



T.C.
SELÇUK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**SPOR HAREKETLERİNİN DERİN ÖĞRENME
YÖNTEMLERİ İLE ANALİZİ**

Ahmet ÇELİKEL

YÜKSEK LİSANS TEZİ

Bilişim Teknolojileri Mühendisliği Anabilim Dalı

Eylül-2024
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Ahmet ÇELİKEL tarafından hazırlanan “Spor Hareketlerinin Derin Öğrenme Yöntemleri ile Analizi” adlı tez çalışması 23/09/2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Selçuk Üniversitesi Fen Bilimleri Enstitüsü Bilişim Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. İsmail KOÇ

.....

Danışman

Doç. Dr. İlker Ali ÖZKAN

.....

Üye

Doç. Dr. Murat KÖKLÜ

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Ömer Faruk YÜKSEL

FBE Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

02.09.2024
Ahmet ÇELİKEL

ÖZET

YÜKSEK LİSANS TEZİ

SPOR HAREKETLERİNİN DERİN ÖĞRENME YÖNTEMLERİ İLE ANALİZİ

Ahmet ÇELİKEL

Selçuk Üniversitesi Fen Bilimleri Enstitüsü
Bilişim Teknolojileri Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. İlker Ali ÖZKAN

2024, 58 Sayfa

Jüri

Doç. Dr. İsmail KOÇ
Doç. Dr. İlker Ali ÖZKAN
Doç. Dr. Murat KÖKLÜ

Spor, fiziksel ve zihinsel insan sağlığı açısından vazgeçilmez bir öneme sahiptir. Spor hareketlerinin analizi edilmesi, sportif performansın optimize edilmesi, sakatlanma risklerinin minimize edilmesi ve sporcuların doğru tekniklerle çalışmasının sağlanması açısından büyük önem taşımaktadır. Son yıllarda spor hareketlerin analizinde derin öğrenme yöntemlerinin kullanılması, önceki yöntemlere kıyasla daha başarılı sonuçlar verdiği görülmüştür. Powerlifting, bench press, deadlift ve squat gibi temel hareketlerden oluşan bir güç sporudur. Powerlifting hareketleri genellikle karmaşık ve icra edilmesi nispeten zor hareketlerdir. Bu nedenle, bu hareketlerin doğru teknikle ve güvenli bir şekilde uygulanması büyük önem taşımaktadır. Bu çalışmanın amacı, Powerlifting sporundaki temel hareketlerin (bench press, deadlift ve squat) doğru tekniklerle uygulanmasını sağlamak ve sakatlanma risklerini en aza indirilmesi amacıyla, derin öğrenme yöntemleri kullanarak bu hareketlerin sınıflandırılmasını gerçekleştirmektir. Bu çalışmada, derin öğrenme tabanlı SqueezeNet mimarisi kullanılarak Powerlifting hareketlerinden özellik çıkarımı yapılarak makine öğrenmesi algoritmaları ile sınıflandırılması yapılmıştır. Veri seti, internet üzerindeki çeşitli kaynaklardan toplanan bench press, deadlift ve squat hareketlerine ait toplam 876 görüntüden oluşturulmuştur. Ayrıca veri artırma teknikleri uygulanarak bu veri seti artırılmış ve MediaPipe kütüphanesi kullanılarak hareketlerin duruş tahminine ilişkin anahtar noktalar görüntülere eklenmiştir. Ayrıca SqueezeNet ile özellik çıkarımı yerine sadece duruş tahmini bilgilerinin kullanımı da test edilmiştir. Elde edilen veri setleri, Yapay Sinir Ağı, Destek Vektör Makinesi, Rastgele Orman ve Lojistik Regresyon modelleri ile sınıflandırılmış ve model performansları çeşitli değerlendirme metrikleri ile analiz edilmiştir. Ham veri seti (876 görüntü) üzerinde yapılan deneyler, Yapay Sinir Ağı modelinin en yüksek doğruluk oranı olan (0,925) ile en iyi performansı gösterdiğini ortaya koymuştur. Veri artırma teknikleri ve anahtar noktalar eklenen genişletilmiş veri seti üzerinde yapılan analizlerde ise yine Yapay Sinir Ağı modelinin en yüksek doğruluk oranı olan (0,989) ile en iyi performansı gösterdiğini ortaya koymuştur. Sadece duruş tahmini verilerinin kullanımı ile de Yapay Sinir Ağı modelinin en yüksek doğruluk oranı (0,977) ile en iyi performansı gösterdiği görülmüştür. Sonuçlar, duruş tahmini ve veri artırma tekniklerinin bir arada kullanılmasının, sınıflandırma doğruluğunu ve genel model performansını önemli ölçüde artırdığını göstermektedir. Bu çalışma, derin öğrenme yöntemlerinin spor hareket analizinde güçlü bir araç olduğunu ve sporcuların performanslarının değerlendirilmesinde önemli katkılar sağlayabileceğini göstermektedir. Bu yöntemler, doğru tekniklerin uygulanması ve hareketlerin hassas bir şekilde analiz edilmesi açısından önemli avantajlar sunmaktadır.

Anahtar Kelimeler: Derin Öğrenme, Hareket Analizi, MediaPipe, Powerlifting, Spor Hareketleri

ABSTRACT

MS THESIS

ANALYSIS OF SPORTS MOVEMENTS WITH DEEP LEARNING METHODS

Ahmet ÇELİKEL

THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
SELÇUK UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN COMPUTER ENGINEERING

Advisor: Assoc. Prof. Dr. İlker Ali ÖZKAN

2024, 58 Pages

Jury

Assoc. Prof. Dr. İsmail KOÇ

Assoc. Prof. Dr. İlker Ali ÖZKAN

Assoc. Prof. Dr. Murat KÖKLÜ

Sport has an indispensable importance for physical and mental human health. Analyzing sports movements is of great importance in terms of optimizing sports performance, minimizing injury risks and ensuring that athletes work with the correct techniques. In recent years, the use of deep learning methods in the analysis of sports movements has shown more successful results compared to previous methods. Powerlifting is a strength sport that consists of basic movements such as bench press, deadlift and squat. Powerlifting movements are often complex and relatively difficult to perform. Therefore, safe execution of these movements with correct technique is of great importance. The aim of this study is to classify the basic movements in powerlifting (bench press, deadlift and squat) using deep learning methods in order to ensure that they are performed with correct techniques and to minimize the risk of injury. In this study, deep learning based SqueezeNet architecture is used to extract features from Powerlifting movements and classify them with machine learning algorithms. The dataset consists of 876 images of bench press, deadlift and squat movements collected from various sources on the internet. In addition, this dataset was increased by applying data augmentation techniques and key points related to the posture estimation of the movements were added to the images using the MediaPipe library. In addition, the use of only pose estimation information instead of feature extraction with SqueezeNet was also tested. The datasets were classified with Artificial Neural Network, Support Vector Machine, Random Forest and Logistic Regression models and the model performances were analyzed with various evaluation metrics. Experiments on the raw dataset (876 images) revealed that the Neural Network model performed the best with the highest accuracy of (0.925). Analyses on the extended dataset, where data augmentation techniques and key points were added, again showed that the Neural Network model performed the best with the highest accuracy of (0.989). It was also observed that the Neural Network model performed best with the highest accuracy rate of (0.977) when only the stop prediction data was used. The results show that the combination of stance prediction and data augmentation techniques significantly improves the classification accuracy and overall model performance. This study shows that deep learning methods are a powerful tool in sports motion analysis and can make significant contributions to the evaluation of athletes' performance. These methods offer significant advantages in terms of applying the right techniques and analyzing the movements precisely.

Keywords: Deep Learning, MediaPipe, Movement Analysis, Powerlifting, Sports Movements

ÖNSÖZ

Yüksek Lisans tez çalışması olarak hazırladığım bu çalışmada beni yönlendiren, desteğini hiçbir zaman esirgemeyen, bilgi ve tecrübeleriyle bana sürekli katkı sağlayan tez danışmanım Sayın Doç. Dr. İlker Ali ÖZKAN' a katkılarından ve desteklerinden dolayı çok teşekkür ederim.

Ahmet ÇELİKEL
KONYA-2024



İÇİNDEKİLER

ÖZET	IV
ABSTRACT.....	V
ÖNSÖZ	VI
İÇİNDEKİLER	VII
SİMGELER VE KISALTMALAR.....	IX
1. GİRİŞ.....	1
1.1. Tezin Önemi ve Amacı	2
1.2. Kaynak Araştırması	4
1.3. Tezin Organizasyonu	5
2. SPOR HAREKETLERİNİN ANALİZİ VE POWERLİFTİNG	7
2.1. Marker Tabanlı Hareket Analizi	7
2.2. Marker Tabanlı Olmayan Hareket Analizi	9
2.3. Diğer Analiz Teknikleri	11
2.4. Derin Öğrenme ve Hareket Tanıma	12
2.5. Güç Sporları ve Powerlifting	13
3. DURUŞ TAHMİNİ	15
3.1. MediaPipe	15
3.2. OpenPose	16
3.3. PoseNet	17
3.4. AlphaPose	18
3.5. DeepPose	19
3.6. MoveNet	20
4. MATERYAL VE YÖNTEM.....	22
4.1. Veri Seti	23
4.2. Veri Ön İşleme.....	24
4.3. Duruş Tahmini Bilgilerinin Kullanımı	25
4.4. Özellik Çıkarımı	26
4.5. Makine Öğrenmesi Algoritmaları	28
4.6. Performans Değerlendirme Metrikleri.....	30
5. ARAŞTIRMA SONUÇLARI.....	33
5.1. Duruş Tahmini Bilgilerinin Kullanımı ile Alınan Sonuçlar	33
5.1.1. 33 Anahtar Nokta ile Duruş Tahmini Sonuçları	34
5.1.2. 12 Anahtar Nokta ile Duruş Tahmini Sonuçları	36
5.1.3. Duruş Tahmininde Güvenilirlik Eşik Değeri Kullanılarak Alınan Sonuçlar	38
5.2. Derin Öğrenme Tekniklerinin Kullanımı ile Alınan Sonuçlar	41
5.2.1. Ham Veri Seti ile Alınan Sonuçlar	41

5.2.2. Geniřletilmiř Veri Seti ile Alınan Sonular.....	43
5.2.3. Anahtar Noktalar İeren Ham Veri Seti Sonuları	45
5.2.4. Anahtar Noktalar İeren Geniřletilmiř Veri Seti Sonuları.....	47
6. SONULAR VE ÖNERİLER	50
KAYNAKLAR	53
EKLER	57
ÖZGEMİř	58



SİMGELER VE KISALTMALAR

Kısaltmalar

AİE	Algılayıcı İşletim Eğrisi (Receiver Operating Characteristic)
DSA	Derin Sinir Ağları (Deep Neural Networks)
DN	Doğru Negatif (True Negative)
DP	Doğru Pozitif (True Positive)
DVM	Destek Vektör Makinesi (Support Vector Machine)
EAA	Eğri Altındaki Alan (Area Under the Curve)
EMG	Elektromiyografi
ESA	Evrişimsel Sinir Ağları (Convolutional Neural Networks)
F1	F1 Ölçütü (F1 Score)
LR	Lojistik Regresyon (Logistic Regression)
MKK	Matthews Korelasyon Katsayısı (Matthews Correlation Coefficient)
RO	Rastgele Orman (Random Forest)
SD	Sınıflandırma Doğruluğu (Classification Accuracy)
YN	Yanlış Negatif (False Negative)
YP	Yanlış Pozitif (False Positive)
YSA	Yapay Sinir Ağı (Artificial Neural Network)

TABLULAR LİSTESİ

Tablo 5.1. 33 anahtar nokta kullanımı ile modellerin performans sonuçları	34
Tablo 5.2. 12 anahtar nokta kullanımı ile modellerin performans sonuçları	36
Tablo 5.3. Duruş tahmininde güvenilirlik eşik değeri kullanımı ile modellerin performans sonuçları.....	38
Tablo 5.4. Ham Powerlifting veri seti ile alınan modellerin performans sonuçları.....	41
Tablo 5.5. Genişletilmiş veri seti ile alınan modellerin performans sonuçları	43
Tablo 5.6. Anahtar nokta içeren ham veri seti ile modellerin alınan performans sonuçları	45
Tablo 5.7. Anahtar noktalar içeren genişletilmiş veri seti ile modellerin alınan performans sonuçları.....	47



ŞEKİLLER LİSTESİ

Şekil 2.1. Marker tabanlı hareket analizi	8
Şekil 2.2. Silüet analizi ile model oluşturma, tespit ve izleme süreci.....	9
Şekil 2.3. Derinlik Kamerası ile insan vücut parçalarının tespiti ve 3D eklem önerileri analizi.....	10
Şekil 2.4. Powerlifting sporunda kullanılan temel hareketler.....	13
Şekil 3.1. MediaPipe kullanımı ile elde edilen 33 anahtar noktanın dağılımı	16
Şekil 3.2. OpenPose kullanımı ile elde edilen 25 anahtar noktanın dağılımı	17
Şekil 3.3. Örnek PoseNet duruş tahminleri.....	18
Şekil 3.4. Örnek AlphaPose duruş tahminleri.....	19
Şekil 3.5. Örnek DeepPose duruş tahminleri	20
Şekil 3.6. Örnek MoveNet karşılaştırma sonuçları.....	21
Şekil 4.1. Powerlifting hareketlerinin sınıflandırılması için kullanılan modelleme sürecine ait akış şeması.....	22
Şekil 4.2. Kullanılan veri seti ve kategorilere göre dağılımı	23
Şekil 4.3. MediaPipe kütüphanesi kullanılarak Deadlift hareketi sırasında tespit edilen 33 anahtar nokta ile iskelet yapısının görselleştirilmesi	24
Şekil 4.4. SqueezeNet modelinin mimari yapısı.....	26
Şekil 4.5. Yapay sinir ağı mimarisi.....	28
Şekil 4.6. Üçlü sınıflandırma için karmaşıklık matrisi	30
Şekil 5.1. Farklı modeller için 33 anahtar nokta bilgisi ile AİE analizleri	35
Şekil 5.2. 33 Anahtar nokta bilgisi ile duruş tahmini modellerinin karmaşıklık matrisleri	36
Şekil 5.3. Farklı modeller için 12 anahtar nokta bilgisi ile AİE analizleri	37
Şekil 5.4. 12 Anahtar nokta bilgisi ile duruş tahmini modellerinin karmaşıklık matrisleri	38
Şekil 5.5. Duruş tahmininde güvenilirlik eşik değeri kullanımı ile AİE analizleri	39
Şekil 5.6. Duruş tahmininde güvenilirlik eşik değeri kullanımı ile duruş tahmini modellerinin karmaşıklık matrisleri.....	40
Şekil 5.7. Ham Powerlifting veri seti için AİE analizleri	42
Şekil 5.8. Ham Powerlifting veri seti için modellerin karmaşıklık matrisleri	43
Şekil 5.9. Genişletilmiş veri seti için AİE analizleri.....	44
Şekil 5.10. Genişletilmiş veri seti için modellerin karmaşıklık matrisleri.....	45
Şekil 5.11. Anahtar noktalar içeren ham veri seti için AİE analizleri	46
Şekil 5.12. Anahtar noktalar içeren ham veri seti için modellerin karmaşıklık matrisleri	47
Şekil 5.13. Anahtar noktalar içeren genişletilmiş veri seti için AİE analizleri.....	48
Şekil 5.14. Anahtar noktalar içeren genişletilmiş veri seti için karmaşıklık matrisleri ..	49

1. GİRİŞ

Spor, özellikle günümüzde hem fiziksel hem de zihinsel insan sağlığı açısından vazgeçilmez bir öneme sahiptir. Düzenli egzersiz yapmak, vücut fonksiyonlarının iyileştirilmesi, iskelet kaslarının gücünün artırılması, kilo kontrolü ve vücut esnekliğinin geliştirilmesi gibi pek çok faydayı beraberinde getirmektedir (Warburton et al., 2006). Düzenli egzersizin insan sağlığı üzerindeki olumlu etkileri birçok bilimsel araştırmalar ile desteklenmiştir. Warburton ve ark. yaptıkları bir çalışmada, aerobik aktivitelerin kardiyovasküler sağlığı iyileştirdiği, kan basıncını düşürdüğü ve kolesterol seviyelerini dengelediğini belirtmektedir (Warburton et al., 2006).

Fiziksel aktivite daha iyi yaşam kalitesini beraberinde getirir. Fiziksel aktiviteler stresin azalması, ruh sağlığının iyileşmesi ve sosyal etkileşimin artması gibi önemli psikolojik faydalar da sunmaktadır (Penedo & Dahn, 2005). Başka bir çalışmada fiziksel aktivitenin obeziteyi önleme ve vücut ağırlığını kontrol etmede etkili olduğu gösterilmiştir (Donnelly et al., 2009). Düzenli egzersiz, kas gücünü, esnekliği ve koordinasyonu artırarak fiziksel işlevselliği de iyileştirir.

Spor, zihinsel sağlık üzerinde de birçok olumlu etki sunmaktadır. Fiziksel aktivitenin konsantrasyon, odaklanma ve bilişsel işlevleri artırdığı bildirilmiştir (Donnelly et al., 2016). Başka bir çalışma, yine düzenli egzersizin psikolojik sağlığı iyi etkilediği, depresyon ve anksiyete semptomlarını azalttığını ortaya koymuştur (Schuch et al., 2016). Spor ve fiziksel aktivite, özgüven ve özyeterlilik gibi duyguları güçlendirerek genel psikolojik iyilik halini artırır (Laird et al., 2018).

Düzenli spor yapmak, sadece sağlık ve psikoloji üzerinde değil, aynı zamanda sportif performans üzerinde de olumlu etkiler sağlamaktadır. Bir araştırmada, düzenli antrenman yapmanın dayanıklılık, güç, esneklik ve çeviklik gibi fiziksel kapasiteleri iyileştirdiği bulunmuştur (Hecksteden et al., 2015). Sonuç olarak, fiziksel aktivitenin ve spor yapmanın sağlık, psikoloji ve sportif performans açısından çok yönlü faydalar sunduğu açıkça görülmektedir.

Spor, fiziksel ve ruhsal sağlığımız için olmazsa olmaz bir unsurdur. Ancak, sporu doğru teknikle yapmak, sadece performansımızı artırmakla kalmaz, aynı zamanda sakatlanma riskini de önemli ölçüde azaltır. Yanlış teknikler, kas dengesizliklerine, eklem problemlerine ve hatta ciddi yaralanmalara yol açabilir.

Spor hareketlerinin doğru teknikle uygulanmasının sağlanması ve sakatlanma risklerinin en aza indirilmesi açısından büyük önem arz etmektedir. Bu işlem için son yıllarda derin öğrenme tabanlı yöntemlerin kullanımı artmıştır. Spor analizinde temel problemlerden biri sporda kullanılan bazı hareketlerin doğru teknikle uygulandığının belirlenmesinin zorluğudur. Ayrıca spor yaparken kullanılan hareketlerin karmaşıklığı bu hareketlerin yapılmasını zorlaştırmaktadır. Bu nedenle, bu hareketlerin doğru teknikle ve güvenli bir şekilde uygulanması büyük önem taşımaktadır.

Ayrıca bir diğer problem hatalı hareket formlarının sakatlanma riskini artırmasıdır. Hatalı hareket formları, sporcuların sakatlanma riskini artırmakta ve performanslarını olumsuz etkilemektedir. Özellikle Bench press, squat, deadlift gibi yüksek ağırlıklar ile çalışılan hareketlerde, hareket tekniği ve doğruluğu büyük öneme sahiptir.

Yapılan çalışmalarda spor hareketlerinin analizinde geleneksel yöntemlerin yetersiz kaldığı görülmektedir. Bu nedenle, daha yüksek doğruluk ve genel performans sağlayabilecek gelişmiş analiz yöntemlerine ihtiyaç duyulmaktadır. Derin öğrenme, spor hareketlerinin analizinde daha yüksek doğruluk oranları sunarak, sporcuların performanslarını daha detaylı değerlendirmelerine olanak tanıyan sistemlerin geliştirilmesine katkı sağlayabilir. Bu problemlere çözüm olarak, bu tez çalışmasında derin öğrenme tabanlı bir yaklaşım önerilmektedir. Bu yaklaşım, spor hareketlerinin daha doğru ve güvenilir bir şekilde analiz edilmesine olanak sağlayarak, geleneksel yöntemlerin sınırlamalarını aşmayı hedeflemektedir.

1.1. Tezin Önemi ve Amacı

Spor yaparken hareketlerin doğru teknik ile icra edilmesi, hedeflenen kas gruplarını optimal olarak çalışmasını sağlar. Bu hem kas gücünün hem de dayanıklılık ve vücut koordinasyonunun artmasına katkı sağlar. Örneğin, ağırlık antrenmanında doğru teknik kullanımı, kasları etkili bir şekilde çalıştırırken eklemlere binen yükü azaltır. Bir egzersiz sırasında doğru tekniğin uygulanması, enerji verimliliğini artırırken sakatlanma riskini minimize eder.

