

T.C.
İSTANBUL KÜLTÜR ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YAPAY ZEKA TABANLI TEMEL HAREKET BECERİLERİ
ÖLÇÜM SİSTEMİ

YÜKSEK LİSANS TEZİ
MURAT TAŞAR SU
2100003325

Anabilim Dalı: Bilgisayar Mühendisliği
Programı: Bilgisayar Mühendisliği

Tez Danışmanı: Doç. Dr. Akhan Akbulut

HAZİRAN 2024

T.C.
İSTANBUL KÜLTÜR ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YAPAY ZEKA TABANLI TEMEL HAREKET BECERİLERİ
ÖLÇÜM SİSTEMİ

YÜKSEK LİSANS TEZİ
MURAT TAŞAR SU
2100003325

Anabilim Dalı: Bilgisayar Mühendisliği
Programı: Bilgisayar Mühendisliği

Tez Danışmanı: Doç. Dr. Akhan Akbulut
Jüri Üyesi: Dr. Öğr. Üyesi Öznur Şengel
Jüri Üyesi: Doç. Dr. Can Eyüpoğlu

HAZİRAN 2024

ÖNSÖZ

Tez çalışmamdaki katkıları ve desteğinden dolayı değerli hocam, tez danışmanım Doç. Dr. Akhan AKBULUT'a çok teşekkür ederim. Her daim yanımda olan ve desteğini benden hiç esirgemeyen sevgili eşim Ayşe TAŞARŞU'ya ve tüm aileme çok teşekkür ederim. Bu çalışma 1001 spor araştırmaları çağrısı kapsamında kabul edilen 121E688 numaralı proje olarak TÜBİTAK tarafından desteklenmiştir, projede emeği geçen tüm hocalarım ve takım arkadaşlarıma teşekkür ederim. Bu çalışmada hazırlanan yapay zeka modellerinin Yüksek Performanslı Hesaplama Laboratuvarında (HPC) eğitilmesine imkan sağlayan İstanbul Kültür Üniversitesi'ne teşekkür ederim.

HAZİRAN 2024

Murat TAŞARŞU

İÇİNDEKİLER

ÖNSÖZ.....	i
İÇİNDEKİLER.....	ii
KISALTMALAR	v
TABLO LİSTESİ.....	vi
ŞEKİL LİSTESİ.....	vii
ÖZET.....	viii
ABSTRACT	ix
1. GİRİŞ	1
1.1. Problemin Tanımı.....	2
1.2. Tezin Amacı ve Hipotez.....	3
1.3. Literatüre Katkıları.....	4
1.4. Tezin Organizasyonu	4
2. TEMEL BİLGİLER VE LİTERATÜR TARAMASI	5
2.1. Literatür Taraması.....	7
3. YÖNTEM.....	15
3.1. Gereksinimler	15
3.1.1. Fonksiyonel Gereksinimler	15
3.1.2. Fonksiyonel Olmayan Gereksinimler	16
3.2. Kullanım Senaryosu	17
3.2.1. Masaüstü Programı Kullanım Senaryosu	17
3.2.2. Backend Programı Kullanım Senaryosu	18
3.3. Kinect Sensör	19
3.4. Veri Toplama Uygulaması.....	22
3.5. Veri İşleme	29
3.6. Toplanan Verilerden Örnekler	32
4. SINIFLANDIRICI YAPAY ÖĞRENME MODELLERİ.....	35
4.1. Veri Seti Oluşturma.....	35
4.2. Dosyaların Dönüştürülmesi.....	37
4.3. Modeller	38
4.3.1. Model 1: CNN LSTM Modeli	39
4.3.2. Model 2: Pretrained LSTM Modeli	41
4.4. Videoları Kullanıma Hazırlama.....	44

5. BULGULAR.....	47
5.1. Problem 1: Hareketi Tahmin Etme.....	47
5.1.1. Model Doğruluğu Grafikleri.....	47
5.1.2. Model Kaybı Grafikleri	48
5.1.3. ROC Eğrisi	49
5.1.4. Sınıflandırma Raporu	50
5.2. Problem 2: Tipik ve Atipik Katılımcıları Tahmin Etme	51
5.2.1. Model Doğruluğu Karşılaştırma	51
5.2.2. Model Kaybı Karşılaştırma	52
5.2.3. ROC Eğrisi	53
5.2.4. Sınıflandırma Raporu	54
5.3. Problem 3: Puanlamaları Tahmin Etme.....	55
5.3.1. Model Doğruluğu Grafikleri.....	55
5.3.2. Model Kaybı Grafikleri	56
5.3.3. ROC Eğrisi	57
5.3.4. Sınıflandırma Raporu	58
6. TARTIŞMA.....	60
6.1. Bulgulara Dair Yorumlar.....	60
6.1.1. Problem 1: Hareketi Tahmin Etme	60
6.1.2. Problem 2: Tipik ve Atipik Katılımcıları Tahmin Etme	60
6.1.3. Problem 3: Puanlamaları Tahmin Etme	61
6.2. Geçerliliğe Yönelik Tehditler	61
6.2.1. Veri Setinin Küçük ve Sınırlı Olması	62
6.2.2. Veri Setinin Dengesiz Olması	62
6.2.3. Veri Setinin Temsil Etmemesi.....	62
6.2.4. Aşırı Öğrenme (Overfitting)	62
6.2.5. Veri Toplama Araçlarının Kısıtları	63
6.2.6. Katılımcı Davranışlarındaki Farklılıklar	63
7. SONUÇ.....	64
KAYNAKÇA.....	66
EKLER.....	69
EK-1. Etik Kurul Kararı	69
EK-2. Proje Kabul Yazısı	70

EK-3. Veli Onam Formu	72
EK-4. Oluřturulan JSON Dosya Formatı	74



KISALTMALAR

CNN	: Konvolüsyonel sinir ağı (Convolutional neural network)
HPC	: Yüksek Performanslı Hesaplama (High Performance Computing)
LSTM	: Uzun kısa süreli bellek (Long short-term memory)
LMA	: Laban Hareket Analizi
ROC	: Alıcı İşletim Karakteristik Eğrisi (Receiver Operating Characteristic Curve)
AUC	: ROC Eğrisi altında kalan alan (Area Under Curve)
RNN	: Tekrarlayan Sinir Ağları (Recurrent neural network)
SPA	: Tek Sayfa Uygulama (Single Page Application)
SDK	: Yazılım Geliştirme Kiti (Software Development Kit)
SQL	: Yapılandırılmış Sorgu Dili (Structured Query Language)

TABLO LİSTESİ

Tablo 1.1 Yapay Zeka Modellerinin Çözmek Üzere Eğitileceği Problemler	3
Tablo 3.1 Fonksiyonel Olan ve Fonksiyonel Olmayan Gereksinimler	17
Tablo 3.2 Hareketleri Puanlamak İçin Kullanılan Sorular	25
Tablo 4.1 Veri Toplama Yapılan Hareketler	36
Tablo 4.2 Kategorilere Göre Kaydedilen Video Sayıları	37
Tablo 4.3 Eğitim, Doğrulama ve Test İçin Ayrılmış Katılımcı Sayıları	46
Tablo 5.1 Problem 1 Model 1 Sınıflandırma Raporu	50
Tablo 5.2 Problem 1 Model 2 Sınıflandırma Raporu	51
Tablo 5.3 Problem 2 Model 1 Sınıflandırma Raporu	54
Tablo 5.4 Problem 2 Model 2 Sınıflandırma Raporu	55
Tablo 5.5 Problem 3 Model 1 Sınıflandırma Raporu	58
Tablo 5.6 Problem 3 Model 2 Sınıflandırma Raporu	59

ŞEKİL LİSTESİ

Şekil 3.1 Masaüstü Uygulaması Kullanım Senaryosu Diyagramı	18
Şekil 3.2 Backend Uygulaması Kullanım Senaryosu	19
Şekil 3.3 Xbox One Kinect v2.....	20
Şekil 3.4 Kinect sensör tarafından gönderilen noktalar	21
Şekil 3.5 Sistemin Dağıtım Diyagramı (Deployment Diyagram)	23
Şekil 3.6 İstemci Uygulamanın Dizi Diyagramı (Sequence Diyagram)	24
Şekil 3.7 Kayıt ve Etiketleme İşlemlerinin Örnek Görüntüleri.....	26
Şekil 3.8 Veri tabanı UML Diyagramı	29
Şekil 3.9 Yürüme Hareketi Örnek Verisi.....	33
Şekil 3.10 Yatay Atlama Hareketi Örnek Verisi	33
Şekil 3.11 Topu Yakalama Hareketi Örnek Verisi	33
Şekil 3.12 Topa Vurma Hareketi Örnek Verisi.....	34
Şekil 4.1 Model 1 Katmanlar	41
Şekil 4.2 Model 2 Katmanlar	44
Şekil 5.1 Problem 1 Model Doğruluğu Karşılaştırma	48
Şekil 5.2 Problem 1 Model Kaybı Karşılaştırma.....	49
Şekil 5.3 Problem 1 ROC Eğrisi Karşılaştırma	50
Şekil 5.4 Problem 2 Model Doğruluğu Karşılaştırma	52
Şekil 5.5 Problem 2 Model Kaybı Karşılaştırma.....	53
Şekil 5.6 Problem 2 ROC Eğrisi Karşılaştırma	54
Şekil 5.7 Problem 3 Model Doğruluğu Karşılaştırma	56
Şekil 5.8 Problem 3 Model Kaybı Karşılaştırma.....	57
Şekil 5.9 Problem 3 ROC Eğrisi Karşılaştırma	58

Üniversite	: T.C. İstanbul Kültür Üniversitesi
Enstitü	: Lisansüstü Eğitim Enstitüsü
Anabilim Dalı	: Bilgisayar Mühendisliği
Program	: Bilgisayar Mühendisliği
Tez Danışmanı	: Doç. Dr. Akhan AKBULUT
Tez Türü ve Tarihi	: Yüksek Lisans – Haziran 2024

ÖZET

Bu çalışma, İstanbul Kültür Üniversitesi ve Sakarya Uygulamalı Bilimler Üniversitesi'nin ortak yürüttüğü ve TÜBİTAK tarafından desteklenen iki yıllık bir projenin ürünüdür. Projenin amacı, çocukların motor becerilerini etkin bir şekilde değerlendirme potansiyeline sahip yapay zeka destekli bir ölçüm aracı geliştirmektir. İlk olarak, Kinect sensörlerini kullanarak çocukların yürümek, atlamak, top tutmak ve topa vurmak gibi temel hareketlerini kaydeden bir yazılım geliştirilmiş ve 50 tipik ile 50 atipik çocuktan oluşan bir grup üzerinde denemeler yapılmıştır. Toplanan hareket verileri daha sonra yapay zeka modeline dönüştürmek için işlenmiştir. Projede, katılımcıların tipik mi atipik mi olduğunu, hangi hareketi yaptıklarını bilen ve hareketlere puan verebilen yapay zeka modelleri geliştirilmiştir. Geliştirilen modeller, çocukların hareketlerinin doğru ve güvenilir bir şekilde analiz edilebilmesi için Kinect sensörlerden gelen veriler ile özel olarak oluşturulup kaydedilen videonun CNN ve LSTM yapısıyla analiz edilmesi üzerine kurgulanmıştır. Bu çalışma, kinematik değerlendirme sonuçlarıyla birlikte veriye dayalı motor beceri ölçüm araçlarının geliştirilmesine dair somut bir çalışmadır. Toplanan veri setinin norm değerler üzerinden yapay zeka modeli ile işlenmesi, çocukların motor becerilerinin değerlendirilmesine yönelik önemli bir ilerleme olarak kaydedilebilir. Çocukların motor gelişimini objektif ve güvenilir bir biçimde ölçebilen bu yapı, eğitim ve spor antrenmanlarında değerli bir araç olma potansiyeline sahiptir.

Anahtar Kelimeler: AI, Kinect, CNN, LSTM

University	: T.C. İstanbul Kültür University
Institute	: Institute of Graduate Studies
Department	: Computer Engineering
Program	: Computer Engineering
Thesis Advisor	: Assoc. Prof. Akhan AKBULUT
Degree Awarded And Date	: MSc – June 2024

ABSTRACT

This study is the product of a two-year project jointly conducted by Istanbul Kültür University and Sakarya Applied Sciences University and supported by TÜBİTAK. The project's objective is to develop an AI-supported measurement tool capable of effectively assessing children's motor skills. Initially, software was developed using Kinect sensors to record basic movements of children such as walking, jumping, catching, and hitting a ball; trials were conducted on a group of 50 typical and 50 atypical children. The collected movement data were then processed to transform into an artificial intelligence model. In the project, AI models were developed that can identify the performed movements, determine whether the participants are typical or atypical, identify which movement the children are performing, and score their movements. Two different AI models were developed to accurately and reliably analyze the children's actions through analysis of data from Kinect sensors and specially created and recorded videos using CNN and LSTM structures. This work is a solid study on the development of data-based motor skills measurement tools, along with kinematic assessment results. Processing the collected dataset through an artificial intelligence model based on norm values can be considered a significant advance in the assessment of children's motor skills. This structure, which can objectively and reliably measure children's motor development, has the potential to be a valuable tool in education and sports training.

Keywords: AI, Kinect, CNN, LSTM

1. GİRİŞ

Bu tez TUBİTAK'ın 1001 spor araştırmaları çağrısı kapsamında kabul edilen ve hazırlanan 121E688 numaralı “Temel Hareket Becerileri Analizinde Kullanılacak Yapay Zeka Temelli Ölçüm Aracının Geliştirilmesi: AIMove” projesinin bir çıktısı olarak hazırlanmıştır. Etik kurul kararı EK-1’de, kabul yazısı EK-2’te verilmiş olan proje iki yıllık bir proje olup 4 Temmuz 2022 tarihinde hazırlanmaya başlanmıştır. İstanbul Kültür Üniversitesi ve Sakarya Uygulamalı Bilimler Üniversitesi tarafından ortak olarak yürütülen projenin veri toplamak için tarafımızca geliştirilen yazılımı ve toplanan verinin yapay zeka modeline dönüştürülmesi aşamaları bu tezin konusu kapsamındadır.

Kinect Tabanlı Ölçüm Sistemi olan AIMove projesinin temel hedefi, çocukların yürüme, yatay atlama, topu yakalama, ayakla topa vurma gibi, motor becerilerinin temellerini oluşturan, temel hareket becerilerini ölçmek için etkin bir değerlendirme aracı geliştirmektir. Proje başvuru formunda da belirtildiği üzere projenin temel amacı; tipik (normal motor gelişim gösteren) ve atipik (normal motor gelişim göstermeyen) çocukların temel hareket becerilerine bağlı yeterliliklerini tespit edip, olası anormallikleri veya hareket becerilerine bağlı özel yeteneklerine ilişkin bilgileri raporlayabilen geçerlik ve güvenilirliği kanıtlanmış, yapay zekâ temelli bir ölçüm aracının geliştirilmesidir. Proje, veri toplama ve yapay zeka kullanarak verileri analiz etme olarak iki aşamadan oluşmaktadır. Projenin veri toplama kısmını oluşturan ilk aşamasında amaç, Kinect sensörlerini kullanarak çocukların hareketlerini yakalayan aracın bir prototipini oluşturmak, tipik ve atipik çocuklardan oluşan bir grup ile test etmektir. İkinci aşamada ise geçerlilik ve güvenilirlik sağlamak için sonuçların yapay zeka ile analiz edilmesi amaçlanmaktadır. AIMove projesinin veri toplama kısmında Kinect kamerası ile ölçümler yapabilen, veri yakalayabilen, katılımcıların hareketlerinin önceden tanımlanmış kriterlere dayalı olarak kalitesini değerlendirebilen ve her katılımcı için puanlar üretebilen bir prototip geliştirilmiş;

tipik ve atipik çocukların temel hareket becerilerinin ölçümü yapılarak veriler başarılı bir şekilde toplanmıştır.

Projenin ikinci aşamasında toplanan veriler işlenerek MP4 video formatına dönüştürülmüş, bu videolar kullanılarak yapay zeka modeli oluşturulmuştur. Keras Kütüphanesi'nden CNN (Convolutional neural network), 2D convolution layer katmanları kullanılarak videolar işlenmiş, birçok farklı mimari ile denemeler yapılmış ve LSTM (Long short-term memory) katmanları ile zamana bağlı veri yapay zeka modeli olarak eğitilmiştir. Doğruluk değerlerinin karşılaştırılması için Keras Kütüphanesinden daha önceden eğitilmiş Inception modeli ince ayar yapılarak kullanılmıştır. AIMove, frontend ve backend olmak üzere iki ana bileşenden oluşur. Frontend tarafında, kullanıcı dostu bir masaüstü uygulaması geliştirilmiştir. Bu uygulama, çocukların hareketlerini yakalamak ve puanlamak için Kinect sensörlerini kullanır. Backend tarafında ise, kullanıcıların veri yönetimini ve kullanıcı yetkilerini kontrol eden bir sistem bulunmaktadır.

1.1. Problemin Tanımı

Normal motor gelişim gösteren tipik çocuklar ve otizm spektrum bozukluğu ve down sendromundan etkilenmiş zihinsel yetersizliği bulunan atipik çocukların temel hareket yeteneklerini ölçümlemek bazı engellerden dolayı mevcut yöntemlerle yetersiz kalmaktadır. Bu engeller, kolay erişim, fonksiyonellik, uygun fiyat, taşınabilirlik ve tüm gerekli özelliklerin tek bir platformda bulunmayışı olarak tanımlanabilir. Mevcut ölçme araçları, Gençlik ve Spor Bakanlığının 8 - 9 yaş aralığındaki çocuklar için uyguladığı yetenek tarama projelerinde olduğu gibi genellikle kinematic değerlendirme içermemektedir ve yoğun olarak gözlemsel metodlara dayanmaktadır. Bu sürecin yarattığı yetersizlikler çocukların motor becerilerinin etkili bir şekilde ölçülmesini, eğitilmesini ve geliştirilmesini engellemekte olup oyunlara, sporlara ve fiziksel uygunluk aktivitelerine gelecekteki katılımı etkilemektedir. Bu problemi çözebilmek adına Tübitak tarafından kabul edilen 121E688 numaralı “Temel Hareket Becerileri Analizinde Kullanılacak Yapay Zeka Temelli Ölçüm Aracının Geliştirilmesi: AIMove” projesi kapsamında yapay zeka temelli bir araç geliştirilmesi amaçlanmıştır. Bu araç ile eğitim ve spor antrenmanı

ortamlarında ölçme ve değerlendirme süreçlerini yürütmek ve değerlendirmek için gerekli sonuçlara erişimi kolaylaştırmak hedeflenmektedir. Bu sebeple çocukların motor becerileri hakkında bilgi veren, bu becerilerdeki anormallikleri ortaya koyabilen, yetkinliği başarılı bir şekilde değerlendirebilen, güvenilir, geçerliliği olan bir yapay zeka temelli ölçüm aracı tasarlanmıştır.

