansör kasları ve ayak bileğinin plantar fleksörleri tarafından gerçekleştirilir. Hazırlık aşamasında bu kaslar eş zamanlı olarak eksantrik olarak kasılır, böylece dizlerin ve kalçaların esnemesine ve ayak bileklerinin dorsifleksiyonuna izin verilir. Eylem aşamasında ise, kalça ve dizler aynı anda ekstansiyon yaparken, vücudu dikey olarak yukarı kaldıran kaslar kısalır ve ayak bileklerinin plantar fleksiyonu gerçekleşir. Atlayıcının kol hareketleri de atlamaya katkıda bulunur ve doğru bir şekilde koordine edildiğinde performansı artırır. Ayakta dikey sıçramada bacak ve kol hareketlerinin iyi koordine edilmesi önemlidir ve bu hareket, saha testlerinde kullanılan bir bacak gücü testidir [30].

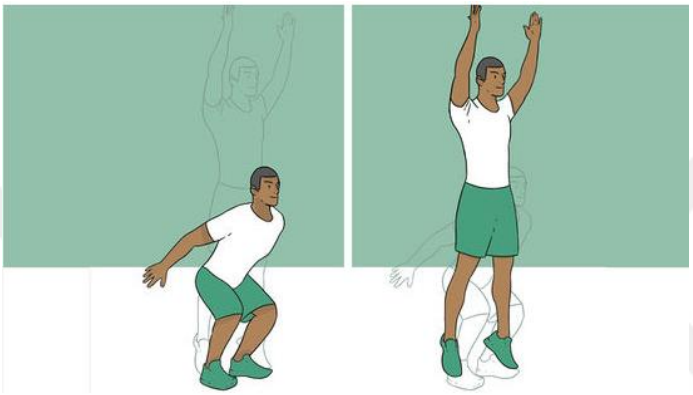

Şekil 1.11. Ayakta dikey atlamanın biyomekaniksel aşamaları

Ayakta Geniş Veya Uzun Atlama: Atlayıcının ayakta uzun veya geniş sıçrama hareketindeki ilkeleri, ayakta dikey sıçramaya çok benzer. Ancak, atlayıcının hedefi mümkün olduğunca yatay bir mesafeye zıplamak olduğundan, özellikle öne doğru eğilerek, zıplamanın dikey ve yatay yönleri arasında eforun paylaştırılması gerekir. Bu, görevi biraz karmaşıklaştırır. Kol salınımı olmadan yapılan atlama ile kol salınarak yapılan atlama karşılaştırıldığında, koordineli kollardan elde edilen salınım performansı artırır. Tüm uzuv hareketlerinin koordinasyonu önemlidir. Kalkış yüksekliği iniş yüksekliğinden ne kadar yüksekse, kalkış açısı o kadar küçük olmalıdır. Kalkış ve iniş yükseklikleri eşitse, optimum açı 45° olacaktır [31].

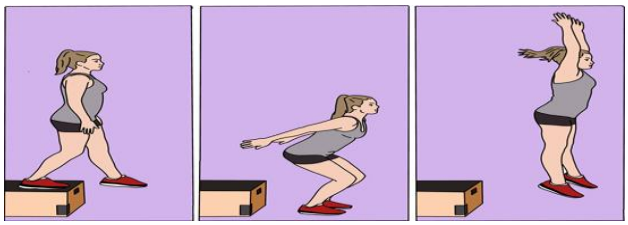

Şekil 1.12. Ayakta geniş veya uzun atlamanın biyomekaniksel aşamaları

Fırlatma: Sporcunun el ile ya da lakros durumunda bir alet ile bir nesne fırlattığı, geçirdiği, bowling gibi yuvarlama yaptığı, ateş ettiği spor veya etkinliklerin ilkelerine odaklanır. Bu ilkelerin bazıları veya tümü şunlarla ilgilidir: çemberden atışlar – çekiç ve disk atışları, gülle atma; çapraz beceriler – cirit atma ve kriket bowlingi; beyzbol ve softbolda atış; basketbol, netbol, hentbol, sutopu ve lakrosta şut ve pas hareketleri; fırlatma becerileri – beyzbol, kriket, futbol, rugby, Amerikan ve diğer futbol çeşitleri; koltuk altı bowlingi; ve dart atma. Diğer balistik spor hareketlerinde olduğu gibi, birçok atış biyomekanik olarak üç aşamaya ayrılabilir: hazırlık, eylem ve toparlanma [32]. Fırlatma hareketleri genellikle koltuk altı, kol üstü veya yan kol olarak sınıflandırılır. Aşırı kol ve yan kol modelleri olarak da adlandırılan son iki atış türü, gövdenin yanal fleksiyonu ve bükülmesi yoluyla belirlenir. Aşırı kol modelinde, gövde fırlatan koldan yanal olarak esnerken yan kol modelinde gövde, kola doğru yanal olarak esner. Bir fırlatma hareketinin amaçları, genellikle mesafe, doğruluk veya her ikisinin bir kombinasyonudur ve görevin kısıtlamalarına göre belirlenir [33].

Şekil 1.13. Fırlatma adımının biyomekaniksel aşamaları

Koltuk Altı Atışları: Bowling hareketlerinden çim bowlingi, tenpin bowlingi, dokuz kukada kullanılan çeşitli diğer bowling hareketleri, curling ve softbol atışları, koltuk altı atışlarıdır. Tek kolla koltuk altı atışları genellikle yatayın üzerinde aşırı uzatılmış bir konumdan, ağırlıklı olarak fleksiyon olan omuz hareketi ile karakterize edilir. Hazırlık aşamasında, ağırlık arka ayağa aktarılır ve ön ayak öne doğru adım atar. Hareket aşaması sırasında, pelvis ve gövde sola doğru dönerken (sağ elini kullanan bir atıcı için) ağırlık ön ayağa aktarılır. Dirsek hareket aşamasında uzar ve serbest bırakıldığında fırlatma kolu gövde çizgisine paralel veya biraz önündedir [34].

1.4. Biyomekaniksel Açıdan Bir Hareketin Kritik Özelliklerini Belirlemek

Hareket analizi, spor becerilerinin incelenmesini ve değerlendirilmesini içeren bir alanı ifade eder. Hareketin 'kritik özelliklerini' belirleyerek, gözlemlenen hareketin 'tekniğini' analiz etmek mümkündür. Bu özellikler, belirli bir becerinin performansını

artırmak veya yaralanma riskini azaltmak için çok önemlidir - bazen her ikisi birden. Bu, niteliksel bir biyomekanik analist için hareketin bu özelliklerini gözlemlemek anlamına gelir. Nicel analist için ise bu özelliklerin ölçülmesi ve sıklıkla daha fazla matematiksel analizi gerektirir. Kritik özellikler için bir 'doğruluk ölçeği' belirlemek yararlı olabilir. İdeal performans veya seçkin atlet şablonu yaklaşımı, genellikle elit bir oyuncunun performansından tanımlanan bir dizi kritik özellik tasarlamayı içerir. Ancak bu yaklaşım, her icracının kendine özgü kısıtlamaları olduğu gerçeğini göz ardı eder. Bu nedenle, hareket analistleri arasında, herhangi bir spor hareketi modeli için evrensel bir 'en uygun performans modeli' olmadığı konusunda geniş bir fikir birliği var [35].

1.5. Biyomekanik Alanlarından Spor Biyomekaniği Kavramı

Spor Biyomekaniği, anatomi ve fizyoloji bilgileriyle birlikte, mekanik ilkeler ve yöntemlerini kullanarak insan vücudunu ve hareketlerini inceleyen bilim dalıdır [36]. Yapılan bu çalışmanın daha rahat anlaşılması için bazı temel kavramların bilinmesi önem arz etmektedir. Bunları şu şekilde sıralayabiliriz;

1.5.1. Kinematik

Kinematik, bir nesnenin konum, hız ve ivmesini ve bunların zamanla nasıl değiştiğini inceleyen bir fizik dalıdır. Hareketlerin yol, zaman ve açı (dönme hareketinde) gibi ölçümleri de kinematik açıdan incelenir [37].

Örneğin, bir futbolcunun şut attığı sırada topun yörüngesi, topun hızı, kat ettiği mesafe, hedefe ulaşana kadar geçen süre gibi faktörler kinematik açıdan değerlendirilebilir. Ayrıca topun dönme hareketi, yani spininin hızı, yönü ve etkisi de kinematik ölçümler arasındadır.

1.5.2. Kinetik

Kinematik, hareketi ve hareketin niteliklerini zaman, uzay ve açısal parametreler kullanarak incelerken, kinetik, harekete neden olan ve hareketten doğan kuvvetleri ele alır. Bir objeye etki eden kuvvetlerin yanı sıra, kasların açığa çıkardığı kuvvetler, yerçekimi kuvveti ve yer reaksiyon kuvveti gibi faktörler kinetikte ele alınır. Şut atan bir futbolcunun örneğinde, topa uygulanan kuvvet, kasların açığa çıkardığı kuvvetler, eklemlerde dengeyi sağlayan kuvvetler ve top kaleci tarafından yakalandığında top ile kaleci arasında oluşan etki-tepki kuvvetleri gibi kinetik değerlendirmeler de yapılır [38].

1.5.3. Doğrusal Kinematik

Sporcu veya spor malzemesi (top, raket, tekne, araba vb.) tarafından doğrusal olarak gerçekleştirilen hareketlerin hızını, yönünü, kat ettiği mesafeyi inceleyen bilim dalıdır. İki veya üç boyutlu ortamlarda kişinin hareketinin başlangıç ve bitiş noktaları, hızı, kat edilen mesafe, hedefe göre konumu, yer değiştirmenin miktarı, ortaya çıkan hız değişimleri incelenir. Ayrıca, hareket açısal bir hareket ise, açısal değişiklikler göz önünde bulundurularak, bir dairenin çevresi, kaplanan alan, merkezden uzaklık ve devir sayısı gibi konular da değerlendirilir [39].

1.5.4. Açısal Kinematik

Açısal kinematik, insan vücudundaki hareketlerin incelenmesinde sıklıkla kullanılan bir mekanik dalıdır. Bir merkez ve ekseni çevresinde yapılan yörüngesel hareketleri araştırarak eklemlerde meydana gelen hareketleri değerlendirmekte en uygun yöntemdir. Günlük yaşamda veya spor amaçlı gerçekleştirilen tüm hareketler açısal değişiklikler içerdiğinden, açısal kinematik ile yapılan değerlendirmeler ve sonuçlar, atletlerin hareketlerinin analiz edilmesinde, antrenörlerin ve sporcuların kendilerini geliştirmesinde ve yeni tekniklerin oluşturulmasında yardımcı olmaktadır [40].

1.6. Bilgisayarlı Görü Nedir?

Bilgisayarlı görü, insan beyninin görme işlemlerini makineye aktarmayı amaçlayan bir alandır. Bu alandaki temel amaç, dijital görüntülerin içeriğini anlayarak, içerisindeki nesneleri tanımlayabilmek ve gruplandırabilmektir. Bu sayede makine, görüntü üzerinde bir nesne, metin veya model çıkarımı yapabilir hale gelir [41].

Bilgisayarlı görü, insan beyninin görme yeteneğinin makinelere aktarılması ve dijital görüntülerin içeriğinin anlamlandırılması için kullanılan bir alan olarak tanımlanabilir. Görüntü işleme konusunun da üst konularından birini oluşturur. Nesne tanıma, hata tespiti, sınıflandırma gibi işlemlerle uğraşır ve amaç, görüntülerden elde edilen bilgiyi kullanarak farklı veya istenilen çıktıları elde etmektir. Bu amaç doğrultusunda, görüntü işleme teknikleri de kullanılabilir. Ancak, karar verme hususu görüntü işleme alanının içinde yer alsa da, bilgisayarlı görü elde edilen bilgiyi kullanarak belirli işlemler yapmak için farklı tekniklerden faydalanabilir [42].

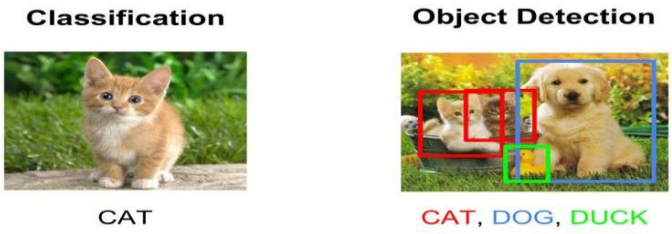

Şekil 1.14. Bilgisayarlı görünün nesne algılama ve sınıflandırması

1.7. Derin Öğrenme Nedir?

Derin öğrenme, makine öğrenmesinin bir türüdür. Bu yöntem, birçok doğrusal olmayan işlem birimi katmanını kullanarak özellik çıkarma ve dönüştürme işlemleri gerçekleştirir. Her ardışık katman, önceki katmandan gelen çıktıyı girdi olarak alır. Algoritmalar hem denetimli öğrenme (sınıflandırma gibi) hem de denetimsiz öğrenme (desen analizi gibi) için kullanılabilir [43].

Derin öğrenme, çok katmanlı sinir ağlarının kullanıldığı bir makine öğrenmesi yaklaşımıdır. Verilerin özelliklerinin ve temsillerinin öğrenilmesi, birden fazla katman kullanılarak yapılır. Bu katmanlar, alt düzey özelliklerin üst düzey özelliklere dönüştürülmesiyle oluşan hiyerarşik bir temsil oluştururlar. Bu temsil, verilerin farklı soyutlama seviyelerine karşılık gelen birden çok temsil seviyesini öğrenmektedir [44]. Derin öğrenme, verilerin temsillerini öğrenme temeline dayalı bir makine öğrenmesi yöntemidir. Bu yöntemde, örneğin bir görüntü için, piksel yoğunluklarından veya özel şekillerden oluşan özellik vektörleri gibi çeşitli özellikler kullanılır. Derin öğrenme algoritmaları, elle çıkarılan özellikler yerine, verinin en iyi şekilde temsil edilmesi için hiyerarşik bir özellik çıkarımı yapabilen etkin yöntemler kullanır. Bu yöntemde, alt düzey özellikler üst düzey özelliklere dönüştürülerek hiyerarşik bir temsil oluşturulur [45].

Bilgisayarlı görü ile görüntü işleme alanında, nesnelerin ayrıştırılması için derin öğrenme algoritmalarından faydalanmak gerekmektedir. En çok kullanılan derin öğrenme algoritmalarından biri evrişimli sinir ağlarıdır (CNN). Yann LeCun tarafından geliştirilen bu sinir ağları, görüntülerdeki nesneleri ayırt etmek için etkili bir yöntemdir. Evrişimli sinir ağları, özelleştirilmiş bir derin öğrenme algoritmasıdır. İlk katmanı konvolüsyonel bir katmandan oluşan bu ağların devamında pooling ve fully-connected katmanları yer alır. Konvolüsyonel katmanlar, görüntünün temel özelliklerini anlamaktan sorumludur. Pooling katmanları, boyut küçültme ve hesaplama sayısını azaltmak için kullanılır. Fully connected katmanı ise klasik sinir ağı yapısında bulunan bir katmandır ve her zaman en

sonda yer alır. Model eğitimi için birçok tekrarlı katman, ileri veya geri yayılım ve test işlemleri yapılır. Böylece, makinelere göz işlevi atanarak görüntü tanıma görevleri gerçekleştirilebilir [46].

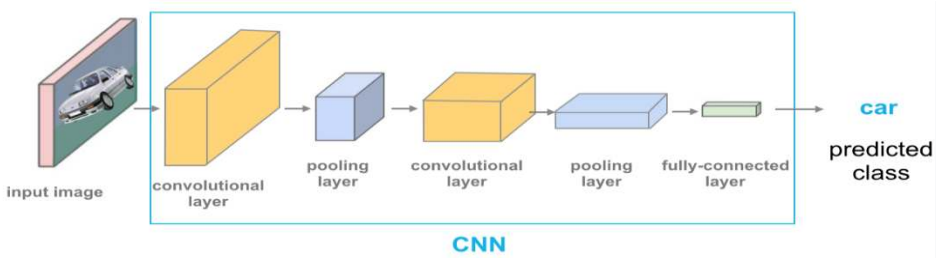

Şekil 1.15. Evrişimsel Sinir Ağı Modeli

1.8. İnsan Poz Tahmini Nedir?

İnsan Poz Tahmini, görüntülerin ya da videoların içerisinde insan vücuduna ait hatların ve eklem noktalarının poz durumunu tanımlayıp sınıflandıran bir tekniktir. Bu teknik aslında, İki Boyutlu (2B) ve Üç Boyutlu (3B) uzayda insan pozlarını tespit edip ardından sonuç çıkaran model tabanlı bir tekniktir.

Temel olarak, bu poz tahminleme modeli, resimlerde veya videolarda insan vücut eklem noktalarını, yani bilekler, omuzlar, dizler, gözler, kulaklar, ayak bilekleri ve kollar gibi önemli noktaları belirleyerek bir dizi koordinat elde etme yolunu benimser.

Bir görüntü ya da video girdi olarak kullanıldığında, poz tahminleme modeli tespit ettiği vücut hat ve eklemleri çıktı olarak koordinat bölgelerini sunar ve bu tahminlerin netliğini belirten bir güven puanı ile birlikte sunar.

1.8.1. İnsan Poz Tahmin Teknikleri

İnsan poz tahmin modelleri, insan pozlarını algılayabilmek amacıyla kullandığı başlıca iki teknik bulunmaktadır.

- **2B poz tahmini:** Bu teknikte, model 2B uzayda vücut eklemlerinin konumlarını tahmin eder. Konum, her bir eklem için X ve Y koordinatlarıyla gösterilir.
- **3B poz tahmini:** Bu teknikte, model 2B görüntüyü 3B nesneye dönüştürmek için ek bir Z boyutu tahmin eder. 3B poz tahmini, temsil edilen bir kişinin veya nesnenin gerçek uzaysal konumunu temin etmeye çalışır.

2B poz tahmini, daha basit ve daha az karmaşık bir tekniktir. Ancak, 3B poz tahmini, daha doğru sonuçlar vermektedir. 3B poz tahmini, makine öğrenimi mühendisleri için ciddi derecede bir zorluktur. Çünkü, 2B görüntüden 3B uzaya

projeksiyon yapmak için çeşitli faktörleri tahmin eden veri kümeleri ile algoritmalar elde etmek gerekir. Bu faktörler arasında arka plan sahnesi, ışık koşulları ve kameranın konumu bulunmaktadır.

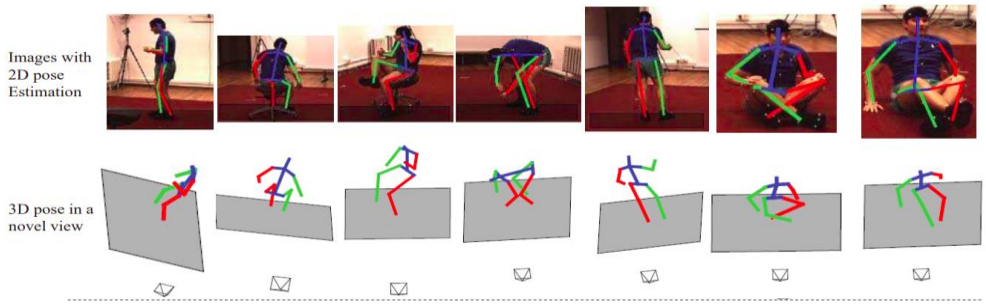

Şekil 1.16. 2B ve 3B poz tahmini

1.8.2. İnsan Poz Tahmin Model Türleri

İnsan pozu tahmini için kullanılan üç ana model türü şunlardır:

- **İskelet tabanlı model:** Bu model, insan vücut bölgesinin iskelet yapısını temsil etmektedir. Model, ayak bilekleri, dizler, omuzlar, dirsekler, bilekler ve uzuv yönelimleri gibi bir dizi kilit noktayı içermektedir. Ayrıca model, farklı vücut hatları arasındaki ilişki ve farklılıkları yakalamak için de kullanılmaktadır.
- **Kontur tabanlı model:** Bu model, insan vücut hatlarının görünüşünü ve şeklini temsil etmektedir. Model; gövde, gövdeye bağlı uzuvların kontur ve kaba genişlik formunu kullanmaktadır. Ayrıca, vücut bölüm hatlarının bir kişiye ait kontur sınırları ve dikdörtgenleriyle görüntülendiği bir insan vücudunun görünümünü ve şeklini temsil etmektedir.
- **Hacim tabanlı model:** Bu model, insan vücudunu hacimsel olarak temsil eder. Ayrıca bu model, insan geometrik ağları ve şekilleri ile temsil edilen çok sayıda popüler 3B insan vücudu modeli ve pozundan oluşmaktadır. Hacim Tabanlı Model, genel de 3B poz tahmini için kullanılmaktadır.

Şekil 1.17. İnsan Poz Tahmin Model Türleri

1.8.3. İnsan Poz Tahmini Yöntemleri

İnsan pozu tahmini yöntemleri, iki temel yaklaşıma göre sınıflandırılmaktadır:

Aşağıdan yukarıya yöntemler: Bu yöntem, her bir vücut eklemini ayrı ayrı tahmin eder ve ardından bu eklemleri birleştirerek bir poz oluşturur. Ayrıca yöntemin ayrıcalığı, karmaşık pozları tahmin etmek için daha iyi olmasıdır.

Yukarıdan aşağıya yöntemler: Bu yöntemde ise, ilkin bir vücut detektörü kullanılarak bir kişinin sınırlayıcı kutuları tahmin edilir. Ardından, sınırlayıcı kutular içindeki vücut eklemleri tahmin edilmekteri. Bu yöntemin avantajı, daha hızlı ve daha basit yapıda olmasıdır.

1.8.4. İnsan Poz Tahmini Nasıl Çalışır?

İnsan poz tahmin probleminin çözümü için birkaç önerilen yöntem bulunmaktadır. Genel de bu yöntemler üç ana gruba ayrılmaktadırlar. Bunlar; Mutlak Poz Tahmini, Göreli Poz Tahmini ve bu ikisinin birleşimi olan Uygun Poz Tahmini.

Mutlak Poz Tahmini: Uydu tabanlı navigasyon sinyalleri, navigasyon işaretleri, aktif ve pasif yer işaretleri ile ısı haritası eşleştirmelerine dayanan bir yöntemdir. Bu yöntem, insan pozunu belirlemek için çeşitli veri kaynaklarını kullanmaktadır.

Göreli Poz Tahmini: Bilinen bir eklem noktasından olan mesafeyi hesaplayarak insan pozunu aşamalı olarak güncelleyen ölçümlere dayanarak yapılan yöntemdir. Başlangıçta insanın pozisyonunu ve uyumunu tahmin edip akabinde bu tahminleri güncelleyerek poz tahminini iyileştirme yoluna gitmektedir.

Genel olarak, bu algoritmaların temel mantığı, bir kişinin arka planla ilişkisini tahmin etmek için insan pozunu ve yönlendirmesini kullanarak yapılmaktadır. İnsanları tanımlayan sınırlayıcı kutuları belirleyip her bir kutunun pozunu değerlendirmektedirler. Daha sonra, dirsek, diz, bilek gibi eklem noktalarını vurgulayarak tek bir kişi veya birden fazla kişi için poz tahminleri yapabilmeleridir. Ayrıca, bir giriş görüntüsünden başlayarak özellikleri çıkaran bir kodlayıcı kullanmaları ve poz tahmini için kullanılan yönteme bağlı olarak farklı işlemler yapabilmeleri bu yöntemlerin üstün ayrıcalıkları taraflarıdır.

Kavramsal olarak en basit sistem, her anahtar noktanın X, Y ve Z koordinatlarını tahmin etmek için bir giriş görüntüsü almaktadır. Ancak bu basit yaklaşım, doğru sonuçlar üretmeden önce daha fazla iyileştirme gerektirir.

Daha karmaşık bir yaklaşım, bir kodlayıcı-kod çözücü mimarisi kullanır. Bu mimaride, kodlayıcı bir kod çözücü ile birleştirilir ve ısı haritaları oluşturulur. Isı

haritaları, belirli bir bölgede bir eklem olasılığını temsil eder. Kesin koordinatlar, en yüksek olasılığa sahip ısı haritası konumları seçilerek belirlenir.

Gelişen bilgisayarlı görüş yöntemleri ile poz tahmini, görüntü segmentasyonu ve nesne algılama gibi birçok görevde daha iyi performans göstermektedir. Bu nedenle insan poz tahmini için derin öğrenme tabanlı birkaç popüler kitaplık bulunmaktadır. Bu kitaplıklar şu şekildedir:

OpenPose: Gerçek zamanlı insan eklem algılama için ücretsiz bir kitaplık olan OpenPose, çeşitli kaynaklardan gelen giriş görüntülerini işlemek için kullanılmaktadır.

Pose Detection: Bu kitaplık, TensorFlow.js üzerine kurulu olup hafif cihazlarda verimli bir şekilde çalışır ve farklı modeller aracılığıyla poz tahmini yapabilir.

DensePose: İki boyutlu RGB görüntülerin insan yüzeyine üç boyutlu bir model ile eşleştirilmesini sağlayan ücretsiz ve açık kaynaklı bir kitaplıktır.

AlphaPose: AlphaPose, çok kişili insan poz tahmini için kullanılan yüksek doğruluklu bir açık kaynaklı kitaplıktır.

HRNet (High-Resolution Network): Bu mimari, belirli nesneleri veya kişileri tanımak için yüksek çözünürlüklü temsiller kullanır ve anahtar nokta ısı haritaları tahmin eder.

Bu kitaplıklar, farklı poz tahmini ihtiyaçlarına ve uygulamalara yönelik olarak kullanılabilirler.

1.9. Makine Öğrenmesi Kavramı

Makine öğrenmesi, bir bilgisayarın gelecekte ortaya çıkabilecek benzer olaylar hakkında kararlar verme yeteneğini ve oluşabilecek problemlere çözüm üretme kapasitesini geliştirmek için, bir olayla ilgili edinilen bilgi ve deneyimlere dayalı olarak öğrenme sürecidir. Makine öğrenmesi, geçmiş verileri kullanarak çeşitli yöntemlerle bir model oluşturur ve bu modeli yeni veriler için tahminler yapmak amacıyla kullanır [47].

Çok büyük miktarlardaki verinin manuel olarak işlenmesi ve analiz edilmesi oldukça zorlu bir süreçtir. Makine öğrenmesi, bu verileri kullanarak gelecekteki durumlar için tahminler yapmak için farklı yöntemler kullanır. Uygulama alanı ne olursa olsun, makine öğrenmesi yöntemleri, büyük veri analizi yaparak gelecekle ilgili tahminlerde bulunmak ve karar vermeye yardımcı olmak için giderek daha önemli hale gelmektedir.

Makine Öğrenmesi (Machine Learning), yapay zekanın bir dalıdır ve bilgisayarların öğrenme görevlerini yerine getirebilmeleri için geliştirilen algoritmalar ve tekniklerle ilgilenir. Doğal Dil İşleme, Konuşma ve El Yazısı Tanıma, Nesne Tanıma, Bilgisayar Oyunları, Robot Hareketleri, Arama Motorları ve Tıbbi Teşhis gibi birçok alanda uygulanır [48].