Özellikle güç sporları alanında, hareketlerin doğru ve verimli gerçekleştirilmesi oldukça önemlidir. Bu tür sporlarda teknik hatalar yaralanmalara neden olabileceği için, sporcuların hareket tekniklerinin hassas bir şekilde analiz edilmesi ve geri bildirim sağlanması kritiktir.

Günümüzde görüntü işleme ve makine öğrenmesi teknolojilerindeki ilerlemeler, spor hareketlerinin otomatik analiz edilmesine imkân tanımaktadır. Spor hareketlerinin analizi için derin öğrenme tekniklerinin kullanımı hızla yaygınlaşmakta olup, bu teknikler ile yüksek doğruluk oranlarına ulaşmak mümkün olmuştur.

Literatürde, spor hareketlerinin analizi için derin öğrenme yöntemlerinin kullanıldığı görülmektedir. Ancak, bu çalışmaların büyük bir kısmı, yürüme, koşma gibi temel spor aktivitelerine odaklanmıştır. Powerlifting gibi kompleks ve teknik gerektiren spor hareketlerinin derin öğrenme yöntemleri ile analiz eden ve yüksek doğruluk oranlarına sahip bir çalışmaya literatürde rastlanılmamıştır.

Bu çalışmanın temel amacı, powerlifting sporunda kullanılan hareketlerin derin öğrenme yöntemleri kullanılarak yüksek doğruluk oranlarıyla analiz edilmesi ve sınıflandırılmasıdır. Bu amaçla, spor hareketlerinin analizinde derin öğrenme tabanlı tekniklerin potansiyelini incelemeyi hedeflemekteyiz. Bu inceleme, Powerlifting gibi teknik açıdan karmaşık hareketlerin daha doğru ve verimli bir şekilde değerlendirilmesi için derin öğrenme yaklaşımlarının sağladığı avantajları ortaya koymayı amaçlamaktadır. Bu çalışma ile powerlifting hareketlerinin derin öğrenme teknikleriyle analiz edilmesine yönelik bir yaklaşım sunulması ve bu alandaki boşluğu doldurması hedeflenmektedir. Uygulamada ise, bu çalışmanın, sporcuların ve antrenörlerin performanslarını daha objektif ve bilimsel yöntemlerle değerlendirmelerine olanak tanıyacak bir sistem geliştirilmesine katkı sağlaması beklenmektedir.

Araştırmanın temel çıkış noktası “Spor hareketlerinin derin öğrenme yöntemleri kullanılarak sınıflandırılması mümkün müdür?” sorusuna dayanmaktadır. Bunun yanında, “Derin öğrenme tabanlı bir model, Powerlifting hareketlerinin doğru teknikle uygulanmasını ve sakatlanma risklerini en aza indirmeyi sağlayabilir mi?” ve “Veri artırma teknikleri ve duruş tahmini kullanımı, spor hareketlerinin sınıflandırma doğruluğunu ve genel model performansını iyileştirebilir mi?” soruları da bu araştırmanın önemli odak noktalarını oluşturmaktadır.

Bu tez çalışmasında, derin öğrenme yöntemlerinin, spor hareketlerinin doğru teknikle uygulanmasını ve sakatlanma risklerini en aza indirebilecek kadar yüksek doğruluk oranlarına sahip bir sınıflandırma sistemi geliştirilme potansiyeli incelenmiştir. Ayrıca, veri artırma teknikleri ve duruş tahmini kullanımının, derin öğrenme modelinin performansına olan etkileri bu çalışmada detaylı olarak değerlendirilmiştir.

1.2. Kaynak Araştırması

Geleneksel hareket analiz tekniklerinin yanı sıra spor hareketlerinin analizinde derin öğrenme kullanımını giderek daha fazla ilgi görmeye başlamıştır. Cust ve ark., spor hareketlerinin otomatik tespiti ve tanınması için makine ve derin öğrenme tekniklerini inceleyen bir literatür derlemesinde, bu hareketlerin özelliklerine uygun yaklaşımların benimsenmesi gerektiğini vurgulamaktadırlar (Cust et al., 2019).

Ronao ve ark. tarafından akıllı telefon sensörlerinden toplanan veriler kullanılarak derin öğrenme tabanlı insan aktivitesi tanıma üzerine yaptıkları bir çalışma da, spor aktivitelerinin (yürüme, koşma, bisiklet sürme vb.) tanınmasında başarılı sonuçlar elde etmiştir (Ronao & Cho, 2016). Başka bir çalışma da Wang, P. derin öğrenme algoritmaları kullanarak spor antrenmanı eylemlerinin tanınması incelenmiş ve eylemlerinin tanınmasında derin öğrenme algoritmalarının kullanılması önerilmektedir (Wang, 2021). Pajak, G. ve ark. atalet sensörü verileri kullanılarak spor aktivitelerinin tanınmasında derin öğrenme, özellikle CNN ve ensemble yaklaşımlarının performansını incelemektedir (Pajak et al., 2022). Xu, Y. derin öğrenme tabanlı bir spor eğitimi video sınıflandırma modeli çalışmasında derin öğrenme tabanlı spor eğitimi video sınıflandırma modelinin yüksek doğruluk ve hız sağladığını göstermiştir (Xu, 2021).

Pan, S. yaptığı çalışmada, spor videolarındaki (özellikle halter videolarındaki) temel duruş ve hareket tanımayı derin öğrenme teknikleri ile otomatikleştiren bir yöntem önermektedir. Bu yöntem, geleneksel hedef algılama ve takip yöntemlerinin karşılaştığı zorlukları (görüntü bozulması, arka plan etkisi, aniden değişen aydınlatma gibi) ele almayı hedeflemektedir. Önerilen RoI_KP yöntemi, bölge tabanlı sınıflandırma ve evrişimli sinir ağlarının ince ayarı ile temel duruşları otomatik olarak tespit etmektedir (Pan, 2022). Wang, L. ve ark., serbest jimnastik videolarındaki insan hareketlerinin otomatik olarak anlaşılmasına odaklanan büyük veri ve derin öğrenme tabanlı bir sınıflandırma modeli geliştirmiştir. Geliştirilen bu model, spor videolarının sınıflandırılmasındaki doğruluğu önemli ölçüde artırmaktadır (Wang et al., 2021). Zhao, X., derin öğrenme kullanarak genç sporcuların antrenmanlarındaki yanlış teknik hareketlerin analizini ve düzeltilmesini amaçlayan bir çalışma gerçekleştirmiştir. Beden eğitimi ve antrenman sürecindeki yanlış hareketlerin tespiti için Evrişimsel Sinir Ağları ve Derin Öğrenme tabanlı bir model geliştirmişlerdir. Simülasyon sonuçları, bu yöntemin yanlış hareket tespiti doğruluğunun %92,16 olduğunu göstermektedir (Zhao, 2022).

Ferreira ve ark. yaptıkları bir çalışma da spor hareketlerinin tekrar sayısını ve geçerliliğini otomatik olarak belirlemek için bilgisayarlı görü ve derin öğrenme

tekniklerinin kullanılmasını araştırmışlar. Bu çalışmada, 2D insan duruş tahmini kullanılarak egzersiz tekrarlarını sayma ve doğrulama sistemi geliştirilmiş, yanlış yapılan egzersiz tekrarları tespit edilmiştir. Araştırmacılar, 130'dan fazla katılımcıdan 5 popüler CrossFit egzersizine ait veri toplamış ve bu verilerle geliştirilen tekrar sayma ve doğrulama modülü, tahmin edilen egzersiz anlarını alıp geçerli tekrar sayısını %92'nin üzerinde doğrulukla belirleyebilmiştir (Ferreira et al., 2021). Chen ve ark., evde fitness egzersizi yapan kişilerin hatalı hareketlerden kaynaklanan yaralanmaları önlemek amacıyla benzer bir çalışma gerçekleştirmiş ve bir fitness hareketi tespit ve sınıflandırma sistemi geliştirmiştir. Geliştirilen sistem, YOLOv4 nesne tespiti ve MediaPipe poz tahmini kullanılarak 12 farklı spor hareketinin gerçek zamanlı tespitini sağlamıştır. Elde edilen sonuçlara göre, hareket tipi sınıflandırmasında %98,56 doğruluk elde edilirken, hareket tamamlanma sınıflandırmasında %92,84 doğruluk kaydedilmiştir. Sistem, ortalama 17.5 FPS hızında gerçek zamanlı çalışabilmektedir. Bu araştırma ile transfer öğrenme ve nesne tespiti-poz tahmini kombinasyonunu kullanarak yüksek doğrulukta ve verimli bir fitness hareketi tespit sistemi geliştirilebilmiştir (Chen et al., 2022).

Literatür incelendiğinde, derin öğrenme yöntemlerinin insan hareketlerinin analizinde başarılı sonuçlar verdiği ve bu yöntemlerin hareketlerin özelliklerini doğru bir şekilde tanımlayabildiği görülmektedir. Çalışmalar, özellikle yanlış hareketlerin tespiti ve spor antrenmanlarındaki hataların değerlendirilmesiyle, sporcuların performanslarını geliştirme ve sakatlanma risklerini azaltma açısından önemli katkılar sunmaktadır. Ayrıca, duruş tahmini ve veri artırma teknikleri gibi yöntemlerin kullanımı, spor hareketlerinin daha hassas bir şekilde analiz edilmesine olanak sağlayarak, sporcuların antrenman tekniklerinin iyileştirilmesine yardımcı olmaktadır. Literatürdeki bulgular, derin öğrenme tekniklerinin spor hareket analizinde geleneksel yöntemlere kıyasla daha yüksek doğruluk oranları sunduğunu ortaya koymaktadır.

1.3. Tezin Organizasyonu

Yapılan tez çalışması 6 ana başlık altında ele alınmıştır. İlk bölümde, spor hareketlerinin analizi ve powerlifting hakkında genel bilgiler verilmiştir. Tezin önemi, amacı ve çalışmanın literatürdeki yeri gibi bilgilere yer verilmiştir. İkinci bölümde, spor hareketlerinin analizinde kullanılan geleneksel ve modern yöntemler detaylandırılmış; marker tabanlı ve marker tabanlı olmayan analiz teknikleri ile derin öğrenme tabanlı yaklaşımlar anlatılmıştır. Aynı zamanda, güç sporları ve özellikle Powerlifting'e dair açıklamalar yapılmıştır. Üçüncü bölümde duruş tahmini teknikleri ele alınmıştır.



MediaPipe, OpenPose, PoseNet, AlphaPose, DeepPose ve MoveNet gibi duruş tahmini yöntemlerine dair ayrıntılı bilgilere yer verilmiş, bu yöntemlerin spor hareketlerinin analizindeki uygulamaları incelenmiştir. Dördüncü bölümde ise tez çalışmasında kullanılan materyal ve yöntemler anlatılmıştır. Kullanılan veri seti, veri ön işleme aşamaları, duruş tahmini bilgilerinin kullanımı, özellik çıkarımı ve sınıflandırma için kullanılan makine öğrenmesi algoritmalarına dair detaylar verilmiştir. Ayrıca, performans değerlendirme metrikleri de bu bölümde ele alınmıştır. Beşinci bölümde, yapılan deneylerin sonuçlarına yer verilmiştir. Duruş tahmini ile elde edilen sonuçlar, derin öğrenme tekniklerinin kullanımıyla alınan sonuçlar ve veri artırma tekniklerinin etkileri analiz edilmiştir. Ayrıca, MediaPipe ile yapılan duruş tahmini sonuçları ve veri artırma ile birlikte alınan sonuçlar da karşılaştırılmıştır. Son olarak, altıncı bölümde elde edilen bulgular ve sonuçlar incelenmiş, bu sonuçlara dayalı öneriler sunulmuştur. Tez çalışmasının katkıları, sınırlamaları ve ileride yapılacak çalışmalar için tavsiyeler bu bölümde yer almaktadır.

2. SPOR HAREKETLERİNİN ANALİZİ VE POWERLİFTİNG

Spor hareketlerinin analizi, sporcuların performansını artırmak ve sakatlanma risklerini azaltmak için oldukça önemlidir. Bu amaçla literatürde Marker Tabanlı Hareket, Marker Tabanlı Olmayan Hareket, Elektromiyografi (EMG), Kinematik, Kinetik gibi çeşitli analiz yöntemleri kullanılmaktadır. Bu bölümde spor hareketlerinin analiz yöntemlerinden ve Powerlifting sporundan bahsedilmektedir.

2.1. Marker Tabanlı Hareket Analizi

Marker tabanlı hareket analizi, insan vücudunun hareketlerini 3 boyutlu olarak ölçmek için kullanılan bir yöntemdir. Bu yöntem, vücuda yerleştirilen markerlar aracılığıyla hareketleri takip eder ve bu markerların hareketlerini kullanarak eklemlerin açılarını ve hareketlerini hesaplar (Lempereur et al., 2014). Markerlar, kameralar tarafından kolayca tespit edilebilir ve hareketin doğru bir şekilde takip edilmesini sağlar. Yüksek hızlı kameralar, markerların konumunu kaydeder. Bu kameralar, genellikle hareketin tüm yönlerini yakalamak için farklı açılardan yerleştirilir. Kaydedilen veriler, özel yazılımlar kullanılarak işlenir. Bu yazılımlar, markerların konumunu kullanarak hareketin üç boyutlu bir modelini oluşturur. Bu model, hareketin hızını, ivmesini, açısal hızı ve yer değiştirmesini belirlemek için kullanılabilir (Kolahi et al., 2007).



Şekil 2.1. Marker tabanlı hareket analizi

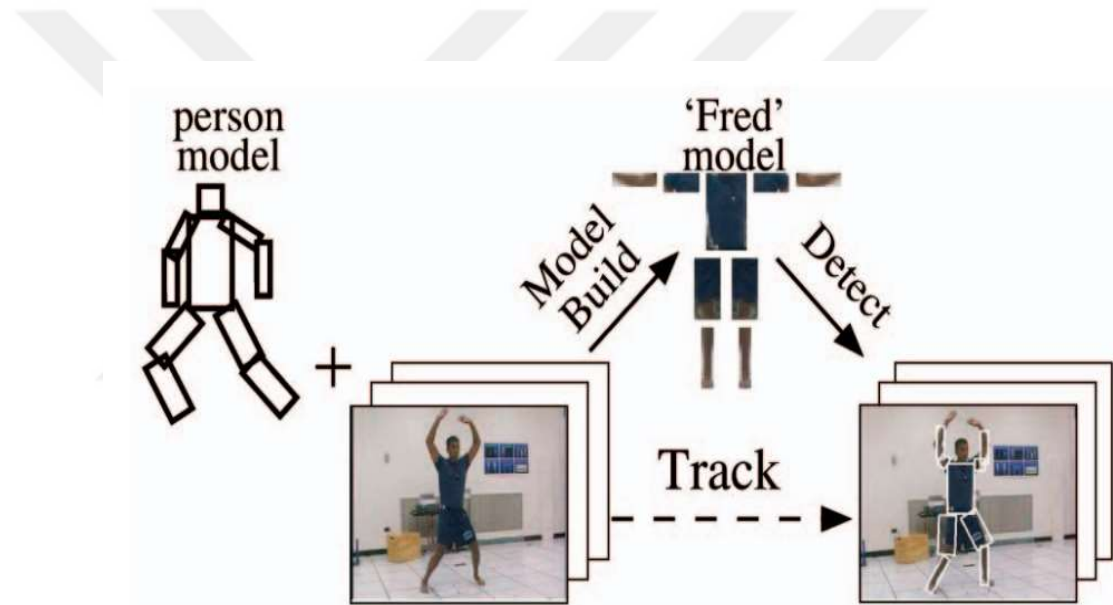
Şekil 2.1’de verilen Chatzitofis ve arkadaşlarının yaptığı bir çalışmada, düşük maliyetli bir marker tabanlı hareket yakalama sistemi olan DeMoCap üzerine çalışılmıştır. DeMoCap, "Low-Cost Marker-Based Motion Capture System" ifadesinin kısaltmasıdır. Sistemin adı, "DEveloped MOtion CAPture System" olarak da kullanılır (Chatzitofis et al., 2021). Bu çalışmada, düşük maliyetli bir marker tabanlı hareket yakalama sistemi olan DeMoCap'a odaklanılmıştır. DeMoCap sistemi, RGB-D kamera ve basit bir markalama yöntemi kullanarak hareketi kaydetmektedir. DeMoCap sistemi, birkaç örnek hareket üzerinde test edilmiş ve markalama doğruluğu ve sistem performansı incelenmiştir. Sonuçlar, DeMoCap sisteminin düşük maliyetli olmasına rağmen, yüksek doğruluk ve performans sağladığını ortaya koymuştur.

Geleneksel olarak, spor hareketlerinin analizi için kullanılan yöntemler çoğunlukla, marker tabanlı sistemlerdir. Ancak, bu yöntemler pahalı ve sınırlı bir alanı kapsayabilirler.

2.2. Marker Tabanlı Olmayan Hareket Analizi

Marker tabanlı olmayan hareket yakalama, insan hareketini kaydetmek için vücuda işaretler takılmasını gerektirmeyen teknikleri ifade eder. Marker tabanlı olmayan sistemler oyun geliştirme, animasyon, sağlık ve spor gibi çeşitli alanlarda kullanılmaktadır.


Marker tabanlı olmayan sistemlerden biri olan optik akış, videodaki piksellerin hareketini analiz ederek hareketleri takip eder (Horn & Schunck, 1981). Silüet analizi ise insan vücudunun silüetini analiz ederek hareketleri belirler (Ramanan et al., 2006). Ramanan ve arkadaşlarının yaptığı bir çalışmada, iki aşamalı tamamen otomatik bir sistem geliştirmişlerdir. İlk olarak, her bireyin görünüm modeli oluşturulmakta, ardından bu modeller kullanılarak her karede takip edilmektedir.



Şekil 2.2. Silüet analizi ile model oluşturma, tespit ve izleme süreci

Şekil 2.2’ de görüldüğü üzere Silüet Analizinde aşağıdan yukarıya vücut parçalarını gruplanır, daha sonra yukarıdan aşağıya anahtar pozlardan model oluşturulur (Ramanan et al., 2006). Ayrıca Ramanan ve arkadaşlarının yaptığı bu çalışmada geliştirilen sistem, karmaşık arka planlarda ve çok sayıda karede, insanların sayısını doğru bir şekilde sayma, izleme ve vücut konfigürasyonlarını belirleme yeteneğine sahip olduğunu belirtilmiştir. Yapılan deneylerde, sistemin insanların hareketlerini başarıyla takip edebildiğini belirtilmiştir.

Marker tabanlı olmayan analiz yöntemlerinden biriside derinlik kamerası yöntemidir. Bu yöntemde derinlik kameraları, 3 boyutlu derinlik bilgisi sağlayarak insan vücudunun hareketini takip edebilir (Shotton et al., 2011).



Şekil 2.3. Derinlik Kamerası ile insan vücut parçalarının tespiti ve 3D eklem önerileri analizi

Şekil 2.3’de görüldüğü üzere tek bir giriş derinliği görüntüsünden, piksel başına vücut kısmı dağılımını elde edilir. Renkler her pikseldeki parça etiketleri ve ortak tekliflerde karşılık gelen en muhtemel olanı gösterir. Bu sinyalin yerel modlarının, birden fazla kullanıcı için bile vücut eklemlerinin 3 boyutlu konumları için yüksek kaliteli öneriler vereceği tahmin edilmektedir (Shotton et al., 2011).

Shotton ve arkadaşlarının yaptığı derinlik kamerası ile analiz çalışmasında, tek bir derinlik görüntüsünden insan vücudu eklemlerinin 3D konumlarını hızlı ve doğru bir şekilde tahmin eden yeni bir yöntem önerilmektedir. Yöntem olarak derinlik görüntüsünü, her piksel için vücut parçalarını sınıflandıran bir model ile işlenmektedir. Bu, karmaşık bir poz tahminini basit bir sınıflandırma problemine dönüştürür. Çeşitli bir eğitim veri seti kullanılarak, poz, vücut şekli ve giysi gibi değişkenlere karşı dayanıklı tahminler yapılmıştır. Derinlik kameraları sayesinde düşük ışıkta bile etkili bir şekilde çalışır. Yapılan testlerde, hem sentetik hem de gerçek veri setlerinde yüksek başarı elde edilmiştir.

Marker tabanlı olmayan bir diğer hareket analizi yöntemi inert sensörlerdir. İnsan hareket analizi için giyilebilir eylemsizlik sensörleri kullanılabilirler. İvmeölçerlerin ve jiroskoplar vücudun hareketini ve yönünü ölçerek hareketleri takip edebilirler (Iosa et al., 2016).

Marker tabanlı olmayan hareket yakalama tekniklerinin en büyük avantajı işaret takma gerektirmediği için kurulumu kolaydır ve marker olmadığı için hareket özgürlüğü daha fazladır. Markerlar, hareketleri kısıtlayabilirken, marker tabanlı olmayan yakalama teknikleri daha doğal hareketleri kaydedebilir.