Bu proje kapsamında belirlenen yürüme, yatay atlama, topu yakalama ve ayakla topa vurma temel hareketlerini 50 tipik ve 50 atipik çocuk tarafından her bir hareket 100 adet tekrarlanacak şekilde toplamda 40.000 adet kayıt işlemi yapılması öngörülmüştür. Bu aşamada hareketleri yaparak kayıt altına alınacak çocuklar belirlenmiş ve her bir katılımcı için EK-3'te verilen veli onam formu doldurtulmuştur. İki yıl süren bu projenin ilk iş planı olarak bu verileri toplayacak yazılımı geliştirme ve sonrasında veriler toplandıktan sonra ikinci iş planı olarak toplanan verilerin işlenerek yapay zeka modellerinin geliştirilmesi sağlanmıştır. Bu tez kapsamında geliştirilecek yapay zeka modellerinin çözmek üzere eğitilecekleri problemler Tablo 1.1de verilmiştir.

Tablo 1.1 Yapay Zeka Modellerinin Çözmek Üzere Eğitileceği Problemler

1. Problem	Katılımcının yaptığı hareketin yürüme, yatay atlama, topu yakalama, ayakla topa vurma hareketlerinden hangisi olduğunun tespiti.
2. Problem	Katılımcının Tipik mi Atipik mi olduğunun tespiti.
3. Problem	Katılımcının yaptığı harekete verilen puanın ortalamasının tespiti.

1.2. Tezin Amacı ve Hipotez

Bu çalışmada tipik ve atipik öğrencilerden elde edilen yürüme, yatay atlama, topu yakalama, ayakla topa vurma gibi temel hareketlerin norm değerler üzerinden yeterliliklerinin, olası anormalliklerinin ve çocukların özel yeteneklerinin tespitine yönelik geçerliliği ve güvenilirliği olan verisetinin toplanması, toplanan veriseti ile yapay zeka modelleri geliştirilmesi sağlanmıştır. Bu kapsamda reddedilecek ve kabul edilecek hipotezler aşağıdaki gibidir.

H0: (Null Hipotez) Tipik ve atipik motor gelişim gösteren çocukların temel hareket becerilerinin norm değerler ile eğitilmiş yapay zeka modelleri ile başarılı bir şekilde ölçümü yapılamaz.

H1: Tipik ve atipik motor gelişim gösteren çocukların temel hareket becerilerinin norm değerler ile eğitilmiş yapay zeka modelleri ile başarılı bir şekilde ölçümünün yapılması sağlanabilir.

1.3. Literatüre Katkılar

Bu çalışmada, gözlem aracılığıyla sahada elde edilen performans verileri, güvenilir ve geçerli bir materyal ile kinematik değerlendirme sonuçlarıyla desteklenerek ölçülmüştür. Katılımcıların temel motor becerilerinin ölçümlerinde, laboratuvara gerek duymadan, toplanan veri üzerinden, norm değerler çerçevesinde ölçüm yapılabilmesine imkan sağlanmıştır. Bu tez kapsamında tasarlanan iki farklı yapay zeka modeli ile 3 farklı problem özelinde karşılaştırmalar yapılmış ve kullanılan modellerin avantajları ve dezavantajları tartışılmıştır. Yapılan çalışma hem toplanan veri bakımından hem de uygulanan veri işleme metodları bakımından tamamen özgün ve benzersiz bir çalışmadır. Benzer problemleri olan diğer araştırma alanları için de bir örnek teşkil etmektedir.

1.4. Tezin Organizasyonu

Bu tez 7 bölümden oluşmaktadır. İlk olarak giriş bölümünde yapılan çalışma hakkında bilgi verilmiş, problemin tanımı, tezin amacı ve literature katkısı vurgulanmıştır. İkinci bölümde temel bilgiler ve yapılan literatür araştırması hakkında bilgi verilmiştir. Üçüncü bölümde yöntem, veri toplama hazırlığı, veri toplama ve veri işleme süreçleri açıklanmıştır. Dördüncü bölümde sınıflandırıcı yapay öğrenme modelleri hakkında bilgi verilmiş, beşinci bölümde ise elde edilen bulgular paylaşılmıştır. Altıncı bölümde elde edilen bulguların başarısı ve geçerliğe yönelik tehditler tartışılmış, yedinci bölümde yapılan çalışma ile ne sonuca ulaşıldığının bilgisi ele alınmıştır.

2. TEMEL BİLGİLER VE LİTERATÜR TARAMASI

Video analizinde yapay zekanın ilk kullanımı basit görüntü tanıma ile başlamış ve sinir ağlarının ortaya çıkmasıyla önemli ölçüde gelişmiştir. Video verilerine sinir ağı uygulamalarının ilk aşamaları, hesaplama kısıtlamaları ve derin öğrenme tekniklerinin eksikliği nedeniyle sınırlıdır. Bununla birlikte, konvolüsyonel sinir ağlarının (CNN) geliştirilmesi, video verilerini benzeri görülmemiş derinlik ve doğrulukla analiz etmek için güçlü araçlar sunarak alanı önemli ölçüde ilerletmiştir [1]. CNN'ler, derinliği ve genişliği artırırken hesaplama bütçesini sabit tutabilme yetenekleri nedeniyle görüntü odaklı görevleri yerine getirmedeki üstünlüklerini kanıtlamış sinir ağlarıdır [2]. Derin sinir ağlarının bir sınıfı olan CNN'ler, görüntüler veya videolar gibi çoklu diziler şeklinde gelen verileri işlemek için özel olarak tasarlanmıştır. Bu, CNN'leri özellikle video analizi içeren görevler için çok uygun hale getirir. Konvolüsyonel katmanlar, havuzlama katmanları ve tam bağlantılı katmanların bir kombinasyonu aracılığıyla görüntüleri işlemek için benzersiz bir şekilde yapılandırılmış, görüntülerdeki özelliklerin ve desenlerin yüksek verimlilik ve minimum hesaplama ile öğrenilmesini kolaylaştırmıştır [1]. CNN'ler nesne algılama, etkinlik tanıma ve hatta video akışları içinde gerçek zamanlı etkileşim dahil olmak üzere çeşitli uygulamalar için kullanılabilir.

Yazar Zewen Li ve diğerlerinin çeşitli CNN modellerini incelemek üzere yaptıkları çalışma, CNN'lerin iki boyutlu görüntülerin ötesinde, tek boyutlu ve çok boyutlu konvolüsyonlara uygulanması, karmaşık veri türlerini ele almadaki çok yönlülüğünü göstermesi açısından dikkate değerdir. Çeşitli aktivasyon fonksiyonları, kayıp fonksiyonları, optimize ediciler ve diğer hiper parametreler ile yaptıkları deneyler ile yapılabilecek optimum seçimler hakkında fikir vermektedir [3]. CNN'lerin video verilerini analiz etmedeki etkinliği büyük ölçüde otomatik özellik çıkarma yeteneklerine bağlanmaktadır. Manuel özellik çıkarımı gerektiren geleneksel makine öğrenimi algoritmalarının aksine, CNN'ler özellikleri doğrudan video karelerinden tanımlamayı ve çıkarmayı öğrenebilir, bu da karmaşıklığı önemli ölçüde azaltır ve

video analizinin verimliliğini artırır [4]. CNN'lerin video analizindeki uygulamaları çok geniş ve çeşitlidir. Bunlar arasında insan hareketlerini tanıma, nesne algılama ve Kinect sensörü gibi cihazlar tarafından çekilen videolardaki hareketlerin değerlendirilmesi yer almaktadır [5]. Özellikle bu sensör, yüksek çözünürlüklü derinlik ve görsel veriler sağlayarak gelişmiş video analiz uygulamalarını kolaylaştırmış ve insan faaliyetlerinin, hareketlerinin ve etkileşimlerinin 3 boyutlu bir alanda daha iyi analiz edilmesini sağlamıştır [6].

LSTM (Uzun Kısa Dönem Hafıza), hatalı geri yayılma problemlerini aşmak için tasarlanmış, özel birimler aracılığıyla sürekli hata akışını koruyan çarpıcı kapılara sahip etkin bir gradyan tabanlı tekrarlayan sinir ağı yöntemidir ve bu sayede uzun zaman aralıkları boyunca bilgi öğrenmeyi ve depolamayı mümkün kılar [7]. RNN (Tekrarlayan sinir ağlarının) gelişmiş bir çeşidi olan LSTM ağları, özellikle zamansal örüntüleri anlamının çok önemli olduğu video analizinde, sıralı ve zamansal verilerin analizinde önemli bir rol oynamaktadır [8]. LSTM ağları, bilgi akışını düzenleyebilen kapılara sahip karmaşık bir mimari içererek geleneksel RNN'lerin temel sınırlamalarının üstesinden gelmek için tasarlanmıştır. Bu kapılar arasında giriş kapısı, çıkış kapısı ve unutma kapısı yer alır ve ağı uzun diziler boyunca bilgiyi seçici olarak tutmasını veya unutmasını sağlar. Bu mimari, LSTM'lerin zamansal bağımlılıkları yakalamasına ve bilgileri uzun süreler boyunca hatırlamasına olanak tanır; bu, bağlam ve zamansal ilerlemenin önemli olduğu video dizilerini işlemek için gerekli olan bir özelliktir [9]. Yazdıkları makalede Uzun Kısa Süreli Bellek (LSTM) hücreleri ve bunların tekrarlayan sinir ağlarındaki (RNN) uygulamaları hakkında kapsamlı bir inceleme sunan Yong Yu ve diğerleri, LSTM hücrelerinin derin öğrenme teknolojilerinin geliştirilmesinde oynadığı önemli rolü vurgulamaktadır. LSTM'ler, bilgi akışını düzenleyen işlevleriyle metin, ses ve video içeren görevler için sıralı verileri yöneten uzun vadeli bağımlılıkları öğrenmekte oldukça iyidir. Ayrıca, Yong Yu ve diğerleri, LSTM'ler içindeki bağlantıları geliştirmeye odaklanan LSTM ağlarının yanı sıra LSTM'leri CNN'ler gibi diğer nöral bileşenlerle birleştiren entegre LSTM ağları üzerinde de incelemeler yapmışlardır [10]. LSTM'ler, zamansal örüntülere ilişkin karmaşık anlayışları ve diğer sinir ağı mimarileriyle entegrasyonları sayesinde, video verilerinin dinamiklerini yorumlamaya en uygun modern yapay zeka sistemlerinin temel taşı temsil etmektedir [11].

2.1. Literatür Taraması

Literatür taraması, bilimsel çalışmaların temel taşlarından biridir ve mevcut bilgiler ışığında yeni bir araştırmanın temellerini oluşturmaktadır. Bu çalışmada, Xbox Kinect sensörü kullanılarak gerçekleştireceğimiz projenin daha önceki araştırmalar incelenerek bu doğrultuda gelişmesi amaçlanmaktadır. Kinect sensörünün çeşitli bilimsel ve teknolojik uygulamalarda kullanımı, son yıllarda büyük ilgi görmüş ve bu konuda birçok farklı çalışma yapılmıştır. Bu çalışmalarda elde edilen sonuçlar ve kullanılan metodolojiler dikkatle analiz edilmiştir. Özellikle Kinect tabanlı araştırmaların bulguları üzerine odaklanılarak, bu sensörün potansiyel kullanım alanları ve mevcut sınırlamaları değerlendirilmiştir. Literatürdeki ilgili çalışmaların amaç ve sonuçlarına dair ayrıntılı bilgiler, çalışmamızın sonunda tablo olarak sunulmuştur.

M. van Diest, J. Stegenga, ve diğerleri tarafından 2014 yılında yapılan çalışma, bir video oyunu sensörü olan Kinect'in, özellikle yaşlılarda ev tabanlı denge eğitimi için tüm vücut hareketlerini yakalamak ve analiz etmek için kullanımını değerlendirmeyi amaçlamıştır. Yirmi sağlıklı yetişkin beş koşul altında bir ağırlık kaydırma exergame oynamıştır. Hareketleri Kinect ve Vicon 3D kamera sistemi kullanılarak kaydedilmiştir. Her iki sistemden alınan hareket modellerini karşılaştırmak için Temel Bileşen Analizi (PCA) kullanılmıştır. Sonuçlar, her iki sistemin de vücut segmenti hareketlerindeki varyansın %90'ından fazlasını üç temel bileşen içinde yakaladığını göstermiştir. Kinect gövde hareketlerini doğru bir şekilde yakalamış ancak el ve ayak segmenti ölçümlerinde %30'a varan hata yapmıştır. Kinect ve Vicon ölçümleri arasındaki denge sonuçlarındaki farklılıklar %0,3 ile %64,3 arasında değişmektedir. Bu farklılıklara rağmen Kinect, karmaşık exergaming görevleri sırasında denge becerisini ölçme potansiyeli göstermiştir ve yaşlılarda ev tabanlı denge eğitimi için yararlı olabileceğini düşündürmektedir.[12]

Ting H, Sim K, Abas F, ve diğerleri tarafından 2015 yılında yapılan spor bilimleri araştırmalarında elde edilen sonuçlara göre, hareket tanıma ve analizi için manuel video açıklama ve fiziksel vücut işaretleri kullanma gibi geleneksel teknikler zaman alıcı ve elverişsizdir. Bu durum özellikle Malezya'da popüler olan ancak hareket tanıma konusunda bilimsel araştırmaların eksik olduğu badminton gibi sporlar

için geçerlidir. Bunu ele almak için, Microsoft Kinect sensöründen alınan derinlik haritası dizilerini kullanan yeni bir yöntem ve badminton hareketlerini tanımak ve analiz etmek için dinamik bir zaman eğriltme algoritması ile yeni bir sıkıştırma tekniği önerilmiştir. Çalışmada, bakış açısı, vücut boyutu, kıyafet, hız ve cinsiyet gibi çeşitli faktörler göz önünde bulundurularak 20 oyuncudan alınan 600 örnekten oluşan bir veri kümesi kullanılmıştır. Sistem neredeyse %95 gibi yüksek bir ortalama tanıma doğruluğuna ulaşmıştır. Ayrıca, spor bilimcileri, antrenörler ve oyuncuların performanslarını geliştirmeleri için yararlı olan hareketleri analiz edip ayrıntılı geri bildirim sağlayabilmiştir. Bu yeni sistem, badminton becerilerini geliştirmek için pratik ve etkili bir araç sunarken manuel ve işaretleyici tabanlı yöntemlerin dezavantajlarını ortadan kaldırmaktadır.[13]

2015 tarihli Tsachor R. tarafından yazılan “Laban Movement Analysis Using Kinect” başlıklı makale, Microsoft'un Kinect V2 sensörünü kullanarak Laban Hareket Analizi (LMA) niteliklerini otomatik olarak tanımaya yönelik bir yöntemi ele almaktadır. Dans topluluğunda yetmiş yılı aşkın bir süredir geliştirilen bir sistem olan LMA, insan hareketini gözlemlemeye, tanımlamaya ve yorumlamaya yardımcı olmaktadır. Araştırmacılar, Kinect sensöründen alınan hareket yakalama iskelet kayıtlarında LMA niteliklerini belirlemek için bir yöntem oluşturmuşlardır. Yaklaşımları genel olarak yaklaşık %60 hatırlama ve kesinlik elde etmiş; zıplama, yayılma ve batma gibi daha büyük hareketlerin %60 ila %90 arasında değişen hassasiyet ve hatırlama ile tanınmasını daha kolay hale getirmiştir. Bununla birlikte, “güçlü” ve “pasif” gibi daha ince niteliklerin, kinematik terimlerdeki karmaşıklıkları nedeniyle %40 ile %60 arasında değişen hassasiyet ve geri çağırma ile ölçülmesinin daha zor olduğu belirlenmiştir. Zorluklara rağmen yöntem, uygun fiyatlı ve yaygın olarak bulunan bir sensör kullanarak çoğu LMA niteliğinin özünü başarıyla yakalamıştır.[14]

Zerpa C. ve Less C. tarafından 2015 yılında yazılan makale, insan hareket kinematikini analiz etmek için Microsoft Kinect sistemi kullanmanın güvenilirliğini ve geçerliliğini değerlendirmeyi amaçlamıştır. Geleneksel 3D hareket sistemleri etkili olmakla birlikte genellikle işaretleyiciler, birden fazla kamera, kapsamlı kalibrasyon gerektirir ve maliyetlidir. Buna karşılık, Kinect sistemi uygun maliyetli, taşınabilir ve

kurulumu kolay bir alternatif sunmaktadır ancak güvenilirliği ve geçerliliği tam olarak belirlenmemiştir. Yirmi altı katılımcının yer aldığı çalışmada Peak Motus sistemi ve özelleştirilmiş Kinect iskelet yazılımı kullanılarak katılımcılar hareketli bir platform üzerinde otururken veri kaydı yapılmıştır. Sonuçlar, Peak Motus sisteminin Kinect'e kıyasla tüm vücut eklemlerinde üstün güvenilirlik sergilediğini ortaya koymuştur. Bununla birlikte, Kinect diz eklemi hareketlerini ölçmede Peak Motus ile güçlü bir uyum göstermiş ve insan hareket analizi için uygun bir araç olabileceğini düşündürmüştür. Kurulum ve veri toplamadaki avantajlarına rağmen, küçük bir örneklem boyutu ve Peak Motus sisteminde yalnızca iki kamera kullanılması gibi potansiyel olarak veri hatalarına yol açan sınırlamalar vardır. Gelecekteki araştırmalar, karmaşık hareketleri ve nesnelerle etkileşimleri daha iyi izlemek için daha büyük örneklem boyutları, birden fazla kamera ve yazılım geliştirmeleri içermelidir. Çalışma, Kinect sisteminin umut vaat etmesine rağmen, klinik, iş ve spor ortamları gibi çeşitli uygulamalardaki potansiyelini tam olarak gerçekleştirmek için daha fazla modifikasyon ve değerlendirmenin gerekli olduğu sonucuna varmaktadır.[15]

Nichols J., Sena M. ve diğerleri tarafından 2017 yılında yapılan çalışma, hareket analiz sistemlerini daha uygun fiyatlı ve erişilebilir hale getirmeyi amaçlamaktadır. Şu anda Vicon gibi hassas sistemler genel kullanım için çok maliyetliken, daha ucuz alternatifler hassasiyetten yoksundur. Bu sorunu çözmek için araştırmacılar, uygun fiyatlı ve yaygın olarak bulunan Microsoft Kinect derinlik kamerasını kullanarak bir Derinlik Kamerası Hareket Değerlendirme Sistemi (DCMAS) oluşturdular. DCMAS ve Vicon'dan alınan işaretleyicilerin 3D konum verilerini karşılaştırdılar ve DCMAS'ın, bir işaretleyici türündeki küçük bir tutarsızlık dışında, konumları 1,55 cm'lik bir marj içinde neredeyse Vicon kadar doğru ölçebildiğini gösterdiler. Çalışma düz ve konturlu yüzeylere yapıştırılan işaretleyicilere odaklanmış ve işaretleyici konumuna bağlı olarak algılama sıklığını incelemiştir. DCMAS'ı klinik açıdan daha uygun hale getirmek için gelecekte veri işleme ve test protokolünde iyileştirmeler yapılması planlanmaktadır. Bu teknoloji, klinik deneyler için yüksek kaliteli insan hareketi profilleri ve ölçümleri sağlayarak önleyici tıbbı yard ve katılımcıların zaman içindeki ilerlemesini izlemeye yardımcı olabilir. Amaç, hassas hareket değerlendirme araçlarını daha geniş bir kitlenin

kullanımına sunarak daha az maliyetli ve yüksek doğruluk payına sahip bir yapı oluşturmaktadır.[16]