Makine öğrenmesi genellikle üç önemli aşamayı içerir:

Veri Hazırlama: Birinci aşama, öğrenme işlemi için kullanılacak veri kümesinin uygun şekilde hazırlanması aşamasıdır.

Öğrenme Modelinin Seçimi ve Uygulanması: İkinci aşama, uygun öğrenme yöntemi ve algoritmanın seçilerek veri kümesine uygulanması aşamasıdır.

Performans Değerlendirmesi: Üçüncü aşama, uygulanan öğrenme modelinin performansının ölçülmesi ve sonuçların yorumlanması aşamasıdır.

Makine öğrenmesinde, öğrenme işlemi için kullanılacak veri kümesi öncelikle belirli bir düzenleme ve hazırlık sürecinden geçirilmelidir. Öğrenme yöntemlerinde genellikle istatistiksel teknikler kullanılır ve yeni geliştirilen yöntemler de bu temele dayanır. Yeni bir öğrenme yöntemi geliştirildiğinde, bu yöntemin performansı ölçülerek diğer yöntemlerle karşılaştırılması yapılır. Makine öğrenmesi yöntemleri farklı uygulama alanları için analiz edilerek ve farklı beklentilere göre sınıflandırılarak kullanılabilir [49].

Makine öğrenmesi yöntemleri, farklı uygulama alanlarına uygun olarak analiz edilebilir ve çeşitli beklentileri karşılamak üzere sınıflandırılabilir [50].

Makine öğrenmesi yöntemleri, çeşitli işlemleri yerine getirmek için kullanılabilir. Bunlar şunlardır:

- **Sınıflandırma (classification):** Yeni bir verinin sınıfını tahmin etmek için, belirli bir sınıfa ait verilerden yararlanma işlemidir.
- **Kümeleme (clustering):** Önceden bilinmeyen verilerin birbirine benzerliğine göre gruplandırılması işlemidir.
- **Regresyon (regression):** Önceki verilere dayanarak sürekli bir çıktı değeri tahmin etme işlemidir.
- **Özellik seçimi ve çıkarımı:** Verilerin özelliklerinden yola çıkarak, veri kümesinin veya sınıfının belirlenmesinde kullanılan özelliklerin tespit edilme işlemidir.
- **İlişki belirleme:** Sınıflar veya kümeler arasındaki ilişkilerin analiz edilmesi sürecidir.

Makine öğrenmesi teknikleri, denetimli ve denetimsiz öğrenme yöntemleri olmak üzere iki farklı kategoriye ayrılır.

1.9.1 Denetimsiz Öğrenme

Denetimsiz öğrenme, etiketlenmemiş veri kümesindeki veriler arasındaki mevcut ancak açıkça belirtilmeyen ilişkilerin ortaya çıkarılma sürecidir. Bu yöntemde, makine öğrenmesi algoritmaları veri setindeki yapıları kendi başlarına öğrenmeye ve gruplandırma, boyut indirgeme gibi işlemleri gerçekleştirmeye çalışır [51]. Denetimsiz öğrenme, etiketlenmemiş veri kümesindeki veriler arasındaki ilişkileri keşfetmeyi amaçlamasının yanı sıra bu yöntem sadece girdileri kullanarak çıktıları tahmin etmek yerine, veri sıkıştırma, boyut indirgeme, veri kümesi görselleştirme ve benzeri birçok alanda kullanılabilen makine öğrenmesi yöntemidir [52].

Denetimsiz öğrenme, genellikle veri kümesindeki örneklerin çıktılarının bilinmediği durumlarda kullanılır. Bu yöntemde, amaç genellikle tanıma veya sınıflandırma değil, farklı hedeflere yöneliktir. Örnek olarak, kümeleme, olasılık yoğunluk tahmini, öznitelikler arasındaki ilişkilerin bulunması ve boyut indirgeme gibi işlemler gözetimsiz öğrenme yöntemleri arasında yer alır [53].

Denetimsiz öğrenme tekniği, özellikle olasılık teorisine dayanan kümeleme işlemlerinde sıklıkla kullanılmaktadır. Kümeleme, farklı gruplarda benzer özelliklere sahip nesnelerin sınıflandırılması anlamına gelir ve bu yöntem, veri madenciliği, örüntü tanıma, resim analizi gibi alanlarda istatistiksel veri analizini gerçekleştirmek için yaygın bir şekilde kullanılan bir tekniktir. Denetimsiz öğrenme, etiketlenmemiş veriler üzerinde yapılan bu kümeleme işlemleri sayesinde veri kümesindeki yapısal özelliklerin keşfedilmesine ve daha sonra kullanılabilecek anlamlı özelliklerin çıkarılmasına yardımcı olur.

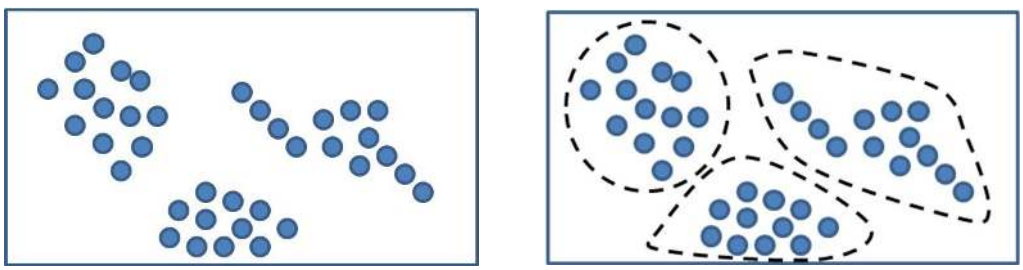

Şekil 1.18. Denetimsiz öğrenme örneği

1.9.2 Denetimli Öğrenme

Denetimli Öğrenme, önceki etiketli verilerden faydalanarak, bu verilerden ve sonuçlarından tümünü ihtiva eden özel bir fonksiyon elde etmeyi amaçlayan makine öğrenmesi yöntemidir. Bu yöntem, eğitim verileri temelinde bir fonksiyon üreten bir tekniktir. Algoritma, girdiler (etiketli olmayan veriler) ile çıktılar (etiketli olan veriler) arasında olası en iyi eşleşmeyi sağlayan fonksiyon elde etmek için çalışır. Eğitim verileri, giriş nesnelerini ve buna karşılık gelen sonuçları içerir. Denetimli öğrenme, özellikle sınıflandırma ve regresyon gibi problemlerde yaygın olarak kullanılan bir öğrenme tekniğidir.

Denetimli öğrenme teknolojisinde, veri setindeki her bir örneğin giriş ve çıkışları sisteme verilerek öğrenme sağlanır. Örneğin, bir sınıflandırma çalışmasında metnin içeriği giriş verisi olarak kullanılırken, metnin ait olduğu kategori çıkış olarak belirlenir. Sonrasında doğrulama aşaması için test veri seti kullanılır. Doğrulama aşamasında, öğrenme algoritması test veri setindeki kategori bilgilerini önceden bilmediğinden, eğitim verisi üzerinden öğrendiği bilgileri kullanarak doğru bir tahmin yapmaya çalışır [54].

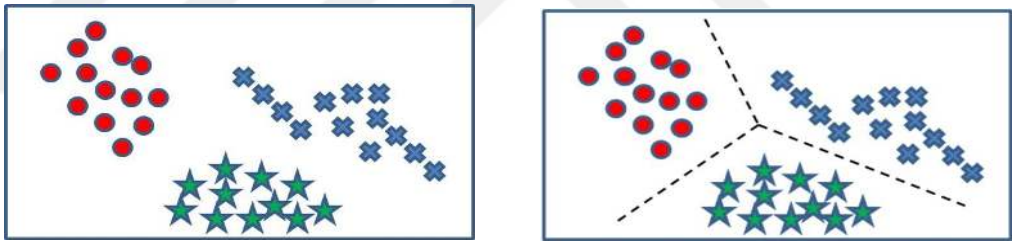

Şekil 1.19. Denetimli öğrenme

1.10. Sınıflandırma

Sınıflandırma, farklı bilgi parçalarını sınıflandırma işlemidir ve örüntü tanıma gibi alanlarda kullanılmaktadır. İnsan beyni yüz tanıma, ses tanıma gibi günlük hayatta sınıflandırma yapar. Veri toplama ve sınıflandırma işlemleriyle elde edilen veriler, kullanım amacına göre farklı kategorilere ayrılarak modelleme yapılır ve sistemler tanımlanır. Bu sistemler daha sonra, konuşma tanıma, parmak izi tanıma, DNA dizilimlerini doğrulama gibi çeşitli uygulamalarda kullanılabilirler [55].

Sınıflandırma problemi, farklı sınıflara ait nesnelerin başlangıçta verildiği ve daha sonra hangi sınıfa ait olduğu bilinmeyen yeni bir nesnenin hangi sınıfa ait olduğunun belirlenmesi problemidir. Veri Madenciliği (data mining) ise, veri setleri üzerinde yapılan analizlerle, içerisinden işe yarayan bilginin çıkarılması sürecidir. Doğal

dil işlemede sıkça kullanılan makine öğrenmesi yöntemleri arasında sınıflandırma önemli bir yer tutar ve metin sınıflandırma da bu alanda yaygın olarak kullanılır [56].

Sınıflandırma, makine öğrenmesinin gözetimli öğrenme yöntemlerinden biridir. Bu yöntem veriyi, benzerlik veya uzaklık ölçütlerine göre kategorilere ayırmayı içerir.

1.10.1 Makine Öğrenmesi Kavramları

Makine öğrenmesi konusunda şu terimler önemlidir:

Eğitim Kümesi (Örnekleme Kümesi)(Training Set): Bilinen girdiler ve bu girdilere ait çıktılar kümesidir. Yeni bir örneğin sınıfın elde edilen bu u küme aracılığıyla, yeni bir örneğin sınıfı olarak belirlenir.

Gürültü (Noise): Makine öğrenmesi algoritmalarının amacı, gereksiz ve anlamsız bilgiyi azaltarak, gürültülü veriyi en aza indirgemek ve doğru sınıfları belirlemeye çalışmaktır. Bu nedenle konuyu ihtiva etmeyen ve konu içinde olan anlamsız olan bilgi türü gürültüdü olarak adlandırılır. Eğitim kümesinde gürültülü veri bulunması, yeni verilerin tahminini zorlaştırabilir.

Çapraz Doğrulama (Cross Validation): Eğitim verisini alt kümelerine ayırarak bir kısmını eğitim amacıyla kullanırken diğer kısmını doğrulama işlemi için kullanma yöntemidir. Tüm alt kümeler için tekrarlanarak elde edilen bu işlem, çapraz doğrulama olarak adlandırılır.

Çapraz doğrulama, veri kümesinin eşit parçalara ayrılmasıyla gerçekleştirilir. Bu parçalardan ilki test kümesi olarak belirlenirken, geri kalanlar eğitim kümesi olarak ataması yapılır ve sınıflandırma işlemi bu şekilde gerçekleştirilir. Daha sonra, bir sonraki parça test kümesi olarak seçilirken, diğerleri eğitim kümesi olarak kullanılır. Bu işlem, tüm parçalar için aynı şekilde tekrarlanır. Sistemin genel performansı, tüm sınıflandırmaların sonuçlarının ortalaması alınarak hesaplanır. Literatürde en yaygın kullanılan 'n' değeri genellikle 10 değeri olarak alınmaktadır [57].

N değerinin 10 seçilmesi durumunda verinin çapraz doğrulama yöntemi için 10 eşit parçaya bölüneceği anlamına gelmektedir. Her bir adımda, veri kümesinin 9/10'u eğitim kümesi olarak kullanılırken, kalan 1/10'luk bölüm test kümesi olarak kullanılmaktadır. Her adımda, farklı bir parça test kümesi olarak seçilir ve geri kalan parçalar eğitim kümesi olarak kullanılır. Toplamda 10 kere çapraz doğrulama işlemi gerçekleştirilir. Bu işlemin genel yapısı aşağıdaki şekildedir [58].

	1. Parça	2. Parça	3. Parça	4. Parça	5. Parça	6. Parça	7. Parça	8. Parça	9. Parça	10. Parça
1. Adım	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim
2. Adım	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim
3. Adım	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim
4. Adım	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim
5. Adım	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim
6. Adım	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim
7. Adım	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim
8. Adım	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim
9. Adım	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim
10. Adım	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test

Şekil 1.20. 10-N çapraz doğrulama işlem adımları

Veri kümesindeki tüm örneklerin eğitim ve test kümesi olarak kullanılması, 10 kere çapraz doğrulama ile sağlanan önemli bir avantajdır.

1.11. Boyut İndirgeme

Boyut indirgeme, makine öğrenmesinde birden fazla boyutlu uzayın daha düşük boyutlu bir forma dönüştürülmesi işlemidir. Bu işlem, veriyi tanımlayan özellik alt kümelerinin seçilmesi yoluyla gerçekleştirilir. Doküman kümesi gibi ayırt edici özelliklere sahip olmayan özellikler belirlenerek çıkarılır ve böylece boyut azaltma işlemi gerçekleştirilmiş olur. Boyut indirgeme, makine öğrenmesinde önemli bir adımdır ve başarıyı etkiler. Boyut indirgeme, daha az boyutlu uzaylarda daha kesin sonuçlar elde edilerek sürecin doğruluğunu artırır. Bu konu kapsamında, öznitelik seçimi ile öznitelik çıkarımı esas olmak üzere iki tür farklı yaklaşım vardır [59].

Öznitelik seçimi, büyük boyutlu uzay problemini çözmek için sistemin eğitim evresinden evvel, mevcut öznitelikler arasından verinin daha iyi tanımlanması için bir öznitelik alt kümesinin seçilmesi işlemidir [60]. Boyut azaltma işlemi, yüksek boyutlu uzayları daha az boyutlu bir uzayla ifade etme işlemidir. Bu işlem, öznitelik seçme veya öznitelik çıkarma yöntemleriyle gerçekleştirilir. Boyut azaltmanın faydaları arasında veriyi görselleştirme ve anlama kolaylığı, boyutlandırma ve verinin uygun bir şekilde depolamanması gereksinimlerinde azalma, eğitim ve test sürelerinde kısalma ve performans artışı sağlama gibi etkiler sayılabilir [61].

Öznitelik çıkarma yaklaşımında ise, özniteliklerin önem sırasına göre seçilerek daha aktif ve düşük boyutlu bir özniteliğe bağlı alt kümesi oluşturulur [62]. Öznitelik

seçme ve öznitelik çıkarma yaklaşımları, veri kümesindeki bilgiyle alakasız ve kargaşa olarak adlandırılan özniteliklerin elenmesi ile bu uzayın boyutunun düşürülmesini sağlayarak performans ve zaman kazancı bakımından sınıflandırma aşamalarında olumlu etki yaratır [63].

Literatürde Ki-Kare (CS: Chi-Square), Karşılıklı Bilgi (MI: Mutual Information), Bilgi Kazanımı (IG: Information Gain) ve Doküman Frekansı (DF: Document Frequency) gibi birçok öznitelik seçme yöntemi bulunmakta olup, bu yöntemler sıklıkla tercih edilenler arasında yer almaktadır [64].

1.12. Performans Değerleme

Genellikle makine öğrenmesi performansnın değerleme işlemi karmaşıklık matrisi (confusion matrix) olarak adlandırılan bir yöntemle hesaplanmaktadır. Bahsi geçen matris, gerçek sınıf ile tahmin edilen sınıf arasındaki farklılıkları gösterir. Matrisin satırları gerçek sınıfları, sütunları ise tahmin edilen sınıfları temsil eder. Dört farklı değer elde edilir: doğru pozitif (True Positive, TP), doğru negatif (True Negative, TN), yanlış pozitif (False Positive, FP) ve yanlış negatif (False Negative, FN). Gerçekte pozitif sınıfa ait olan ancak sınıflandırma sonucunda pozitif sınıfta yer alan bir örneğe doğru pozitif denir. Gerçekte negatif sınıfa ait olan ancak sınıflandırma sonucunda negatif sınıfta yer alan bir örneğe doğru negatif denir. Gerçekte negatif sınıfa ait olan ancak sınıflandırma sonucunda pozitif sınıfta yer alan bir örneğe yanlış pozitif denir. Gerçekte pozitif sınıfa ait olan ancak sınıflandırma sonucunda negatif sınıfta yer alan bir örneğe ise yanlış negatif denir. Aşağıdaki Çizelge 1.1'de tüm durumlar gösterilmektedir.

Çizelge 1.1. Karmaşıklık matrisi durumları

		Gerçek Değerler	
		Pozitif (1)	Negatif (0)
Negatif Değerler	Pozitif (1)	True Positif	False Positif
	Negatif (0)	False Negatif	True Negatif

Doküman sınıflandırmada, karşılaştırma yöntemleri genellikle kesinlik (precision) ve hatırlatma (recall) ölçüleri ile belirlenir. Kesinlik, doğru olarak sınıflandırılan belgelerin sınıftaki toplam belge sayısına oranını; hatırlatma ise doğru olarak sınıflandırılan belgelerin sistem tarafından belirlenen toplam belge sayısına oranını ifade eder. Ancak, kesinlik ve hatırlatma ölçüleri yalnız başlarına karşılaştırma sonucu olarak anlamlı bir yeterliliğe sahip değildir. Bu nedenle, tümünü bir arada analiz etmek için F-ölçüsü değeri hesaplanır. F-ölçüsü, kesinlik ve hatırlatma değerlerinin harmonik ortalamasını ifade eder ve her ikisinin de iyi olması için dengelenmiş bir yaklaşım sağlar [65]. Tüm bu değerlere ait formüller aşağıda sunulmaktadır.

$$Kesinlik = \frac{\text{Doğru sınıflandırılmış pozitif örnek sayısı}}{\text{Pozitif sınıflandırılmış örneklerin sayısı}} = \frac{\text{DP}}{\text{DP+YP}} \tag{1.1}$$

$$Anma = \frac{\text{Doğru sınıflandırılmış pozitif örnek sayısı}}{\text{Pozitif örnek sayısı}} = \frac{\text{DP}}{\text{DP+YN}} \tag{1.2}$$

$$F - \text{Ölçüsü} = \frac{\text{2 x Kesinlik x Anma}}{\text{Kesinlik + Anma}} \tag{1.3}$$

1.13. Bazı Önemli Makine Öğrenmesi Algoritmaları

Elde edilen sonuçların iyileştirilmesi için kullanılan yöntemlerden biri, makine öğrenmesi algoritmalarıdır. Bu algoritmalar, çok çeşitli alanlarda kullanılmaktadır ve birçok farklı teknik içermektedirler. Bu konu ile ilgili olarak belli başlı önemli makine öğrenmesi algoritmaları hakkında detaylı bilgiler alt başlıkta detaylı bir şekilde anlatılmıştır.

1.13.1. K-Means (K-Ortalama) Algoritması

K-means algoritması, veri kümesinde bulunan n adet verinin k adet veri kümesine bölünmesini sağlayan bir algoritmadır. Kümeleme neticesinde, benzerliklerin küme içindeki nesneler arasında artması, öteki kümelerde bulunan nesneler ile arasındaki benzerlik oranlarının ise azalması hedeflenmektedir [66].

K-ortalama algoritması, iki temel bileşenden oluşur. İlk bileşen, k merkez değerlerinin rastgele seçilmesi ve girdi olarak sunulmasıdır. İkinci bileşen olarak verilen bilgi kümesi içerisindeki her nesnenin, ona daha bitişik merkez noktasına ait kümesinin içerisine aktarılmasıdır [67]. Bu şekilde kümelerin oluşturulması ve nesnelerin bu kümeler içinde toplanması sağlanır. Kümeleme sonucunda, kümeler arasındaki

benzerliklerin maksimize edilmesi ve aynı kümedeki nesneler arasındaki benzerliklerin ise minimize edilmesi amaçlanır.

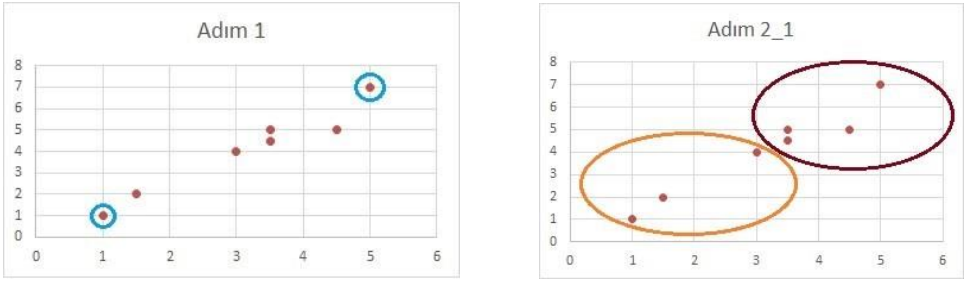

Şekil 1.21. K-Means algoritması durum aşaması örneği

K-Means algoritması öncelikle rastgele k adet merkez değeri seçerek başlamaktadır. Daha sonra, her bir nesne kendisine en yakın merkeze atanarak ilgili kümeye dahil edilmektedir. Her kümeye dahil olan nesneler arasındaki benzerliklerin en yüksek, farklı kümeler arasındaki benzerliklerin en düşük olması hedeflenmektedir. Sonrasında, tüm kümenin her bir öğesinin ortalama değeri hesaplanıp yeni küme merkezleri bu şekilde belirlenmektedir. Bu işlem, kümelerin değişmediği veya belirli bir kriteri karşılayana kadar tekrarlanmaktadır. Nesnelerin hangi merkeze daha yakın olduğu hesaplanarak hangi kümede olacakları belirlenmektedir. Nesne ile merkez arasındaki uzaklık değeri en düşük olan merkezin kümesine dahil edilmektedir [68].

1.13.2. K – Nearest Neighbor (K-En Yakın Komşu) Algoritması

Bu algoritma, veri içerisindeki bir nesnenin sınıfını ortaya çıkarmak için evvelden bilindik sınıfları olan ve eğitim kümesi olarak bilinen küme içerisindeki k adet örneği baz alarak hesaplama yapmaktadır. Belirsiz sınıflı bir nesne, Öteki tüm sınıflarda bulunan nesnelerle karşılaştırılır ve en yakın k örnek verisi seçimi yapılır. Seçilen örneklerin daha genel olarak hangi sınıfa ait olduğuna bakılır ve sınıfı belirlenmek istenen nesne de o sınıfa atanır. Nesnelerin birbirleri arasındaki mesafe genellikle Öklid uzaklık formülü ya da Kosinüs benzerlik formülü ile hesaplaması yapılır. Bu algoritma uygulanırken öncelikle k değeri belirlenir. Elde edilen k'nın değeri, sınıfı daha ortaya çıkarılmayan yeni bir örneğe daha bitişik olan k komşuluk değerine bakılarak sınıfının ortaya çıkarılmasına çalışıldığını ifade eder [69].

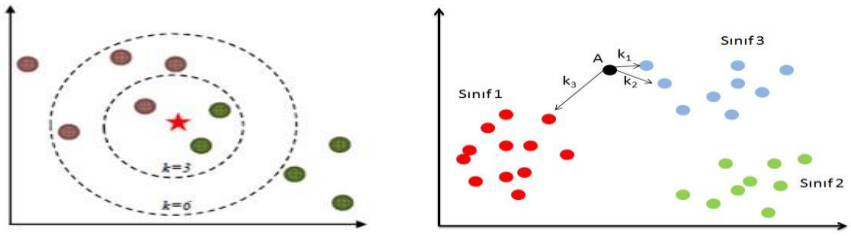

Şekil 1.22. K-En yakın komşu sınıflandırması modeli

1.13.3. Decision Trees: DTs (Karar Ağaçları)

Bu algoritma, ağacın kökleri şeklinde verileri gösteren bir sınıflandırma yöntemi olarak kullanılmaktadır. Bu yapı düğümler, dallar ve yapraklar şeklinde oluşmaktadır. Düğümler, soruları içerirken, dallar ise bu soru içeriğine verebileceği cevapları, bu işlemlerden sonra yapraklar ise mevcut sınıflandırma değerini ortaya koymaktadır [70].

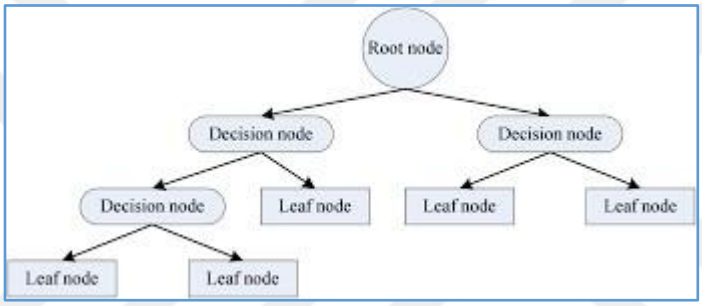

Şekil 1.23. Bir Karar Ağacı modeli

Bu algoritma, sınıflandırma işlemi için kök düğümden başlayıp yaprak düğümlere doğru hareket ederek sınıflandırma işlemi için verileri ağaç yapısı şeklinde göstermeye çalışır. Bu şekilde sınıflandırma, verinin bilgiye dönüşmesi için tümevarımsal bir yaklaşım sergiler. Verinin özelliklerine göre yapılan arama işlemi, örneklerin en optimum bir biçimde ayrılarak yeni özelliklerin ortaya çıkarılması çabasıdır. En optimum sınıflandırma yapıldığı esnasında işlem bekleme aşamasına geçer. Şayet sınıflandırma uygun bir şekilde yapılmadığında, bir özelliğe ait olası değerlerin sayısı kadar bölümlere ayrılmış alt kümeler üzerinde tekrarlı olarak işlemlerini sürdürür. Ancak, önceki seçimleri yeniden ele almadığı için hatalı sınıflandırma durumları ortaya çıkabilmektedir. Bu algoritmanın ana işlevi, ağaç yapısındaki her düğüm teste tabi tutularak özellik çıkarımı yapılmaktadır.

1.13.4 Naive Bayes Sınıflandırıcı

Bu algoritma, metinleri sınıflandırmak için sık bir şekilde kullanılan ve öteki sınıflandırıcılara göre daha keskin sonuçlar üreten bir yöntem olarak uygulanmaktadır.

