



**SAMSUN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**VIDEO TABANLI EGZERSİZ TANIMA
VE KALORİ YAKIMI TAHMİNİ**

Kaan Kubilay ÖZDEMİR

YÜKSEK LİSANS TEZİ

**Yazılım Mühendisliği Anabilim Dalı
Danışman: Dr. Öğr. Üyesi Emel SOYLU**

Temmuz 2024

16/07/2024

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Samsun Üniversitesi tarafından kullanılan “bilimsel intihal tespit programı”yla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Kaan Kubilay ÖZDEMİR

ÖNSÖZ

Video tabanlı egzersiz tanıma ve kalori yakımı tahmini, günümüzde sağlıklı yaşam ve fitness alanında büyük bir öneme sahiptir. Modern yaşam koşulları, teknolojinin hızla gelişmesi ve bireylerin sağlık bilincinin artması, bu konunun önemini daha da artırmaktadır. Ancak, egzersiz hareketlerinin çeşitliliği, karmaşıklığı ve doğru kalori hesaplamalarının yapılması, video tabanlı egzersiz tanıma problemini zorlaştırmaktadır.

Makine öğrenmesi, verilerden öğrenme ve bu bilgiyi kullanarak karar verme yeteneğine sahip modeller geliştirmek için kullanılan bir yaklaşımdır. Bu yöntemler, egzersiz hareketlerinin karmaşık özelliklerini öğrenme ve tanıma yeteneğine sahiptir. Bu sayede, video tabanlı egzersiz tanıma ve kalori yakımı tahmini problemini daha doğru ve verimli bir şekilde çözmek mümkündür. Bu tez, makine öğrenmesi yöntemleri ile video tabanlı egzersiz tanıma ve kalori yakımı tahmin etme problemini ele almaktadır.

Tez çalışmasının konusunun belirlenmesinde ve hazırlanma sürecinin her aşamasında bilgilerini, tecrübelerini ve değerli zamanlarını esirgemeyerek bana her fırsatta yardımcı olan değerli danışman hocam Dr. Öğr. Üyesi Emel SOYLU'ya ve tüm eğitim hayatım boyunca benden maddi ve manevi desteklerini esirgemeyen, her zaman yanımda olan sevgili aileme teşekkürü bir borç bilirim.

Temmuz 2024

Kaan Kubilay ÖZDEMİR

İÇİNDEKİLER

ÖNSÖZ	IV
ÖZET	VII
ABSTRACT	VIII
Tablolar Listesi.....	IX
Görseller Listesi.....	XI
Şekiller Listesi.....	XII
Kısaltmalar Dizini	XIII

BİRİNCİ BÖLÜM

1. GİRİŞ	1
----------------	---

İKİNCİ BÖLÜM

2. YÖNTEMLER.....	14
2.1. Mediapipe	15
2.2. KNN Makine Öğrenmesi Modeli	16
2.3. ADA Makine Öğrenmesi Modeli	18
2.4. SVC Makine Öğrenmesi Modeli	19
2.5. DT Makine Öğrenmesi Modeli	21
2.6. GB Makine Öğrenmesi Modeli	23
2.7. RF Makine Öğrenmesi Modeli.....	24
2.8. RC Makine Öğrenmesi Modeli	25
2.9. NB Makine Öğrenmesi Modeli	27
2.10. LR Makine Öğrenmesi Modeli	28
2.11. Performans Metrikleri	29
2.12. Açık Hesaplama	30
2.13. Hareketli Noktalar Filtresi.....	32
2.14. Sinyalde Tepe Sayma	33

2.15. Kalori Hesaplama.....	33
-----------------------------	----

ÜÇÜNCÜ BÖLÜM

3. VERİ SETİ	34
--------------------	----

3.1. Video Bilgileri.....	34
---------------------------	----

3.2. Veri Setinden Örnekler	34
-----------------------------------	----

3.3. Videoların Toplanması.....	38
---------------------------------	----

3.4. Eğitim Test Olarak Ayrılması.....	39
--	----

3.5. Csv Dosyasının Oluşturulması.....	39
--	----

DÖRDÜNCÜ BÖLÜM

4. DENEYSEL ÇALIŞMALAR.....	40
-----------------------------	----

4.1. Eğitimler Ve Sonuçları	40
-----------------------------------	----

4.2. Testler Ve Sonuçları.....	51
--------------------------------	----

4.3. Hareket Sayaç Sonuçları.....	61
-----------------------------------	----

4.4. Dakikadaki Hareket Sayısına Göre MET Değeri.....	64
---	----

BEŞİNCİ BÖLÜM

5. SONUÇLAR ve ÖNERİLER	66
-------------------------------	----

KAYNAKÇA.....	72
---------------	----

ÖZGEÇMİŞ.....	72
---------------	----

ÖZET

VIDEO TABANLI EGZERSİZ TANIMA

VE KALORİ YAKIMI TAHMİNİ

Kaan Kubilay Özdemir

Yazılım Mühendisliği Anabilim Dalı

Samsun Üniversitesi, Lisansüstü Eğitim Enstitüsü, Temmuz 2024

Danışman: Dr. Öğr. Üyesi Emel SOYLU

Modern yaşam koşulları ve sağlıksız beslenme nedeniyle obezite ve hareketsizlik kaynaklı sağlık sorunları günümüzde büyük bir problem haline gelmiştir. Sağlıklı bir yaşam sürmek veya kilo vermek isteyen bireyler çeşitli spor aktiviteleri yapmayı tercih ederler, ancak bu aktivitelerin doğru bir şekilde yapılması ve yakılan kalorilerin doğru hesaplanması zordur. Yanlış kalori hesaplamaları kilo kontrolünü zorlaştırabilir ve motivasyon kaybına, metabolizma sorunlarına, yorgunluğa ve performans kaybına yol açabilir. Bu nedenle, egzersiz sırasında yakılan kalorinin doğru hesaplanması çok önemlidir. Bu çalışmada, kişinin yaptığı egzersiz türüne göre kendi videosu üzerinden ne kadar kalori harcadığını hesaplayan bir yazılım geliştirilmiştir. Yazılım, video görüntüsünden egzersiz türünü tanımlama, hareket sayısını sayma ve tahmini kalori yakımını izleme yeteneklerine sahiptir. Literatürde ayrı ayrı ele alınan video sınıflandırma, hareket sayma ve kalori hesaplama problemleri bu çalışmada bütüncül bir yaklaşımla bir araya getirilmiştir. Çalışmada barfiks, şınav, koşma, bisiklet, squat ve ip atlama gibi yaygın egzersiz türleri ele alınmıştır. Yapılan deneysel sonuçlara göre yüksek doğruluklar elde edilmiştir.

Anahtar Sözcükler: Mediapipe, Video Sınıflandırma, Hareket Sayacı, Makine Öğrenmesi, Hareket Algılama, Kalori Hesaplama

ABSTRACT

VIDEO-BASED EXERCISE RECOGNITION AND CALORIE BURN ESTIMATION

Kaan Kubilay Özdemir

Software Engineering Graduate Program

Samsun University, Graduate School, July 2024

Supervisor: Assist. Prof. Dr. Emel SOYLU

Due to modern living conditions and unhealthy eating habits, obesity and inactivity-related health issues have become major problems today. Individuals aiming to maintain a healthy lifestyle or lose weight often engage in various sports activities, but performing these activities correctly and accurately calculating the calories burned can be challenging. Incorrect calorie calculations can complicate weight control and lead to a loss of motivation, metabolic issues, fatigue, and performance decline. Therefore, accurately calculating the calories burned during exercise is crucial. In this study, software was developed to calculate the calories burned based on the type of exercise performed, using the individual's video footage. The software is capable of identifying the exercise type, counting repetitions, and tracking estimated calorie burn from video footage. Problems such as video classification, repetition counting, and calorie calculation, which are typically addressed separately in the literature, have been integrated into a holistic approach in this study. Commonly preferred exercise types such as pull-ups, push-ups, running, cycling, squats, and jumping rope have been considered. Experimental results demonstrated high accuracy.

Keywords: Mediapipe, Calorie Calculation, Deep Learning, Motion Detection, Motion Counter, Video Classification

Tablolar Listesi

Tablo 1. Açık hesaplamada kullanılan anahtar noktalar.	31
Tablo 2. Tez çalışmasında kullanılan veri kaynakları.	34
Tablo 3. Toplanan videoların sayısal dağılımı.	34
Tablo 4. RF karmaşıklık matrisi sonuçları.	40
Tablo 5. RF performans metrikleri.	40
Tablo 6. GB karmaşıklık matrisi sonuçları.	41
Tablo 7. GB performans metrikleri.	42
Tablo 8. LR karmaşıklık matrisi sonuçları.	42
Tablo 9. LR performans metrikleri.	43
Tablo 10. RC karmaşıklık matrisi sonuçları.	43
Tablo 11. RC performans metrikleri.	44
Tablo 12. NB karmaşıklık matrisi sonuçları.	45
Tablo 13. NB performans metrikleri.	45
Tablo 14. KNN karmaşıklık matrisi sonuçları.	46
Tablo 15. KNN performans metrikleri.	46
Tablo 16. ADA karmaşıklık matrisi sonuçları.	47
Tablo 17. ADA performans metrikleri.	47
Tablo 18. DT karmaşıklık matrisi sonuçları.	48
Tablo 19. DT performans metrikleri.	49
Tablo 20. SVC karmaşıklık matrisi sonuçları.	49
Tablo 21. SVC performans metrikleri.	50
Tablo 22. Eğitim verilerinin kategori bazlı model doğruluk oranları.	51
Tablo 23. RF karmaşıklık matrisi test sonuçları.	52
Tablo 24. RF test performans metrikleri.	52
Tablo 25. GB karmaşıklık matrisi test sonuçları.	53
Tablo 26. GB test performans metrikleri.	53
Tablo 27. LR karmaşıklık matrisi test sonuçları.	54
Tablo 28. LR test performans metrikleri.	54
Tablo 29. RC karmaşıklık matrisi test sonuçları.	55
Tablo 30. RC test performans metrikleri.	55
Tablo 31. NB karmaşıklık matrisi test sonuçları.	56
Tablo 32. NB test performans metrikleri.	56
Tablo 33. KNN karmaşıklık matrisi test sonuçları.	57
Tablo 34. KNN test performans metrikleri.	57

Tablo 35. ADA karmaşıklık matrisi test sonuçları.	58
Tablo 36. ADA test performans metrikleri.	58
Tablo 37. DT karmaşıklık matrisi test sonuçları.	59
Tablo 38. DT test performans metrikleri.....	59
Tablo 39. SVC karmaşıklık matrisi test sonuçları.	60
Tablo 40. SVC test performans metrikleri.	60
Tablo 41. Test verilerinin kategori bazlı model doğruluk oranları.....	61
Tablo 42. Squat test videolarından elde edilen hareket sayaç sonuçları.	61
Tablo 43. Koşma test videolarından elde edilen hareket sayaç sonuçları.	62
Tablo 44. Şınav test videolarından elde edilen hareket sayaç sonuçları.	62
Tablo 45. Bisiklet test videolarından elde edilen hareket sayaç sonuçları.	63
Tablo 46. Barfiks test videolarından elde edilen hareket sayaç sonuçları	63
Tablo 47. İp Atlama test videolarından elde edilen hareket sayaç sonuçları.....	64
Tablo 48. Hareket sayacı sonuçları.	64
Tablo 49. Dakikadaki hareket sayısına göre MET değeri.....	65

Görseller Listesi

Görsel 1. Barfiks görüntüsü ve giydirilmiş hali	35
Görsel 2. Squad görüntüsü ve giydirilmiş hali	36
Görsel 3. Koşma görüntüsü ve giydirilmiş hali	36
Görsel 4. Bisiklet görüntüsü ve giydirilmiş hali.....	37
Görsel 5. Squat görüntüsü ve giydirilmiş hali	37
Görsel 6. Atlama görüntüsü ve giydirilmiş hali	38



Şekiller Listesi

Şekil 1. Modelin geliştirilmesi grafiksel özeti	12
Şekil 2. Modelin çalıştırılması grafiksel özeti	13
Şekil 3. Video sınıflandırıcı model oluşturma süreci.	14
Şekil 4. Sistemin çalışma şekli.....	15
Şekil 5. Mediapipe pose detection (33 Key Points, 2024).....	16
Şekil 6. KNN makine öğrenmesi modeli.....	17
Şekil 7. ADA makine öğrenmesi modeli.....	18
Şekil 8. SVC makine öğrenmesi modeli.....	20
Şekil 9. DT makine öğrenmesi modeli	22
Şekil 10. GB makine öğrenmesi modeli	23
Şekil 11. RF makine öğrenmesi modeli	25
Şekil 12. RC makine öğrenmesi modeli	26
Şekil 13. NB makine öğrenmesi modeli	27
Şekil 14. LR makine öğrenmesi modeli	28
Şekil 15. Doğrunun eğimi.	31
Şekil 16. Kesişen iki doğru arasındaki açı.....	31
Şekil 17. Barfiks kaydından alınmış açısal değişim.....	32
Şekil 18. Filtre uygulanmış kayıt örneği.	33
Şekil 19. Csv dosyasını oluşturma	39
Şekil 20. Çerçeve bazında sonuç kayıtları.....	51

Kısaltmalar Dizini

3D-CNNs	: 3D Convolutional Neural Networks (3B Evrişimli Sinir Ağları)
ADA	: AdaBoost (Adaptive Boosting)
ARNs	: Action Recognition Networks (Eylem Tanıma Ağları)
AUC	: Area Under the Curve (Eğri Altındaki Alan)
BA	: Body Assessment (Vücut Değerlendirmesi)
C4.5	: Classification and Regression Trees (CART) V4.5
CART	: Classification and Regression Trees (Sınıflandırma ve Regresyon Ağaçları)
ConvLSTM	: Convolutional LSTM (Evrişimli LSTM)
DL	: Deep Learning (Derin Öğrenme)
DT	: Decision Tree (Karar Ağacı)
EKK	: Least Squares (En Küçük Karalar)
GB	: Gradient Boosting (Gradyan Artırma)
GPS	: Global Positioning System (Küresel Konumlama Sistemi)
KNN	: K-Nearest Neighbors (K-En Yakın Komşu)
LPD	: Landmark Pose Detection (İşaret Nokta Poz Tespiti)
LR	: Logistic Regression (Lojistik Regresyon)
LSTM	: Long Short-Term Memory (Uzun kısa süreli bellek)
MC	: Motion Counter (Hareket sayacı)
MD	: Motion Detection (Makine hareketi algılama)
MET	: Metabolic Equivalent of Task (Metabolik Eşdeğer)
ML	: Machine Learning (Makine Öğrenmesi)
NB	: Naive Bayes (Saf Bayes)
OpenCV	: Open Source Computer Vision Library (Açık Kaynak Bilgisayar Görüşü Kütüphanesi)
RC	: Ridge Regression (Ridge Regrasyonu)
RE	: Rapid Entire Body Assessment (Hızlı Tüm Vücut Değerlendirmesi)
RF	: Random Forest (Rastgele Orman)
RGB	: Red-Green-Blue (Kırmızı-Yeşil-Mavi)
RNN	: Recurrent Neural Network (Tekrarlayan Sinir Ağı)
ROC	: Receiver Operating Characteristic (Alıcı İşletim Karakteristiği)
SVC	: Support Vector Classification (Destek Vektör Sınıflandırması)
SVM	: Support Vector Machine (Destek Vektör Makinesi)

TSNs : Temporal Segment Networks (Zamansal Segment Ağları)
VC : Video Classification (Video Sınıflandırma)



BİRİNCİ BÖLÜM

1. GİRİŞ

Obezite ve hareketsizlik kaynaklı sağlık sorunları, günümüzün en büyük problemlerindendir. Modern yaşam koşulları ve sağlıksız beslenme nedeniyle insanlar her geçen gün daha hareketsiz hale gelmektedir. Sağlıklı bir yaşam sürmek veya zayıflamak isteyen kişiler, çeşitli spor aktiviteleri yapmayı tercih etmektedirler. Bu kişiler, profesyonel yardım almadan bireysel olarak spor yapmayı tercih edebilirler. Ancak, bu durumda egzersiz hareketlerini doğru bir şekilde yapıp yapmadıklarını veya egzersiz sırasında ne kadar kalori harcadıklarını kendi kendilerine kestiremeyebilirler. Spor yaparken yakılan kaloringin yanlış hesaplanması çeşitli olumsuzluklara yol açabilir. Bu durum, kilo kontrolü ve zayıflama hedeflerine ulaşmayı zorlaştırabilir, çünkü yanlış hesaplamalar kişinin ihtiyacından fazla veya az kalori almasına neden olabilir. Beslenme dengesinin bozulması, fazla kalori alımı durumunda yağ birikimi ve obezite riskini artırırken, yetersiz kalori alımı enerji eksikliği, kas kaybı ve genel sağlık problemlerine yol açabilir. Yanlış kalori hesaplamaları, egzersizden beklenen sonuçların alınamamasına ve dolayısıyla motivasyon kaybına neden olabilir. Ayrıca, bu durum metabolizma üzerinde olumsuz etkiler yaratarak yorgunluk, bağışıklık sisteminin zayıflaması ve hormon dengesizlikleri gibi sağlık sorunlarına yol açabilir. Sporcular için de performans kaybına neden olabilen yanlış hesaplamalar, enerji eksikliğine ve antrenmanlarda beklenen performansın gösterilememesine sebep olabilir. Sürekli olarak yanlış kalori hesaplamaları ve beklenen sonuçların alınamaması, psikolojik olarak da moral bozukluğu, stres, kaygı ve depresyon gibi sorunlara yol açabilir. Bu nedenle, egzersiz sırasında yakılan kaloringin doğru bir şekilde hesaplanması, bu olumsuzlukların önlenmesi açısından kritik bir öneme sahiptir.

Bu aşamada kişinin yaptığı egzersiz türüne göre kendi videosu üzerinden ne kadar kalori harcadığını hesaplayan bir yazılım faydalı olabilir fikrinden hareketle bu çalışmanın kapsamı belirlenmiştir. Kullanıcıların egzersiz yaparken daha bilinçli ve etkili bir şekilde egzersizlerini yönlendirmelerini sağlamak amacıyla, video görüntüsünden egzersiz türünü tanımlama, hareket sayısını sayma ve tahmini kalori yakımını izleme amaçlı çalışma yapılmış video sınıflandırılması için farklı algoritmalar karşılaştırılmıştır. Bu tez çalışmasının özgünlüğü, üç ayrı problemi bir arada çözmeye yönelik kapsamlı bir yaklaşım sunmasıdır. Literatürde, video sınıflandırma, hareket sayacı ve kalori hesaplama gibi problemler genellikle ayrı ayrı ele alınmıştır. Video görüntülerinden egzersiz türünü tanımlama, hareket sayısını sayma ve tahmini kalori yakımını izleme gibi süreçlerin bir arada değerlendirildiği bu çalışma, literatürdeki

benzer alıřmalardan farklı olarak, bütüncül bir yaklaşım sunarak daha kullanışlı ve pratik bir uygulama ortaya koymaktadır. alıřmada video sınıflandırma, hareket sayacı, kalori hesaplama gibi farklı problemleri özmek üzerine odaklanılmıştır. Literatür araştırması yapılırken bu ana başlıklar üzerine odaklanılmıştır.

Video sınıflandırma, fitness ve spor endüstrisinde önemli bir yer tutar ve eřitli uygulamalarda kullanılır. Egzersiz tanıma, bu teknolojinin en belirgin kullanım alanlarından biridir. Bu uygulamalar sayesinde, kullanıcılar egzersizlerini yaparken doğru formu koruyabilir ve gerekli düzeltmeleri yapabilirler. Egzersiz türüne ve süresine baėlı olarak, video sınıflandırma kullanılarak kalori yakımı tahmini yapılabilir. Bu, kullanıcıların egzersiz performanslarını izlemelerine ve hedeflerine ulaşmalarına yardımcı olur. Örneėin, belirli bir egzersizin ne kadar süreyle yapıldığına baėlı olarak günlük kalori yakımı tahmin edilebilir ve bu bilgi, kullanıcıların beslenme ve egzersiz programlarını optimize etmelerine yardımcı olur. Fizik tedavi ve rehabilitasyon süreçlerinde hastaların belirli hareketleri doğru bir şekilde yapmalarını izlemek için video sınıflandırma teknikleri kullanılabilir. Bu, hastaların iyileřme sürecini hızlandırır ve doğru hareketlerin yapılmasını saėlar. Örneėin, bir fizik tedavi programı sırasında hastanın hareketlerini izleyerek doğru formda yapılmadığında düzeltmeler önerilebilir ve tedavi süreci optimize edilebilir.

Video sınıflandırma, görüntü işleme uygulamalarında sıkça ele alınan bir başlıktır ve bu problemi özmek için eřitli yöntemler bulunmaktadır. Bu yöntemler, videoların mekansal ve zamansal özelliklerini analiz ederek belirli hareketleri ve aktiviteleri tanımlamayı amaçlar. Long Short-Term Memory (LSTM), zaman serisi verilerini işlemek için kullanılan bir tür tekrarlayan sinir aėıdır ve egzersiz sırasında yapılan hareketlerin sırasını ve zamanlamasını öğrenmek için kullanılabilir. Uzun süreli baėımlılıkları öğrenme yeteneėi sayesinde karmařık hareket dizilerini tanımlamak için idealdir. Temporal Segment Networks (TSNs) ise bir videoyu kısa kliplere bölerek her bir klibi ayrı ayrı analiz eder ve ardından bu analizleri birleřtirir. Bu yaklaşım hem mekansal hem de zamansal özellikleri analiz etmeye olanak tanır ve bu sayede farklı egzersiz türlerini ve bunların sırasını belirlemek için kullanılabilir. Limin Wang ve ark. zamansal Segment Aėları (TSN'ler), uzun menzilli zamansal yapıları verimli bir şekilde modellemeyi amaçlayan video tabanlı eylem tanıma için bir ereve olarak tanıtmışlardır (Wang v.d., 2018). Action Recognition Networks (ARNs), videolarda belirli eylemleri veya hareketleri tanımlamak için kullanılır. Yüksek doğruluk ve gerek zamanlı izleme yeteneėiyle ARNs, egzersiz türlerinin ve hareketlerin gerek zamanlı olarak tanımlanması için idealdir. 3D Convolutional Neural Networks (3D-CNNs) ise videoların hem mekansal hem de zamansal özelliklerini analiz eder. Bu entegre analiz, karmařık egzersiz

hareketlerinin tanımlanması ve izlenmesi için oldukça etkilidir. Convolutional LSTM (ConvLSTM) LSTM'nin bir varyasyonudur ve giriş ve çıkış verilerini 2D haritalar olarak ele alır. Hem mekansal hem de zamansal bilgilerin entegre analizi sayesinde ConvLSTM, egzersizlerin mekansal formlarını ve zamansal dizilerini birlikte analiz etmek için idealdir. Bu çeşitli sinir ağı türleri, egzersiz hareketlerinin kapsamlı ve doğru bir şekilde tanımlanmasına ve izlenmesine olanak tanır.

Bu tarz çalışmalara ek olarak, duruş tespiti algoritmaları kullanılarak yapılan hareket analizi çalışmalarında da başarılı sonuçlar elde edilmektedir. Duruş tespiti ile hareket analizi çalışmalarına örnekler vermek gerekirse;

Zhang ve ark. MediaPipe kullanarak cihazda gerçek zamanlı el takibi yapmışlardır (Zhang *et al.*, 2020) ve zhang ve ark. mediapipe çerçevelerinin birleşimi, etkili bir insan derin çömelme algılama yöntemi yapmışlardır (Zhang *v.d.*, 2022).

Pauzi ve ark. bir kişinin vücut hareketlerini takip ederken vücuttaki etiketli iskelet eklemlerini artıran bir sistem incelemişlerdir. Çalışmada, ağır iş yükü sırasında vücut yaralanmalarını tespit etmek için özel olarak tasarlanmış küratörlü hareketlerin algılanması ve tahmin edilmesi için Mediapipe BlazePose adlı bir algoritma kullanılmıştır (Pauzi *v.d.*, 2021).

Amprimo ve ark. basit motor görevlerdeki el becerilerindeki bozulmaların erken tespiti için bir RGB-Derindelik kamerası ve Google MediaPipe Hands kullanarak bir çözüm sunmuştur. Önerilen yöntem, el motor becerilerinin uzaktan değerlendirilmesi için bir araç sağlar ve el performansındaki bozulmaları otomatik olarak belirleme yeteneğine sahiptir. Bu, özellikle yaşlılar ve nörolojik hastalıkları olan kişilerde genel sağlık koşullarının kötüleşmesini erken aşamada belirleyebilir ve hızlı tedavi uygulamasını mümkün kılmayı hedeflemiştir (Amprimo *v.d.*, 2022).

Lin ve ark. Mediapipe'nin 3D insan duruşu algılamadaki hatalarını düzeltmek amacıyla çeşitli yöntemler sunmuştur. İyileştirilmiş Mediapipe temelli 3D insan duruşu tespitinin doğruluğunun farklı boyut, ağırlık, yaş ve cinsiyetlere sahip kişiler üzerinde yapılan çoklu duruş tanıma testi ile %90'dan fazla olduğu doğrulanmıştır (Lin, Jiao ve Zhao, 2023).