“Kinect Sensörü Kullanarak Otistik Çocuklarda Basmakalıp Hareketlerin Otomatik Tespiti” başlıklı, Jazouli M., Majda A. ve diğerleri tarafından 2019 yılında yayınlanan makale, Otizm Spektrum Bozukluğu (OSB) olan bireylerde basmakalıp motor hareketlerin otomatik olarak tespit edilmesine yönelik bir yöntemi araştırmaktadır. OSB, iletişimi, sosyal becerileri ve davranışları etkileyen, genellikle tekrarlayan hareketler veya olağandışı davranışlarla sonuçlanan gelişimsel bir bozukluktur. Bu çalışma beş spesifik stereotipik motor hareketi belirlemeyi amaçlamaktadır: vücut sallama, el çırpma, parmak çırpma, eller yüzde ve eller arkada. Yöntem, Kinect sensöründen alınan veriler aracılığıyla bu hareketleri gerçek zamanlı olarak tanımlamak için Point-Cloud Recogniser'ı kullanmıştır. Sistemin bu hareketleri tespit etmedeki doğruluğu ölçülmüş ve %94'lük bir başarı oranı göstermiştir ki bu da tatmin edici olarak kabul edilmektedir. Bu teknoloji, OSB teşhisinde yardımcı olan akıllı video gözetim sistemlerinin oluşturulmasına katkıda bulunabilir. Gelecekteki araştırmalar, yanlış pozitifleri azaltmak için hareket tanıma algoritmalarının doğruluğunu artırmaya ve teşhis süreçlerine daha fazla yardımcı olmak için otistik çocuklar için kapsamlı bir veri tabanı geliştirmeye odaklanacaktır.[17]

Peicong Li tarafından 2020 yılında yazılan makaleye göre, son yıllarda robot teknolojisi, havacılık, tıp, eğitim ve hizmetler gibi çeşitli alanlarda giderek daha fazla kullanılmakta ve robotlar ile insanlar arasında daha yakın ilişkiler yaratmaktadır. Robot zekasının ilerlemesi, insan-bilgisayar etkileşimi teknolojisinin önemli ölçüde yardımcı olduğu harici bilgilerden sürekli öğrenmeye dayanmaktadır. 2020'de yapılan “Kinect Sensörüne Dayalı Robot Boks Hareketi Simülasyonu Üzerine Araştırma” başlıklı bir çalışma, Tai Chi'yi örnek olarak kullanarak bu kavramı araştırmıştır. Araştırmacılar Tai Chi'nin standart hareketlerini analiz ederek hareket parametre bilgilerini elde etmişlerdir. Bir Kinect sensörü kullanarak insan vücudunun derinlik görüntüsünü ve kemik yapısını yakalamış ve eklem konumu verilerini kaydetmişlerdir. Bu veriler daha sonra robotun beynine gönderilerek Tai Chi hareketlerini taklit etmesi sağlanmıştır. DeneySEL sonuçlar, bu yöntemin Tai Chi uygulamasını etkili bir şekilde simüle edebileceğini, uygulama eksikliklerini belirleyebileceğini ve sporu teşvik

edebileceğini göstermiştir. Çalışma, doğal insan-bilgisayar etkileşimini kullanan robotların insan eylemlerini hızlı bir şekilde öğrenmesine, robotik operasyonları ve insanlara hizmeti geliştirmesine olanak tanıdığı sonucuna varılmıştır. Araştırmacılar, insan hareketlerini yakalamak ve robot hareketlerine dönüştürmek için Kinect'i kullanarak, robotların insan duruşlarını iyi bir şekilde taklit etmesini sağlayan bir sistem geliştirmişlerdir, ancak bu sistem henüz insansı robotların dengesini dikkate almamaktadır.[18]

2020'de yapılan “Microsoft Kinect V2 Sensörü Kullanılarak Hareket Kalitesinin Otomatik Sınıflandırılması” başlıklı çalışmada, teknolojiyi kullanarak hareket kalitesi değerlendirmesinin nasıl daha iyi ve daha hızlı yapılabileceği incelendi. Normalde, bir kişinin squat ve lunge gibi egzersizlerle ne kadar iyi hareket ettiğini değerlendirmek çok zaman alabilir ve bir değerlendiriciden diğerine farklılık gösterebilir. Araştırmacılar bu sorunu çözmek için Kinect V2 sensörünü kullanarak bu egzersizleri yapan 31 aktif erkeğin hareketlerini yakaladı. Daha sonra Hareket Yeterlilik Ekranı (MCS) kriterlerine göre hareket kalitesini sınıflandırmak için bu sensörden toplanan verilere makine öğrenimi modelleri uyguladılar. Çalışma, modeller için özellikler oluşturmak üzere belirli eklem hareketlerine (kinematik değişkenler) odaklandı. MCS skorları üretmek için çok sınıflı lojistik regresyon kullanılmış ve modellerin sırasıyla 0,66 ile 0,89, 0,58 ile 0,86 ve 0,74 ile 0,85 arasında değişen iyi bir duyarlılık, özgüllük ve doğruluğa sahip olduğu tespit edilmiştir. Sonuç olarak, Kinect tabanlı sistemin hareket kalitesini otomatik olarak değerlendirmek için etkili, yeni ve kullanışlı bir yöntem olduğu kanıtlanmıştır.[19]

2022'de yayınlanan “Kinect Sensör İskeleti Verilerinin Örüntü Madenciliği ile İşçi Performansının Değerlendirilmesi” başlıklı makale, Endüstri 4.0 teknolojilerini kullanarak üretimde çalışanların performansını değerlendirmek için yeni bir yaklaşımı tartışmıştır. İşçi performansını gözlemlemeye yönelik geleneksel yöntemler yavaş ve uzman görüşüne dayanırken, yeni yaklaşımda akıllı sensörler ve veri madenciliği kullanılmaktadır. Çalışma, Kinect sensöründen alınan iskelet verilerini kullanarak ve örüntü madenciliği ile denetimli öğrenme algoritmalarını uygulayarak işçilerin hareketlerini ve performansını otomatik olarak değerlendirmeyi amaçlamaktadır. Bir elektrik montaj hattındaki kullanım örneği, bu yöntemin işçi hareketlerini segmentlere

ayırabildiğini ve performansı değerlendirebildiğini göstermiştir. Sonuçlar, örüntü madenciliğinin iş prosedürlerini, ergonomiyi ve vücut kullanımını iyileştirmek için kullanılabilecek ortak iş hareketlerini belirleyebileceğini göstermektedir. Çalışma, bu yaklaşımın insan merkezli iyileştirmelere odaklanan Endüstri 5.0'ın hedefleriyle tutarlı olduğunu vurgulamaktadır. İlk umut verici sonuçlar, ergonomi tasarımı ve insan-robot işbirliği gibi daha gelişmiş uygulamalar için Kinect verilerini kullanma potansiyeline sahip bu teknolojilerin daha fazla araştırılmasını teşvik etmektedir. Bu makale, bu tür yeniliklerin imalat sektöründe hem bireysel hem de kurumsal gelişimi artırabileceğini öne sürmektedir. [20]

T. Y. Shih ve diğerleri 2023 yılında yaptıkları çalışmaya göre, tek taraflı beyin felci geçiren (UCP) çocuklarda üst ekstremit motor fonksiyonunu iyileştirmek için kısıtlamaya bağlı hareket terapisi (CIMT) yaygın olarak kullanılmaktadır ancak daha az etkilenen kolun kısıtlanması ve yoğun eğitim nedeniyle süreç zorlayıcı olabilmektedir. Bu sorunları ele almak için kinect tabanlı yeni bir CIMT programı geliştirilmiştir. Bu çalışmada kinect tabanlı CIMT'in etkinliği geleneksel terapist tabanlı CIMT ile karşılaştırılmıştır. UCP'li yirmi dokuz çocuk katılmış ve 8 hafta boyunca haftada 2 gün, günde 2,25 saat kinect tabanlı veya terapist tabanlı CIMT'e tabi tutulmuştur. Sonuçlar, her iki CIMT türünün de üst ekstremit motor kontrolünü ve günlük motor fonksiyonunu benzer şekilde geliştirdiğini göstermiştir. Bununla birlikte, kinect tabanlı CIMT grubu, terapist tabanlı CIMT grubuna kıyasla gövde motor kontrolünde daha fazla gelişme göstermiştir. Bu durum, kinect tabanlı CIMT'in geleneksel yöntemlere uygulanabilir bir alternatif olabileceğini, üst ekstremit motor fonksiyonu için benzer faydalar ve gövde motor kontrolü için ek avantajlar sunabileceğini ve böylece UCP'li çocuklar için CIMT'in genel etkinliğini ve klinik faydasını artırabileceğini göstermektedir.[21]

Açış B ve Güney S tarafından 2023 yılında yazılan makaleye göre son yıllarda, sağlık ve güvenlik gibi alanlarda insan hareketlerinin sınıflandırılmasına yönelik ilgi giderek artmaktadır. Bunu başarmak için görüntü işleme yöntemleri ve makine öğrenimi algoritmaları giderek yaygınlaşmaktadır. Makine öğrenimi ve derin öğrenme algoritmaları, eklemleri tespit etmek için kızılötesi ışınlar kullanan ve bu verileri bir bilgisayara ileten Microsoft Kinect sensörü gibi çeşitli sensörlerden gelen görüntüleri

kullanarak insan duruşunu tanımlamaya yardımcı olmaktadır. Bu çalışma, Kinect sensöründen alınan gerçek zamanlı duruş verilerini ve görüntüleri içeren CAD60 veri setini kullanmaya odaklanmıştır. Farklı sınıflandırma algoritmaları MATLAB kullanılarak test edilmiş ve performansları karşılaştırılmıştır. Ham sensör verileri için Cosine K-En Yakın Komşu yöntemi %72,60'lık bir sınıflandırma doğruluğu elde etmiş ve bu oran özellik seçimi yöntemleri kullanılarak %74,18'e yükselmiştir. Çalışmanın en önemli ilerlemesi, özellik çıkarma ve ardından Destek Vektör Makineleri (SVM) sınıflandırması için bir derin öğrenme yöntemi olan Uzun Kısa Süreli Bellek (LSTM) kullanılması ve bunun sonucunda %98,95'lik bir doğruluk elde edilmesidir. Araştırma, Kinect sensöründen alınan ortak verilerin RGB görüntülerden daha iyi sınıflandırma sonuçları verdiğini ortaya koymuştur. Gelecek çalışmalarda daha fazla RGB kamera görüntüsü ile derin öğrenme mimarilerinin geliştirilmesi ve hatalı duruşların tespit edilip düzeltilmesi için ergonomik uyarı sistemlerinin tasarlanması önerilmektedir.[22]

Çalışma	Yıl	Amaç / Sonuç
[12]	2014	Egzersiz sırasında bütün vücut hareketi desenlerini yakalamak ve analiz etmek için Kinect kullanımını değerlendirmek ve Vicon ile karşılaştırmak. / Her iki sistem arasındaki ölçümler %0 ve %64 arasında değişkenlik göstermiştir.
[13]	2015	Kinect sensörüyle elde edilen badminton hareket tanıma ve analiz sistemi geliştirmek. / Badminton hareket tanıma için ortalama %94,5 tanıma doğruluğu sağlanmış.
[14]	2015	Kinect V2 sensörünü kullanarak hareket yakalama iskelet kayıtlarından Laban niteliklerini tanımak. / %60 civarında bir ortalama doğruluk ile Laban hareket analizi sağlanabilmektedir.
[15]	2015	İnsan hareket analizinde yer değiştirmeyi ölçmek için Microsoft Kinect sistemini Peak Motus sistemi ile karşılaştırarak güvenilirliğini ve geçerliliğini sağlamak. / Kinect sistemi özellikle diz eklemleri karşılaştırıldığında Peak Motus sistemi ile benzerlikler göstermiş ve insan kinematik hareket analizinde kullanılabilecek bir araç olma potansiyelini göstermiştir.

[16]	2017	Endüstri standardı Vicon sistemi ile karşılaştırılabilir doğrulukta, uygun fiyatlı bir hareket değerlendirme sistemi geliştirmek. / Ucuz hareket değerlendirme sistemi, bazı istisnalar dışında Vicon sistemi ile 1.55 cm'lik marjda 3d marker pozisyon ölçümleri sağlayabilmiştir.
[17]	2019	Kinect sensörü kullanarak Otizm Spektrum Bozuklukları olan çocuklarda stereotipik motor hareketlerini gerçek zamanlı olarak tespit etmek. / %94 oranında doğruluk ile stereotipik hareketleri tespit edilebilmiştir.
[18]	2020	İnsan-bilgisayar etkileşimi ve kinect sensörü kullanarak robot öğrenimi için Tai Chi hareketlerini simüle etmek ve analiz etmek. / Önerilen yöntem Tai Chi hareketlerini taklit edebilir ve hataları analiz ederek sporun gelişimini teşvik edebilir.
[19]	2020	Hareket Yeterlilik Ekranı (MCS) sonuçlarını çeşitli makine öğrenim modelleri ile sınıflandırarak değerlendirmek. / %74 ile %85 arasında doğruluk sonuçları gözlenmiştir.
[20]	2022	Örüntü madenciliği ve gözetimli öğrenme (supervised learning) kullanarak işçi performansını iskelet verileri ile otomatik olarak değerlendirmek. / Yaklaşımın doğrulanmasında umut verici sonuçlar elde edilmiş, mühendislik ekibine süreçleri iyileştirmede yardımcı olunmuştur.
[21]	2023	Tek taraflı beyin felci geçiren, kısıtlamaya bağlı hareket terapisi gören çocukların günlük motor fonksiyon hareketlerinin kinect ve terapist tabanlı karşılaştırılması. / Hem kinect bazlı grup hem de terapist bazlı grup günlük motor fonksiyonlarında benzer gelişim gösterirken, gövde motor fonksiyonlarında kinect bazlı grup daha yüksek gelişme göstermiş.
[22]	2023	Kinect sensörü kullanarak insan hareketlerini sınıflandırmak ve sınıflandırma doğruluğunu artırmak. / Cosine K-NN 72.60%, Geriye dönük özellik seçimi %75, LSTM + SVM %98 doğruluk sağlayabilmiştir.

3. YÖNTEM

Bu çalışma kapsamında kullanılacak yöntem, ilk olarak veri toplamak, daha sonra toplanan veriler ile yapay zeka modelleri geliştirmek olacaktır. Bu aşamada yapılması gereken Kinect sensör ile entegre olarak çalışacak, ihtiyacımız olan verileri toplamak için kullanacağımız bir program geliştirmektir. Bu bölümde ilk olarak Kinect sensör hakkında yapılan araştırma sonrasında, tasarlama aşamasının daha sağlıklı ilerleyebilmesi için Kinect tabanlı ölçüm sisteminin gereksinim analizi yapılmıştır. Geliştirilecek programın fonksiyonel ve fonksiyonel olmayan gereksinimleri hakkında bilgi verildikten sonra, program geliştirme süreçlerinden bahsedilecek, geliştirilirken kullanılan paketler ve bu kapsamda yapılan veri işleme hakkında bilgi verilecektir.

3.1. Gereksinimler

Fonksiyonel gereksinimler; kayıt işlemleri, etiketleme ve puanlama, video görüntüleme, veri taşıma, veri seti yönetimi, kullanıcı girişi, socket bağlantı, katılımcı yönetimi, yetki kontrolü, performans ve hız, kullanıcı dostu arayüz olarak belirlenmiştir. Fonksiyonel olmayan gereksinimler ise performans, doğruluk, kullanılabilirlik, güvenilirlik, uyumluluk ve ölçeklenebilirlik olarak belirlenmiştir.

3.1.1. Fonksiyonel Gereksinimler

Katılımcıların hareketlerini kinect sensörler aracılığı ile kayıt altına alan yöneticiler, kayıt yapılacak katılımcıyı seçebilmeli ve hangi hareketin kaydedileceğini belirleyebilmelidir. Kayıt işlemi başladığında, Kinect sensörleri kullanılarak rgb video ve iskelet video görüntüleri veri tabanına kaydedilmeli ve istendiğinde görüntülenebilmelidir. Sistem aynı anda iki Kinect ile veri toplama işlemini desteklemelidir. Yöneticiler, kaydedilen hareketlerin etiketlenmesini gerçekleştirmelidir. Her bir hareket için bir dizi soru oluşturulmalı ve bu sorulara 1-5 arasında puan verilmelidir. Etiketlenen veriler, hareket verileri ile birlikte saklanabilmelidir. Kullanıcılar, kaydedilen rgb video ve iskelet video görüntülerini

görsüntüleyebilmeli ve gerektiğinde tam ekran modunda izleyebilmelidir. Kullanıcılar, videoları dosya olarak kaydetmeden yeni kayıt yapabilmelidir. Belirli aralıklarla, kaydedilen dosyaların harici bir diske taşınması sağlanmalıdır. Yöneticiler, yeni veri setleri oluşturabilmeli ve mevcut veri setlerini düzenleyebilmelidir. Bir veri seti oluşturulurken, veri setinin adı ve açıklaması belirtilmelidir. Yöneticiler, kullanıcıları veri setlerine atayabilmeli ve atanmış kullanıcıları düzenleyebilmelidir. Kullanıcılar, sistemde oturum açmak için kullanıcı adı ve şifrelerini girmelidir. Doğru kullanıcı adı ve şifre girildiğinde kullanıcı ana sayfaya yönlendirilmelidir. Aynı anda birden fazla kinect ile kayıt yapabilmek için bilgisayarın socket bağlantı ile peer to peer bağlanması sağlanmalıdır. Yardımcı olarak bağlanan bilgisayar ekstra hiçbir işlem yapmadan kayıt işlemini gerçekleştirebiliyor olmalıdır. Kullanıcılar, yeni katılımcılar ekleyebilmeli ve mevcut katılımcıları düzenleyebilmelidir. Bir katılımcının adı, boyu, kilosu ve doğum tarihi gibi bilgiler kaydedilmelidir. Kaydedilen veriler, yerleşik veri tabanında tutulmalı ve istendiğinde görüntülenebilmelidir. Kullanıcılar, sadece kendilerine atanmış veri setlerine erişebilmelidir. Yöneticiler, veri setlerini düzenleyebilmeli ve kullanıcılara erişim izni verebilmelidir. Uygulama, yüksek kalitede veri yakalama yetenekleri ve gerçek zamanlı izleme özelliği ile kullanıcılarına hızlı ve sorunsuz bir deneyim sunmalıdır. Uygulama kullanıcı dostu bir arayüzü olmalı ve kullanıcılar tarafından kolayca anlaşılabilir olmalıdır. Arayüz, farklı ekran çözünürlüklerinde düzgün görünmeli ve kullanıcı deneyimini iyileştirmelidir.