Algoritma, doküman sınıfını ortaya çıkarmak için kelimeler ile sınıfların tümleşik ihtimallerini kullanmaktadır. Bu yöntem, sınıf belirlemek için koşullu olasılıklarını ortaya koymak için sözcükler ve sınıfları kullanır. Bir sınıflandırıcı, verilen sorulara cevaplar türetebilmek adına Bayes ağ yapısını kullanmaktadır. Bu ağ yapısından faydalanabilmek için bazı olasılık modellerine ihtiyaç duyulur. Bayes teoreminin genel formülü şu şekildedir:

$$P(A|B) = \frac{P\,(B\,|A\,)\;x\,P(A)}{P(B)} \tag{1.4}$$

P(A) ve **P(B) :** A ve B olaylarının olasılıkları,

P(A|B) : B olayı ortaya çıkması esnasında A olayının gerçekleşmesi olasılığı, **P(B|A) :** A olayının ortaya çıkması esnasında B olayının gerçekleşmesi olasılığıdır.
Bu yöntem, dokümanları sınıflandırmak için genellikle çok kullanılan bir yöntemdir. Bu yöntemde, öncelikle dokümanlar ve sınıflar belirlenir. Ardından, veriler üzerinden kelimelerin dokümanlardaki olasılıkları hesaplanarak dokümanın sınıfı tahmin edilir. Bu süreçte, belirlenecek dokümanın sınıfı, D={d1,d2,….dn} şeklindeki sınıfı bilinmeyen dokümanlar ve C1,C2,….Cm şeklindeki sınıflar olarak temsil edilir. Sınıf belirleme işlemi için kullanılan olasılık denklemi aşağıdaki gibidir:

$$P(Ci|D) = \frac{P\,(D\,|Ci\,)\;x\,P(Ci)}{P(D)} \tag{1.5}$$

Karar ağacının avantajları arasında, öğretim ve ölçeklendirme işlemlerinin oldukça hızlı olması ve normal yaşamdaki problemlere çok iyi derecede çıktılar vermesidir. Ancak dezavantajları arasında, çok karmaşık sınıflama problemlerinde yetersiz kalabilmesi bulunmaktadır.

1.13.5. Yapay Sinir Ağları

Bu ağ, Frank Rosenblatt tarafından ilkin 1950'lerde basit nöron yapısına bağlı bir model önermesi ile ortaya çıkan çalışmalarda kendini göstermiştir. Sonrasında ise tek katmanlı ilk Yapay Sinir Ağı modeline perceptronlar da eklenmiştir. Yapay sinir ağları, insan beyninin sinir sistemi yapısına benzer bir yöntem kullanılmıştır. İnsan beyni gibi öğrenme kavramıyla güncel ve yeni bilgiler elde etme, araştırma yapma, var olan verilerle meydana gelen olaylar hakkında analiz yapma, karşılaştırma, ilişki kurma gibi özellikleri ortaya çıkarabilmesi için hazırlanmıştır. Yapay sinir ağları, sinir hücrelerinin

katmanlar şeklinde birbirleri ile çeşitli şekillerde birleştirilmesi ile oluşur. Donanımsal bir şekilde elektronik devrelerle tasarımları gerçekleştirilir. Yapay sinir ağları, öğrenme süreci esnasında bilgi elde edip hücreler arasındaki bağlantı ağırlıkları ile bu bilgiyi depolayabilmektedir. Ayrıca, öğrenme süreci boyunca amacına ulaşabilmek için bu ağ yapısı ağırlıklarının güncellenmesi işlemini sürekli olarak yapmaktadırlar [71].

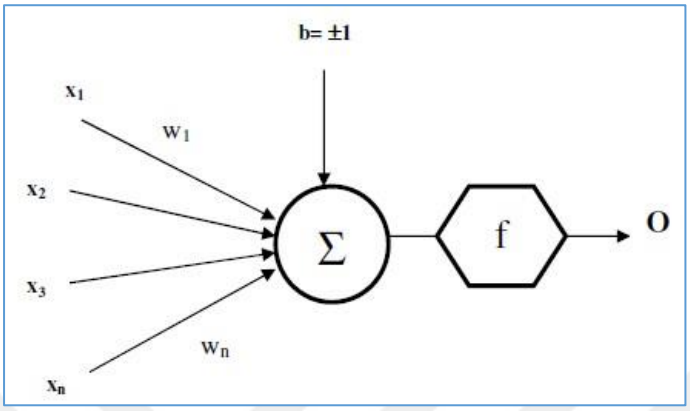

Şekil 1.24. Basit Yapay sinir ağı hücresi

Yapay sinir ağları (YSA) Frank Rosenblatt tarafından 1950'lerde yapılan ilk çalışmalarla basit bir nöron modeli iken daha sonraları, tek katmanlı yapay sinir ağı modeli olan Perceptrona dönüştürülmüştür. Yapay sinir ağları, insan beyninin öğrenme, araştırma, kararlaştırma, bağlantı oluşturma gibi özellikleri modellenmek amacıyla tasarlanmıştır. Bu ağ, yapay sinir hücrelerinin birbirleriyle farklı biçimlerde bir araya gelmeleri vasıtasıyla oluşur ve özellikle katmanlar şeklinde düzenlenmektedir. Elektronik devreler şeklinde de tasarımları yapılabilmektedir. Bir öğrenme evresinde bilgi toplayıp hücreler arasındaki ilişkili ağırlıkları güncelleyerek bilgiyi depolama kabiliyetlerine sahiptir. Ayrıca, istenilen hedefe varmak için yapay sinir ağı ağırlıklarının güncellenmesini yapan algoritmalar üretebilmektedir. Bu ağ, belirli bir amaç dahilinde var olan örnekler aracılığıyla öğrenme işlevini yerine getirir. Yapay sinir ağları, Tek Katmanlı (Perceptron) ve Çok Katmanlı olmak üzere iki çeşidi vardır. Çok Katmanlı Algılayıcı Modeli, girdi katmanı, bir veya daha fazla gizli katmanı ile bir çıktı katmanından oluşmaktadır [72].

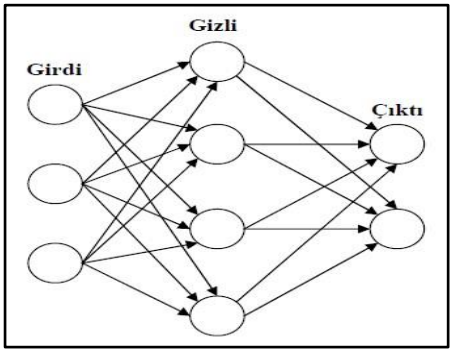

Şekil 1.25. Çok katmanlı yapay sinir ağı modeli

Çok katmanlı ağ modelinde, girdi katmanı dışarıdan gönderilen bilgileri ağa gönderir. Gizli katmanları, girdi katmanından gelen bilgileri işleyip çıktı katmanına aktarır. Ağda çok sayıda gizli katman verilebileceğinden çıktı katmanı, gizli katmandan alınan verileri ele alarak girdi katmanı için elde etmesi gereken çıktıyı yaratır ve ortaya çıkan çıktıları gerçek dünyaya aktarım işlemini yapar [73].

1.13.6. Support Vector Machine: SVM (Destek Vektör Makinesi)

Bu model, optimizasyona bağlı yerinde bir karar fonksiyonu ile sınıfları birbirinden ayıracak düzlem ortaya koyan bir sınıflandırma türüdür. Veri kümesinin hiper düzlemini en iyi şekilde iki sınıf şeklinde belirleme amacını gütmektedir. Bu amaç sayesinde, öncelikle doğrusal olarak veri kümesinin ayrılıp ayrılamadığına karar vererek, uygun sınıflandırma işlemi yapmaktadır.

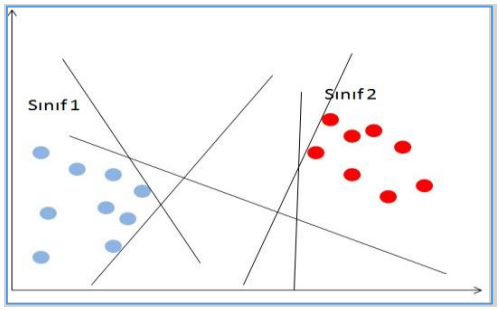

Şekil 1.26. Support vector machine sınıflandırma işlemi

Bu algoritmanın yöntemi, devasa boyutlu verilerin sınıflandırılmasıdır. Küçük boyuttaki ve doğrusal olarak ayrılamayan veri kümelerini daha yüksek boyutlara ulaştırarak, ayırma işlemini bir düzlem yardımıyla gerçekleştirir. Bu yöntemin çalışma mantığını anlamak için, öncelikle doğrusal yapının nasıl yapıldığına bakılmalıdır. [74]

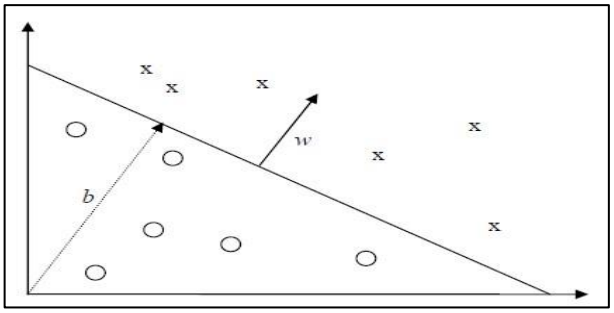

Şekil 1.27. Doğrusal support vector machine sınıflandırma şekli

Fisher Lineer Diskriminantı (Fisher Linear Discriminant) formülü yukarıda bahsi geçen iki farklı veri grubunu birbirinden doğrusal olarak ayırmaktadır.

$$f(x) = \sum_{n=1}^{n} w_i x_i + b \quad (1.6)$$

Parçalama fonksiyonu için kullanılan formüldeki x verisi girdi verisi, b verisi eşik değeri ya da orjine olan uzaklığa atıf yaparken, w değeri ise veri eğitimi aşamasında oluşan ağırlık matrisi ya da vektörünü ifade etmektedir. X vektörünün sınıfı şayet f(x) ≥ 0 ise pozitif olarak değerlendirilir, öte taraftan negatif olarak ele alınır.

Bu yöntem, yaygın olarak büyük boyutlu verileri sınıflandırmanın yanı sıra düşük boyutlu verileri de daha üst bir konuma taşıyarak doğrusal olarak ayrılamayan verileri bir düzlem aracılığıyla ayırma işlemini yapar. Verinin gürültü içerip içermemesine bağlı olarak maksimal marjin ve esnek marjin olmak üzere iki yaygın yöntemi vardır.

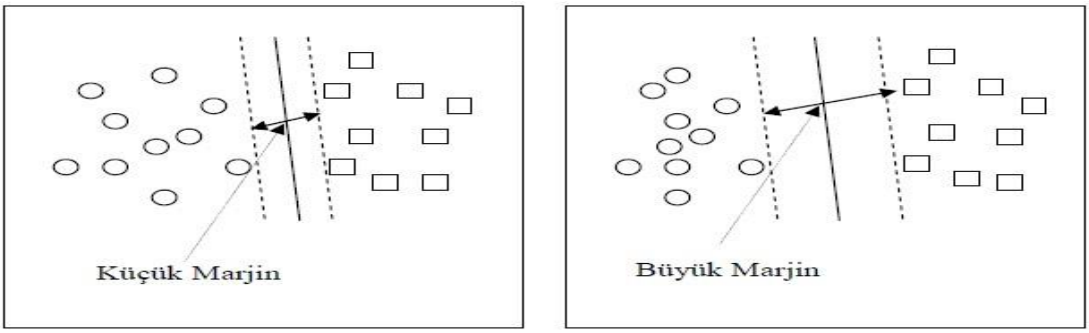

Şekil 1.28. Maksimal marjin ile esnek marjin örneği

1.14. Spor Biyomekaniği Açısından Hareket Analizinin Önemi

Hareket analizi, insan hareketini objektif olarak analiz edebilmek amacıyla bazı teknikler kullanmaktadır. Bu teknikler sayesinde elde edilen objektif ölçümler, kişinin gelişimini ya da sporcudaki ilerlemeyi takip etmek açısından önemlidir. Gözlemsel

analizler çok subjektif olduğundan, verilerin kesinliğini arttırmak için iyi bir ölçüm aracı kriterlerini sağlamış ekipmanlar gereklidir. Günümüzde bilgisayarların hızı, hafıza kapasitesi ve gelişmiş yazılımlar, hareket analizinde veri toplama, hesaplama, analiz etme ve raporlama işlemlerini oldukça verimli kılmıştır. Teknolojideki gelişmeler, çeşitli veri toplama araçlarının senkronizasyonunu da mümkün kılmaktadır [75].

1.15. Günümüz Hareket Analiz Yazılım ve Türleri

İnsana özgü hareketlerin incelenmesi konusuna çok eski dönemlerden itibaren ilgi duyulmuştur ve bu alanda birçok araştırma yapılmıştır. 1830'larda Weber kardeşlerin öncülüğünde, insan hareketlerinin modern anlamda incelenmesi başlamıştır. İlk yürüyüş analiz çalışmalarında Weber kardeşler, modern yöntemleri kullanarak önemli bir rol oynamışlardır [76]. Çoğu günümüzde yürütülen araştırma, Winter'ın çalışmalarının etkisi altında devam etmektedir [77].

Biyomekanik çalışmalarının öncüleri arasında yer alan Braune ve Fischer, insan ve sporcu hareketlerinin incelenmesi için yüksek hızda kayıt yapabilen sistemlerin kullanılmasını önermişlerdir. Teknolojideki gelişmeler paralelinde, elektronik ve bilgisayar sistemlerinin ilerlemesi, sporcu hareketlerinin analizinde yeni yöntemlerin gelişmesine olanak tanımıştır [78].

İnsan hareketi 3 boyutlu bir uzayda gerçekleşir ve hareket analizi için gerekli olan 3B uzaysal konum bilgisini elde etmek için en az eşzamanlı 2 farklı görüntüye ihtiyaç vardır. Abdel-Aziz ve Karara, doğrudan doğrusal dönüşüm (DDD) yöntemini geliştirerek bu ihtiyacı karşılamıştır. DDD yönteminde, hareket alanı ve 2 boyutlu görüntü yüzeyi arasında doğrusal dönüşümde 11 parametre kullanılır ve bu parametrelerin hesaplanması için bir kalibrasyon işlemi uygulanır. Kontrol bölgesi içerisinde hassas olarak yerleştirilen kontrol noktaları kullanılarak kalibrasyon gerçekleştirilir. DDD yöntemi birçok çalışmada başarılı sonuçlar vermiştir ancak kontrol alanının dışına çıkıldığında doğruluk azalabilir [79].

Biyomekanik, sporcu sağlığı ve sportif çalışmalara yönelik birçok yazılım ve ticari hareket analizi sistemi bulunmaktadır. TASS (TNO Automotive Safety Solitiouns), LifeMOD, The AnyBody Modelling System, OpenSim ve CATIA gibi örnekler, ergonomik tasarım ve analiz modülü olarak kullanılan bazı sistemlerdir. APAS (Ariel Dynamics, Inc.), CODA (Charnwood Dynamics Ltd.), ELITE (Bioengineering Technology and Systems), OPTOTRACK (Northern Digital, Inc.), PEAK (Peak

Performance Technologies, Inc.), QUALISYS (Qualisys Medical AB) ve VICON (Vicon Motion Systems Ltd.) tarafından geliştirilen sistemler ise hareket analizi alanında en yaygın bilinenler arasındadır [80].

SimMechanics, Simulink ve MATLAB (The MathWorks) araçlarının birleşimiyle karmaşık olmayan sporcu hareketlerinin incelendiği bir yazılımdır. Aslında mekanik sistemler için geliştirilmiş olsa da SimMechanics, insan hareketinin incelendiği uygulamalarda da başarıyla kullanılmaktadır.

Hacettepe Üniversitesi biyomekanik araştırma grubu tarafından tasarlanan HUBAG, akademisyenler, mühendisler ve hekimler için tasarlanmış bir Üç Boyutlu Hareket Analizi Yazılımıdır. MATLAB ortamında çalışan yazılım, kas-iskelet sistemlerini analiz etmek isteyen kullanıcılar için tasarlanmıştır. HUBAG ile sporcuların hareketlerinin incelenmesi ve sporcu tekniğinin geliştirilmesi amaçlanmaktadır [81].

1.16. Spor Biyomekaniği Açısından Bilgisayarlı Görü

Spor biyomekaniği, sporcuların ve hareket eden nesnelerin en karmaşık hareketlerini ince detaylarına kadar irdeleyen bir bilim dalıdır [82]. Biyomekanik, insana özgü hareketlerin mekanik yönlerini araştıran bir bilim dalıdır. Bu alanda, sporcuların özelliklerine özgü hareketler incelenir ve hareket sırasında vücutta meydana gelen değişimler ölçülür [83].

Ayrıca spor biyomekaniği, insan hareketinin incelenmesinde birçok farklı bilim dalının ortak alanı içerisinde bulunmaktadır. Spor bilimleri, fizyoterapi, rehabilitasyon, ortopedi gibi alanlarda kullanılan spor biyomekaniği, farklı amaçlar için uygulanmaktadır [84]. Spor biyomekaniğinin önemli amaçlarından biri, sporcuların sakatlanmalarını önlemek ve rehabilitasyonlarını sağlamaktır. Bunun da ötesinde, sportif performansın geliştirilmesi ve optimize edilmesi de spor biyomekaniğinin ilgi alanına girmektedir [85].

Egzersizler sırasında gerçekleştirilen hareketlerin tanımlanması ve analizi için kullanılan terimler ve yöntemler, hareket analizinde önemli bir yer tuttuğundan günümüz teknolojileri ile bu işlemleri daha etkin ve verimli kullanabilmek adına bilgisayarlı görü ile yapmak mümkün hale gelmiştir. Spor biyomekaniği alanına bilgisayarlı görü kavramı dahil edildiğinde en karmaşık hareketlerin bile inceleneceği ve hareketler esnasında fizyolojik değişimlerin de ölçülebileceği açıkça ortaya çıkmıştır. Tüm bu nedenlerle bilgisayarlı görü kavramının spor biyomekaniği açısından tarihçesinin, kullanım alanlarının bir de insan poz tahmini açısından öneminin bilinmesi gerekmektedir.

1.16.1. Bilgisayarlı Görünün Kısa Tarihçesi

1966 yılında Seymour Papert, Marvin Minsky ve ekibi tarafından "yaz görüşü" projesi başlatıldı. Bu projenin amacı, bir bilgisayar programının nesneleri tanımasıydı. Ancak bu tanıma işlemi manuel olarak gerçekleştiriliyordu. Her nesne için ayrı kurallar yazılıyor ve makinenin nesnenin doğru bir şekilde tanınmasını sağlaması bekleniyordu. Farklı açılardan ve ışık koşullarında görüntülenen nesneler dikkate alındığında, tüm nesneler için manuel kurallar yazmak zor oluyordu ve bu proje olumlu bir sonuçla tamamlanmadı.

1979'da Kunihiko Fukushima tarafından geliştirilen çok katmanlı "neocognitron" adlı yapay sinir ağı, nesnelerin tanınmasını kolaylaştırma potansiyeline sahipti. Bu ağ, nesneleri öğrenebilme yeteneğine sahipti, ancak model yeterince iyi sonuçlar üretmedi. Bununla birlikte, bu, bilgisayarlı görü alanında önemli bir ilerleme olarak kabul edildi.

Yann LeCun, 1980'lerde geri yayılımlı evrişimli sinir ağlarını (CNN) tanıtarak büyük bir ilerleme kaydetti. CNN'ler, dijital görsellerden bilgi elde etmek için kullanılıyordu. Yann LeCun ve ekibinin 1990'larda yayınladığı "LeNet-5" ise ilk başarılı sonuçlar veren bir evrişimli sinir ağı modeliydi. Bu basit model, el yazısı, çekler ve posta numaralarını okuma konusunda olumlu sonuçlar elde etti.

2012 yılında ImageNet yarışmasının galibi olan "AlexNet", evrişimli sinir ağlarına olan ilgiyi yeniden alevlendirdi. Evrişim ve havuzlama katmanlarının ardışık yapısı, LeNet modeline benzerken daha derin ve daha büyük bir yapıdadır. AlexNet, sınıflandırma hatasını %26'dan %15'e düşürerek etkileyici bir yenilik oldu. Bu olay son derece heyecan verici ve başarılı bir gelişme olmuştu ve birçok şirket, AlexNet'in bu başarısının ardından yapay sinir ağlarını hizmet sunumlarında kullanmaya başladı. Günümüzde bile, bu ağlar kesinlikle bilgisayarlı görü uygulamalarında en yaygın olarak kullanılanlar arasında yer almaktadır [86].

1.16.2. Bilgisayarlı Görünün Kullanım Alanları

Bilgisayarlı görü, günlük hayatta kullanılan birçok teknolojinin içinde bulunmaktadır. Örneğin, Google Görseller'de kedi resmi aratıldığında, bu ağlar çalışarak mevcut tüm görseller içinden kedi olan görselleri belirleyip çıktı olarak vermektedir. Benzer şekilde, otomatik metin düzelticiler sayesinde yazılan yazı okunup anlaşılarak, daha doğru bir yazı sunulabilir. Bu örneklerin yanı sıra, otonom araçlardan yüz tanıyarak açılan telefonlara kadar pek çok alanda bilgisayarlı görü kullanılmaktadır.

Bilgisayarlı görünün en kritik kullanım alanlarından biri, medikal alandır. Bilgisayarlı görü, MR ve röntgen sonuçlarını tarayarak kanserli hücreleri tespit edebilir. Ayrıca, göz rahatsızlıkları ve damar rahatsızlıkları gibi hastalıkların erken teşhisinde de yardımcı olabilir. Kan kayıplarının veya kanamaların tespitinde de bilgisayarlı görü doğru sonuçlar vermektedir. Bu yöntem, özellikle cerrahi operasyonlar sırasında sıkça kullanılmaktadır.

Bilgisayarlı görünün en popüler ve heyecan verici kullanım alanı, otonom araçlar üzerinde yapılan çalışmalardır. Bu çalışmalar, trafik kazalarının birçoğunun yorgun veya dikkatsiz sürücülerden kaynaklandığı gerçeğinden yola çıkarak, aracın kendi kendine gitmesi üzerine odaklanmaktadır.

Bilgisayarlı görü ayrıca güvenlik sektöründe de yaygın bir şekilde kullanılmaktadır. Telefonlardaki yüz tanıma özelliği, kapılardaki retina tarayıcılar ve otomatik plaka tanıma sistemleri gibi pek çok güvenlik önlemi, bilgisayarlı görü teknolojisinden yararlanmaktadır. Ayrıca araç takip sistemleri de yine bilgisayarlı görü teknolojisini kullanmaktadır.

Bilgisayarlı görü teknolojisi, günlük hayatta kullandığımız birçok teknolojide yer almaktadır. Örneğin, Google görsellerde kedi resmi aratıldığında, bilgisayarlı görü teknolojisi kullanılarak var olan tüm görsellerin içinden kedi olan görseller tespit edilip çıktı olarak sunulmaktadır. Metin düzelticiler sayesinde yazılan metinlerin okunması ve benzer daha doğru bir metin sunulması gibi örnekler de bilgisayarlı görü teknolojisinin kullanım alanlarından birkaçıdır.

Bunun yanı sıra, bilgisayarlı görü teknolojisi, medikal alanda da oldukça yaygın olarak kullanılmaktadır. Örneğin, MR ve röntgen sonuçlarını tarayarak kanserli hücreleri tespit etmek, göz ve damar rahatsızlıklarının erken teşhisini sağlamak gibi önemli tıbbi uygulamalar için kullanılmaktadır. Ayrıca, kan kaybı ve kanamaların tespitinde de doğru sonuçlar vermektedir.

Bilgisayarlı görü teknolojisi, ayrıca otonom araçlar üzerinde yapılan çalışmalarla trafik kazalarının önlenmesi, güvenlik sektöründe yüz tanıması ve plaka tanıma gibi uygulamalarla da kullanılmaktadır. Bunların yanı sıra, içerik denetimi, askeriye, haritacılık, optik karakter tanıma, pazarlama ve finans gibi alanlarda da yaygın olarak kullanılmaktadır.

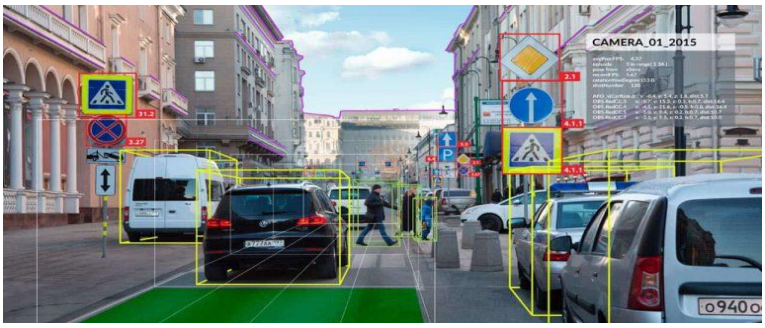

Şekil 1.29. Nesne Algılama ile ilgili örnek

1.16.3. Bilgisayarlı Görü ile İnsan Poz Tahmini

İnsan Poz tahmini, insanların hareket ya da bulundukları pozisyonu grafik şeklinde bilgisayarlı görü tekniği ile ortaya koymaktadır. Bu yöntem, bireylerin olası vücut hatlarını ya da eklem konumlarını bulabilmek için genel bir biçimde bilgisayar bilimi alanında uygulanmaktadır. Günümüzde de böyle bir teknolojiden faydalanılabilecek uygulamaların çokluğundan dolayı çok fazla dikkati üzerine çeken bilgisayarlı görü alanında en haz verici konseplerin başında gelmektedir.

1.17. İnsan Poz Tahmininin Önemi

İnsanların teknolojik araçlarla algılanabilir hale gelmesi uzun zamandır nesne algılama konusunda önemli bir mesele olmuştur. Ancak, son yıllarda makine öğrenimi algoritmalarının gelişmesi ile bilgisayarlar artık insan pozu algılayıp takibini yaparak insanların vücut hatlarını anlaşılabilir hale getirmiştir. Teknolojik aletlerin gelişimi ile insan vücut hat ve pozisyonlarının doğruluğu arttıkça ve lazım olan gerekli donanım daha ulaşılabilir hale geldikçe, insan poz tahmin teknolojisi ticari sahada daha yaygın bir şekilde kullanılabilir hale gelmiştir.

Ayrıca teknolojinin gelişimi ile yüksek performans gösteren anlık poz algılayıp izlemede bilgisayarlı görü alanının kayda değer bir hale ulaşmasına olanak tanımaktadır. İnsan poz tahmini ile mesafe ölçmenin birleştirilerek toplumsal yerlerde mesafe bulma konusunda kullanıbileceğinin yanı sıra insanların çok olduğu karmaşık yerlerde fiziksel mesafenin korunması hususunda da öncü olmaktadır.

İnsan poz tahmini güvenlik, iş, sağlık, güvenlik, eğlence gibi alanları önemli derecede etkilemektedir. Bu teknoloji aynı zamanda otonom sürüş alanında da önemli bir rol oynamaktadır. Gerçek zamanlı insan poz tahmini, bilgisayarların yaya hareketini daha iyi seçip ayırt etmelerine olanak tanıyarak daha güvenli sürüş koşullarına katkı sağlamaktadır.

1.17.1. İnsan Poz Tahmini Uygulamaları

İnsan poz tahmini, bilgisayarla görü alanında geniş çapta ilgi çeken bir olması nedeniyle çok çeşitli uygulamanın kullanılması aşamasında başarılı bir şekilde entegre edilmiştir. Bu uygulama alanlarının kapsamı genelde insan-bilgisayar etkileşimi, hareket analizi, artırılmış gerçeklik (AR) ile sanal gerçeklik (VR) gibi çeşitli alanları içermektedir.