Thaman ve ark. COVID-19 salgınında yüz maskelerinin doğru kullanımının önemini vurgulayarak, insanların yüz maskesi takıp takmadığını otomatik olarak tespit etmek için alternatif bir yaklaşım sundular. MediaPipe gibi bir makine öğrenme modeli kullanarak, mobil cihazlarda da kullanılabilen bir görüntü segmentasyon ve nesne tespiti çözümü geliştirmişlerdir (Thaman, Cao ve Caporusso, 2022).

Jeong ve Kook kas-iskelet sistemi rashatsızlıklarının (KİSH'ler) önemli bir sorun olduğu endüstriyel sağlık alanında, çalışma duruşlarının otomatik ve tutarlı bir şekilde

değerlendirilebilmesi için bir bilgisayar tabanlı otomatik bir sistem önerdi. Bu sistem, MediaPipe'ın vücut ve yüz algılama modellerini kullanarak çalışanın alanını ve eklemlerini algılayıp eklem açılarını hesaplamıştır ve REBA yöntemi ile çalışma duruşunun yük derecesini otomatik olarak değerlendirmişlerdir (Jeong ve Kook, 2023).

Jeong ve Kook el hareketlerinin videolarının kaydedilmesini ve Google MediaPipe kullanılarak önemli noktaların çıkarılmasını içeren, jest sınıflandırma modelini eğitmek için bir veri kümesi oluşturma süreci oluşturdular. Akıllı telefonlar ve diğer cihazlar tarafından çekilen yürüyüş videolarından yürüyüş döngülerini otomatik olarak analiz edebilen MediaPipe'ı kullanarak niceliksel ve basit bir yürüyüş analiz sistemi oluşturuldu (Jeong ve Kook, 2023).

Shaikh ve ark. el işareti tanıma sistemleri, sağır ve dilsiz bireylerin iletişim ihtiyacına odaklanarak geliştirdiler. Bu sistemler, Python, Mediapipe, OpenCV ve Scikit Learn gibi araçları kullanarak gerçek zamanlı el işareti algılama ve tanıma yeteneklerini birleştirip bu sayede, çeşitli el şekillerini ve yönelimlerini tanıyarak geniş bir kullanım alanına sahip oldular (Shaikh v.d., 2023).

Romindo ve ark. standart RGB kameralar aracılığıyla JSL hareketlerini yakalayan bir video veri seti topladılar ve el pozu tahmini için MediaPipe'ı kullanmışlardır (Kakizaki *et al.*, 2024). MediaPipe Pose Estimation kütüphanesi kullanılarak geliştirilen bir sınıflandırma modeli, bale pozlarını tanımlamak için destek vektör makinesi algoritmasını kullanılmıştır. Model, yedi farklı bale pozunda eğitilmiştir ve %87'lik bir doğruluk elde etmiştir. Hem görüntülerde hem de canlı videolarda başarıyla çalışmıştır (Romindo v.d., 2022).

Gopal, Azure Kinect'in vücut izleme algoritmasını vücuttaki antropometrik noktalara karşılık gelen 32 eklemden oluşan 3 boyutlu bir iskelet modeli kullanarak vücut hareketini gerçek zamanlı olarak yakalamıştır. Çıplak el hareketlerini yakalamak için, Google MediaPipe Hands'in 3 boyutlu versiyonunu uygulamıştır. Bu sistem ile kamera tarafından sağlanan derinlik bilgilerinden yararlanarak doğru bir 3 boyutlu el iskelet modeli elde etmiştir (Gopal, 2023).

Chen ve Liu görsel tabanlı insan poz tespiti alanında önemli bir uygulama olan kondisyon hareketi sayımı için bir sistem geliştirmiştir. Sistem, hafif bir MediaPipe modeli kullanarak insan iskelet noktalarını tespit edererek ve bunları birleştirerek insan poz iskeleti oluşturmuşlardır. Bu iskelet yapıları, insan hareketinin özelliklerini doğru bir şekilde temsil eder ve kondisyon hareketlerinin doğruluğunu değerlendirmektedir. (Chen ve Liu, 2023).

X. Li ve ark. Google Mediapipe çerçevesi kullanarak temel fitness hareketlerinin sınıflandırılması ve sayılmasını hedefleyen bir yöntem sunmaktadır. Fitness hareketleri için uygun pozlar toplanıp eğitildikten sonra, KNN makine öğrenmesi modeliyle farklı hareketler tanımlanıp sınıflandırmışlardır. Sonuçlar işlenerek fitness hareketleri doğru bir şekilde sayılır

ve analiz edip MediaPipe BlazePose algoritması, diğer tanıma çerçevelerine göre daha düşük performans gereksinimleri ve yüksek doğruluk sağlandığını görmüşlerdir, bu da mobil fitness uygulamaları için ideal olduğunu kullanıcıların fitness etkinliklerini izlemesine ve geliştirmesine yardımcı olduğunu göstermiştir (X. Li v.d., 2022).

Bu tez çalışmasında video sınıflandırılmasında duruş tespitinden elde edilen koordinat bilgilerinin kullanılması benimsenmiştir. Bu versiler kullanılarak makine öğrenmesi algoritmaları ile sınıflandırma yapılmaktadır. Hareketlerin sınıflandırılması için Naive Bayes (NB), K-En Yakın Komşu (KNN), Lojistik Regresyon (LR), Rastgele Orman (RF), Alternatif Karar Ağacı (ADA), Destek Vektör Sınıflandırıcısı (SVC), Karar Ağaçları (DT), Gradyan Artırma (GB), Ridge Regrasyonu (RC) kullanılmıştır. Bu yöntemler literatürde pek çok probleme çözüm üretmektedir.

Kocakulak ve ark. MediaPipe, temassız avuç içi görüntüleme sistemleri, gerçek zamanlı el hareketi tanıma ve tam vücut kardiyovasküler algılamaya odaklanan çalışmalarda kullanılmış ve biyometri, sağlık hizmetleri ve yapay zeka alanlarındaki uyarlanabilirliğini vurgulamıştır(Kocakulak ve Acır, 2023)(Abdallah v.d., 2022).Jebur, Gu, Kang MediaPipe, anormal olay tespiti, sinir yaralanması olan hastalarda anormal el hareketi tespiti ve çeşitli deepfake türleri için tespitin geliştirilmesini içeren araştırmalarda da kullanılmış ve anormallik tespiti ve tıbbi uygulamalardaki önemini vurgulamışlardır. (Jebur v.d., 2022)(Gu v.d., 2022)(Kang v.d., 2022). Çerçevenin anormallikleri tespit etme, jestleri ayırt etme ve yaralanmaları tahmin etme potansiyeli, sağlık ve güvenlikle ilgili görevlerdeki değerini ortaya koyuyor. Sonuç olarak MediaPipe'in sağlam özellikleri ve esnekliği, onu işaret dili tanımadan anormallik tespitine ve sağlıkla ilgili görevlere kadar çok çeşitli uygulamalar için değerli bir araç haline getiriyor. Gerçek zamanlı yetenekleri, kilit nokta tahminindeki doğruluğu ve alanlar arası uyarlanabilirliği onu bilgisayarlı görme ve yapay zeka alanlarında yenilikçi çözümler geliştirmek için çok yönlü bir çerçeve olarak konumlandırıyor.

Leone MediaPipe çerçevesini kullanarak poz tahmini için KNN makine öğrenmesi modelini uygulamak için birkaç önemli referans değerli bilgiler sağladı. Poz modellerini tahmin etmek için MediaPipe çerçevesini bir Python kütüphanesi olarak kullandı(Leone v.d., 2022). Bu, MediaPipe'in poz tahmin görevlerindeki pratik uygulamasını vurgulamaktadır. Doan ise MediaPipe Pose çerçevesini bir LSTM ağını kullanarak gerçek zamanlı hasta etkinliği tanıma sürecine dahil etti(Doan, 2022), MediaPipe'ı etkinlik tanıma için makine öğrenimi modelleriyle birleştirmenin etkinliğini sergiledi. Muhammad MediaPipe Pose modelinin, Leonardo'nun Vitruvius Adamı'ndan esinlenerek insan vücudundaki yer işaretlerini belirlemedeki

yeteneklerini tartıřtı (Muhammad v.d., 2022).Fan ve ark. MediaPipe Pose modeliyle elde edilebilecek anatomik doęruluęu vurguladılar. Ayrıca, bale poz analizi için MediaPipe Pose'dan yararlandılar ve eklem açıları ve vücut hareketlerinin analiz edilmesinde faydalı olduęu ortaya çıktı(Fan, Guo ve Sun, 2022). Samaan Hareket tanıma bağlamında, dinamik iřaret dili tanıma için MediaPipe'ı RNN modelleri ile birlikte başarıyla kullandı(Samaan v.d., 2022). Bu, MediaPipe'ın jestleri ve pozları tanımadaki çok yönlülüęünün altını çizmiştir. Abdallah konum tahmini için MediaPipe kullanılarak el hareketi tanımaya yönelik RNN modelleri geliştirildi(Abdallah v.d., 2022), bu da MediaPipe'ın jestle ilgili görevlerdeki etkinlięini daha da destekledi. Sonuç olarak, KNN makine öğrenmesi modelinin poz tahmini için MediaPipe çerçevesiyle entegrasyonu, aktivite tanıma, jest tanıma ve bale poz analizine odaklanan çeřitli çalışmalarda gösterildięi gibi, vücut iřaretlerini ve hareketlerini belirlemede MediaPipe'ın doęruluęunu ve çok yönlülüęünü güçlendirmiştir.

Mudili ve Ghosh ADA'nın rastgele orman, gradyan artırma ve aşırı gradyan artırma gibi dięer modellerle birlikte geleceęin durumunu tahmin etmede iyi performans gösterdięini bulmuřtur(Muduli ve Ghosh, 2023). řerit bazlı olmayan heterojen trafik kořulları altındaki yayalar. Arařtırma, bu modelleri 0,5 ila 4 saniye arasında deęiřen farklı tahmin ufukları için deęerlendirdi. İlginç bir řekilde, 1 saniyelik bir tahmin ufkuna kadar ADA dahil tüm modeller, 0,95'i aşan ROC eęrisi altındaki alan (AUC) deęerleriyle yüksek performans gösterdi. Bu çalışma, ADA'nın karmařık tr afik senaryolarında yaya davranıřını tahmin etmedeki etkinlięini vurgulamaktadır. Bulgular, birden fazla zayıf öğreniciyi güçlü bir sınıflandırıcı oluřturmak için birleřtirme yeteneęi ile bilinen ADA'nın özellikle řerit bazlı olmayan heterojen trafik kořulları gibi dinamik ve zorlu ortamlarda yaya hareketlerini modelleme ve tahmin etmede deęerli bir araç olabileceęini göstermektedir. Yaya tespit sistemlerinin veya trafik yönetimi stratejilerinin geliştirilmesi gibi pratik uygulamalarda, ADA'nın bir bütünlük yaklařımının parçası olarak kullanılması, özellikle kısa vadeli tahmin senaryolarında tahminlerin doęruluęunu ve güvenilirlięini artırabilir. Arařtırmacılar ve uygulayıcılar, ADA dięer birleřtirme teknikleriyle birlikte kullanarak, dinamik ortamlarda genel tahmin performansını iyileřtirmek için farklı modellerin güçlü yönlerinden yararlanabilirler

Myles DT, verilerdeki bilgilendirici özellikleri ve kalıpları keřfetme yetenekleriyle bilgisayar bilimi, yapay zeka ve makine öğrenmesi gibi çeřitli alanlarda yaygın olarak kullanıldığını saptamıştır(Myles v.d., 2004). Janssens ulařım modellemesi bağlamında yapılan arařtırmalarda Bayes ağlarını karar ağačlarıyla entegre etmenin, yalnızca karar ağačlarını kullanmaya kıyasla tahmin gücünü artırabildięini göstermiştir (Janssens v.d., 2006).Akamine

ve Ajmera Akustik modellerde vektör nicelemesini geliřtirmek için konuřma tanımada karar aęalarında uygulamıřtır.(Akamine ve Ajmera, 2011)

Cao ve ark. Bilgisayarlı grme ve hareket tanımada, karar aęaları, gerek zamanlı el hareketi tanıma için MediaPipe erevesi dahilinde derin ğrenme teknikleriyle entegre etmiřlerdir ve Karar aęaları, farklı zelliklerin tahminlere nasıl katkıda bulunduęunu aıka gsterdikleri için makine ğreniminde aıklanabilirlikleri aısından deęerli olduęunu belirtirler(Cao, Sarlin ve Jung, 2020). Janssens C4.5 ve CART gibi karar aęaı tmevarım algoritmaları, eřitli sistemlerde tahmin grevleri için etkin bir řekilde kullanılmaktadır(Janssens v.d., 2004).

Mienye ve Sun Gradyan destekli karar aęaları (GBDT) gibi gradyan artırma modelleri, temel ğreniciler olarak karar aęalarını kullanarak saęlam topluluk sınıflandırıcıları retme yetenekleri nedeniyle makine ğreniminde nemli bir ilgi kazadırdılar(Mienye ve Sun, 2022). D.Li Ařırı gradyan artırma (XGBoost), hafif gradyan artırma makinesi (LightGBM) ve kategori gradyan artırma makinesini (CatBoost) ieren bu modeller, dřk nyargılı ve yksek varyanslı senaryoların ele alınmasındaki etkinlikleri nedeniyle eřitli uygulamalarda yaygın olarak kullanılmıřtır(D. Li v.d., 2022).

Rathnayake Gradyan artırma teknięi, tahminlerle ilgili hatanın gradyanına dayalı olarak hedef sonuların tanımlanmasını ierir ve yinelemeli model iyileřtirmelerine izin vermiřtir(Rathnayake v.d., 2023). Muduli ve Ghosh Ulařım arařtırması baęlamında, eęim artırma ve ařırı eęim artırma gibi topluluk teknikleri, řerit bazlı olmayan trafik kořullarında yaya tahmini için bařarıyla uygulanmıř ve 0,95'in zerindeki ROC eęrisi altındaki Alan (AUC) deęerleriyle yksek performans sergilemiřtir.(Muduli ve Ghosh, 2023)

Chen RF makine ğrenmesi modelleri, karar aęalarını rastgele ormanlarda birleřtirerek tahmin doęruluęunu artırma ve ařırı uyumu kontrol etme yeteneklerinden dolayı makine ğreniminde nem kazanmıřtır(Chen v.d., 2021).Byeon Breiman tarafından nerilen bu modeller, nykleme rneklerini kullanarak eřitli karar aęaları reten ve regresyon modellerine veya bireysel karar aęalarına kıyasla daha yksek tahmin doęruluęuna yol aan torbalama algoritmasına dayanmaktadır(Byeon, 2020). G.Li ve Zhang Tıbbi uygulamalar baęlamında, anti-LGI1 ensefalitinin fonksiyonel sonularını tahmin etmek ve inli Han yetiřkinlerinde dislipidemi riskini deęerlendirmek için RF makine ğrenmesi modelleri kullanılmıř olup, bu modellerin saęlık hizmeti ortamlarındaki ok ynllęn ve etkinlięini ortaya koymuřtur.(Zhang v.d., 2019).

Xie NB modelleri, çeşitli alanlardaki sınıflandırma görevlerindeki basitlikleri ve etkinlikleriyle tanınmaktadır. Bu modeller, sınıf etiketi verilen öznitelik bağımsızlığı varsayımı altında çalışır, bu da onların hesaplama verimliliğine ve yorumlanabilirliğine katkıda bulunur(Xie v.d., 2002). Religia ve ark. Hiyerarşik NB sınıflandırıcısı da dahil olmak üzere NB sınıflandırıcıları, basitlikleri ve güçlü performansları nedeniyle gerçek dünya uygulamalarında yaygın olarak kullanılmıştır(Religia, Pranoto ve Suwancita, 2021). Wang ve Li Bilgisayar bilimi alanında NB modelleri, metin sınıflandırmasından yazılım hata tahminine kadar çeşitli bağlamlarda başarıyla uygulanmıştır. Duygu sınıflandırması, spam filtreleme ve yazılım hatası tahmini gibi görevlerde çok yönlülüklerini ve pratikliklerini sergileyerek önemli bir etkinlik göstermişlerdir (Wang ve Li, 2010).Taniguchi basitliklerine ve dayandıkları bağımsızlık varsayımlarına rağmen NB sınıflandırıcılarının çeşitli sınıflandırma senaryolarında sağlam ve doğru olduğunu kanıtlamıştır (Taniguchi v.d., 2015).

Yanuar ve ark. Tarım bağlamında, İnsani Gelişme Endeksi'ni modellemek için ridge regresyonu uygulanmıştır; bu, çoklu bağlantı sorunlarının ele alınmasında ve öngörücü değişkenlerin tutarlı tahminlerinin sağlanmasında faydasını ortaya koymaktadır (Yanuar, Tillah ve Devianto).Kumar Hintli tarım işçilerinin analizinde, çoklu bağlantının varlığında güvenilir tahminler elde etmedeki etkinliğini gösteren ridge regresyonundan yararlanmıştır (Kumar v.d., 2021).

Christodoulou LR modelleri kapsamlı bir şekilde incelenmiş ve çeşitli alanlarda makine öğrenimi ML modelleriyle karşılaştırmıştır. Tarafından yapılan sistematik bir inceleme, klinik tahmin modelleri için ML'nin LR'ye göre önemli bir performans avantajı bulamamıştır(Christodoulou v.d., 2019). Kim LR modelleri, yoğun bakım ünitelerinde deliryum gibi sonuçların tahmin edilmesinde kabul edilebilir ila mükemmel ayırt edici gücü göstermiştir(Kim v.d., 2022). Hong ve ark. LR, acil servislerdeki hastaneye başvuruların tahmin edilmesinde başarıyla kullanılmıştır (Hong, Haimovsich ve Taylor, 2018).Lee LR modelleri ayrıca farklı senaryolarda ML modelleriyle karşılaştırıldı. Renal hücreli karsinomlu hastalarda nefrektomi sonrası akut böbrek hasarını öngörmek için ML modelleri geliştirdiler ve performanslarını LR tabanlı puanlama modelleriyle karşılaştırdılar(Lee v.d., 2021).

Bu tez çalışmasında çözüm üretilen problemlerden biri de video görüntüsünden bir fiziksel hareketin kaç kez tekrarlandığıdır. Hareket sayacı, egzersiz yaparken gerçekleştirilen tekrarların sayısını otomatik olarak takip eden bir sistemdir. Örneğin, squat, şınav, barfiks gibi egzersizlerde her bir tekrarın sayılması, kullanıcıların belirledikleri hedeflere ulaşmalarını kolaylaştırır ve egzersiz programlarının etkinliğini artırır.

Video tabanlı hareket sayacı sistemleri, kamera görüntülerini kullanarak kullanıcıların vücut hareketlerini izler ve bu hareketlerin tekrarlarını tespit eder. Bu tür sistemler, makine öğrenimi ve görüntü işleme teknikleri kullanarak vücut pozisyonlarını ve hareketlerini analiz eder. Diğer yandan, giyilebilir cihazlar ve kullanıcı üzerine yerleştirilen sensörler de hareket sayacı olarak kullanılabilir. Bu cihazlar, kullanıcının hareketlerini algılayarak her bir tekrarın sayılmasını sağlar.

Stenum ve ark. yürüyüş analizi yaptıkları bir çalışmada klinik ve temel araştırmalarda önemli bir yer tutan çalışma gerçekleştirmişlerdir. Geleneksel yöntemler, pahalı ekipmanlar ve uzmanlık gerektiğini ve video tabanlı poz tahminindeki gelişmeler, akıllı telefonlar gibi kolay erişilebilir cihazlar kullanarak yürüyüş analizi yapma potansiyelini ortaya koyduğunu göstermişlerdir. OpenPose kullanılarak video tabanlı yürüyüş analizi ile üç boyutlu hareket yakalama sistemini karşılaştırmışlar hareket sayacı oluşturmuşlardır (Stenum, Rossi ve Roemmich, 2021).

Jaiswal, egzersiz tekniğindeki hataları teşhis edebilen ve gerçek zamanlı olarak düzeltici öneriler sunabilen bir algoritmik sistem geliştirmiştir. Sistem, poz tanıma için MediaPipe kullanarak, yüksek belirginlik tespitiyle tekrarları sayar ve her egzersiz için hareket gelişimini izlemek amacıyla öğrenilebilir bir fizik simülatörü uygulamıştır. Test videosuna istatistiksel öğrenme kullanılarak, prototip öğrenilen hareketten sapmalara dayalı olarak tanı koymuştur. Altı tam ve üst vücut egzersizi üzerinden değerlendirilen bu sistem, düşük maliyetli ekipmanlar aracılığıyla gerçek zamanlı öneriler sunmuştur (Jaiswal, 2023).

Tomar ve ark. OpenCV ve MediaPipe gibi teknolojileri kullanan bir insan hareketi takip cihazı geliştirme işlemini yapmışlardır. Bu cihaz, web kamerası aracılığıyla gerçek zamanlı video akışını kullanarak vücut hareketinin önemli noktalarını algılar sayma işlemi yapar ve takip eder. Omuzlar, dirsekler gibi vücut parçaları arasındaki açılar belirleyerek vücut pozunu izler ve gerektiğinde düzeltme yapabilir. Uygulama, bireyin hareketlerini tespit eder, izler, tanımlar ve bu bilgileri gerçek zamanlı olarak ekranda gösterebilir. Ayrıca, kullanıcının jestlerini tanıyabilir ve video akışının doğru aktarıldığından emin olmak için kamera konumunun uygun şekilde ayarlanması gerektiğininde vurgulamışlardır (Tomar v.d., 2023).

Luangaphirom ve ark. MediaPipe ve OpenCV çerçeveleriyle entegre olan bir web uygulamasını tanıtarak, temel vücut ağırlığı egzersizlerinde doğru duruş ve performans sağlama uygulamasını yapmışlardır. Uygulama, kullanıcının vücudundaki önemli noktaları canlı bir kameradan çıkararak, yedi temel egzersiz duruşuna odaklanmıştır. Kullanıcıların görüş açılarını ayarlamalarıyla poz tahmini işlevleri etkinleştirip algoritma, duruş eşiklerini ve üç kilit nokta

arasındaki açılar kullanarak yanlış duruşları tespit eder, gerçek zamanlı geri bildirim sağlamış ve tekrar sayımlarını izlemişlerdir (Luangaphirom v.d., 2024).

Bu tez çalışmasındaki son aşama, kalori yakımı hesaplama aşamasıdır. Kalori yakımı, enerji harcamasının izlenmesi açısından önemli bir ölçüttür ve çeşitli yöntemlerle hesaplanabilir. Günümüzde teknolojinin ilerlemesiyle birlikte kalori yakımını takip etmek için bir dizi cihaz ve yöntem geliştirilmiştir. Bu cihazlar ve yöntemler, bireylerin günlük aktivitelerini, uyku düzenlerini ve genel sağlık durumlarını izlemelerine olanak tanır.

Kalori yakımı takibinde kullanılan çeşitli yöntemler bulunmaktadır. Akıllı saatler ve bileklikler bu alanda en popüler cihazlardan bazılarıdır. Akıllı telefonlar da kalori yakımı takibinde önemli bir rol oynar. MyFitnessPal, Google Fit ve Samsung Health gibi uygulamalar, kullanıcının günlük aktivitelerini ve besin tüketimini kaydedip analiz eder. Ayrıca, akıllı telefonlarda bulunan ivmeölçer ve jiroskop gibi iç sensörler, adım sayısını ve temel aktiviteleri takip etmeye olanak tanır. Giyilebilir cihazlar da kalori yakımını izlemek için yaygın olarak kullanılır. Kalp atış hızı monitörleri, göğüs veya kol bantları şeklinde olup daha doğru kalp atış hızı verisi sağlar. Global Positioning System (GPS) saatler ise özellikle koşucular ve bisikletçiler tarafından kullanılarak mesafe ve hız gibi bilgileri sağlar. Akıllı teraziler, vücut kompozisyonu analizi yaparak ağırlık, vücut yağı ve kas kütlesi gibi ölçümleri sağlar ve genel sağlık durumunu izler. Polar ve Whoop gibi fitness takip cihazları, kalp atış hızı, uyku düzeni ve günlük aktivite seviyelerini izleyerek detaylı veri sunar. Son olarak, sensörlü giysiler gibi akıllı kıyafetler, spor sırasında kas aktivitesini ve kalori yakımını izleyen yenilikçi bir seçenektir.