3.1.2. Fonksiyonel Olmayan Gereksinimler

Sistem, iki kinect ile eş zamanlı ve önemli bir gecikme olmadan çalışmalıdır. Sistem, katılımcının vücut hareketlerini iskelet videosunda doğru bir şekilde gösterebilmelidir. Uygulamanın kullanıcı arayüzü, yöneticinin katılımcı bilgilerini kolayca girmesine, etkinlikleri seçmesine ve kayıt sürecini kontrol etmesine izin verecek şekilde kullanıcı dostu olmalıdır. Sistem, kayıtlarda veri kaybı ya da bozulma olmadan doğru bir şekilde kaydedilmesini sağlayacak şekilde güvenilir olmalıdır. Uygulama, işletim sistemiyle uyumlu olmalı ve birden fazla kinect v2 sensörünün entegrasyonunu desteklemelidir. Sistem, performans düşüşü olmadan belirlenen katılımcı sayısını ve kayıt oturumlarını yönetebilmelidir.

Tablo 3.1 Fonksiyonel Olan ve Fonksiyonel Olmayan Gereksinimler


Fonksiyonel Gereksinimler	Fonksiyonel Olmayan Gereksinimler
Kayıt İşlemleri	Performans
Etiketleme ve Puanlama	Doğruluk
Video Görüntüleme	Kullanılabilirlik
Veri Taşıma	Güvenilirlik
Veri Seti Yönetimi	Uyumluluk
Kullanıcı Girişi	Ölçeklenebilirlik
Socket Bağlantısı	
Katılımcı Yönetimi	
Yetki Kontrolü	
Performans ve Hız	
Kullanıcı Dostu Arayüz	

3.2. Kullanım Senaryosu

Veri toplamak için kullanılacak program backend ve frontend olmak üzere iki kısımdan oluşmaktadır. Her iki kısım için de kullanım senaryoları (Use Case Diyagram) belirlenmiş, ona göre çalışmalar şekillenmiştir.

3.2.1. Masaüstü Programı Kullanım Senaryosu

Masaüstü uygulamasının çalışmasına yönelik kullanım senaryosu diyagramı Şekil 3.1’de verilmiştir. Burada sistemle etkileşimde olan iki aktör bulunmaktadır: kullanıcı ve katılımcı. Kullanıcı, “Kullanıcı Girişi” durumunu gerçekleştirebilir. Bu durumda bilgileri kontrol edilir ve doğru ise sisteme başarıyla giriş yapar. Giriş doğrulamasıyla birlikte ilgili kullanıcının üzerinde çalıştığı veri setleri ve etiketler veri tabanlarından çekilir. Bu çekilen veri setleri “Veri Setini Seç” durumunda kullanıcıya listelenir ve seçim yapması sağlanır. Benzer bir şekilde kayıtlar için “Katılımcı Seç” durumu ile yeni kullanıcı oluşturulabilir ya da var olan kullanıcı seçilebilir. Katılımcı ve kullanıcının aktör olduğu “Hareket Kaydı” durumunda kullanıcı gerekli bilgileri girdikten sonra katılımcıdan Kinect sensörleri aracılığıyla veri toplanır. Kullanıcı, kaydının başarıyla alınması sonrasında o kayıt için ilgili etiketi seçer. Kullanıcı “Veri Seti Kaydı” durumunda alınan kayıtların senkronizasyonunu tamamlar.




Şekil 3.1 Masaüstü Uygulaması Kullanım Senaryosu Diyagramı

3.2.2. Backend Programı Kullanım Senaryosu

Backend sistemi, ilişkisel MySQL veri tabanı ve PHP dili ile Laravel framework teknolojileri kullanılarak inşa edilmiştir. Yöneticilerin yeni kullanıcılar oluşturması, veri setleri ataması ve etiketleme için kullanılacak puanlama kriterlerini oluşturması gibi tanımlamaların yapılmasına olanak sağlar. Şekil 3.2’de sistemin backend kısmı için hazırlanan use case diyagramı verilmiştir. Bu senaryoda yönetici olarak tek aktör bulunmaktadır. Yönetici “Kullanıcı Girişi” durumu ile giriş yapabilir ve “Kullanıcıları Yönet” durumu ile diğer kullanıcılar üzerinde tanımlanan veri seti bilgilerini düzenleyebilir. “Veri Seti Yönet” durumunda sistem, yöneticiye yeni veri seti oluşturma imkânı verir. “Etiketleri Yönet” durumunda ise her aktivite ya da veri

seti ile ilgili olan durum için çeşitli etiketler ve değerlendirme aralıkları oluşturabilmektedir. Bu etiketler kayıt toplama sırasında veri toplayıcı kişiye gösterilerek her kayıt için etiketleme işlemi yapılmasını sağlamaktadır.



Şekil 3.2 Backend Uygulaması Kullanım Senaryosu

3.3. Kinect Sensör


Kinect teknolojisi, her ne kadar Microsoft Xbox tarafından oyun oynamak üzere geliştirilmiş olsa da basit hareket algılamadaki üstün performansı ve uygulama geliştiriciler için sağladığı yazılım geliştirme materyalleri (SDK) sayesinde, video analizinde Kinect sensörler kullanılarak, bir çok uygulama geliştirilmiştir [23]. Yüksek çözünürlüklü sensörlerin dahil edilmesi ve gerçek zamanlı olarak insan iskeletlerini takip edebilme yeteneği, interaktif oyun deneyimlerini sadece geliştirmekle kalmamış, aynı zamanda sağlık, perakende ve güvenlik gibi alanlarda daha zengin veri setleri

sağlayarak yeni yollar açmıştır [24]. Yapılan çalışmada Şekil 3.3'te bulunan Xbox One Kinect v2 kullanılmıştır. Her ne kadar Kinect SDK, tek bilgisayara birden fazla sensör takılmasını desteklemese de benzer çalışmaların varlığı sayesinde araştırmalarımızı bu konu üzerine yoğunlaştırarak[25], yapılan çalışmada kaliteyi arttırmak için aynı anda iki adet Kinect sensör kullanarak iki farklı açıdan video çekim işlemi yapılmıştır. Kinect sensörleri, bir sahnenin derinlik bilgisini yakalamak ve sahnenin 3 boyutlu bir temsilini sağlamak ve altı kişiye kadar insanın eklem noktalarını tespit edecek şekilde geliştirilmiştir. Bu özellik, insanların önemli özelliklerini saptamaya yardımcı olmaktadır. Kinect sensörlerinden elde edilen derinlik bilgileri sayesinde geliştirilen yapay zeka modelleri sadece gerekli hareket bilgisine odaklanarak, diğer çevresel faktörler minimize edilmiştir. Sonuç olarak yapay zeka modelleri tarafından analiz edilen verinin kalitesi oldukça yüksek olmaktadır. Kinect sensörleri sayesinde CNN'ler, sensörlerden toplanan vücut hareketiyle ilgili önemli bilgilere daha fazla odaklanmaktadır.



Şekil 3.3 Xbox One Kinect v2

Kinect v2 sensörleri, kızılötesi derinlik sensörleri kullanarak aynı anda 6 kişiye kadar insanı tanıyabilir. Tanımladığı insanlara ait 25 adet noktanın koordinatlarını iletir.



Şekil 3.4 Kinect sensör tarafından gönderilen noktalar

Kinect sensor tarafından bodyFrame verisi ile gönderilen bilgiler şu şekilde tanımlanmaktadır: 0 - Omurga Tabanı, 1 - Omurga Ortası, 2 - Boyun, 3 - Kafa, 4 - Sol Omuz, 5 - Sol Dirsek, 6 - Sol Bilek, 7 - Sol El, 8 - Sağ Omuz, 9 - Sağ Dirsek, 10 - Sağ Bilek, 11 - Sağ El, 12 - Sol Kalça, 13 - Sol Diz, 14 - Sol Ayak Bileği, 15 - Sol Ayak, 16 - Sağ Kalça, 17 - Sağ Diz, 18 - Sağ Ayak Bileği, 19 - Sağ Ayak, 20 - Omurga Omuz, 21 - Sol El Ucu , 22 - Sol Başparmak, 23 - Sağ El Ucu, 24 - Sağ Başparmak

Kinect sensörleri ile Kinect SDK üzerinden iletişim kurulabilir. Kinect SDK bir bilgisayarda sadece bir Kinect sensor bağlantısını desteklemektedir. Bu sebeple bir bilgisayarda sanallaştırma ile ikinci işletim sistemi kurularak tek bilgisayarda iki adet Kinect Sensör ile kayıt yapmak üzere çalışmalar yapılmıştır. Bu kapsamda USB

Redirector uygulaması kullanılmış ve Incentive Pro firmasından ücretsiz lisans alınmıştır. Bu sayede tek bilgisayarda sanallaştırma ile iki adet Kinect Sensör ile kayıt yapılabilmektedir.

Kinect sensörleri ile alınan veriler, colorFrame ve bodyFrame şeklinde alınmaktadır. Color Frame metodundan 1920x1080 çözünürlüğünde video alınabilirken Body Frame metodundan gelen veriler anlık olarak iskelet videosuna dönüştürülmüştür. Video oluşturulurken 3 numaralı kafa noktasına büyük bir daire, diğer tüm noktalara daha küçük daireler yerleştirilmiştir. Sensörden gelen veriler arasında noktanın uzaklık bilgisi de vardır. Bu bilgiye göre noktalar daha küçük veya daha büyük olarak oluşmaktadır. Ayrıca [0, 1, 20, 2, 3], [15, 14, 13, 12, 0, 16, 17, 18, 19], [21, 7, 6], [10, 11, 23], [22, 6, 5, 4, 20, 8, 9, 10, 24] noktaları birleştirilerek çizgiler oluşturulmuş ve iskelet görünümü elde edilmiştir. Projenin ilerleyen aşamalarında yapay zeka ile hareketleri tanımak için rgb video ve json dosyasının yanı sıra anlık oluşturulan bu iskelet videosu da kullanılarak denemeler yapılmış ve en uygun formata karar verilmiştir.


Kinect sensörleri ile iletilen veriler, Frontend arayüzünü kullanarak canlı olarak görüntülenir. Her kayıt işlemi için RGB video, iskelet video ve iskelet verisi (JSON formatında) olmak üzere 3 dosya kaydedilir: Dosyaların adlarında benzersiz bir UUID, veri seti ID'si ve kullanıcı ID'si kullanılır ve dosyalar belirli aralıklarla harici bir diske taşınır. Kaydedilen videolar arayüzde görüntülenebilir ve tam ekran modunda oynatılabilir. Kullanıcı, videoları etiketlemek için hareketle ilgili puanlama yapabilir ve etiketleme için kullanılacak kriterler sunucudan masaüstü uygulamaya çekilir. Etiketler ve puanlamalar kayıt işlemi sırasında json dosyasına kaydedilir. Bu aşamadan sonra veri toplama kısmı tamamlanmış ve veriler veri işleme aşamasına geçmeye hazır hale getirilmiş olur.

3.4. Veri Toplama Uygulaması

AIMove uygulaması, backend için Laravel framework ve frontend için Electron üzerine çalışacak şekilde Vue.js framework kullanılarak geliştirilmiştir. Framework seçimi, kullanım kolaylığı, sağlam özellikler, esneklik ve performans

özellikleri incelenerek ve geliştirme yapan ekibin tecrübeleri değerlendirilerek yapılmıştır.


Şekil 3.5'te verilen Deployment Diyagramı, projedeki bileşenleri ve bağlantılarını göstermektedir. İki Kinect sensörü tek bilgisayara bağlı olarak sanallaştırma ile iki farklı makine üzerinde çalışır gibi kurgulanmıştır. Bilgisayarlar veri tabanlarına erişmek ve değiştirmek için sanal sunucuyla iletişim kurar. Bu, verilerin sistem genelinde sorunsuz paylaşımını ve senkronizasyonunu sağlar. Bilgisayarlardaki masaüstü uygulamaları, yerel makinelerin bilgi işlem gücünü kullanarak video verilerini yakalamak ve işlemek için Kinect cihazlarıyla etkileşime girer. Kaydedilen veriler taşınabilir disk sürücünde yerel olarak depolanabilir ve bu da bir yedekleme ve çevrimdışı depolama seçeneği sunar.



Şekil 3.5 Sistemin Dağıtım Diyagramı (Deployment Diyagramı)

Sanal sunucudaki API ağ geçidi ile önemli verileri depolayan veri tabanlarını barındıran diğer bir sanal sunucuya erişilmektedir. Bu sayede üç veri tabanına erişim sağlanabilmektedir: veri seti veri tabanı, kayıt veri tabanı ve kullanıcı veri tabanı. Kayıt veri tabanı ham video ve iskelet video verilerini içermektedir. Kullanıcı veri tabanı, kimlik doğrulama ve yetkilendirme amacıyla yönetici ve kullanıcı kimlik bilgilerini saklamaktadır.

Şekil 3.6, veri toplama işlemi yapacak istemci uygulamanın dizi diyagramını göstermektedir. İlk olarak veri toplamak isteyen uzman uygulamaya giriş yapmalıdır. Web uygulaması kullanıcının bilgilerinin doğruluğunu veri tabanından kontrol eder ve buna göre giriş gerçekleştirilir. Uzman veri setlerini listeleme, seçim yapma, yeni bir kayıt oluşturma gibi işlemleri yapabilmektedir. Yeni bir veri eklenecekse uygulama web uygulaması ile haberleşerek veri tabanını güncellemek üzere gerekli işlemler gerçekleştirilir.



Şekil 3.6 İstemci Uygulamanın Dizi Diyagramı (Sequence Diyagram)


Web uygulamasına kaydolduktan sonra kullanıcı adı ve şifre ile giriş yapılır ve buradan veri setlerini listeleme, etiket oluşturma, etiketlerin sırasını düzenleme gibi birçok düzenleme yapılabilir. Masaüstü uygulamasına da web uygulamasında olduğu gibi kullanıcı adı ve şifre ile giriş yapılır ve kullanıcı, yetkisine göre işlemleri gerçekleştirebilir. Veri setleri görüntüleme ve kayıt alma gibi işlemler yönetilebilir. Katılımcı eklerken gerekli kişisel bilgilerin girilmesi gerekmektedir. Bu bilgiler veri toplama işlemini yapan kişi tarafından girildikten sonra “EKLE” butonuna basarak işlem tamamlanmaktadır. Eklenen kullanıcı, ilgili aktivitelerin kayıt sayıları ve verilerin yüklenme oranı listede görülür. Tablo 3.2’de kullanıcıların katılımcı hareketlerini puanlamak için kullandıkları sorular verilmiştir.

Tablo 3.2 Hareketleri Puanlamak İçin Kullanılan Sorular

Yürüme	1) Vücut dik olmalı. 2) Baş ve gözler karşıya bakmalı. 3) Kollar ters kol ters bacak olacak şekilde doğal, rahat, gövdeden çok açılmadan ritmik hareket etmeli. 4) Yürürken ayaklar düz, tabandan parmak ucuna doğru hareket tamamlanmalı. 5) Denge bozulmadan yürünmeli. 6) Ritmik bir şekilde (hız değişimi olmadan) eşit adımlarla yürüyüş yapılmalı.
Yatay Atlama	1) Ayaklar omuz genişliğinde açık, dizler hafif bükülü, kollar geriye alınarak beklenmeli. 2) Baş ve gözler karşıya bakmalı. 3) Atlamanın ilk basamağında kollar aşağıdan öne alınırken çift ayak yerden kaldırılmalı. 4) Havada mesafe alınmalı. 5) Ayaklar omuz genişliğinde açık, dizler bükülü iki ayakla yere konuş yapılmalı. 6) Yere konuşa denge kaybı olmamalı.
Topu Yakalama	1) Yakalama sırasında top takibi yapılmalı. 2) Top, eller öne ve yukarı uzatılarak vücuda temas ettirmeden önde tutulmalı/yakalanmalı. 3) Top iki el kullanılarak tutulmalı.

	4) Top tutulduktan sonra dirsekler bükülerek vücuda yaklaştırılmalı. 5) Tutmada/yakalamada ağırlık aktarımı yapılmalı
Ayakla Topa Vurma	1) Destek ayağı, topun yanına konmalı. 2) Vuruş öncesi hedefe bakılmalı. 3) Vuruş yapacak bacak kalçadan geriye alınmalı 4) Vuruş bacağı öne topa doğru hareket etmeli. 5) Ayağın iç kısmı ile topun yanına vuruş yapılmalı. 6) Topa vurduktan sonra bacak ile takibi yapılmalı.

Yeni kayıt alma ve etiketleme adımları Şekil 3.7’de Şekil 3.1 verilmiştir. Yönetici tarafından daha önceden ilgili veri seti için belirlenen etiketler kayıt tamamlandıktan sonra veri seti ile eşleştirilir ve kayıt alma işlemi sırasında video kaydı tamamlandıktan sonra bütün etiketler ve derecelendirme bölümü görüntülenir. Veri toplayan uzman video kayıtlarına göre bu bilgileri doldurarak veri toplama işlemini tamamlar.



Şekil 3.7 Kayıt ve Etiketleme İşlemlerinin Örnek Görüntüleri

Uygulama, katılımcıların hareketlerini iki adet Kinect v2 sensör kullanarak yakalayacak şekilde geliştirilmiştir. Kinect v2, kamera ve emitörden oluşan kızılötesi bir derinlik sensörü kullanmaktadır. Kamera yansıyan noktaları yakalarken emitör kızılötesi noktalardan oluşan bir desen yansıtmaktadır, bu nokta desenleri analiz edilerek derinlik bilgisi hesaplanır. Kızılötesi kamera aynı zamanda düşük ışık koşullarında da cihazın çalışmasını sağlamak ve desenleri tespit ederek iskelet

takibine yardımcı olmaktadır. İskelet takip algoritması, derinlik verilerini analiz ederek katılımcının eklemlerini ve vücut segmentlerini tanımlamaktadır. Bu eklemleri 3 boyutlu bir alanda eşleştirerek, katılımcının hareketlerini gerçek zamanlı olarak izlemeye olanak sağlamaktadır. Kinect üzerinde bir de RGB kamera bulunmakta ve bu kamera ile kullanıcının ve çevredeki ortamın video akışı yakalanmaktadır. Bu girdi renk tabanlı hareketlerin ve yüz ifadelerinin tanımlanmasına da olanak sağlamaktadır. Yüksek kalitede veri yakalama yetenekleri ve katılımcılarının iskelet verilerini çözümleyebilmelerinin yanı sıra SDK ile uygulama geliştirilebilmektedir.