Ancak marker tabanlı olmayan hareket yakalama teknikleri marker tabanlı yakalamaya göre daha az hassas olabilir ve verileri analiz etmek için daha karmaşık algoritmalar gerektirebilir.

2.3. Diğer Analiz Teknikleri

Spor hareketlerinin form analizi için kullanılan diğer ileri analiz teknikleri arasında EMG analizi, kinematik analiz ve kinetik analiz gösterilebilir.

EMG analizi, hareket sırasında kasların elektriksel aktivitesini ölçer. Bu analiz, kasların nasıl çalıştığını ve hareketin nasıl etkilendiğini anlamak için kullanılır (Netto & Burnett, 2006).

Kinematik analiz, hareketin uzamsal ve zamansal özelliklerinin incelenmesidir. Bu analiz, hareketin yolunu, hızını ve ivmesini ölçerek hareketin nasıl gerçekleştiğini anlamaya çalışır (Hermsdörfer et al., 1996). Kinematik analiz hareketin nasıl gerçekleştiğini inceler. Konum, hız, ivme ve açısal hareket gibi değişkenleri ölçer. Hareketin geometrik yönlerini ele alır (Silva et al., 2022). Örneğin, bir koşucunun bacaklarının hareketini, ayaklarının yere temas süresini veya vücudun açısal hızını analiz eder.

Kinetik analiz ise harekete etki eden kuvvetleri inceler. Kuvvet, tork, güç ve enerji gibi değişkenleri ölçer. Hareketin nedenlerini ele alır (Silva et al., 2022). Örneğin, bir koşucunun yere uyguladığı kuvveti, eklemlerdeki yükü veya kasların ürettiği gücü analiz eder.

2.4. Derin Öğrenme ve Hareket Tanıma

Derin Öğrenme, yapay zekâ ve makine öğreniminin bir alt dalıdır ve yapay sinir ağları kullanarak verilerden otomatik öğrenme yöntemidir. Geleneksel makine öğrenimi tekniklerinden farklı olarak, derin öğrenme, ham verileri işleyerek yüksek düzeyde soyutlama düzeyleri oluşturmayı mümkün kılar. Bu süreç, verilerin daha anlamlı ve kullanışlı temsil biçimlerine dönüştürülmesini sağlar (LeCun et al., 2015).


Derin öğrenme, bir dizi katman içeren ağlardan oluşur. Her katman, önceki katmanın çıktısını alır ve bu veriyi daha yüksek bir soyutlama düzeyine dönüştürür. İlk katman genellikle temel özellikleri (örneğin, kenarları) öğrenirken, sonraki katmanlar daha karmaşık motifleri ve nesne parçalarını tanır. Geri Yayılım Algoritması, modelin tahmin hatalarını minimize etmek için ağırlıkları günceller. Hatalar, çıktılar ile beklenen sonuçlar arasındaki farkı ölçen bir fonksiyon kullanılarak hesaplanır (LeCun et al., 2015). Derin öğrenme, görüntülerdeki nesnelere tanımda yüksek başarı oranları sağlar. Örneğin, yüz tanıma sistemleri ve otonom araçlar bu teknolojiyle çalışır. Ses verilerini analiz ederek metne dönüştürme işlemleri, derin öğrenme ile daha doğru hale gelmiştir. Metin sınıflandırma, duygu analizi ve dil çevirisi gibi görevlerde etkili sonuçlar elde edilir. E-ticaret siteleri ve medya platformları, kullanıcıların ilgi alanlarına dayalı olarak içerik önerileri sunmak için derin öğrenme tekniklerini kullanır. Derin öğrenme, potansiyel ilaç moleküllerinin etkinliğini tahmin etme ve genetik verileri analiz etme gibi bilimsel araştırmalarda da önemli bir rol oynar (LeCun et al., 2015).

Derin öğrenme, karmaşık veri setlerinden anlamlı bilgiler çıkarmak için güçlü bir yöntem olup hareket tanıma sistemlerinin doğruluğunu ve etkinliğini artırmak için yaygın olarak kullanılmaktadır. Derin öğrenme algoritmaları, hareket verilerini analiz ederek daha karmaşık hareketleri tanıma yeteneğine sahip olup, bu sayede daha iyi sonuçlar elde edilmesini sağlar. Bu, spor hareketlerinin analizi ve sporcuların performanslarının değerlendirilmesi açısından önemli avantajlar sunmaktadır. Ayrıca, büyük veri setlerini işleyerek karmaşık problemleri çözme kapasitesine sahipken, hareket tanıma, insanların ve nesnelere hareketlerini algılayarak etkileşimli ve akıllı sistemler geliştirmeye olanak tanımaktadır.

Derin öğrenme, otomatikleştirilmiş sistemlerin geliştirilmesine olanak tanırken, insan hatalarını minimize ederek daha güvenilir sonuçlar elde edilmesine yardımcı olmaktadır. Bu alanda yapılmış çalışmalara kaynak araştırması bölümünde değinilmiştir.

2.5. Güç Sporları ve Powerlifting

Bazı spor hareketleri, insan vücudundaki birçok kas grubunu aynı anda çalıştırmaları nedeniyle temel hareketler olarak nitelendirilebilir. Powerlifting, squat, bench press ve deadlift gibi üç temel hareketten oluşan bir güç sporudur. Bu üç temel hareket, vücuttaki bütün kas gruplarını çalıştırabilir. Powerlifting, maksimal kuvvet gerektiren bir spordur. Sporcular her hareket kategorisinde üç deneme hakkına sahiptir ve tek bir tekrarda maksimum yükü kaldırmalıdır. Sporcuların her kategoride kaldırdığı en yüksek ağırlıklar toplanarak puanı belirlenir (Ferland & Comtois, 2019). Squat, ön bacak, kalça ve bel bölgesindeki kasları güçlendiren temel bir alt vücut egzersizidir. Deadlift ise sırt bölgesi, arka bacak ve kalça kaslarını en çok çalıştıran temel bir alt vücut egzersizi olarak bilinir. Squat hareketi daha çok ön bacak ve diz eklemlerini, deadlift ise daha çok sırt, kalça ve arka bacak bölgesini ağırlıklı olarak hedeflemektedir (Hales et al., 2009). Bench press, göğüs, omuz ve kol kaslarını daha yoğun olarak çalıştıran temel bir üst vücut egzersizidir (Brennecke et al., 2009). Bu hareketlerin uygulanması ile vücuttaki iskelet kaslarının neredeyse tamamına yakını çalıştırılarak verimli bir antrenman gerçekleştirilebilir.



Şekil 2.4. Powerlifting sporunda kullanılan temel hareketler

Şekil 2.4.a’da görüldüğü üzere, bench press, bir sehpa üzerine sırt üstü yatılarak halterin göğüs üzerinden itilmesiyle gerçekleştirilen bir spor hareketidir. Profesyonel kaldırırlarda kaldırılan ağırlık oldukça yüksek olduğundan dolayı halterin iki yanında da ağırlığın sporcunun üstüne düşmemesi için yardımcıları bulunurlar (Siewe et al., 2011).

Şekil 2.4.b’de yer alan deadlift hareketi, halteri eğilip yerden kaldırarak gerçekleştirilmektedir. Bu hareket sırasında halterin sporcunun üzerine düşme riski

bulunmamaktadır; ancak sakatlanma riskinin yüksek olması nedeniyle dikkatli bir şekilde yapılmalıdır (Siewe et al., 2011).

Şekil 2.4.c’de yer alan squat hareketi omzun üstüne alınan halterin çömelerek tekrar kaldırılması ile gerçekleştirilen bir spor hareketidir. Profesyonel kaldırışlarda halterin iki tarafında da yardımcıları bulunur ve sporcunun kaldıramadığı durumlarda müdahale ederler (Siewe et al., 2011).

Bununla birlikte, bu hareketlerinin doğru teknikle ve güvenli bir şekilde yapılması oldukça önemlidir. Hareketlerin doğru bir teknikle yapılmaması ya da hatalı hareket formları, sporcuların sakatlanma riskini artırmakta ve performanslarını olumsuz etkilemektedir (Meeuwisse et al., 2007). Özellikle Bench press, squat, deadlift gibi daha fazla kas grubunu aktif hale getiren hareketlerde, yüksek ağırlıklarla çalışabilme potansiyeli nedeniyle, hareket tekniği ve doğruluğu büyük öneme sahiptir. Bu nedenle, powerlifting hareketlerinin doğru tekniklerle yapılması sakatlanma riskini azaltmak ve sportif performansı optimize etmek için kritik öneme sahiptir.

3. DURUŞ TAHMİNİ


Duruş tahmini, bir nesnenin veya insanın konumunu ve yönelimini belirleme sürecidir. Genellikle bilgisayarla görme ve makine öğrenimi alanlarında kullanılır. 2D ve 3D duruş tahmini olmak üzere iki ana türü vardır. 2D duruş tahmini, iki boyutlu görüntülerden, insan vücudunun ana noktalarını (örneğin, baş, omuzlar, dirsekler) tespit etmektedir. Bu, genellikle görüntü işleme teknikleri ve derin öğrenme algoritmaları kullanılarak yapılır. 3D duruş tahmini ise üç boyutlu nesnelerin veya insanların pozisyonlarını ve yönelimlerini belirler. Bu tür tahmin, daha karmaşık algoritmalar ve genellikle daha fazla veri gereksinimi doğurur. Duruş tahmininin uygulamaları arasında, sanal gerçeklik, artırılmış gerçeklik, spor analizi, insan bilgisayarla etkileşim, güvenlik sistemleri gibi alanlar bulunmaktadır.

Duruş tahmini, spor hareketlerinin analizinde çeşitli çerçeveler ile birlikte kullanılmaktadır. Spor hareketlerinin analizi için en uygun çerçeveler, analiz etmek istenilen hareket türüne ve ihtiyaç duyulan hassasiyet seviyesine bağlı olarak değişmektedir. Ancak, genel olarak, aşağıdaki çerçeveler spor hareketlerinin analizi için iyi seçeneklerdir.

3.1. MediaPipe

MediaPipe, Google tarafından geliştirilen, algılayıcı verileri işlemek için kullanılan bir çerçevedir. Geliştiricilerin makine öğrenimi algoritmalarını ve modellerini hızlı bir şekilde prototipleyip uygulamalara dönüştürmelerine olanak tanır. MediaPipe, bileşenleri bir grafik şeklinde bir araya getirerek veri akışlarını yönetir ve farklı platformlarda çalışabilmektedir (Lugaresi et al., 2019).

MediaPipe, açık kaynak kodlu ve özellikle poz tahmini için tasarlanmış güçlü bir çerçevedir. Vücut noktalarını hassas bir şekilde tespit edebilmesi, spor hareketlerinin ayrıntılı bir şekilde analiz edilmesine olanak tanır. Ayrıca, gerçek zamanlı performansı, onu spor uygulamaları için ideal hale getirmektedir. Geleneksel ters kinematik yaklaşımlarının insan duruşlarındaki çeşitliliği ele almada yetersiz kaldığı durumlarda, MediaPipe bu kısıtlamaları aşmak için geliştirilmiştir. MediaPipe kütüphanesi, egzersiz videoları ve düşme senaryoları üzerinde test edilmiş olup, GPU'suz tek kartlı bilgisayarlarda bile çerçeve başına 33 ms hızında gerçek zamanlı olarak çalışabilme yeteneği göstermiştir (Kim et al., 2023). Bu özelliklerin MediaPipe kullanımı ile elde edilen 33 anahtar noktanın dağılımı Şekil 3.1' de gösterilmiştir.

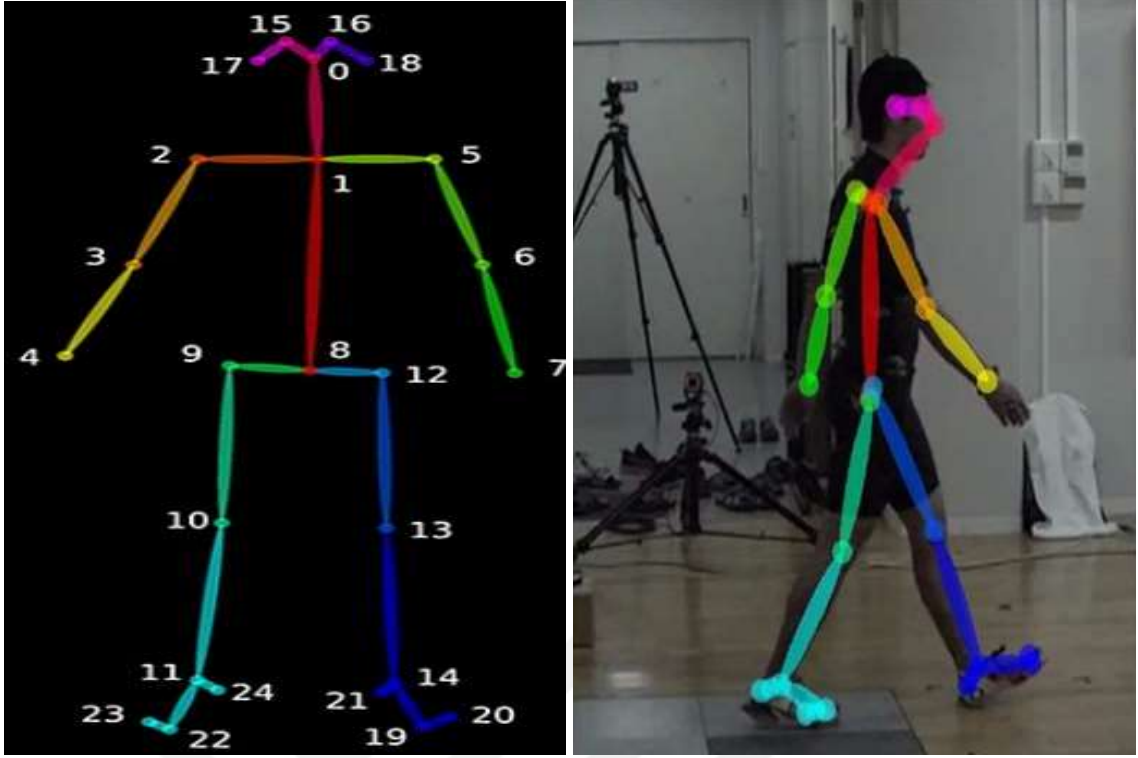


Şekil 3.1. MediaPipe kullanımı ile elde edilen 33 anahtar noktanın dağılımı

Google tarafından geliştirilen MediaPipe, kolay entegrasyon ve düşük gecikme süresi ile hızlı performans sunmaktadır. Aynı zamanda Şekil 3.1’de görüldüğü üzere 33 nokta dağılımı ile hassas tahminlerde yapabilmektedir. MediaPipe anahtar nokta tablosu Ek-1’de verilmiştir. MediaPipe birçok uygulama için hazır çözümler sunabilmekte ve özellikle insan vücudu duruş tahmini, hareket analizi veya artırılmış gerçeklik uygulamalarında oldukça kullanışlıdır. Bu özellikleri, geliştiricilerin çeşitli alanlarda hızlı ve etkili çözümler üretmelerine olanak tanımaktadır.

3.2. OpenPose

OpenPose, insan vücut pozlarını ve anahtar noktalarını (eklem merkezleri) tespit etmek için kullanılan bir bilgisayarla görme teknolojisidir. Derin öğrenme algoritmalarıyla çalışan bu sistem, görüntülerden veya videolardan insan postürlerini belirleyerek, 2D ve 3D koordinatları çıkartabilir. (Nakano et al., 2020).



Şekil 3.2. OpenPose kullanımı ile elde edilen 25 anahtar noktanın dağılımı

Şekil 3.2’ de görüldüğü üzere OpenPose 25 anahtar nokta ile duruş tahmini yapmaktadır (Nakano et al., 2020). Çalışmalar, OpenPose’un işaretli hareket yakalama için etkili bir yöntem sunduğunu ve farklı motor görevlerini doğru bir şekilde analiz edebildiğini göstermektedir.

OpenPose gerçek zamanlı insan poz tahmini için kullanılabilir. Görüntüdeki tüm anahtar noktaları (örneğin, dirsek, bilek, diz, ayak bileği) tespit edilebilir. Tespit edilen anahtar noktalar, aynı kişiye ait olanları bir araya getirerek, kişilerin iskeletlerini oluşturmak için gruplandırılır (Osokin, 2018).

OpenPose’un orijinal mimarisinin VGG-19 gibi büyük bir ağı kullanması, özellikle son işlem aşaması zaman alıcı olması ve çok fazla işlem gücü gerektirmesi gibi dezavantajlı yönleri sahiptir.

3.3. PoseNet

PoseNet’in TensorFlow üzerinde geliştirilmiş bir derin öğrenme modelidir. TensorFlow, Google tarafından geliştirilen bir açık kaynak derin öğrenme çerçevesidir. PoseNet, bu çerçeveyi kullanarak insan duruş tahmini gerçekleştiren bir modeldir.

PoseNet, insan vücudunun ana eklem noktalarını tahmin etmek için kullanılır. PoseNet, bir görüntüyü alır ve bu görüntüdeki ana eklem noktalarının (baş, omuz, dirsek,

vb.) konumlarını tahmin eder. PoseNet, bu noktaların konumlarını belirlemek için ısı haritaları kullanır. Her bir eklem noktası için bir ısı haritası üretilir (Chen et al., 2017).



Şekil 3.3. Örnek PoseNet duruş tahminleri

Şekil 3.3’ de görüldüğü üzere PoseNet insan vücudunun belirli noktalarını (örneğin, dirsek, bilek, omuz, diz, ayak bileği) tespit edebilir. Bu noktaların konumları, insanın pozunu temsil eden bir "iskelet" oluşturmak için kullanılır (Shah et al., 2021).

Genellikle, bir konvolüsyonel sinir ağı (CNN) mimarisi kullanır. Bu mimari, görüntüdeki özellikleri öğrenmek için katmanlar halinde yapılandırılmıştır. Spor analizleri, sanal gerçeklik uygulamaları, hareket algılama sistemleri ve daha fazlasında kullanılabilir. İnsan poz tahmini, ayrıca oyunlar ve etkileşimli medya gibi alanlarda da önemli bir rol oynamaktadır.

PoseNet hızlı bir şekilde tahminler yapabilir, bu da onu gerçek zamanlı uygulamalar için uygun hale getirir. Farklı poz ve açıları tanıma yeteneği ile geniş bir kullanım alanına sahiptir (Chen et al., 2017).

3.4. AlphaPose

AlphaPose, çoklu kişi poz tahmini ve izleme işlemini gerçeğe yakın zaman diliminde gerçekleştiren bir sistemdir. Geleneksel vücut poz tahminlerinden farklı olarak, yüz, beden, el ve ayak gibi tüm vücut parçalarının tahminini yapar (Fang et al., 2022).



Şekil 3.4. Örnek AlphaPose duruş tahminleri

Şekil 3.4’ de AlphaPose ile yapılan duruş tahminleri verilmiştir (Fang et al., 2022). AlphaPose hızlı ve hassas konumlandırma sağlayabilir. Ayrıca gereksiz insan tespitlerini ortadan kaldırabilir. Duruş tahmini ve izlemeyi aynı anda yapabilmektedir.

3.5. DeepPose

DeepPose, insan poz tahmini için geliştirilmiş bir derin öğrenme yöntemidir. Bu yöntem, bir görüntüdeki insan vücudu eklemlerinin konumunu tahmin etmek amacıyla derin sinir ağları (DSA) kullanır. DeepPose, poz tahminini bir regresyon problemi olarak ele alır ve tüm görüntüyü dikkate alarak eklemlerin konumlarını tahmin eder (Toshev & Szegedy, 2014).