Genel anlamda, insan poz tahmini hemen hemen her alanda sonsuz uygulama potansiyeline sahip olması nedeniyle hızlı bir şekilde gelişerek ilerlemektedir. Günümüzde geliştirilmekte olan bazı yaygın uygulama alanları şunlardır:

İnsan Aktivitesi ve Hareket Tahmini: İnsan poz tahmini, insanların faaliyetlerini ve hareketlerini izlemek ve analiz etmek için kullanılır. Bu teknoloji, spor antrenmanlarını destekleyen yapay zeka uygulamalarından, oturma hareketlerini izlemeye kadar çeşitli uygulamalarda kullanılır. Örneğin, spor salonunda bireylere rehberlik eden sanal antrenörler bu teknolojiyi kullanabilir. Ayrıca, işyerlerinde çalışanların etkinliklerini izlemek veya işaret dili iletişimini desteklemek gibi farklı alanlarda kullanılabilir.

Artırılmış Gerçeklik ve Sanal Gerçeklik (AR/VR): İnsan poz tahmini, AR ve VR uygulamaları ile birleştirildiğinde daha etkileyici ve duyarlı deneyimler sunabilir. Örneğin, bu teknoloji sayesinde tenis veya golf gibi oyunları oynamak için poz tabanlı sanal eğitmenler oluşturulabilir. Ayrıca, askeri uygulamalarda düşmanları ve dost birlikleri ayırt etmek gibi AR programlarında da kullanılır.

Robotik: Geleneksel endüstriyel robotlar, genellikle 2B görüntü sistemlerine dayanır ve sınırlamalara sahiptir. Ancak 3D poz tahmini teknikleri, robotların daha hassas, esnek ve gerçeğe daha yakın hareket etmelerini sağlar. Bu yaklaşım, örneğin öğretmenin duruşunu ve görünümünü takip ederek robotların eylemlerini anlamalarına yardımcı olabilir.

Animasyon ve Oyun: Modern poz tahmini ve hareket yakalama teknolojileri, karakter animasyonunu daha akıcı ve otomatik hale getirir. Özellikle Microsoft'un Kinect derinlik kamerası, gerçek zamanlı insan hareketlerini yakalayarak bunları sanal karakterlerin eylemlerine dönüştürmek için kullanılır. Bu şekilde uygulama, sürükleyici video oyunları ve animasyonları geliştirmek için büyük bir potansiyel sunmaktadır.

1.17.2. Poz Tahmini ile Spor Antrenmanlarının Yapılması

Günümüzde bilgisayarlı görü alanında oldukça iyi performans sergileyen yapay öğrenme modelleri, genel olarak 2 boyutlu algılama üzerine odaklanmaktadır. Bu modeller eğitilirken fotoğraflar 2 boyutlu veriyi esas alırlar. Aynı zamanda 2 boyutlu algılama sonucunda, algılanmış nesneyi çevreleyen 2 boyutlu bir kutu çizilmektedir.

Üç boyutlu nesne algılandığında ise nesnenin boyutu, pozisyonu ve oryantasyonu gibi çıkarımlar daha keskin şekilde yapılabilmesi için araştırmalar devam etmektedir. Bu nedenle 3 boyutlu nesne algılamada kayda değer gelişmeler robotikten, artırılmış gerçekliğe kadar birçok farklı alanda işlevsel olabilecektir.

Tüm bu amaçlar doğrultusunda gerçek zamanlı olarak Google tarafından açık kaynaklı olarak sunulan derin öğrenme tabanlı Mediapipe Kütüphanesi bulunmaktadır. Mediapipe, Google'a ait, açık kaynak bir model iş hattı aracıdır. Bir yerde üretilen bir modelin başka cihazlarda, başka kaynaklarla (örneğin canlı yayınlarda) ve başka donanımlarla çalışabilmesini sağlamak gibi hedefleri olan platform, yüz algılamadan iris takibine kadar birçok işlemi gerçekleştirmek için kullanılabilmektedir. Tüm bu bilgiler ışığında tez çalışmamızın uygulama kısmı mediapipe kitaplığı ile hazırlanmıştır.

1.18. Mediapipe Poz Tahmini Kütüphanesi

Spor antrenmanlarında da Mediapipe kütüphanesi aracılığı ile insan poz sınıflandırması yaparak insan vücudu tespit edilmektedir. Tespit edilen vücut hatlarının matematiksel yöntemler kullanılarak yapılan antrenmanın doğru olup olmadığı belirlenebilmektedir. Örneğin aşağıdaki resimde görüleceği üzere verilen poz, vücut parçası açılarının aşağıdaki birleşimi olarak tanımlanabilir:

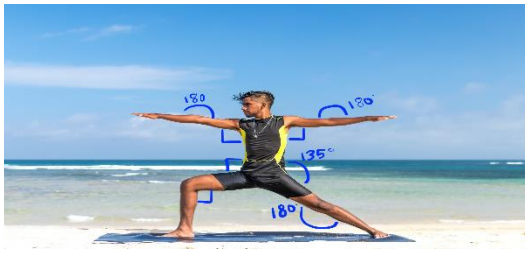

Şekil 1.30. Poz Algılama

- Her iki omuzda 90 derecelik açı
- Her iki dirsekte 180 derecelik açı
- Ön bacakta ve belde 90 derecelik açı

- Arka dizde 180 derecelik açı
- Belde 135 derecelik açı

Bu açıları hesaplamak için poz işaretleri kullanılmaktadır. Örneğin sağ ön bacak ve beldeki açı, sağ omuzdan sağ kalçaya kadar olan çizgi ile sağ kalçadan sağ dize kadar olan çizgi arasındaki açıdır.

Pozu tanımlamak için gereken tüm açılar hesaplandıktan sonra, bir eşleşme olup olmadığı kontrol edilir, eşleşme oluşması durumunda poz tanınmış olmaktadır.

1.18.1. MediaPipe Poz Tahmini Nasıl Çalışır?

Giriş görüntüsü, kullanıcının vücudunun anahtar nokta tespiti için MediaPipe kütüphanesi ile beslenir. Çıktı, insan vücudunun 33 ana kilit noktası için X, Y ve Z eksenindeki koordinatların bir listesidir. Bu koordinat listesi, giriş görüntüsündeki her bir ana vücut parçasının konumunu tanımlar. Bu koordinatları kullanarak kullanıcının doğru bir iskelet yönelimini oluşturabiliriz. Aşağıdaki şekilde, işaretler insan vücudundaki ana eklemleri ve yerleri göstermektedir. MediaPipe kitaplığından çıkan toplam 33 yer işaretini belirtmek için 0'dan 32'ye kadar indeksleme yapılır. Yüz işaretleme prosedürü için 0'dan 10'a kadar ilk 11 yer işareti kullanılır. Bu yer işaretlerini veya kilit noktaları kullanarak bir görüntüdeki yüzü ve yönü tespit edilebilir. 11'den 22'ye kadar olan sonraki 11 yer işareti, üst gövdenin algılanmasından kullanılır. Üst vücut omuzları, dirsekleri, bilekleri, elleri ve her iki elde de serçe parmak, işaret parmağı ve başparmak olmak üzere 3 parmaktan oluşur. 23'ten 32'ye kadar olan son 11 kilit nokta/nitelik, kalçalar, dizler, bacaklar ve ayaktan oluşan alt gövdeyi tanımlamak için kullanılır. Birlikte yalnızca görüntüdeki insan vücudu yapısı hakkında değil, aynı zamanda vücudun 3B uzaydaki yönelimi hakkında da bir tahmin verirler.

Poz algılama, önceden eğitilmiş MediaPipe modeli kullanılarak elde edilir. MediaPipe, ses, video ve dizi verileri gibi gerçek zamanlı medya akışı için açık kaynaklı, platformlar arası özelleştirilebilir bir makine öğrenimi çözümüdür. Kitaplık, Android, iOS, Python, JavaScript gibi birden çok platformda desteklenir. MediaPipe kitaplığı tarafından sağlanan çözümlerden bazıları arasında poz tahmini, saç segmentasyonu, yüz ağı, hareket izleme ve Keypoint Neural Invariant Feature Transform (KNIFT) sayılabilir. MediaPipe kitaplığına veri girişi, kamera tarafından yakalanan görüntüdür.

MediaPipe kitaplığı tarafından üretilen çıktı, X, Y ve Z kartezyen koordinatlarına karşılık gelen anahtar noktaların bir listesidir. Bu kilit noktalar, gerçek zamanlı olarak

verilen görüntü veya video akışındaki insan vücudu yapısının ve yöneliminin kabaca tahminini almak için kullanılabilir. MediaPipe kitaplığının belgelerinde belirtilen kare hızı saniyede 30 karedir.

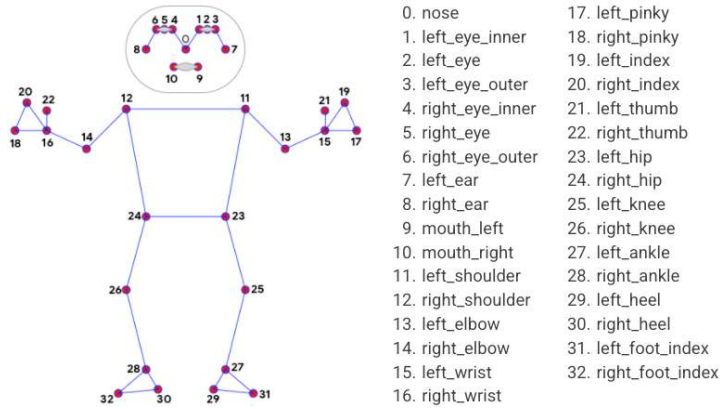

Şekil 1.31. MediaPipe Kitaplığında belirtilen kilit noktalar

1.18.2. MediaPipe Kütüphanesi Model Mimarisi

Mediapipe kütüphanesi, ısı haritaları (heatmaps) kullanarak görüntü işleme ve analizinde kullanmaktadır. Isı haritaları, nesnelerin hareketi veya bir olayın gelişimi sırasında belirli bir özellik veya ölçümün zamanla nasıl değiştiğini gösteren görsel bir yöntemdir. Mediapipe kütüphanesi, özellikle insan vücudu ve yüzü gibi kompleks nesneler için ısıl haritalar kullanarak çeşitli görevler için modeller oluşturur [87]. Modellerden bazıları şunlardır:

El işaretleri tanıma: İnsanların ellerinin pozisyonlarını ve hareketlerini takip eden ısı haritalarını kullanarak, mediapipe kütüphanesi el işaretlerini tanımak için bir model oluşturabilir. Bu model, işitme engelliler için daha erişilebilir bir arayüz sağlamak veya uzaktan kumandalı cihazları kontrol etmek gibi birçok uygulamada kullanılabilir.

Yüz tanıma: Mediapipe, yüzlerin ısıl haritalarını kullanarak yüz özelliklerini tanıyan bir model oluşturabilir. Bu model, yüz ifadesi analizi, göz takibi, gülümseme tespiti ve yüz tanıma gibi birçok uygulama için kullanılabilir.

Beden hareketleri takibi: Mediapipe, insan bedeninin ısıl haritasını kullanarak bir model oluşturabilir ve vücut pozisyonları, eklemler ve hareketler hakkında bilgi sağlayabilir. Bu model, fitness uygulamaları, fizyoterapi ve spor analizi gibi birçok uygulamada kullanılabilir.

Görüntü sınıflandırma: Mediapipe, ısıl haritaların yanı sıra görüntü sınıflandırması için kullanılan diğer özelliklerle birlikte çalışarak, görüntülerin içeriklerine

göre sınıflandırılması için bir model oluşturabilir. Bu model, nesne tanıma, trafik analizi ve tıbbi görüntüleme gibi birçok uygulama için kullanılabilir.

Bu modeller, ısıl haritaların birleşik kullanımı ile yüksek doğruluk ve performans sağlar. Mediapipe kütüphanesi, bu modelleri oluşturmak için gerekli veri toplama, veri ön işleme ve makine öğrenimi teknikleri gibi çeşitli araçlar ve yöntemler sunmasının yanı sıra ısı haritaları yöntemiyle oluşturduğu modellerle, belirli özellikleri ve nesneleri tespit etmek, takip etmek ve analiz etmek için derin öğrenme algoritmalarını da kullanır. Bu modeller, özellikle insan bedeni gibi çok sayıda detay içeren nesnelerin tespiti ve takibi için kullanışlıdır. Aynı zamanda, kullanımı kolay ve özelleştirilebilir bir ara yüz sunar. Kullanıcılar, farklı işlevleri destekleyen farklı modelleri birleştirebilir ve bunları kendi ihtiyaçlarına göre yapılandırabilirler. Bu, Mediapipe'nin çeşitli uygulama senaryolarında kullanılabilmesini de mümkün kılmaktadır [88].

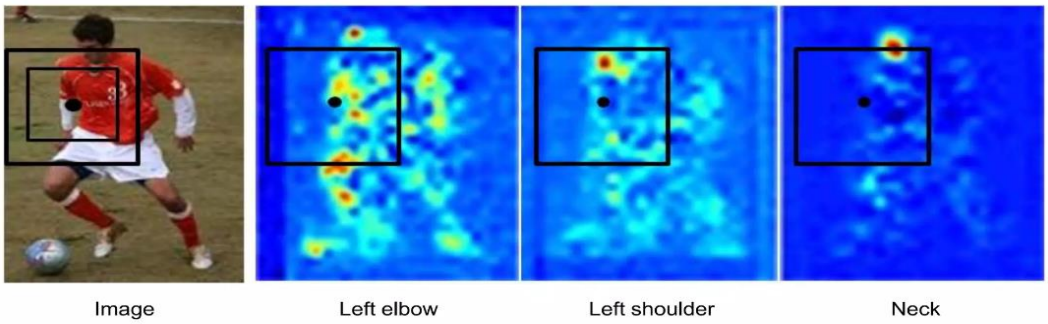

Şekil 1.32. Mediapipe Kütüphanesi Isı Haritaları (Heatmaps) kullanımı

1.18.3. Mediapipe Kütüphanesinin Kullandığı Topoloji

Mediapipe kütüphanesi, insan vücudunun çeşitli bölgelerine yerleştirilmiş 33 anahtar noktadan oluşan kişi tespiti için yeni bir topoloji sunmaktadır. Bu topoloji, BlazeFace, BlazePalm ve COCO veri kümelerinde ve çıkarım ağlarında kullanılan anahtar noktaların bir üst kümesidir ve farklı veri kümeleri ve modeller arasında tutarlılık sağlar [89].

OpenPose ve Kinect gibi diğer popüler topolojilerle karşılaştırıldığında Mediapipe'ın topolojisi yüz, eller ve ayaklar üzerinde minimum sayıda kilit nokta kullanır. Bu, modelin ilgilenilen bölgenin dönüşünü, boyutunu ve konumunu yüksek doğruluk ve verimlilikle tahmin etmesini sağlar. Model, yalnızca gerekli anahtar noktaları kullanarak hesaplama karmaşıklığını azaltabilir ve algılama hızını artırabilir [90].

Genel olarak Mediapipe topolojisi, artırılmış gerçeklikten spor analizine kadar çeşitli uygulamalar için uygun, doğru ve verimli kişi tespiti sağlamak temeli üzerine tasarlanmıştır [91].

1.18.4. Mediapipe Kütüphanesinde Kullanılan Veri Seti

Isı haritalarını kullanarak kilit noktaları tespit eden mevcut poz tahmini çözümlerinin çoğuyla karşılaştırıldığında, temel alınan çözüm başlangıçta bir poz hizalaması gerektirmektedir. Veri kümesi, kişinin tamamının görünür olduğu ya da kalça ve omuz kilit noktalarının güvenle açıklanabildiği durumlarla sınırlandırılmaktadır. Modelin veri kümesinde bulunmayan ağır oklüzyonları desteklediğinden emin olmak için önemli ölçüde oklüzyon simülasyonu artırımı kullanılmaktadır. Eğitim veri kümesi, sahnede ortak pozlarda tek veya birkaç kişinin bulunduğu 60 bin görüntüden ve sahnede fitness egzersizleri yapan tek bir kişinin bulunduğu 25 bin görüntüden oluşmaktadır [92].

1.18.5. Mediapipe Avantaj ve Dezavantajları

MediaPipe, Google tarafından ses, video ve görüntü işleme çözümleri sunarak geliştiren bir kütüphanedir. Kütüphane, özellikle gerçek zamanlı uygulamalar için tasarlanmış olduğundan akıllı telefonlar, tabletler ve masaüstü bilgisayarlar gibi çeşitli platformlarda çalışabilmesinin yanı sıra kullanıcıların videoları işleyebilmelerine, nesne algılama, yüz algılama, nesne takibi ve pose tahmini gibi görevleri gerçekleştirebilmelerine olanak tanıdığından şu şekilde avantajları vardır:

Gerçek zamanlı uygulamalar için optimize edilmiştir: MediaPipe, gerçek zamanlı video işleme çözümleri sunmak üzere tasarlanmıştır. Bu nedenle, akıllı telefonlar, tabletler ve diğer mobil cihazlar gibi sınırlı kaynaklara sahip platformlarda bile hızlı ve verimli bir şekilde çalışabilir.

Yüksek doğruluk: MediaPipe, yüksek kaliteli sonuçlar sağlamak için hassas algoritmalar ve çeşitli derin öğrenme teknikleri kullanır. Bu nedenle, özellikle nesne takibi, yüz algılama ve pose tahmini gibi görevlerde yüksek doğruluk sağlar.

Modüler yapı: MediaPipe, modüler bir yapıya sahiptir. Bu, kullanıcıların farklı bileşenleri seçerek veya yenilerini oluşturarak ihtiyaçlarına göre kendi iş akışlarını tasarlamalarına olanak tanır. Böylece, MediaPipe kullanarak farklı görevleri gerçekleştirmek için birçok farklı çözüm geliştirilebilir.

Çoklu platform desteği: MediaPipe, çeşitli platformlarda çalışabilir ve farklı cihazlarda çalıştırılabilen uygulamalar oluşturmak için kullanılabilir.

Bunların yanı sıra MediaPipe'in şu dezavantajları da bulunmaktadır:

Düşük esneklik: MediaPipe, modüler yapısı nedeniyle bazı durumlarda düşük esneklik sağlayabilir. Bazı kullanıcılar, kendileri için özelleştirilmiş çözümler oluşturmak istediklerinde sınırlamalarla karşılaşabilirler.

Sınırlı veri setleri: Mediapipe, yalnızca belirli veri setleri üzerinde eğitilmiştir. Bu, farklı uygulamalar için özelleştirilmesi gerektiğinde sınırlayıcı olabilir [93].

2. MATERYAL VE YÖNTEM

2.1. Yöntem

Bilgisayarlı görü teknikleri ile gerçekleştirilen spor antrenmanlarının doğruluğunun tespiti uygulaması Windows işletim sistemi üzerinde Python programlama dili kullanılarak geliştirildi. Ayrıca uygulamada MediaPipe, NumPy, Pandas ve Scikit-Learn olmak üzere dört Python kütüphanesi kullanılmaktadır.

Google tarafından geliştirilen bir açık kaynaklı çoklu ortam çerçevesi ile video ve ses işleme, makine öğrenimi ve derin öğrenme gibi alanlarda kullanılan MediaPipe kütüphanesini kullanarak, poz tahmin modeli yapılan diğer derin öğrenme algoritmalarına göre üstünlük sağlayan Mediapipe poz tahmini modeli kullanılarak gerçek zamanlı insan poz tahmini elde edilmiştir.

Elde edilen insan poz tahminlerinden bilimsel hesaplamalar yaparak elde edilen eklem noktalarını çok boyutlu diziler ve matrisler üzerinde işlem yapmak amacıyla NumPy kütüphanesini kullandık.

Yine Python'da veri analizi ve manipülasyonu için kullanılan Pandas kütüphanesi ile tablo verileri üzerinde işlem yapmak için uygulamada kullanıldı. Bununla birlikte sınıflandırma yaparak oluşturmuş olduğumuz veri setimizde regresyon problemlerini ele almak amacıyla Scikit-Learn kütüphanesi ile makine öğrenimi algoritmalarından günümüzde popüler olan ve veri bilimi açısından daha keskin sonuçlar elde etmeye yarayan lineer regresyon, katı sınıflandırıcı, rastgele orman sınıflandırıcı ile eğim destekli sınıflandırıcı algoritmalar temelli uygulamada işlemler yapıldı.

Tüm bu aşamalar bahsi geçen kütüphaneler kullanılarak, aşağıdaki adımlar uygulanarak uygulama gerçekleştirilmiştir.

1. MediaPipe kütüphanesi kullanılarak gerçek zamanlı poz tahmini verileri elde edildi.
2. NumPy kütüphanesi kullanılarak poz tahmini verileri işlendi. NumPy, poz tahmini verileri matris şeklinde tutarak bu verileri daha kolay bir şekilde işleyebilmek amacıyla CSV formatında kaydedildi.
3. Pandas kütüphanesi kullanılarak poz tahmini verileri analiz edildi. Pandas, poz tahmini verilerini tablo şeklinde göstererek, bu veriler üzerinde daha kolay bir şekilde çalışma sağlanıldı.

4. Scikit-Learn kütüphanesi kullanılarak spor aktivitelerinin doğruluk oranı CSV formatındaki kayıt edilen verilerle makine öğrenimi algoritmalarından Lineer Regresyon (Lineer Regresyon), Katı Regresyon (Ridge Regresyon), Rastgele Orman Sınıflandırıcı (Random Forest Classifier) ve Eğim Destekli Sınıflandırıcı (Gradient Boosting Classifier) Algoritmalarından faydalanarak spor aktivitelerinin doğruluğu tespit edilmeye çalışıldı.

Bu adımlar takip edilerek, derin öğrenme tabanlı MediaPipe Poz Tahmin modeli kullanarak gerçek zamanlı görüntülerden elde edilen insan poz tahmini verilerini, spor biyomekaniği alanında spor aktivitelerinin doğruluk oranını öncelikle deney yapılacak olan spor aktiviteleri belirlendikten sonra aşama aşama tespit etmeye çalıştık.

2.2. Amaç

Yapılan uygulamanın temel amacı, derin öğrenme tabanlı MediaPipe Poz Tahmin modeli kullanarak gerçek zamanlı görüntülerden elde edilen insan poz tahmini verilerini, spor biyomekaniği alanında spor aktivitelerinin doğruluk oranını tespit etmek amacıyla hazırlanmıştır. Bu amaçla, MediaPipe Poz Tahmin modeli kullanılarak toplanan veriler, makine öğrenme algoritmaları kapsamında analiz edilmiştir.

Aynı zamanda uygulama, spor biyomekaniği alanında geleneksel yöntemlerin yanı sıra, derin öğrenme tekniklerinin de kullanılabileceğini göstermektedir. Bu yeni yaklaşımın sporcuların performansını ve sakatlanma riskini değerlendirmek için kullanılabilirliğini ve doğruluğunu artırmayı amaçlamaktadır.

Sonuç olarak, bu uygulamanın amacı, MediaPipe Poz Tahmin modeli kullanarak elde edilen insan poz tahmini verilerinin, spor aktivitelerinin doğruluk oranını tespit ederek spor biyomekaniği alanında yeni bir yaklaşım sunmaktır. Bu yaklaşımın, sporcuların performansını ve sakatlanma riskini değerlendirmek için kullanılabilirliğini de ayrıca artırmayı amaçlamaktadır.

2.8. Algoritma Oluşturma ve Antrenman Seçimi

Şekil 2.1, hareket analizi sürecinin bir akış şemasını göstermektedir. Egzersiz hareket tanıma sistemi, bir bilgisayar web kamerası kullanılarak oluşturulan giriş görüntülerini OpenCV kullanarak BGR görüntülerinden RGB görüntülerine dönüştürür. MediaPipe Poz Tahmin modelini kullanarak, postüral analiz için gerekli olan vücut yer işaretlerini algılar ve pozisyonu kaydeder. Analiz edilen pozisyonun x, y, z koordinatları kullanılarak önceden eğitilen model doğrultusunda karşılaştırma yapılıp duruş açısı

hesaplanarak doğru egzersiz duruşu kriterlerini karşılayıp karşılamadığı doğrulanır. Kullanıcının doğru duruş kriterlerini karşılamaması halinde ekranda uygun şekilde uyarılar gösterilmektedir. Duruşun, doğru olması halinde düzeltme antrenman sayısı artırılarak ekrana çıktı verilir.

Bu program için en uygun egzersizler olan çömelme (squat) ve ağırlık kaldırma (deadlift) seçildi.

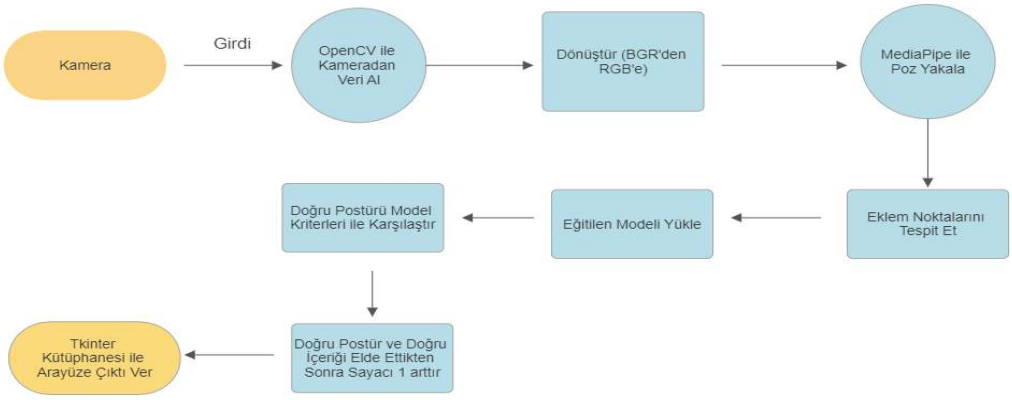

Şekil 2.1. Kameradan doğru pozisyon algılama uygulaması süreçleri

2.8.1. Ağırlık Kaldırma (Deadlift)

Ağırlık kaldırma (Deadlift), bacakların ve kalçanın güçlü bir şekilde çalıştığı bir egzersizdir ve vücut geliştirme, fitness ve güç sporları için sıkça kullanılır. Ağırlık kaldırmanın doğru formda yapılması, sakatlık riskini azaltır ve performansı arttırır. Ayrıca ağırlık kaldırma, tam vücut kuvveti ve gücü geliştirmek için çok etkili bir egzersizdir. Ancak, doğru teknik kullanılmadan yapıldığında ciddi yaralanma riski ortaya çıkabilmektedir.

Ağırlık kaldırma egzersizinin sakatlık riskini azaltıp performansı arttıracak şekilde doğru formda yapılması için uygun kinematik değerler dâhilinde yapılması gerekmektedir. Uygun kinematik değerler hakkında birçok çalışma ve kaynak bulunmaktadır. Bunlardan biri olan Escamilla ve ark. (2001) tarafından yapılan çalışmada, ağırlık kaldırma (deadlift) egzersizinde uygun hareket aralığı ve teknikleri incelenmiştir. Çalışma, kuvvet ve kondisyon antrenmanı yapan 8 erkeğe ağırlık kaldırma egzersizi yaptırmış ve bu egzersiz sırasında bel ve bacak açıları ölçülmüştür.