Frontend sistemi Vue js framework ile Electron üzerinde masaüstü uygulama olarak geliştirilmiş, veritabanı olarak SQLite kullanılmıştır. İki farklı Kinect ile aynı anda kayıt yapabilmek için Socket bağlantı altyapısı olarak Pusher js kullanılmıştır. Bu sayede sanallaştırma ile tek bilgisayarda kayıt yapılmasına imkan sağlanabiliyorken farklı iki bilgisayar ile de senkronize olarak veri toplanmasına imkan tanınmıştır.

Frontend sistemi geliştirilirken çeşitli kütüphaneler kullanılmıştır. Bu kütüphanelerden bazıları hakkında bilgi vermek gerekirse, Electron, işletim sistemi üzerinde masaüstü uygulamaları geliştirmek için kullanılan bir framework olup, Chromium ve Node.js'i bir araya getirerek tarayıcı tabanlı uygulama geliştirilmesine olanak tanır. Sass, CSS'in daha güçlendirilmiş bir sürümüdür ve değişkenler, fonksiyonlar ve nesting gibi özellikler ile daha kolay ve düzenli CSS yazılımını destekler. Vite, modern tarayıcıların native ES modules özelliğinden faydalananak hızlı bir geliştirme sunucusu ve yapılandırma aracı olarak hizmet verir. Axios, HTTP istekleri yapmak için kullanılan kolay ve işlevsel bir kütüphane sunar. Kinect2, Kinect sensörü ile iletişim kurmak için kullanılan ve motion capture, ses algılama ve görüntü işleme gibi özellikleri destekleyen bir kütüphanedir. Date-fns, tarih ve saat işlemleri için kullanılan ve tarih formatlama, manipüle etme ve çeşitli zaman dilimlerinde çalışma işlevleri sunan bir kütüphanedir. TailwindCSS, CSS'in utility-first yaklaşımını benimseyen ve önceden tanımlanmış sınıflar ile stil uygulamasını hızlı ve verimli hale getiren bir araçtır. Vue, component tabanlı bir yapıya sahip olan ve SPA (Single Page Application) geliştirmek için ideal bir JavaScript frameworküdür. SQLite3, küçük ve yerel veri tabanı ihtiyaçları için kullanılan, hafif ve taşınabilir bir SQL veri tabanıdır.

Knex, SQL sorguları oluşturmak ve veri tabanı işlemlerini yönetmek için kullanılan ve farklı veri tabanı motorları ile uyumlu çalışabilen bir sorgu yapısı oluşturma kütüphanesidir. Pusher.js, WebSocket tabanlı mesajlaşma hizmeti Pusher'ın JavaScript istemci kütüphanesi olup, gerçek zamanlı bildirimler için kullanılır. Laravel Echo ise gerçek zamanlı uygulamalar için WebSocket bağlantısını kolaylaştıran ve Laravel ile kolay entegrasyon sağlayan bir kütüphanedir.

Backend sistemi, MySQL veri tabanı ve Laravel framework kullanılarak geliştirilmiştir. Yöneticilerin kullanıcıları, veri setlerini ve puanlama kriterlerini yönetmesine olanak sağlar. Kullanıcının veri seti seçimini gerçekleştirir ve ilgili veri setine kayıt yapabilir. Pusher ve Laravel Echo kullanılarak, birden fazla bilgisayardan yetkisi olduğu veri setine bağlanmasını, peer to peer bağlantı kurmasını sağlar ve aynı anda bağlı bilgisayarların kayıt işlemine başlamasına, durdurmasına ve kaydetme işlemini yapmasına imkan verir.

Veri tabanı tasarımı Şekil 3.8 Veri tabanı UML Diyagramı gösterilmektedir. Kullanıcı (user) bilgileri bir tabloda tutularak yetkilendirme yapılır; kullanıcı, admin ya da veri toplama görevlisinden birisi olabilir. Bir diğer tabloda veri setlerinin bilgileri tutulmaktadır. Kullanıcı ve veri setleri (datasets) tabloları arasında bir ilişki vardır. Birden fazla kullanıcı birden fazla dataset üzerinde çalışabileceği için bu iki tablo “dataset_user” tablosu ile ilişkilendirilmiştir. Her dataset için kaydı alınacak katılımcıların bilgilerini tutmak için “candidates” tablosu oluşturulmuştur. Her datasetin birden fazla katılımcısı olur ve katılımcıların kayıt bilgileri “records” tablosunda tutulur. “Predictions”, “models” ve “labels” tabloları makine öğrenmesi çalışmasında kullanılmak üzere tasarlanmıştır.



Şekil 3.8 Veri tabanı UML Diyagramı

3.5. Veri İşleme

Frontend sistemi Vue js framework ile Electron üzerinde masaüstü uygulama olarak geliştirilmiştir. Yazılım Electron framework ile hazırlandığı için web

teknolojileri ile uygulama geliştirilmiş ve Windows, Mac ve Linux işletim sistemlerinde çalışabilen bir program ortaya çıkmıştır fakat Kinect SDK sadece windows üzerinde çalıştığı için uygulama sadece windowsta çalışır durumdadır.

Backend tarafında tanımlanmış kullanıcı ile giriş yapıldığında kullanıcı, yetkisi olan veri setlerini görebilir ve istediği veri setine yönetici veya yardımcı olarak girebilir. Uygulama SPA (single page application) olarak vue js framework ile hazırlanmıştır. Arayüzler tailwindcss kullanılarak kodlanmış bu sayede farklı ekran çözünürlüklerinde uygulamanın düzgün görünmesi sağlanmıştır. Burada sistemle etkileşimde olan iki aktör bulunmaktadır: kullanıcı ve katılımcı. Kullanıcı yetkisi dahilinde Backend sistemine giriş yaparak veri setleri oluşturabilir, başka kullanıcıları bu veri setlerini kullanmak üzere yetkilendirebilir. Kullanıcı ayrıca masaüstü uygulamaya da kullanıcı adı ve şifresi ile giriş yapabilir. Masaüstü uygulamaya giriş yapan ilgili kullanıcının, yetkisi dahilinde olan, üzerinde kayıt yapabileceği veri setleri ve kaydettiği videoların etiketleri backend uygulamadan çekilir. Bu çekilen veri setleri kullanıcıya listelenir ve seçim yapması sağlanır. Kullanıcı istediği veri setine "Yönetici" veya "Yardımcı" olarak giriş yapabilir. Bu durumda kullanıcı eğer "Yardımcı" rolünü seçti ise sensör aktif hale gelir, ekranda rgb video ve iskelet video görüntüleri açılır ve yöneticiden gelecek komutları dinlemeye geçer. Kullanıcının burada başka işlem yapmasına gerek yoktur. Kullanıcı eğer "Yönetici" rolünü seçti ise katılımcıları yöneteceği ekran açılır. Bu ekranda katılımcıların isim, boy, kilo, doğum tarihi kriterleri girilerek kayıtları yapılır ve tüm katılımcılar listelenir. Her bir katılımcı için hangi hareketin kaç kez kaydedildiği gösterilir. Yönetici "Hareket Kaydı" için kayıt yapmak istediği katılımcıyı seçer.

Yönetici bir katılımcıyı kaydetmek istediğinde bu kayıt sadece kullanılan bilgisayara yapılır, sunucu tarafına katılımcı bilgileri kaydedilmez. Uygulamada bu kayıt işlemi için SQLITE veritabanı ve bu veri tabanı ile iletişim için SQLITE3 paketi kullanılmıştır. Uygulamanın bir kez giriş yapıldıktan sonra offline olarak çalışması için ORM olarak knex paketi kullanılmış böylece local veritabanı işlemleri kolaylaştırılmıştır. Kullanıcı katılımcıyı kaydettikten sonra, bir katılımcıyı seçmesi ile kayıt ekranı açılır, sensör aktif hale gelir ve rgb video ve iskelet video görüntüleri açılır. Yönetici kayıt ekranını açtığında Kinect 2 paketi ile Kinect 2 SDK bağlantısı

kurulur ve Kinect 2 SDK ile sağlanan tüm özellikler kullanılabilir. Bu yazılımda sensör tarafından iletilen colorFrame ve bodyFrame verileri kullanılmıştır. ColorFrame verisi rgb video olarak, bodyFrame verisi ise iskelet video olarak kaydedilir. BodyFrame verisi bir obje şeklindedir ve içeriğinde 6 adete kadar insanı yakalayabilir ve her insanın baş, boyun, omuz kol gibi 25 adet noktasının 3 boyutlu kordinatını içermektedir. İskelet videosunu hazırlarken bu noktalar kullanılarak iskelet çizimi yapılmış anlık olarak 60 fps ile video haline getirilmiştir. Ayrıca sensör tarafından iletilen objeler de olduğu gibi saklanmış ve ihtiyaç halinde daha sonra kullanmak üzere json formatında kaydedilmiştir. Yönetici kayıt ekranını açtığı anda Pusher js ile Socket bağlantısı kurulur. Yöneticinin kendi bilgisayarından yapacağı kayıt başlatma işlemi, kaydı durdurma işlemi ve etiketleme işlemi Pusher js ile socket bağlantısı kurulan diğer bilgisayarlara iletilir. Bu sayede aynı anda, aynı veri setine bağlı olan tüm bilgisayarda kayıt yapılabilir.

Socket bağlantısı için presence channel özelliği kullanılmış backend sunucu tarafında sadece kullanıcıların yetkisi olan veri setlerine bağlanmaları sağlanmış, yetki kontrolü için backend tarafında laravel-echo kullanılmıştır. Pusher üzerinde whisper özelliği ile peer to peer bağlantı kurularak backend sunucu üzerinden veri aktarımı yapılmamış; başlat, durdur ve kaydet komutları ile yardımcı bilgisayarlara sadece direktifler iletilmiştir. Böylece kayıt işleminin senkronize olarak aynı veri setinde çalışan tüm aktif bilgisayarlarda yapılması sağlanmıştır.


Kullanıcılar kayıt işlemi sonrasında kaydedilen rgb videoyu ve iskelet videoları ayrı ayrı ve isterse tam ekran olarak görüntüleyebilir, bu dosyaları dosya olarak kaydetmeden yeni video kaydı yapabilirler. Eğer videolar doğru olarak çekildiyse etiketleme işlemi yapılır. Etiketleme işlemi için kullanıcıdan hareket ile ilgili sorulara 1 den 5 e kadar puan vermesi istenir. Etiketlerin her biri için puanlama yapıldıktan sonra kullanıcının videoyu kaydetmek için kullanacağı buton aktif hale gelir. Kullanıcı videoyu kaydettiğinde socket bağlantısı ile bağlı olan diğer bilgisayarlar da kaydetme işlemini aynı etiket bilgisi ile yapar. Etiketleme işlemi sonrasında kullanıcının ekranı temizlenerek aynı katılımcı ile tekrar kayıt yapması sağlanır. Bu sayede aynı katılımcı ile farklı hareketlerin kaydı ard arda yapılabilir.

Kayıt işlemi yapıldığında her bilgisayara 3 adet dosya kaydedilmektedir. Birinci video kinect sensör üzerinden colorFrame verisi ile gelen rgb video kaydıdır. İkinci video kinect sensör üzerinden bodyFrame verisi ile anlık olarak oluşturulan iskelet video kaydıdır. Üçüncü dosya ise kinect sensör üzerinden bodyFrame verisi ile gelen iskelet verisidir. Bu json veri sensörden iletilen verinin raw halidir. Projenin ilerleyen aşamalarında yapay zeka ile hareketi tanımak için ihtiyaç halinde bu veri kullanılarak iskelet hareketleri yeniden oluşturulabilir. Bu veri json formatında kaydedilmiştir. Her bir kayıt işlemi için benzersiz bir UUID oluşturulmaktadır. Kayıt işlemi yapıldığında veri setine bağlı olan tüm bilgisayarlara bu UUID iletilmektedir ve kaydedilen dosyaların her birinin dosya adında UUID, veri seti idsi ve kullanıcı idsi kullanılmaktadır. Bu sayede veri seti içerisindeki tüm kayıtların birbirinden farklı dosya adları olur ancak aynı kayda ait olan dosyalar da kolayca ayırt edilebilir. Kaydedilen json dosyasında ayrıca kaydın yapıldığı tarih, katılımcının boy, kilo, doğum tarihi bilgileri ve kullanıcının etiketleme bilgilerine de yer verilmektedir. Dosyaların kaydedildiği klasör yine program arayüzünden açılabilir. Belirli aralıklarla bu kaydedilen dosyalar harici bir diske taşınır.


Backend Sistemi, ilişkisel MySQL veritabanı ve PHP dili ile Laravel framework teknolojileri kullanılarak inşa edilmiştir. Yöneticilerin yeni kullanıcılar oluşturması, veri setleri oluşturması, kullanıcıları veri setlerine ataması ve hareketleri etiketleme için kullanılacak puanlama kriterlerinin oluşturması gibi tanımlamaların yapılmasına olanak sağlar. Ayrıca laravel-echo ile Pusher üzerindeki veri setlerine bağlı olan bilgisayarlara yetki kontrolü de sağlar.

3.6. Toplanan Verilerden Örnekler


Toplanan verilerden örnekler aşağıdaki şekillerde verilmiştir. Kayıtlarla birlikte oluşturulan json dosyası formatı ise EK-4'te verilmiştir.




Şekil 3.9 Yürüme Hareketi Örnek Verisi



Şekil 3.10 Yatay Atlama Hareketi Örnek Verisi



Şekil 3.11 Topu Yakalama Hareketi Örnek Verisi



Şekil 3.12 Topa Vurma Hareketi Örnek Verisi

4. SINIFLANDIRICI YAPAY ÖĞRENME MODELLERİ

Dağıtık mimariye göre hiçbir problem ve çakışma olmadan verileri kaydedebilmek için UUID kullanılmış ve farklı zamanlarda, farklı mekanlarda iki farklı kinect setiyle yapılan kayıtların çakışması engellenmiştir. Tek bir merkezi noktada veri tabanı oluşturmaya ihtiyaç kalmadan dosyalar üzerinden kendi veritabanımızı oluşturabileceğimiz bir yapı kurgulanmıştır. Bu yapı sayesinde veri toplama aşamasında toplanan ve hard drive üzerine farklı isimlerde klasörlere yüklenmiş halde bulunan kayıtlar tipik ve atipik olarak iki ana klasöre ayrılmış ve kullanılabilir hale getirilmiştir. Veri toplama işleminde her bir kinect kameradan 3 dosya kaydı yapılmıştır. Bu dosyalardan ilki hem kinect kameradan gelen verilerin kaydedildiği hem de katılımcının doğum tarihi, yaş, kilo, hangi hareketi yaptığı, yaptığı hareketin puanlaması gibi bilgilerin olduğu bir adet json dosyası. İkinci dosya kinect kameradan elde edilen eklem nokta koordinatları ile çizilmiş, katılımcı hareketleri ile ilgili iskelet videosunun webm formatında kaydı ve son olarak aynı sürecin standart rgb renklerle kaydedilmiş webm formatında video dosyasıdır.

Tüm katılımcıların her veri kaydı 2 kinect kamera ile yapıldığı için her bir çekimde toplamda altı adet dosya kaydolmuştur. Bu altı dosyanın her birinin adında, o çekim için oluşturulan benzersiz UUID kodu, dosyanın iskelet videosu mu yoksa rgb video mu olduğu bilgisi, bu dosyanın ana kamera ile mi yapıldığı yoksa yardımcı kamera ile mi yapıldığı bilgisi bulunmaktadır. Dosyalar bir çok farklı klasör altında dağınık şekilde bulundukları için dosya konumlarını, katılımcı bilgilerini içeren veri seti veritabanı olarak kullanılacak bir csv dosyası oluşturmak için geliştirme yapılmıştır.

4.1. Veri Seti Oluşturma

Veri seti veritabanı oluşturmak için python yazılım dilinde geliştirme yapılmıştır. Bu kod katılımcı hareketleriyle ilgili video ve JSON veri dosyalarını

işlemek için tasarlanmış, verilerin çıkarılmasına, dönüştürülmesine ve yüklenmesine odaklanan kapsamlı bir komut dosyası olarak hazırlanmıştır. Kullanılan temel kütüphaneler regex için re, CSV dosyalarını işlemek için csv, JSON dosyalarını ayrıştırmak için json, dosya sistemi navigasyonu için os ve glob, tarih ve saat özniteliklerini işlemek için datetime, veri manipülasyonu için pandas ve np'dir.

Geliştirilen kod ile ilk olarak verilen klasör ve tüm alt klasörleri recursive olarak gezerek webm ve json formatındaki tüm dosyaların pathlerini elde edecek şekilde işlem yapılmıştır. Elde edilen dosyalara ait tüm pathler bir csv dosyasına yazılmış ve dosya isimlerinde geçen her veri kaydı için benzersiz olan UUIDleri tespit edecek bir regular expression yazılmıştır. Bu sayede her çekime ait altı adet dosya birbirleri ile ilişkilendirilebilmiştir. Kodun en karmaşık kısmı, daha ayrıntılı ve temiz bir CSV çıktısı oluşturmak için verilerin işlenmesiyle ilgilidir. Bu kısımda ilk oluşturulan dosya yollarının yazılı olduğu CSV dosyası ve JSON dosyaları, içeriği de dahil olmak üzere, okunur. Her çekim işlemi için bir satır işlenir ve o çekimdeki katılımcıya ait doğum tarihinden çekim yapılan gün arasındaki fark alınarak katılımcının yaşı hesaplanır. Verilen etiket değerlerinin hepsinin ortalamaları alınır ve üç üzerinden bir değer olarak Label 3 kolonuna yazılır. Type kolonuna katılımcılar, atipik için 'A' ve tipik için 'T' olarak kaydedilir. Tablo 4.1'de verildiği gibi yapılan hareketin yürüme, yatay atlama, topu yakalama, ayakla topa vurma gibi hareketlerden hangisi olduğu bilgisi de Movement sütununa 1, 2, 3, 4 olarak işlenir.

Tablo 4.1 Veri Toplama Yapılan Hareketler

1	2	3	4
Yürüme	Yatay Atlama	Topu Yakalama	Ayakla Topa Vurma

Proje başlangıcından tez yazımına kadar olan süreçte toplanan veri adetleri Tablo 4.2 de verildiği gibidir. Tablodan da görüleceği üzere Atipik katılımcılardan Hareket 1 verisi 964 adet ile en az toplanan veri olmuştur.