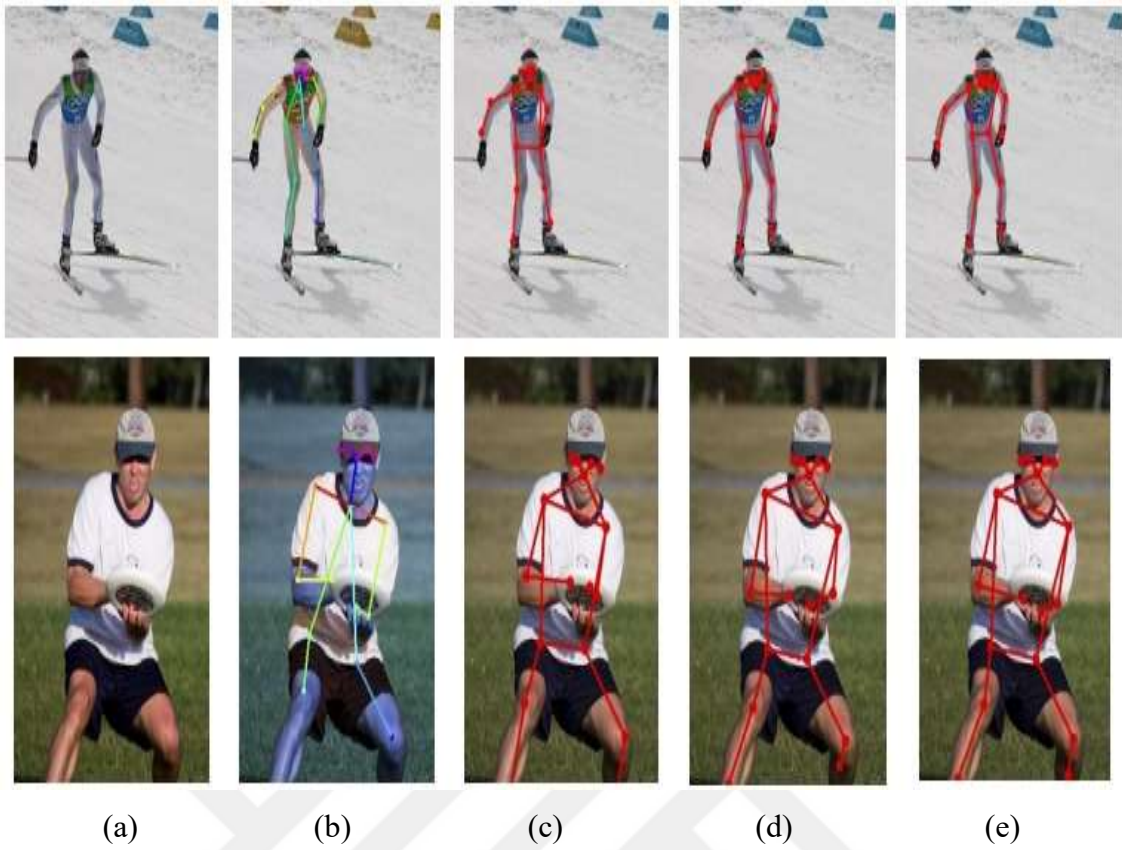


Şekil 3.5. Örnek DeepPose duruş tahminleri

Şekil 3.5’de verilen görseller Toshev ve arkadaşlarının DSA ile yaptığı çalışma ile elde edilmiştir. DeepPose, eklemlerin konumunu tahmin ederken tüm görüntüyü analiz eder. Bu, eklemler arasındaki ilişkilerin daha iyi anlaşılmasını sağlar. Duruş tahmini, bir DSA aracılığıyla, her bir eklemin koordinatlarının doğrudan regresyonu ile gerçekleştirilir. İlk tahminlerden sonra, daha yüksek çözünürlüklü alt görüntüler kullanılarak poz tahminleri incelenir ve iyileştirilir (Toshev & Szegedy, 2014).

3.6. MoveNet

MoveNet, Google tarafından geliştirilen bir poz tahmin modelidir. Lightning ve Thunder olmak üzere iki versiyonu bulunur. Bu modeller, mobil cihazlar için optimize edilmiştir ve hızlı, doğru poz tahmini sağlamayı hedefler (Jo & Kim, 2022).

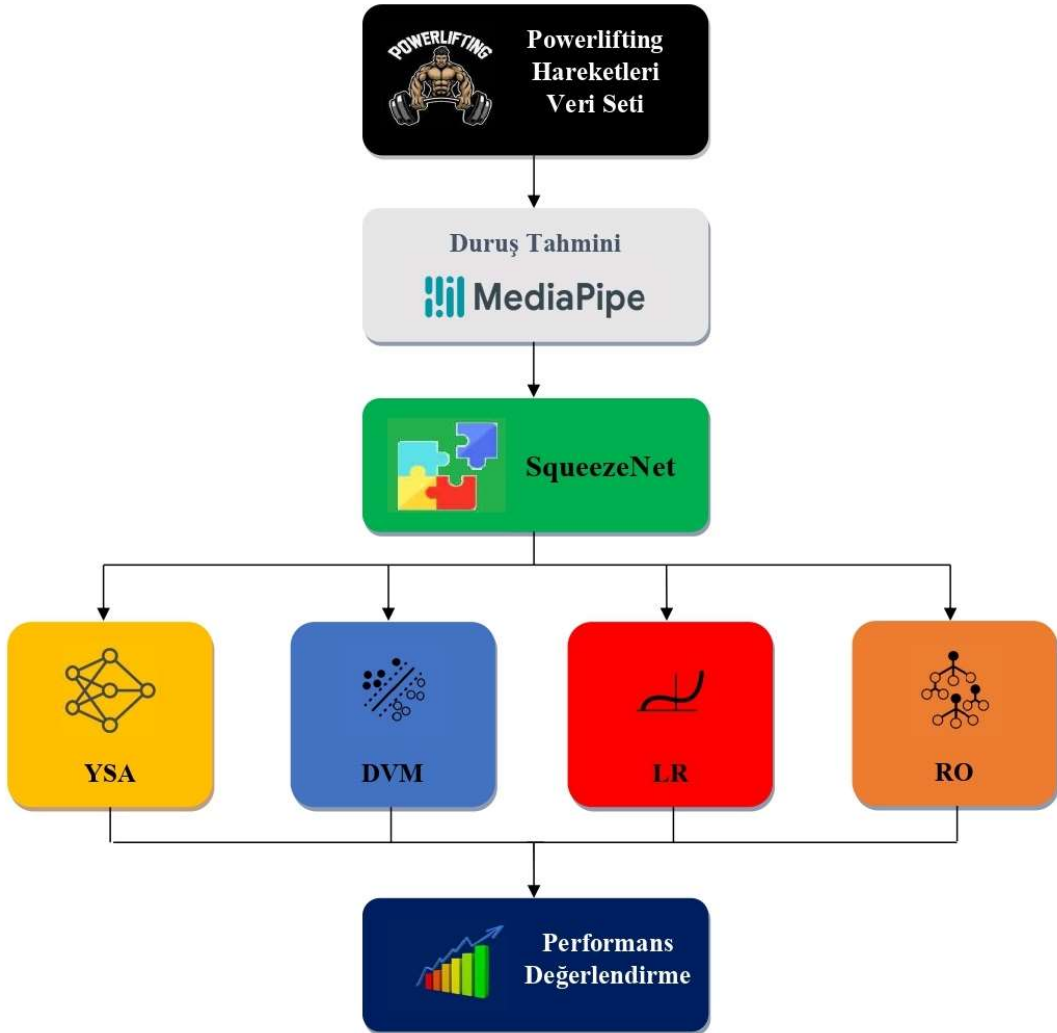


Şekil 3.6. Örnek MoveNet karşılaştırma sonuçları
 (a) Orijinal görüntü (b) OpenPose (c) PoseNet (d) MoveNet Lightning
 (e) MoveNet Thunder

Şekil 3.6’ da OpenPose, PoseNet, MoveNet Lightning ve MoveNet Thunder modellerine ait sonuçlar gösterilmiştir (Jo & Kim, 2022). MoveNet Lightning, hız odaklıdır ve daha az hesaplama gücü ile çalışarak hızlı sonuçlar sunar. Girdi boyutu 192x192 piksel ve 1.0 derinlik çarpanı kullanır. MoveNet Thunder, hassasiyet odaklıdır ve daha yüksek doğruluk sağlar. Girdi boyutu 256x256 piksel ve 1.75 derinlik çarpanı kullanır (Jo & Kim, 2022). MoveNet, bir kişinin merkez noktasını belirler ve bu noktaya dayalı olarak diğer anahtar noktaları çıkarabilir. MoveNet, mobil cihaz uygulamalarında, artırılmış gerçeklik (AR), sağlık teknolojileri ve spor gibi alanlarda kullanılabilir.

4. MATERYAL VE YÖNTEM


Bu çalışmada, Powerlifting hareketlerini içeren veri seti oluşturularak ve bu veri seti kullanılarak duruş tahmini yapılmıştır. Duruş tahmini yapılan veri setindeki görüntülerden özellik çıkarımı yapmak amacıyla, hafif ve hızlı bir evrimsel sinir ağı mimarisi olan SqueezeNet modeli kullanılmıştır. Çıkarılan bu özellikler, YSA, DVM, LR ve RO makine öğrenmesi algoritmalarına girdi olarak verilmiş, ardından elde edilen sınıflandırma sonuçları ayrıntılı bir şekilde analiz edilmiştir. Her bir modelin performansı, Doğruluk, Kesinlik, Duyarlılık ve F1 ölçütü gibi yaygın kullanılan performans metrikleri ile değerlendirilmiştir. Şekil 4.1, tez çalışması kapsamında kullanılan veri akışını ve modelleme sürecini sunmaktadır.



Şekil 4.1. Powerlifting hareketlerinin sınıflandırılması için kullanılan modelleme sürecine ait akış şeması

4.1. Veri Seti

Bu çalışmada, Powerlifting hareketlerini (bench press, squat, deadlift) içeren bir veri seti, arama motorları, sosyal medya platformları gibi çeşitli çevrimiçi kaynaklardan derlenerek oluşturulmuştur. Bu veri seti oluşturma süreci için, Selçuk Üniversitesi Teknoloji Fakültesi Bilimsel Araştırma ve Etik kurulundan 2024/03 sayılı kararı ile izin alınmıştır. Şekil 4.2’de gösterildiği üzere ham veri seti Bench press hareketi için 217, Deadlift hareketi için 359, Squat hareketi için 300 toplamda 876 görüntüden oluşmaktadır. Görüntülerin çözünürlüğü ve kalitesi değişiklik gösterdiğinden, ilk adım olarak tüm görüntüler 640x640 piksel boyutlarına ölçeklendirilmiştir.



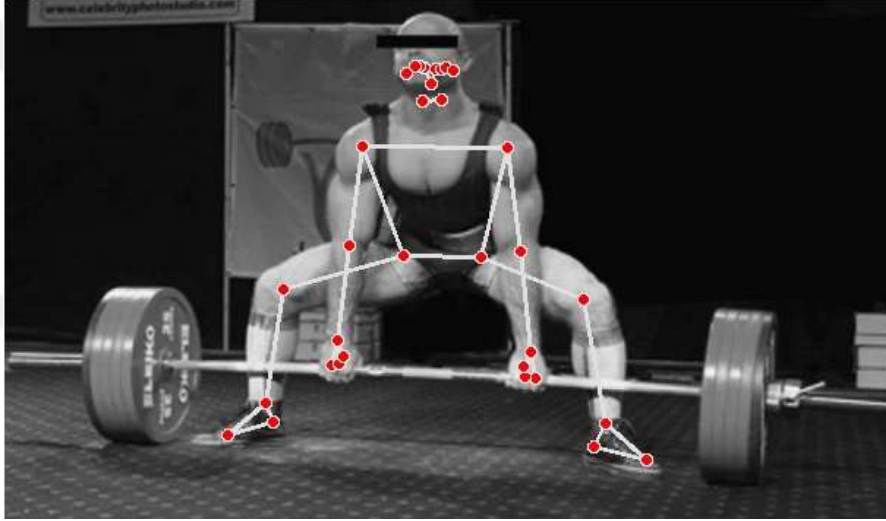
Şekil 4.2. Kullanılan veri seti ve kategorilere göre dağılımı

Veri artırma (data augmentation), mevcut veri seti üzerinden küçük varyasyonlar içeren sentetik veri oluşturma tekniklerini ifade eder. Bu teknikler, modelin öngörülerini değiştirmeden verinin çeşitliliğini artırarak aşırı öğrenmeyi (overfitting) önlemeye yardımcı olur. Böylece model, rastlantısal örüntüleri ezberlemek yerine daha genelleştirilebilir özellikler öğrenebilir (Shorten et al., 2021). Bu çalışmada veri artırma tekniklerinden döndürme (rotation) yöntemi kullanılmıştır. Toplanan orijinal görüntüler üzerinde -15° ile $+15^\circ$ arasında rastgele döndürme işlemi uygulanmıştır. Bu süreç sonucunda, orijinal 876 görüntüden toplam 2557 görüntü üretilmiştir. Spesifik olarak, Bench Press için 217 görüntü 636’ya, Squat için 300 görüntü 875’e ve Deadlift için 359 görüntü 1046’ya çıkarılmıştır. Bu veri artırma süreci ile, modelin daha genelleştirilebilir ve güçlü özellikler öğrenmesi amaçlanmıştır.

4.2. Veri Ön İşleme

MediaPipe, hız, performans, kullanım kolaylığı, çok yönlülük, hassasiyet ve mobil destek gibi avantajlarıyla duruş tahmini için tercih edilmiştir. Bu kapsamda, elde edilen 2557 görüntü üzerinde 3 boyutlu duruş tahmini gerçekleştirmek için MediaPipe kütüphanesi kullanılmıştır.

MediaPipe'in Pose Estimation modülü, insan vücudunun konumunu ve duruşunu yüksek doğrulukla tahmin edebilen bir yapay zeka modeli içermektedir. Bu model, insan vücudunun 33 anahtar noktasını tespit ederek, her bir görüntü için 3 boyutlu iskelet verilerinin çıkarılmasını sağlamıştır. Bu sayede, her görüntüye ait 33 anahtar noktanın koordinatlarını içeren veriler elde edilmiştir. Şekil 4.3'te gösterildiği üzere, her bir görüntü üzerine bu anahtar noktalar eklenmiştir.



Şekil 4.3. MediaPipe kütüphanesi kullanılarak Deadlift hareketi sırasında tespit edilen 33 anahtar nokta ile iskelet yapısının görselleştirilmesi

Bu tez çalışmasında ilk olarak SqueezeNet ile özellik çıkarımı yapılmadan yalnızca MediaPipe kütüphanesinin belirlediği 33 anahtar noktanın x, y ve z koordinatları kullanılarak makine öğrenmesi modeli oluşturulmuş ve bu model test edilmiştir. Ayrıca SqueezeNet ile özellik çıkarımı yapılmış, ardından bu özelliklerle birlikte veri artırma ve duruş tahmini sonuçları test edilmiştir.

4.3. Duruş Tahmini Bilgilerinin Kullanımı

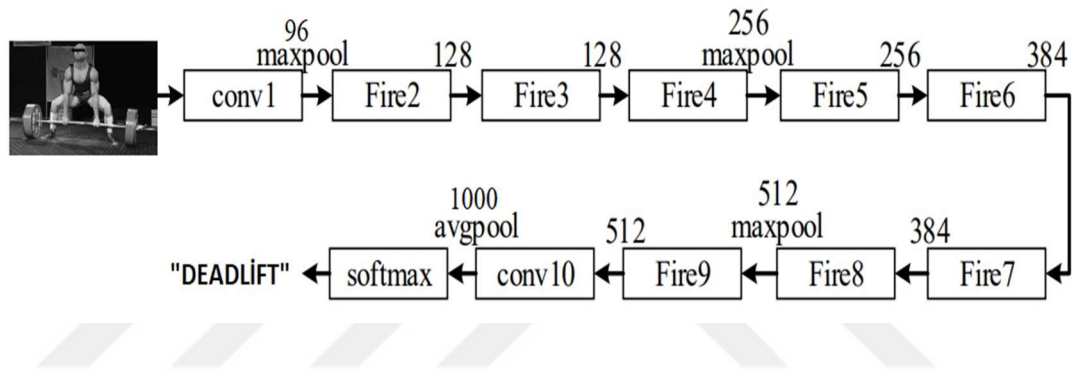
MediaPipe, insan vücudunda 33 anahtar noktayı tespit ederek duruş tahmini yapabilen bir çerçeve sunmaktadır. MediaPipe kütüphanesi tespit edilen bu 33 noktanın x,y ve z koordinatlarını verebilmektedir. X ve y koordinatları, görüntünün genişliği ve yüksekliği üzerinden 0 ile 1 arasında normleştirilmiş değerlerdir. X koordinatı, soldan sağa doğru yatay ekseninde, Y koordinatı ise yukarıdan aşağıya doğru dikey ekseninde konumlandırmayı belirtir. Z koordinatı ise derinliği, vücudun kameraya olan mesafesi hakkında bilgi verir. Z değeri de normleştirilmiş olup genellikle ortalama bir zemin düzlemine göre hesaplanır.

Güvenirlilik eşik değeri, modelin bir vücut parçasını veya belirli bir anahtar noktayı tespit etme konusunda ne kadar emin olması gerektiğini belirleyen bir parametredir. Örneğin güvenirlilik eşik değeri 0.5 olarak ayarlandığında, modelin tespit ettiği bir noktanın güvenirlilik skoru en az %50 olmalıdır. Başka bir deyişle, model bir anahtar noktanın doğru olduğuna %50 veya daha fazla güven oranıyla tahmin ediyorsa, bu nokta tespit edilmiş kabul edilir. Güvenirlilik skoru %50'nin altında kaldıysa, model bu noktayı tespit etmemiş olarak değerlendirilebilir ya da daha düşük bir güvenle raporlayabilir. Bu eşik değeri, uygulamanızın gereksinimlerine göre ayarlanabilir. Daha yüksek bir eşik değeri (örneğin 0.7 veya 0.8) kullanılırsa, yalnızca daha emin olunan tespitler kabul edilir, ancak bazı noktalar kaçırılabilir. Daha düşük bir eşik değeri ise daha fazla tespiti kabul edebilir, ancak bu durumda bazı tespitler daha az güvenilir olabilir. Bu veriler, özellikle insan vücudu poz takibi, hareket analizi veya artırılmış gerçeklik uygulamaları gibi projelerde oldukça kullanışlıdır.

Bu çalışmada duruş tahmini verilerinin kullanımı üç aşama halinde test edilmiştir. İlk aşamada 33 anahtar nokta bilgilerinin tamamı kullanılarak model değerlendirilmiştir. İkinci aşamada ise, duruş tahmini bilgilerinin kullanımı için tüm noktaların kullanımı yerine Powerlifting hareketlerinin tespitinde daha belirleyici olan 12 anahtar nokta kullanılarak test edilmiştir. Bu noktalar; 11. Nokta (Sol Omuz), 12. Nokta (Sağ Omuz), 13. Nokta (Sol dirsek), 14. Nokta (Sağ dirsek), 15. Nokta (Sol Bilek), 16. Nokta (Sağ bilek), 23. Nokta (Sol kalça), 24. Nokta (Sağ Kalça), 25. Nokta (Sol diz), 26. Nokta (Sağ diz), 27. Nokta (Sol ayak bileği) ve 28. Nokta (Sağ ayak bileği) olarak belirlenmiştir. Üçüncü aşamada ise, 12 anahtar nokta ile beraber MediaPipe güvenirlilik eşik değeri kullanılarak model test edilmiş ve sonuçlar paylaşılmıştır.

4.4. Özellik Çıkarımı

SqueezeNet, derin öğrenme arařtırmacıları tarafından mobil ve gömülü cihazlarda çalıştırılabilecek şekilde tasarlanmış, düşük parametrelili bir Evriřimsel Sinir Ađı (ESA) mimarisidir. Bu mimari, AlexNet gibi daha büyük modellerle kıyaslandığında, benzer doğruluk seviyelerine ulaşırken önemli ölçüde daha az hesaplama yükü gerektirir. SqueezeNet, ImageNet'te AlexNet'e yakın doğruluk elde eden ancak parametresi 50 kat daha az olan bir CNN mimarisidir. SqueezeNet'in temel yapıtaşı, "Fire Modülü" olarak adlandırılan ve sıkıştırma (squeeze) ile genişleme (expand) aşamalarından oluşan bir modüldür. Fire Modülü, giriş kanallarını önemli ölçüde azaltarak, modelin parametre sayısını azaltmakta kritik bir rol oynar. SqueezeNet mimarisi, 8 Fire Modülü ve başlangıç ile çıkış katmanlarından oluşur (Iandola et al., 2016).



Şekil 4.4. SqueezeNet modelinin mimari yapısı

Şekil 4.4'te gösterildiđi üzere, SqueezeNet tek bir başlangıç konvolüsyon katmanı (conv1) ile başlar ve ardından 8 adet "Fire Modülü" (fire2-9) yer alır. Modelin sonunda ise tek bir çıkış konvolüsyon katmanı (conv10) bulunmaktadır. Fire Modülleri içindeki filtre sayıları, ađın derinliđi arttıkça artırılır; bu, ilerleyen modüllerde daha fazla filtre kullanılması anlamına gelir. Ayrıca, maksimum havuzlama katmanları conv1, fire4, fire8 ve conv10 katmanlarından sonra uygulanır. Bu mimari tasarım kararları, SqueezeNet'in parametre sayısını önemli ölçüde azaltarak AlexNet seviyesinde doğruluk elde etmesini sağlamayı hedefler. Özellikle, Fire Modülü yapısı ve havuzlama katmanlarının stratejik konumlandırılması, bu hedefin gerçekleştirilmesine katkıda bulunur. SqueezeNet'in daha az katman kullanımı, modelin hafif olmasını ve daha düşük bellek gereksinimi ile çalışmasını sağlar (Iandola et al., 2016). SqueezeNet mimarisinin temel yapısı, Fire Modülü tasarımı ve havuzlama katmanlarının konumlandırılması, parametre sayısını önemli ölçüde azaltırken yüksek doğruluk elde etmeyi hedefleyen verimli bir derin öğrenme mimarisidir.