Çalışmada, ağırlık kaldırma egzersizinde bel açısının ortalama olarak 137 derece olduğu, bacak açısının ise 118 derece olduğu tespit edilmiştir. Ayrıca, bel açısının yere

paralel olması, sırtın düz tutulması ve kalçanın yere yakın durması gibi tekniklerin uygulanması önerilmiştir [94].

Benzer şekilde, Swinton ve ark. (2012) tarafından yapılan bir çalışmada da ağırlık kaldırma egzersizinde uygun teknikler ve kinematik değerler incelenmiştir. Çalışmada, deadlift egzersizinde bel açısının ortalama olarak 140 derece olduğu, bacak açısının ise 105 derece olduğu tespit edilmiştir. Ayrıca, sırtın düz tutulması, çenenin göğse yakın olması, kalçanın yere yakın durması ve çekme hareketinin yere paralel yapılması gibi tekniklerin uygulanması önerilmiştir [95].

Bu çalışmaların yanı sıra genelde ağırlık kaldırma egzersizinde doğru pozisyon, Amerikan Kuvvet ve Kondisyon Derneği'nin (American College of Sports Medicine - ACSM) referanslarına dayanarak belirlenir.

Amerikan Kuvvet ve Kondisyon Derneği'ne göre, deadlift egzersizinde kalçaların en alt seviyede olduğu pozisyonun en etkili olduğunu belirtir ve bu pozisyonda kalça açısı 120-140 derece arasında olması gerektiğini belirtmektedir [96]. Ayrıca, diz açısı da 100-120 derece arasında olması belirtilmektedir [97]. Bu pozisyonda, vücut ağırlığı topuklar üzerine yerleştirilmeli, omuzlar hizalanmalı ve baş dik bir şekilde tutulmalıdır.

Ağırlık kaldırma hareketi sırasında, sırtın düz tutulması gerektiği vurgulanır ve bel açısı da 0-30 derece arasında olmalıdır. Ayrıca, başın öne doğru eğilmesi de engellenmelidir [98].

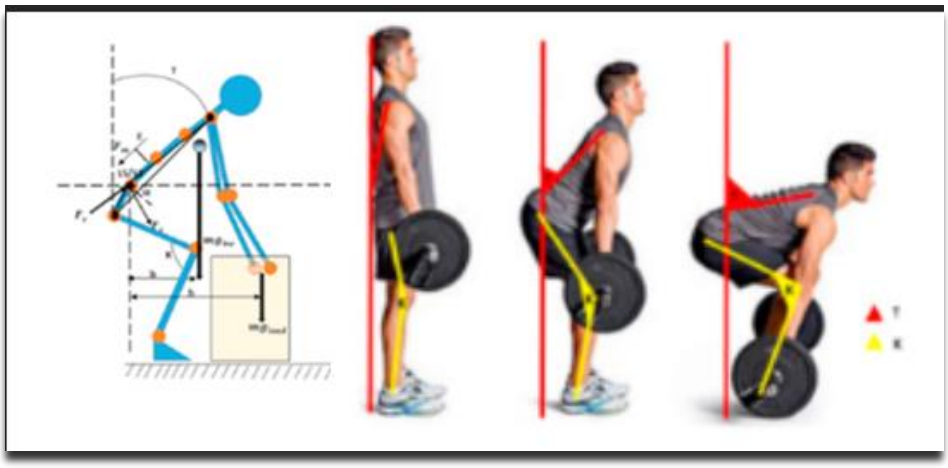

Şekil 2.2. Doğru Deadlift postürü ve açısı

2.8.2. Çömelme (Squat)

Çömelme egzersizinde doğru pozisyon; kalça, bacak ve bel kaslarının güçlenmesi için hayati öneme sahiptir. Çömelme egzersizi, doğru formda yapıldığında kasların güçlenmesine ve sakatlanmaların önlenmesine yardımcı olur.

Çömelme egzersizinde uygun kinematik değerler hakkında birçok çalışma ve kaynak bulunmaktadır. Örneğin, Escamilla ve ark. (2001) tarafından yapılan bir çalışmada, çömelme egzersizinde uygun hareket aralığı ve teknikleri incelenmiştir. Çalışmada, 8 erkek katılımcıya çömelme egzersizi yaptırılmış ve bu egzersiz sırasında kalça, diz ve ayak bileği açıları ölçülmüştür. Çalışmanın sonuçlarına göre, çömelme egzersizinde kalça açısının ortalama olarak 109 derece, diz açısının ortalama olarak 104 derece ve ayak bileği açısının ortalama olarak 38 derece olduğu tespit edilmiştir. Ayrıca, sırtın düz tutulması, gözlerin öne doğru bakması ve çekme hareketinin yere paralel yapılması gibi tekniklerin uygulanması önerilmiştir [99].

Benzer şekilde, Neumann ve ark. (2009) tarafından yapılan bir çalışmada da çömelme egzersizinde uygun teknikler ve kinematik değerler incelenmiştir. Çalışmada, çömelme egzersizinde kalça açısının ortalama olarak 118 derece, diz açısının ortalama olarak 120 derece ve ayak bileği açısının ortalama olarak 15 derece olduğu tespit edilmiştir. Ayrıca, sırtın düz tutulması, gözlerin öne doğru bakması, dizlerin ayak uçlarından öne doğru gitmemesi ve kalçanın yere yakın durması gibi tekniklerin uygulanması önerilmiştir.

Çömelme egzersizinde uygun kinematik değerler hakkında yapılan diğer çalışmalar da mevcuttur ve her bir çalışmanın sonuçları biraz farklılık gösterebilmektedir. Ancak genel olarak, squat egzersizinde sırtın düz, gözlerin öne bakık ve çekme hareketinin yere paralel yapılması, kalça, diz ve ayak bileği açılarının belirli bir aralıkta tutulması önerilmektedir [100].

Genelde çömelme egzersizinde doğru pozisyon, Amerikan Kuvvet ve Kondisyon Derneği'nin (American College of Sports Medicine - ACSM) referanslarına dayanarak belirlenir. Amerikan Kuvvet ve Kondisyon Derneği, çömelme egzersizinde kalça açısının 120-130 derece arasında olması gerektiğini belirtmektedir [101]. Diz açısı ise, 100-110 derece aralığında olmalıdır. Çömelme egzersizinde ayakların genişliği, kişinin rahat hissettiği aralıkta olabilir.

Çömelme egzersizinde ayrıca, sırtın düz tutulması ve belin sabit tutulması önemlidir. Sırt düz ve göğüs kafesi açık bir şekilde tutulmalıdır. Ayrıca, başın öne doğru eğilmesi de engellenmelidir [102].

Tam açı ölçüleri ise, kişinin boyuna ve fiziksel yeteneğine bağlı olarak değişebilir. Örneğin, olimpik halterciler tam çömelme pozisyonunda kalçaları topukların altına getirebilirken, diğer kişiler bu pozisyona ulaşamayabilir. Ancak, tam çömelme pozisyonunda kalça açısının 140 derece civarında olduğu belirtilmektedir.

Şekil 2.3. Doğru Squat postürü ve açısı

2.9. Veri Seti Oluşturma Aşaması

Derin öğrenme modelleri, genellikle büyük miktarda etiketlenmiş veri gerektirir. Bu veriler, genellikle bir veri kümesi olarak adlandırılır ve model eğitimi için kullanılır. Ancak, bazen uygun bir veri kümesi bulmak zor olabilir [103]. Bu durumlarda, video dosyalarından veri seti oluşturma yöntemi kullanılabilir. Bizler de bu çalışmamızda bu yöntemi kullanarak veri setimizi kendimiz oluşturduk.

Video dosyalarından veri setini oluştururken, video kayıtlarından görüntüleri çerçeve çerçeve ayıklayıp bu görüntüleri etiketleyerek gerçekleştirdik. Ayrıca bu yöntem, özellikle nesne tanıma, yüz tanıma, insan aktivitesi tanıma gibi alanlarda kullanılmaktadır.

İlk aşama, video dosyalarından görüntü çerçevelerini MediaPipe kütüphanesine göre insan iskeletindeki 33 eklem noktasına göre uzman kişiler eşliğinde sosyal medya platformlarında spor biyomekaniği açısından doğru olan deadlift ve squat hareketlerinin olduğu video dosyalarını kaydedip bu video dosyalarını tek bir video dosyası haline getirdikten sonra videoyu açarak ve ardından çerçeve çerçeve ilerleyerek gerçekleştirdik. Her çerçeveyi, bir görüntü olarak kaydını yaptık.

İkinci aşama ise veri kümesi oluşturmak için, 33 eklem noktası baz alınarak her görüntü için doğru etiketin belirlenmesidir. Bizler de videodaki spor hareketlerini kinematik veriler ışığında Amerikan Kuvvet ve Kondisyon Derneğinin (ACSM) belirlediği açı değerlerine bağlı olarak "yukarı (up)" ya da "aşağı (down)" olarak belirli bir aktiviteyi kıstaslar eşliğinde görüntüler ön işleme tabi tutularak düzenlenmesi yapıldıktan sonra virgülle ayrılmış değerler dosyası anlamına gelen sınırlandırılmış bir metin dosyası türü olan csv dosyası olarak kaydettik. Bu adımda, ekran yönergelerine göre fps değerleri, hareketin başarı yüzdesi ile birlikte uygun kinematik ölçümler dâhilinde sayaç artırımı dâhilinde verilerin doğru şekilde biçimlendirilmesini ve boyutlandırılmasını yapmış olduk.

Şekil 2.4. Kinematik ölçümler dahilinde veri seti oluşturma

2.10. Sınıflandırma Seçimi ve Modelleme Aşaması

Veri seti ile modelleme, makine öğrenimi ve yapay zeka gibi alanlarda sıklıkla kullanılan bir yaklaşımdır. Bu yaklaşım, bir veri setindeki örnekleri kullanarak bir model oluşturma işlemidir. Bu model, daha sonra yeni verileri sınıflandırmak, tahmin etmek veya keşfetmek için kullanılabilir.

Bizler de bu çalışmamızda csv dosya formatında hazırladığımız veri seti ile modelleme yapmak için genellikle şu adımları izledik:

Veri setimizi, **yüzde seksen (%80) eğitim ve yüzde yirmi (%20) test verileri** olarak ikiye ayırarak, eğitim verilerini modelin öğrenme sürecinde kullanılırken, test verilerini ise modelin performansının ölçülmesi için kullandık.

Sonraki aşamada, veri setinin özelliklerini kullanarak bir model oluşturduk. Bu modeli oluştururken aşağıda tablo halinde verilen farklı sınıflandırıcı algoritmalarını scikit-learn kütüphanesini kullanarak günümüzde popüler olan ve genelde en iyi performans gösteren algoritmayı elde etmek amacıyla kullandık.

Sınıflandırma Algoritması	**Açıklama**
Lojistik Regresyon [104]	Sınıflandırma problemlerinde kullanılan bir makine öğrenimi algoritmasıdır. Çıktı olarak 0-1 aralığında bir olasılık değeri verir ve eşik değeri belirlenerek tahmin yapılır. Çoklu sınıf sınıflandırması için one-vs-all veya multinomial yöntemleri kullanılabilir. Temel mantığı, verilerin belirli bir doğruya en iyi şekilde uygunlaştırılmasıdır. Bu nedenle, lineer bir sınıflandırma yöntemi olarak da düşünülebilir.
Katı (Ridge) Sınıflandırıcı [105]	Sınıflandırma problemlerinde kullanılan bir makine öğrenimi algoritmasıdır. Lineer bir model kullanır ve doğrusal olmayan veriler için kernel trick yöntemi uygulanabilir. Ridge sınıflandırıcısı, genel olarak diğer lineer sınıflandırma algoritmalarından daha az hassas ve daha istikrarlıdır. Ayrıca özellikler arasındaki çoklu bağlantıları yönetme yeteneği ile bilinir.
Rastgele Orman (Random Forest) Sınıflandırıcı [106]	Karar ağacı temelli bir sınıflandırma algoritmasıdır. Temel fikri, verileri alt örneklemeler halinde rastgele ağaçlara ayırmaktır ve her bir ağacın tahminlerinin ortalamasını kullanarak son tahmini yapmaktır. Bu yöntem, geniş bir veri kümesinde yüksek doğruluk elde etmek için kullanılabilir. Ayrıca, veri setindeki özellikler arasındaki ilişkileri de anlamaya yardımcı olabilir.
Eğim Destekli (Gradient Boosting) Sınıflandırıcı [107]	Birçok zayıf sınıflandırıcıyı bir araya getirerek güçlü bir sınıflandırıcı oluşturan bir makine öğrenimi algoritmasıdır. Gradient boosting, bir hata fonksiyonunu en aza indirecek şekilde yeni sınıflandırıcılar oluşturur. Hata fonksiyonu, gerçek değerler ve tahminler arasındaki farkları ölçer. Yeni sınıflandırıcılar, gerçek değerleri tahmin etmek

	için oluşturulan hatalar üzerinde odaklanır. Gradient boosting, yüksek doğruluk sağlamak için veri setlerinin boyutu büyüdükçe daha etkili hale gelir. Ayrıca, birçok farklı hiperparametre ayarlarıyla denenebilir.

Veri setini test ettikten sonra her bir modelin performansı ölçülüp hata oranı gibi performans metrikleri hesaplandıktan sonra modelin gelecekteki tahminler için ve sonradan kullanılabilmesi amacıyla uygun olan modelimizi Pickle dosyası olarak kaydettik.

Çizelge 2.1. Model eğitim veri seti doğrulama metrik değerleri

Algoritma	**Doğruluk(Accuracy)**	**Keskinlik (Precision)**	**Hatırlatma (Recall)**
Lojistik Regresyon	1.0	1.0	1.0
Katı sınıflandırıcı	1.0	1.0	1.0
Rastgele Orman Sınıflandırıcı	0.998	0.996	0.994
Eğim Destekli Sınıflandırıcı	0.955	0.994	0.988

Python programlama dilinde nesnelerin serializasyonu için kullanılan pickle kütüphane ile modelin eğitimini tamamladıktan sonra, Pickle modülü kullanılarak içerisinde Mediapipe poz tahmin modeli kullanılarak elde edilen 33 eklem noktasının özniteliklerini ile hareketin aşağı ya da yukarı doğru olduğuna dair **7795** satırdan oluşan ayrıca yaklaşık **8,22 Megabyte** yer kaplayan csv dosyası daha küçük bir formata kaydedildi. Bu şekilde elde edilen dosya **219 Kilobyte** yer kaplayarak makine öğrenme modeline uygun hale getirildi.

2.9.5. Model Test Aşaması

Makine öğrenimi açısından başarılı bir modelleme işlemi için veri setinin kalitesi, boyutu ve dengesi gibi faktörler dikkate alınarak uygun formata dönüşüm işlemi yapıldıktan sonra elde ettiğimiz modelimizi Python kodumuzu test ettik.

Python kodumuz, vücut dilini tanıyan bir modeli test etmek için video akışını alarak insan vücudunun konumunu algılamak için MediaPipe Poz Tahmini modelini kullanarak mevcut konumlandırmayı bir veri çerçevesine dönüştürür. Ardından, bu veri çerçevesi, önceden eğitilmiş ve bir pickle dosyası olarak kaydedilmiş sınıflandırma modeline verilir ve vücut dilinin hangi sınıfa ait olduğunu tahmin etmeye çalışır.

Bu özel kod, yukarıda tanımı yapılmış ağırlık kaldırma ya da çömelme egzersizinde, kullanıcının yaptığı hareketler doğrultusunda yukarı kalkıp uygun bir şekilde çömeldiği sayıyı sayan bir mekanizma sağlar. Kullanıcının "yukarı" ve "aşağı" hareketleri sırasında gösterdiği vücut dilini algılar ve "yukarı" hareketlerinin sayısını tutar. Bu bilgiler, ekranda görüntülenen bir kutuda gösterilir. Video akışı sırasında, modelin tahmin ettiği sınıfın yanı sıra tahmin olasılıkları da görüntülenir.

Şekil 2.5. Elde edilen modelin test edilmesi

2.10. Arayüz Oluşturma

Uygulanan sistemin başarımı test edilip doğru yürütüldüğünü belirledikten sonra bir kişinin video akışından bir insanın duruşunu tahmin etmek için doğru deadlift ya da

squat formu ile egzersiz yapmasına yardımcı olmak amacıyla Python kodunda basit bir grafik arayüzü tasarlanmıştır.

Uygulama, kullanıcının hareketini gerçek zamanlı olarak görüntülemek için bir web kamerası kullanır ve Mediapipe Kütüphanesi aracılığıyla vücut pozisyonunu tanımlar. Ardından, tahminleri daha önceden oluşturmuş olduğumuz makine öğrenimi modelini kullanarak değerlendirir. Arayüzdeki bileşenler, etiketler, düğmeler ve görüntüler kullanıcının doğru hareketleri yapmadığında oluşan geri bildirimleri ve istatistikleri görüntülemek için kullanıcının dikkatini dağıtmayacak şekilde belli bir düzene göre tasarlanmıştır.

Grafik arayüz kodu, Tkinter, Pandas, Numpy, Pickle, Mediapipe, OpenCV ve PIL modüllerini içerir. Program, video akışını alır, vücut yapısını tanımlar ve belirli bir duruşun doğruluğunu tahmin eder. Sonuçlar, kullanıcı arayüzünde Mediapipe Poz Tahmin modelindeki 33 eklem noktası baz alınarak eğitilen model kapsamında **%70 ve üzeri benzerlik olması halinde hareketin "up" yani yukarı aksi taktirde "down" ya da aşağı yapıldığına dair uygun ekran yönergeleri** ile gösterilir

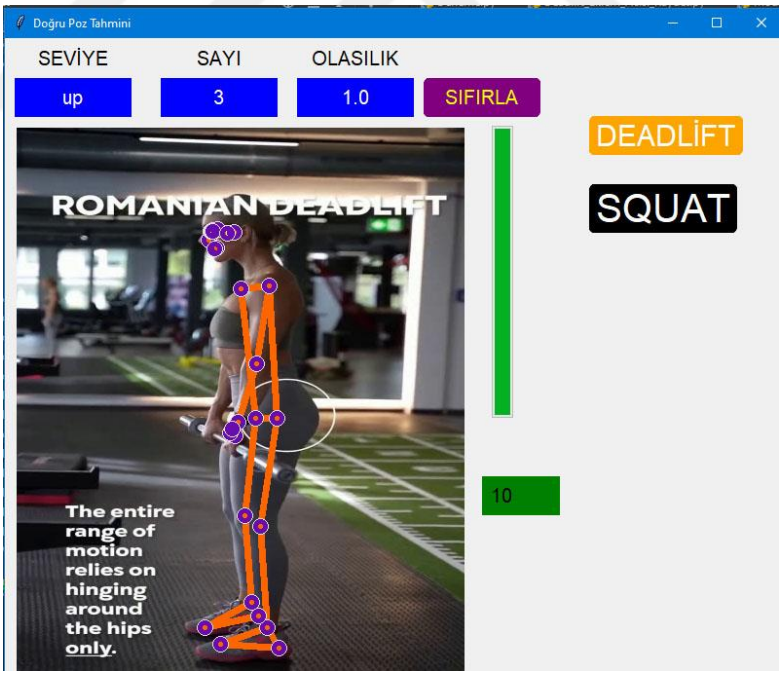

Şekil 2.6. Model arayüz tasarım ekranı

3. BULGULAR VE TARTIŞMA

3.1. Poz Eklem Noktalarının Hesaplanması

Uygulamamızda kullandığımız hem ağırlık kaldırma hem de çömelme için doğru duruş koşullarının karşılanıp karşılanmadığını belirlemek için MediaPipe eklem noktaları modelinin temel noktalarını kullandık. Bu temel noktalar Şekil 3.1'de görüleceği üzere sağ ve sol kalçanın açıları farklı olabileceğinden kalçanın ortalama kalça açısı olarak iki değeri baz alarak formülüze ettik. Şekil 3.2'de ise doğru çömelme (squat) ve de ağırlık kaldırma (deadlift) duruşunu doğrulamak için eklem noktalarının istenilen koşullardaki kilit noktalarını baz alarak gerekli işlemleri yaptık.

Şekil 3.1. Belli kamera açısından elde edilen kinematik değerler

Uygulamamızda sol kalça açısı (sol diz(25), sol kalça(23), sol omuz(11)), Sağ kalça açısı (sağ diz(26), sağ kalça(24), sağ omuz(12)) elde edilen veriler ışığında şu şekilde formüle edilir:

Kalça açısı: (sağ kalça açısı+sol kalça açısı)/2 (3.1)

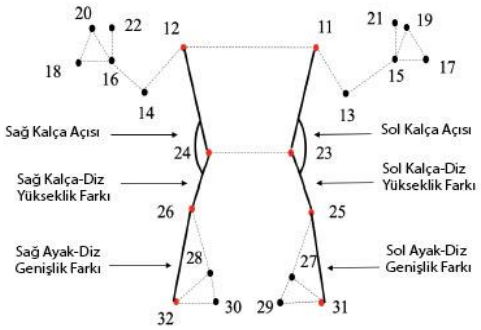

Şekil 3.2. Ağırlık kaldırma doğru postür geçerliliği için eklem noktaları

Ayrıca çömelme egzersizinin doğru duruş koşullarını karşılayıp karşılamadığını belirlemek için de MediaPipe poz tahmin kütüphanesinin eklem noktası modelinin temel

noktaları kullanılarak sol ve sağ dirsek açıları farklı olabileceğinden iki değerin ortalaması dirsek açısı olarak kullandık. Vücut açısı da yine sağ ve sol kalça açılarının ortalama değeri hesaplanarak Şekil 3.3, doğru çömelme duruşunu doğrulamak için koşullarda kullanılan kilit noktaları baz alarak gerekli işlemleri gerçekleştirdik.

Uygulamada sol dirsek açısı (sol bilek(15), sol dirsek(13), sol omuz(11)) ile sağ dirsek açısı (sağ bilek(16), sağ dirsek(14), sağ omuz(12)) elde edilen veriler ışığında şu şekilde formüle edilir:

Dirsek Açısı= (Sağ Dirsek Açısı+Sol Dirsek Açısı)/2 (3.2)

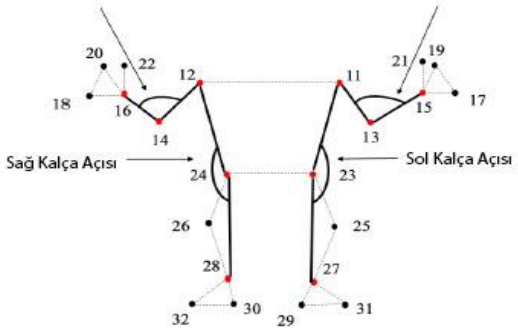

Şekil 3.3. Çömelme Doğru Postür Geçerliliği İçin Eklem Noktaları

3.2. Açı Hesaplama

Uygulamamızda İnsan Poz Tahmini yapmak için, üç nokta arasındaki açıyı hesaplamak için x, y ve z koordinatları kullanılmaktadır. Şekil 3.4, üç nokta arasındaki açıyı göstermektedir. Üç nokta A, B ve C olsun. Ve elde edilecek açı θ 'dir. θ'yi elde etmek için vektörlerin iç çarpımını kullandık.

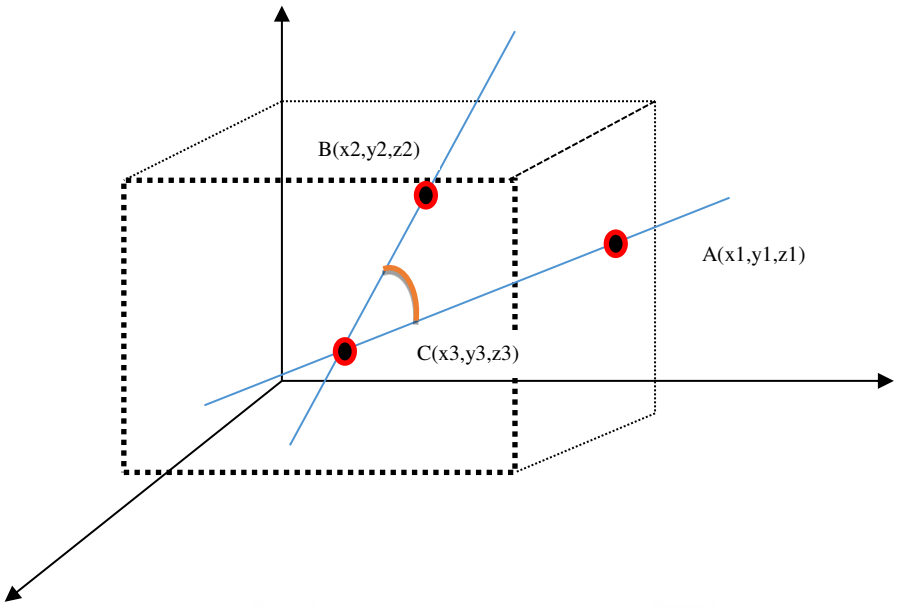

Şekil 3.4. Üç nokta arasındaki açı

Bakış noktası C noktası ve bitiş noktası A olan vektöre $\underset{CA}{\rightarrow}$, bakış açısı C noktası ve bitiş noktası B olan vektöre $\underset{CB}{\rightarrow}$ denir. $\underset{CA}{\rightarrow}$ ve $\underset{CB}{\rightarrow}$ vektörleri (3.3, 3.4) olarak tanımlandığı şekilde gerekli hesaplamaları yaptık.

$$\underset{CA}{\rightarrow} = (x1 - x3, y1 - y3, z1 - z3) \tag{3.3}$$

$$\underset{CB}{\rightarrow} = (x2 - x3, y2 - y3, z2 - z3) \tag{3.4}$$

Böylece θ, vektörün iç formülü yerine konarak elde ederek bu şekilde üç nokta arasındaki açı (3.5, 3.6) olarak tanımlayarak açısal işlemleri gerçekleştirdik.

$$\underset{CA}{\rightarrow} . \underset{CB}{\rightarrow} = \left|\underset{CA}{\rightarrow}\right| \left|\underset{CA}{\rightarrow}\right| \cos(\theta) \tag{3.5}$$

$$\theta = \cos^{-1} \frac{\overrightarrow{CA} \cdot \overrightarrow{CB}}{\left|\overrightarrow{CA}\right| \left|\overrightarrow{CA}\right|} \tag{3.6}$$

3.3. İnsan Poz Tahmin Modellerinin Karşılaştırılması

Uygulamamız, özel bir eğitmene ihtiyaç duymadan egzersiz yapmayı kolaylaştıracağı gibi yanlış teknik nedeniyle yaralanmaları azaltma hedefi taşımaktadır. Bu amaç doğrultusunda uygulamamızda kullandığımız Mediapipe kütüphanesinin BlazePose modelinin diğer modellerle karşılaştırması yapılarak bu kütüphanenin

dezavantajlarının aksine avantajlarının olup olmadığı yönünde spor biyomekaniği alanında etkinliği irdelenmeye çalışılmıştır.