Tablo 4.2 Kategorilere Göre Kaydedilen Video Sayıları

Tür	Yürüme	Yatay Atlama	Topu Yakama	Topa Vurma
Atipik	964	1074	1012	1131
Tipik	2936	3135	2888	2939

Bu işlemlerden sonra yapay zeka eğitiminde kullanılacak verinin dengeli olabilmesi için, katılımcı tipi, hangi hareketi yaptığı gibi bilgileri kategori olarak değerlendirirsek veri setinin bir kategoriye doğru eğilimli olarak sonuç üretmemesi için veri budama işlemi yapılmıştır. Her ne kadar toplamda 16072 adet video çekimi yapılmış olsa da, budama işlemi ile her bir Tür / Hareket kombinasyonu için 964 adet olmak üzere toplamda 7712 video kullanılabilmiştir. Aynı zamanda verilen değerdeki eğilimi yok etmek için ise geliştirme aşamasında “stratify” özelliği de kullanılmıştır. Veri setini daha iyi anlamak ve kontrol etmek için bu işlemler tüm model eğitim süreçlerinden önce yapılmıştır. Genel olarak geliştirilen bu kod ile ham veriden yapay zeka model eğitimi aşamasında kullanılabilecek şekilde yapılandırılmış bir veritabanı oluşturulmuştur.

4.2. Dosyaların Dönüştürülmesi

Geliştirme sırasında elde edilen videolar herhangi bir işleme tabi tutulmadan webm formatında kaydedildi. WebM formatı, web akışı için verimli olsa da, yaygın olarak desteklenen bir format olmadığından, makine öğrenimi için kullanım sırasında ortaya çıkması muhtemel uyum sorunları nedeniyle videolar MP4 formatına dönüştürüldü. Bu dönüşüm işlemi veri toplama aşamasında yapılabileceği gibi tüm veriler toplandıktan sonra yapay zeka sürecinden önce de yapılabilirdi. Veri toplamada kullanılan bilgisayarlara ekstra bir işlem maliyeti çıkarmamak ve süreci daha kısa tutmak adına tüm veriler toplandıktan sonra kaydedilen videoların MP4 formatına dönüştürülmesi tercih edildi. Bu dönüşüm aşamasında Python yazılım dili kullanılarak geliştirme yapıldı.

Geliştirilen Python kodunda, video, ses ve diğer multimedya dosyalarını ve akışlarını işleyen güçlü bir multimedya olan FFmpeg kütüphanesi kullanıldı. FFmpeg bir çok video dosyasını desteklediği gibi videoları WebM formatından MP4 formatına dönüştürmek için de uygun bir yapıya sahip olduğu için tercih edildi. Video dosyalarını WebM'den MP4 formatına dönüştürme sürecinde, dönüştürmenin sonucunu ve verimliliğini önemli ölçüde etkileyebilecek çok sayıda parametre vardır. Standardizasyon ve optimum performans için, ünlü açık kaynaklı video kod dönüştürücü HandBrake tarafından yaygın olarak kullanılan ve sitelerinde yayınlanan FFmpeg dönüştürme parametreleri kullanıldı. HandBrake'in benimsediği bu parametrelerden yararlanarak, video dönüştürme sürecinde tutarlı, yüksek kaliteli ve düşük boyutlu dosyalar elde edildi.

MP4 dosyaları yalnızca çeşitli video işleme ve makine öğrenimi kütüphaneleriyle evrensel olarak uyumlu olmakla kalmayıp aynı zamanda nispeten küçük dosya boyutlarıyla yüksek görsel kaliteyi de korumaktadır. Veri kümesinin güvenilir ve verimli makine öğrenimi deneyleri yapmak için en uygun format olan MP4 formatına videoların dönüşümünün sağlanması analizimizi daha yüksek doğrulukla ve daha az teknik aksaklıkla gerçekleştirmemize imkan verdi. İşlem sonucunda kinect sensörlerinden elde edilen koordinatlarla yapay olarak oluşturulan, katılımcı hareketlerine ait videolar H264 - MPEG4 AVC (avc1) video codec ile 1920x1080 pixel çözünürlüğünde, saniyede 30 frame olacak şekilde ses katmanı olmadan sadece ITU-R BT.601 Range renk uzayında video dosyası olarak kaydedildi. Video dosyaları dönüştürme işleminden sonra veri seti veritabanı olarak kullandığımız csv dosyası güncellenerek yeni oluşturulan MP4 dosyalarına ait pathler sütünlara eklendi.

4.3. Modeller


Araştırma sırasında, yaygın olarak kullanılan kütüphaneler ile çeşitli yapay zeka model mimarileri denendi. Bu süreç sonucunda, en iyi doğruluk oranını alacağı düşünülen iki farklı model üzerinde yoğunlaşıldı. İlerleyen süreçte detaylı olarak tanımlanacak olan modellerin ardındaki çalışma mantığı ve her birinin sunduğu belirli hesaplama avantajları açıklanacaktır.

4.3.1. Model 1: CNN LSTM Modeli

Üzerinde çalışma yapılan ilk model, özellikle video içeriğini kategorize etmek için oluşturulmuş, gelişmiş bir sinir ağı türüdür. Konvolüsyonel sinir ağları (CNN) ve uzun, kısa süreli bellek (LSTM) teknolojilerini birleştiren bir yapıya sahiptir. Daha önce de belirtildiği gibi, CNN'ler videoların görsel yönlerini işleme, desenleri ve özellikleri anlamak için görüntüler içindeki alanı analiz etme konusunda oldukça iyidir. Öte yandan, LSTM'ler olayların zaman içindeki ilerleyişini ele alarak bir kareden diğerine nasıl değiştiğini anlamlandırır. Bu model, CNN'leri her kareye ayrı ayrı uygulayan TimeDistributed katmanlarını, ardından kareler arasındaki değişiklikleri değerlendirmek için LSTM katmanlarını ve son olarak gerçek sınıflandırma kararını veren yoğun katmanları entegre ederek, hem görsel ayrıntıları hem de videolardaki dinamik hareketleri etkili bir şekilde yakalar ve video sınıflandırma görevleri için oldukça etkili hale getirir.

Modelimizin ilk aşamasında, MaxPooling2D, Dropout ve BatchNormalization gibi diğer katman türleriyle birleştirilen birkaç Conv2D katmanının etrafında TimeDistributed katmanları kullanan bir yöntem uygulanmıştır. Bu teknik, her konvolüsyonel işlemin ve ilgili işlemlerin bir video dizisinin her bir zaman dilimine veya karesine eşit şekilde uygulanmasını sağlar. Modelimiz, filtre boyutunda (32, 64, 128, 256 ve 512) artan Conv2D katmanları kullanarak çeşitli seviyelerde daha karmaşık desenlerin tanımlanmasına olanak tanır. Ek olarak, her Conv2D katmanına doğrusal olmama özelliği eklemek için bir ReLU aktivasyon fonksiyonu kullanır ve video verilerinden daha iyi öğrenmeye yardımcı olur. Modelin, eğitim verilerini ezberlemesini önlemeye yardımcı olmak için, öğrenme modelindeki büyük katsayıları durdurarak riski azaltan L2 düzenleyicisi kullanılmıştır. MaxPooling2D katmanları, bu konvolüsyonlar tarafından oluşturulan özellik haritalarının boyutunu azaltmaya yardımcı olmak için konvolüsyon katmanlarından sonra yerleştirilmiştir. Boyuttaki bu azalma yalnızca hesaplama yükünü azaltmakla kalmaz, aynı zamanda modeli görüntülerdeki özelliklerin tam konumlarına daha az duyarlı hale getirir ve böylece genelleme yeteneğini geliştirir. Bu süreç esasen modelin karmaşıklığını yönetmeyi destekler ve modelin eğitim verilerinde iyi performans gösterdiği ancak görünmeyen verilerde kötü performans gösterdiği yaygın bir sorun olan ezberlemeyi (Overfit) azaltmaya yardımcı olur.

Her bir yığın içindeki çıktıların tutarlı bir ortalama ve varyansa sahip olmasını sağlamak için BatchNormalization katmanları kullanılır ve bu da daha istikrarlı ve daha hızlı bir eğitim sürecine katkıda bulunur. Modelin yapısında, tek tek kareleri işleyen ilk CNN bölümünden sonra mimari, LSTM katmanlarını kullanarak olayların sırasını ve zamanlamasını anlamak için tasarlanmış bir aşamaya geçer. LSTM'nin ilk katmanı, sonraki LSTM katmanının analiz etmesi için kronolojik sırayı bozulmadan tutarak dizileri döndürür. Bu sonraki katman daha sonra dizinin zamanlamasına bağlı olan özellikleri tanımlamaya odaklanır. Modelin verileri ezberlemesini önlemek için bu LSTM katmanlarında, modelin yeni, görülmemiş verilere daha iyi genelleme yapmasına yardımcı olmak için, eğitim sırasında verilerin bazı kısımlarını rastgele atlayan Dropout kullanılmıştır. Bu rastgelelik, özelliklerin daha sağlam bir şekilde öğrenilmesini teşvik eder. Bu teknikler birlikte modelin eğitimini kolaylaştırarak daha etkili ve verimli bir hale getirir. Model, veri girdilerini işlemek için yoğun katmanlar (Dense) olarak adlandırılan katmanları kullanır. Bu katmanların sonunda softmax veya sigmoid aktivasyon fonksiyonu kullanılır. Softmax özellikle verilerin farklı kategorilerde sınıflandırılmasını içeren görevler için kullanışlı iken, sigmoid 0-1 gibi binary veriler için de kullanılır. Çok sınıflı sınıflandırma yapabilmek için modelde, kayıp fonksiyonu olarak categorical crossentropy kullanılmıştır. Bu fonksiyon özellikle çoklu sınıflar arasında ayırım yapmak için etkilidir ve bu tür senaryolarda standart bir seçimdir. 0-1 şeklinde binary sınıflandırma yapabilmek için ise binary_crossentropy kayıp fonksiyonu kullanılmaktadır. Modeli optimize etmek için özellikle derin öğrenme çalışmalarında büyük veri kümeleri ve çok sayıda parametre ile çalışırken gösterdiği verimlilik ile bilinen Adam optimize edici kullanılmıştır. Yine bu modelde de eğitim sürecinin gerçekleştiği her bir döngü (Epoch) sonrası EarlyStopping ve ModelCheckpoint callback tanımlamaları yapılmıştır.



Şekil 4.1 Model 1 Katmanlar

4.3.2. Model 2: Pretrained LSTM Modeli

Araştırma sırasında kullanılan yapay zeka modelinde, Keras derin öğrenme kütüphaneleri kullanılarak video sınıflandırması için daha önce eğitilmiş Inception modeli tercih edilerek derin sinir ağı modelinin oluşturulması ve eğitilmesi gerçekleştirildi. Bu model, doğası gereği ard arda gelen video frame verilerini işlemek için konvolüsyonel sinir ağlarını (CNN) ve uzun kısa süreli bellek ağlarını (LSTM) birleştirmektedir. Modelin özünde TimeDistributed katmanlarının içine gömülü Inception mimarisinin kullanımı yer alır. Özellikle görüntü verileri için faydalı olan Inception modeli, derin bir konvolüsyon katmanı, pooling ve çeşitli ölçeklerdeki özelliklerin birleştirilmesi yoluyla videonun her karesinden belirli özelliklerin çıkarılmasına olanak tanır. Inception hazır modeli kullanılarak son dört katmanı hariç


diğer tüm katmanları dondurulmuş görüntü verilerinin sadece son dört katmanı işlenmiş ve minimum hesaplama ek yükü ile güçlü performansından ve verimliliğinden faydalanılmıştır.

TimeDistributed wrapper, derin öğrenme modellerinin görüntüleri analiz etmekten videoları anlamaya geçişinde çok önemli bir rol oynar. Inception gibi belirli bir katmanı videonun her karesine bağımsız olarak uygulayarak çalışır. Bu, modelin her kareyi ayrı bir veri dilimi olarak ele aldığı ve her birinden ayrı ayrı özellikler öğrendiği anlamına gelir. Bu adım çok önemlidir çünkü modelin, tüm video dizisi boyunca hareketleri ve değişiklikleri anlamak için bunları birleştirmeden önce zaman içindeki her andan ilgili özellikleri yakalamasına olanak tanır. Bu özellikler daha sonra düzleştirme (Flattening) adı verilen bir işlemle daha basit, düz bir formata dönüştürülür. Bunu takiben veriler, dizileri anlamak için tasarlanmış özel bir ağ türü olan LSTM katmanlarından geçer. LSTM, sahnelerin ve eylemlerin zaman içindeki ilerleyişini kavrayabildiği için videoları analiz etmekte özellikle etkilidir. Tasarlanan yapay zeka modeli özellikle her düzleştirme adımından sonra iki LSTM katmanı kullanır, bu da video ilerledikçe zamansal değişiklikler hakkında daha ayrıntılı özelliklerin yakalanmasına yardımcı olur. Ayrıca, modelin sadece verileri ezberlemesini önlemek için (Overfit), dropout adı verilen bir teknik kullanılmaktadır. Bu teknik, eğitim sırasında bu katmanlardaki bazı düğümleri rastgele hariç tutarak modelin sadece eğitim verilerinde gördüklerini tekrarlamak yerine daha iyi genelleme yapmayı öğrenmesini sağlar.

Modelin videoları anlama sürecinde, bir videonun özelliklerini sırayla analiz ettikten sonra, öğrendiği önemli özellikleri videoyu belirli gruplara ayırmasına olanak tanıyan bir biçime dönüştüren yoğun katmanlar kullanır. Modelin bu karmaşık süreçle başa çıkmasına yardımcı olmak için bu katmanlarda doğrusal olmayan özellikler sunan ReLU aktivasyon fonksiyonları kullanılır. Modelin sadece eğitim verilerini ezberlemediğinden ve yeni, görülmemiş videolara da iyi genelleme yapabileceğinden emin olmak için, her yoğun katmandan önce yine dropout uygulanır. Modelin son kısmı, farklı kategorilerin olasılığını tahmin etmek için bir softmax veya binary tipinde tek bir seçeneği tahmin etmek için sigmoid aktivasyon fonksiyonu kullanan yoğun bir katmandır. Eğitim sırasında, modelin tahminlerinin gerçek kategorilerle ne kadar iyi

eşleştigini ölçmek için kategorik çapraz entropi kaybı adı verilen bir yöntem kullanılmıştır. Bu yöntem, bir ögenin birkaç kategoriden birine ait olabileceği durumlarda yaygın olarak kullanılır ve modelin tahminlerinin doğru olmasını sağlamaya yardımcı olur.

Araştırmada, model derleme için Adam optimizer'ı kullanıldı ve çeşitli parametreler için öğrenme oranları bağımsız olarak ayarlanarak eğitim süreci verimli bir şekilde optimize edildi. Modelin eğitim sürecinin gerçekleştiği her bir döngü (Epoch) sonrası callback adı verilen parametreye iki fonksiyon tanımlaması yapıldı. İlki, eğitimi geliştirmek için, metriklerdeki iyileşme sona erer ermez eğitimi durduran, hem zamandan hem de hesaplama gücünden tasarruf sağlayan ve modelin ezberleme yapmasını önlemeye yardımcı olan EarlyStopping callback fonksiyonu. İkincisi ise, eğitim aşamasında modeli sistematik olarak kaydeden ModelCheckpoint callbackidir. Bu, uzun eğitim döngüleri için çok önemlidir, çünkü süreç beklenmedik bir şekilde kesintiye uğrarsa bile en iyi modelin kayıtlı bir şekilde kalmasını sağlar.



Şekil 4.2 Model 2 Katmanlar

4.4. Videoları Kullanıma Hazırlama

Video dosyalarından gerekli verilerin çıkarılması ve işlenmesi için bu konuda yaygın olarak kullanılan OpenCV kütüphanesi tercih edildi. Çalışmaları yapılan tüm yapay zeka modellerini eğitmek ve video analizi yapmak için kullanılacak bu veriler araştırma sürecinde oldukça kritik bir rol üstlenmektedir. Video verilerinin çıkarılması için bir metod hazırlanmış ve tüm model çalışmalarında aynı metod kullanılmıştır.

Toplanan video verileri genelde 2 ile 5 saniye arasında değişen sürelerde kayıt altına alınmış ve her bir video dosyası MP4 formatına dönüştürülürken saniyede 30 frame olarak kaydedilmiştir. Videolardan veri çıkarma işlemi OpenCV kütüphanesinin

VideoCapture metodu kullanılarak yapılmış, süreç videoların bu metoda iletilmesi ile başlamıştır. Her bir videodan kaç frame alınması gerektiği ile ilgili 10, 20, 30 frame kullanılarak denemeler yapılmış ve en yüksek verim 20 frame ile elde edilmiştir. Bu verinin ışığında diğer tüm çalışmalara 20 frame ile devam edilmiştir. Videolardan 20 frame almak için videonun toplam frame sayısı bulunmuş ve kare çıkarımını tüm videoya eşit olarak dağıtmak için yakalanacak kareler arasındaki aralık hesaplanmıştır. Böylece alınacak karelerin videonun farklı bölümlerine eşit şekilde yayılması sağlanmıştır. Kurulan döngü ile sırayla okunan karenin, hesaplanan aralıktaki indekse göre kullanılacak veriler arasına dahil edilip edilmeyeceği kontrol edilip, eğer dahil edilecekse bir sonraki boyutlandırma işlemi için ayrılması sağlanmıştır. Kullanılacak kare, boyutlandırma işlemine alınmış, boyutlandırma ölçüsü bir değişkene bağlanmış ve standart olarak 128x128 pixel olarak belirlenmiştir. Boyutlandırma işleminden sonra karede bulunan her bir pixel 255 değerine bölünerek 0 ve 1 değerlerine normalleştirilmiştir. Bu normalleştirme işlemi, veri boyutlandırmanın genellikle performansı artırdığı sinir ağı girdilerine uygun verileri hazırlamak için oldukça önemlidir.

Yeniden boyutlandırma ve normalleştirmeden sonra kareler bir listeye eklenmiş ve döngü, tüm video karelerinin işlenmesi veya istenen kare sayısına ulaşılmasıyla sona ermiştir. Çalışmalar süresince videonun bir saniyeden kısa olma durumunda, 20 kareden daha az kare içerdiği durumlarda, listeyi belirtilen kare sayısına kadar doldurmak için “np.zeros” kullanılarak ek dolgu yapılmış ve bu gibi durumlarda girdi olarak kullanılacak veri boyutları tutarlı hale getirilmiştir. Yapay zeka modeline her video karesi grubu X dizisi olarak hazırlanırken aynı index üzerinden Y dizisi de oluşturularak video karesi grubuna ait etiketleme verisi hazırlanmıştır. Bu veri hazırlanırken Tipik ve Atipik tahmini için ayrı, hareketin tahmini için ayrı, yapılan hareketin puanlaması için ayrı bir işlem yapılmıştır.