Inception-v3, derin öğrenme alanında yaygın olarak kullanılan bir ESA mimarisidir. Google tarafından geliştirilmiştir ve özellikle görüntü sınıflandırma görevlerinde yüksek performans göstermektedir (Wang et al., 2019). Inception-v3 mimarisi, farklı boyutlardaki filtreleri (1x1, 3x3, 5x5) aynı anda kullanarak, çeşitli özellikleri aynı katmanda öğrenir. Bu, modelin daha fazla bilgi yakalamasını sağlar. Inception-v3, toplamda 48 katmandan oluşur ve bu derinlik, karmaşık görüntülerin daha iyi sınıflandırılmasını mümkün kılar. Inception-v3, büyük bir veri seti olan ImageNet üzerinde eğitilmiştir. Bu, modelin daha az veri ile eğitildiğinde bile iyi performans göstermesini sağlar (Wang et al., 2019).


VGG-19, derin öğrenme alanında yaygın olarak kullanılan bir ESA mimarisidir. VGG-19, 19 katmandan oluşur. Bu katmanlar, 16 evrişimsel katman ve 3 tam bağlı katmandan oluşur (Mateen et al., 2018). Evrişimsel katmanlar, 3x3 boyutunda filtreler kullanarak görüntüdeki özellikleri çıkarmak için tasarlanmıştır. Bu küçük filtre boyutları, daha derin katmanlar oluşturulmasına olanak tanır. Her iki veya üç evrişimsel katmandan sonra, boyut azaltma için havuzlama katmanları eklenmiştir. Bu, modelin hesaplama yükünü azaltırken aynı zamanda özelliklerin özetlenmesine yardımcı olur. VGG-19, iki adet tam bağlı katman içerir. Bu katmanlar, çıkarılan özellikleri sınıflandırmak için kullanılır ve her biri 4096 nöron içerir. VGG-19, ImageNet veri seti üzerinde eğitilmiştir ve görüntü sınıflandırma görevlerinde yüksek doğruluk oranları elde etmiştir (Mateen et al., 2018).

Bu çalışmada SqueezeNet, Inception-v3 ve VGG-19 olmak üzere üç farklı ESA mimarisi test edilmiştir. Test sonuçlarına göre, SqueezeNet %86,8 doğruluk oranıyla diğer iki mimariden daha başarılı bulunmuş ve bu nedenle çalışma kapsamında tercih edilmiştir. SqueezeNet'in son katmanlarından biri olan conv10 katmanından her bir görüntü için 1000 adet özellik çıkarılmıştır. Bu özellikler, görüntülerin derin öğrenme modelleri tarafından daha iyi anlaşılabilmesi için gerekli olan yüksek seviyeli temsillerdir. Ancak, yüksek boyutlu özellik vektörleri, hesaplama yükünü artırabilir ve modelin genelleme yeteneğini azaltabilir. Bu nedenle, elde edilen 1000 özellik arasından en anlamlı ve ayırt edici olanlarını seçmek amacıyla Gini indeksi kullanılmıştır. Gini indeksi, özellikle sınıflar arasındaki ayrımı en iyi şekilde gerçekleştiren özellikleri seçmektedir. Bu süreç sonunda, ilk 500 özellik belirlenmiş ve bu özellikler modelin eğitim ve test aşamalarında kullanılmıştır.

4.5. Makine Öğrenmesi Algoritmaları

Bu araştırmada, yaygın olarak kullanılan makine öğrenmesi algoritmaları olan Yapay Sinir Ağı (YSA), Lojistik Regresyon (LR), Destek Vektör Makinesi (DVM) ve Rastgele Orman (RO) algoritmaları kullanılmıştır.

YSA, beyindeki nöronlar ve sinaptik bağlantılar gibi çalışan bilgisayarlaştırılmış modellerdir(Rumelhart et al., 1986). Birden çok katmandan oluşan, geri yayılım algoritmasıyla eğitilen derin öğrenme mimarileri, görüntü, ses, dil işleme gibi karmaşık problemlerde yüksek başarı sağlar(LeCun et al., 2015). Özellik çıkarımını ve sınıflandırmayı birleştirir ve çok sayıda parametre içerir, daha güçlü temsil öğrenebilir(Goodfellow et al., 2016).



Şekil 4.5. Yapay sinir ağı mimarisi

Şekil 4.5’de verilen YSA mimarisinde görüldüğü üzere giriş birimleri (Input Units) modelin aldığı verileri ve modelin öğrenmeye başladığı verileri temsil etmektedir (LeCun et al., 2015). Gizli birimler (Hidden Units) giriş verilerinin daha yüksek düzeyde temsilini oluşturmaktadır. Her gizli birim, önceki katmandan aldığı bilgileri işler ve çıkış birimlerine iletir. Çıkış birimleri (Output Units), modelin son çıktısını temsil eder. Genellikle sınıflandırma problemlerinde belirli sınıflara ait olasılıkları üretmektedir. Ağırlıklar (Weights), katmanlar arasındaki bağlantıları temsil eder. Her bir bağlantı, sinir ağının öğrenme sürecinde güncellenen bir değerdir. Ağırlıklar, modelin girişten çıkışa geçişteki etkisini belirler (LeCun et al., 2015). Yapay Sinir Ağı, bu yapı sayesinde karmaşık görevleri yerine getirebilmektedir.

LR, doğrusal bir sınıflandırma algoritmasıdır ve genellikle ikili sınıflandırma problemleri için kullanılır(Hastie et al., 2009). Bağımsız değişkenlerin doğrusal kombinasyonunu kullanarak, bağımlı değişkenin olasılığını hesaplar ve sınıf etiketlerini tahmin eder. Parametreleri gradyan yöntemi gibi optimizasyon teknikleriyle öğrenilir. Bu algoritma, özellikle sınıfların birbirinden belirgin bir şekilde ayrılabilirdiği durumlarda etkilidir (Bishop & Nasrabadi, 2006).

DVM, hem sınıflandırma hem de regresyon problemleri için kullanılabilen bir algoritmadır. Temel amacı, sınıflar arasındaki optimal ayırıcı hiper düzlemi bulmaktır. DVM, çekirdek fonksiyonları (kernel functions) kullanarak doğrusal olmayan problemleri de çözebilme kapasitesine sahiptir (Cortes & Vapnik, 1995). Aykırı değerlere ve gürültüye karşı dayanıklıdır ve yüksek boyutlu veri için etkilidir(Schölkopf & Smola, 2002).

RO, çok sayıda karar ağacının birleştirilmesiyle oluşan bir topluluk öğrenme algoritmasıdır (Breiman, 2001). Her bir ağaç, eğitim verilerinin rastgele bir alt kümesi üzerinde eğitilir ve sonuçların çoğunluğuna göre nihai sınıflandırma veya regresyon tahmini yapılır. RO, aykırı değerlere, gürültüye ve aşırı uyum problemlerine karşı dayanıklı olup, ayrıca değişken önem sıralaması yapabilme kabiliyeti ile dikkat çeker (Liaw & Wiener, 2002).

Bu çalışmada kullanılan her bir makine öğrenmesi algoritmasının güçlü ve zayıf yönleri, çözülmesi gereken problemin türüne ve veri setinin özelliklerine göre farklılık gösterebilmektedir. Bu nedenle, powerlifting hareketlerinin sınıflandırılmasında en uygun algoritmayı belirleyebilmek için kapsamlı bir değerlendirme ve karşılaştırma yapılmıştır. Bu süreçte, YSA, LR, DVM ve RO algoritmaları, model performansı ve doğruluk açısından test ve analiz edilmiştir.

4.6. Performans Değerlendirme Metrikleri

Makine öğrenmesi modellerinin performansını değerlendirmek için kullanılan temel yöntemlerden biri karmaşıklık matrisi analizidir. Karmaşıklık matrisi, modelin tahminlerinin doğruluğunu çeşitli kategorilerde özetler ve dört temel bileşeni içerir: Doğru Pozitif (DP), Doğru Negatif (DN), Yanlış Pozitif (YP) ve Yanlış Negatif (YN).

DP, modelin doğru bir şekilde pozitif olarak tahmin ettiği örneklerdir. DN, modelin doğru bir şekilde negatif olarak tahmin ettiği örneklerdir. YP, modelin yanlış bir şekilde pozitif olarak tahmin ettiği örneklerdir. YN, modelin yanlış bir şekilde negatif olarak tahmin ettiği örneklerdir(Sokolova & Lapalme, 2009).

		TAHMİN EDİLEN SINIF		
		Bench Press	Deadlift	Squat
GERÇEK SINIF	Bench Press	DP	YN	YN
	Deadlift	YP	DP	YN
	Squat	YP	YP	DP

Şekil 4.6. Üçlü sınıflandırma için karmaşıklık matrisi

DN, belirli bir sınıf için doğru negatif tahminlerin sayısını ifade eder. Yani, belirli bir sınıfın dışında kalan diğer sınıflar için doğru tahminlerdir. Denklem 5.1, 5.2, 5.3, 5.4, 5.5, 5.6 verildiği gibi karmaşıklık matrisi kullanılarak çeşitli performans metrikleri hesaplanabilir.

Üçlü sınıflandırma için performans metriklerini hesaplamak, her sınıf için ayrı ayrı değerlendirme yapmayı gerektirir.

Modelin doğru sınıflandırdığı örneklerin toplam örneklere oranı Doğruluk ile ifade edilmektedir. Denklem 5.1’de üçlü sınıflandırma da doğruluk için gerekli formül verilmiştir.

$$\text{Doğruluk} = \frac{DP_1+DP_2+DP_3}{DP_1+DN_1+Y_1+YN_1+DP_2+DN_2+YP_2+YN_2+DP_3+DN_3+YP_3+YN_3} \quad (5.1)$$

Kesinlik (Precision), pozitif tahmin edilen örneklerden kaçının gerçekten pozitif olduğunu gösterir. Yanlış pozitiflerin oranını azaltmayı hedefleyen durumlar için önemlidir. Denklem 5.2' de Kesinlik formülü verilmiştir.

$$\text{Kesinlik}_i = \frac{DP_i}{DP_i+YP_i} \quad (5.2)$$

Duyarlılık (Recall) veya Gerçek Pozitif Oranı (True Positive Rate), gerçek pozitif örneklerin ne kadarının doğru tahmin edildiğini gösterir. Modelin, pozitif sınıfı yakalama kabiliyetini ifade eder. Denklem 5.3'de Duyarlılık formülü verilmiştir.

$$\text{Duyarlılık}_i = \frac{DP_i}{DP_i+YN_i} \quad (5.3)$$

F1 Ölçütü, Kesinlik ve Duyarlılık metriklerinin harmonik ortalamasıdır ve özellikle dengesiz veri kümelerinde daha anlamlı bir ölçü olabilir. Denklem 5.4'de F1 Ölçütü formülü verilmiştir.

$$F1_i = \frac{2 \times \text{Duyarlılık}_i \times \text{Kesinlik}_i}{\text{Duyarlılık}_i + \text{Kesinlik}_i} \quad (5.4)$$

Her sınıf için ayrı ayrı hesaplanan metrikler, genel bir performans değerlendirmesi elde edebilmek amacıyla aritmetik ortalama ile birleştirilmiştir. Örneğin, F1 ölçütü için her sınıfa ait F1 skorları alınmış ve bu skorların aritmetik ortalaması hesaplanarak genel bir F1 skoru elde edilmiştir. Bu işlem için Denklem 5.5'te verilen formül kullanılmıştır.

$$F1 = \frac{F1_1+F1_2+F1_3}{3} \quad (5.5)$$

Matthews Korelasyon Katsayısı (MKK), sınıflandırma problemlerinde kullanılan güçlü bir performans metriğidir ve tüm karmaşıklık matrisi bileşenlerini (TP, TN, FP, FN) hesaba katarak bir sınıflandırıcının genel doğruluğunu ölçer. MKK, özellikle dengesiz veri kümelerinde önemli bir ölçüt olarak kabul edilir. Değeri -1 ile +1 arasında değişir; +1 mükemmel sınıflandırmayı, 0 rastgele tahmini ve -1 tamamen hatalı tahmini gösterir. Denklem 5.6'da MKK formülü verilmiştir. Burada DP, DN, YP ve YN her bir

sınıf için ayrı ayrı hesaplanmalıdır. Genel bir performans değerlendirmesi yapmak amacıyla MKK değerlerinin ortalaması alınmıştır.

$$MKK = \frac{DP \times DN - Y \times YN}{\sqrt{(DP+YP)(DP+YP)(DN+YP)(DN+YN)}} \quad (5.6)$$

Eğrinin Altındaki Alan (EAA), sınıflandırıcının genel performansını gösteren ve 0 ile 1 arasında değer alan bir ölçümdür. 1'e yakın değerler daha iyi sınıflandırma performansını temsil eder. Algılayıcı işletim eğrilerinde bu değerler gösterilmiştir.



5. ARAŞTIRMA SONUÇLARI

Bu tez çalışmasının araştırma sonuçları, spor hareketlerinin derin öğrenme yöntemleri kullanılarak başarılı bir şekilde tanınabileceğini ve ilgili hareket tekniklerinin ayrıntılı olarak analiz edilebileceğini göstermektedir. Bunun için yapılan çalışmalar bu bölümde ayrıntılı olarak sunulmuştur. Görüntü İşleme alanında yaygın olarak kullanılan sinir ağı mimarileri olan SqueezeNet, Inception-v3 ve VGG-19 derin öğrenme modelleri, powerlifting hareketlerinin sınıflandırılmasında test edilmiştir. Ham veri seti üzerinden yapılan değerlendirmeler sonucunda, SqueezeNet (0,868), Inception-v3 (0,828) ve VGG-19 (0,771) doğruluk oranı elde edilmiştir. SqueezeNet'in sağladığı bu doğruluk oranı nedeniyle, bu çalışma da derin öğrenme mimarisi olarak SqueezeNet kullanımını tercih edilmiştir.

Ayrıca SqueezeNet yerine direkt Mediapipe üzerinden elde edilen duruş tahmini verilerinin makine öğrenmesi algoritmaları ile kullanımı da test edilmiştir. Araştırma çalışmasında elde edilen sonuçlar, adım adım tablolar halinde sunulmuştur.

Veri Setinin %80' i model eğitimi, %20' si ise test işlemleri için ayrılmıştır. Veri seti, her bir iterasyonda rasgele örnekleme yöntemi ile ayrılmış ve her model 10 kez eğitilerek test sonuçları elde edilmiştir. Modelin eğitim ve test süreçleri, Intel(R) Core(TM) i3-4000M CPU @ 2.40GHz işlemci, 8GB RAM, AMD Radeon R5 M230 Series ekran kartına sahip bir sistem üzerinde gerçekleştirilmiştir. Araştırma sonuçları, duruş tahmini bilgilerinin kullanımı ve derin öğrenme teknikleri kullanımı olmak üzere iki ana başlık halinde paylaşılmıştır.

5.1. Duruş Tahmini Bilgilerinin Kullanımı ile Alınan Sonuçlar

Bu bölümde, Şekil 4.1' de verilen akış şemasında bulunan SqueezeNet ile özellik çıkarımı yapılmamış, bunun yerine duruş tahmini ile elde edilen anahtar noktaların bilgileri kullanılmıştır. Veri artırma işlemi sonucunda 2557 görüntüye çıkarılan genişletilmiş veri seti üzerinde, MediaPipe ile gerçekleştirilen duruş tahmini sayesinde elde edilen anahtar noktaların x,y ve z koordinat değerleri veri seti olarak kullanılmıştır. Elde edilen duruş tahmini veri seti 3 farklı şekilde araştırmada kullanılmıştır. İlk olarak veri setinde 33 anahtar noktanın tamamı kullanılmış, ikinci olarak powerlifting hareketleri için önemli olan 12 anahtar nokta bilgisi değerlendirilmiş, son olarak ise 12 anahtar nokta bilgisine ek olarak güvenilirlik eşik değeri de kullanılarak sonuçlar paylaşılmıştır.

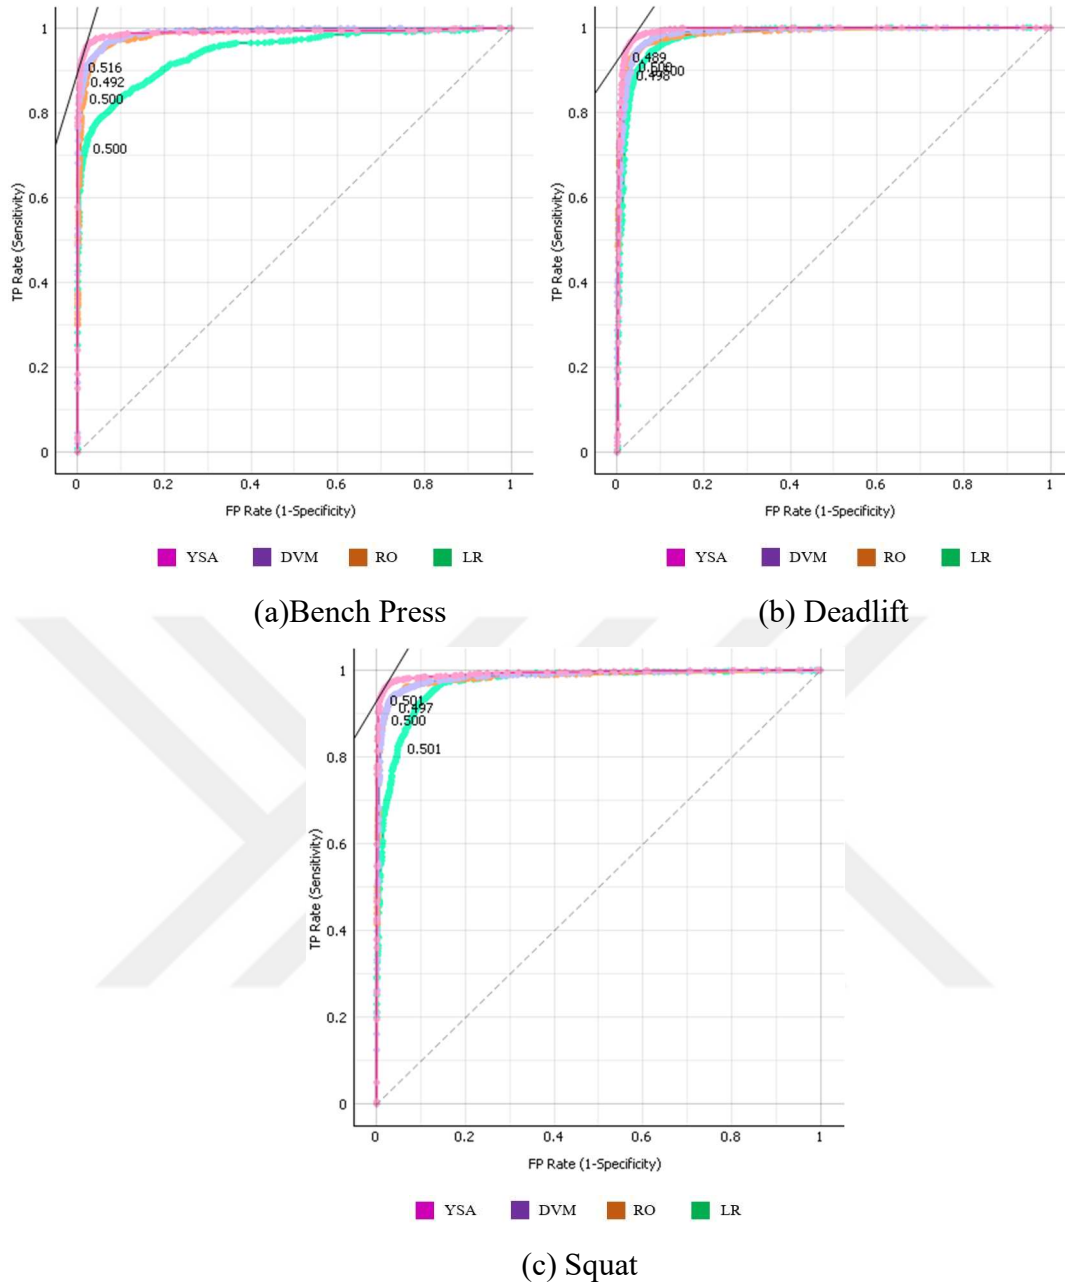
5.1.1. 33 Anahtar Nokta ile Duruş Tahmini Sonuçları

MediaPipe ile elde edilen 33 anahtar noktanın x, y ve z değerleri kullanılarak YSA, LR, RO ve DVM modelleri oluşturulmuş ve modellerin sonuçları Tablo 5.1'de özetlenmiştir.