Yapmış olduğumuz geniş çaplı araştırmalar neticesinde İnsan Poz Tahmini kitaplıklarında anahtar nokta algılama yaklaşımı olan yukarıdan aşağıya ve aşağıdan yukarıya yöntemlerin açıklanması gerekliliği ortaya çıkmaktadır. Yukarıdan aşağıya yöntemde, önce verilen girdiden kişi sayısı belirlenir ve her kişi sırasıyla ayrı bir sınırlayıcı kutuya atanır [108]. Daha sonra, her sınırlayıcı kutuda anahtar nokta tahmini gerçekleştirilir. Yukarıdan aşağıya yöntemin aksine, aşağıdan yukarıya yöntem, ilk adımda anahtar nokta tespitini gerçekleştirir [109]. Bundan sonra, anahtar noktalar insan örneklerine göre gruplandırılır. Aşağıdaki çizelge 3.1'de insan poz tahmini kitaplıklarının kullandıkları yöntemler ve diğer özellikleri tanımlanmaktadır.

Çizelge 3.1. İnsan Poz Tahmini Kütüphanelerinin Genel Özellikleri

Kütüphaneler	**Poz Tipi**	**Maksimum Anahtar Nokta Sayısı**	**Metot**	**Vücut Bölümlerindeki Anahtar Pozisyonları**	**Çıkış Tarihi**
PoseNet [110]	Tekli ve çoklu kişi	17	Yukarıdan aşağıya	Baş, üst gövde, alt gövde	2017
MoveNet [111]	Tekli ve çoklu kişi	17	Aşağıdan yukarıya	Baş, üst gövde, alt gövde	2021
OpenPose [112]	Tekli ve çoklu kişi	135	Aşağıdan yukarıya	Yüz, el, baş, üst gövde, alt gövde	2017
MediaPipe Pose [113]	Tekli ve çoklu kişi	33	Yukarıdan aşağıya	Baş, üst gövde, alt gövde	2020

Günümüzde İnsan Poz Tahminine olan talep arttıkça birçok iskelet tabanlı İnsan Poz Tahmin algoritması geliştirilmiş ve araştırmacılara kullanım kolaylığı sağlamak için İnsan Poz Tahmin algoritmaları kitaplıklar halinde paketlenme işlemine tabi tutulmuştur. İnsan Poz Tahmini kitaplıklarının performansı, entegre oldukları farklı pratik uygulamaların güvenilirliğini sağlamak açısından önemli olduğu hususunda **Jen-Li Cung ve arkadaşlarının "Comparative Analysis of Skeleton-Based Human Pose Estimation**" isimli çalışmalarında PoseNet, MoveNet, OpenPose ve MediaPipe Pose olmak üzere kamera konumu, kendi kendini kapatma gibi zorluklar bulunmasına karşın görüntülere ve videolara dayalı olarak dört adet son teknoloji ürünü İnsan Poz Tahmini kitaplığının karşılaştırmalı bir analizini gerçekleştirmişlerdir.

Bahsi geçen deneyde kullanılan görüntü ve video kaynaklarının veri kümeleri sırasıyla Microsoft Common Object in Context (COCO) [114] ve Penn Action [115] veri kümeleri kullanılmıştır.

COCO, büyük ölçekli bir nesne algılama, segmentasyon ve altyazı oluşturma veri kümesi olup insan poz tahmini için yapılan deneylerde yaygın olarak kullanılmaktadır. 330.000 görüntü, 1,5 milyon nesne örneği, 80 nesne kategorisi, 91 malzeme kategorisi ve 250.000 insandan oluşan bir veri setini oluşturmaktadır. Bu veri setinin çeşitli sürümlerinin bulunmasının ötesinde bir kişinin her örneğinin 17 anahtar nokta ile etiketlendiği vücut anahtar noktası tespiti için ek açıklamalar sağlamaktadır. Penn Action ise 2326 video sekansından oluşan bir video veri setidir.

Yapılan deneyde, İnsan Poz Tahmini kitaplıklarının performansını değerlendirmeden önce, her iki veri kümesindeki ilgisiz verileri elemek için veri ön işlemesi yapılmıştır. COCO veri kümesinde, tek bir kişinin görüntüleri, birden çok kişinin görüntüleri ve insan olmayan görüntüler olmak üzere üç farklı görüntü türü bulunduğundan, deneyde yalnızca tek kişilik İnsan Poz Tahminine odaklandığı için birden çok kişinin ve insan olmayan görüntülerin filtrelenmesi sağlanmıştır. Ayrıca, insan vücudunun yalnızca yarısının görüldüğü görüntüler de elenerek, deney için 1100 görüntü seçilmiştir.

Yapılan deneyde, dört İnsan Poz Tahmini kitaplığının performansını karşılaştırmak için, insan vücudundan yaygın olarak algılanan 17 anahtar nokta, veri kümesi tarafından sağlanan 17 ek açıklama ile eşleştirilmiştir. Bu eşleştirme, karşılaştırma için temel gerçek olarak kabul edilmiştir.

Penn Action videoları için, video karelerindeki insan vücudunun üst yarısından oluşan gitar çalma eylemi gibi bazı eylemler çıkartılarak toplamda 14 eylem üzerinde durulmuştur. Bu nedenle adil bir karşılaştırma yapmak için baş kısımları deneylerden çıkarılmıştır. Bu şekilde, kalan 12 anahtar nokta, temel gerçek nokta olarak kullanılmıştır.

İnsan poz tahmini kitaplıklarının kalitesinin değerlendirilmesi ölçütleri önemli bir rol oynadığından deneyde ayrıca değerlendirme metriği olarak **Tespit Edilen Eklemlerin Yüzdesi** formülü ile algılama doğruluğunu ölçmek için temel gerçek değer ile piksel cinsinden tahmin edilen anahtar noktalar arasındaki Öklid mesafesi kullanılarak formülüze edilmiştir. Tespit edilen eklemlerin yüzdesi formül sonucu çıkan değer ne kadar yüksek olursa, doğruluk oranı da o kadar yüksek olduğu sonucu ele alınmıştır. Formül şu şekildedir:

$$d(x-y) = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2}\text{piksel} \quad (3.7)$$

$$gövde\ çapı = \sqrt{(x_{ls} - x_{rh})^2 + (y_{ls} - y_{rh})^2} \quad (3.8)$$

$$tespit\ edilen\ eklem\ yüzdesi = \frac{\sum_{i=1}^{n} bool(d_i < 0.05 * gövde\ çapı)}{n} \quad (3.9)$$

Temel gerçek noktalar (x_1, y_1) ile tahmin edilen anahtar noktalar (x_2, y_2) arasındaki Öklid mesafesi d(x, y)'nin hesaplanması Denklem (3.7)'de gösterilmiştir. Gövde çapı değeri için tespit edilen eklem yüzde eşiği 0.05'tir. Gövde çapı, Denklem (3.8)'de gösterildiği gibi koordinatlar (x_{ls}, y_{ls}) ve (x_{rh}, y_{rh}) olarak temsil edilen sol omuzdan sağ kalçaya Öklid mesafesi için hesaplanmıştır. Öngörülen anahtar noktalar ile temel gerçeklik anahtar noktaları arasındaki d(x, y) şayet eşikten küçük olduğunda, tahmin edilen anahtar noktaların doğru bir şekilde tespit edildiği kabul edilmiştir. Bu nedenle, tespit edilen eklem, Denklem (3.9)'te gösterildiği gibi hesaplanmaya tabi tutulmuştur. Ayrıca n değeri ise tahmin edilen eklemlerin toplam sayısını temsil etmektedir.

Bu şekilde belirtilen kıstaslar eşliğinde insan poz tahmini kitaplıklarının performanslarını değerlendirmek için üç deney gerçekleştirilmiştir. Görüntü veri kümesi için, her görüntü için her bir insan poz tahmini kitaplığının performansını karşılaştırmak amacıyla bir deney gerçekleştirilmiştir. Video veri kümesi için ilk deney, her bir video karesi için her bir insan poz tahmini kitaplığının performansını karşılaştırmak üzere yürütülürken ikinci deney, her bir insan poz tahmini kitaplığının her bir eylemin her bir vücut parçası için ne kadar iyi performans gösterdiğini araştırmaktadır.

Her görüntü için tespit edilen eklem değeri, her görüntü için insan poz tahmini kitaplıklarının performansını karşılaştırmak üzere hesaplanmış olup sonuçlar aşağıdaki şekilde kutu grafiği olarak sunulmuştur.

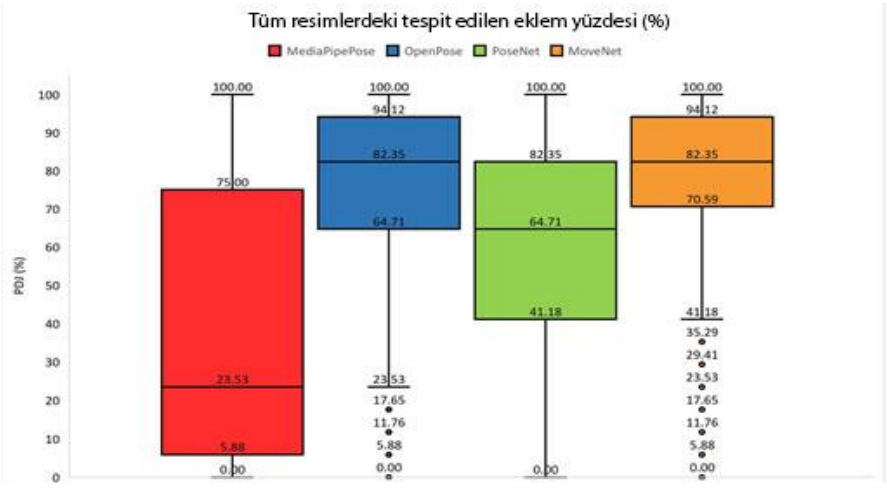

Şekil 3.5. Veri setindeki resimlerin tespit edilen eklem sayısının kutu grafiği

Aşağıdaki Çizelge 3.2'de, yapılan deneyde insan poz tahmini kitaplıklarının performansını %0, %0–25, %25–50, %50–75 ve %75–100 dahil olmak üzere her grup, belirli tespit edilen eklem değerleri aralığında insan poz tahmini kitaplığı tarafından tanınan görüntü sayısını göstermektedir. MoveNet, 5 görüntüyü içeren tespit edilen eklem yüzdesi %0'a ulaşarak en az sayıda görüntüye sahip iken OpenPose %0 ile 8 görüntü içererek ikinci en düşük görüntü sayısına ulaşmıştır. Akabinde onu PoseNet 30 görüntü ve MediaPipe Pose 240 görüntü izlemiştir. %0–25 aralığında en az görüntü sayısına 33 görüntü ile MoveNet sahipken onu 87 görüntü ile OpenPose, 128 görüntü ile PoseNet ve 342 görüntü ile MediaPipe Pose izlemiştir. Aynı şekilde 68 görüntü ile MoveNet, %25-50 aralığında tespit edilen eklem yüzdesine ulaşan en az sayıda görüntüye sahip olduğu ortaya çıkmıştır.

Deneyde MoveNet, son iki grupta en yüksek görüntü sayısına (%50-100) aralığında sahip olduğu için 994 görüntüden tespit edilen anahtar noktaların %50'den fazlasının temel gerçekle doğru bir şekilde eşleştiğini göstererek üstün performans sergilemiştir. Buna karşılık, MediaPipe Pose birinci ile üçüncü gruplarda (%0-50) en yüksek sayıda görüntüye sahip iken (%50-100) aralığında en düşük performansı ortaya sergilemiştir. Toplam 698 görüntüde, tespit edilen kilit noktaların %50'den azı temel gerçekle doğru şekilde eşleştirilmiştir. Genel olarak, MoveNet 1.100 görüntüden 747'sinin MoveNet tarafından %75-100 anahtar noktayı algılayarak en yüksek performansı göstermiştir. Buna karşılık MediaPipe Pose, %75-100 aralığında yalnızca en düşük görüntü sayısını elde ettiği için en düşük performansı göstermesine karşılık %0 grubunda en yüksek görüntü sayısını elde etti. OpenPose, MoveNet'ten biraz daha düşük olan ikinci en yüksek performans, PoseNet ve MediaPipe Pose ise sırasıyla üçüncü ve dördüncü en yüksek performansı elde etmiştir.

Çizelge 3.2. Tespit edilen eklem yüzdesinin her bir belirli orandaki insan poz tahmini tarafından tespit edilen resim sayısı

	0% < TEY ≤ 25%		**25% < TEY ≤ 50%**	**50% < TEY ≤ 75%**	**75% < TEY ≤ 100%**
MediaPipe Poz	240	342	116	127	275
OpenPoz	8	87	85	252	668
PoseNet	30	128	185	323	434
MoveNet	5	33	68	247	747

Deneyde kullanılan video veri setleri için ise her eylem için ortalama tespit edilen eklem yüzdesi hesaplanıp değerleri Şekil 2.10'daki gibi gösterilmiştir. Üç insan poz tahmini kitaplığı arasında MoveNet (turuncu kutu), MediaPipe Pose (kırmızı kutu) ve PoseNet (yeşil kutu) minimum, birinci çeyrek, medyan, maksimum ve üçüncü çeyrek değerleri açısından benzer performanslar elde ettiği ortaya çıkmıştır. MediaPipe Pose (kırmızı kutu) maksimum ve medyan değerler açısından en yüksek tespit edilen eklemlerin yüzdesine sahipken, MoveNet (turuncu kutu) minimum, birinci ve üçüncü çeyrek değerleri açısından en yüksek puanı almıştır. OpenPose (mavi kutu), tüm çeyrekler için en düşük değerlerle zayıf bir performans göstermiştir.

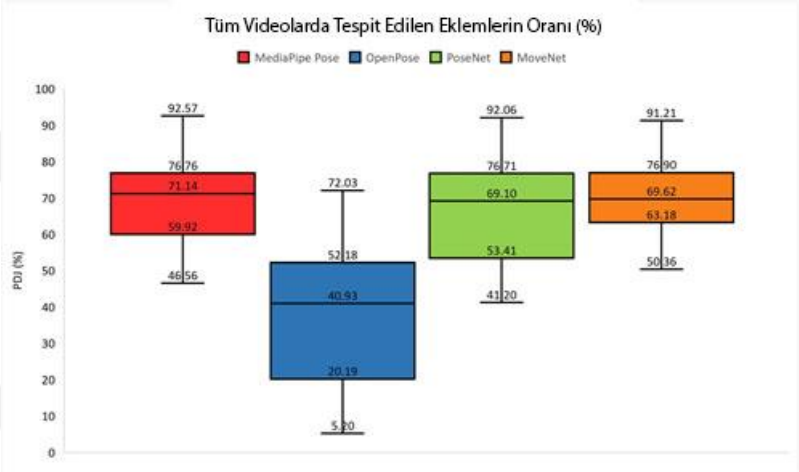

Şekil 3.6. Video veri setinde tespit edilen eklemlerin yüzdesi

Her eylem için insan poz tahmini kitaplıklarının performansını daha iyi anlamak için, her kitaplığın her eylem için en yüksek ve en düşük ortalama tespit edilen eklem yüzdesi değerleri Çizelge 3.3'te vurgulanmıştır. 14 eylem arasında, kitaplıklar en iyi performansı Eylem 8'deki Atlama eylemi ile elde etmiştir. MediaPipe Pose, tüm eylemler arasında en düşük performansı Eylem 12'deki Squat (Çömelme) hareketi ile göstermiştir. Tesadüfen, hem OpenPose hem de PoseNet, Eylem 2'deki Halter Kaldırma'da en düşük performansı gösterirken öte yandan MoveNet, Eylem 4'teki bowlingte en düşük performansı göstermiştir. Tüm eylemler için genel ortalama tespit edilen eklem yüzdesi değerleri Çizelge 3.3'ün son satırında vurgulanmıştır. En yüksekten en düşüğe performans sıralaması MoveNet, MediaPipe Pose, PoseNet ve OpenPose şeklindedir. MoveNet, MediaPipe Pose ve PoseNet arasındaki performanslar %65 ile %70 arasında düşme eğiliminde iken OpenPose'un performansı, yaklaşık %37 oranında diğerlerinden çok daha düşük seviyededir. MediaPipe Pose, MoveNet'ten daha yüksek olan %75 ile

%100 arasında tespit edilen eklem yüzdesi elde ederek 5 eylemi başarıyla tespit etmesine rağmen, genel performansı MoveNet'inkinden %1,38 daha düşük seviyededir.

Çizelge 3.3. Her eylemde Tespit Edilen Eklem Yüzdesi genel ortalaması (%).

	MediaPipe Pose	**OpenPose**	**PoseNet**	**MoveNet**
Eylem 1	66.62	39.94	68.47	68.70
Eylem 2	48.38	5.20	41.20	58.68
Eylem 3	74.21	52.35	77.55	80.58
Eylem 4	48.92	21.04	56.69	53.95
Eylem 5	76.34	45.44	72.34	75.67
Eylem 6	79.00	54.71	77.49	81.42
Eylem 7	72.10	44.17	69.72	69.31
Eylem 8	92.57	72.03	92.06	91.21
Eylem 9	78.03	35.98	76.45	71.85
Eylem 10	63.59	14.11	48.66	66.73
Eylem 11	66.32	17.63	54.89	64.68
Eylem 12	46.56	23.93	48.97	50.36
Eylem 13	75.72	52.12	72.99	74.79
Eylem 14	70.17	41.91	65.82	69.93
Ortalama Tespit Edilen Eklem Yüzdesi (%)	68.47	37.18	65.95	69.85

*Yeşil kelimeler, tüm eylemler arasında her bir insan poz tahmini kitaplığının en yüksek Tespit Edilen Eklem Yüzdesini temsil etmektedir.

*Kırmızı kelimeler, tüm eylemler arasında her bir insan poz tahmini kitaplığının en düşük Tespit Edilen Eklem Yüzdesini temsil etmektedir.

*Yeşil hücre, ortalama Tespit Edilen Eklem Yüzdesindeki en yüksek değeri temsil etmektedir.

*Kırmızı hücre, ortalama Tespit Edilen Eklem Yüzdesindeki en düşük değerleri temsil etmektedir.

Deneyde ayrıca, her eylem için kitaplığın sıralaması Çizelge 3.4'te listelenmiştir. MediaPipe Pose, 14 eylemin 7'sinde en yüksek performansı, 3 eylemde en yüksek ikinci performansı ve 4 eylemde en yüksek üçüncü performansı elde ederken MoveNet, 6 eylemde en yüksek performansı, 5 eylemde ikinci en yüksek performansı ve 3 eylemde üçüncü en yüksek performansı etmiş, PoseNet ise yalnızca Eylem 4'te (bowling) en yüksek performansı, 6 eylemde ikinci en yüksek performansı ve 7 eylemde üçüncü en yüksek performansı göstermişken OpenPose, tüm HPE kitaplıkları arasında tüm eylemlerde en düşük performansı gösterdiği ortaya çıkmıştır.

Çizelge 3.4. Her bir Eylemdeki Tespit Edilen Eklem Yüzdesinin Ortalaması

Eylemler	Derece 1	Derece 2	Derece 3	Derece 4
Eylem 1	MoveNet	PoseNet	MediaPipe Pose	OpenPose
Eylem 2	MoveNet	MediaPipe Pose	PoseNet	OpenPose
Eylem 3	MoveNet	PoseNet	MediaPipe Pose	OpenPose
Eylem 4	PoseNet	MoveNet	MediaPipe Pose	OpenPose
Eylem 5	MediaPipe Pose	MoveNet	PoseNet	OpenPose
Eylem 6	MoveNet	MediaPipe Pose	PoseNet	OpenPose
Eylem 7	MediaPipe Pose	PoseNet	MoveNet	OpenPose
Eylem 8	MediaPipe Pose	PoseNet	MoveNet	OpenPose
Eylem 9	MediaPipe Pose	PoseNet	MoveNet	OpenPose
Eylem 10	MoveNet	MediaPipe Pose	PoseNet	OpenPose
Eylem 11	MediaPipe Pose	MoveNet	PoseNet	OpenPose
Eylem 12	MoveNet	PoseNet	MediaPipe Pose	OpenPose
Eylem 13	MediaPipe Pose	MoveNet	PoseNet	OpenPose
Eylem 14	MediaPipe Pose	MoveNet	PoseNet	OpenPose

Çizelge 3.4'teki sonuçlar, dört HPE kitaplığının tüm eylemler arasında Eylem 8'de (atlama hareketleri) en iyi performansı elde ettiğini gösterdiğinden, daha yakından bir analiz gerçekleştirilmiştir. MediaPipe Pose, MoveNet ve PoseNet yaklaşık %92'ye ulaşırken OpenPose, Eylem 8 için yaklaşık %72'ye ulaşmıştır. Tablo 5, kapanıklık ve uygun olmayan kamera konumunun olmadığı Eylem 8'in video çerçevesini ve algılama sonuçlarını göstermektedir. Bu nedenle, anahtar nokta tespitini etkileyen daha az zorluk olduğunda İnsan Poz Tahminin performansının daha iyi olduğu sonucuna varılmıştır. Öte yandan, daha fazla zorluk olduğunda İnsan Poz Tahmini performansının düştüğü deneyde gözlemlenmiştir. MediaPipe Pose, Eylem 12'de (çömelme) en düşük performansı gösterirken OpenPose ve PoseNet, Eylem 2'de (bench press) en kötü performansı, MoveNet ise Eylem 4'te (bowling) en düşük performansı göstermiştir.

Genel karşılaştırma bakımından deneyde kullanılan MoveNet kitaplığı, diğer İnsan Poz Tahimini kitaplıklarıyla karşılaştırıldığında minimum, ilk çeyrek ve üçüncü çeyrek değerleri açısından en yüksek Tespit Edilen Eklem Yüzdesi değerlerini elde etmiştir. Tüm eylemlerde MoveNet için Tespit Edilen Eklem Yüzdesi değerleri %50'den fazla iken, MediaPipe Pose, maksimum ve medyan değerler açısından en yüksek Tespit Edilen Eklem Yüzdesi değerlerine ulaşmıştır. Tüm İnsan Poz Tahmini kitaplıkları, daha az zorluktan oluşan tüm eylemler arasında Eylem 8'de (atlama) üstün performans elde etmiştir. İnsan Poz Tahmini kitaplıklarının her eylemdeki sıralamasına göre, MediaPipe

Pose 7 eylemde en yüksek performansı elde ederken MoveNet 6 eylem ve PoseNet ise 1 eylemde en yüksek performans elde etmiştir. Ancak OpenPose, tüm eylemlerde en düşük performansı göstermiştir. MoveNet en yüksek ortalama Tespit Edilen Eklem Yüzdesi değerini elde ederken, OpenPose en düşük ortalama Tespit Edilen Eklem Yüzdesi değerini göstermiştir. Ancak MediaPipe Pose ve PoseNet, bu üç kitaplık için ortalama Tespit Edilen Eklem Yüzdesi değerleri %65-68 aralığında olduğu için MoveNet ile rekabetini sürdüğü gözlemlenmiştir.

Sonuç olarak yapılan deneyde MediaPipe Pose, görüntü veri kümesindeki en düşük genel performansa sahip iken video veri kümesinde iyi bir performans sergileyip genel performansı en iyi genel performans gösteren MoveNet'ten biraz daha düşük olmasına rağmen 14 eylemden 7'sinde en iyi performansı elde etmiştir.

İnsan Poz Tahmini kitaplıklarının performansı, uygun olmayan kamera konumu ve görüntü netliği etkisi gibi zorluklarla kısıtlandığında düştüğü bilinmektedir. Ancak bu deneyin sonuçlarına göre, MoveNet hem görüntüleri hem de videoları algılamak için uygun olmasının ötesinde MediaPipe Pose, videoları algılamak bakımından daha uygun olduğu ortaya çıktığı sonucuna varılmıştır [116].

Ayrıca başka bir çalışmada yine Mediapipe kütüphanesi BlazePose modelinin kalitesi temel olarak OpenPose ile karşılaştırıp değerlendirmek amacıyla 1000 görüntüden oluşan AR veri seti ile Yoga Dataseti tutarlılık ve değerlendirme için OpenPose ve BlazePose'un ortak bir alt kümesi olan 17 puanlı MS Coco topolojisi kullanılarak Doğru Noktaların Yüzdesi formülü ile iki model eğitilmiştir. Çizelge 3.5'te görüleceği üzere modeller, Arttırılmış Gerçeklik (AR) veri kümesinde OpenPose modelinden biraz daha kötü performans gösterse de, BlazePose Full, Yoga/Fitness kullanım durumlarında OpenPose'dan daha iyi performans gösterdiği gözlemlenmesinin yanı sıra aynı zamanda, BlazePose istenen kaliteye bağlı olarak, 20 çekirdekli bir masaüstü işlemcisindeki OpenPose'a kıyasla tek bir orta seviye telefon CPU'sunda 25-75 kat daha hızlı performans gösterdiği ortaya çıkmıştır [117].

Çizelge 3.5. BlazePose ve OpenPose Karşılaştırılması

Model	**FPS**	**AR Dataset, PCK@0.2**	**Yoga Dataset, PCK@0.2**
OpenPose (yalnızca vücut)	0.4	**87.8**	83.4
BlazePose Full	10	84.1	**84.5**

BlazePose Lite	**31[2]**	79.6	88.6

3.2. Uygulama Performans Değerlendirmesi

Yaptığımız uygulama spor biyomekaniği ölçütlerine uygun olarak ağırlık kaldırma (deadlift) ve çömelme (squat) spor egzersizleri video dosyasından gelen veriler ışığında Mediapipe Poz Tahmin Kütüphanesi aracılığıyla kinematik açıları hesaplanarak hareketler "yukarı(up)" ve "aşağı(down)" olmak üzere etiketleme yapılarak csv dosya türü olarak kayedildi. Akabinde ağırlık kaldırma (deadlift) egzersizi için oluşturulan csv formatındaki dosyada **7795 satır ve 33 sütundan oluşan veri seti** makine öğrenme algoritmalarından Lojistik Regresyon, Katı (Rijit) Regresyon, Rastgele Orman Sınıflandırıcısı ve Eğim Destekli (Gradient Boosting) Sınıflandırıcısı olmak üzere dört makine öğrenme algoritması olarak eğitime tabi tutuldu. CSV veri seti üzerinde eğitilen bir sınıflandırma algoritmasının performans ölçümlemesi karmaşıklık matrisi (confusion matrix) kullanılarak ortaya çıkan hataların değerlendirilmesi ve doğruluk oranlarının en efektif biçimde ortaya konulabilmesi için başlıca metrikler kullanıldı. Bu metriklerden doğruluk (accuracy), hassaslık (precision), hatırlatma (recall) skorlarının karşılaştırılması yapılarak 4 sınıflandırıcı bakımından veriler eğitime tabi tutuldu. Bu 4 makine öğrenme algoritmalarından en iyi sonucu veren Rastgele orman sınıflandırma algoritması kapsamında veriler yaklaşık **8,22 Megabyte** yer kaplayan csv dosyasının daha küçük bir formata ve de makine öğrenme algoritmalarına uygun bir hale getirilmesi için dosyayı 20 kat daha küçük hale getirmek amacıyla pickle dosyası olarak kaydedildi. Bu şekilde elde edilen dosya **219 Kilobyte** yer kaplayarak makine öğrenme modeline uygun hale getirildi.