Etiketleme verisi Tipik ve Atipik olduğunun tahmin edileceği yapay zeka modeli için veri setinde bulunan ‘Type’ sütununda yazan T veya A verisi normalleştirilerek 0 ve 1 olarak Y dizisine eklenmiştir. Yapılan hareketin tahmin edileceği yapay zeka modeli için ‘Movement’ sütununda kaydedilen 4 farklı hareket için 1, 2, 3, 4 olarak tutulan veri (1: yürüme, 2: yatay atlama, 3: topu yakalama, 4: topa

ayakla vurma) 0, 1, 2, 3 olarak Y dizisine eklenmiştir. Yapılan hareketin puanlamasının tahmini için Label 3 verisi 0, 1, 2 olarak Y dizisine eklenirken ayrıca hareketin ne olduğu bilgisi de 0, 1, 2, 3 olarak ayrı bir M dizisine eklenmiştir. Daha sonra video ve hareket verisi birlikte [X, M] şeklinde girdi olarak kullanılacak ve Y verisi tahmin edilmeye çalışılacaktır. Veri setinin hazırlanması sürecinde yapılan budama işlemi sonrasında her bir Tür / Hareket kombinasyonu için kullanılan 656 adet video ile toplamda 5248 adet video kullanılmıştır. Bu videolar 56 farklı katılımcı ile, her bir katılımcının her bir hareketi için maksimum 50 adet video kaydı alınarak oluşturulmuştur. Model eğitim süreçleri başlamadan önce, manuel olarak veriler katılımcı bazında tür ve hareket videoları olarak; eşit şekilde eğitim, doğrulama ve test olmak üzere üçe ayrılmıştır. Bu kapsamda yaklaşık 1000 adet doğrulama, 1000 adet test ve 3250 adet eğitim verisi ile çalışma yapılmıştır. Bu kapsamda modeller eğitim sürecini eğitim ve doğrulama verileri ile yaparken, daha sonra model raporları eğitim sırasında modelin hiç görmediği katılımcılara ait videolar ile yapılmıştır.

Tablo 4.3 Eğitim, Doğrulama ve Test İçin Ayrılmış Katılımcı Sayıları

Veri Seti	Tipik Katılımcı	Atipik Katılımcı
Eğitim	45	44
Doğrulama	7	9
Test	4	3


5. BULGULAR

5.1. Problem 1: Hareketi Tahmin Etme

Bu problemde, her iki model de eğitim ve validasyon aşamalarında doğruluk ve kayıp grafikleri ayrıca çok sınıflı sınıflandırma için ROC eğrilerini ve precision, recall, F1-score ve support'u kapsayan sınıflandırma raporlarını içerir. Bu modelleri etkili bir şekilde karşılaştırmak için bu temel metriklerin her biri incelenmiştir.

5.1.1. Model Doğruluğu Grafikleri


Şekil 5.1'te iki modelin doğruluk grafikleri verilmiştir. Model 1'in eğitim doğruluğu yaklaşık 0.6'dan başlayıp 5. epochda yaklaşık 0.9'a ulaşarak istikrarlı bir artış sergilemektedir. Ancak validasyon doğruluğu, epoch boyunca önemli dalgalanmalar göstermekte, başlangıçta 0.6'nın üstünde olup hızla yükselmekte ve zaman zaman 0.5 civarına kadar düşebilmektedir, bu da dengesiz ve tutarsız bir performansa işaret eder. Model 2'nin eğitim doğruluğu ise yaklaşık 0.8'den başlayıp 3. epochda 0.9'ı geçerek istikrarlı bir şekilde artmakta ve yaklaşık 0.97'de stabilleşmektedir. Validasyon doğruluğu da Model 1'e kıyasla daha az dalgalanma göstermekte ve genellikle eğitim doğruluğuna yakın seyretmektedir. İlk birkaç epochda bazı dalgalanmalar olsa da genel olarak daha stabil ve düzgün bir seyir izlemektedir. Sonuç olarak, Model 2 hem doğruluk hem de stabilite bakımından üstün performans sergilemekte, validasyon doğruluğundaki dalgalanmalar Model 1'e kıyasla çok daha az ve daha tutarlıdır, böylece genel olarak daha iyi bir model olarak öne çıkmaktadır.



Şekil 5.1 Problem 1 Model Doğruluğu Karşılaştırma

5.1.2. Model Kaybı Grafikleri


Şekil 5.2, Model 1 ve Model 2 için model kayıp grafiklerini vermektedir. Her iki grafik de eğitim ve validasyon verisetlerindeki kayıp eğilimini epochlar boyunca göstermektedir. Mavi renkte verilen Model 1 eğitim kaybı, başlangıçta yüksek olup, genel olarak azalan bir eğilim sergileyerek istikrarlı bir şekilde düşmektedir ve birkaç epochdan sonra büyük ölçüde stabilize olmaktadır. Turuncu renkte verilen validasyon kaybı ise çok yüksek başlayıp epochlar boyunca önemli ölçüde dalgalanmakta, net bir düşüş eğilimi göstermemekte ve oldukça değişken kalmaktadır. Model 2 eğitim kaybı, göreceli olarak yüksek başlayıp epochlar boyunca net bir şekilde azalarak istikrarlı bir düşüş eğilimi göstermektedir, Model 1'e kıyasla dalgalanma minimum düzeydedir. Model 2 validasyon kaybı göreceli olarak düşük başlayıp sürekli azalan bir eğilim göstermekte, bazı dalgalanmalar görülmekle birlikte genel olarak eğitim kaybına paralel bir seyir izlemekte ve daha istikrarlı bir performans sergilemektedir. Genel olarak, Model 2 daha iyi performans göstermekte, epochlar boyunca eğitim ve validasyon veri setlerinde daha istikrarlı ve tutarlı kayıp azalması sergilemektedir; Model 1 ise validasyon kaybında istikrarsızlık yaşamakta ve bu nedenle daha az genellemeyebilme kapasitesine sahiptir.



Şekil 5.2 Problem 1 Model Kaybı Karşılaştırma

5.1.3. ROC Eğrisi

Şekil 5.3'da, iki modelin çok sınıflı sınıflandırma performansı için ROC (Receiver Operating Characteristic) eğrilerini göstermektedir. Model 1 için ROC eğrilerinin analizinde, dikey eksen Doğru Pozitif Oranını, yatay eksen Yanlış Pozitif Oranı temsil ederken, kesikli çizgi ayırım çizgisini temsil etmektedir. Model 1'de sınıf 0'ın ROC eğrisi (mavi) 1.00'luk bir Eğri Altındaki Alan (AUC) değerine sahip olup, sınıf 1'in ROC eğrisi (kırmızı) 0.99 AUC, sınıf 2'nin ROC eğrisi (yeşil) 1.00 AUC ve sınıf 3'ün ROC eğrisi (turuncu) 0.99 AUC değerine sahiptir. Model 2'de ise tüm sınıflar için ROC eğrileri 1.00'luk AUC değerleriyle mükemmel performans sergilemektedir. Bu noktada Model 2, sınıfların tümünde AUC değerlerinin mükemmel olması nedeniyle Model 1'e göre biraz daha üstün performans göstermektedir. İki model de ROC eğrileriyle yüksek performans sergilerken, Model 2'nin mükemmel AUC değerleri onun sınıflar arasında yanlış sınıflandırmalardan tamamen kaçınarak daha başarılı bir ayırım yapabildiğini göstermektedir. Sonuç olarak, her iki model de çok sınıflı sınıflandırma görevinde son derece iyi performans göstermektedir, ancak Model 2 tüm sınıflar için mükemmel AUC skorlarıyla biraz daha üstün bir sonuç elde etmektedir.



Şekil 5.3 Problem 1 ROC Eğrisi Karşılaştırma

5.1.4. Sınıflandırma Raporu

Bu raporlar, modelin eğitim sürecinde hiç görmediği, önceden ayrılmış katılımcılara ait test verileri ile yapılmıştır. İlk Model, ikinci modele kıyasla sınıflar arasında daha düşük precision, recall ve F1 skorları gösterirken, ortalama değerler %96 civarındadır. İkinci model, genel olarak tüm sınıflarda biraz daha düşük precision, recall ve F1-skorları gösterir. Ortalama değerler %95 civarındadır.

Tablo 5.1 Problem 1 Model 1 Sınıflandırma Raporu

	Precision	Recall	F1-Score	Support
0	0.96	0.99	0.98	189
1	0.97	0.93	0.95	186
2	0.94	0.97	0.95	180
3	0.98	0.96	0.97	198
Accuracy			0.96	753
Macro Avg	0.96	0.96	0.96	753
Weighted Avg	0.96	0.96	0.96	753

Tablo 5.2 Problem 1 Model 2 Sınıflandırma Raporu

	Precision	Recall	F1-Score	Support
0	0.97	0.99	0.98	269
1	0.94	0.92	0.93	238
2	0.96	0.98	0.97	283
3	0.93	0.92	0.93	260
Accuracy			0.95	1050
Macro Avg	0.95	0.95	0.95	1050
Weighted Avg	0.95	0.95	0.95	1050


5.2. Problem 2: Tipik ve Atipik Katılımcıları Tahmin Etme

Bu karşılaştırmada, 1. Model ile 2. Model, ikili sınıflandırma (binary classification) görevi için uygun şekilde kurgulanmış; son yoğunluk katmanında aktivasyon fonksiyonu olarak sigmoid kullanılmış ve sonuç olarak katılımcıların Tipik mi Atipik mi olduğu sorusuna cevap verecek bir model geliştirilmiştir.

5.2.1. Model Doğruluğu Karşılaştırma

Şekil 5.4'de Model 1 ve Model 2'nin doğruluk değerleri karşılaştırılırken, eğitim ve doğrulama doğruluklarının analiz edilmesi gerekmektedir. Model 1'in eğitim doğruluğu, kademeli bir artış göstererek %85 seviyesine ulaşırken, doğrulama doğruluğu genel olarak %70 civarında seyretmektedir ancak belirgin dalgalanmalar göstermektedir. Model 2'de ise eğitim doğruluğu, yine kademeli bir artış göstererek %98 değerine ulaşırken, doğrulama doğruluğu belirgin dalgalanmalar göstermekte ve net bir artış eğilimi olmaksızın %90 civarında seyretmektedir. Her iki model de yüksek ve kararlı eğitim doğruluğu sergilemekte, bu da her ikisinin de eğitim verisine iyi uyum sağladığını göstermektedir. Ancak validasyon doğruluğunda, Model 2, daha net bir artış trendi ve stabilizasyona sahipken, Model 1'nin doğrulama doğruluğu önemli ölçüde dalgalanmakta ve tutarlı bir artış trendi göstermemektedir. Model 2, doğrulama doğruluğunun daha stabil olması ve yüksek doğruluk değerlerine daha yakın seyretmesi ile daha iyi bir genelleme potansiyeli sunarken, Model 1'nin doğrulama doğruluğundaki yüksek değişkenlik, daha düşük güvenilirlik ve muhtemelen aşırı öğrenme (overfitting) anlamına gelebilir. Sonuç olarak, Model 2, hem eğitim hem de

doğrulama doğruluğu itibarıyla daha iyi bir performans sergileyerek, görülmeyen verilere daha iyi genelleme yapabilme olasılığı yüksek olan bir model olarak değerlendirilebilir.




Şekil 5.4 Problem 2 Model Doğruluğu Karşılaştırma

5.2.2. Model Kaybı Karşılaştırma

Şekil 5.5’de eğitim kaybı ve validasyon kaybının epoch sayısına karşı değişimleri gösterilmiştir. Model 1’de mavi renk ile belirtilen eğitim kaybı çizgisi yaklaşık 0.9 seviyesinde başlayıp bir hafif düşüş ve dalgalanma göstererek yine 0.6 civarında sonlanmaktadır. Eğitim kaybı genellikle düşük ve stabildir. Turuncu renk ile belirtilen validasyon kaybı ise oldukça yüksek bir başlangıç olan 1.7 seviyesinden ilk epoch sonrası keskin bir düşüş gösterir. Daha sonra önemli dalgalanmalarla birlikte düşüş eğilimi göstererek 1.0 civarında stabil hale gelecek şekilde yaklaşık 0.6 ile 1.0 arasında dalgalanma göstermektedir. Model 2’de eğitim kaybı 0.4’in altında başlayıp kademeli bir düşüş göstererek neredeyse sıfır değerine oldukça yakın bir seviyede sonlanmaktadır. Validasyon kaybı ise 0.4 seviyesinde başlayıp ilk birkaç epoch içinde 0.25 ve 0.40 arasında dalgalanmalar göstermektedir. Validasyon kaybı stabil olmayıp yüksek değişkenlik göstererek son epochlarda 0.35 seviyesinde bitirmiştir. Sonuç olarak, Model 2, eğitim ile validasyon kaybı arasındaki fark nedeniyle bazı fazla öğrenme belirtileri gösterse de bu fazla öğrenme nispeten kontrol altındadır ve validasyon kaybı belirli bir noktada stabil olma eğilimindedir. Buna karşın, Model 1, validasyon kaybında büyük ve tutarsız dalgalanmalar göstererek ciddi fazla öğrenme


sorunları yaşamakta, yani eğitim verisine çok fazla odaklanırken validasyon verisine yeterli genelleme yapamamaktadır. Sonuç olarak, Model 2, Model 1’ye kıyasla daha kontrollü bir eğitim süreci göstermektedir.



Şekil 5.5 Problem 2 Model Kaybı Karşılaştırma

5.2.3. ROC Eğrisi

Şekil 5.6, Model 1 ve Model 2’nin, eğri altındaki alan (AUC) ile Alıcı İşletim Karakteristiği (ROC) eğrilerini karşılaştırmaktadır. Soldaki grafikte turuncu çizgi ile gösterilen Model 1’in ROC eğrisi, pozitif ve negatif sınıflar arasında yüksek bir ayırt etme yeteneğini gösteren 0.90 AUC'ye sahiptir. Buna karşılık, sağdaki grafikte gösterilen ve 0.98 AUC'ye sahip olan Model 2’nin ROC eğrisi, iki sınıfı ayırt etme yeteneğinin daha da yüksek olduğunu göstermektedir. Model 2’nin ROC eğrisinin sol üst köşeye daha yakın olması, daha az yanlış pozitif ve daha yüksek doğru pozitif oranlarına sahip olduğunu gösterir. Dolayısıyla, AUC değerleri ve ROC eğrilerinin görsel grafiklerine dayanarak, Model 2’nin sınıflandırma etkinliği açısından Model 1’den daha üstün olduğu sonucuna varabiliriz.



Şekil 5.6 Problem 2 ROC Eğrisi Karşılaştırma

5.2.4. Sınıflandırma Raporu

Bu raporlar, modellerin eğitim sürecinde hiç görmediği, farklı katılımcıya ait önceden ayrılmış test verileri ile yapılmıştır. İlk Model 0,82'luk bir doğruluk ve 0,82'luk bir F1 puanı gösterirken, ikinci model ise 0,93'lik bir doğruluk ve 0,93'lik bir F1 puanı göstermektedir. Bu sonuçlar göz önüne alındığında, ikinci modelin çeşitli ölçütlerde daha iyi performans gösterdiği görülmektedir. Bu modeli gerçek dünya uygulamalarında kullanmadan önce bu metriklere tam olarak güvenmek için başka testler yapmak oldukça önemlidir.

Tablo 5.3 Problem 2 Model 1 Sınıflandırma Raporu

	Precision	Recall	F1-Score	Support
0	0.82	0.80	0.81	514
1	0.81	0.83	0.82	531
Accuracy			0.82	1045
Macro Avg	0.82	0.82	0.82	1045
Weighted Avg	0.82	0.82	0.82	1045

Tablo 5.4 Problem 2 Model 2 Sınıflandırma Raporu

	Precision	Recall	F1-Score	Support
0	0.91	0.94	0.93	514
1	0.94	0.91	0.93	531
Accuracy			0.93	1045
Macro Avg	0.93	0.93	0.93	1045
Weighted Avg	0.93	0.93	0.93	1045


5.3. Problem 3: Puanlamaları Tahmin Etme

Bu çalışmada model, yapılan hareketin puanlamasının tahmini için eğitilmiştir. Daha önce belirtildiği gibi girdi olarak video ve hangi hareketin yapıldığı bilgisi verilirken çıktı olarak 0: Kötü, 1: Orta, 2: İyi olacak şekilde verilen puanların ortalaması tahmin edilmiştir. Diğer çalışmalarda olduğu gibi bu çalışma sırasında da biri CNN LSTM yapılandırması olan, diğeri ise önceden eğitilmiş (Pretrained) model temeline oturan iki model kullanılmıştır.

5.3.1. Model Doğruluğu Grafikleri

Şekil 5.7, her iki modelin doğruluk grafiklerini vermektedir. Model 1'in eğitim doğruluğu, 3. epocha kadar yaklaşık 0.55'ten 0.73'e yükselmekte ve 10. epoch civarında yaklaşık 0.80'de dengelenmektedir. Validasyon doğruluğu ise 0.30 civarında başlayıp başlarda dalgalanmalar göstermekte, 3. epochda eğitim doğruluğunu aşarak yaklaşık 0.78'e ulaşmakta ve küçük dalgalanmalarla bu performansını sürdürmektedir. Model 2'nin eğitim doğruluğu ise 0.68'de başlayıp 20. epochda 0.90'ı aşacak şekilde sürekli artmakta, validasyon doğruluğu ise 0.70 civarında başlayıp erken epochlarda küçük artışlar göstermekte ve genellikle 0.70-0.75 arasında dalgalanarak genel bir durgunluk ve kararsızlık sergilemekte, bu da muhtemel aşırı öğrenmeyi işaret etmektedir. Karşılaştırmada, her iki model de eğitim doğruluğunda aşamalı artış göstermekte olup, Model 2 daha yüksek son eğitim doğruluğuna ulaşmaktadır. Ancak, Model 1 daha yüksek ve tutarlı validasyon doğruluğu ile daha iyi genelleme göstermektedir. Her iki modelde de eğitim doğruluğu önemli ölçüde artıp, neredeyse

sabit bir çizgiye yaklaşmaktadır, bu da iyi bir öğrenmeyi gösterir. İlk modelde validasyon doğruluğu epoklar boyunca önemli ölçüde değişiklik gösterip, potansiyel ezberleme (overfit) durumuna işaret eder. İkinci modelde ise, ilk modele kıyasla, validasyon doğruluğunda hafif bir iyileşme ile daha tutarlı bir artış vardır.