Tablo 5.1. 33 anahtar nokta kullanımı ile modellerin performans sonuçları

<i>Model</i>	<i>Doğruluk</i>	<i>F1</i>	<i>Kesinlik</i>	<i>Duyarlılık</i>	<i>MKK</i>	<i>EAA</i>
YSA	0,957	0,955	0,956	0,955	0,934	0,992
DVM	0,934	0,931	0,934	0,929	0,898	0,987
RO	0,931	0,928	0,930	0,927	0,894	0,985
LR	0,877	0,866	0,881	0,878	0,809	0,966

Tablo 5.1'de yer alan verilere göre, YSA modeli 0,957 doğruluk ve 0,992 EAA değeri ile en iyi performansı göstermiştir, buna karşılık LR modeli, diğer algoritmalarla kıyaslandığında daha düşük performans sergilemiştir. Şekil 5.1'de sırasıyla Bench Press, Deadlift ve Squat hareketleri için temel veri seti kullanılarak eğitilmiş farklı makine öğrenmesi modellerinin AİE'leri gösterilmektedir.



Şekil 5.1. Farklı modeller için 33 anahtar nokta bilgisi ile AİE analizleri

YSA, DVM ve RO modelleri, yüksek EAA değerleri iyi performans göstermektedir. Şekil 5.2’de modellerin sınıflandırma performansını gösteren karmaşıklık matrisleri sunulmuştur.

		YAPAY SINIR AĞI					DESTEK VEKTÖR MAKİNESİ		
		TAHMİN EDİLEN					TAHMİN EDİLEN		
		BENCH PRESS	DEADLİFT	SQUAT			BENCH PRESS	DEADLİFT	SQUAT
GERÇEK	BENCH PRESS	949	37	24	GERÇEK	BENCH PRESS	911	56	43
	DEADLİFT	27	1735	38		DEADLİFT	36	1707	57
	SQUAT	24	40	1566		SQUAT	33	68	1529

		RASTGELE ORMAN					LOJİSTİK REGRESYON		
		TAHMİN EDİLEN					TAHMİN EDİLEN		
		BENCH PRESS	DEADLİFT	SQUAT			BENCH PRESS	DEADLİFT	SQUAT
GERÇEK	BENCH PRESS	911	60	39	GERÇEK	BENCH PRESS	772	109	129
	DEADLİFT	40	1709	51		DEADLİFT	40	1689	71
	SQUAT	37	79	1514		SQUAT	86	113	1431

Şekil 5.2. 33 Anahtar nokta bilgisi ile duruş tahmini modellerinin karmaşıklık matrisleri


5.1.2. 12 Anahtar Nokta ile Duruş Tahmini Sonuçları

Tablo 5.2'de, duruş tahmininde kullanılan 33 anahtar noktanın tamamı yerine, hareketlerde daha aktif olarak kullanılan ve daha yüksek başarı elde edilebileceği öngörülen 12 anahtar nokta tercih edilmiştir. Kullanılan noktalar: 11. Nokta (Sol Omuz), 12. Nokta (Sağ Omuz), 13. Nokta (Sol dirsek), 14. Nokta (Sağ dirsek), 15. Nokta (Sol Bilek), 16. Nokta (Sağ bilek), 23. Nokta (Sol kalça), 24. Nokta (Sağ Kalça), 25. Nokta (Sol diz), 26. Nokta (Sağ diz), 27. Nokta (Sol ayak bileği), 28. Nokta (Sağ ayak bileği).

Tablo 5.2. 12 anahtar nokta kullanımı ile modellerin performans sonuçları

Model	Doğruluk	F1	Kesinlik	Duyarlılık	MKK	EAA
YSA	0,960	0,959	0,960	0,958	0,939	0,993
DVM	0,933	0,930	0,933	0,927	0,897	0,987
RO	0,932	0,929	0,930	0,927	0,895	0,988
LR	0,873	0,860	0,870	0,854	0,803	0,960

Tablo 5.2'de yer alan veriler incelendiğinde, YSA modeli 0,960 doğruluk ve 0,993 EAA değeri ile en iyi performansı gösterirken, LR modeli diğer algoritmalarla kıyaslandığında daha düşük performans sergilemiştir. Şekil 5.3'de sırasıyla Bench Press, Deadlift ve Squat hareketleri için temel veri seti kullanılarak eğitilmiş farklı makine öğrenmesi modellerinin algılayıcı işletim eğrileri gösterilmektedir.



Şekil 5.3. Farklı modeller için 12 anahtar nokta bilgisi ile AİE analizleri

YSA, DVM ve RO modelleri, yüksek EAA değerleri iyi performans göstermektedir. Şekil 5.4’de modellerin sınıflandırma performanslarını gösteren karmaşıklık matrisleri verilmiştir.

YAPAY SINIR AĞI					DESTEK VEKTÖR MAKİNESİ				
TAHMİN EDİLEN					TAHMİN EDİLEN				
GERÇEK	BENCH PRESS	DEADLİFT	SQUAT		GERÇEK	BENCH PRESS	DEADLİFT	SQUAT	
BENCH PRESS	954	39	17		BENCH PRESS	901	63	46	
DEADLİFT	25	1742	33		DEADLİFT	32	1707	61	
SQUAT	19	44	1567		SQUAT	34	61	1535	

RASTGELE ORMAN					LOJİSTİK REGRESYON				
TAHMİN EDİLEN					TAHMİN EDİLEN				
GERÇEK	BENCH PRESS	DEADLİFT	SQUAT		GERÇEK	BENCH PRESS	DEADLİFT	SQUAT	
BENCH PRESS	913	56	41		BENCH PRESS	748	120	142	
DEADLİFT	47	1710	43		DEADLİFT	32	1694	74	
SQUAT	33	84	1513		SQUAT	88	110	1432	

Şekil 5.4. 12 Anahtar nokta bilgisi ile duruş tahmini modellerinin karmaşıklık matrisleri


5.1.3. Duruş Tahmininde Güvenilirlik Eşik Değeri Kullanılarak Alınan Sonuçlar

Bu çalışmada, 33 anahtar nokta yerine daha yüksek başarı elde edilen 12 eklem noktası kullanılmıştır. Ayrıca, MediaPipe kütüphanesinde bulunan güvenilirlik eşik değeri özelliği kullanılarak bu değer 0,5 olarak ayarlanmıştır. Tablo 5.3'de modellerin performans sonuçları verilmiştir.

Tablo 5.3. Duruş tahmininde güvenilirlik eşik değeri kullanımı ile modellerin performans sonuçları

Model	Doğruluk	F1	Kesinlik	Duyarlılık	MKK	EAA
YSA	0,977	0,957	0,971	0,944	0,959	0,994
DVM	0,967	0,931	0,974	0,901	0,940	0,996
RO	0,952	0,899	0,934	0,874	0,913	0,992
LR	0,921	0,753	0,873	0,726	0,856	0,978

Tablo 5.3'de yer alan verilere incelendiğinde, YSA modeli 0,977 doğruluk, 0,994 EAA değeri ve DVM modeli de 0,967 doğruluk ve 0,996 EAA değeri ile en iyi performansları gösterdikleri görülmüştür. LR modeli diğer algoritmalarla kıyaslandığında daha düşük performans sergilemiştir. Şekil 5.5'de sırasıyla Bench Press, Deadlift ve Squat hareketleri için temel veri seti kullanılarak eğitilmiş farklı makine öğrenmesi modellerinin algılayıcı işletim eğrileri gösterilmektedir.



Şekil 5.5. Duruş tahmininde güvenilirlik eşik değeri kullanımı ile AİE analizleri

YSA, DVM ve RO modelleri, yüksek EAA değerleri iyi performans göstermektedir. Şekil 5.6'da modellerin sınıflandırma performanslarını gösteren karmaşıklık matrisleri paylaşılmıştır.

		YAPAY SINIR AĞI					DESTEK VEKTÖR MAKİNESİ		
		TAHMİN EDİLEN					TAHMİN EDİLEN		
GERÇEK		BENCH PRESS	DEADLİFT	SQUAT	GERÇEK		BENCH PRESS	DEADLİFT	SQUAT
	BENCH PRESS	103	4	13		BENCH PRESS	88	4	28
	DEADLİFT	2	691	7		DEADLİFT	1	692	7
	SQUAT	3	10	897		SQUAT	0	17	893

		RASTGELE ORMAN					LOJİSTİK REGRESYON		
		TAHMİN EDİLEN					TAHMİN EDİLEN		
GERÇEK		BENCH PRESS	DEADLİFT	SQUAT	GERÇEK		BENCH PRESS	DEADLİFT	SQUAT
	BENCH PRESS	81	9	30		BENCH PRESS	28	6	86
	DEADLİFT	4	684	12		DEADLİFT	2	681	17
	SQUAT	6	22	882		SQUAT	7	19	884

Şekil 5.6. Duruş tahmininde güvenilirlik eşik değeri kullanımı ile duruş tahmini modellerinin karmaşıklık matrisleri

Bu bölümde SqueezeNet ile özellik çıkarımı yapılmadan duruş tahmini bilgilerinin kullanılması incelenmiştir. Duruş tahmini bilgilerinin kullanımı için en başarılı YSA modeli ile 0,977 doğruluk, 0,994 EAA değerleri elde edilmiştir.

5.2. Derin Öğrenme Tekniklerinin Kullanımı ile Alınan Sonuçlar

Bu bölümde, ilk olarak powerlifting hareketlerine ait veri seti kullanılarak duruş tahmini gerçekleştirilmiştir. MediaPipe ile elde edilen anahtar noktalar, SqueezeNet derin öğrenme mimarisi ile işlenmiş ve özellik verileri oluşturulmuştur. Ardından, bu özellik verileri YSA, DVM, LR ve RO modelleri kullanılarak sınıflandırılmıştır. Son olarak, her modelin performansı değerlendirilmiştir. Şekil 4.1'de verilen akış şeması adım adım uygulanarak elde edilen sonuçlar paylaşılmıştır. Powerlifting hareketlerini içeren veri seti dört farklı şekilde kullanılmış ve sonuçları paylaşılmıştır. Öncelikle, 876 görüntüden oluşan Powerlifting ham veri seti kullanılmış ve Tablo 5.4'de analizleri verilmiştir. İkinci olarak, veri artırma teknikleri ile genişletilen Powerlifting veri seti, 2557 görüntü ile Tablo 5.5'de sunulmuştur. Üçüncü olarak, Powerlifting ham veri setine duruş tahmini ile anahtar noktalar eklenmiş ve elde edilen sonuçlar Tablo 5.6'da yer almıştır. Son olarak, genişletilmiş veri setine duruş tahmini anahtar noktaları eklenerek yapılan analizler Tablo 5.7'de paylaşılmıştır.

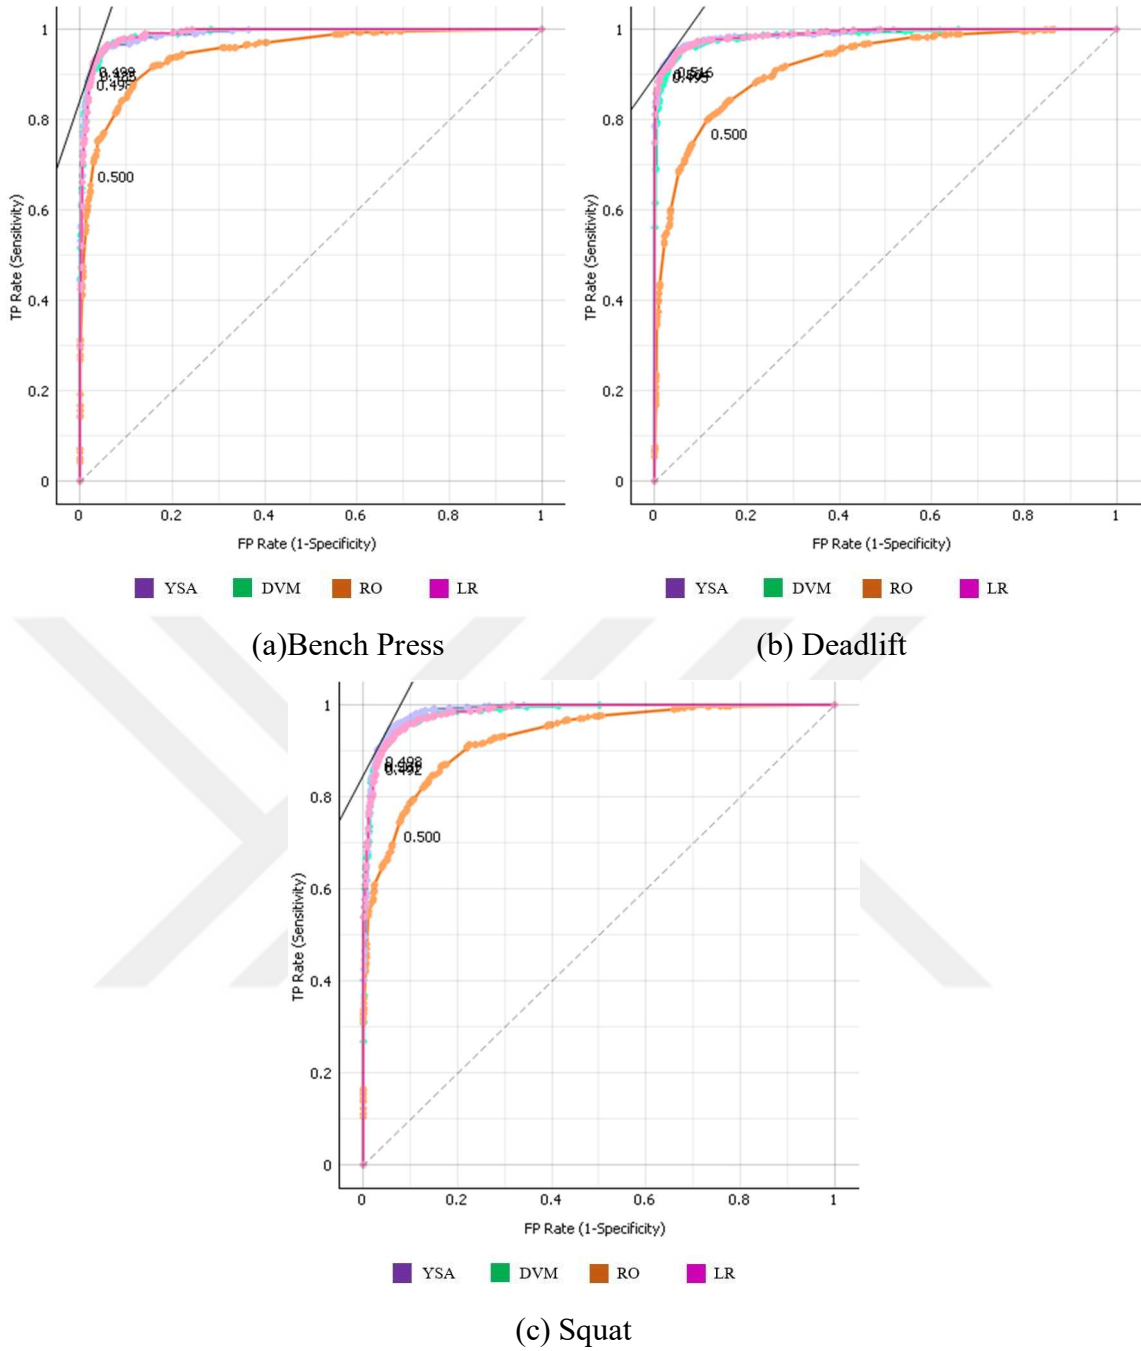
5.2.1. Ham Veri Seti ile Alınan Sonuçlar

Tablo 5.4'de, Powerlifting ham veri seti (876 görüntü) kullanılarak SqueezeNet ile gerçekleştirilen özellik çıkarımı sonrasında YSA, LR, DVM ve RO algoritmalarının uygulanmasıyla elde edilen analiz sonuçları özetlenmektedir.

Tablo 5.4. Ham Powerlifting veri seti ile alınan modellerin performans sonuçları

<i>Model</i>	<i>Doğruluk</i>	<i>F1</i>	<i>Kesinlik</i>	<i>Duyarlılık</i>	<i>MKK</i>	<i>EAA</i>
<i>YSA</i>	<i>0,925</i>	<i>0,923</i>	<i>0,922</i>	<i>0,925</i>	<i>0,886</i>	<i>0,988</i>
<i>DVM</i>	<i>0,921</i>	<i>0,919</i>	<i>0,919</i>	<i>0,920</i>	<i>0,879</i>	<i>0,986</i>
<i>RO</i>	<i>0,804</i>	<i>0,803</i>	<i>0,806</i>	<i>0,808</i>	<i>0,700</i>	<i>0,932</i>
<i>LR</i>	<i>0,923</i>	<i>0,921</i>	<i>0,920</i>	<i>0,923</i>	<i>0,882</i>	<i>0,987</i>

Tablo 5.4'de yer alan verilere göre, YSA modeli 0,925 doğruluk ve 0,988 EAA değeri ile en iyi performansı gösterirken, RO modeli diğer algoritmalarla kıyaslandığında daha düşük performans sergilemiştir. Şekil 5.7'de sırasıyla Bench Press, Deadlift ve Squat hareketleri için temel veri seti kullanılarak eğitilmiş farklı makine öğrenmesi modellerinin algılayıcı işletim eğrileri gösterilmektedir.



Şekil 5.7. Ham Powerlifting veri seti için AİE analizleri

AİE analizleri incelendiğinde YSA ve LR modelleri, yüksek EAA değerleri ile en iyi performansı göstermektedir. Şekil 5.8' de elde edilen karmaşıklık matrisleri paylaşılmıştır.

		YAPAY SINIR AĞI					DESTEK VEKTÖR MAKİNESİ		
		TAHMİN EDİLEN					TAHMİN EDİLEN		
		BENCH PRESS	DEADLİFT	SQUAT			BENCH PRESS	DEADLİFT	SQUAT
GERÇEK	BENCH PRESS	409	13	18	GERÇEK	BENCH PRESS	404	17	19
	DEADLİFT	15	674	31		DEADLİFT	12	676	32
	SQUAT	31	24	545		SQUAT	31	28	541

		RASTGELE ORMAN					LOJİSTİK REGRESYON		
		TAHMİN EDİLEN					TAHMİN EDİLEN		
		BENCH PRESS	DEADLİFT	SQUAT			BENCH PRESS	DEADLİFT	SQUAT
GERÇEK	BENCH PRESS	345	63	32	GERÇEK	BENCH PRESS	412	13	15
	DEADLİFT	42	603	75		DEADLİFT	15	675	30
	SQUAT	38	95	467		SQUAT	32	31	537

Şekil 5.8. Ham Powerlifting veri seti için modellerin karmaşıklık matrisleri

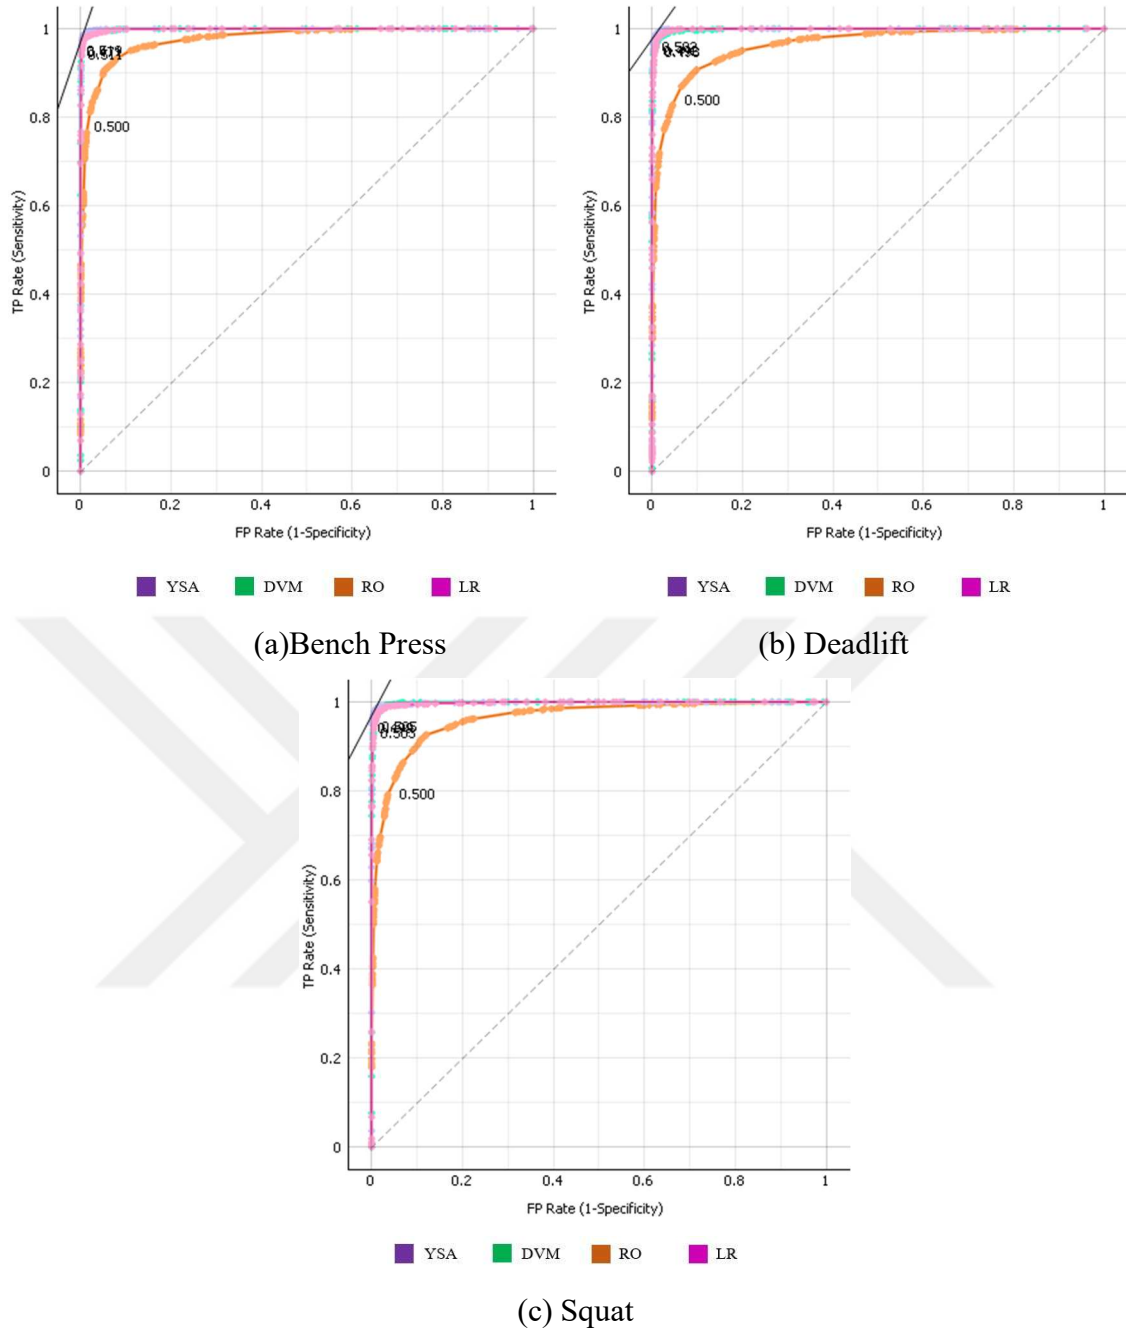
5.2.2. Genişletilmiş Veri Seti ile Alınan Sonuçlar

Veri artırma işlemi ile elde edilen 2557 görüntüden oluşan genişletilmiş veri seti kullanılarak gerçekleştirilen analizlerin sonuçları Tablo 5.5.'de verilmiştir.