Bu cihazlar ve yöntemler, bireylerin kalori yakımını daha bilinçli ve doğru bir şekilde takip etmelerine olanak tanır. MET (Metabolic Equivalent of Task) değeri, bu hesaplamalarda önemli bir rol oynar. MET değeri, belirli bir aktivitenin enerji harcamasını ifade eder ve kişinin dinlenme halindeki enerji harcamasına oranla hesaplanır. 1 MET, kişinin istirahat durumundaki enerji tüketimine eşittir. Örneğin, bir aktivitenin MET değeri 3 ise, bu aktivite kişinin istirahat durumundaki enerji tüketiminin üç katını temsil eder. Bu değerler, akıllı cihazlar ve sensörler aracılığıyla toplanan verilerle birleştirilerek kalori yakımını daha doğru bir şekilde hesaplamaya yardımcı olur. MET değeri, egzersizin türüne, süresine, yoğunluğuna ve kişinin fiziksel durumuna bağlı olarak değişebilir. Egzersiz programları genellikle aktivitelerin MET değerlerini gösterir ve kişinin enerji harcamasını takip etmesine yardımcı olur. Egzersizlerin farklı MET değerleri, farklı yoğunluklara ve enerji harcamalarına sahip olduklarını gösterir.

Batan ve ark. Sabit bisiklet kullanımı sırasında yakılan kalorilerin doğru hesaplanabilmesi için vücut ağırlığının da dikkate alınması gerektiğini öne sürmektedir. İnsan vücudu poz


tahmincisi kullanılarak sabit bisiklete binme aktivitesi tespit edilmiş ve bu verilere kişinin ağırlığı eklenerek yakılan tahmini kalori hesaplanmıştır. Araştırma sonuçları, kişinin ağırlığının sabit bisiklet sürerken yakılan kaloriler üzerinde önemli bir etkisi olduğunu göstermektedir. Özellikle, ağırlığı arttıkça yakılan kalorilerdeki farklılıklar da artmaktadır (Batan v.d., 2023).

Saleem ve ark. Python'da MediaPipe adı verilen bir poz tahmin modülü, insan vücudundaki tüm ana eklemlerin tespit edilmesine yardımcı olmuştur. Daha sonra eklemler arasındaki açıyı hesaplar ve her tekrar için sayacı arttırmışlardır. Poz tahmini, vücudun ana eklemlerinin kesin konumlarını belirlemek için deneğin bir resmini veya videosunu kullanıp bilgisayarlı görüntü teknolojisi ile filmlerdeki insan duruşunu tanımlar ve bitmiş üründe dirsek veya omuz gibi önemli bölgeleri görüntüler sayma işlemi yapıp kalori yakımını hesaplamışlardır v.d., 2023).

Taware ve ark. geliştirilen bir sistem, kullanıcıların egzersizlerini doğru bir şekilde izlemelerini sağlamışlardır ve Mediapipe Poz Tahmin Modeli aracılığıyla vücut hareketlerini takip ederek sistem egzersiz sırasında sesli talimatlar vererek kullanıcıların doğru formda egzersiz yapmalarına yardımcı olmuştur ve bunların kalori hesabını yapmıştır. Bu sistem ayrıca kullanıcıların fiziksel ölçümlerini ve diyet alışkanlıklarını izleyerek, kişiselleştirilmiş kalori alımını önerir. Bu sayede kullanıcılar, formda kalmak ve normal Beden Kitle İndeksine ulaşmak için gerekli beslenme ve egzersiz adımlarını daha etkin bir şekilde takip edebilir hale gelmiştir (Taware v.d., 2022).


Mediapipe gibi araçları kullanarak spor aktivitelerinde kalori harcamasını doğru bir şekilde hesaplamak için sporun türü, aktivitenin yoğunluğu ve bireysel özellikler gibi faktörlerin dikkate alınması çok önemlidir. Loshkarova tarafından yapılan araştırma, yetenekli dayanıklılık sporcularında yoğun antrenman ve yarışma sırasında günlük enerji harcamasının 10.000 kcal'ı aşabileceğini göstererek, sporcuların enerji gereksinimlerini karşılamasını sağlamak için kesin tahminin önemini vurgulanmaktadır (Loshkarova.,2024). Hussein ve ark. tarafından yapılan çalışma, fiziksel ve biyomekanik yetenekleri geliştirmek için antrenmanlarda enerji ihtiyaçlarının dikkate alınmasının önemini vurgulamaktadır. Antrenman programlarının spor aktiviteleri sırasında harcanan enerjiyi hesaba katması gerektiğini öne sürüyor ve antrenman sonuçlarını ve performansı optimize etmek için doğru kalori hesaplamalarının gerekliliğini vurguluyor (Hussein ve Ahmed, 2021). Shwed ve ark. aşırı kalori alımının, sporda ödül olarak sıklıkla kullanılan fast food ve şekerli ikramların mevcudiyeti ile ilişkili olabileceğini belirtmektedir. Bu, sağlıklı alışkanlıkları teşvik etmek ve performansı artırmak için özellikle spor katılımı bağlamında kalori alımını izlemenin ve anlamının önemini vurgulamaktadır (Shwed v.d., 2023).

Video görüntülerinden kalori yakımı çalışmaları incelendiğinde duruş tespiti yöntemlerinin başarılı sonuçlar verdiği görülmektedir. Literatür çalışmaları ışığında bu çalışmada kullanılacak yol haritası ve yöntemler belirlenmiştir. Öncelikle çalışmada kullanılacak egzersiz kategorileri belirlenmiştir. Bu egzersiz kategorileri arasında barfiks, şınav, koşma, bisiklet, squat ve ip atlama bulunmaktadır. Bu kategorilerin tercih nedeni bireysel olarak yaygınca tercih edilen sporlar olması ve veri toplama aşamasında zengin kaynaklara ulaşabilme imkanının olmasıdır. İkinci aşamada veri seti oluşturulmuş ve duruş tespiti algoritması ile anahtar nokta koordinatları çıkarılmış makine öğrenmesi modelleri için veri seti düzenlenmiştir. Bu veri seti ile eğitilen makine öğrenmesi modelleri videodan egzersiz türü sınıflandırmada kullanılmaktadır. Şekil 1’de yapay zeka modelinin geliştirilmesini anlatan sürecin grafiksel özeti verilmektedir. Egzersiz türü belirlendikten sonra yine duruş tespiti algoritması kullanılarak egzersiz türüne göre hareket sayacı yapılmakta ve kalori hesaplama yapılmaktadır. Bu süreci anlatan blok diyagram Şekil 2’de verilmektedir.



Şekil 1. Modelin geliştirilmesi grafiksel özeti.

Bu tez çalışmasının ikinci bölümünde, kullanılan yöntemler ayrıntılı bir şekilde sunulmaktadır. Üçüncü bölümde, veri setinin oluşturulma süreci ve içeriği hakkında kapsamlı bilgiler verilmektedir. Dördüncü bölümde, deneysel çalışmalar ele alınmakta ve uygulanan deneylerin sonuçları detaylı olarak incelenmektedir. Son bölümde ise, elde edilen sonuçlar değerlendirilmekte ve gelecekte yapılacak çalışmalar için öneriler sunulmaktadır.




Şekil 2. Modelin çalıştırılması grafiksel özeti.


İKİNCİ BÖLÜM

2. YÖNTEMLER

Şekil 3’de bu tez çalışmasında kullanılacak olan en iyi video sınıflandırıcı modelin oluşturulma süreci verilmektedir. İlk aşama veri toplama adımıdır. Veri toplama aşamasında açık kaynaklardan 6 adet spor türüne ait 100’er video toplanmıştır. İkinci adımda bu videoların 10’ar tanesi test için ayrılmıştır. Üçüncü adımda eğitim verisindeki videolardan duruş tespitinde kullanılan Mediapipe kütüphanesi kullanılarak anahtar noktaların koordinatları çıkarılıp .csv uzantılı dosyaya kaydedilmiştir. Bu dosyaya etiket sütunu eklenerek video sınıfları girilmiştir. Dördüncü aşamada sınıflandırıcı modellerin eğitiminde bu dosyadaki veriler kullanılmaktadır. NB, KNN, LR, RF, ADA, SVC, DT, GB, RC modelleri makine öğreniminde yaygın olarak kullanılan çeşitli algoritmalarlardır. Her biri farklı yöntemlerle veri analizi yaparak, tahminler veya sınıflandırmalar gerçekleştirir. Son aşamada ise test verisi için ayrılan videolar ile eğitim sonucu oluşan modellerin performansları karşılaştırılmıştır.



Şekil 3. Video sınıflandırıcı model oluşturma süreci.



Şekil 4. Sistemin çalışma şekli.


Şekil 4’de sistemin çalışmasına ait blok diyagram verilmektedir. İlk olarak video girdisinde spor yapan kişinin duruş tespiti algoritması ile anahtar noktaları tespit edilmektedir. Anahtar nokta koordinatları hareket sınıflandırıcı modelin girdisini oluşturmaktadır. Hareket sınıfı belirlendikten sonra anahtar noktalardan elde edilen veriler kullanılarak hareket sayısı hesaplanmaktadır. Burada hareket türüne göre sayma işlemi yapılmaktadır. Örneğin koşma türünde diz açısına bakılırken, barfix türünde dirsek açısına bakılmaktadır. Video boyunca açısal değişimler hesaplanmakta ve hareketli noktalar ortalaması ile elde edilen açısal veri eğrisindeki gürültüler elimine edilmektedir. Daha sonra elde edilen eğrideki tepe noktalar sayılmakta ve hareket sayısı elde edilmektedir. Video süresi ve hareket sayısı arasında kullanılan bağıntı ile hareket yoğunluğu belirlenmektedir. Hareket yoğunluğu MET değeri belirlemede etkili olmaktadır. Bu değer belirlendikten sonra dakikada harcanan kalori hesaplanmaktadır. Tezin bu bölümünde modelin geliştirilmesi ve sistemin çalışmasında kullanılan yöntemler ile ilgili bilgiler verilmektedir.

2.1. Mediapipe

MediaPipe, Google tarafından geliştirilen ve gerçek zamanlı video ve ses işleme uygulamaları için kullanılan açık kaynaklı bir çerçevedir. Görüntü işleme, ses işleme ve makine öğrenimi tekniklerini bir araya getirerek çeşitli uygulamalar geliştirmek için kullanılabilir. MediaPipe özellikle bilgisayarlı görme ve işitsel analiz alanlarında geniş bir kullanım alanına sahiptir. Birçok farklı uygulama için kullanılabilir, bunlar arasında el ve yüz tanıma, insan hareketi takibi, nesne algılama, işaret dili tanıma, duygu tanıma ve daha fazlası yer alır. Bu çerçevenin en önemli özelliklerinden biri, gerçek zamanlı uygulamalarda düşük gecikme süresi sağlamak için optimize edilmiş olmasıdır. Ayrıca, yüksek düzeyde kullanıcı dostu bir arabirime sahiptir, böylece geliştiricilerin hızla uygulamalar oluşturmalarını ve özelleştirmesini sağlar. MediaPipe, endüstriyel uygulamalardan eğlence sektörüne kadar geniş bir yelpazede kullanılabilir. Örneğin, sağlık hizmetlerinde rehabilitasyon uygulamaları, akıllı gözlüklerde artırılmış gerçeklik deneyimleri, oyun endüstrisinde etkileşimli deneyimler gibi alanlarda kullanılabilir.

MediaPipe Landmark Pose Detection ile insan vücudundaki 33 önemli noktanın tespiti yapılabilmektedir. Bu noktalar, insan vücudunun farklı bölgelerini temsil eder ve birlikte çalışarak insan vücudunun dijital bir temsilini oluşturur. Örneğin, omuzlar, dirsekler, bilekler ve parmak uçları gibi üst vücut noktaları, el hareketlerini izlemek ve analiz etmek için değerli sayısal veriler oluşturmaktadır. MediaPipe, bu noktaları tespit etmek için derin öğrenme ve görüntü işleme tekniklerini kullanır. Öncelikle, bir video veya görüntü akışı alınır ve ardından bu görüntülerde insan vücudu tespit edilir. Daha sonra, tespit edilen vücut parçaları incelenir ve her birinin içerdiği noktalar belirlenir. Bu noktalar, genellikle x-y koordinatları olarak temsil edilir ve her biri insan vücudunun belirli bir bölgesini tanımlar.

Şekil 5’de mediapipe kütüphanesi kullanılarak duruş tespiti ile tespit edilen anahtar noktalar gösterilmektedir. Bu şekil insan vücudunun çeşitli bölgelerini ve eklem noktalarını göstermektedir. İnsan vücudunun çeşitli bölgelerini ve eklem noktalarını göstermektedir. Her bölge ve eklem noktası numaralandırılmıştır.




Şekil 5. Mediapipe pose detection (33 Key Points, 2024).

2.2. KNN Makine Öğrenmesi Modeli

KNN, temel bir denetimli öğrenme algoritmasıdır. Bu algoritma, bir veri noktasını sınıflandırmak veya regresyon yapmak için çevresindeki en yakın k veri noktasının etiketlerini veya değerlerini kullanır. Algoritmanın adı, bir veri noktasının sınıflandırılması veya tahmin edilmesinde kullanılan "en yakın komşuların" sayısı olan k'yi ifade eder. Bir veri noktasının sınıflandırılması için, algoritma o veri noktasının en yakın komşularının etiketlerini kullanarak çoğunluk oylaması prensibini uygular. Yani, bir veri noktasının sınıfı, k en yakın komşusunun çoğunluk sınıfıdır. Sınıflandırma problemlerinde, veri noktaları belirli bir kategoriye atanırken,

regresyon problemlerinde, veri noktaları belirli bir değere tahmin edilirken kullanılır. Bu algoritmanın avantajları arasında basitlik, etkili sonuçlar ve eğitim sürecinin olmaması sayılabilir. Ancak, büyük veri kümeleri üzerinde çalışırken hesaplama maliyeti yüksek olabilir ve veri noktalarının etiketleri veya değerleri arasındaki uzaklık ölçümüne duyarlıdır.

Şekil 6’da KNN makine öğrenmesi modeline ait bir görsel verilmektedir. Burada, $k=3$ ve $k=7$ gibi belirli bir k değeri seçildiğinde, yeni örnek, k -en yakın komşularına göre sınıflandırılabilir. Bu durumda, bulunduğu konuma en yakın olan 3 veya 7 komşunun hangi sınıfa ait olduğuna bakarak, yeni örneği sınıflandırabilirsiniz. Bu, veri noktasının sınıfını belirlemek için kullanılan temel mantığı açıklar (Maillo v.ds., 2017).



Şekil 6. KNN makine öğrenmesi modeli.

KNN'nin matematiksel temsili oldukça basittir. Lubis ve ark. veri noktalarını X ile temsil ettiler, bu noktalar p -boyutlu özellik vektörleridir. Her bir veri noktası bir sınıf etiketi Y ile ilişkilendirilir. Bir tahmin yapmak için, yeni bir veri noktası x_q verildiğinde, KNN algoritması, bu noktanın k en yakın komşusunu bulur. Bu yakınlık genellikle öklid mesafesi kullanılarak hesaplanır, ancak başka mesafe metrikleri de kullanılabilirliğini gösterdiler. Eşitlik 2.1 'de iki boyutlu bir uzayda, Öklid mesafesi hesaplanmaktadır (Lubis, v.d., 2020).

$$d(x_i, x_q) = \sqrt{(x_{i1} - x_{q1})^2 + (x_{i2} - x_{q2})^2} \quad (2.1)$$

Eşitlik 2.1 'deki x_i ve x_q sırasıyla bir eğitim veri noktası ve yeni tahmin edilen nokta x_{ij} ve x_{qj} ise belirli özelliklerdir.


- $d(x_i, x_q)$, x_i ve x_q noktaları arasındaki mesafeyi temsil eder.

- x_i, x_q ve x_q her biri n boyutlu vektörlerdir, yani her biri n özellik içerir.
- x_{i1}, x_{iq} birinci boyuttaki özelliklerdir, x_{i2} ve x_{q2} ikinci boyuttaki özelliklerdir ve böylece devam eder.

Bu formül, iki nokta arasındaki mesafeyi hesaplamak için iki noktanın her bir boyutundaki farkın karesini alır, bunları toplar ve son olarak toplamın karekökünü alır. Bu, iki nokta arasındaki öklid mesafesi olarak bilinir. Öklid mesafesi, noktalar arasındaki doğrudan uzaklığı ölçer ve KNN gibi algoritmalar için sıklıkla kullanılır. Daha sonra, bu k en yakın komşunun sınıf etiketleri (veya regresyon durumunda değerleri) kullanılarak, tahmin yapılır. Sınıflandırma durumunda, genellikle çoğunluk sınıf etiketi alınır. Yani, yeni noktanın sınıfı, en yakın k komşunun etiketlerinin en yaygın olanıdır.

2.3. ADA Makine Öğrenmesi Modeli

ADA zayıf öğrencileri bir araya getirerek güçlü bir öğrenci oluşturan bir topluluk öğrenme algoritmasıdır. Temel fikir, zayıf öğrencilerin birbiri ardına eğitilmesi ve her bir öğrencinin öncekinden yapılan hataları düzeltmeye odaklanmasıdır. Her bir öğrenci, daha önce yanlış sınıflandırılan örnekler üzerinde daha fazla ağırlığa sahip olacak şekilde eğitilir. Ardından, her bir öğrencinin performansına göre bir ağırlık atanır ve topluluk, her bir öğrencinin katkısını dikkate alarak son tahminlerini yapar. ADA'nın avantajları arasında, yüksek derecede doğruluk sağlayabilmesi, aşırı uydurmayı azaltabilmesi ve çeşitli sınıflandırıcıları bir araya getirebilmesi sayılabilir. Şekil 7'de ADA makine öğrenmesi modeline ait bir görsel verilmektedir.



Şekil 7. ADA makine öğrenmesi modeli.

Qi ve ark. AdaBoost modeli bağlamında, ağırlıklı oylama yoluyla zayıf sınıflandırıcıların birleştirilmesi, sağlam ve doğru bir sınıflandırma modelin oluşturulmasına olanak tanır (Qi, Zhang and Li, 2013). Matematiksel olarak, ADA algoritması Eşitlik 2.2'deki denklemle temsil edilir:

$$H(x) = \text{sign}(\sum_{t=1}^T h_t a_t(x)) \quad (2.2)$$

$H(x)$, giriş x için tahmin edilen çıktıyı temsil eder.

- $\text{sign}(\cdot)$, içine aldığı değerin işaretini (pozitif, negatif veya sıfır) döndüren bir işlemdir.
- $\sum_{t=1}^T h_t a_t$, tüm zayıf öğrenicilerin (genellikle karar ağaçları gibi) birleşimini ifade

eder. Her bir zayıf öğrenici h_t tarafından yapılan tahminler, belirli bir ağırlık a_t ile çarpılır ve sonuçlar toplanır.


Başlangıçta, eğitim örneklerinin ağırlıkları eşitlenir. Her bir örnek, modelin eğitiminde eşit derecede katkıda bulunur. Her adımda, bir zayıf sınıflandırıcı eğitilir ve hata oranı belirlenir. Bu zayıf sınıflandırıcılar, genellikle karar ağaçları gibi basit modellerdir. Hata oranına dayanarak, bir ağırlık faktörü hesaplanır. Bu faktör, zayıf sınıflandırıcının katkısını belirler. Ağırlık faktörüne göre, eğitim örneklerinin ağırlıkları güncellenir. Yanlış sınıflandırılan örneklerin ağırlıkları artırılırken, doğru sınıflandırılanların ağırlıkları azaltılır. Tüm zayıf sınıflandırıcıların ağırlıklı oyları toplanarak birleştirilmiş güçlü sınıflandırıcı elde edilir. Bu, her bir zayıf sınıflandırıcının tahminlerinin ağırlıklı toplamı ile gerçekleştirilir. Bu şekilde, ADA her adımda önceki adımdaki hatalardan öğrenir ve daha sonra yeni bir zayıf sınıflandırıcı ekleyerek toplam doğruluğu artırır. Bu iteratif süreç, zayıf sınıflandırıcıların bir araya gelerek güçlü bir sınıflandırıcı oluşturmasını sağlar.

2.4. SVC Makine Öğrenmesi Modeli

SVC, sınıflandırma görevleri için önemli bir denetimli makine öğrenimi algoritmasıdır. Özellik uzayında farklı sınıfları en iyi şekilde ayıran hiperdüzlemi bulmak suretiyle çalışır. SVC, çok modlu makine öğrenimi hatları oluşturmaya yönelik bir çerçeve olan Mediapipe kitaplığı içinde de önemli bir rol oynar. Örneğin, hareket tanıma, nesne algılama ve yüz tanıma gibi görevlerde kullanılabilir. SVC'yi Mediapipe çerçevesinde kullanırken, verilerin uygun şekilde ön işlenmesi son derece önemlidir. Bu, giriş verilerinden ilgili özelliklerin çıkarılmasını, özelliklerin normalleştirilmesini veya ölçeklendirilmesini ve verilerin eğitim ve test setlerine bölünmesini içerebilir. SVC makine öğrenmesi modeli daha sonra, eğitim verileri üzerinde farklı sınıfları en iyi şekilde ayırmak için hiperdüzlemi optimize eden uyum yöntemini kullanarak eğitilebilir. Eğitildikten sonra, SVC makine öğrenmesi modeli yeni veriler üzerinde

tahminlerde bulunmak için tahmin yöntemini kullanabilir. Modelin performansı, doğruluk, kesinlik, geri çağırma ve F1 puanı gibi metrikler kullanılarak değerlendirilebilir.

Şekil 8’de SVC makine öğrenmesi modeline ait bir şekil verilmektedir. X Eksen, veri noktalarının giriş özelliklerini veya verilerini temsil ederken, Y Eksen çıkışı veya hedef değişkeni temsil eder. Bu, modelin öğrenme sürecinde kullanılan temel giriş ve çıkış değişkenlerini gösterir. Destek vektörleri, karar sınırına en yakın olan veri noktalarıdır. Bu noktalar, marjın ve karar sınırının tanımlanmasında kritik öneme sahiptir. Destek vektörleri, modelin öğrenme sürecinde kullanılan temel noktalardır ve karar sınırının belirlenmesinde büyük rol oynarlar. Vektör veya hiperdüzlem sınıfları ayıran çizgidir. Optimal hiperdüzlem, sınıflar arasındaki marjı maksimuma çıkarandır. Bu, modelin sınıfları ayıran doğruyu belirlemek için temel yapı taşı oluşturur. Kenar boşluğu karar sınırı ile destek vektörleri arasındaki mesafedir. SVC makine öğrenmesi modeli bu marjı maksimuma çıkaran hiperdüzlemi bulmayı amaçlamaktadır. Bu marj, sınıflar arasındaki ayrımı optimize etmek ve modelin genelleme yeteneğini artırmak için kullanılır. İki sınıf (A Sınıfı ve B Sınıfı), karar sınırının her iki tarafındaki veri noktalarıyla temsil edilir. Bu, modelin öğrenme sürecinde işlenen ve sınıflandırılmaya çalışılan veri noktalarını gösterir.



Şekil 8. SVC makine öğrenmesi modeli.

SVC'nin matematiksel denklemi, bir veri noktasının sınıfını belirlemek için destek vektörlerinin ağırlıklı toplamını ve bir eşik değerini kullanır. Eğitim süreci, destek vektörlerinin

belirlenmesi ve bu ağırlıkların ve eşik değerinin öğrenilmesiyle gerçekleşir. Bu denklem, veri noktalarını sınıflandırmak için kullanılan temel yapı taşlarını açıklar ve modelin sınıflandırma yeteneğini temsil eder. Brereton ve Lloyd SVC'nin, çekirdek fonksiyonu tarafından tanımlanan özellik uzayındaki farklı sınıfları en iyi şekilde ayıran hiper düzlemi bularak örnekleri sınıflandırmasına olanak tanıdılar (Brereton ve Lloyd, 2010). Matematiksel olarak, SVC algoritması Eşitlik 2.3'deki denklemle temsil edilir:

$$H(x) = \text{sign}(\sum_{i=1}^N y_i a_i K(x, x_i) + b) \quad (2.3)$$


$f(x)$, giriş özelliklerini x olan bir veri noktasının sınıflandırma tahminini ifade eder. N , eğitim veri setindeki örneklerin toplam sayısını temsil eder. a_i , destek vektörlerinin sınıflandırma işlemindeki ağırlıklarını gösterir. y_i , i indeksine sahip veri noktasının sınıf etiketini temsil eder. $K(x, x_i)$, çekirdek fonksiyonudur ve x ve x_i arasındaki benzerliği ölçer. Doğru çekirdek fonksiyonu seçimi, modelin performansını önemli ölçüde etkiler. b , karar sınırının konumunu ve veri noktalarının sınıflandırılmasında kullanılan eşik değerini temsil eder. SVC'nin matematiksel denklemi, bir veri noktasının sınıfını belirlemek için destek vektörlerinin ağırlıklı toplamını ve bir eşik değerini kullanır. Eğitim süreci, destek vektörlerinin belirlenmesi ve bu ağırlıkların ve eşik değerinin öğrenilmesiyle gerçekleşir. Bu denklem, veri noktalarını sınıflandırmak için kullanılan temel yapı taşlarını açıklar ve modelin sınıflandırma yeteneğini temsil eder.