Eğitilen modellerden karmaşıklık matrisi metriklerine göre en iyi sonucu veren sınıflandırma algoritması kullanılarak test edildi. Akabinde kameralardan elde edilen verilerle spor egzersizlerinin doğruluğunu değerlendirmek için bir arayüz geliştirildi. Ayrıca, spor egzersizinin kinematik açıları elde edilen veriler ışığında 33 eklem noktası baz alınarak pickle dosyası olarak kaydedilen makine öğrenmesi modeli bağlamında işlemci ve bellek kullanımı açısından performansı test edildi.

Bu şekilde test edilen iki yaklaşımdan elde edilen analizlerin değerlendirilmesi sürecinde kinematik verilerin işlemci ve bellek performansları ile kamera veya video fps değerlerinin karşılaştırıldığını ve bu karşılaştırma sonucunda makine öğrenmesi yönteminin aşağıdaki grafiklerde de görüleceği üzere daha iyi bir performans gösterdiğini açık bir şekilde gözler önüne sermektedir.

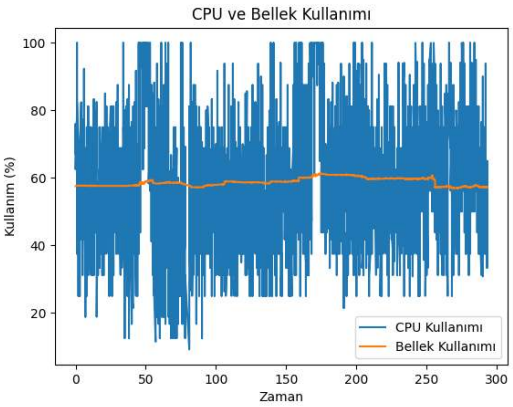

Şekil 3.7. Kinematik açı ölçümleri performansı

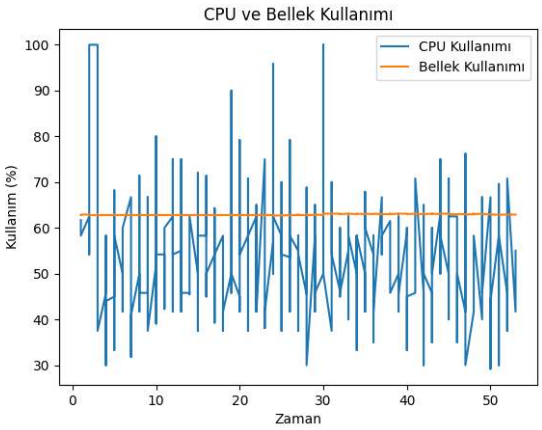

Şekil 3.8. Makine öğrenmesi performansı

4. SONUÇ VE ÖNERİLER

Ticari yazılımların olanak ve yeterlilikleri ile sınırlı kalmak, sporcu hareketlerinin analizini kolaylaştıran teknolojik olanaklar sayesinde izlenmesi kolaylaşan ancak analiz edilmesi karmaşıklaşan bir olgudur. Bu nedenle sporcu hareketlerinin analizi için kullanılan yöntemlerin incelenmesi, farklı görüntü alımı ve analiz süreçlerinin entegre edilmesiyle mümkündür.

Bu bağlamda, sporcu hareketlerinin analiz edilmesi için geliştirilen yeni yöntemler ve teknolojiler sürekli olarak araştırılmakta ve geliştirilmektedir. Özellikle son yıllarda, yapay zeka, makine öğrenmesi, derin öğrenme ve benzeri teknolojilerin sporcu hareketlerinin analizinde kullanılmaya başlandığı görülmektedir. Bu teknolojiler sayesinde, sporcu hareketlerinin daha ayrıntılı ve kapsamlı bir şekilde analiz edilmesi, analiz sonuçlarının daha doğru ve güvenilir bir şekilde elde edilmesi mümkün olmaktadır.

Bu amaç doğrultusunda hazırlanan tez çalışmasında, derin öğrenme tabanlı MediaPipe Poz Tahmin modeli diğer modellerle kıyaslanarak gerçek zamanlı görüntülerden elde edilen insan poz tahmini verilerini, spor biyomekaniği alanında spor aktivitelerinin doğruluk oranını ne derecede tespit ettiği yönünde hazırlanmıştır. Bu amaçla, MediaPipe Poz Tahmin modeli kullanılarak toplanan veriler, makine öğrenme algoritmaları kapsamında uygulamalı olarak ele alınmıştır.

Aynı zamanda yapılan uygulama, spor biyomekaniği alanında geleneksel yöntemlerin yanı sıra, derin öğrenme tekniklerinin de kullanılabileceğini göstermektedir. Bu yeni yaklaşımın sporcuların performansını ve sakatlanma riskini değerlendirmek için kullanılabilirliğini ve doğruluğunu artırmayı amaçlamaktadır.

Yapılan uygulama, "Windows" işletim sistemi platformunda, "Python" programlama dili kullanılarak "PyCharm" geliştirme ortamı aracı ile oluşturulmuştur. Uygulama, gerçek zamanlı ya da video ve resimlerden insan poz tahmini yapmak için MediaPipe Poz Tahmin modülü ile ilk başta sınıflandırma yapmak amacıyla Python'da bilimsel hesaplama yapmak için Numpy kütüphanesi, veri analizi ve manipülasyonu için Pandas kütüphanesi gibi kütüphaneler kullanılarak American Kuvvet ve Kondisyon Derneği verilerine göre çömelme ve ağırlık kaldırma olarak ele aldığımız egzersizlere bağlı olarak uygulama gerçekleştirilmiştir. Bu amaçla ele aldığımız egzersizlerin performansını iyileştirmek amacıyla Python'da bilimsel işlemler yapmak amacıyla sıklıkla kullanılan Scikit-Learn kütüphanesinden faydalanılmıştır.

Bu kütüphaneler aracılığıyla MediaPipe Poz Tahmin kütüphanesi kullanılarak elde edilen veri setine göre spor aktivitelerinin doğruluk oranı CSV formatındaki kayıt edilen verilerle makine öğrenimi algoritmalarından Lojistik Regresyon, Katı (Ridge) Sınıflandırıcı, Rastgele Orman (Random Forest) Sınıflandırıcı ve Gradient Boosting (Eğim Destekleyici) Sınıflandırıcı Algoritmalarından faydalanarak performans yönünden karşılaştırılmaları amacıyla karmaşıklık matrisi metrikleri kullanılarak en uygun makine öğrenme algoritması seçilip model test aşaması sonrasında görsel bir arayüz üzerinden spor aktivitelerinin doğruluğu uygun ekran yönergeleri doğrultusunda elde edilmeye çalışılmıştır.

Tüm bu adımlar öncesinde, spor biyomekaniği alanında ağırlık kaldırma (deadlift) ve çömelme (squat) spor aktivitelerinin doğruluk oranı yapılan çeşitli literatür çalışmalarındaki genel kabul edilen görüşler doğrultusunda sosyal medya aracılığıyla bu spor dallarına ilişkin yapılan videolar kaydedilip video dosyalarından görüntü çerçevelerini MediaPipe Poz Tahmini modülüne göre insan iskeletindeki 33 eklem noktası baz alınarak her görüntü için doğru etiketin belirlenmesi amacıyla videodaki spor hareketlerini "yukarı (up)" ya da "aşağı (down)" olarak belirli bir aktiviteyi kinematik veriler ışığında görüntüler sınıflandırılarak bir csv dosyasına kaydı gerçekleştirildi.

Sonraki aşamada makine öğrenimi ile veri setimizi, yüzde seksen (%80) eğitim ve yüzde yirmi (%20) test verileri olarak ikiye ayırarak, eğitim verilerini modelin öğrenme sürecinde kullanılırken, test verilerini ise modelin performansının ölçülmesi için kullanılarak model oluşturuldu. Model oluşturulurken farklı sınıflandırıcı, regresyon ve kümeleme algoritmalarını scikit-learn kütüphanesini kullanarak en iyi performans gösteren algoritma elde edilmek amacıyla kullanıldı.

Veri seti test edildikten sonra her bir modelin performansı ölçülüp hata oranı gibi performans metrikleri hesaplanarak modelin gelecekteki tahminler için ve sonradan kullanılabilmesi amacıyla en uygun olan modelimiz, yaklaşık 20 kattan daha yüksek bir sıkıştırma algoritması sunan Pickle kütüphanesi ile ikili (binary) dosyalama sistemi ile modelimiz kaydedildi.

Veri seti ile oluşturulan modeli test etmek amacıyla ağırlık kaldırma ya da çömelme egzersizinde, kullanıcının yaptığı hareketler doğrultusunda yukarı kalkıp uygun bir şekilde çömeldiği sayıyı sayan bir mekanizma için grafik ara yüzü oluşturularak video akışı sırasında, doğru postürün %70 ve yukarı olması halinde en uygun olarak

kaydettiğimiz modelin tahmin ettiği regresyon tahmin olasılıkları dâhilinde başarımı test edildi.

Uygulanan sistemin başarımı test edilip doğru yürütüldüğü belirledikten sonra bir kişinin video akışından duruşunu tahmin etmek için doğru ağırlık kaldırma ya da çömelme formu ile egzersiz yapmasına yardımcı olmak amacıyla oluşturulan basit bir grafik arayüzü ile kullanıcı bir web kamerası kullanarak gerçek zamanlı olarak vücut pozisyonunu bileşenler, etiketler, düğmeler ve görüntüler aracılığıyla doğru hareketlerin yapılması esnasında geri bildirimleri ve istatistikleri görüntülemek için kullanıcının dikkatini dağıtmayacak şekilde belli bir düzene göre tanımlayarak oluşturulan makine öğrenimi modeli kullanılıp değerlendirerek ekrana yansıtmaktadır.

Bu şekilde oluşturulan program sayesinde kişiler profesyonel bir eğitmen yardımı olmadan evde ya da herhangi uygun bir ortamda doğru duruşla spor aktivitesini yapabilecek ve spor aktivitesinin ekonomik faydasını elde edebileceklerdir.

Ek olarak, duruş analizi için gereken sürenin kısa olması, kullanıcının anında geri bildirim alabilmesi gibi bir avantajı vardır.

Bu doğrultuda oluşturulan sistemimiz, özel bir eğitmene ihtiyaç duymadan egzersiz yapmayı kolaylaştıracağı gibi yanlış teknik nedeniyle yaralanmaları azaltacaktır. Ayrıca Mediapipe kütüphanesinin kullanmış olduğu BlazePose modelinin diğer modellerle karşılaştırması yapılarak bu kütüphanenin dezavantajlarının aksine avantajlarının fazla olması nedeniyle spor biyomekaniği alanında etkin bir şekilde kullanılabileceği yönünde olduğudur. Yapmış olduğumuz bu sistem ile ileride Android ya da IOS uygulamasına sistemi taşıyarak ve ilerleme izlemesi için kişiselleştirilmiş hesap oluşturarak daha geniş bir kitleye ulaşmaya yardımcı olunabilecektir. Ayrıca akıllı telefonlardaki derinlik sensörlerinin ortaya çıkması, pozu çok daha hassas bir şekilde tespit etme doğruluğunun iyileştirilmesine de ayrıca yardımcı olacak ve bu da karşılaştırma için daha doğru bir duruş oluşturmaya yardımcı olacağı kanaatiyle bu tez çalışması yapılmıştır.

KAYNAKLAR

[1] Ö. Çevik, Oğuzhanoglu, N. K., & Gülbas, Z., "Spor Yaralanmaları: Önleme ve Tedavi," *Türk fiziksel tıp ve rehabilitasyon dergisi,* vol. 64, no:3, pp. 266-273, 2018.

[2] I. Shrier, "Strategic Assessment of Risk and Risk Tolerance (StARRT) framework for return-to-play decision-making," *British journal of sports medicine,* vol. 49, no: 19, pp. 1311-1315, 2015.

[3] R. Bahr, & Holme, I, "Risk factors for sports injuries-a methodological approach," *British journal of sports medicine,* vol. 37, no: 5, pp. 384-392, 2003.

[4] Y. Çakır, "Biyomekaniksel Analizler," İstanbul Medipol Üniversitesi, Sağlık Bilimleri Enstitüsü, Yüksek Lisans Tezi, 2019.

[5] İ. Sarı, "Biyomekanik ve Fiziksel Performansın Biyomekanik Analizi," *Hacettepe Spor Bilimleri Dergisi,* vol. 25, no: 4, pp. 153-167, 2014.

[6] S. Mülayim, "Spor Biyomekaniği," *Ankara Üniversitesi Beden Eğitimi ve Spor Yüksekokulu Dergisi,* vol. 19, no: 3, pp. 183-192, 2019.

[7] Y. Güneri, "Biyomekanik, sağlık bilimleri ve spor bilimleri açısından önemi," *Türkiye Klinikleri Journal of Sports Sciences,* vol. 11, no: 1, pp. 16-22, 2019.

[8] D. A. Winter, *Biomechanics and motor control of human movement*, *John Wiley & Sons,* 2019.

[9] V. M. Zatsiorsky, & Seluyanov, V. N, *The mass and inertia characteristics of the main segments of the human body,* Biomechanics *VIII-B,* pp. 115-122, 1983.

[10] Elsevier. Kinesiology and Biomechanics for Humans, Athletics, and Robotics. 2019.

[11] A. Çilli, & S. Arıtan, Temel Bileşenler Analizi Yardımı ile Elde Edilen Daha Az Boyutlu Bir Hareket Modeli Oluşturulması, *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, vol. 23, no: 4, pp. 857-864, 2008.

[12] F. Muradlı, "*Derin Öğrenme Kullanılarak Görüntülerden İnsan Duruş Tespiti"*, Sakarya Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi, 2021.

[13] A. Özdemir, & A. Özdemir, MediaPipe Pose ile Evde Egzersiz Yaparken Duruş Tespiti ve Rehberlik Etme, *International Journal of Informatics Technologies*, vol. 14, no: 2, pp. 123-132, 2021.

[14] D. Ak, Biyomekanik Nedir?, Medium. https://medium.com/@denizak/biyomekanik-nedir-ffaa33144e5f, (accessed May, 17 2020)

[15] M. Nordin, & V.H. Frankel, *Basic biomechanics of the musculoskeletal system,* Lippincott Williams & Wilkins, 2012.

[16] N. Özkaya, M. Nordin, D. Goldsheyder, & D. Leger, *Fundamentals of biomechanics: equilibrium, motion, and deformation*, Springer Science & Business Media, 2012.

[17] M. Canlıdınç, & M. Güleşen, *Biyomekanik Analizde Yük Kaldirma Hareketi Yakalama Yöntemleri ve Örnek Uygulama*, Kırklareli Üniversitesi Mühendislik ve Fen Bilimleri Dergisi, vol. 7, no: 2, pp. 123-138, 2021.

[18] J. Hamill, K.M Knutzen, *Biomechanical Basis of Human Movement*, Wolters Kluwer Health/Lippincott Williams & Wilkins, 2009.

[19] M. Nordin, V.H. Frankel, *Basic Biomechanics of the Musculoskeletal System,* Lippincott Williams & Wilkins, 2012.

[20] D.A. Winter, *Biomechanics and motor control of human movement*, *John Wiley & Sons*, 2009.

[21] M, Nordin, V.H. Frankel, *Basic Biomechanics of the Musculoskeletal System,* Lippincott Williams & Wilkins, 2012.

[22] J. Tortora, Bryan H. Derrickson, *Principles of Anatomy and Physiology*, 14th edition, John Wiley & Sons, Inc. 2014.

[23] M. Nordin, & V.H. Frankel, *Basic biomechanics of the musculoskeletal system,* Lippincott Williams & Wilkins, 2012.

[24] J. Hamill, & K.M. Knutzen, *Biomechanical basis of human movement*, Lippincott Williams & Wilkins, 2009.

[25] D. Knudson, *Qualitative biomechanical principles*, In Qualitative Analysis in Sport and Physical Activity, pp. 27-50, Routledge, 2017.

[26] Whiting, C. William , et al. *Fundamentals of biomechanics in sport and exercise*. 2008.

[27] L.A. Fleisher, & S. Ludwig, *Clinical Pediatric Emergency Medicine,* Philadelphia, PA: Mosby/Elsevier, 2005.

[28] D.A. Winter, *Biomechanics and Biology of Movement*, Human Kinetics, 2009.

[29] M. Clark, S. Lucett & B. Sutton, (Eds.), *NASM essentials of sports performance training*, Lippincott Williams & Wilkins, 2012.

[30] *Biomechanics of Sport and Exercise (3rd Edition)* by Peter M. McGinnis, sayfa 22.

[31] *Long and Triple Jump Techniques and Training,* by Todd Lane and Boo Schexnayder, 2008.

[32] D. Knudson, *Biomechanics of exercise and sport*, Human Kinetics, 2013.

[33] *Biomechanical Principles of Sport Technique* by James Watkins and Mark Dinan.

[34] M.L. Anderson, *Motor control and learning: A behavioral emphasis,* Routledge, pp. 26-28, 2016.

[35] S. J. Hoffman, *Introduction to kinesiology: studying physical activity*. Human Kinetics, 2009.

[36] S. Muratlı, F. Toraman, and E. Çetin, Sportif hareketlerin biomekanik temelleri, *Ankara: Bağırgan Yayımevi*, 5, 2000.

[37] Muratlı ve diğerleri, (2000:6).- S. Muratlı, F. Toraman, and E. Çetin, Sportif hareketlerin biomekanik temelleri, *Ankara: Bağırgan Yayımevi*, 6, 2000.

[38] H. İnal, S., Spor ve egzersizde vücut biyomekaniği, *İstanbul: Papatya Yayıncılık Eğitim*, 17, 2013

[39] H. İnal, S., Spor ve egzersizde vücut biyomekaniği. *İstanbul: Papatya Yayıncılık Eğitim*, 51, 2013.

[40] H. İnal, S., Spor ve egzersizde vücut biyomekaniği, *İstanbul: Papatya Yayıncılık Eğitim,* 73, 2013.

[41] B.F. LeVeau, İnsan hareketinde biyomekanik, Sağlık profesyonelleri için temeller ve ilerisi (çev. ed. Yakut, Y.), *Ankara: Pelikan Yayıncılık,* 161, 2014.

[42] MR Yeadon, JH Challis, Future directions for performance related research in sports biomechanics, *The Sports Council Ancient House Press*, Ipswich London:6, 1992.

[43] Türkiye Cumhuriyeti Cumhurbaşkanlığı Dijital Dönüşüm Ofisi - CBDDO. (t.y.). Yapay zeka. https://cbddo.gov.tr/sss/yapay-zeka/ (accessed 22, July 2022)

[44] L. Deng and D. Yu, "Deep Learning: Methods and Applications," *Found. Trends® Signal Process.*, vol. 7, no. 3–4, pp. 197–387, 2014.

[45] Y. Bengio, "Learning Deep Architectures for AI," Found. trends® Mach. Learn., vol. 2, no. 1, pp. 1–127, 2009.

[46] H. A. Song and S.-Y. Lee, "Hierarchical Representation Using NMF," in International Conference on Neural Information Processing., 2013, pp. 466–473.

[47] P. Okunev, D. Belousov, A. Gritsenko, & M. Shugrina, Benchmarking mobile real-time multi-person pose estimation frameworks, arXiv preprint arXiv:2003.09154, 2020.

[48] Jianing Wei, Ming Guang Yong, Valentin Bazarevsky, Ronald S. C. Lin, Fenghai Liu, Mike Ying, Dale Rahn, Ryan White, and Scott Satkin, *MediaPipe: A Framework for Building Perception Pipelines.*

[49] E. Öztemel, *Yapay Sinir Ağları*, İstanbul: Papatya yayıcılık, 2. Baskı, 2006.

[50] Kutlugün ve ark., Yapay Sinir Ağları ve K-En Yakın Komşu Algoritmalarının Birlikte Çalışma Tekniği (Ensemble) ile Metin Türü Tanıma, *İstanbul: XXII. Türkiye'de Internet Konferansı (inet'tr17), Bahçeşehir Üniversitesi,* 2017.

[51] E. Uzun, *"İnternet Tabanlı Bilgi Erişimi Destekli Bir Otomatik ÖğrenmeSistemi"*, Edirne: Trakya Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, 2007.

[52] E. Alpaydın, *Introduction to Machine Learning*, The MIT Press, Sayfa: 3-6, E. 2004.

[53] H. Nizam, H. ve ark., Sosyal Medyada Makine Öğrenmesi ile Duygu Analizinde Dengeli ve Dengesiz Veri Setlerinin Performanslarının Karşılaştırılması, *XIX. Türkiye'de İnternet Konferansı,* 2014.

[54] G. Hinton ve T.J. Sejnowski, G. Hinton ve Sejnowski T.J. (editorler), 1999, "Unsupervised Learning and Map Formation: Foundations of Neural Computation", *MIT Press*, ISBN 0-262-58168-X, *MIT Press*, ISBN 0-262-58168-X, 1999.

[55] W. Chao, Machine Learning Tutorial, Taiwan: National Taiwan University, *Graduate Institute of Communication Engineering*, DISP Lab, 2011.

[56] S.B. Kotsiantis, Supervised machine learning: A review of classification techniques, *Greece: University of Peloponnese, Department of Computer Science and Technology,* 2011.

[57] C.W. Therrien, Decision estimation and classification: an introduction to pattern recognition and related topics, Monterey, CA: Naval Postgraduate School, ISBN:0-471-83102-6, 1989.

[58] R. Yılmaz, "Türkçe Dokümanların Sınıflandırılması", *Aydın: Adnan Menderes Üniversitesi Yüksek Lisans Tezi*, 2013.

[59] R. Pehlivan, "Resim Tabanlı Osmanlıca Belgelerde Sınıflandırma", *İstanbul: İstanbul Kültür Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi,* 2014.

[60] G. Biricik, "Metin Sınıflama İçin Yeni Bir Özellik Çıkarım Yöntemi", *İstanbul: Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü*, *Doktora Tezi,* 2011.

[61] Y. Şirin ve M.A. Kutlugün, *Konuşma Sentezinde Artan Doğallık için Boyut Azaltma Seçimi*, Signal Processing and Communications Applications Conference (SIU*)*, 2017 25th (s. 10.1109/SIU.2017.7960573), Antalya: IEEE, 2017.

[62] A. Dasgupta ve ark., *Feature selection methods for text classification*, In Proceedings of the 13th ACM SIGKDD international conference on Knowledge discovery and data mining, pp. 230-239, ACM, 2007.

[63] I. Guyon, ve A. Elisseeff, *An introduction to variable and feature selection*, The Journal of Machine Learning Research, vol. 3, pp. 1157-1182, 2003.

[64] Y.H. Li ve A.K. Jain, *Classification of text documents*, The Computer Journal, 1998.

[65] Ö. Çoban, "Metin Sınıflandırma Teknikleri ile Türkçe Twitter Duygu Analizi", *Erzurum: Atatürk Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi*, 2016.

[66] Y. Yang ve J.O. Pedersen, A comparative study on feature selection in text categorization, *In ICML*, vol. 97, pp. 412-420, 1997.

[67] C.J. van Rijsbergen, Information Retrieval. London: Butterworths, 1979.

[68] H.R.A. Alzand ve H. Karacan, *Bölümleyici kümeleme algoritmalarının farklı veri yoğunluklarında karşılaştırılması*, ISSN 1012-2354 (s. 56-62), Kayseri: Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi*,* 2014.

[69] J. Chen ve ark., A Fast k-means Clustering Algorithm Based on Grid Data Reduction, 9980042(1095-323X), (s. 1-6), IEEE digital library, 2009.

[70] H. Jiawei, Cluster Analysis, Data Mining: Concepts and Techniques, *U.S.A.: Elsevier Inc.,* 2006.

[71] T.M. Cover ve P.E. Hart, Nearest Neighbor Pattern Classification, *IEEE TransEylems on Information Theory*, vol. 13, pp. 21-27, 1967.

[72] R. Yılmaz, Türkçe Dokümanların Sınıflandırılması, *Yüksek Lisans Tezi*. Aydın: Adnan Menderes Üniversitesi, 2013.

[73] S. Haykin, Neural Networks, *USA: Macmillan College Publishing Company,* pp. 696, 1994.

[74] K. Tekeli ve R. Aşliyan, Çok Katmanlı Algılayıcı, K-NN ve C4.5 Metotlarıyla İstenmeyen E-postaların Tespiti, *Aydın: XVIII. Akademik Bilişim Konferansı,* 2016.

[75] B.F. LeVeau, İnsan hareketinde biyomekanik, Sağlık profesyonelleri için temeller ve ilerisi (çev. ed. Yakut, Y.), *Ankara: Pelikan Yayıncılık,* 161, 2014.

[76] G. Yavuzer, The use of computerized gait analysis in the assessment of neuromusculoskeletal disorders, *Journal Of Physical Medicine And Rehabilitation Sciences*, vol. 10, no: 2, pp. 043-045, 2007.

[77] DA Winter, Biomechanics And Motor Control Of Human Movement, *2nd Edition, John Wiley & Sons Canada*, 1990.

[78] W. Braüne, O. Fischer, The Human Gait (Ceviri: Maquet P Furlong R), *Springer-Verlag Heidelberg Almanya*, 1987.

[79] YI Abdel-Aziz, HM Karara, Direct linear transformation from comparator coordinates ınto object space coordinates in close-range photogrammetry proceedings of the asp/ui, *Symposium on Close-range Photogrammetry American Society of Photogrammetry,* Falls Church VA, s 1-18, 1971.

[80] K. Lee, *Cad systems for human-centered design computer-aided design & applications*, vol.3-5, pp. 615-628, 2006.

[81] E. Civek, Comparison of kinematic results between Metu-kiss & Ankara University-vicon gait analysis systems, *Y Lisans Tezi, Odtü Makina Mühendisliği Bölümü*, 2006.

[82] MR Yeadon, JH Challis, Future directions for performance related research in sports biomechanics, *The Sports Council Ancient House Press*, Ipswich London:6, 1992.

[83] N. Çetin, Biyomekanik, *Setma Baskı Ankara, vol.* 1, pp.4-41, 1997.

[84] C. Açıkada, H. Demirel, Biyomekanik ve Hareket Bilgisi, *AÜAÖFEskişehir,* pp. 15,1993.

[85] S. Muratlı, F. Toroman, E. Çetin, Sportif Hareketlerin Biyomekanik Temelleri, *Bağırgan Yayınevi Ankara, vol* 1, no: 2, pp.16-24, 2000.

[86] G. Acer, Görüntü işleme (Image processing)— Bilgisayarlı görü (Computer vision) konusunda uzmanlaşmak için yol haritası, Medium https://gokhanacer.medium.com/g%C3%B6r%C3%BCnt%C3%BC-i%CC%87%C5%9Fleme-image-processing-bilgisayarl%C4%B1-g%C3%B6r%C3%BC-computer-vision-konusunda-uzmanla%C5%9Fmak-i%C3%A7in-da82887a2d6d, (accessed 15 Mart 2021).

[87] S.J. Russell, & P. Norvig, Artificial Intelligence: A Modern Approach (3rd ed.), *Prentice Hall Press,* sayfa 986, 2010.

[88] Z. Cao, T. Simon, S.E. Wei, & Y. Sheikh, Realtime multi-person 2d pose estimation using part affinity fields, *In CVPR,* Vol. 1, pp. 1302-1310, 2017.