Tablo 5.5. Genişletilmiş veri seti ile alınan modellerin performans sonuçları

Model	Doğruluk	F1	Kesinlik	Duyarlılık	MKK	EAA
YSA	0,983	0,983	0,983	0,982	0,974	0,999
DVM	0,974	0,974	0,973	0,975	0,961	0,999
RO	0,875	0,875	0,876	0,874	0,809	0,967
LR	0,977	0,977	0,977	0,976	0,964	0,998

Tablo 5.5'de yer alan sonuçlar, veri setinin artırılmasıyla model performansının önemli ölçüde iyileştiğini göstermektedir. YSA modeli, 0,983 doğruluk değeri ile en iyi performansı sergileyen model olarak öne çıkmaktadır. Veri artırma tekniklerinin uygulanmasıyla, model doğruluğunun artırıldığı ve sınıflandırma performansının iyileştiği görülmektedir. RO modeli, diğer algoritmalarla kıyaslandığında performans açısından daha düşük kalmıştır, ancak genişletilmiş veri seti ile performans artışı göstermiştir. Şekil 5.9'da sırasıyla Bench Press, Deadlift ve Squat hareketleri için genişletilmiş veri seti kullanılarak eğitilmiş farklı makine öğrenmesi modellerinin algılayıcı işletim eğrileri gösterilmektedir.



Şekil 5.9. Genişletilmiş veri seti için AİE analizleri

Şekil 5.9'da veri artırma işlemi ile elde edilen veri seti kullanılarak eğitilmiş farklı makine öğrenmesi modellerinin algılayıcı işletim eğrileri incelendiğinde YSA ve DVM modelleri, yüksek EAA değerleri ile en iyi performansı göstermektedir. Şekil 5.10'da modellerin sınıflandırma performanslarını gösteren karmaşıklık matrisleri paylaşılmıştır.



Şekil 5.10. Genişletilmiş veri seti için modellerin karmaşıklık matrisleri

5.2.3. Anahtar Noktalar İçeren Ham Veri Seti Sonuçları

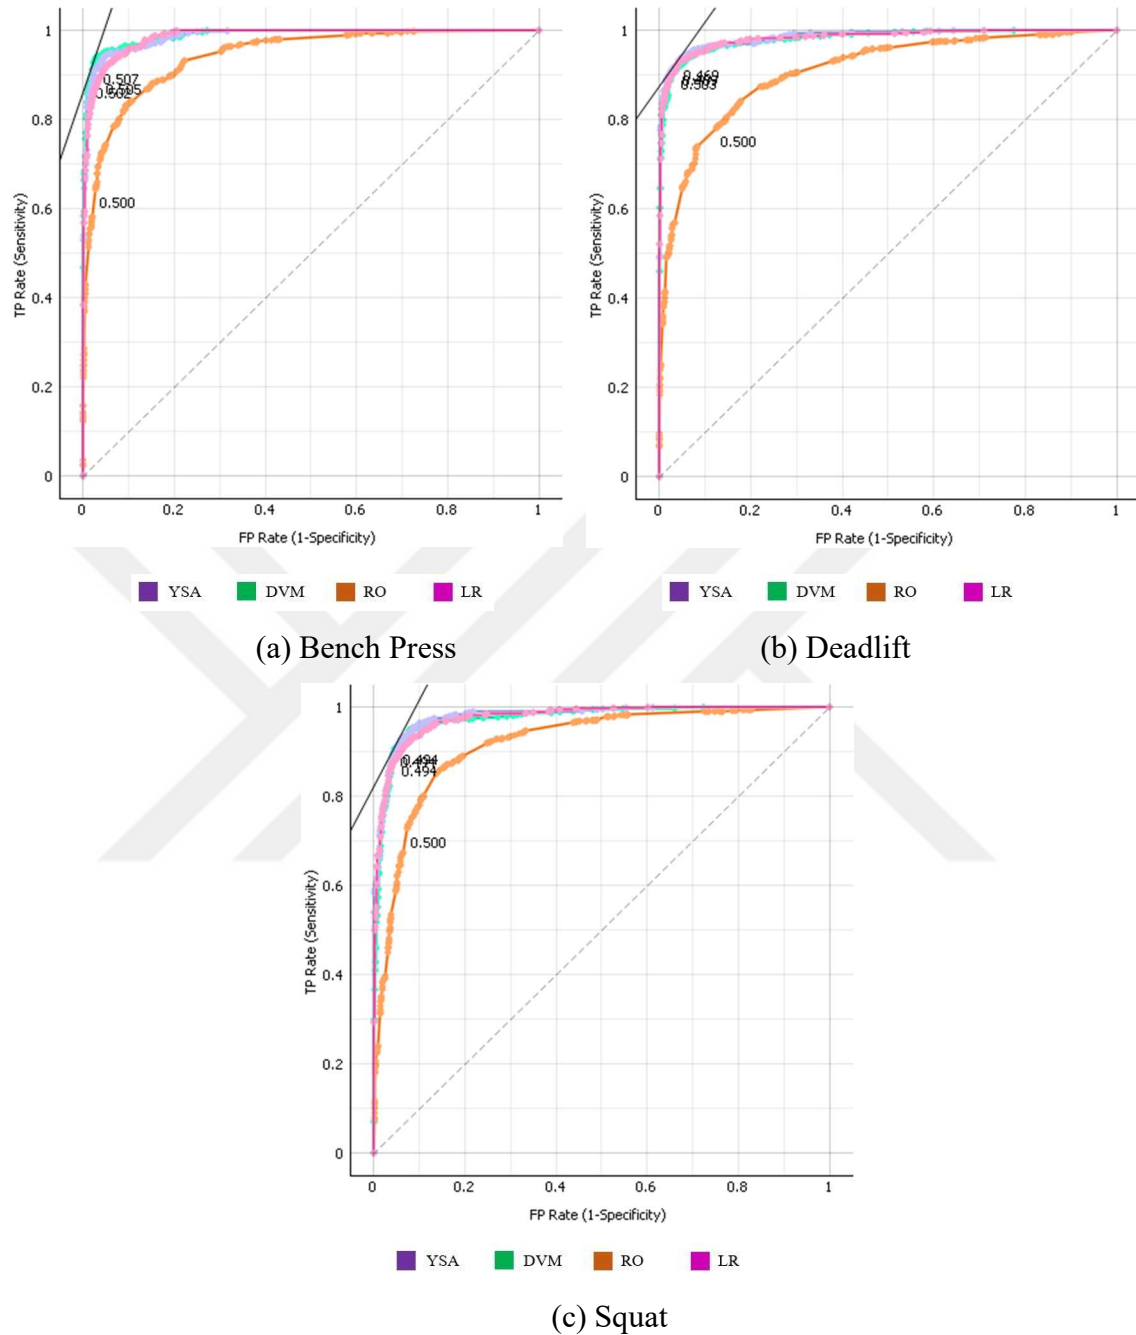
Bu bölüm, MediaPipe kullanılarak duruş tahmini yapılan ham veri seti ile gerçekleştirilen analiz sonuçlarını içermektedir. Kullanılan veri seti, 876 görüntüden oluşan ham veri setine duruş tahmini uygulanarak, anahtar noktaların görüntü üzerine eklenmesiyle oluşturulmuştur. MediaPipe kütüphanesi ile her bir görüntü için duruş tahmini yapılmış ve bu tahmin edilen anahtar noktalar görüntülere eklenmiştir. Tablo 5.6'da, anahtar noktalar eklenmiş Powerlifting ham veri seti kullanılarak SqueezeNet ile gerçekleştirilen özellik çıkarımından sonra YSA, LR, DVM ve RO algoritmalarının uygulanmasıyla elde edilen analiz sonuçları özetlenmektedir.

Tablo 5.6. Anahtar nokta içeren ham veri seti ile modellerin alınan performans sonuçları

Model	Doğruluk	F1	Kesinlik	Duyarlılık	MKK	EAA
YSA	0,916	0,915	0,913	0,917	0,873	0,984
DVM	0,919	0,919	0,921	0,918	0,877	0,982
RO	0,795	0,797	0,836	0,825	0,696	0,922
LR	0,909	0,906	0,905	0,907	0,861	0,982

Tablo 5.6' da yer alan sonuçlar, ham veri seti üzerine duruş tahmini yapılarak elde edilen veriler kullanıldığında, model performansının Tablo 5.6' daki artırılmış veri setine kıyasla bir miktar düştüğünü göstermektedir. DVM modeli, 0,919 doğruluk değeri ile bu sınıflandırma görevinde en iyi performansı gösteren model olarak öne çıkmaktadır. Bununla birlikte, duruş tahmininin uygulanmasının, model doğruluğunda bir miktar azalmaya neden olduğu, ancak yine de makul bir performans sergilediği gözlemlenmiştir. Şekil 5.11'de sırasıyla Bench Press, Deadlift ve Squat hareketleri için duruş tahmini

yapılmış veri seti kullanılarak eğitilmiş farklı makine öğrenmesi modellerinin algılayıcı işletim eğrileri gösterilmektedir.



Şekil 5.11. Anahtar noktalar içeren ham veri seti için AİE analizleri

Şekil 5.11' de, MediaPipe ile duruş tahmini yapılan veri seti kullanılarak eğitilmiş farklı makine öğrenmesi modellerinin algılayıcı işletim eğrileri karşılaştırıldığında DVM ve YSA modelleri, yüksek EAA değerleri ile en iyi performansı gösterdiği görülmektedir. Şekil 5.12' de çalışma sonucunda elde edilen karmaşıklık matrisleri paylaşılmıştır.

		YAPAY SINIR AĞI					DESTEK VEKTÖR MAKİNESİ		
		TAHMİN EDİLEN					TAHMİN EDİLEN		
		BENCH PRESS	DEADLİFT	SQUAT			BENCH PRESS	DEADLİFT	SQUAT
GERÇEK	BENCH PRESS	406	13	21	GERÇEK	BENCH PRESS	400	15	25
	DEADLİFT	21	662	37		DEADLİFT	11	670	39
	SQUAT	26	29	545		SQUAT	14	38	548

		RASTGELE ORMAN					LOJİSTİK REGRESYON		
		TAHMİN EDİLEN					TAHMİN EDİLEN		
		BENCH PRESS	DEADLİFT	SQUAT			BENCH PRESS	DEADLİFT	SQUAT
GERÇEK	BENCH PRESS	332	62	46	GERÇEK	BENCH PRESS	397	14	29
	DEADLİFT	43	600	77		DEADLİFT	19	670	31
	SQUAT	27	105	468		SQUAT	36	31	533

Şekil 5.12. Anahtar noktalar içeren ham veri seti için modellerin karmaşıklık matrisleri

5.2.4. Anahtar Noktalar İçeren Genişletilmiş Veri Seti Sonuçları

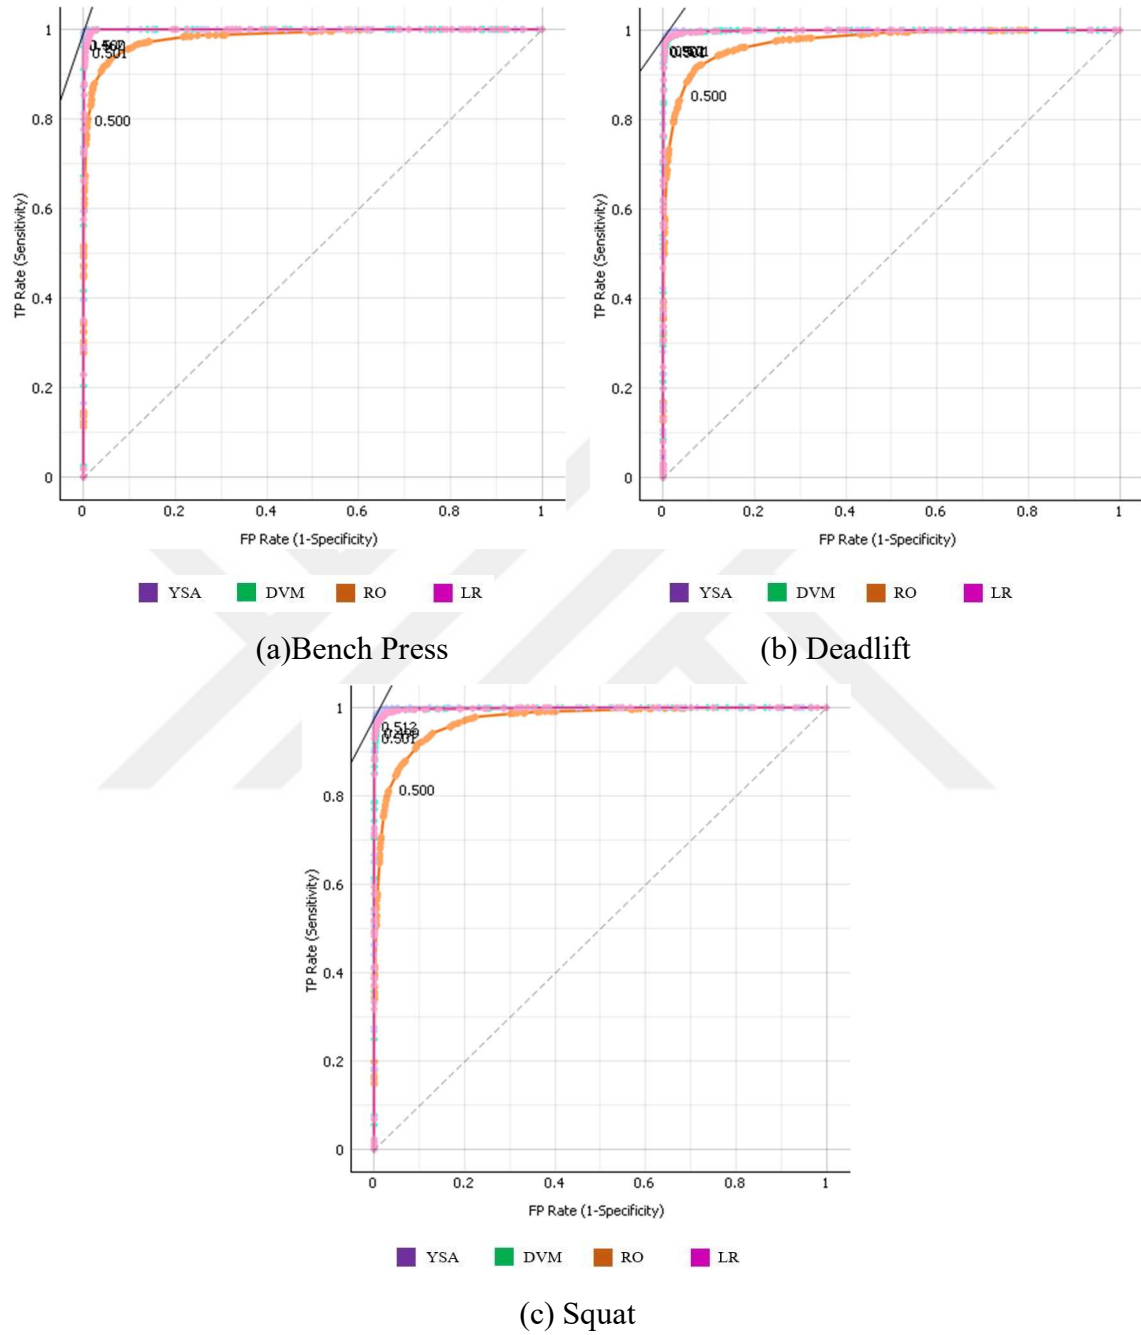
Bu bölüm, MediaPipe kullanılarak duruş tahmini yapılan genişletilmiş veri seti ile gerçekleştirilen analiz sonuçlarını içermektedir. Kullanılan veri seti, 876 görüntüden oluşan ham veri seti veri artırma teknikleri kullanılarak çoğaltılmış ve 2557 görüntüye çıkarılmıştır. MediaPipe kütüphanesi ile her bir görüntü için duruş tahmini yapılmış ve bu tahmin edilen anahtar noktalar görüntülere eklenmiştir. Tablo 5.7'de, anahtar noktalar eklenmiş ve veri artırma işlemiyle genişletilmiş Powerlifting veri seti kullanılarak SqueezeNet ile gerçekleştirilen özellik çıkarımından sonra YSA, LR, DVM ve RO algoritmalarının uygulanmasıyla elde edilen analiz sonuçları özetlenmektedir.

Tablo 5.7. Anahtar noktalar içeren genişletilmiş veri seti ile modellerin alınan performans sonuçları

Model	Doğruluk	F1	Kesinlik	Duyarlılık	MKK	EAA
YSA	0,989	0,989	0,989	0,990	0,983	1,000
DVM	0,980	0,981	0,981	0,981	0,969	0,999
RO	0,894	0,894	0,896	0,892	0,837	0,975
LR	0,978	0,977	0,977	0,978	0,967	0,998

Tablo 5.7'de yer alan sonuçlar, model başarısının önemli ölçüde arttığını göstermektedir. YSA modeli, 0,989 doğruluk ve 1,000 EAA değeri ile bu sınıflandırma görevinde en iyi performansı sergileyen model olarak öne çıkmaktadır. Duruş tahmininin veri artırma teknikleriyle birleştirilmesi, modelin sınıflandırma doğruluğunu ve genel performansını önemli ölçüde iyileştirmiştir. Şekil 5.13'de sırasıyla Bench Press, Deadlift ve Squat hareketleri için artırılmış ve duruş tahmini yapılmış veri seti kullanılarak

eđitilmiş farklı makine öğrenmesi modellerinin algılayıcı işletim eğrileri gösterilmektedir.



Şekil 5.13. Anahtar noktalar içeren genişletilmiş veri seti için AİE analizleri

Şekil 5.13' de, artırılmış ve duruş tahmini ile güçlendirilmiş veri seti kullanılarak eğitilmiş farklı makine öğrenmesi modellerinin algılayıcı işletim eğrileri karşılaştırıldığında YSA modeli, EAA açısından iyi bir performans sergileyerek, bu sınıflandırma görevinde en iyi model olarak öne çıkmıştır.