2.5. DT Makine Öğrenmesi Modeli

DT sınıflandırma ve regresyon problemleri için kullanılan bir makine öğrenimi algoritmasıdır. Bu algoritma, veri noktalarını bir dizi karar kuralı ve özelliklerin değerlerine göre sınıflandıran veya tahmin eden bir ağaç yapısı oluşturur. Karar ağaçları, bir veri kümesini rekürsif olarak bölerek en homojen alt kümeleri elde etmeye çalışır. Her bölünme, veri kümesini en iyi şekilde bölmek için seçilen bir özellik ve bu özelliğin belirli bir değeri arasında yapılır. Böylece, ağaç, bir veri noktasının sınıfını veya değerini tahmin etmek için kullanılan bir dizi karar kuralını temsil eder. Karar ağaçlarının avantajları arasında yüksek yorumlanabilirlik, doğrusal olmayan ilişkileri modelleme yeteneği ve kayıp verilerle başa çıkma yeteneği sayılabilir. Ancak, aşırı uyumluluğa eğilimli olabilirler ve veri dengesizliği durumlarında yanlı olabilirler.

Bir karar ağacı, kök düğüm, karar düğümleri ve yaprak düğümleri olmak üzere üç temel bileşenden oluşur. Kök düğüm, ağaçtaki tüm veri kümesini temsil eden en üstteki düğümdür. Karar düğümleri, verileri belirli koşullara veya özelliklere dayalı olarak alt kümelere bölmek

için kullanılır. Yaprak düğümleri ise belirli bir giriş için tahmin edilen sınıfı veya değeri temsil eder. Karar ağacı modeli'nin akışı şu şekilde çalışır: Kök düğüm, belirli bir özellik veya koşula dayanarak iki veya daha fazla alt kümeye bölünür. Her alt küme, sonraki karar düğümlerine bağlı olarak daha küçük alt kümeler halinde bölünür. Bu süreç, tahmin edilen sınıf veya değeri sağlayan bir yaprak düğüme ulaşılan kadar devam eder. Bu şekilde, karar ağacı verileri hiyerarşik bir yapıda sınıflandırır veya regresyon yapar, böylece her bir veri örneği bir yaprak düğümünde sonlandırılır ve tahmin edilen sonuç elde edilir. Şekil 9'da DT makine öğrenmesi modeline ait bir görsel verilmektedir.



Şekil 9. DT makine öğrenmesi modeli.


Sadiq ve Abdulazeez karar ağacı modelleri, kararların veya özelliklerle ilgili testlerin her düğümde yapıldığı, farklı dallara ve nihayetinde yaprak düğümlerinde bir karara veya sonuca yol açan hiyerarşik ağaç yapıları olduğunu göstermiştir.(Sadiq ve Abdulazeez, 2024). Matematiksel olarak, DT algoritması Eşitlik 2.4'deki denklemlerle temsil edilir:

$$f(x) = \sum_{m=1}^M c_m \cdot I(x \in R_m) \quad (2.4)$$

Karar ağacı modeli, giriş özelliklerini x olan bir veri noktasının tahminini temsil eden $f(x)$ fonksiyonuyla ifade edilir. Bu fonksiyon, ağacın yaprak düğümlerindeki tahminlerin bir kombinasyonunu kullanır. Her bir yaprak düğümü, belirli bir veri noktasının girdi özelliklerine göre tahmin edilen değeri veya sınıfı temsil eden c_m tahmini sağlar. Ağaçtaki toplam yaprak düğümlerinin sayısı M ile temsil edilir. Her bir veri noktası, ağacın dallarını takip ederek belirli bir yaprak düğüme atanır. Atama süreci, veri noktasının özelliklerine göre karar düğümlerini takip ederek gerçekleştirilir. Her bir yaprak düğümünde o düğüme ait olan c_m tahmini alır ve bu veri noktasının tahmini sonucunu oluşturur.

2.6. GB Makine Öğrenmesi Modeli

GB, sınıflandırma ve regresyon problemleri için kullanılan güçlü bir makine öğrenimi tekniğidir. GB, birçok zayıf öğrencinin bir araya gelerek güçlü bir öğrenci oluşturulmasına dayanır. Temel fikir ardışık olarak zayıf öğrencilerin eğitilmesi ve her birinin önceki öğrencinin hatalarını düzeltmeye odaklanmasıdır. Her bir öğrenci, daha önce yanlış sınıflandırılan örnekler üzerinde daha fazla vurguya sahip olacak şekilde eğitilir. Ardından, her bir öğrencinin tahminlerine göre bir ağırlık atanır ve topluluk, bu ağırlıklı tahminlerin birleşimiyle nihai tahminini yapar. GB'nin avantajları arasında yüksek tahmin doğruluğu, aşırı uyumluluğa karşı direnç ve farklı veri yapılarıyla iyi çalışabilme yeteneği sayılabilir. Ancak, modelin karmaşıklığını artırma eğiliminde olduğu için, doğru hiperparametre ayarlaması önemlidir. Şekil 10'da GB makine öğrenmesi modeline ait bir görsel verilmektedir.



Şekil 10. GB makine öğrenmesi modeli.

GB zayıf öğrencileri bir araya getirerek güçlü bir öğrenci oluşturan bir toplu öğrenme tekniğidir. Bu model, ardışık olarak oluşturulan zayıf öğrencileri kullanarak tahminler yapar ve bunları bir araya getirerek güçlü bir tahminci elde eder.

GB sayısı arttıkça kaybı en aza indirmek için bir gradyan iniş algoritmasının kullanıldığı özel bir artırma türüdür (Gao and Lantz, 2022). Matematiksel olarak, GB algoritması Eşitlik 2.5'teki denklemle temsil edilir:

$$f(x) = \sum_{m=1}^M y_m h_m(x) \quad (2.5)$$

$F(x)$, giriş özelliklerini x olan bir veri noktasının tahminini ifade eder. M , toplam ağaç sayısını temsil eder. y_m , m indeksine sahip ağacın katkısını temsil eden bir ölçüdür. $h_m(x)$, m indeksine sahip ağacın tahminini ifade eder. GB, ardışık olarak zayıf öğrencileri birleştirerek güçlü bir tahminci oluşturur. Her bir ağaç, önceki ağaçların tahmin hatalarını düzeltmek için


eğitilir. Bu nedenle, her bir ağaç, önceki ağaçların bıraktığı hataları telafi etmeye çalışır. Sonuç olarak, Gradient Boosting modeli, veri setindeki karmaşık ilişkileri öğrenmek için etkili bir yöntemdir. GB matematiksel denklemi, giriş özelliklerini kullanarak bir veri noktasının tahminini yaparken her bir ağacın katkısını temsil eder. Bu katkılar, her bir ağacın tahminlerinin bir araya getirilmesiyle elde edilir. Bu şekilde, GB makine öğrenmesi modeli zayıf öğrencilerin bir araya getirilmesiyle güçlü bir tahminci oluşturarak karmaşık problemleri etkili bir şekilde çözebilir.

2.7. RF Makine Öğrenmesi Modeli

RF sınıflandırma ve regresyon problemleri için kullanılan güçlü bir makine öğrenimi algoritmasıdır. Rastgele ormanlar, birden çok karar ağacını bir araya getirerek bir model oluşturur ve bu sayede yüksek doğruluk ve genelleme yeteneği sağlar. Bu algoritma, her bir ağacın veri kümesinin rastgele alt örneklemini alarak ve her düğümde en iyi bölünmeyi seçerek çalışır. Bu işlem, her ağacın birbirinden farklı bir şekilde eğitilmesini sağlar, böylece varyansı azaltır ve aşırı uyumu önler. RF özellikle büyük özellik kümesi ve yüksek boyutlu veri setleriyle iyi çalışır. Ayrıca, eksik verilerle iyi başa çıkabilir ve tahminlerdeki önemli özellikleri belirlemek için kullanılabilir. Bu algoritmanın avantajları arasında yüksek performans, doğruluk, tolerans ve kullanım kolaylığı yer alırken, dezavantajları arasında modelin iç yapısının anlaşılması ve yorumlanması zor olabilir. Bununla birlikte, genel olarak, rastgele ormanlar, birçok uygulama alanında etkili bir şekilde kullanılan önemli bir makine öğrenimi aracıdır. RF, birden fazla karar ağacını bir araya getirerek daha doğru ve istikrarlı tahminler elde etmeyi sağlayan güçlü bir makine öğrenme algoritmasıdır. Bu algoritma, her biri rastgele seçilen özellik alt kümeleri ve eğitim örnekleri üzerinde eğitilen bir dizi karar ağacını içerir. Her ağacın tahminleri daha sonra birleştirilerek nihai tahmin oluşturulur. Şekil 11’de RF makine öğrenmesi modeline ait bir görsel verilmektedir. Şekil 11, bir makine öğrenimi veya topluluk yöntemlerini içeren bir süreci gösteren bir diyagram veya akış şeması gibi görünmektedir. Bu süreçte üç ana sonuç, yani Sonuç 1, Sonuç 2 ve Sonuç 3 bulunmaktadır ve ayrıca yeni bir örnek girişi de yer almaktadır. Süreç, iki topluluk yöntemini içermektedir;

Çoğunluk oyu / Ortalama: Bu yöntem, Sonuç 1 ve Sonuç 2’yi girdi olarak alır ve bir çıktı üretir. Rastgele Orman Tahmini: Bu yöntem aynı zamanda yeni örneği girdi olarak alır ve bir çıktı üretir; bu çıktı daha sonra Sonuç 3’ü üretmek için çoğunluk oylama/ortalama yönteminin çıktısıyla birleştirilir. Diyagram, birden fazla modelden elde edilen çıktıların (Sonuç 1 ve Sonuç 2), daha doğru veya sağlam bir sonuç (Sonuç 3) üretmek için topluluk yöntemleri kullanılarak birleştirildiğini göstermektedir. Bu süreç, topluluk yöntemlerinin, farklı modellerden elde

edilen tahminleri entegre ederek daha güvenilir sonuçlar elde etmede nasıl kullanılabileceğini açıkça göstermektedir.



Şekil 11. RF makine öğrenmesi modeli.

Rebela RF eğitim sırasında birden fazla karar ağacı oluşturan ve regresyon görevleri için bireysel ağaçların ortalama tahminini çıktı olarak veren bir topluluk öğrenme yöntemini saptadılar (Rebala v.d., 2019). Matematiksel olarak, RF algoritması Eşitlik 2.6'deki denklemle temsil edilir:

$$f(x) = \frac{1}{N} \sum_{i=1}^N T_i(x) \quad (2.6)$$

RF algoritması, bir veri noktasının tahminini ifade eden $F(x)$ fonksiyonu üzerinden çalışır. Burada x , giriş özelliklerini temsil eder. N , toplam ağaç sayısını ifade ederken, $T_i(x)$ ise i indeksine sahip bir ağacın tahminini ifade eder.

Algoritmanın işleyişi, her bir karar ağacının tahminlerinin toplanması ve bunların ortalamasının alınması veya çoğunluk oyu yöntemiyle nihai tahminin oluşturulması üzerine kuruludur. Bu yöntem, birden fazla ağacın tahminlerinin birleştirilmesiyle daha güçlü ve istikrarlı bir tahmin modeli elde edilmesini sağlar.


2.8. RC Makine Öğrenmesi Modeli

RC lineer regresyonun bir türüdür ve regresyon analizinde yaygın olarak kullanılan bir yöntemdir. Temel amacı, bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi modellemek ve bu ilişkiyi kullanarak bağımlı değişkenin değerini tahmin etmektir. Lineer regresyonun geliştirilmiş bir versiyonudur ve aşırı uyumlu modelleri azaltmak için kullanılır. Bu yöntem, geleneksel lineer regresyonun aksine, model parametrelerini sıfıra yakın tutarak regresyon katsayılarının büyüklüğünü sınırlar. L2 düzenleme yöntemi kullanarak regresyon

katsayılarını küçültür. Bu, modelin karmaşıklığını azaltırken, aynı zamanda varyansı artırarak aşırı uyumu önler.

RC'nin avantajları arasında basitlik, yüksek hız bağımsız değişkenlerin varlığında stabilite yer alır. Dezavantajları arasında ise, regresyon katsayılarının yorumlanması zor olabilir. Sonuç olarak, RC, regresyon analizinde yaygın olarak kullanılan etkili bir yöntemdir ve özellikle çoklu korelasyon problemi olduğunda ve aşırı uyumu önlemek istendiğinde tercih edilir.

Şekil 12’de solda bulunan grafikte kırmızı noktaların öğrenim verileri olduğunu varsayalım. EKK (En Küçük Katsayı) ile model fit edildiğinde en düşük hata kareleri toplamı en az olacak şekilde kırmızı çizgi ile gösterilen model kurulacaktır. Ancak test verilerini göz önüne alındığında EKK’nın aşırı öğrenme yaptığını ve test verilerinde yüksek varyanslı tahminler yaptığı görülmektedir. RC ‘nin buradaki amacı yeni bir doğru bulmaktır. Yani yeni doğruya yanlılık ekleyerek model yeniden fit edilir. Bu durumda model yanlı ama düşük varyanslı hale gelmektedir. Bu durum “doğrunun açısını değiştirerek “weight” değişkeninin hassasiyetinin azaltılması” olarak da yorumlanabilir.



Şekil 12. RC makine öğrenmesi modeli.

RC doğrusal regresyon modellerinin bir türüdür ve regresyon katsayılarını sıfıra yakın hale getirerek aşırı öğrenmeyi azaltmayı amaçlar. Gijbels ve ark. P-splines kullanarak değişken seçim hesaplamalı istatistikler yayınladı (Gijbels, Verhasselt ve Vrinssen, 2015). Matematiksel olarak, RC’nin temel denklemi Eşitlik 2.7’deki denklemle temsil edilir:

$$\beta^{ridge} = \arg_{\beta} \min \left\{ \sum_{i=1}^N (y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j)^2 + \lambda \sum_{j=1}^p \beta_j^2 \right\} \quad (2.7)$$


RC, doğrusal regresyonun bir türüdür ve regresyon katsayılarını sıfıra yakın hale getirerek aşırı öğrenmeyi azaltmayı amaçlar. Bu yöntemde, tahmin edilen regresyon katsayıları β^{ridge} olarak ifade edilir. y_i ve x_i ise sırasıyla i-inci gözlem için hedef değişken ve j-inci özellik değerini temsil eder. Regresyon katsayıları β_0 ve β_j şeklinde gösterilir; bunlar sırasıyla kesme terimi ve özelliklerin regresyon katsayılarıdır. N veri setindeki gözlem sayısını, p ise özellik

sayısını ifade ederken, λ ise Ridge Regresyonu'nun düzenleme parametresidir ve regresyon katsayılarının büyüklüğünü kontrol eder.

2.9. NB Makine Öğrenmesi Modeli

NB sınıflandırma problemleri için kullanılan bir makine öğrenimi modelidir. Temel olarak, Bayes teoremi ve "naive" (saf, basit) varsayımı üzerine kurulmuştur. NB, bir belgenin veya veri noktasının hangi kategoriye veya sınıfa ait olduğunu tahmin etmek için kullanılır. Bu modelin çalışma prensibi, bir belgenin veya veri noktasının özelliklerini kullanarak her sınıf için olasılıkları hesaplamaktır. Daha sonra, en yüksek olasılığa sahip sınıfı seçerek belgenin veya veri noktasının sınıflandırılması gerçekleştirilir.

NB sınıflandırıcısı, karmaşık modeller oluşturmadan doğru tahminler yapabilmesi ve hızlı çalışması nedeniyle çeşitli uygulamalarda tercih edilir. Şekil 13'de NB makine öğrenmesi modeline ait bir görsel verilmektedir.



Şekil 13. NB makine öğrenmesi modeli.

NB sınıflandırıcısı, Bayes teoremini temel alarak bir örneğin özellikleri göz önüne alındığında bir sınıfın olasılığını hesaplamak için kullanılır. Temel olarak, bir örneğin sınıfını belirlemek için özelliklerin birleşik olasılığını kullanır. Andrian kullanıcı görevinde açıklanan NB makine öğrenmesi modeliyle uyumlu olarak Gauss NB, Multinomial NB ve Bernoulli NB'i içeren üç NB varyasyonunun uygulanmasını araştırmaktadır (Andrian v.d., 2023). Matematiksel olarak, NB algoritması Eşitlik 2.8'deki denklemlerle temsil edilir:


$$P(c_k | x_1, x_2, \dots, x_n) = P(x_1, x_2, \dots, x_n | c_k) \cdot P(c_k) / P(x_1, x_2, \dots, x_n) \quad (2.8)$$

NB sınıflandırıcısı, bir örneğin özelliklerine göre bir sınıfın olasılığını hesaplayarak sınıflandırma yapar. Bu sınıflandırıcı, Bayes teoreminin temel prensibine dayanır ve sınıflandırma işlemi için bir olasılık tabanlı yaklaşım kullanır. Formülde verilen ifadelerin açıklamalarına baktığımızda, $P(c_k | x_1, x_2, \dots, x_n)$ özellikler $(x_1, x_2, \dots, x_n)$ verildiğinde sınıf c_k

olasılığını ifade eder. $P(x_1, x_2, \dots, x_n | c_k)$ sınıf c_k altında özelliklerin birleşik olasılığını, $P(c_k)$ sınıf c_k olasılığını ve $P(x_1, x_2, \dots, x_n)$ ise özelliklerin birleşik olasılığını ifade eder. NB sınıflandırıcısı, bu denklemleri kullanarak veri setindeki örneklerin ve özelliklerin belirli bir sınıfa ait olma olasılığını hesaplar. Ardından, her sınıfın olasılığını karşılaştırarak en yüksek olasılığa sahip sınıfı tahmin eder.

2.10. LR Makine Öğrenmesi Modeli

LR girdi özelliklerinin bir lineer kombinasyonunu alır ve bu kombinasyonu bir sigmoid fonksiyonuna geçirerek bir çıktı üretir. Bu çıktı, 0 ile 1 arasında bir olasılık değeri olarak yorumlanabilir ve genellikle bir eşik değeri belirlenerek sınıflandırma yapılır. Bu model, sınıflandırma problemi için kullanılan birçok algoritmadan biridir. Özellikle iki sınıflı sınıflandırma problemlerinde etkilidir, ancak çoklu sınıflı sınıflandırma problemlerine de genişletilebilir. LR'nin avantajları arasında basitlik, yorumlanabilirlik, hızlı eğitim ve tahmin süreçleri, düşük bellek gereksinimi ve iyi performans yer alır. Ancak, bu model doğrusal ilişkileri varsayar, bu da bazı veri setlerinde karmaşık ilişkileri yeterince yakalayamayabileceği anlamına gelir. Sonuç olarak, LR, sınıflandırma problemlerinin çözümünde kullanılan etkili ve yaygın bir makine öğrenimi modelidir. Basitliği ve yorumlanabilirliği nedeniyle birçok uygulama alanında tercih edilir. Şekil 14'de LR makine öğrenmesi modeline ait bir görsel verilmektedir.



Şekil 14. LR makine öğrenmesi modeli.

LR bir bağımlı değişkenin, bir veya daha fazla bağımsız değişken tarafından lineer bir kombinasyonu ile açıklanmaya çalışıldığı istatistiksel bir modeldir. Bu model, genellikle en küçük kareler yöntemiyle tahmin edilir. Boateng ve ark. kullanıcı görevinde açıklanan LR uyumlu olan, tıbbi araştırmalardaki uygulamasını vurgulayan lojistik regresyon modeline odaklanmaktadır (Boateng, Abaye v.d., 2019). Matematiksel olarak, RC algoritması Eşitlik 2.9'daki denklemlerle temsil edilir:

$$y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_X X_n + \epsilon \quad (2.9)$$

y: Tahmin edilen bağımlı değişken (output veya hedef değişken).

Q_0 : Modelin sabiti (intercept). Bu değer, tüm bağımsız değişkenler sıfır olduğunda y'nin alacağı değeri temsil eder.

Q_1, Q_2, Q_X : Bağımsız değişkenlerin katsayıları (coefficients). Her bir bağımsız değişkenin ($X_1, X_2, \dots, X_n$) y üzerindeki etkisini ölçer. Bu katsayılar modelin parametreleridir ve veriye dayalı olarak tahmin edilir.

$X_1, X_2, \dots, X_n$: Bağımsız değişkenler (predictors). Bunlar y'yi tahmin etmek için kullanılan değişkenlerdir.

ϵ : Hata terimi (error term). Modelin mükemmel olmaması nedeniyle tahmin edilen y ile gerçek y arasındaki farkı temsil eder.

Doğrusal regresyon modeli, veri setindeki gözlemler arasındaki ilişkiyi özetler. Regresyon katsayıları, bağımsız değişkenlerin bağımlı değişken üzerindeki etkisini temsil eder. Model, bu ilişkiyi kullanarak bağımlı değişkenin tahminlerini yapar. Bu tahminler, modelin öğrenilmiş katsayıları ve yeni bir gözlemdeki bağımsız değişken değerleri kullanılarak hesaplanır.

2.11. Performans Metrikleri

Bu tez çalışmasında, performans değerlendirmesi için ayrılan test verisi, eğitim sonucunda elde edilen modeller üzerinde test edilmiştir. Bu süreçte, modellerin performansını değerlendirmek için karmaşıklık matrisleri oluşturulmuştur. Karmaşıklık matrisi, bir sınıflandırma modelinin tahmin ettiği ve gerçek sınıfların sayısını gösteren ve modelin doğruluğunu değerlendirmeye yarayan önemli bir araçtır.

Karmaşıklık matrisleri, modelin tahmin ettiği ve gerçek sınıfları içeren bir tablo şeklinde sunulur. Bu tablo, modelin ne kadar doğru sınıflandırma yapabildiğini görmemizi sağlar. Karmaşıklık matrisinden hareketle, model performansını değerlendirmek için doğruluk, hassasiyet, kesinlik, geri çağırma ve F1 skoru gibi çeşitli performans metrikleri hesaplanabilir. Her bir metrik, modelin farklı bir yönünü değerlendirir ve genel performansı anlamamıza yardımcı olur. Bu metriklerin her biri modelin farklı bir yönünü değerlendirir ve modelin ne kadar iyi performans gösterdiğini anlamamıza yardımcı olur. Bu değerlerin hesaplanmasında TP, TN, FP ve FN değerleri kullanılmaktadır. Bu çalışmada, modelin doğru ve yanlış tahminlerini değerlendirmek için kullanılan dört temel metriği tanımlayacağız. TP (True

Positive), gerçekte MS olan ve model tarafından da MS olarak tahmin edilen seslerin sayısını ifade eder. TN (True Negative), gerçekte MS olmayan ve model tarafından da MS olarak tahmin edilmeyen seslerin sayısını belirtir. FP (False Positive), gerçekte MS olmayan fakat model tarafından MS olarak tahmin edilen seslerin sayısını gösterir. FN (False Negative) ise gerçekte MS olan fakat model tarafından MS olarak tahmin edilmeyen seslerin sayısını ifade eder. Bu metrikler, modelin performansını ve doğruluğunu ölçmek için kritik öneme sahiptir.

Denklem 2.10'da verildiği gibi pozitif olarak tahmin ettiği örnekler arasından pozitif örnekleri belirler. Gerçek pozitif olarak da bilinen hatırlama oranı veya duyarlılık, Denklem 2.11'de tanımlandığı gibi modelin tüm olumlu örnekleri doğru şekilde tanımlama yeteneğini değerlendirir. F1 skoru, kesinlik ve hatırlamanın uyumlu bir ortalaması olarak, kesinlik ve hatırlama arasında bir denge kurarak kullanıcılar için değerli olduğunu kanıtlar. Denklem 2.12'ye göre dengesiz veri kümeleri hesaplanır. Modelin tahminlerinin doğruluğu, derin öğrenmeye dayalı sınıflandırma sisteminin blok diyagramı Şekil 3'te verilmiştir.

$$P = \frac{TP}{TP+FP} \quad (2.10)$$

$$R = \frac{TP}{TP+FN} \quad (2.11)$$

$$F1 \text{ Score} = 2 \cdot \frac{P \cdot R}{P+R} \quad (2.12)$$


2.12. Açı Hesaplama

Açı hesaplama, landmark pose detection sürecinin önemli bir parçasıdır ve bu çalışmada insan vücudu veya nesnelerin hareketini analiz etmek için kullanılır. Bu süreç, başlangıçta görüntü veya videodaki belirli noktaların (landmarkların) tespit edilmesiyle başlar. Bu noktalar genellikle omuzlar, dirsekler, bilekler, kalça, dizler, ayak bilekleri gibi insan vücudu için önemli bölgeleri temsil eder. Ardından, her bir landmark noktası için x ve y koordinatları belirlenir ve bazen derin öğrenme modelleri kullanılarak bu koordinatlar hassas bir şekilde tahmin edilir. Bu tez çalışmasında squat, barfiks, bisiklet, koşma, şınav ve ip atlama egzersiz türlerinde odaklanılan açısal değerler sırasıyla sağ diz, sağ dirsek, sol diz, sol bel, sol dirsek ve sol diz açılarıdır. Şekil 5'te gösterilen landmark değerlerinden hangilerinin açı hesaplamasında kullanıldığı Tablo 1'de verilmektedir.

Tablo 1. Açı hesaplamada kullanılan anahtar noktalar.