[89] Z. Zhang, C. Lan, W. Zeng, & Y. Chen, Real-time human pose estimation with convolutional neural networks, *In Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 1293-1301, 2018.

[90] Valentin Bazarevsky, Ivan Grishchenko, Dmitry Vetrov, Andrey Ryabtsev, BlazeFace: Sub-millisecond Neural Face Detection on Mobile GPUs, arXiv preprint arXiv:1907.05047, 2019.

[91] Hang Zhang, Andrew Jones, Jonghoon Jin, Eddy Wu, Searching for MobileNetV3, arXiv preprint arXiv:1905.02244, 2019.

[92] Z. Cao, T. Simon, S.E. Wei, & Y. Sheikh, Realtime multi-person 2d pose estimation using part affinity fields, *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 1302-1310, 2017.

[93] J.-L. Chung, L.-Y. Ong, & M.-C. Leow, Comparative analysis of skeleton-based human pose estimation, *Journal of Visual Communication and Image Representation*, vol. 55, pp. 435-445, doi: 10.1016/j.jvcir.2018.08.015, 2018.

[94] M. Telcioğlu, "Veri Madenciliğinde Genetik Programlama Temelli Yeni Bir Sınıflandırma Yaklaşımı ve Uygulaması", *Kayseri: Erciyes Üniversitesi, Endüstri Mühendisligi Anabilim Dalı*, *Yüksek Lisans Tezi,* 2007.

[95] V. Kecman, Learning and Soft Computing: Support Vector Machine, Neural Networks, and Fuzzy Logic Models, *The MIT Press*, ISBN 0-262-11255-8, 2001.

[96] R.F. Escamilla, A.C. Francisco, A. V. Kayes, K.P. Speer & C.T. Moorman, An electromyographic analysis of sumo and conventional style deadlifts, *Medicine and science in sports and exercise*, vol. 34, no: 4, pp. 682-688, 2002.

[97] P.A. Swinton, A.D. Stewart, J.W. Keogh, I. Agouris & R. Lloyd, Kinematic and kinetic analysis of maximal velocity deadlifts performed with and without the inclusion of chain resistance, *Journal of Strength and Conditioning Research*, vol. 25, no: 11, pp. 3163-3174, 2011.

[98] Wolters Kluwer, American College of Sports Medicine, ACSM's Guidelines for Exercise Testing and Prescription (10th ed.), 2018.

[99] G.G. Haff & N.T. Triplett, (Eds.), Essentials of Strength Training and Conditioning (4th ed.), *Human Kinetics*, 2016.

[100] T.R. Baechle & R. W. Earle, (Eds.), Essentials of Strength Training and Conditioning (3rd ed.), *Human Kinetics,* 2008.

[101] R.F. Escamilla, A.C. Francisco, G.S. Fleisig, S.W. Barrentine, C. M. Welch, A.V. Kayes & J.R. Andrews, A three-dimensional biomechanical analysis of the squat during varying stance widths, *Medicine and Science in Sports and Exercise*, vol. 32, no: 5, pp. 110-114, 2000.

[102] Wolters Kluwer, American College of Sports Medicine, *ACSM's Guidelines for Exercise Testing and Prescription (10th ed.),* 2018.

[103] M. Orescanin, L. N. Smith, S. Sahu, P. Goyal, and S. R. Chhetri, "Editorial: Deep learning with limited labeled data for vision, audio, and text," (in English), *Frontiers in Artificial Intelligence,* Editorial vol. 6, 2023-June-13 2023, doi: 10.3389/frai.2023.1213419.

[104] Ö. Çokluk, "Lojistik regresyon analizi: Kavram ve uygulama.", *Kuram ve uygulamada eğitim bilimleri*, vol.10, no: 3, pp. 1357-1407, 2010.

[105] C.F. İşçen et al, "Su Kalitesi Değişimine Etki Eden Değişkenlerin Lojistik Regresyon, Lojistik-Ridge Ve Lojistik-Lasso Yöntemleri İle Tespiti.", *Biyoloji Bilimleri Araştırma Dergisi*, vol. 14, no: 1, pp. 1-12.

[106] F. Erdem, et al., "Rastgele orman yöntemi kullanılarak kıyı çizgisi çıkarımı İstanbul örneği.", *Geomatik 3.2*,pp. 100-107, 2018.

[107] N. Chakrabarty, et al., "Flight arrival delay prediction using gradient boosting classifier.", *Emerging Technologies in Data Mining and Information Security: Proceedings of IEMIS* 2018, Volume 2. Springer Singapore, 2019, 2018.

[108] Z. Cao, T. Simon, S.E. Wei, & Y. Sheikh, Realtime multi-person 2d pose estimation using part affinity fields. *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 7291-7299, 2019.

[109] A. Toshev, C. Szegedy, Deeppose: Human pose estimation via deep neural networks, *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Columbus, OH, USA, pp. 1653–1660, 28 June 2014.

[110] L. Pishchulin, E. Insafutdinov, S. Tang, B. Andres, M. Andriluka, P.V.Gehler, B. Schiele, Deepcut: Joint subset partition and labeling for multi person pose estimation, *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition,* Las Vegas, NV, USA, pp. 4929–4937, 30 June 2016.

[111] G. Papandreou, T. Zhu, N. Kanazawa, A. Toshev, J. Tompson, C. Bregler, K. Murphy, Towards accurate multi-person pose estimation in the wild, *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, HI, USA, pp. 4903–4911, 21–26 July 2017.

[112] B. Jo, S. Kim, Comparative Analysis of OpenPose, PoseNet, and MoveNet Models for Pose Estimation in Mobile Devices, *Trait. du Signal*, vol.39, pp.119–124, [CrossRef], 2022.

[113] Z. Cao, T. Simon, S.E. Wei, Y. Sheikh, Realtime multi-person 2d pose estimation using part affinity fields, *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, HI, USA, pp. 7291–7299, 21–26 July 2017.

[114] V. Bazarevsky, I. Grishchenko, K. Raveendran, T. Zhu, F. Zhang, M. Grundmann, BlazePose: On-device Real-time Body Pose tracking, arXiv 2020, arXiv:2006.10204.

[115] T.Y, Lin, M. Maire, S. Belongie, J. Hays, P. Perona, D. Ramanan, P. Dollár, C.L. Zitnick, Microsoft coco: Common objects in context, *In Proceedings of the European Conference on Computer Vision*, Zurich, Switzerland,Springer: Cham, Switzerland, 2014; pp. 740–755, 6–12 September 2014.

[116] W. Zhang, M. Zhu, K.G. Derpanis, From actemes to action: A strongly-supervised representation for detailed action understanding, *In Proceedings of the IEEE International Conference on Computer Vision*, Sydney, Australia, pp. 2248–2255, 1–8 December 2013.

[117] V. Bazarevsky, I. Grishchenko, K. Raveendran, T. Zhu, F. Zhang, and M. Grundmann, "Blazepose: On-device real-time body pose tracking," *arXiv preprint arXiv:2006.10204,* 2020.

EKLER

Bu bölümde uygulama gerçekleştirme bölümünde kullanılan bazı önemli program kod parçaları gerekli açıklamaları ile aşağıda sunulmuştur.

- **Mediapipe Poz Tahmin modeli ile Eklem Noktalarını Kullanarak Açı Hesaplama ve Veri Seti Oluşturma işlemleri için kullanılan kodlar;**

```
import os
import time
from datetime import datetime
import cv2
import mediapipe as mp
import numpy as np
import PoseModule as pm
import csv
import psutil
import matplotlib.pyplot as plt

detector = pm.poseDetector()

mp_pose = mp.solutions.pose

cpu_usage = []
memory_usage = []
times = []
start_time = datetime.now()

count = 0
direction = 0
form = 0
pTime = 0
keypoints = []
feedback = "Poz Düzelt"

landmarks = ['class']
for val in range(1, 33 + 1):
    landmarks += ['x{}'.format(val), 'y{}'.format(val), 'z{}'.format(val), 'v{}'.format(val)]

dosya_yolu = "koordinatlar.csv"

# Dosya var mı yok mu kontrol et
dosya_var_mi = os.path.isfile(dosya_yolu)

# Dosya varsa, veri eklemek için hazırla
if dosya_var_mi:
    print("Dosya zaten var. Veri eklemek için hazır.")
else:
    with open('koordinatlar.csv', mode='w', newline='') as f:
        csv_writer = csv.writer(f, delimiter=',', quotechar='"', quoting=csv.QUOTE_NONE)
        csv_writer.writerow(landmarks)
        print("Dosya oluşturuldu.")

def performans_hesapla():
    cpu_usage = psutil.cpu_percent()
    memory_usage = psutil.virtual_memory().percent
    zaman = (datetime.now() - start_time).seconds
    return zaman, memory_usage, cpu_usage
```

```
def export_landmark(results, action):
    try:
        keypoints = np.array(
            [[res.x, res.y, res.z, res.visibility] for res in results.pose_landmarks.landmark]).flatten().tolist()
        keypoints.insert(0, action)

        with open('koordinatlar.csv', mode='a', newline='') as f:
            csv_writer = csv.writer(f, delimiter=',', quotechar='"', quoting=csv.QUOTE_MINIMAL)
            csv_writer.writerow(keypoints)
    except Exception as e:
        pass


# Giriş videolarının adlarını ve yollarını belirleme
# video_files = ["videos/deadlift_yeni.avi", "videos/4.avi", "videos/5.avi"]
video_files = ["videos/2.avi"]
for video_file in video_files:

    cap = cv2.VideoCapture(video_file)
    while cap.isOpened():
        ret, img = cap.read()  # 640 x 480
        # Determine dimensions of video - Help with creation of box in Line 43
        width = cap.get(3)  # float `width`
        height = cap.get(4)  # float `height`
        # print(width, height)

        if not ret:
            break

        img = detector.findPose(img, False)
        lm = detector.EklemNoktalari(img)
        lmList = detector.findPosition(img, False)


        if len(lmList) != 0:

            sol_dirsek = detector.findAngle(img, 11, 13, 15)
            sol_omuz = detector.findAngle(img, 13, 11, 23)
            sol_kalca = detector.findAngle(img, 11, 23, 25)
            sol_diz = detector.findAngle(img, 23, 25, 27)

            sag_dirsek = detector.findAngle(img, 12, 14, 16)
            sag_omuz = detector.findAngle(img, 14, 12, 24)
            sag_kalca = detector.findAngle(img, 12, 24, 26)
            sag_diz = detector.findAngle(img, 24, 26, 28)

            dirsek = (sol_dirsek + sag_dirsek) / 2
            omuz = (sol_omuz + sag_omuz) / 2
            kalca = (sol_kalca + sag_kalca) / 2
            diz = (sol_diz + sag_diz) / 2

            # Percentage of success of pushup
            per = np.interp(kalca, (120, 140), (0, 100))

            # Bar to show Pushup progress
            bar = np.interp(kalca, (120, 140), (380, 50))

            # Program başlamadan önce doğru postürü test etmek için
```

```
if kalca > 160 and dirsek > 160:
    form = 1
color = (255, 0, 255)
if form == 1:
    if per == 0:
        if kalca <= 120 and dirsek >= 160:
            feedback = "down"
            color = (0, 255, 0)
            export_landmark(lm, feedback)
            if direction == 0:
                count += 0.5
                direction = 1
                print(count, "kalça=", kalca, "diz=", diz, "dirsek=", dirsek)
        else:
            feedback = "Poz Düzelt"
    if per == 100:
        if kalca > 160 and dirsek > 160:
            feedback = "up"
            color = (0, 255, 0)
            print(lm)
            export_landmark(lm, feedback)
            if direction == 1:
                count += 0.5
                direction = 0
        else:
            feedback = "Poz Düzelt"

    print(count, "kalça=", kalca, "diz=", diz, "dirsek=", dirsek)



current_time = time.time()
fps = int(1 / (current_time - pTime))
pTime = current_time
print("FPS:", fps)

cv2.putText(img, f'FPS:', (5, 50), cv2.FONT_HERSHEY_PLAIN, 2,
            (255, 200, 0), 3)
cv2.putText(img, str(int(fps)), (75, 50), cv2.FONT_HERSHEY_PLAIN, 2,
            (255, 200, 0), 3)

# İlerleme Çubuğunu Çiz
if form == 1:
    cv2.rectangle(img, (430, 50), (450, 380), color, 3)
    cv2.rectangle(img, (430, int(bar)), (450, 380), color, cv2.FILLED)
    cv2.putText(img, f'{int(per)}%', (405, 430), cv2.FONT_HERSHEY_PLAIN, 2,
                color, 2)

# Deadlift Sayaç
cv2.rectangle(img, (0, 380), (100, 480), (0, 255, 0), cv2.FILLED)
cv2.putText(img, str(int(count)), (25, 420), cv2.FONT_HERSHEY_PLAIN, 2,
            (255, 0, 0), 5)

# Feedback
cv2.rectangle(img, (300, 440), (480, 480), (0, 255, 0), cv2.FILLED)
cv2.putText(img, feedback, (310, 465), cv2.FONT_HERSHEY_PLAIN, 2,
            (255, 0, 0), 2)

zaman, hafiza, islemci = performans_hesapla()
memory_usage.append(hafiza)
```

```
            cpu_usage.append(islemci)
            times.append(zaman)

        cv2.imshow('Deadlift Doğru Pozisyon', img)

        if cv2.waitKey(10) & 0xFF == ord('q'):
            break

    cap.release()

print("CPU kullanımı:", cpu_usage)
print("Bellek kullanımı:", memory_usage)
print("Zaman:", times)

# Çizgi grafiği oluşturma
plt.plot(times, cpu_usage, label='CPU Kullanımı')
plt.plot(times, memory_usage, label='Bellek Kullanımı')
plt.legend()
plt.xlabel('Zaman')
plt.ylabel('Kullanım (%)')
plt.title('CPU ve Bellek Kullanımı')
plt.show()

cv2.destroyAllWindows()
```

- **Kinematik Açılarla Oluşturulan Veri Setini Makine Öğrenme Algoritmalarıyla Eğitme işlemleri için kullanılan kodlar;**

```
import pandas as pd
from sklearn.pipeline import make_pipeline
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler

from sklearn.linear_model import LogisticRegression, RidgeClassifier
from sklearn.ensemble import RandomForestClassifier, GradientBoostingClassifier

from sklearn.metrics import accuracy_score, precision_score, recall_score  # Accuracy metrics
import pickle

df = pd.read_csv("koordinatlar.csv", sep=",")
print(df.head())
print(df.tail())
print(df[df['class'] == 'up'])

X = df.drop('class', axis=1)  # features
y = df['class']  # target value

X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=1234)
y_test

pipelines = {
    'lojistik regresyon': make_pipeline(StandardScaler(), LogisticRegression(solver='lbfgs',
max_iter=1000)),
    'ridge classifier': make_pipeline(StandardScaler(), RidgeClassifier()),
    'random forest classifier': make_pipeline(StandardScaler(), RandomForestClassifier()),
    'gradient boosting classifier': make_pipeline(StandardScaler(), GradientBoostingClassifier())
}

fit_models = {}
for algo, pipeline in pipelines.items():
```

```
    model = pipeline.fit(X_train, y_train)
    fit_models[algo] = model

fit_models['random forest classifier'].predict(X_test)

for algo, model in fit_models.items():
    yhat = model.predict(X_test)
    print(algo, accuracy_score(y_test.values, yhat),
          precision_score(y_test.values, yhat, average="binary", pos_label="up"),
          recall_score(y_test.values, yhat, average="binary", pos_label="up")
          )

with open("deadlift.pkl", "wb") as f:
    pickle.dump(fit_models['random forest classifier'], f)
```

- **Makine Öğrenme Algoritmalarıyla Eğitilen Modelin Test işlemleri için kullanılan kodlar;**

```
import pickle
import mediapipe as mp
import cv2
import numpy as np

import pandas as pd

with open("deadlift.pkl", "rb") as f:
    model = pickle.load(f)

landmarks = ['class']
for val in range(1, 33 + 1):
    landmarks += ['x{}'.format(val), 'y{}'.format(val), 'z{}'.format(val), 'v{}'.format(val)]

#X=pd.DataFrame([row], columns=landmarks[1:])

counter = 0
current_stage = ''

cap = cv2.VideoCapture("videos/5.avi")
# Initiate holistic model
mp_pose=mp.solutions.pose
mp_drawing=mp.solutions.drawing_utils

with mp_pose.Pose(min_detection_confidence=0.5, min_tracking_confidence=0.5) as pose:
    while cap.isOpened():
        ret, frame = cap.read()

        if not ret:
            break

        # Recolor Feed
        image = cv2.cvtColor(frame, cv2.COLOR_BGR2RGB)
        image.flags.writeable = False

        # Make Detections
        results = pose.process(image)

        # Recolor image back to BGR for rendering
        image.flags.writeable = True
        image = cv2.cvtColor(frame, cv2.COLOR_RGB2BGR)
```

```
        mp_drawing.draw_landmarks(image, results.pose_landmarks, mp_pose.POSE_CONNECTIONS,
                                  mp_drawing.DrawingSpec(color=(245, 117, 66), thickness=2, circle_radius=4),
                                  mp_drawing.DrawingSpec(color=(245, 66, 230), thickness=2, circle_radius=2)
                                  )
        try:
            row=np.array([[res.x, res.y, res.z, res.visibility] for res in
results.pose_landmarks.landmark]).flatten().tolist()
            X=pd.DataFrame([row], columns=landmarks[1:])
            body_language_class=model.predict(X)[0]
            body_language_prob=model.predict_proba(X)[0]
            print(body_language_class, body_language_prob)

            if body_language_class == 'down' and body_language_prob[body_language_prob.argmax()] >=
0.7:
                current_stage = 'down'
            elif current_stage == 'down' and body_language_class == 'up' and
body_language_prob[body_language_prob.argmax()] >= 0.7:
                current_stage = "up"
                counter += 1
                print(current_stage)



            #Get status box
            cv2.rectangle(image, (0,0), (250,60), (245,117,16),-1)

            #Display Class
            cv2.putText(image, 'CLASS'
                        , (95,12), cv2.FONT_HERSHEY_SIMPLEX, 0.5, (0,0,0), 1, cv2.LINE_AA)
            cv2.putText(image, body_language_class.split(' ')[0]
                        , (90, 40), cv2.FONT_HERSHEY_SIMPLEX, 1, (255, 255, 255), 2, cv2.LINE_AA)

            #Display Probability
            cv2.putText(image, 'PROB'
                        , (15,12), cv2.FONT_HERSHEY_SIMPLEX, 0.5, (0,0,0), 1, cv2.LINE_AA)
            cv2.putText(image, str(round(body_language_prob[np.argmax(body_language_prob)],2))
                        , (10, 40), cv2.FONT_HERSHEY_SIMPLEX, 1, (255, 255, 255), 2, cv2.LINE_AA)

            # Display Probability
            cv2.putText(image, 'COUNT'
                        , (180, 12), cv2.FONT_HERSHEY_SIMPLEX, 0.5, (0, 0, 0), 1, cv2.LINE_AA)
            cv2.putText(image, str(counter)
                        , (175, 40), cv2.FONT_HERSHEY_SIMPLEX, 1, (255, 255, 255), 2, cv2.LINE_AA)

        except Exception as e:
            pass

        cv2.imshow("Raw webcam feed", image)
        if cv2.waitKey(10) & 0xFF == ord('q'):
            break

cap.release()
cv2.destroyAllWindows()
```

- **Makine Öğrenme Algoritmalarıyla Eğitilen ve Test Edilen Model için oluşturulan Arayüz işlemleri için kullanılan kodlar;**

```
import tkinter as tk
```

```
from tkinter import ttk
import customtkinter as ck
import pandas as pd
import numpy as np
import pickle
import mediapipe as mp
import cv2
from PIL import Image, ImageTk
from landmarks import landmarks
import PoseModule as pm
from datetime import datetime
import psutil
import matplotlib.pyplot as plt
import time


cpu_usage = []
memory_usage = []
times = []
start_time = datetime.now()
prev_time = 0

def performans_hesapla():
    cpu_usage = psutil.cpu_percent()
    memory_usage = psutil.virtual_memory().percent
    zaman = (datetime.now() - start_time).seconds
    return zaman, memory_usage, cpu_usage

def reset_counter():
    global counter
    counter = 0


def step(value):

    my_progress['value'] = value
    # my_progress.start(value)


detector = pm.poseDetector()

VIDEO_PATH = "videos/4.avi"

cap = cv2.VideoCapture(VIDEO_PATH)

window = tk.Tk()
window.geometry("800x650")
window.title("Doğru Poz Tahmini")
ck.set_appearance_mode("dark")

classLabel = ck.CTkLabel(window, height=40, width=120, font=("Arial", 20), text_color="black",
padx=10)
classLabel.place(x=10, y=1)
classLabel.configure(text='SEVİYE')
counterLabel = ck.CTkLabel(window, height=40, width=120, font=("Arial", 20), text_color="black",
padx=10)
counterLabel.place(x=160, y=1)
counterLabel.configure(text='SAYI')
probLabel = ck.CTkLabel(window, height=40, width=120, font=("Arial", 20), text_color="black",
padx=10)
```

```
probLabel.place(x=300, y=1)
probLabel.configure(text='OLASILIK')
classBox = ck.CTkLabel(window, height=40, width=120, font=("Arial", 20), text_color="white", fg_color="blue")
classBox.place(x=10, y=41)
classBox.configure(text='0')
counterBox = ck.CTkLabel(window, height=40, width=120, font=("Arial", 20), text_color="white", fg_color="blue")
counterBox.place(x=160, y=41)
counterBox.configure(text='0')
probBox = ck.CTkLabel(window, height=40, width=120, font=("Arial", 20), text_color="white", fg_color="blue")
probBox.place(x=300, y=41)
probBox.configure(text='0')
fpsLabel = ck.CTkLabel(window, height=40, width=120, font=("Arial", 20), text_color="black", fg_color="green", padx=10)
fpsLabel.place(x=450, y=450)
fpsLabel.configure(text='FPS')

button = ck.CTkButton(window, text='SIFIRLA', command=reset_counter, height=40, width=120, font=("Arial", 20),
                      text_color="yellow", fg_color="purple")
button.place(x=430, y=41)

deadlift_button = ck.CTkButton(window, text='DEADLİFT', command=reset_counter, height=40, width=120, font=("Arial", 30),
                               text_color="white", fg_color="orange")
deadlift_button.place(x=600, y=80)

squat_button = ck.CTkButton(window, text='SQUAT', command=reset_counter, height=40, width=120, font=("Arial", 40),
                            text_color="white", fg_color="black")
squat_button.place(x=600, y=150)

# Güncelleme işlevini 50 milisaniye sonra tekrar çağır
# progress_bar.after(10, update_progress)


# CustomTkinter progress bar oluştur
my_progress = ttk.Progressbar(window, length=300, orient="vertical", mode="determinate", maximum=100, style='red.Vertical.TProgressbar')
my_progress.place(x=500, y=90)

s=ttk.Style()

s.configure('yellow.Horizontal.TProgressbar', background='yellow')

frame1 = tk.Frame(height=640, width=480)
frame1.place(x=10, y=90)

lmain = tk.Label(frame1)
lmain.place(x=0, y=0)

mp_drawing = mp.solutions.drawing_utils
mp_pose = mp.solutions.pose
pose = mp_pose.Pose(min_tracking_confidence=0.5, min_detection_confidence=0.5)

with open('deadlift.pkl', 'rb') as f:
    model = pickle.load(f)
```

```
current_stage = ''
counter = 0
bodylang_prob = np.array([0, 0])
bodylang_class = ''
hipslang_prob = np.array([0, 0])
hipslang_class = ''
leanlang_prob = np.array([0, 0])
leanlang_class = ''


def detect():
    global current_stage
    global counter
    global bodylang_class
    global bodylang_prob
    global hipslang_class
    global hipslang_prob
    global leanlang_class
    global leanlang_prob
    global prev_time

    ret, frame = cap.read()

    if not ret:
        window.quit()
        return

    # fps = cap.get(cv2.CAP_PROP_FPS)

    width = cap.get(3)  # float `width`
    height = cap.get(4)  # float `height`
    # print(width, height)

    # Recolor Feed
    image = cv2.cvtColor(frame, cv2.COLOR_BGR2RGB)
    image.flags.writeable = False

    # Make Detections
    results = pose.process(image)
    #
    # Recolor image back to BGR for rendering
    image.flags.writeable = True
    image = cv2.cvtColor(frame, cv2.COLOR_RGB2BGR)

    # image = cv2.resize(frame, (480, 640), fx=0, fy=0, interpolation=cv2.INTER_CUBIC)

    mp_drawing.draw_landmarks(image, results.pose_landmarks, mp_pose.POSE_CONNECTIONS,
                              mp_drawing.DrawingSpec(color=(106, 13, 173), thickness=4, circle_radius=5),
                              mp_drawing.DrawingSpec(color=(255, 102, 0), thickness=5, circle_radius=10))

    try:
        row = np.array(
            [[res.x, res.y, res.z, res.visibility] for res in results.pose_landmarks.landmark]).flatten().tolist()
        X = pd.DataFrame([row], columns=landmarks)
        bodylang_prob = model.predict_proba(X)[0]
        bodylang_class = model.predict(X)[0]

        # step(bodylang_prob[bodylang_prob.argmax()]*100)

        if bodylang_class == "down" and bodylang_prob[bodylang_prob.argmax()] > 0.7:
```

```
            current_stage = "down"
            my_progress['value']=(bodylang_prob[bodylang_prob.argmax()] * 100-90)

            # print(bodylang_prob)
        elif current_stage == "down" and bodylang_class == "up" and
bodylang_prob[bodylang_prob.argmax()] > 0.7:
            current_stage = 'up'
            counter += 1
            my_progress['value'] = bodylang_prob[bodylang_prob.argmax()] * 100+20

    except Exception as e:
        print(e)

    img = image[:, :460, :]
    imgarr = Image.fromarray(img)
    imgtk = ImageTk.PhotoImage(imgarr)
    lmain.imgtk = imgtk
    lmain.configure(image=imgtk)
    lmain.after(10, detect)

    counterBox.configure(text=counter)
    probBox.configure(text=bodylang_prob[bodylang_prob.argmax()])
    classBox.configure(text=current_stage)


    zaman, hafiza, islemci = performans_hesapla()
    memory_usage.append(hafiza)
    cpu_usage.append(islemci)
    times.append(zaman)

    current_time = time.time()
    fps = int(1 / (current_time - prev_time))
    prev_time = current_time
    print("FPS:", fps)

    fpsLabel.configure(text=fps)


detect()
window.mainloop()
pose.close()
cap.release()

print("CPU kullanımı:", cpu_usage)
print("Bellek kullanımı:", memory_usage)
print("Zaman:", times)

# Çizgi grafiği oluşturma
plt.plot(times, cpu_usage, label='CPU Kullanımı')
plt.plot(times, memory_usage, label='Bellek Kullanımı')
plt.legend()
plt.xlabel('Zaman')
plt.ylabel('Kullanım (%)')
plt.title('CPU ve Bellek Kullanımı')
plt.show()

cv2.destroyAllWindows()
```