Tablo 5.7 ve Şekil 5.13'te görüldüğü gibi, MediaPipe ile duruş tahmini tekniği, veri seti genişletildiğinde model performansında belirgin bir iyileşme sağlamaktadır. Ham veri setine kıyasla, duruş tahmini ve veri artırma teknikleri bir araya getirildiğinde, sınıflandırma doğruluğu ve diğer performans metriklerinde önemli iyileşmeler gözlemlenmiştir. Şekil 5.14' de anahtar noktalar içeren genişletilmiş veri setinden elde edilen sonuçların karmaşıklık matrisleri paylaşılmıştır.

		YAPAY SINIR AĞI					DESTEK VEKTÖR MAKİNESİ		
		TAHMİN EDİLEN					TAHMİN EDİLEN		
		BENCH PRESS	DEADLİFT	SQUAT			BENCH PRESS	DEADLİFT	SQUAT
GERÇEK	BENCH PRESS	1265	0	5	GERÇEK	BENCH PRESS	1267	0	3
	DEADLİFT	7	2068	25		DEADLİFT	8	2071	21
	SQUAT	3	18	1729		SQUAT	14	57	1679

		RASTGELE ORMAN					LOJİSTİK REGRESYON		
		TAHMİN EDİLEN					TAHMİN EDİLEN		
		BENCH PRESS	DEADLİFT	SQUAT			BENCH PRESS	DEADLİFT	SQUAT
GERÇEK	BENCH PRESS	1125	73	72	GERÇEK	BENCH PRESS	1245	6	19
	DEADLİFT	52	1914	134		DEADLİFT	17	2059	24
	SQUAT	56	156	1538		SQUAT	26	20	1704

Şekil 5.14. Anahtar noktalar içeren genişletilmiş veri seti için karmaşıklık matrisleri

Bu bölümde elde edilen sonuçlar, veri artırma tekniklerinin yanı sıra görüntü ve duruş tahminini belirten anahtar nokta verilerinin birlikte kullanılmasının model performansını önemli ölçüde artırdığı tespit edilmiştir. Ayrıca, kullanılan derin öğrenme algoritmasının seçiminin de sınıflandırma sonuçlarını etkilediği gözlemlenmiştir.

6. SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında, powerlifting hareketlerinin duruş tahmini kullanılarak tanınması ve sınıflandırılması üzerine çalışılmıştır. Bu amaçla oluşturulan powerlifting veri seti üzerinde, öncelikle MediaPipe kütüphanesi ile duruş tahminini belirten anahtar noktalar çıkarılmış ve YSA, DVM, LR, RO gibi makine öğrenmesi algoritmalarıyla sınıflandırma işlemleri gerçekleştirilmiştir. Ayrıca, MediaPipe kütüphanesinden elde edilen 33 anahtar nokta yerine, veri setine daha uygun olduğu düşünülen 12 anahtar nokta kullanılarak performans değerlendirilmiş ve güvenilirlik eşik değeri ile bu performansın etkisi incelenmiştir. Bir diğer çalışmada ise, görüntüden elde edilen veriler SqueezeNet modeli ile özellik çıkarımı yapılarak, bu özellikler YSA, DVM, LR, RO algoritmaları ile sınıflandırılmıştır. Ek olarak, veri artırma teknikleri uygulanmış ve duruş tahmini ile elde edilen anahtar noktaların görüntülere eklenmesi sonucu genişletilen veri setleri üzerinde model performansları analiz edilmiştir. Elde edilen sonuçlar, duruş tahmini ile çıkarılan anahtar noktaların model performansını iyileştirdiğini ve kullanılan derin öğrenme algoritmasının sınıflandırma sonuçları üzerinde önemli bir etkisi olduğunu göstermektedir. Bu çalışmanın temel bulgularından biri yüksek sınıflandırma doğruluğudur. YSA modeli, %98,9 doğruluk oranı ile en iyi performansı göstermiştir. Duruş tahmini belirten anahtar noktaların ve veri artırma tekniklerinin bir arada kullanımı, sınıflandırma doğruluğunu ve genel model performansını önemli ölçüde iyileştirdiği görülmüştür. Ayrıca derin öğrenme teknikleri ile özellik çıkarımı yerine duruş tahmini bilgilerinin kullanımı da test edilmiştir. Duruş tahmini bilgilerinin kullanılmasıyla da yine YSA modeli, %97,7 doğruluk oranı ile en iyi performansı göstermiştir.

Çalışmada, doğruluk, F1 ölçütü, kesinlik, duyarlılık ve EAA gibi çeşitli performans metrikleri kullanılarak model performansları değerlendirilmiştir. Çalışma, derin öğrenme yöntemlerinin spor hareket analizinde güçlü bir araç olduğunu ve sporcuların performanslarının değerlendirilmesinde önemli katkılar sağlayabileceğini göstermektedir.

Elde edilen yüksek performans, modelin gerçek dünya uygulamalarında kullanılabilirliğini, derin öğrenme modellerinin spor hareketlerini başarılı bir şekilde tanıyabileceğini ve bu tanıma işleminin, sporcuların performanslarının değerlendirilmesinde önemli bir rol oynayabileceğini göstermektedir. Bu bulgular, derin öğrenme yöntemlerinin spor bilimlerinde daha geniş bir uygulama alanı bulabileceğini işaret etmektedir.

Ayrıca, gerçek zamanlı hareket tanıma ve analiz sistemlerinin geliştirilmesi, mobil cihazlar ve giyilebilir teknolojilerde kullanılmak üzere uyarlanabilir. Bu tür uygulamalar, sporcuların antrenman sırasında anlık geri bildirim almasını sağlayarak performanslarını optimize etmelerine yardımcı olabilir. Bir diğer önemli araştırma yönü, farklı derin öğrenme mimarileri ve algoritmalarının karşılaştırılması ve bu yöntemlerin spor hareket analizi üzerindeki etkilerinin incelenmesidir. Özellikle, derin öğrenme yöntemleri ile birlikte hibrit modellerin geliştirilebilir ve model performansını daha da artırabilir.

Son olarak, bu çalışmanın bulguları, spor hareketlerinin derin öğrenme ile analiz edilmesinin yalnızca sportif performansın değerlendirilmesinde değil, aynı zamanda yaralanmaların önlenmesi ve rehabilitasyon süreçlerinin izlenmesinde de faydalı olabileceğini göstermektedir. Sporcularda meydana gelebilecek yanlış hareketlerin tespit edilmesi ve bu hareketlerin düzeltilmesi, sakatlanma riskini minimize edebilir ve sporcuların uzun vadeli sağlığını koruyabilir.

Özetle, bu çalışma, powerlifting gibi güç gerektiren spor hareketlerinin derin öğrenme teknikleriyle başarılı bir şekilde analiz edilebileceğini ve bu yöntemlerin spor bilimlerinde önemli bir rol oynayabileceğini göstermiştir. Bu alandaki araştırmalar, sporcuların performanslarını daha iyi anlamalarına ve geliştirmelerine yardımcı olabilecek yeni nesil araçların geliştirilmesine katkıda bulunacaktır.

Gelecekte yapılacak çalışmalar için, bu çalışmanın geliştirilebilir yönlerinden biri kullanılan veri seti miktarının artırılması olabilir. Çalışmada kullanılan veri setinden daha büyük ve daha çeşitli bir veri seti, modelin genelleştirilebilirliğini artırabilir ve daha başarılı sonuçlar sağlayabilir.

Çalışma üç temel Powerlifting hareketine (bench press, deadlift ve squat) odaklanılmıştır. Daha fazla hareket türünün dahil edilmesi, modelin daha geniş bir uygulama alanına sahip olmasını sağlayabilir.

Ayrıca gerçek zamanlı performans değerlendirme yapılması ve modelin işlem süresinin optimize edilmesi gerekebilir. MediaPipe kütüphanesi kullanılarak yapılan duruş tahmini, bazı durumlarda hatalı sonuçlar verebilir. Daha farklı hareketler için diğer duruş tahmini algoritmaları test edilip kullanılarak bu sorun giderilebilir. Model, belirli bir veri seti üzerinde eğitilmiş olduğundan, farklı veri setlerinde aynı performansı gösteremeyebilir. Modelin genelleştirilebilirliğini artırmak için daha fazla araştırma ve geliştirme çalışması faydalı olacaktır.

Bu durumlar, gelecekte yapılacak çalışmalar için önemli araştırma alanları sunmaktadır. Daha büyük ve daha çeşitli bir veri seti kullanımı, gerçek zamanlı uygulama

için model optimizasyonu, daha gelişmiş duruş tahmini algoritmaları ve modelin geliştirilebilirliğinin artırılması, gelecekteki çalışmalarda ele alınması gereken önemli konulardır.



KAYNAKLAR

- Bishop, C. M., & Nasrabadi, N. M. (2006). *Pattern recognition and machine learning* (Vol. 4). Springer.
- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.
- Brennecke, A., Guimarães, T. M., Leone, R., Cadarci, M., Mochizuki, L., Simão, R., Amadio, A. C., & Serrão, J. C. (2009). Neuromuscular activity during bench press exercise performed with and without the preexhaustion method. *The Journal of Strength & Conditioning Research*, 23(7), 1933-1940.
- Chatzitofis, A., Zarpalas, D., Daras, P., & Kollias, S. (2021). DeMoCap: Low-cost marker-based motion capture. *International Journal of Computer Vision*, 129(12), 3338-3366.
- Chen, K.-Y., Shin, J., Hasan, M. A. M., Liaw, J.-J., Yuichi, O., & Tomioka, Y. (2022). Fitness movement types and completeness detection using a transfer-learning-based deep neural network. *Sensors*, 22(15), 5700.
- Chen, Y., Shen, C., Wei, X.-S., Liu, L., & Yang, J. (2017). Adversarial poseNet: A structure-aware convolutional network for human pose estimation. Proceedings of the IEEE international conference on computer vision,
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20, 273-297.
- Cust, E. E., Sweeting, A. J., Ball, K., & Robertson, S. (2019). Machine and deep learning for sport-specific movement recognition: A systematic review of model development and performance. *Journal of sports sciences*, 37(5), 568-600.
- Donnelly, J. E., Blair, S. N., Jakicic, J. M., Manore, M. M., Rankin, J. W., & Smith, B. K. (2009). Appropriate physical activity intervention strategies for weight loss and prevention of weight regain for adults. *Medicine & Science in Sports & Exercise*, 41(2), 459-471.
- Donnelly, J. E., Hillman, C. H., Castelli, D., Etnier, J. L., Lee, S., Tomporowski, P., Lambourne, K., & Szabo-Reed, A. N. (2016). Physical activity, fitness, cognitive function, and academic achievement in children: a systematic review. *Medicine and science in sports and exercise*, 48(6), 1197.
- Fang, H.-S., Li, J., Tang, H., Xu, C., Zhu, H., Xiu, Y., Li, Y.-L., & Lu, C. (2022). Alphapose: Whole-body regional multi-person pose estimation and tracking in real-time. *IEEE transactions on pattern analysis and machine intelligence*, 45(6), 7157-7173.
- Ferland, P.-M., & Comtois, A. S. (2019). Classic Powerlifting Performance: A Systematic Review. *The Journal of Strength & Conditioning Research*, 33, S194-S201. <https://doi.org/10.1519/jsc.0000000000003099>
- Ferreira, B., Ferreira, P. M., Pinheiro, G., Figueiredo, N., Carvalho, F., Menezes, P., & Batista, J. (2021). Deep learning approaches for workout repetition counting and validation. *Pattern Recognition Letters*, 151, 259-266.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.
- Hales, M. E., Johnson, B. F., & Johnson, J. T. (2009). Kinematic analysis of the powerlifting style squat and the conventional deadlift during competition: is there a cross-over effect between lifts? *The Journal of Strength & Conditioning Research*, 23(9), 2574-2580.
- Hastie, T., Tibshirani, R., Friedman, J. H., & Friedman, J. H. (2009). *The elements of statistical learning: data mining, inference, and prediction* (Vol. 2). Springer.
- Hecksteden, A., Kraushaar, J., Scharhag-Rosenberger, F., Theisen, D., Senn, S., & Meyer, T. (2015). Individual response to exercise training-a statistical perspective. *Journal of applied physiology*, 118(12), 1450-1459.

- Hermsdörfer, J., Mai, N., Spatt, J., Marquardt, C., Veltkamp, R., & Goldenberg, G. (1996). Kinematic analysis of movement imitation in apraxia. *Brain*, *119*(5), 1575-1586.
- Horn, B. K., & Schunck, B. G. (1981). Determining optical flow. *Artificial intelligence*, *17*(1-3), 185-203.
- Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J., & Keutzer, K. (2016). SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size. *arXiv preprint arXiv:1602.07360*.
- Iosa, M., Picerno, P., Paolucci, S., & Morone, G. (2016). Wearable inertial sensors for human movement analysis. *Expert review of medical devices*, *13*(7), 641-659.
- Jo, B., & Kim, S. (2022). Comparative analysis of OpenPose, PoseNet, and MoveNet models for pose estimation in mobile devices. *Traitement du Signal*, *39*(1), 119.
- Kim, J.-W., Choi, J.-Y., Ha, E.-J., & Choi, J.-H. (2023). Human pose estimation using mediapipe pose and optimization method based on a humanoid model. *Applied sciences*, *13*(4), 2700.
- Kolahi, A., Hoviattalab, M., Rezaeian, T., Alizadeh, M., Bostan, M., & Mokhtarzadeh, H. (2007). Design of a marker-based human motion tracking system. *Biomedical Signal Processing and Control*, *2*(1), 59-67.
- Laird, Y., Fawcner, S., & Niven, A. (2018). A grounded theory of how social support influences physical activity in adolescent girls. *International journal of qualitative studies on health and well-being*, *13*(1), 1435099.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, *521*(7553), 436-444.
- Lempereur, M., Brochard, S., Leboeuf, F., & Rémy-Néris, O. (2014). Validity and reliability of 3D marker based scapular motion analysis: a systematic review. *Journal of biomechanics*, *47*(10), 2219-2230.
- Liaw, A., & Wiener, M. (2002). Classification and regression by randomForest. *R news*, *2*(3), 18-22.
- Lugaresi, C., Tang, J., Nash, H., McClanahan, C., Uboweja, E., Hays, M., Zhang, F., Chang, C.-L., Yong, M. G., & Lee, J. (2019). Mediapipe: A framework for building perception pipelines. *arXiv preprint arXiv:1906.08172*.
- Mateen, M., Wen, J., Nasrullah, Song, S., & Huang, Z. (2018). Fundus image classification using VGG-19 architecture with PCA and SVD. *Symmetry*, *11*(1), 1.
- Meeuwisse, W. H., Tyreman, H., Hagel, B., & Emery, C. (2007). A Dynamic Model of Etiology in Sport Injury: The Recursive Nature of Risk and Causation. *Clinical Journal of Sport Medicine*, *17*(3), 215-219.
<https://doi.org/10.1097/JSM.0b013e3180592a48>
- Nakano, N., Sakura, T., Ueda, K., Omura, L., Kimura, A., Iino, Y., Fukushima, S., & Yoshioka, S. (2020). Evaluation of 3D markerless motion capture accuracy using OpenPose with multiple video cameras. *Frontiers in sports and active living*, *2*, 50.
- Netto, K. J., & Burnett, A. F. (2006). Reliability of normalisation methods for EMG analysis of neck muscles. *Work*, *26*(2), 123-130.
- Osokin, D. (2018). Real-time 2d multi-person pose estimation on cpu: Lightweight openpose. *arXiv preprint arXiv:1811.12004*.
- Pajak, G., Krutz, P., Patalas-Maliszewska, J., Rehm, M., Pajak, I., & Dix, M. (2022). An approach to sport activities recognition based on an inertial sensor and deep learning. *Sensors and Actuators A: Physical*, *345*, 113773.

- Pan, S. (2022). A method of key posture detection and motion recognition in sports based on Deep Learning. *Mobile Information Systems*, 2022(1), 5168898.
- Penedo, F. J., & Dahn, J. R. (2005). Exercise and well-being: a review of mental and physical health benefits associated with physical activity. *Current Opinion in Psychiatry*, 18(2), 189-193. https://journals.lww.com/co-psychiatry/fulltext/2005/03000/exercise_and_well_being_a_review_of_mental_and.13.aspx
- Ramanan, D., Forsyth, D. A., & Zisserman, A. (2006). Tracking people by learning their appearance. *IEEE transactions on pattern analysis and machine intelligence*, 29(1), 65-81.
- Ronao, C. A., & Cho, S.-B. (2016). Human activity recognition with smartphone sensors using deep learning neural networks. *Expert systems with applications*, 59, 235-244.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *nature*, 323(6088), 533-536.
- Schölkopf, B., & Smola, A. J. (2002). *Learning with kernels: support vector machines, regularization, optimization, and beyond*. MIT press.
- Schuch, F. B., Vancampfort, D., Rosenbaum, S., Richards, J., Ward, P. B., & Stubbs, B. (2016). Exercise improves physical and psychological quality of life in people with depression: A meta-analysis including the evaluation of control group response. *Psychiatry research*, 241, 47-54.
- Shah, D., Rautela, V., & Sharma, C. (2021). Yoga pose detection using posenet and k-nn. 2021 International conference on computing, communication and green engineering (CCGE),
- Shorten, C., Khoshgoftaar, T. M., & Furht, B. (2021). Text data augmentation for deep learning. *Journal of big Data*, 8(1), 101.
- Shotton, J., Fitzgibbon, A., Cook, M., Sharp, T., Finocchio, M., Moore, R., Kipman, A., & Blake, A. (2011). Real-time human pose recognition in parts from single depth images. CVPR 2011,
- Siewe, J., Rudat, J., Röllinghoff, M., Schlegel, U., Eysel, P., & Michael, J.-P. (2011). Injuries and overuse syndromes in powerlifting. *International journal of sports medicine*, 32(09), 703-711.
- Silva, S., Ribeiro, F., Figueira, V., & Pinho, F. (2022). Methodological Considerations in the Kinematic and Kinetic Analysis of Human Movement among Healthy Adolescents: A Scoping Review of Nonlinear Measures in Data Processing. *Sensors*, 23(1), 304.
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information processing & management*, 45(4), 427-437.
- Toshev, A., & Szegedy, C. (2014). Deeppose: Human pose estimation via deep neural networks. Proceedings of the IEEE conference on computer vision and pattern recognition,
- Wang, C., Chen, D., Hao, L., Liu, X., Zeng, Y., Chen, J., & Zhang, G. (2019). Pulmonary image classification based on inception-v3 transfer learning model. *IEEE Access*, 7, 146533-146541.
- Wang, L., Zhang, H., & Yuan, G. (2021). Big Data and Deep Learning-Based Video Classification Model for Sports. *Wireless Communications and Mobile Computing*, 2021(1), 1140611.
- Wang, P. (2021). Research on sports training action recognition based on deep learning. *Scientific Programming*, 2021(1), 3396878.

- Warburton, D. E., Nicol, C. W., & Bredin, S. S. (2006). Health benefits of physical activity: the evidence. *CMAJ*, *174*(6), 801-809.
<https://doi.org/10.1503/cmaj.051351>
- Xu, Y. (2021). A sports training video classification model based on deep learning. *Scientific Programming*, *2021*(1), 7252896.
- Zhao, X. (2022). Analysis and Correction of Wrong Technical Actions in Juvenile Sports Training Based on Deep Learning. *Computational Intelligence and Neuroscience*, *2022*(1), 6492410.



EKLER**EK-1 MediaPipe Anahtar Noktaları**

No	Türkçe Adı	No	Türkçe Adı	No	Türkçe Adı
0	Burun	11	Sol omuz	22	Sağ baş parmak
1	Sol göz içi	12	Sağ omuz	23	Sol kalça
2	Sol göz	13	Sol dirsek	24	Sağ kalça
3	Sol göz dışı	14	Sağ dirsek	25	Sol diz
4	Sağ göz içi	15	Sol bilek	26	Sağ diz
5	Sağ göz	16	Sağ bilek	27	Sol ayak bileği
6	Sağ göz dışı	17	Sol serçe parmak	28	Sağ ayak bileği
7	Ağız sol	18	Sağ serçe parmak	29	Sol topuk
8	Ağız sağ	19	Sol işaret parmak	30	Sağ topuk
9	Sol kulak	20	Sağ işaret parmak	31	Sol ayak işaret parmak
10	Sağ kulak	21	Sol baş parmak	32	Sağ ayak işaret parmak

ÖZGEÇMİŞ**KİŞİSEL BİLGİLER**

Adı Soyadı : Ahmet ÇELİKEL
Uyruğu : T.C.

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	Fatih Mesleki ve Teknik Anadolu Lisesi- SELÇUKLU / KONYA	2007
Üniversite	Selçuk Üniversitesi - SELÇUKLU / KONYA	2012
Yüksek Lisans	-	-
Doktora	-	-

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2013 -	MİLLİ EĞİTİM BAKANLIĞI	Bilişim Teknolojileri Öğretmeni

YABANCI DİLLER

İngilizce