Açı Hesaplama	Açı Değeri	Landmark
Squat	Sağ Diz	23,25,27
Barfiks	Sağ dirsek	11,13,15
Bisiklet	Sol Diz	24,26,28
Koşma	Sol Bel	12,24,26
Şınav	Sol Dirsek	12,14,16
İp atlama	Sol diz	24,26,28

Şekil 15’te d1 ve d2 doğruları verilmektedir. Bu iki doğrunun eğimleri sırası ile m1 ve m2 değerleridir. Kesişim noktasındaki açı ise α değeridir. Eşitlik 2.14’de kesişim noktasındaki açının tanjant değerinin hesaplama formülü verilmektedir. Tanjant değeri bulunan açının değeri Eşitlik 2.15’de verildiği üzere arctan değeri bulunarak hesaplanmaktadır. Verilen 3 noktadan ortadaki noktanın açısını hesaplamak için açı hesaplama fonksiyonu yazılmıştır. Şekil 16’da kesişen iki doğru arasındaki açı verilmektedir.



Şekil 15. Doğrunun eğimi.

$$m = \tan a = \frac{y_2 - y_1}{x_2 - x_1} \quad (2.13)$$



Şekil 16. Kesişen iki doğru arasındaki açı.

$$\tan a = \frac{m_2 - m_1}{1 + m_1 \cdot m_2} \quad (2.14)$$


$$a = \arctan(\tan(a)) \quad (2.15)$$

2.13. Hareketli Noktalar Filtresi


Açısal değişimdeki gürültüleri azaltmak amacıyla kullanılan hareketli noktalar yöntemi, sinyal işlemede yaygın olarak başvurulmuş bir yumuşatma filtresidir. Bu yöntem, zaman domeninde örneklendirilmiş sinyallerin gürültülerden arındırılmasında etkili bir rol oynamaktadır. Temel prensibi, sürekli giriş değerlerinin ortalamasını alarak sinyali yumuşatmaktır. Eşitlik 2.16'da n örnek için filtreleme denklemi verilmiştir. Bu denkleme göre, $q(m)$ filtrelenmiş değeri ifade ederken, m ortalamaya dahil edilecek örnek sayısını, d örnek değerini ve n ise toplam örnek sayısını temsil etmektedir. Bu şekilde, hareketli ortalama yöntemi, sinyallerin gürültüden arındırılmasında önemli bir araç olarak kullanılmaktadır ve böylece daha pürüzsüz ve güvenilir veriler elde edilmektedir.

$$q(m) = \frac{d(m) + d(m-1) + d(m-2) + \dots + d(m-n+1)}{n} \quad (2.16)$$

Şekil 17'de barfiks kaydından alınmış açısal değişim değerleri ve Şekil 18'de ise hareketli noktalar filtresinden geçirildikten sonraki açı eğrisi verilmektedir.



Şekil 17. Barfiks kaydından alınmış açısal değişim.



Şekil 18. Filtre uygulanmış kayıt örneği.

2.14. Sinyalde Tepe Sayma

Filtreleme işleminden sonra elde edilen sinyaldeki tepe noktalarını saymak için "scipy" kütüphanesindeki "find_peaks" fonksiyonu kullanılmıştır. Bu fonksiyon, 1 boyutlu bir dizi olarak, komşu değerlerin basit bir karşılaştırması yoluyla tüm yerel maksimumları tespit eder. Elde edilen sonuç hareket sayısını belirlemektedir.

2.15. Kalori Hesaplama

Aktivite sırasında harcanan kalori miktarını hesaplamak için Eşitlik 2.17'deki denklemle temsil edilir:

$$Kalori = \frac{(Video\ Süresi)(MET)(Kilo)}{200} \quad (2.17)$$

Burada:

- Kalori: Harcanan kalori miktarı
- Video Süresi: Aktivitenin yapıldığı süre (saniye cinsinden)
- MET: Metabolik Eşdeğer (aktivitenin türüne ve yoğunluğuna bağlı olarak değişen birim)
- Kilo: Vücut ağırlığı (kg cinsinden)

Bu denklem, aktivitenizin süresi, yoğunluğu ve vücut ağırlığınızı dikkate alarak tahmini kalori harcamanızı hesaplar. MET değeri, aktivitenin ne kadar yoğun olduğunu belirler ve standart bir referans ölçü birimidir.

ÜÇÜNCÜ BÖLÜM

3. VERİ SETİ

Bu tez çalışması için açık kaynaklardan videolar toplanmıştır. Spor kategorileri olarak ip atlama, squat, koşma, şnav, bisiklet, barfiks kategorileri belirlenmiştir. Bu kategorilere ait videoları bulmak için arama anahtar kelimeleri olarak Türkçe ve İngilizce “ip atlama”, “squat”, “koşma”, “bisiklet”, “barfiks”, “şnav” kelimeleri kullanılmıştır. Tablo 2’de kaynaklardan alınan video sayıları verilmiştir.

Tablo 2. Tez çalışmasında kullanılan veri kaynakları.

Kaynak	Video Sayısı Sayısı
(Youtube - Instagram t.y.)	356
Google arama	367
(Stok Videolar - iStock, t.y.)	172

3.1. Video Bilgileri

Tablo 3’de her bir kategoriden 100’er adet video toplanmıştır. Bu videoların 90’ar tanesi eğitim 10’ar tanesi test için ayrılmıştır.

Tablo 3. Toplanan videoların sayısal dağılımı.

Kategori	Eğitim- Doğrulama	Test
Squat	90	10
Bisiklet	90	10
İp Atlama	90	10
Şnav	90	10
Koşma	90	10
Barfiks	90	10

Video formatının çözünürlüğünde genel olarak mp4 formatında videolar toplanmış olup videonun boyutunu düşünerek veri setinin fazlalığından dolayı biraz daha orta kalitede görüntü kalitesinde olan videolar tercih edilmiştir. Ön işleme bölümünde boyutlandırma, çerçeveleme, normalleştirme yapılmıştır.

3.2. Veri Setinden Örnekler

Bu bölümde, çeşitli spor branşlarının orijinal resimleri ve Mediapipe Pose Detection kullanılarak bu sporların yapıldığı yerin giydirilmiş resimleri sunulmaktadır. Orijinal resimler, ilgili spor branşının tipik bir sahnesini göstermektedir. Mediapipe Pose Detection tekniği, bu resimler üzerinde uygulanarak sporcuların vücut pozisyonları ve hareketlerinin tespit edilmesi sağlanmıştır. Daha sonra, tespit edilen vücut pozisyonlarına dayanarak sporcuların hareket ettikleri yerin giydirilmiş halleri elde edilmiştir. Bu giydirilmiş resimler, sporcuların doğru

formda ve pozisyonda hareket ettikleri zamanı göstermektedir. Bu şekilde, sporcuların tekniklerinin doğruluğu ve hareketlerin etkinliği değerlendirilebilir.

Barfiks, üst vücut kuvvetini geliştirmek için yaygın olarak kullanılan bir egzersizdir. Bu egzersiz, sırt, omuz ve kol kaslarını güçlendirir. Barfiks çekme hareketinde, vücut ağırlığı ellerin ve kolların gücü ile yukarı çekilir. Özellikle kolların ve omuzların doğru pozisyonda olması, hareketin etkili ve güvenli bir şekilde yapılması açısından çok önemlidir. Görsel 1 ‘de barfiks spor branşına ait orijinal resim ve hareketin yapıldığı yerin giydirilmiş hali gösterilmektedir.



Görsel 1. Barfiks görüntüsü ve giydirilmiş hali.

Squat alt vücut kuvvetini geliştirmek için yaygın olarak kullanılan bir egzersizdir. Bu egzersiz, özellikle kalça, bacak ve çekirdek kaslarını güçlendirir. Squat yaparken, vücut ağırlığı bacaklar ve kalça kaslarının gücü ile yukarı ve aşağı hareket ettirilir. Dizlerin ve sırtın doğru pozisyonda olması, hareketin etkili ve güvenli bir şekilde yapılması açısından çok önemlidir.

Görsel 2’de Squat spor branşına ait orijinal resim ve hareketin yapıldığı yerin giydirilmiş hali gösterilmektedir.



Görsel 2. Squad görüntüsü ve giydirilmiş hali.

Koşma kardiyovasküler sağlık ve genel kondisyonu geliştirmek için yaygın olarak kullanılan bir egzersizdir. Bu egzersiz, bacak, kalça ve çekirdek kaslarını güçlendirir. Koşarken, vücut ağırlığı sürekli olarak bir bacak üzerinde taşınır ve ileri doğru hareket edilir. Kolların ve bacakların doğru pozisyonda olması, hareketin etkili ve güvenli bir şekilde yapılması açısından çok önemlidir.

Görsel 3 'de koşma spor branşına ait orijinal resim ve hareketin yapıldığı yerin giydirilmiş hali gösterilmektedir.



Görsel 3. Koşma görüntüsü ve giydirilmiş hali.

Bisiklet sürmek hem dayanıklılığı artıran hem de alt vücut kaslarını güçlendiren popüler bir egzersizdir. Bu spor, bacak kaslarının yanı sıra kalça ve çekirdek kaslarını da çalıştırır. Bisiklet sürerken, pedalların döndürülmesiyle ilerlenir ve vücut ağırlığı bisikletin üzerinde dengede tutulur. Doğru sürüş tekniği ve ergonomik pozisyon hem performansı artırır hem de sakatlanma riskini azaltır.

Görsel 4’de bisiklet spor branşına ait orijinal resim ve hareketin yapıldığı yerin giydirilmiş hali gösterilmektedir.



Görsel 4. Bisiklet görüntüsü ve giydirilmiş hali.

Şınav çekmek, üst vücut kaslarını güçlendiren etkili bir egzersizdir. Bu spor, özellikle göğüs, omuz, triseps ve çekirdek kaslarını çalıştırır. Şınav çekme sırasında, vücut ağırlığı ellerin ve ayak parmaklarının üzerinde dengede tutulur ve vücut düz bir çizgi halinde aşağı ve yukarı hareket ettirilir. Doğru form ve teknik, hem kasların etkili bir şekilde çalışmasını sağlar hem de sakatlanma riskini azaltır.

Görsel 5 ‘de Şınav spor branşına ait orijinal resim ve hareketin yapıldığı yerin giydirilmiş hali gösterilmektedir.




Görsel 5. Squat görüntüsü ve giydirilmiş hali.

İp atlama, kardiyovasküler dayanıklılığı artıran ve tüm vücut kaslarını çalıştıran etkili bir egzersizdir. Bu spor, özellikle bacak, kalça ve çekirdek kaslarını güçlendirir, aynı zamanda

koordinasyon ve dengeyi geliştirir. İp atlama sırasında, vücut sürekli olarak yerden yukarı doğru itilir ve tekrar zemine inerken ip, ayakların altından geçirilir. Doğru teknik ve ritim, egzersizin verimliliğini artırır ve sakatlanma riskini azaltır.

Görsel 6'da Şınav spor branşına ait orijinal resim ve hareketin yapıldığı yerin giydirilmiş hali gösterilmektedir.



Görsel 6. Atlama görüntüsü ve giydirilmiş hali.

3.3. Videoların Toplanması

Videolar Youtube, Vimeo, İstock gibi uygulamalardan indirilmiştir ve videoları hız olarak normal hızda olması sağlanmıştır ve 6-7 saniyeyi geçmeyecek şekilde videolar toplanmıştır. Videoların toplanması süreci başlamadan önce, mevcut veri setleri ve benzer çalışmalardan elde edilen veriler incelenmiştir. Bu inceleme, toplanacak videoların belirlenmesinde ve veri setinin oluşturulmasında yol gösterici olmuştur. Videoların toplanma süreci belirli bir zaman çerçevesinde gerçekleştirilmiştir. Bu sürecin başlangıç ve bitiş tarihleri, çalışmanın hangi dönemde yapıldığını ve hangi zaman aralığında verilerin toplandığını göstermektedir. Toplanan videoların kalitesi özenle kontrol edilmiş ve uygunluk kriterlerine göre filtreleme yapılmıştır. Düşük çözünürlüklü veya bozuk videolar, veri setinden elenmiş ve yalnızca orta kaliteli ve veri setini zorlaştırmayacak videolar kullanılmıştır. Videolar belirlenen spor branşlarına göre kategorize edilmiş ve her bir kategoride kaç adet video olduğu belirtilmiştir. Bu sayede, veri setinin hangi spor branşlarına odaklandığı ve her bir branşın temsil edilme düzeyi hakkında bilgi edinilmiştir. Videoların toplanması sırasında çeşitli zorluklarla karşılaşmış ve bu zorlukların nasıl aşıldığı belirtilmiştir. Örneğin, belirli bir spor branşına ait videoların az bulunması durumunda alternatif kaynaklardan yararlanılmıştır. Toplanan videolara ilişkin etiketleme süreci ve videoların içerdiği meta veriler detaylı bir şekilde incelenmiştir. Başlık,

açıklama, yayın tarihi gibi meta veriler, videoların içeriği hakkında önemli bilgiler sağlamış ve veri setinin yönetimini kolaylaştırmıştır.

3.4. Eğitim Test Olarak Ayrılması

Veri setinin etkin bir şekilde kullanılması ve modelin performansının değerlendirilmesi için, toplanan videolar eğitim ve test setleri olarak ayrılmıştır. Her bir spor kategorisinden toplamda 100 video toplanmış olup, bu videoların %90'ı (90 video) modelin eğitimi için, %10'u (10 video) ise modelin testi için ayrılmıştır. Bu ayırım, modelin yeni ve görülmemiş veriler üzerinden nasıl performans gösterdiğini değerlendirmek için kritik öneme sahiptir. Eğitim seti, modelin öğrenme sürecinde kullanılacak olup, modelin çeşitli spor hareketlerini tanıması ve bu hareketler arasındaki farklılıkları ayırt etmesi için gereken verileri sağlar. Eğitim sürecinde model, bu veri seti üzerinde defalarca çalışarak parametrelerini optimize eder ve en iyi sonuçları verecek şekilde kendini ayarlar. Test seti ise, modelin performansını objektif bir şekilde değerlendirmek için kullanılır. Eğitim sırasında modelin görmediği bu videolar, modelin genelleme yeteneğini ve gerçek dünyada karşılaşılabileceği yeni veriler üzerindeki doğruluğunu ölçer. Test seti ile elde edilen sonuçlar, modelin doğruluğunu, hassasiyetini ve genel başarımını ortaya koyar.

3.5. Csv Dosyasının Oluşturulması

Veri seti toplanıp eğitim ve test verileri ayrıldıktan sonra eğitim verileri kullanılarak csv dosyası elde edilmiştir. Eğitim için ayrılan videolardaki her bir çerçevede algılanan anahtar noktaların koordinatları csv dosyasına kaydedilmiştir. Böylelikle her bir duruş çerçevesi için her bir noktaya ait x,y,z koordinatları olmak üzere 99 adet koordinat kaydedilmekte bir adet te sınıf bilgisi tutulmaktadır. Her bir satırda 100 adet bilgi bulunmaktadır. Şekil 19'da csv dosyasından örnek 4 satır verilmektedir.

	class	x1	y1	z1	v1	x2	y2	z2	v2	x3	...	z31	v31	x32	y32	z32	v32	x33	y33	z33	v33
0	atlama	0.519366	0.087054	-0.293241	0.999998	0.526717	0.069433	-0.273757	0.999996	0.531244	...	0.142055	0.774633	0.545826	1.015714	-0.016338	0.980343	0.508413	1.013557	-0.027389	0.971990
1	atlama	0.519367	0.085921	-0.229617	0.999998	0.526699	0.068484	-0.209738	0.999993	0.531133	...	0.095169	0.769902	0.547722	1.013889	-0.050112	0.979299	0.508497	1.013074	-0.064927	0.970860
2	atlama	0.518971	0.075039	-0.236955	0.999997	0.526325	0.057607	-0.223452	0.999991	0.530638	...	0.108316	0.772061	0.547705	1.010478	-0.051430	0.978725	0.508610	1.012315	-0.054406	0.970747
3	atlama	0.518972	0.065560	-0.279333	0.999996	0.526330	0.047837	-0.262601	0.999985	0.530639	...	0.115431	0.770563	0.547673	1.008606	-0.042914	0.977706	0.508768	1.010402	-0.049074	0.970186
4	atlama	0.519259	0.057379	-0.335126	0.999994	0.527059	0.038456	-0.316512	0.999981	0.531301	...	0.124008	0.771111	0.547829	1.006374	-0.038152	0.976895	0.508829	1.006502	-0.038184	0.969803

Şekil 19. Csv dosyasını oluşturma.

DÖRDÜNCÜ BÖLÜM

4. DENEYSEL ÇALIŞMALAR

Bu bölümde, eğitim ve test çalışmalarından elde edilen sonuçları karşılaştırmalı analizleri verilmektedir. 3. Bölümde elde edilen csv dosyasındaki veriler yine 3. Bölümde bahsedilen makine öğrenme yöntemlerine uygulanarak makine öğrenmesi modelleri elde edilmiştir.

4.1. Eğitimler Ve Sonuçları

Bu tez çalışmasında kullanılan yapay zeka modellerinde scikit-learn kütüphanesinin varsayılan hiperparametreleri kullanılmıştır. Tablo 4’de RF makine öğrenmesi modeli karmaşıklık matrisi sonuçları verilmektedir. Bu veriler eğitim verisindeki her bir çerçevenin modele uygulanmasıyla elde edilmiştir.

Tablo 4. RF karmaşıklık matrisi sonuçları.

RF	Squat	Koşma	İp Atlama	Barfiks	Bisiklet	Şınav	% Başarı
Squat	3.062	11	38	1	0	0	98.39
Koşma	20	1072	80	6	4	10	88.93
İp Atlama	112	29	3690	21	9	31	94.80
Barfiks	70	86	9	2540	12	1	93.45
Bisiklet	37	197	1	25	2.302	0	89.85
Şınav	76	0	17	51	1	4259	96.71

RF makine öğrenmesi modelinin karmaşıklık matrisi sonuçlarına göre elde edilen ortalama doğruluk değeri **%93.69** olarak hesaplanmıştır. Bu yüksek başarı oranı, RF makine öğrenmesi modelinin veri setindeki örüntüleri etkili bir şekilde öğrenebildiğini ve genellikle güvenilir sonuçlar üretebildiğini göstermektedir. Tablo 5’de RF makine öğrenmesi modelinin eğitim verisi üzerinde çalıştırılmasından elde edilen performans metrikleri verilmektedir. Tablo; doğruluk, duyarlılık ve F1-skoru gibi önemli performans ölçütlerini içermektedir.

Tablo 5. RF performans metrikleri.

Sınıf /Metrik	Doğruluk	Duyarlılık	F1-Skor
Squat	0.9839	0.9067	0.9438
Bisiklet	0.8985	0.9842	0.9394
Koşma	0.8993	0.7746	0.8323
İp Atlama	0.9481	0.9716	0.9597
Barfiks	0.9345	0.9610	0.9476
Şınav	0.9671	0.9816	0.9743

En yüksek doğruluk %98.39 ile squat sınıfında elde edilmiştir. Bu, squat sınıfındaki örneklerin büyük çoğunluğunun doğru bir şekilde sınıflandırıldığını gösterir. En düşük doğruluk %89.85 ile bisiklet sınıfında görülmektedir. Bu, modelin bu sınıfta daha fazla hata yaptığını belirtir. En yüksek duyarlılık %98.42 ile bisiklet sınıfında gözlenmiştir. Bu, modelin bisiklet sınıfındaki pozitif örnekleri çok iyi bir şekilde tespit ettiğini gösterir. En düşük duyarlılık %77.46 ile koşma sınıfında elde edilmiştir. Bu, modelin koşma sınıfındaki pozitif örnekleri tespit etmede daha fazla zorluk yaşadığını belirtir. En yüksek F1-skor %97.43 ile şnav sınıfında elde edilmiştir. F1-skor, doğruluk ve duyarlılık arasındaki dengeyi temsil eder ve modelin şnav sınıfındaki performansının çok iyi olduğunu gösterir. En düşük F1-skor %83.23 ile koşma sınıfında görülmektedir. Bu, koşma sınıfında hem doğruluk hem de duyarlılık açısından iyileştirme yapılabileceğini işaret eder.

Tablo 6’da GB karmaşıklık matris sonuçları verilmektedir. Bu veriler eğitim verisindeki her bir çerçevenin modele uygulanmasıyla elde edilmiştir.

Tablo 6. GB karmaşıklık matrisi sonuçları.

GB	Squat	Bisiklet	Koşma	İp Atlama	Barfiks	Şnav	% Başarı
Squat	3043	20	49	0	0	0	97.78
Koşma	24	1058	72	5	28	11	88.26
İp Atlama	131	79	3594	51	0	37	92.34
Barfiks	67	47	9	1028	0	0	89.31
Bisiklet	54	0	9	1	2498	0	97.50
Şnav	48	8	0	105	1	4242	96.32

GB makine öğrenmesi modelinin karmaşıklık matrisi sonuçlarına göre elde edilen ortalama doğruluk değeri **%94.75** olarak hesaplanmıştır. Bu yüksek başarı oranı, GB makine öğrenmesi modelinin veri setindeki örüntüleri etkili bir şekilde öğrenebildiğini ve genellikle güvenilir sonuçlar üretebildiğini göstermektedir. Tablo 8’de GB makine öğrenmesi modelinin eğitim verisi üzerinde çalıştırılmasından elde edilen performans metrikleri verilmektedir. Tablo; doğruluk, duyarlılık ve F1-skoru gibi önemli performans ölçütlerini içermektedir.

En yüksek doğruluk oranı %97.78 ile squat sınıfında elde edilmiştir, bu da squat sınıfındaki örneklerin çoğunun doğru bir şekilde sınıflandırıldığını gösterirken, en düşük doğruluk oranı %88.31 ile bisiklet sınıfında görülmektedir. Bu durum, modelin bisiklet sınıfında daha fazla hata yaptığını belirtir. En yüksek duyarlılık oranı %98.88 ile şnav sınıfında gözlenmiştir, bu da modelin şnav sınıfındaki pozitif örnekleri çok iyi bir şekilde tespit ettiğini gösterirken, en

düşük duyarlılık oranı %86.39 ile ip atlama sınıfında elde edilmiştir. Bu, modelin ip atlama sınıfındaki pozitif örnekleri tespit etmede daha fazla zorluk yaşadığını belirtir. En yüksek F1-skor değeri %97.58 ile şınav sınıfında elde edilmiştir. F1-skor, doğruluk ve duyarlılık arasındaki dengeyi temsil eder ve modelin şınav sınıfındaki performansının çok iyi olduğunu gösterirken, en düşük F1-skor değeri %87.80 ile bisiklet sınıfında görülmektedir. Bu da bisiklet sınıfında hem doğruluk hem de duyarlılık açısından iyileştirme yapılabileceğini işaret eder. Tablo 7’de GB eğitim verisi üzerinde çalıştırılmasından elde edilen performans metrikleri verilmektedir. Tablo; doğruluk, duyarlılık ve F1-skoru gibi önemli performans ölçütlerini içermektedir.

Tablo 7. GB performans metrikleri.

Sınıf /Metrik	Doğruluk	Duyarlılık	F1-Skor
Squat	0.9778	0.9038	0.9393
Bisiklet	0.8831	0.8729	0.8780
Koşma	0.9234	0.9628	0.9427
İp Atlama	0.8931	0.8639	0.8783
Barfiks	0.9750	0.9885	0.9817
Şınav	0.9632	0.9888	0.9758

Tablo 8’de LR karmaşıklık matris sonuçları verilmektedir. Bu veriler eğitim verisindeki her bir çerçevenin modele uygulanmasıyla elde edilmiştir.

Tablo 8. LR karmaşıklık matrisi sonuçları

LR	Squat	Bisiklet	Koşma	İp Atlama	Barfiks	Şınav	% Başarı
Squat	2932	10	110	38	22	0	94.22
Koşma	2	2486	1	2	71	0	97.03
İp Atlama	115	62	2143	98	64	38	92.34
Barfiks	319	74	21	3455	22	1	89.31
Bisiklet	106	6	8	96	2501	1	97.50
Şınav	51	30	24	17	475	3807	86.44

LR makine öğrenmesi modelinin karmaşıklık matrisi sonuçlarına göre elde edilen ortalama doğruluk değeri **%92.80** olarak hesaplanmıştır. Bu yüksek başarı oranı, LR makine öğrenmesi modelinin veri setindeki örüntüleri etkili bir şekilde öğrenebildiğini ve genellikle güvenilir sonuçlar üretebildiğini göstermektedir. Tablo 9’da LR eğitim verisi üzerinde çalıştırılmasından

elde edilen performans metrikleri verilmektedir. Tablo; doğruluk, duyarlılık ve F1-skoru gibi önemli performans ölçütlerini içermektedir.

Tablo 9. LR performans metrikleri.

Sınıf /Metrik	Doğruluk	Duyarlılık	F1-Skor
Squat	0.9422	0.8318	0.8835
Bisiklet	0.9703	0.9318	0.9507
Koşma	0.8504	0.9289	0.8879
İp Atlama	0.8877	0.9323	0.9094
Barfiks	0.9202	0.7927	0.8517
Şınav	0.8644	0.9896	0.9228

En yüksek doğruluk oranı %97.03 ile bisiklet sınıfında elde edilmiştir. Bu sonuç, modelin bisiklet sınıfındaki örnekleri doğru bir şekilde sınıflandırmada yüksek bir başarı gösterdiğini ortaya koymaktadır. En düşük doğruluk oranı ise %85.04 ile koşma sınıfında gözlenmektedir, bu da modelin koşma sınıfındaki sınıflandırmalarda daha fazla hata yaptığını göstermektedir. En yüksek duyarlılık oranı %98.96 ile şınav sınıfında elde edilmiştir. Bu durum, modelin şınav sınıfındaki pozitif örnekleri tespit etme yeteneğinin oldukça yüksek olduğunu göstermektedir. En düşük duyarlılık oranı %79.27 ile barfiks sınıfında gözlenmiştir, bu da modelin barfiks sınıfındaki pozitif örnekleri tespit etmede daha zorlandığını işaret etmektedir. En yüksek F1-skor değeri %95.07 ile bisiklet sınıfında elde edilmiştir. F1-skor, doğruluk ve duyarlılık arasındaki dengeyi temsil eder ve modelin bisiklet sınıfındaki performansının dengeli olduğunu gösterirken, en düşük F1-skor değeri %85.17 ile barfiks sınıfında görülmektedir. Bu durum, barfiks sınıfındaki performansın iyileştirilebileceğini göstermektedir.

Tablo 10’da RC makine öğrenmesi modeli karmaşıklık matris sonuçları verilmektedir. Bu veriler eğitim verisindeki her bir çerçevenin modele uygulanmasıyla elde edilmiştir.

Tablo 10. RC karmaşıklık matrisi sonuçları.

RC	Squat	Bisiklet	Koşma	İp Atlama	Barfiks	Şınav	% Başarı
Squat	3.062	11	0	1	0	38	98.42
Koşma	20	1072	80	6	4	10	88.93
İp Atlama	112	29	3690	21	9	31	94.81
Barfiks	70	86	9	2540	12	1	93.45
Bisiklet	15	52	1	25	2.302	0	97.13
Şınav	27	0	17	23	1	4067	98.35

RC makine öğrenmesi modelinin karmaşıklık matrisi sonuçlarına göre elde edilen ortalama doğruluk değeri **%95.18** olarak hesaplanmıştır. Bu yüksek başarı oranı, RC veri setindeki örüntüleri etkili bir şekilde öğrenebildiğini ve genellikle güvenilir sonuçlar üretebildiğini göstermektedir. Tablo 11’de RC makine öğrenmesi modelinin eğitim verisi üzerinde çalıştırılmasından elde edilen performans metrikleri verilmektedir. Tablo; doğruluk, duyarlılık ve F1-skoru gibi önemli performans ölçütlerini içermektedir.

Tablo 11. RC performans metrikleri.

Sınıf /Metrik	Doğruluk	Duyarlılık	F1-Skor
Squat	0.9721	0.9232	0.9238
Bisiklet	0.8381	0.9362	0.9334
Koşma	0.8443	0.7346	0.8623
İp Atlama	0.9281	0.9317	0.9397
Barfiks	0.9447	0.9511	0.9476
Şınav	0.9111	0.9213	0.9243

En yüksek doğruluk oranı %97.21 ile squat sınıfında elde edilmiştir. Bu sonuç, modelin squat sınıfındaki örnekleri doğru bir şekilde sınıflandırmada yüksek bir başarı gösterdiğini göstermektedir. En düşük doğruluk oranı ise %83.81 ile bisiklet sınıfında gözlenmektedir, bu da modelin bisiklet sınıfındaki sınıflandırmalarda daha fazla hata yaptığını göstermektedir. En yüksek duyarlılık oranı %93.62 ile bisiklet sınıfında elde edilmiştir. Bu durum, modelin bisiklet sınıfındaki pozitif örnekleri tespit etme yeteneğinin oldukça yüksek olduğunu göstermektedir. En düşük duyarlılık oranı %73.46 ile koşma sınıfında gözlenmiştir, bu da modelin koşma sınıfındaki pozitif örnekleri tespit etmede daha zorlandığını işaret etmektedir. En yüksek F1-skor değeri %94.76 ile barfiks sınıfında elde edilmiştir. F1-skor, doğruluk ve duyarlılık arasındaki dengeyi temsil eder ve modelin barfiks sınıfındaki performansının dengeli olduğunu gösterirken, en düşük F1-skor değeri %86.23 ile koşma sınıfında görülmektedir. Bu durum, koşma sınıfındaki performansın iyileştirilebileceğini göstermektedir. Tablo 13’de NB karmaşıklık matris sonuçları verilmektedir. Bu veriler eğitim verisindeki her bir çerçevenin modele uygulanmasıyla elde edilmiştir.

Tablo 12’de NB karmaşıklık matris sonuçları verilmektedir. Bu veriler eğitim verisindeki her bir çerçevenin modele uygulanmasıyla elde edilmiştir.

NB makine öğrenmesi modelinin karmaşıklık matrisi sonuçlarına göre elde edilen ortalama doğruluk değeri **%76.71** olarak hesaplanmıştır. Bu yüksek başarı oranı, NB ‘nin veri setindeki örüntüleri etkili bir şekilde öğrenebildiğini ve genellikle güvenilir sonuçlar üretebildiğini göstermektedir. Tablo 13’de NB makine öğrenmesi modelinin eğitim verisi üzerinde çalıştırılmasından elde edilen performans metrikleri verilmektedir. Tablo; doğruluk, duyarlılık ve F1-skoru gibi önemli performans ölçütlerini içermektedir.

Tablo 12. NB karmaşıklık matrisi sonuçları.

NB	Squat	Bisiklet	Koşma	İp Atlama	Barfiks	Şınav	% Başarı
Squat	2142	10	534	38	102	0	75.80
Koşma	30	1800	222	2	172	21	80.11
İp Atlama	354	62	1500	98	64	38	70.89
Barfiks	453	74	121	2904	85	54	78.68
Bisiklet	304	56	8	96	1999	231	74.20
Şınav	351	30	24	17	473	3241	78.32

Tablo 13. NB performans metrikleri.

Sınıf /Metrik	Doğruluk	Duyarlılık	F1-Skor
Squat	0.7580	0.5894	0.6632
Bisiklet	0.8011	0.8858	0.8413
Koşma	0.7089	0.6227	0.6630
İp Atlama	0.7868	0.9204	0.8484
Barfiks	0.7420	0.6900	0.7151
Şınav	0.7832	0.9040	0.8353

En yüksek doğruluk oranı %80.11 ile bisiklet sınıfında elde edilmiştir. Bu sonuç, modelin bisiklet sınıfındaki örnekleri doğru bir şekilde sınıflandırmada daha yüksek bir başarı gösterdiğini göstermektedir. En düşük doğruluk oranı ise %70.89 ile koşma sınıfında gözlenmektedir, bu da modelin koşma sınıfındaki sınıflandırmalarda daha fazla hata yaptığını göstermektedir. En yüksek duyarlılık oranı %92.04 ile atlama sınıfında elde edilmiştir. Bu durum, modelin atlama sınıfındaki pozitif örnekleri tespit etme yeteneğinin oldukça yüksek olduğunu göstermektedir. En düşük duyarlılık oranı %58.94 ile squat sınıfında gözlenmiştir, bu da modelin squat sınıfındaki pozitif örnekleri tespit etmede daha zorlandığını işaret etmektedir. En yüksek F1-skor değeri %84.84 ile ip atlama sınıfında elde edilmiştir. F1-skor, doğruluk ve duyarlılık arasındaki dengeyi temsil eder ve modelin ip atlama sınıfındaki performansının

dengeli olduğunu gösterirken, en düşük F1-skor değeri %66.30 ile koşma sınıfında görülmektedir. Bu durum, koşma sınıfındaki performansın iyileştirilebileceğini göstermektedir.

Tablo 14’da KNN karmaşıklık matris sonuçları verilmektedir. Bu veriler eğitim verisindeki her bir çerçevenin modele uygulanmasıyla elde edilmiştir.

Tablo 14. KNN karmaşıklık matrisi sonuçları.

KNN	Squat	Bisiklet	Koşma	İp Atlama	Barfiks	Şınav	% Başarı
Squat	3145	0	0	21	34	0	98.28
Koşma	0	2463	0	2	18	21	98.36
İp Atlama	0	8	2094	21	0	35	97.03
Barfiks	0	6	0	3792	43	43	97.63
Bisiklet	0	5	8	3	2777	0	99.43
Şınav	0	24	17	0	47	4132	97.91

KNN makine öğrenmesi modelinin karmaşıklık matrisi sonuçlarına göre elde edilen ortalama doğruluk değeri **%98.11** olarak hesaplanmıştır. Bu yüksek başarı oranı, KNN makine öğrenmesi modelinin veri setindeki örüntüleri etkili bir şekilde öğrenebildiğini ve genellikle güvenilir sonuçlar üretebildiğini göstermektedir. Tablo 15’de KNN makine öğrenmesi modelinin eğitim verisi üzerinde çalıştırılmasından elde edilen performans metrikleri verilmektedir. Tablo; doğruluk, duyarlılık ve F1-skoru gibi önemli performans ölçütlerini içermektedir.

Tablo 15. KNN performans metrikleri.

Sınıf /Metrik	Doğruluk	Duyarlılık	F1-Skor
Squat	0.9828	1.0000	0.9913
Bisiklet	0.9836	0.9915	0.9876
Koşma	0.9703	0.9849	0.9776
Atlama	0.9763	0.9834	0.9798
Barfiks	0.9943	0.9669	0.9804
Şınav	0.9897	0.9765	0.9831

En yüksek doğruluk oranı %99.43 ile barfiks sınıfında elde edilmiştir. Bu sonuç, modelin barfiks sınıfındaki örnekleri doğru bir şekilde sınıflandırmada en yüksek başarıyı gösterdiğini göstermektedir. En düşük doğruluk oranı ise %97.03 ile koşma sınıfında gözlenmektedir, bu da modelin koşma sınıfındaki sınıflandırmalarda daha az başarı gösterdiğini işaret etmektedir. En

yüksek duyarlılık oranı %100.00 ile squat sınıfında elde edilmiştir. Bu durum, modelin squat sınıfındaki pozitif örnekleri tespit etme yeteneğinin mükemmel olduğunu göstermektedir. En düşük duyarlılık oranı %96.69 ile barfiks sınıfında gözlenmiştir, bu da modelin barfiks sınıfındaki pozitif örnekleri tespit etmede daha zorlandığını işaret etmektedir. En yüksek F1-skor değeri %99.13 ile squat sınıfında elde edilmiştir. F1-skor, doğruluk ve duyarlılık arasındaki dengeyi temsil eder ve modelin squat sınıfındaki performansının dengeli olduğunu gösterirken, en düşük F1-skor değeri %97.76 ile koşma sınıfında görülmektedir. Bu durum, koşma sınıfındaki performansın iyileştirilebileceğini göstermektedir.

Tablo 16’da ADA karmaşıklık matrisi sonuçları verilmektedir. Bu veriler eğitim verisindeki her bir çerçevenin modele uygulanmasıyla elde edilmiştir.

Tablo 16. ADA karmaşıklık matrisi sonuçları.

ADA	Squat	Bisiklet	Koşma	İp Atlama	Barfiks	Şınav	% Başarı
Squat	3056	245	2	21	34	173	86.55
Bisiklet	0	2456	387	2	0	11	85.99
Koşma	354	8	2094	21	0	35	83.36
İp Atlama	451	6	32	3792	148	53	84.31
Barfiks	251	5	8	332	2777	0	82.33
Şınav	75	162	124	17	165	3674	87.12

ADA makine öğrenmesi modelinin karmaşıklık matrisi sonuçlarına göre elde edilen ortalama doğruluk değeri **%84,94** olarak hesaplanmıştır. Bu yüksek başarı oranı, ADA makine öğrenmesi modelinin veri setindeki örüntüleri etkili bir şekilde öğrenebildiğini ve genellikle güvenilir sonuçlar üretebildiğini göstermektedir. Tablo 17’de ADA makine öğrenmesi modelinin eğitim verisi üzerinde çalıştırılmasından elde edilen performans metrikleri verilmektedir. Tablo; doğruluk, duyarlılık ve F1-skoru gibi önemli performans ölçütlerini içermektedir.

Tablo 17. ADA performans metrikleri.

Sınıf /Metrik	Doğruluk	Duyarlılık	F1-Skor
Squat	0.8655	0.7299	0.7919
Bisiklet	0.8599	0.8522	0.8560
Koşma	0.8336	0.7911	0.8118
İp Atlama	0.8461	0.9061	0.8750
Barfiks	0.8233	0.8889	0.8549
Şınav	0.8712	0.9311	0.9002

En yüksek doğruluk oranı %87.12 ile şnav sınıfında elde edilmiştir. Bu sonuç, modelin şnav sınıfındaki örnekleri doğru bir şekilde sınıflandırmada en yüksek başarıyı gösterdiğini göstermektedir. En düşük doğruluk oranı ise %82.33 ile barfiks sınıfında gözlenmektedir, bu da modelin barfiks sınıfındaki sınıflandırmalarda daha az başarı gösterdiğini işaret etmektedir. En yüksek duyarlılık oranı %93.11 ile şnav sınıfında elde edilmiştir. Bu durum, modelin şnav sınıfındaki pozitif örnekleri tespit etme yeteneğinin mükemmel olduğunu göstermektedir. En düşük duyarlılık oranı %72.99 ile squat sınıfında gözlenmiştir, bu da modelin squat sınıfındaki pozitif örnekleri tespit etmede daha zorlandığını işaret etmektedir. En yüksek F1-skor değeri %90.02 ile şnav sınıfında elde edilmiştir. F1-skor, doğruluk ve duyarlılık arasındaki dengeyi temsil eder ve modelin şnav sınıfındaki performansının dengeli olduğunu gösterirken, en düşük F1-skor değeri %79.19 ile squat sınıfında görülmektedir. Bu durum, squat sınıfındaki performansın iyileştirilebileceğini göstermektedir.

Tablo 18’de DT karmaşıklık matrisi sonuçları verilmektedir. Bu veriler eğitim verisindeki her bir çerçevenin modele uygulanmasıyla elde edilmiştir.

Tablo 18. DT karmaşıklık matrisi sonuçları.

DT	Squat	Bisiklet	Koşma	İp Atlama	Barfiks	Şnav	% Başarı
Squat	2932	10	110	38	22	0	94.22
Bisiklet	2	2486	1	2	71	0	97.03
Koşma	115	62	2143	98	64	38	92.34
İp Atlama	319	74	21	3455	22	1	89.31
Barfiks	106	6	8	96	2501	1	97.50
Şnav	51	30	24	17	467	3807	86.44

DT makine öğrenmesi modelinin karmaşıklık matrisi sonuçlarına göre elde edilen ortalama doğruluk değeri **%92.80** olarak hesaplanmıştır. Bu yüksek başarı oranı, DT makine öğrenmesi modelinin veri setindeki örüntüleri etkili bir şekilde öğrenebildiğini ve genellikle güvenilir sonuçlar üretebildiğini göstermektedir. Tablo 19’da DT makine öğrenmesi modelinin eğitim verisi üzerinde çalıştırılmasından elde edilen performans metrikleri verilmektedir. Tablo; doğruluk, duyarlılık ve F1-skoru gibi önemli performans ölçütlerini içermektedir.

Tablo 19. DT performans metrikleri.

Sınıf /Metrik	Doğruluk	Duyarlılık	F1-Skor
Squat	0.9512	0.8388	0.8235
Bisiklet	0.9303	0.9718	0.9507
Koşma	0.8204	0.9239	0.8379
İp Atlama	0.8847	0.9333	0.9054
Barfiks	0.8202	0.7427	0.8217
Şınav	0.8744	0.9896	0.9528

En yüksek doğruluk oranı %95.12 ile squat sınıfında elde edilmiştir. Bu sonuç, modelin squat sınıfındaki örnekleri doğru bir şekilde sınıflandırmada en yüksek başarıyı gösterdiğini göstermektedir. En düşük doğruluk oranı ise %82.02 ile barfiks sınıfında gözlenmektedir, bu da modelin barfiks sınıfındaki sınıflandırmalarda daha az başarı gösterdiğini işaret etmektedir. En yüksek duyarlılık oranı %98.96 ile şınav sınıfında elde edilmiştir. Bu durum, modelin şınav sınıfındaki pozitif örnekleri tespit etme yeteneğinin mükemmel olduğunu göstermektedir. En düşük duyarlılık oranı %74.27 ile barfiks sınıfında gözlenmiştir, bu da modelin barfiks sınıfındaki pozitif örnekleri tespit etmede daha zorlandığını işaret etmektedir. En yüksek F1-skor değeri %95.28 ile şınav sınıfında elde edilmiştir. F1-skor, doğruluk ve duyarlılık arasındaki dengeyi temsil eder ve modelin şınav sınıfındaki performansının dengeli olduğunu gösterirken, en düşük F1-skor değeri %82.17 ile barfiks sınıfında görülmektedir. Bu durum, barfiks sınıfındaki performansın iyileştirilebileceğini göstermektedir.

Tablo 20’de SVC karmaşıklık matris sonuçları verilmektedir. Bu veriler eğitim verisindeki her bir çerçevenin modele uygulanmasıyla elde edilmiştir.

Tablo 20. SVC karmaşıklık matrisi sonuçları.

SVC	Squat	Bisiklet	Koşma	İp Atlama	Barfiks	Şınav	% Başarı
Squat	4563	11	0	23	0	129	96.55
Bisiklet	20	2234	180	6	4	42	89.71
Koşma	112	29	3690	21	9	31	94.81
İp Atlama	70	86	9	2540	12	1	93.45
Barfiks	37	197	1	25	2.302	0	89.85
Şınav	232	0	43	75	1	4259	92.38

SVC makine öğrenmesi modelinin karmaşıklık matrisi sonuçlarına göre elde edilen ortalama doğruluk değeri **%92.79** olarak hesaplanmıştır. Bu yüksek başarı oranı, SVC makine öğrenmesi modelinin veri setindeki örüntüleri etkili bir şekilde öğrenebildiğini ve genellikle güvenilir sonuçlar üretebildiğini göstermektedir. Tablo 21’de SVC makine öğrenmesi modelinin eğitim verisi üzerinde çalıştırılmasından elde edilen performans metrikleri verilmektedir. Tablo; doğruluk, duyarlılık ve F1-skoru gibi önemli performans ölçütlerini içermektedir.

Tablo 21. SVC performans metrikleri.

Sınıf /Metrik	Doğruluk	Duyarlılık	F1-Skor
Squat	0.9628	0.9723	0.9913
Bisiklet	0.9636	0.9915	0.9876
Koşma	0.9503	0.9849	0.9776
Atlama	0.9533	0.9834	0.9798
Barfiks	0.9632	0.9669	0.9804
Şınav	0.9657	0.9765	0.9831

En yüksek doğruluk oranı %96.57 ile şınav sınıfında elde edilmiştir. Bu sonuç, modelin şınav sınıfındaki örnekleri doğru bir şekilde sınıflandırmada en yüksek başarıyı gösterdiğini göstermektedir. En düşük doğruluk oranı ise %95.03 ile koşma sınıfında gözlenmektedir, bu da modelin koşma sınıfındaki sınıflandırmalarda diğer sınıflara göre biraz daha az başarı gösterdiğini işaret etmektedir. En yüksek duyarlılık oranı %99.15 ile bisiklet sınıfında elde edilmiştir. Bu durum, modelin bisiklet sınıfındaki pozitif örnekleri tespit etme yeteneğinin mükemmel olduğunu göstermektedir. En düşük duyarlılık oranı %96.69 ile barfiks sınıfında gözlenmiştir, bu da modelin barfiks sınıfındaki pozitif örnekleri tespit etmede diğer sınıflara göre daha zorlandığını işaret etmektedir. En yüksek F1-skor değeri %99.13 ile squat sınıfında elde edilmiştir. F1-skor, doğruluk ve duyarlılık arasındaki dengeyi temsil eder ve modelin squat sınıfındaki performansının dengeli olduğunu gösterirken, en düşük F1-skor değeri %97.76 ile koşma sınıfında görülmektedir. Bu durum, koşma sınıfındaki performansın iyileştirilebileceğini göstermektedir. Tablo 22’de Modellerin eğitim karmaşık matris sonuçları verilmektedir.

Tablo 22. Eğitim verilerinin kategori bazlı model doğruluk oranları

	RC(%)	RF(%)	DT(%)	GB(%)	KNN(%)	SVC(%)	ADA(%)	LR(%)	NB(%)
Squat	98.42	98.39	94.22	97.78	98.28	96.55	86.55	94.22	75.80
Koşma	88.93	88.93	92.34	88.26	98.36	94.81	83.36	97.03	80.11
Atlama	94.81	94.80	89.31	92.34	97.03	93.45	84.31	92.34	70.89
Barfiks	93.45	93.45	97.50	89.31	97.63	89.85	82.33	89.31	78.68
Bisiklet	97.13	89.85	97.03	97.50	99.43	89.71	85.99	97.50	74.20
Şınav	98.35	96.71	86.44	96.32	97.91	92.38	87.12	86.44	78.32
Ortalama	95.18	93.69	92.80	94.75	98.11	92.78	84.94	92.80	76.71

Tablo 22’de verilen modele göre spor türü sınıflandırma doğruluk oranları incelendiğinde **KNN** 5 spor türünde en yüksek başarı oranına ulaşarak ortalama en başarılı model olarak saptanmıştır. **NB** ise en düşük model olarak saptanmıştır.

4.2. Testler Ve Sonuçları

Bu bölümde her spor branşından 10 test videosu alınmıştır ve modellerdeki başarısı incelenmiştir. 10 video üzerinden o branşa ait olan ve ait olmayana göre modelin başarısı tespit edilmiştir. Şekil 20’de, video yolları ve sınıflarını işleyerek modelin doğru verileri sağlama yeteneği incelenmiştir. Model, altı farklı branştan hangisinin en yüksek değere sahip olduğunu tahmin etmektedir. Videolar ilerledikçe, modelin her 10 sonuç üzerinden ortalamaları alarak en fazla tespit edilen spor branşını belirlediği gözlemlenmiştir. Örneğin, ilk 10 sonuç içerisinde 7 squat ve 3 barfiks tespit edildiğinde, model squat branşını çıktıya yansıtacaktır. Bu yaklaşım, modelin genel başarı oranını artırmayı hedeflemektedir.

video_yolu	Class	Probability_0	Probability_1	Probability_2	Probability_3	Probability_4	Probability_5
/content/drive/MyDrive/	squad	0.01521382024	0.06903819328	0.008636972726	0.1233222317	0.003133910506	0.7806548715
/content/drive/MyDrive/	squad	0.02506469048	0.1211570839	0.01299023471	0.2049135186	0.004713484034	0.6311609882
/content/drive/MyDrive/	squad	0.01821300644	0.08803758227	0.009439224024	0.1488983572	0.003425005992	0.7319868241
/content/drive/MyDrive/	squad	0.01481031049	0.1122976911	0.009234377017	0.1444021831	0.003153957109	0.7161014812
/content/drive/MyDrive/	squad	0.01281501789	0.2819486775	0.008105685069	0.1007710956	0.002615054763	0.5937444691
/content/drive/MyDrive/	barfiks	0.006728918802	0.6778377434	0.0038855024	0.05524737178	0.001253540135	0.2550469235
/content/drive/MyDrive/	barfiks	0.01382349684	0.4905850923	0.007982148651	0.1570580706	0.002575199464	0.3279759921
/content/drive/MyDrive/	barfiks	0.01492562753	0.4346927638	0.007954801136	0.1855211691	0.002780517004	0.3541251215
/content/drive/MyDrive/	squad	0.01238214128	0.3642453161	0.007228714926	0.196555669	0.002526721213	0.4170614374
/content/drive/MyDrive/	squad	0.01267425804	0.3565774387	0.007679339687	0.2223912948	0.002586331065	0.3980913377

Şekil 20. Çerçeve bazında sonuç kayıtları

Test videolarındaki her bir çerçeve için sınıflandırma yapılarak türü en çok çıkan sınıfa sınıflandırma yapılmıştır. Örneğin 90 çerçeve içeren bir videoda 80 çerçeve için model “ip atlama” sonucu üretiyorsa modelin sonucu “ip atlama” olarak belirlenmektedir.

Tablo 23’de RF için karmaşık matrisi test sonuçları verilmektedir.

Tablo 23. RF karmaşıklık matrisi test sonuçları.

RF	Squat	Koşma	İp Atlama	Barfiks	Bisiklet	Şınav	% Başarı
Squat	10	0	0	0	0	0	100
Koşma	0	10	0	0	0	0	100
İp Atlama	0	0	10	0	0	0	100
Barfiks	0	0	0	10	0	0	100
Bisiklet	0	0	0	0	9	1	90
Şınav	0	0	0	0	0	10	100

RF makine öğrenmesi modelinin karmaşıklık matrisi test sonuçlarına göre elde edilen ortalama doğruluk değeri **%98.33** olarak hesaplanmıştır. Tüm branşlarda 10 videonun tamamı %100 başarı sağlarken, yalnızca bir bisiklet test videosunda hatalı spor branşı tespit edilmiştir.

Tablo 24’de RF için performans metrikleri verilmektedir.

Tablo 24. RF test performans metrikleri.

Test/Metrik	Doğruluk	Duyarlılık	F1-Skor
Squat	1.0000	1.0000	1.0000
Bisiklet	0.9000	0.9091	0.9474
Koşma	1.0000	1.0000	1.0000
Atlama	1.0000	1.0000	1.0000
Barfiks	1.0000	1.0000	1.0000
Şınav	1.0000	1.0000	1.0000

Model, beş aktivite (Barfiks, Koşma, Atlama, Şınav ve Squat) için mükemmel doğruluk (1.0000) sergilerken, yalnızca bisiklet aktivitesi için biraz daha düşük bir doğruluk (0.9000) göstermektedir. Bu model için, bisiklet aktivitesi duyarlılık açısından bir miktar zayıf kalmaktadır (0.9091), ancak diğer aktiviteler için duyarlılık değeri mükemmeldir (1.0000). Modelin F1-skorları, bisiklet (0.9474) aktivitesi dışında 1.0000'dir, bu da modelin genelde çok yüksek performans gösterdiğini ifade eder. Bu modelin en dikkat çekici özelliği, neredeyse tüm aktivitelerde hatasız çalışmasıdır. Ancak bisiklet aktivitesinde ufak performans düşüklükleri gözlemlenmiştir.

Tablo 25’de GB karmaşık matrisi test sonuçları verilmektedir.

Tablo 25. GB karmaşıklık matrisi test sonuçları.

GB	Squat	Koşma	İp Atlama	Barfiks	Bisiklet	Şınav	% Başarı
Squat	10	0	0	0	0	0	100
Koşma	2	8	0	0	0	0	80
İp Atlama	0	0	10	0	0	0	100
Barfiks	0	0	0	10	0	0	100
Bisiklet	0	0	0	0	10	0	100
Şınav	0	0	0	0	0	10	100

GB makine öğrenmesi modelinin karmaşıklık matrisi test sonuçlarına göre elde edilen ortalama doğruluk değeri **%96.67** olarak hesaplanmıştır. Tüm branşlarda 10 videonun 10'u %100 başarı sağlarken, iki koşma test videosunda hatalı spor branşı tespit edilmiştir.

Tablo 26'de GB için çeşitli test performans metriklerini göstermektedir.

Tablo 26. GB test performans metrikleri.

Test/Metrik	Doğruluk	Duyarlılık	F1-Skor
Squat	1.0000	0.8333	0.9091
Koşma	0.8000	1.0000	0.8889
Bisiklet	1.0000	1.0000	1.0000
İp Atlama	1.0000	1.0000	1.0000
Barfiks	1.0000	1.0000	1.0000
Şınav	1.0000	1.0000	1.0000

Model, beş aktivite (Barfiks, Bisiklet, Atlama, Şınav ve Squat) için mükemmel doğruluk (1.0000) sergilerken, yalnızca koşma aktivitesi için biraz daha düşük bir doğruluk (0.8000) göstermektedir. Bu model için, squat aktivitesi duyarlılık açısından bir miktar zayıf kalmaktadır (0.8333), ancak diğer aktiviteler için duyarlılık değeri mükemmeldir (1.0000). Modelin F1-skorları, koşma (0.9474) ve squat (0.8889) aktiviteleri dışında 1.0000'dir, bu da modelin genelde çok yüksek performans gösterdiğini ifade eder. Bu modelin en dikkat çekici özelliği, neredeyse tüm aktivitelerde hatasız çalışmasıdır. Ancak koşma aktivitesinde ufak performans düşüklükleri gözlemlenmiştir.

Tablo 27’de LR karmaşık matris sonuçları verilmektedir.

Tablo 27. LR karmaşıklık matrisi test sonuçları.

LR	Bisiklet	Koşma	Şınav	Barfiks	Squad	İp Atlama	% Başarı
Bisiklet	10	0	0	0	0	0	100
Koşma	0	10	0	0	0	0	100
Şınav	0	0	9	1	0	0	90
Barfiks	0	0	0	9	0	1	90
Squat	0	0	0	0	10	0	100
İp Atlama	0	0	0	0	0	10	100

LR makine öğrenmesi modelinin karmaşıklık matrisi test sonuçlarına göre elde edilen ortalama doğruluk değeri **%96.67** olarak hesaplanmıştır. Tüm branşlarda 10 videonun 10’u %100 başarı sağlarken, bir şınav ve bir barfiks test videosunda hatalı spor branşı tespit edilmiştir.

Tablo 28’de LR için çeşitli test performans metriklerini göstermektedir.

Tablo 28. LR test performans metrikleri.

Test/Metrik	Doğruluk	Duyarlılık	F1-Skor
Bisiklet	1.0000	1.0000	1.0000
Koşma	1.0000	1.0000	1.0000
Şınav	0.9000	1.0000	0.9434
Barfiks	0.9000	0.9000	0.9000
Squat	1.0000	1.0000	1.0000
İp Atlama	1.0000	0.9091	0.9524

Model, dört aktivite (Bisiklet, İp Atlama, Koşma ve Squat) için mükemmel doğruluk (1.0000) sergilerken, şınav ve barfiks aktiviteleri için biraz daha düşük bir doğruluk (0.9000) göstermektedir. Bu model için, barfiks (0.9000) ve ip atlama (0.9524) aktivitesi duyarlılık açısından bir miktar zayıf kalmaktadır ancak diğer aktiviteler için duyarlılık değeri mükemmeldir (1.0000). Modelin F1-skorları, şınav (0.9434), ip atlama (0.9524) ve barfiks (0.9000) aktiviteleri dışında 1.0000’dir, bu da modelin genelde çok yüksek performans gösterdiğini ifade eder. Bu modelin en dikkat çekici özelliği, neredeyse tüm aktivitelerde hatasız çalışmasıdır. Ancak şınav ve barfiks aktivitesinde ufak performans düşüklükleri gözlemlenmiştir.

Tablo 31’de RC karmaşık matris sonuçları verilmektedir.

Tablo 29. RC karmaşıklık matrisi test sonuçları.

RC	Bisiklet	Koşma	Şınav	Barfiks	Squat	İp Atlama	% Başarı
Bisiklet	10	0	0	0	0	0	100
Koşma	1	7	0	0	1	1	70
Şınav	0	0	10	0	0	0	100
Barfiks	0	0	0	10	0	0	100
Squat	0	0	0	0	10	0	100
İp Atlama	0	0	0	0	0	10	100

RC makine öğrenmesi nbmodelinin karmaşıklık matrisi test sonuçlarına göre elde edilen ortalama doğruluk değeri **%95.00** olarak hesaplanmıştır. Tüm branşlarda 10 videonun 10'u %100 başarı sağlarken, üç koşma test videosunda hatalı spor branşı tespit edilmiştir.

Tablo 30'da RC için çeşitli test performans metriklerini göstermektedir. Tablo; doğruluk, duyarlılık ve F1-skoru gibi önemli performans ölçütlerini içermektedir.

Tablo 30. RC test performans metrikleri.

Test/Metrik	Doğruluk	Duyarlılık	F1-Skor
Bisiklet	1.0000	0.9091	0.9524
Koşma	0.7000	1.0000	0.8235
Şınav	1.0000	1.0000	1.0000
Barfiks	1.0000	1.0000	1.0000
Squat	1.0000	0.9091	0.9524
İp Atlama	1.0000	0.9091	0.9524

Model, beş aktivite (Barfiks, Bisiklet, Atlama, Şınav ve Squat) için mükemmel doğruluk (1.0000) sergilerken, yalnızca koşma aktivitesi için biraz daha düşük bir doğruluk (0.7000) göstermektedir. Bu model için, squat, ip atlama ve bisiklet aktivitesi duyarlılık açısından bir miktar zayıf kalmaktadır (0.9091), ancak diğer aktiviteler için duyarlılık değeri mükemmeldir (1.0000). Modelin F1-skorları, bisiklet, squat, ip atlama aktiviteleri (0.9524) doğruluk değeri gösterirken koşma aktivitesi (0.8235) değer göstermiştir bu aktiviteleri dışında doğruluk değerleri 1.0000'dir. Bu modelin en dikkat çekici özelliği, neredeyse tüm aktivitelerde hatasız çalışmasıdır. Ancak koşma aktivitesinde ufak performans düşüklükleri gözlemlenmiştir.

Tablo 31'de NB karmaşık matris sonuçları verilmektedir.

Tablo 31. NB karmaşıklık matrisi test sonuçları.

NB	Bisiklet	Koşma	Şınav	Barfiks	Squat	İp Atlama	% Başarı
Bisiklet	9	0	0	0	1	0	90
Koşma	1	8	0	0	1	0	80
Şınav	0	0	10	0	0	0	100
Barfiks	0	0	0	10	0	0	100
Squat	4	2	0	0	3	1	30
İp Atlama	1	0	0	1	0	8	80

NB makine öğrenmesi modelinin karmaşıklık matrisi test sonuçlarına göre elde edilen ortalama doğruluk değeri **%80.00** olarak hesaplanmıştır. 10'ar videodan 1 tane bisiklet, 2 tane koşma, 7 tane squat ve 2 tane atlama yanlış spor branşı seçmiştir.

Tablo 32'de NB için çeşitli test performans metriklerini göstermektedir. Tablo; doğruluk, duyarlılık ve F1-skoru gibi önemli performans ölçütlerini içermektedir.

Tablo 32. NB test performans metrikleri.

Test/Metrik	Doğruluk	Duyarlılık	F1-Skor
Bisiklet	0.9000	0.6000	0.7200
Koşma	0.8000	0.8000	0.8000
Şınav	1.0000	1.0000	1.0000
Barfiks	1.0000	0.9091	0.9524
Squat	0.3000	0.7500	0.4286
Atlama	0.8000	0.8000	0.8000

Model, iki aktivite (Barfiks, Şınav) için mükemmel doğruluk (1.0000) sergilerken, koşma (0.8000), bisiklet (0.9000), atlama (0.8000) aktivitesi için biraz daha düşük bir doğruluk göstermiştir squat (0.3000) için çok düşük değer göstermiştir. Bu modelin duyarlılık değerleri için şınav (1.0000) hariç diğer branşlar biraz zayıf kalmaktadır (bisiklet (0.6000), koşma (0.8000), barfiks (0.9091), squat (0.7500), ip atlama (0.8000)) dir. Bu modelin F1-skordeğerleri için şınav (1.0000) hariç diğer branşlar biraz zayıf kalmaktadır (bisiklet (0.7200), koşma (0.8000), barfiks (0.9524), squat (0.4286), ip atlama (0.8000)) dir.

Tablo 33'de KNN karmaşık matris sonuçları verilmektedir.

Tablo 33. KNN karmaşıklık matrisi test sonuçları.

KNN	Bisiklet	Koşma	Şınav	Barfiks	Squad	İp Atlama	% Başarı
Bisiklet	10	0	0	0	0	0	100
Koşma	0	10	0	0	0	0	100
Şınav	0	0	10	0	0	0	100
Barfiks	0	0	0	10	0	0	100
Squa	0	0	0	1	9	0	90
İp Atlama	0	0	0	0	0	10	100

NB makine öğrenmesi modelinin karmaşıklık matrisi test sonuçlarına göre elde edilen ortalama doğruluk değeri **%98.33** olarak hesaplanmıştır. Tüm branşlarda 10 videonun 10'u %100 başarı sağlarken, bir adet squad test videosunda hatalı spor branşı tespit edilmiştir.

Tablo 34'de KNN için çeşitli test performans metriklerini göstermektedir. Tablo; doğruluk, duyarlılık ve F1-skoru gibi önemli performans ölçütlerini içermektedir.

Tablo 34. KNN test performans metrikleri.

Test/Metrik	Doğruluk	Duyarlılık	F1-Skor
Bisiklet	1.0000	1.0000	1.0000
Koşma	1.0000	1.0000	1.0000
Şınav	1.0000	1.0000	1.0000
Barfiks	1.0000	1.0000	1.0000
Squat	0.9000	1.0000	0.9474
Atlama	1.0000	0.9091	0.9524

Model, beş aktivite (Barfiks, Koşma, Atlama, Şınav ve Bisiklet) için mükemmel doğruluk (1.0000) sergilerken, yalnızca squat aktivitesi için biraz daha düşük bir doğruluk (0.9000) göstermektedir. Bu model için, atlama aktivitesi duyarlılık açısından bir miktar zayıf kalmaktadır (0.9091), ancak diğer aktiviteler için duyarlılık değeri mükemmeldir (1.0000). Modelin F1-skorumları, squat (0.9474) ve ip atlama (0.9524) aktiviteleri dışında 1.0000'dir, bu da modelin genelde çok yüksek performans gösterdiğini ifade eder. Bu modelin en dikkat çekici özelliği, neredeyse tüm aktivitelerde hatasız çalışmasıdır. Ancak bisiklet aktivitesinde ufak performans düşüklükleri gözlemlenmiştir.

Tablo 35'de ADA karmaşık matris sonuçları verilmektedir.

Tablo 35. ADA karmaşıklık matrisi test sonuçları.

ADA	Bisiklet	Koşma	Şınav	Barfiks	Squad	İp Atlama	% Başarı
Bisiklet	8	0	0	0	1	1	80
Koşma	2	8	0	0	0	0	80
Şınav	0	0	9	0	1	0	90
Barfiks	0	0	0	9	1	0	90
Squat	0	2	0	2	5	1	50
İp Atlama	0	0	0	0	0	10	100

ADA makine öğrenmesi modelinin karmaşıklık matrisi test sonuçlarına göre elde edilen ortalama doğruluk değeri **%81.67** olarak hesaplanmıştır. Test videolarından 2 adet bisiklet, 2 adet koşma, 1 adet Şınav, 1 adet barfiks, 5 adet squad videosu hatalı çıkmıştır.

Tablo 36’da ADA için çeşitli test performans metriklerini göstermektedir. Tablo; doğruluk, duyarlılık ve F1-skoru gibi önemli performans ölçütlerini içermektedir.

Tablo 36. ADA test performans metrikleri.

Test/Metrik	Doğruluk	Duyarlılık	F1-Skor
Bisiklet	0.8000	0.8000	0.8000
Koşma	0.8000	0.8000	0.8000
Şınav	0.9000	1.0000	0.9474
Barfiks	0.9000	0.8182	0.8571
Squat	0.5000	0.6250	0.5556
İp Atlama	1.0000	0.8333	0.9091

Bisiklet ve koşma aktiviteleri için modelin doğruluğu 0.8000 olarak belirtilmiştir. Bu, modelin bu aktiviteleri %80 doğrulukla tanıdığını göstermektedir. Duyarlılık değeri de bu aktiviteler için 0.8000 olup, modelin bu aktivitelerde pozitif duyarlılık açısından %20 hata yaptığını ifade etmektedir. Bu aktivitelerin F1-skorumları da 0.8000 olup, modelin bu aktivitelerdeki genel performansını göstermektedir. Şınav ve barfiks aktiviteleri için modelin doğruluğu 0.8000 olarak belirtilmiştir. Bu, modelin bu aktiviteleri %80 doğrulukla tanıdığını göstermektedir. Duyarlılık değeri de bu aktiviteler için 1.0000 ve 0.8182 olduğu gözlemlenmiştir. Bu aktivitelerin F1-skorumları da 0.9474 ve 0.8571 çıkmıştır. Squat ve ip atlama aktiviteleri için modelin doğruluğu sırasıyla 0.5000 ve 1.0000 olarak belirtilmiştir. Duyarlılık değeri de bu aktiviteler için 0.6250 ve 0.8333 olduğu gözlemlenmiştir. Bu aktivitelerin F1-

skorları da 0.5556 ve 0.9091 çıkmıştır. En iyi doğruluk değerinin ip atlama çıktığı gözlemlenmiştir.

Tablo 37’de DT karmaşık matris sonuçları verilmektedir.

Tablo 37. DT karmaşıklık matrisi test sonuçları.

DT	Bisiklet	Koşma	Şınav	Barfiks	Squad	İp Atlama	% Başarı
Bisiklet	9	0	0	0	1	0	90
Koşma	0	10	0	0	0	0	100
Şınav	0	0	7	0	2	1	70
Barfiks	0	0	0	8	0	2	80
Squat	0	0	0	0	9	1	90
İp Atlama	0	0	0	0	0	10	100

DT makine öğrenmesi modelinin karmaşıklık matrisi test sonuçlarına göre elde edilen ortalama doğruluk değeri **%84.13** olarak hesaplanmıştır. Test videolarından 1 adet bisiklet, 3 adet Şınav, 2 adet barfiks, 1 adet squad videosu hatalı çıkmıştır.

Tablo 40’da DT için çeşitli test performans metriklerini göstermektedir. Tablo; doğruluk, duyarlılık ve F1-skoru gibi önemli performans ölçütlerini içermektedir.

Tablo 38. DT test performans metrikleri.

Test/Metrik	Doğruluk	Duyarlılık	F1-Skor
Bisiklet	0.9000	1.0000	0.9474
Koşma	1.0000	1.0000	1.0000
Şınav	0.7000	1.0000	0.8235
Barfiks	0.8000	1.0000	0.8889
Squat	0.9000	0.7500	0.8182
Atlama	1.0000	0.7143	0.8333

Model, iki aktivite (Koşma, Atlama) için mükemmel doğruluk (1.0000) sergilerken, (Squat, Bisiklet) aktivitesi için biraz daha düşük bir doğruluk (0.9000) göstermektedir. Onları takip eden barfiks (0.8000) ve şınav (0.7000) daha düşük performans vermektedir. Bu model için, atlama ve squat aktivitesi duyarlılık açısından diğer branşlara göre bir miktar zayıf kalmaktadır (0.7500) ve (0.7143), ancak diğer aktiviteler için duyarlılık değeri mükemmeldir (1.0000). Modelin F1-skorları, koşma (1.0000) dışında düşük kalmıştır. Bu da modelin genelde çok yüksek performans gösterdiğini ifade eder. Atlama ve koşma aktivitelerinde doğruluk değerlerinin tam performansta çıktığı gözlemlenmiştir.

Tablo 39’da SVC karmaşık matris sonuçları verilmektedir.

Tablo 39. SVC karmaşıklık matrisi test sonuçları.

SVC	Bisiklet	Koşma	Şınav	Barfiks	Squad	İp Atlama	% Başarı
Bisiklet	10	0	0	0	0	0	100
Koşma	0	10	0	0	0	0	100
Şınav	0	0	10	0	0	0	100
Barfiks	0	0	0	10	0	0	100
Squat	0	0	0	0	9	1	90
İp Atlama	0	0	0	0	0	10	100

SVC makine öğrenmesi modelinin karmaşıklık matrisi test sonuçlarına göre elde edilen ortalama doğruluk değeri **%98.33** olarak hesaplanmıştır. Test videolarından bir adet squad videosu hatalı çıkmıştır.

Tablo 40’da SVC için çeşitli test performans metriklerini göstermektedir. Tablo; doğruluk, duyarlılık ve F1-skoru gibi önemli performans ölçütlerini içermektedir.

Tablo 40. SVC test performans metrikleri.

Test/Metrik	Doğruluk	Duyarlılık	F1-Skor
Bisiklet	1.0000	1.0000	1.0000
Koşma	1.0000	1.0000	1.0000
Şınav	1.0000	1.0000	1.0000
Barfiks	1.0000	1.0000	1.0000
Squat	0.9000	1.0000	0.9474
Atlama	1.0000	0.9091	0.9524

Model, beş aktivite (Barfiks, Koşma, Atlama, Şınav ve Bisiklet) için mükemmel doğruluk (1.0000) sergilerken, yalnızca squat aktivitesi için biraz daha düşük bir doğruluk (0.9000) göstermektedir. Bu model için, atlama aktivitesi duyarlılık açısından bir miktar zayıf kalmaktadır (0.9091), ancak diğer aktiviteler için duyarlılık değeri mükemmeldir (1.0000). Modelin F1-skorları, squat (0.9474) ve ip atlama (0.9524) aktiviteleri dışında 1.0000’dir, bu da modelin genelde çok yüksek performans gösterdiğini ifade eder. Bu modelin en dikkat çekici özelliği, neredeyse tüm aktivitelerde hatasız çalışmasıdır. Ancak bisiklet aktivitesinde ufak performans düşüklükleri gözlemlenmiştir.

Tablo 43’de Modellerin karmaşık matris sonuçları verilmektedir.

Tablo 41. Test verilerinin kategori bazlı model doğruluk oranları

	RC(%)	RF(%)	DT(%)	GB(%)	KNN(%)	SVC(%)	ADA(%)	LR(%)	NB(%)
Bisiklet	100.00	100.00	90.00	100.00	100.00	100.00	80.00	100.00	90.00
Koşma	70.00	100.00	100.00	80.00	100.00	100.00	80.00	100.00	80.00
Şınav	100.00	100.00	70.00	100.00	100.00	100.00	90.00	90.00	100.00
Barfiks	100.00	100.00	80.00	100.00	100.00	100.00	90.00	90.00	100.00
Squat	100.00	90.00	90.00	100.00	90.00	90.00	50.00	100.00	30.00
Atlama	100.00	100.00	100.00	100.00	100.00	100.00	100.00	100.00	80.00
GO	95.00	98.33	84.13	96.67	98.33	98.33	81.67	96.67	80.00

Tablo 41’de verilen modele göre spor türü test doğruluk oranları incelendiğinde **KNN**, **RF** ve **SVC** makine öğrenmesi modelleri 6 spor türünde en yüksek başarımlarına ulaşarak ortalama en başarılı model olarak saptanmıştır. **NB** makine öğrenmesi modeli ise en düşük model olarak saptanmıştır.

4.3. Hareket Sayaç Sonuçları

Bu bölümde hareket sayaç sonuçları verilmektedir. Spor branşları için model örneği en iyi çıkan KNN makine öğrenmesi modeli kullanılmıştır. Bununla birlikte, gerçek hareket sayısı ve program çıktısı karşılaştırılarak doğruluk değerleri hesaplanmıştır.

Tablo 43’de squat hareket sayacı sonuçları verilmektedir.

Tablo 42. Squat test videolarından elde edilen hareket sayaç sonuçları.

Squat hareket Türü video	Gerçek hareket Sayısı	Program Çıktısı	(%) Doğruluk	Video Süresi(sn)	Bir Dakikada Yapılan hareket Sayısı
1	2	2	100	5,57	21
2	2	2	100	4,83	24
3	3	2	66.3	4,60	26
4	7	6	85.7	13,52	31
5	3	3	100	5,43	33
6	3	3	100	5,13	35
7	6	5	83.3	10,17	35
8	6	3	50	8,97	40
9	4	4	100	5,43	44
10	11	7	66.3	12,48	52

Squat hareket sayacı ortalama doğruluk değeri **%84.83** çıkmıştır.

Tablo 44’de Koşma Hareket Sayacı Sonuçları verilmektedir.

Tablo 43. Koşma test videolarından elde edilen hareket sayaç sonuçları.

Koşma hareket Türü video	Gerçek hareket Sayısı	Program Çıktısı	(%) Doğruluk	Video Süresi(sn)	Bir Dakikada Yapılan hareket Sayısı
1	7	7	100	4.27	98
2	14	14	100	4.3	208
3	20	11	55	4.73	253
4	13	12	92.30	4.5	172
5	17	17	100	5.43	226
6	25	18	72	4.47	335
7	15	12	80	4.73	190
8	11	8	73.3	4.6	104
9	9	9	100	3.17	170
10	25	20	80	4.53	331

Koşma hareket sayacı ortalama doğruluk değeri **%85.26** çıkmıştır.

Tablo 45’de şınav hareket sayacı sonuçları verilmektedir.

Tablo 44. Şınav test videolarından elde edilen hareket sayaç sonuçları.

Şınav hareket Türü video	Gerçek hareket Sayısı	Program Çıktısı	(%) Doğruluk	Video Süresi(sn)	Bir Dakikada Yapılan hareket Sayısı
1	12	11	91	8.3	79
2	8	6	75	7.2	66
3	4	4	100	8.8	27
4	3	3	100	3.47	51
5	6	6	100	7.73	46
6	5	4	80	7.53	39
7	12	9	75	7.7	70
8	3	3	100	5.63	42
9	9	9	100	6.43	90
10	6	6	100	4.53	32

Şınav hareket sayacı ortalama doğruluk değeri **%92.1** çıkmıştır.

Tablo 48’de bisiklet hareket sayacı sonuçları verilmektedir.

Tablo 45. Bisiklet test videolarından elde edilen hareket sayaç sonuçları.

Bisiklet hareket Türü video	Gerçek hareket Sayısı	Program Çıktısı	(%) Doğruluk	Video Süresi(sn)	Bir Dakikada Yapılan hareket Sayısı
1	4	4	100	4.7	51
2	5	5	100	4.4	68
3	5	5	100	3.27	91
4	9	8	88	3.47	114
5	9	7	77	4.23	127
6	5	4	80	4.7	51
7	13	13	100	4.03	112
8	5	4	80	4.8	50
9	6	5	83	4.77	75
10	9	4	44	4.87	110

Bisiklet hareket sayacı ortalama doğruluk değeri % 85.2 çıkmıştır.

Tablo 49’da barfiks hareket sayacı sonuçları verilmektedir.

Tablo 46. Barfiks test videolarından elde edilen hareket sayaç sonuçları

Barfiks hareket Türü video	Gerçek hareket Sayısı	Program Çıktısı	(%) Doğruluk	Video Süresi(sn)	Bir Dakikada Yapılan hareket Sayısı
1	3	3	100	4.77	37
2	4	3	75	4.2	57
3	5	4	80	5.1	58
4	4	4	100	4.57	52
5	4	3	75	4.67	38
6	4	4	100	4.8	50
7	5	5	100	4.7	63
8	5	4	80	4.47	67
9	4	4	100	4.03	59
10	6	4	66	4.2	75

Barfiks hareket sayacı ortalama doğruluk değeri % 87.6 çıkmıştır.

Tablo 50’de ip atlama hareket sayacı sonuçları verilmektedir.

Tablo 47. İp Atlama test videolarından elde edilen hareket sayaç sonuçları

İp Atlama hareket Türü video	Gerçek hareket Sayısı	Program Çıktısı	(%) Doğruluk	Video Süresi(sn)	Bir Dakikada Yapılan hareket Sayısı
1	17	17	100	12.07	84
2	20	17	85	8.73	137
3	5	5	100	2.93	102
4	13	9	69	5.7	136
5	21	16	76	8.63	146
6	16	14	76	8.03	119
7	22	13	59	9.03	146
8	16	16	100	8	127
9	13	11	84	6.63	117
10	33	26	78	12.37	160

İp atlama hareket sayacı ortalama doğruluk değeri % **82.7** çıkmıştır.

Tablo 48. Hareket sayacı sonuçları.

	Squat(%)	Koşma(%)	Şınav(%)	Bisiklet(%)	Barfiks(%)	İp Atlama(%)
GO	84.83	85.26	92.1	85.2	87.6	82.7

Tablo 48’de verilen hareket sayacı sonuçlarına göre **Şınav** modeli 6 spor türünde en yüksek hareket sayacı başarı oranına ulaşarak ortalama en başarılı spor türü olarak saptanmıştır.

İp atlama ise en düşük spor türü olarak saptanmıştır.

4.4. Dakikadaki Hareket Sayısına Göre MET Değeri

Tablo 51’de dakikadaki hareket sayısına göre MET değerleri verilmektedir. Bu tablonun oluşturulmasında online kalori hesaplama web sayfasındaki değerler kullanılmaktadır (*Yakılan Kalori Hesabı*, 2024). Spor branşına göre belirlenen, 1 dakikada harcanan kalori, video süresi ve kullanıcının dışardan girdiği kilo değerleri kullanılarak kalori hesaplama formülümüzde yerine yazılıp MET değerleri hesaplanmaktadır.

Örnek olarak;

Koşma branşında yavaş koşmada 1 dakikada yakılan kalori 9.6 kaloridir, video süresi 4.7 saniye ve kilo değeri 70’dir.Bu kaloriyi formülde yerine yazdığımız zaman yavaş koşma met değeri Eşitlik 1’deki denklemle bulunur ve met sonuç değeri elde edilir. Eşitlik 2’de ise yavaş koşma met değeri sayısal olarak bulunmuştur.

$$9.6 = \frac{(4.7 * MET * 70)}{2000} (1)$$

$$MET = 5.83 (2)$$

Koşma branşında orta koşmada 1 dakikada yakılan kalori 12 kaloridir, video süresi 4.7 saniye ve kilo değeri 70'dir. Bu kaloriyi formülde yerine yazdığımız zaman orta koşma met değeri Eşitlik 1'deki denklemle bulunur ve met sonuç değeri elde edilir. Eşitlik 2'de ise orta koşma met değeri sayısal olarak bulunmuştur.

$$12 = \frac{(4.7 * MET * 70)}{2000} (1)$$

$$MET = 7.29 (2)$$

Koşma branşında hızlı koşmada 1 dakikada yakılan kalori 9.6 kaloridir, video süresi 4.7 saniye ve kilo değeri 70'dir. Bu kaloriyi formülde yerine yazdığımız zaman hızlı koşma met değeri Eşitlik 1'deki denklemle bulunur ve met sonuç değeri elde edilir. Eşitlik 2'de ise hızlı koşma met değeri sayısal olarak bulunmuştur. Bu çalışmada bulunan MET değerlerinin, internet kaynaklarında yer alan MET değerleriyle yakın değerler çıktığı tespit edilmiştir (*Yapılan Sporun Metabolik Eş Değeri*, 2024).

$$19 = \frac{(4.7 * MET * 70)}{2000} (1)$$

$$MET = 11.55 (2)$$

Bu hesaplamalara göre Tablo'49 da verilen değerler elde edilmiştir.

Tablo 49. Dakikadaki hareket sayısına göre MET değeri

Spor Sınıfları	Yavaş		Orta		Hızlı	
	Aralık	MET	Aralık	MET	Aralık	MET
Barfiks	0 - 30	1.82	30 - 60	2.43	>200	5.47
Koşma	0 - 100	5.83	100 - 200	7.29	>200	11.55
Atlama	0 - 50	5.65	50 - 100	7.11	>100	8.51
Bisiklet	0 - 100	5.83	100 - 200	7.29	>60	8.51
Squat	0 - 30	1.82	30 - 60	2.43	>60	5.47
Bisiklet	0 - 30	1.82	30 - 45	2.43	>45	5.47

BEŞİNCİ BÖLÜM

5. SONUÇLAR ve ÖNERİLER

Bu tez çalışmasında egzersiz videoları üzerinden video sınıflandırma ve yakılan kalori hesaplama çalışmaları yapılmıştır. Dokuz farklı makine öğrenmesi modeli ile video sınıflandırma yapılarak bu yöntemlerin performansları karşılaştırılmıştır. Eğitim verilerinde en yüksek performansı KNN makine öğrenmesi modeli gösterirken, en düşük performansı NB öğrenmesi modeli göstermiştir. Test verilerinde ise en yüksek performansı KNN, RF ve SVC öğrenmesi modelleri gösterirken, en düşük performansı yine NB makine öğrenmesi modeli göstermiştir. Hareket sayacı sonuçlarında, sınav aktivitesi en doğru sonuçları verirken, en düşük sonuç ip atlama aktivitesinden elde edilmiştir. Video sınıflandırma ve hareket sayacı takibi yaparak kullandığımız modeller ve yapılan deneysel çalışmalar sayesinde kalori yakımı hesaplanmıştır.

Bu çalışma, farklı alanlarda çeşitli kullanılma potansiyeline sahiptir. Egzersiz yardımcısı olarak egzersiz yapmak isteyen bireylere yardımcı olmak için kullanılabilir. Kullanıcılar, egzersizlerini izlerken ve kalori yakımını takip ederken bu sistemi kullanabilirler. Fitness uygulamalarında kullanıcıların egzersizlerini izlemelerine ve ilerlemelerini takip etmelerine yardımcı olmak için bu teknolojiyi kullanılabilir. Egzersizlerin doğru bir şekilde yapıldığını doğrulamak ve kalori yakımını hesaplamak için kullanılabilir. Sağlık ve rehabilitasyon alanında sağlık profesyonelleri, hastaların egzersiz programlarını izlemek ve önerilen egzersizleri düzgün bir şekilde yapmalarını sağlamak için bu teknolojiyi kullanabilirler. Rehabilitasyon süreçlerini iyileştirebilirler. Bireyler, genel sağlık ve kondisyonlarını izlemek için kişisel sağlık takibinde bu teknolojiyi kullanılabilir. Egzersiz fizyolojisi ve kalori hesaplaması konularında eğitim veren kurumlar ve eğitmenler, bu teknolojiyi öğrencilere ve katılımcılara öğretim materyali olarak kullanabilirler. Spor takımları ve antrenörler, sporcuların egzersizlerini izleyerek performanslarını artırmak ve sakatlık riskini azaltmak için bu teknolojiyi kullanabilirler. Bu çalışma, egzersiz yapmanın ötesinde, günlük aktivitelerin takibi, enerji harcaması tahmini ve daha fazlası için kullanılabilir.

Video sınıflandırma ve hareket sayacı teknolojisinin performansını artırmak için veri çeşitliliğinin artırılması önemlidir. Farklı yaş grupları, cinsiyetler ve fitness seviyelerinden veri toplanarak modelin genelleştirilebilirliği artırılabilir. Kullanıcıların egzersizlerini doğru yapmalarını sağlamak için gerçek zamanlı geribildirim mekanizmaları eklenebilir, böylece hareketlerini anında düzeltebilirler. Kullanıcı dostu bir arayüz, hareket tanıma sonuçlarını ve

kalori yakımını görselleştiren grafikler ve raporlarla desteklenebilir. Adaptif öğrenme algoritmaları, kullanıcının egzersiz rutinini öğrenerek kişiselleştirilmiş öneriler sunabilir.

Birden fazla egzersizi aynı anda tanıyan sistemler geliştirilebilir. Örneğin, bir kullanıcının hem koşu hem de ağırlık kaldırma gibi farklı egzersizleri yapması durumunda, bu aktiviteleri ayrı ayrı analiz eden sistemler faydalı olabilir. Giyilebilir cihazlarla entegrasyon, daha hassas veri toplanmasını ve kalori yakımının doğru hesaplanmasını sağlar. Kullanıcıların egzersiz sonuçlarını sosyal medyada paylaşmalarına ve rekabet etmelerine olanak tanıyan özellikler, motivasyonu artırabilir. Kalori hesaplama algoritmaları, kişisel verilere ve egzersiz süresine dayalı olarak daha hassas hale getirilebilir. Akademik kurumlar ve fitness uzmanlarıyla iş birlikleri yapılarak sistemin güvenilirliği ve geçerliliği artırılabilir. Son olarak, bireysel ihtiyaçlara göre özelleştirilebilir egzersiz programları sunularak kullanıcıların hedeflerine ulaşmalarına yardımcı olunabilir. Bu öneriler, video sınıflandırma ve hareket sayacı teknolojisinin daha etkili ve kullanıcı dostu hale gelmesine katkıda bulunabilir.

KAYNAKÇA

- 33 Key Points Detected on the Human Body by MediaPipe (2024). Available at: https://www.researchgate.net/figure/33-Landmarks-detected-on-the-human-body-using-MediaPipe_fig2_361071987.
- Abdallah, M. S. v.d. (2022) 'Light-weight deep learning techniques with advanced processing for real-time hand gesture recognition', *Sensors*. MDPI, 23(1), p. 2.
- Akamine, M. & Ajmera, J. (2011) 'Decision tree-based acoustic models for speech recognition with improandd smoothness', *IEICE TRANSACTIONS on Information and Systems*. The Institute of Electronics, Information and Communication Engineers, 94(11), pp. 2250–2258.
- Amprimo, G. v.d. (2022) 'Gmh-d: Combining google mediapipe and rgb-depth cameras for hand motor skills remote assessment', in 2022 IEEE International Conference on Digital Health (ICDH), pp. 132–141.
- Andrian, B. W. v.d. (2023) 'Implementation Of and Bayes Algorithm In Sentiment Analysis Of Twitter Social Media Users Regarding Their Interest To Pay The Tax', *International Journal of Science, Technology \& Management*, 4(6), pp. 1733–1742.
- Batan, I. S. v.d. (2023) 'Calorie Burn Estimator on Stationary Bike using Human Body Pose Detector', in 2023 International Seminar on Intelligent Technology and Its Applications (ISITIA), pp. 125–129.
- Boateng, E. Y., Abaye, D. A. v.d. (2019) 'A review of the logistic regression model with emphasis on medical research', *Journal of data analysis and information processing*. Scientific Research Publishing, 7(04), p. 190.
- Brereton, R. G. & Lloyd, G. R. (2010) 'Support andctor machines for classification and regression', *Analyst*. Royal Society of Chemistry, 135(2), pp. 230–267.
- Byeon, H. (2020) 'Is the random forest algorithm suitable for predicting parkinson's disease with mild cognitand impairment out of parkinson's disease with normal cognition', *International journal of environmental research and public health*. MDPI, 17(7), p. 2594.
- Cao, H. E. C., Sarlin, R. & Jung, A. (2020) 'Learning explainable decision rules via maximum satisfiability', *Ieee Access*. IEEE, 8, pp. 218180–218185.
- Chen, S. v.d. (2021) 'Modeling quality changes in Pacific white shrimp (*Litopenaeus vannamei*) during storage: Comparison of the Arrhenius model and Random Forest model', *Journal of Food Processing and Preservation*. Wiley Online Library, 45(1), p. e14999.
- Chen, Y. & Liu, X. (2023) 'Design of Fitness Moandment Detection and Counting System Based on MediaPipe', in International Conference of Pioneering Computer Scientists, Engineers and Educators, pp. 77–92.
- Christodoulou, E. v.d. (2019) 'A systematic review shows no performance benefit of machine learning oandr logistic regression for clinical prediction models', *Journal of clinical epidemiology*. Elsevier, 110, pp. 12–22.
- Doan, T.-N. (2022) 'An efficient patient activity recognition using LSTM network and high-fidelity body pose tracking', *International Journal of Advanced Computer Science and Applications*. Science and Information (SAI) Organization Limited, 13(8).
- Fan, S., Guo, K. & Sun, Y. (2022) 'LaBelle: A Deep Learning APP that Helps You Learn Ballet', pp. 135–146. doi: 10.5121/csit.2022.121714.
- Gao, Q. & Lantz, N. (2022) 'Using Machine Learning Algorithms to Detect Fake News', *Journal of Student Research*, 11(4).
- Gijbels, I., Andrasselt, A. & Vrinssen, I. (2015) 'Variable selection using P-splines', *Wiley Interdisciplinary Reviews: Computational Statistics*. Wiley Online Library, 7(1), pp. 1–20.
- Gopal, A. (2023) "'Self-care Selfies": Patient-uploaded Videos Capture Meaningful Changes in Dexterity Oandr 6 months', *Annals of Clinical and Translational Neurology*. doi:

10.1002/acn3.51928.

Gu, F. v.d. (2022) 'Automatic detection of abnormal hand gestures in patients with radial, ulnar, or median nerand injury using hand pose estimation', *Frontiers in Neurology*. Frontiers Media SA, 13, p. 1052505.

Hong, W. S., Haimovich, A. D. & Taylor, R. A. (2018) 'Predicting hospital admission at emergency department triage using machine learning', *PloS one*. Public Library of Science San Francisco, CA USA, 13(7), p. e0201016.

Hussein, i. s. & Ahmed, b. a. (2021) 'calculated calories for training and their effect on deandloping some physical and biomechanical abilities and achieving 400-meter run for youth', *European journal of physical education and sport science*, 6(10).

Jaiswal, A. (2023) 'Using Learnable Physics for Real-Time Exercise Form Recommendations'. doi: 10.1145/3604915.3608816.

Janssens, D. v.d. (2004) 'Improving performance of multiagent rule-based model for activity pattern decisions with Bayesian networks', *Transportation Research Record*. SAGE Publications Sage CA: Los Angeles, CA, 1894(1), pp. 75–83.

Janssens, D. v.d. (2006) 'Integrating Bayesian networks and decision trees in a sequential rule-based transportation model', *European Journal of operational research*. Elsevier, 175(1), pp. 16–34.

Jebur, S. A. v.d. (2022) 'Review on deep learning approaches for anomaly eandnt detection in video surandillance', *Electronics*. MDPI, 12(1), p. 29.

Jeong, S. & Kook, J. (2023) 'CREBAS: computer-based REBA evaluation system for wood manufacturers using MediaPipe', *Applied Sciences*. MDPI, 13(2), p. 938.

Kakizaki, M. v.d. (2024) 'Dynamic Japanese Sign Language Recognition Throw Hand Pose Estimation Using Effectiand Feature Extraction and Classification Approach', *Sensors*. MDPI, 24(3), p. 826.

Kang, J. v.d. (2022) 'Detection enhancement for various deepfake types based on residual noise and manipulation traces', *IEEE Access*. IEEE, 10, pp. 69031–69040.

Kim, M.-K. v.d. (2022) 'Deandlopment and Validation of Simplified Delirium Prediction Model in Intensiand Care Unit', *Frontiers in Psychiatry*. Frontiers, 13, p. 886186.

Kocakulak, M. & Acir, N. (2023) 'A Contactless Palmprint Imaging System Design Using Mediapipe Hands', *Journal of Innovatiand Science and Engineering*. Bursa Technical Uniandrsity, 7(1), pp. 29–39.

Kumar, B. v.d. (2021) 'An analysis of Indian agricultural workers: a ridge regression approach', *Agricultural Economics Research Review*. Agricultural Economics Research Association, 34(1), pp. 121–127.

Lee, Y. v.d. (2021) 'Machine learning-based prediction of acute kidney injury after nephrectomy in patients with renal cell carcinoma', *Scientific reports*. Nature Publishing Group UK London, 11(1), p. 15704.

Leone, A. v.d. (2022) 'Ambient and wearable sensor technologies for energy expenditure quantification of ageing adults', *Sensors*. MDPI, 22(13), p. 4893.

Li, D. v.d. (2022) 'Noandl ensemble intelligence methodologies for rockburst assessment in complex and variable environments', *Scientific reports*. Nature Publishing Group UK London, 12(1), p. 1844.

Li, X. v.d. (2022) 'Fitness Action Counting Based on MediaPipe', in *2022 15th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI)*, pp. 1–7.

Lin, Y., Jiao, X. & Zhao, L. (2023) 'Detection of 3d human posture based on improandd mediapipe', *Journal of Computer and Communications*. Scientific Research Publishing, 11(2), pp. 102–121.

Luangaphirom, T. v.d. (2024) 'Real-time weight training counting and correction using

MediaPipe', *Advances in Computational Intelligence*. Springer, 4(2), p. 3.

Lubis, A. R., Lubis, M. v.d. (2020) 'Optimization of distance formula in K-Nearest Neighbor method', *Bulletin of Electrical Engineering and Informatics*, 9(1), pp. 326–338.

Maillo, J. v.d. (2017) 'kNN-IS: An Iteratiand Spark-based design of the k-Nearest Neighbors classifier for big data', *Knowledge-Based Systems*. Elsevier, 117, pp. 3–15.

Mienye, I. D. & Sun, Y. (2022) 'A surandy of ensemble learning: Concepts, algorithms, applications, and prospects', *IEEE Access*. IEEE, 10, pp. 99129–99149.

Muduli, K. & Ghosh, I. (2023) 'Prediction of the future state of pedestrians while jaywalking under non-lane-based heterogeneous traffic conditions', *Transportation research record*. SAGE Publications Sage CA: Los Angeles, CA, 2677(10), pp. 554–571.

Muhammad, N. H. v.d. (2022) 'Mono Camera-based Human Skeletal Tracking for Squat Exercise Abnormality Detection using Double Exponential Smoothing', *International Journal of Advanced Computer Science and Applications*. Science and Information (SAI) Organization Limited, 13(7).

Myles, A. J. v.d. (2004) 'An introduction to decision tree modeling', *Journal of Chemometrics: A Journal of the Chemometrics Society*. Wiley Online Library, 18(6), pp. 275–285.

Pauzi, A. S. B. v.d. (2021) 'Moandment estimation using mediapipe blazepose', in *Advances in Visual Informatics: 7th International Visual Informatics Conference, IVIC 2021, Kajang, Malaysia, Noandmber 23--25, 2021, Proceedings 7*, pp. 562–571.

Qi, F., Zhang, X.-J. and Li, W.-H. (2013) 'Some Bernstein functions and integral representations concerning harmonic and geometric means', *arXiv preprint arXiv:1301.6430*.

Rathnayake, N. vd. (2023) 'Water leandl prediction using soft computing techniques: A case study in the Malwathu Oya, Sri Lanka', *Plos one*. Public Library of Science San Francisco, CA USA, 18(4), p. e0282847.

Rebala, G. vd. (2019) 'Random forests', *An Introduction to Machine Learning*. Springer, pp. 77–94.

Religia, Y. R., Pranoto, G. T. & Suwancita, I. M. (2021) 'Analysis of the Use of Particle Swarm Optimization on and Bayes for Classification of Credit Bank Applications', *JISA (Jurnal Informatika dan Sains)*, 4(2), pp. 133–137.

Romindo, R. vd. (2022) 'Implementasi Algoritma Support Andctor Machine Terhadap Klasifikasi Pose Balet', *Building of Informatics, Technology and Science (BITS)*, 4(3), pp. 1558–1566.

Sadiq, B. H. & Abdulazeez, A. M. (2024) 'Facial Beauty Standards Predictions Based on Machine Learning: A Comparatiand Analysis', *Indonesian Journal of Computer Science*, 13(1).

Saleem, S., Nunes, J. vd. (2023) 'TrainERAI-Liand Gym Tracker using Artificial Intelligence'.

Samaan, G. H. vd. (2022) 'Mediapipe's landmarks with rnn for dynamic sign language recognition', *Electronics*. MDPI, 11(19), p. 3228.

Shaikh, S. vd. (2023) 'Sign Language Based Video Calling App'.

Shwed, A. vd. (2023) 'Inandstigating the Impact of Food Rewards on Children's Motivation to Participate in Sport', *Children*. MDPI, 10(3), p. 432.

Stenum, J., Rossi, C. & Roemmich, R. T. (2021) 'Two-dimensional video-based analysis of human gait using pose estimation', *PLoS computational biology*. Public Library of Science San Francisco, CA USA, 17(4), p. e1008935.

Taniguchi, H. vd. (2015) 'Causal cognition and spam classifier', in *AIP Conference Proceedings*, p. 580002.

Taware, G. vd. (2022) 'AI-based Workout Assistant and Fitness guide', in *2022 6th International Conference On Computing, Communication, Control And Automation*

(ICCUBEA, pp. 1–4.

Thaman, B., Cao, T. & Caporusso, N. (2022) ‘Face mask detection using mediapipe facemesh’, in 2022 45th Jubilee International Conandntion on Information, Communication and Electronic Technology (MIPRO), pp. 378–382.

Tomar, Y. vd. (2023) ‘Human Motion Tracker using OpenCv and Mediapipe’, in 2023 3rd International Conference on Innovatiand Mechanisms for Industry Applications (ICIMIA), pp. 1199–1204.

Wang, L. vd. (2018) ‘Temporal segment networks for action recognition in videos’, IEEE transactions on pattern analysis and machine intelligence. IEEE, 41(11), pp. 2740–2755.

Wang, T. & Li, W. (2010) ‘Naiand bayes software defect prediction model’, in 2010 International conference on computational intelligence and software engineering, pp. 1–4.

Xie, Z. v.d. (2002) ‘Snnb: A selectiand neighborhood based naiand Bayes for lazy learning’, in Advances in Knowledge Discoandry and Data Mining: 6th Pacific-Asia Conference, PAKDD 2002 Taipei, Taiwan, May 6--8, 2002 Proceedings 6, pp. 104–114.

Yakılan Kalori Hesabı (2024). Available at: <https://www.calculator.net/calorie-calculator.html>.

Yapılan Sporun Metebolik Eş Değeri (2024). Available at: https://en.wikipedia.org/wiki/Metabolic_equivalent_of_task.

Yanuar, F., Tillah, M. and Devianto, D. (no date) ‘Modeling of Human Deandlopment Index Using Ridge Regression Method. EKSAKTA [Internet].

Yapılan Sporun Metebolik Eş Değeri (2024). Available at: https://en.wikipedia.org/wiki/Metabolic_equivalent_of_task.

Zhang, F. v.d. (2020) ‘Mediapipe hands: On-device real-time hand tracking’, arXiv preprint arXiv:2006.10214.

Zhang, S. v.d. (2022) ‘Human deep squat detection method based on MediaPipe combined with Yolov5 network’, in 2022 41st Chinese Control Conference (CCC), pp. 6404–6409.

Zhang, X. v.d. (2019) ‘Risk prediction of dyslipidemia for Chinese Han adults using random Forest survival model’, Clinical epidemiology. Taylor & Francis, pp. 1047–1055.

ÖZGEÇMİŞ

Adı Soyadı: Kaan Kubilay ÖZDEMİR

Eğitim ve Mesleki Geçmişi:

- Samsun Üniversitesi, Lisansüstü Eğitim Enstitüsü, Yazılım Mühendisliği (YL) (05.08.2022-), Samsun
- Zonguldak Bülent Ecevit Üniversitesi, Of Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü Mezunu (02.02.2022), Zonguldak
- Sampa Automotive, Yazılım Mühendisi (01-07.2020), Samsun (Stajyer)
- Web Beyaz İnternet Hizmetleri, Yazılım Geliştirici, (Tem 2023- Eyl 2023), Samsun
- Wima Bilişim Teknolojileri, Yazılım Geliştirici (Ara 2023- Nis 2024), Samsun

Yayınlar:

- Video-Based Exercise Recognition and Calorie Burn Estimation (Değerlendirme Aşamasında)