Şekil 5.7 Problem 3 Model Doğruluğu Karşılaştırma

5.3.2. Model Kaybı Grafikleri

Şekil 5.8’de Model 1’in eğitim kaybı yaklaşık 0.85’ten başlayarak, validasyon kaybı ise yaklaşık 1.85 seviyesinde başlamakta ve eğitim süresi boyunca kademeli bir azalma göstermektedir. Validasyon kaybı, ilk birkaç dönemde keskin bir düşüş sergileyip, eğitim süresinin sonuna doğru küçük dalgalanmalarla birlikte nispeten sabit kalmaktadır. Nihayetinde, hem eğitim hem de validasyon kayıplarının yaklaşık 0.8 civarında birleşip stabilize olduğu gözlemlenmektedir. Model 2’nin eğitim kaybı yaklaşık olarak 0.7’den başlarken, validasyon kaybı biraz daha yüksek, yaklaşık 0.75’te başlamaktadır. Eğitim kaybı düzenli bir şekilde azalarak sürecin sonunda çok düşük bir değere ulaşmaktadır. Buna karşın, validasyon kaybı başlangıçta düşüş gösterse de, 7-8 epoch sonra keskin bir şekilde artmaya başlayarak aşırı uyum örüntüsü sergilemektedir. Eğitim süresi sonunda, eğitim kaybı 0.1’in altına düşerken, validasyon kaybı önemli ölçüde artarak 0.9 civarına ulaşmaktadır. Karşılaştırma noktalarından biri olan aşırı uyum incelendiğinde, Model 1 önemli bir aşırı uyum belirtisi göstermemekte, eğitim ve validasyon kayıpları benzer değerlere stabilize olmaktadır. Model 2 ise belirgin aşırı uyum belirtileri sergilemektedir; eğitim kaybı sürekli azalırken, validasyon kaybı birkaç epoch sonra artış göstermektedir. Stabilit


açısından, Model 1'in validasyon kaybı ilk düşüşünü takiben daha kararlı bir yapı sergileyerek, modeli iyi bir denge içinde tutmaktadır. Model 2'nin validasyon kaybında görülen istikrarsızlık, modelin görülmemiş verilerde iyi genelleme yapamadığını işaret etmektedir. Sonuç olarak, Model 1 daha iyi bir genelleme ve stabilite sağlarken, Model 2 düşük eğitim kaybına rağmen ciddi aşırı uyum problemleri yaşamaktadır.



Şekil 5.8 Problem 3 Model Kaybı Karşılaştırma

5.3.3. ROC Eğrisi

Bu grafikte, Model 1 ve Model 2 çok sınıflı sınıflandırma performanslarının karşılaştırılması amacıyla ROC (Receiver Operating Characteristic) eğrileri kullanılmıştır. Her bir model için üç sınıfa (sınıf 0, sınıf 1 ve sınıf 2) ait ROC eğrileri ve bu eğriler altında kalan alanlar (AUC) sunulmuştur. Model 1'in Class 0 için AUC değeri 0.94, Class 1 için 0.82 ve Class 2 için 0.93 iken; Model 2'nin aynı sınıflar için AUC değerleri sırasıyla 0.93, 0.81 ve 0.95 olarak belirlenmiştir. İki modelin performans karşılaştırmalarında, Model 1'in Class 0 ve Class 1'de sırasıyla 0.01 oranında daha iyi performans gösterdiği, ancak Model 2'nin Class 2'de 0.02 daha yüksek performans sergilediği görülmektedir. Genel olarak, Model 1'in Class 0 ve Class 1'de daha iyi performans sergilediği, Model 2'nin ise Class 2'de üstün olduğu tespit edilmiştir. Bu sonuçlar, belirli sınıfların performansının kritik olduğu uygulamalarda model seçiminde önemli bir rol oynayabilir. Örneğin, Class 2'nin performansı daha kritikse, Model 2 tercih edilebilir; dengeli performans gerektiğinde ise Model 1 daha uygun bir seçenek olabilir.



Şekil 5.9 Problem 3 ROC Eğrisi Karşılaştırma

5.3.4. Sınıflandırma Raporu

Bu rapor, modelin eğitim sürecinde hiç görmediği, önceden ayrılmış test verileri ile yapılmıştır. İlk Model precision, recall ve F1-score değerleri önceden eğitilmiş ikinci modele kıyasla ortalama olarak nispeten daha düşüktür. Makro ve ağırlıklı ortalamalar doğruluk, hassasiyet, geri çağırma ve F1-skorunda daha düşük puanlar göstermektedir. İkinci model genel olarak daha iyi bir performans göstermektedir.

Tablo 5.5 Problem 3 Model 1 Sınıflandırma Raporu

	Precision	Recall	F1-Score	Support
0	0.80	0.63	0.70	369
1	0.62	0.61	0.61	452
2	0.82	0.94	0.87	602
Accuracy			0.75	1423
Macro Avg	0.75	0.72	0.73	1423
Weighted Avg	0.75	0.75	0.75	1423

Tablo 5.6 Problem 3 Model 2 Sınıflandırma Raporu

	Precision	Recall	F1-Score	Support
0	0.81	0.73	0.70	267
1	0.66	0.60	0.63	343
2	0.80	0.91	0.85	440
Accuracy			0.76	1050
Macro Avg	0.76	0.74	0.75	1050
Weighted Avg	0.76	0.76	0.76	1050



6. TARTIŞMA

Bu çalışma kapsamında değerlendirilen üç problemin analizinde, her modelin başarı ve başarısızlık nedenlerini detaylı olarak ele alınmıştır. İki model arasındaki performans farklarının anlaşılması, gelecekteki model geliştirme çalışmalarında rehberlik etmesi açısından önemlidir.

6.1. Bulgulara Dair Yorumlar

Tez kapsamında hazırlanan yapay zeka modelleri arasında yapılan karşılaştırmalar sonucunda, modeller arasından hangisinin daha iyi performans gösterdiği, her bir problem karşısında hangisinin daha yüksek stabilite ve daha iyi genelleme kapasitesi sunduğu, eğitim verisi üzerinde hangisinin daha başarılı olduğu bilgileri aşağıda verilmiştir.

6.1.1. Problem 1: Hareketi Tahmin Etme

Bu problemde, Model Doğruluğu Grafikleri ve Model Kaybı Grafikleri incelendiğinde, Model 2'nin hem eğitim hem de validasyon doğruluğunda daha az dalgalanma ve daha yüksek doğruluk değerleriyle daha stabil performans gösterdiği görülmektedir. Model 2, eğitim ve validasyon kaybında tutarlı bir düşüş sergileyerek daha iyi bir genelleme yeteneğine sahip olduğunu doğrulamaktadır. ROC eğrisi ve sınıflandırma raporlarında da Model 2, genel olarak daha yüksek AUC ve sınıf performansları sergilerken, Model 1 validasyon doğruluğundaki dalgalanmalardan dolayı daha değişken performans göstermektedir. Ancak Model 1 sınıflandırma raporunda hiç görmediği test verileri üzerinde daha yüksek doğruluk göstermiştir, bu da Model 1'in hareket tahmini görevinde daha başarılı olduğunu göstermektedir.

6.1.2. Problem 2: Tipik ve Atipik Katılımcıları Tahmin Etme

Model Doğruluğu Karşılaştırma ve Model Kaybı Karşılaştırma bölümlerinde elde edilen bulgular, Model 2'in eğitim verisi üzerinde daha iyi bir doğruluk artışı sergilediğini ve validasyon doğruluğunun daha stabil olduğunu ortaya koymaktadır. Aynı şekilde, Model 2'in eğitim ve validasyon kaybı, genel olarak daha az dalgalanma

göstermekte ve daha tutarlı bir öğrenme eğrisi sunmaktadır. Bu, Model 2'in daha iyi bir genelleme potansiyeli sunduğunu ve aşırı öğrenmeden muzdarip olmadığını göstermektedir. Öte yandan, Model 1, özellikle validasyon kaybında büyük dalgalanmalar göstererek ciddi aşırı uyum problemleri yaşamaktadır. Model 1'nin bu başarısızlığı, eğitim verisine aşırı uyum sağlarken, görülmeyen verilere genellemediğini işaret etmektedir. AUC sonuçlarında da Model 2'in daha stabil olması, bu modelin yanlış sınıflandırmalardan daha az etkilenmekte olduğunu göstermektedir.

6.1.3. Problem 3: Puanlamaları Tahmin Etme

Model Doğruluğu Grafikleri ve Model Kaybı Grafikleri incelendiğinde, Model 1'in eğitim ve validasyon doğruluklarında daha tutarlı bir artış gösterdiği ve özellikle validasyon doğruluğunda daha dengeli bir performansa sahip olduğu anlaşılmaktadır. Model 2 ise yüksek eğitim doğruluğu gösterse de, validasyon kaybında ciddi dalgalanmalar yaşayarak aşırı uyum belirtileri göstermektedir. ROC eğrisi ve sınıflandırma raporlarında Model 1'in bazı sınıflarda daha yüksek AUC değerleri ve daha iyi sınıflandırma metrikleri sunduğu görülmektedir. Model 2'nin üstün olduğu yerlerde bile, genel tutarsızlık ve aşırı uyum problemleri bu modelin gerçek dünyada uygulanabilirliğini sınırlamaktadır.

Tüm bu karşılaştırmalar sonucunda, Model 1'in genellikle daha yüksek stabilite ve daha iyi genelleme kapasitesi sunduğu, Model 2'nin ise eğitim verisi üzerinde daha başarılı olmakla birlikte validasyon verisi üzerinde aşırı uyum yaşadığı açıkça görülmektedir. Bu sonuçlar, modellerin mimarilerinden kaynaklanan farklılıklardan ve öğrenme dinamiklerinden kaynaklanmaktadır. Gelecekteki model geliştirme çalışmalarında, daha stabil ve genellemeye açık modeller oluşturmak adına, Model 1'deki gibi kontrollü öğrenme süreçlerine odaklanmak gerekmektedir. Böylelikle, daha etkili ve güvenilir tahminler yapabilen modeller geliştirilmesi mümkün olacaktır.

6.2. Geçerliliğe Yönelik Tehditler

Bu çalışmada toplanan verilerin ve geliştirilen yapay zeka modellerinin geçerliliği, çeşitli tehditler altında incelenmelidir. Herhangi bir araştırma çalışmasında

olduğu gibi, AIMove projesinde de veri seti, model eğitimi ve genelleme aşamalarında karşılaşılabilecek geçerlilik tehditleri aşağıda detaylandırılmaktadır.

6.2.1. Veri Setinin Küçük ve Sınırlı Olması

Projede kullanılan veri seti, her bir hareket için 50 tipik ve 50 atipik çocuk tarafından 100'er tekrar ile toplamda 40.000 kayıt içermektedir. Ancak bu veri seti, geniş bir genelleme yapmak için yetersiz kalabilir. Katılımcı sayısının sınırlı oluşu ve tekrar sayısının belirli bir sayıyla sınırlı kalması, modelin yeni ve farklı veriler üzerinde yeterince başarılı olamamasına neden olabilir. Daha geniş ve çeşitli bir veri seti, modelin farklı çevresel koşullara, farklı yaş gruplarına ve daha fazla demografik değişkene daha iyi uyum sağlamasını mümkün kılacaktır.

6.2.2. Veri Setinin Dengesiz Olması

Toplanan verilerin tipik ve atipik çocuklardan eşit sayıda olması, balans açısından önemli bir avantaj sağlasa da, her iki grubun içindeki çeşitlilik ve farklılıklar yeterince temsil edilmeyebilir. Özellikle atipik çocukların çeşitli motor beceri seviyelerini temsil eden yeterince geniş bir örneklem olmayabilir. Bu durum, modele gerçek dünyada karşılaşılabileceği farklı varyasyonları görme şansı tanımayarak, genelleme kapasitesini düşürür. Veri setinin daha fazla çeşitlilik içerecek şekilde genişletilmesi, bu tehdidin azaltılmasına yardımcı olacaktır.

6.2.3. Veri Setinin Temsil Etmemesi

Araştırmada kullanılan veri seti, sadece belirli motor becerileri (yürüme, yatay atlama, topu yakalama, ayakla topa vurma) içermektedir. Ancak, gerçek dünyada bu temel motor becerilerin dışında pek çok farklı hareket ve beceri bulunmaktadır. Bu yüzden, modelin yalnızca bu dört hareketle sınırlı kalması, geniş bir yelpazede genel geçerliliğini sorgulatmaktadır. Geliştirilen sistemin diğer motor beceriler üzerinde nasıl performans göstereceği bilinmemektedir. Dolayısıyla, veri setini daha çeşitli ve kapsamlı hale getirmek, modelin genel geçerliliğini artırmak için önemlidir.

6.2.4. Aşırı Öğrenme (Overfitting)

Model eğitiminde gözlemlenen aşırı öğrenme belirtileri, özellikle Model 2'de ciddi anlamda sorun teşkil etmektedir. Modelin eğitim verisine aşırı uyum göstermesi,

onun yeni ve görülmemiş verilerde performansının düşmesine neden olabilir. Bu durum, modelin yanlış genellemeler yapmasına yol açar ve verimliliğini azaltır. Aşırı uyarlanmayı önlemek için model karmaşıklığını ve hiperparametre ayarlarını dikkatle düzenlemek, düzenli yapılanma tekniklerini kullanmak gerekmektedir. Bu şekilde, modelin daha dengeli ve genel geçer performans göstermesi sağlanabilir.

6.2.5. Veri Toplama Araçlarının Kısıtları

Araştırmada kullanılan Kinect tabanlı ölçüm sistemi, çeşitli teknik sınırlamalara sahip olabilir. Sensörlerin doğruluğu, hareketlerin yakalanmasındaki olası hatalar ve çevresel faktörlerin etkisi, toplanan verilerin kalitesini etkileyebilir. Ayrıca, sensörlerin belirli çevresel koşullarda (ışık, mesafe, engeller vs.) performans düşüklüğü yaşaması, verilerin güvenilirliğini ve dolayısıyla modelin doğruluğunu olumsuz etkileyebilir.

6.2.6. Katılımcı Davranışlarındaki Farklılıklar

Katılımcı çocukların hareketleri bilinçli olarak zorlama veya yanlış yapma durumları, özellikle atipik çocuklarda daha yaygın görülmektedir. Bu tür bilinçli veya bilinçsiz yanlış hareketler, veri setinin kalitesini düşürebilir ve modelin performansını etkileyebilir. Katılımcıların doğal hareketlerini kaydetmek için daha kontrollü ve izlenebilir ortamlar oluşturulması önemlidir.

AIMove projesinde geliştirilen yapay zeka temelli ölçüm aracı, belirli sınırlamalar ve geçerlilik tehditleri altında performans göstermektedir. Bu tehditlerin kontrol altına alınması ve minimize edilmesi, projede elde edilen sonuçların doğruluğu ve güvenilirliği açısından kritik öneme sahiptir. Gelecekte yapılacak çalışmalarda, bu tehditlerin göz önünde bulundurularak daha kapsamlı ve dengeli veri toplama süreçlerinin ve model doğrulama yöntemlerinin uygulanması önerilmektedir.

7. SONUÇ

Bu çalışma, TÜBİTAK'ın 1001 Spor Araştırmaları çağrısı kapsamında başlatılan 121E688 numaralı “Temel Hareket Becerileri Analizinde Kullanılacak Yapay Zeka Temelli Ölçüm Aracının Geliştirilmesi: AIMove” projesi çerçevesinde, çocukların temel hareket becerilerinin yapay zeka temelli bir ölçüm aracı kullanılarak analiz edilmesini amaçlamaktadır. Proje, hem tipik hem de atipik çocukların motor becerilerinin doğru ve güvenilir bir şekilde değerlendirilmesini sağlayacak bir sistem geliştirmeyi hedeflemektedir. İki yıl süren bu proje, İstanbul Kültür Üniversitesi ve Sakarya Uygulamalı Bilimler Üniversitesi tarafından ortak olarak yürütülmüştür. Proje yürütücülüğü ve veri toplama süreçleri Sakarya Uygulamalı Bilimler Üniversitesi tarafından üstlenilirken, yazılım geliştirme süreçleri ve yapay zeka modeline dönüştürülen verinin toplanması aşamaları İstanbul Kültür Üniversitesi tarafından gerçekleştirilmiştir.

Çalışma, öncelikle Microsoft tarafından geliştirilen Kinect sensörü kullanarak veri toplamak için gerekli olan yazılımın geliştirilmesi ile başlamıştır. Kinect teknolojisi, Microsoft Xbox için oyun amaçlı geliştirilmiş olmasına rağmen, basit hareket algılamadaki üstün performansı ve uygulama geliştiriciler için sağladığı yazılım geliştirme materyalleri sayesinde hareket analizinde kullanıma uygun bir altyapı sunmaktadır. Sensör, çeşitli kameralar kullanarak aynı anda altı kişinin hareketlerini algılayıp 25 farklı noktanın koordinatlarını iletmektedir. Bu koordinatlar kullanılarak yapay bir iskelet oluşturulmuş ve katılımcının hareketleri anlık olarak görselleştirilmiştir. Siyah zemin üzerinde yalnızca katılımcının iskelet videosunun yer alması, yapay zeka modelinin sadece hareketlere odaklanmasını sağlamıştır. Veri toplama sürecinde, katılımcının yaptığı hareketler biri yandan, diğeri karşıdan olmak üzere iki farklı açıdan kaydedilmiştir. Kinect sensörün kısıtlamaları nedeniyle, bir bilgisayara aynı anda sadece bir sensör bağlanabildiği için, geliştirilen uygulama iki farklı bilgisayara bağlı iki sensörün eşzamanlı kayıt yapmasını sağlayacak şekilde yapılandırılmıştır. Veriler Sakarya Uygulamalı Bilimler Üniversitesi tarafından toplanmış ve kaydedilen hareketlerin tamamı doğru bir şekilde puanlanarak arşivlenmiştir. Özellikle atipik katılımcılarla veri toplama sürecinde yaşanan zorluklara rağmen, tipik ve atipik katılımcılardan ve yaptıkları her bir hareketten eşit

sayıda video kullanılarak dengeli bir veri seti oluşturulmuştur. Toplamda yaklaşık 8000 video ile bir veri seti hazırlanmıştır.

Veri seti oluşturma çalışmalarının ardından, iki farklı yapay zeka modeli geliştirilmiş ve bu modeller, en iyi sonucu verebileceği düşünülen CNN ve LSTM katmanları kullanılarak yapılandırılmıştır. Modeller, katılımcının tipik mi atipik mi olduğunun tespiti, yaptığı hareketin tespiti ve harekete verilen puanların tahmini gibi üç farklı problem üzerinde teste tabi tutulmuştur. Elde edilen bulgular, her iki modelin de belirli açılardan başarılı performans gösterdiğini ortaya koymuştur. Ancak, Model 2'nin eğitim verisine aşırı uyum gösterip validasyon verisinde düşük performans sergilediği, bu modelin aşırı öğrenme sorunları yaşadığını göstermiştir. Buna karşılık, Model 1, daha stabil ve genelleme kapasitesi yüksek performansı ile öne çıkmıştır. Veri setinin sınırlılıkları, dengesizlikleri ve temsil yeteneği ile ilgili çeşitli geçerlilik tehditlerinin modellerin genel performansını etkilediği gözlemlenmiştir. Özellikle, veri setinin genişletilmesi ve çeşitlendirilmesi, modellerin genelleme kapasitesini artırmak ve daha güvenilir sonuçlara ulaşmak için kritik öneme sahiptir. Ayrıca, veri toplama araçlarının ve yöntemlerinin iyileştirilmesi, modelin doğruluğunu ve güvenilirliğini artıracaktır.

Sonuç olarak, AIMove projesi kapsamında geliştirilen yapay zeka temelli ölçüm aracı, çocukların temel hareket becerilerinin ölçülmesinde önemli bir adım olarak değerlendirilebilir. Ancak, daha iyi genelleme yapabilen ve aşırı öğrenme problemlerini minimize eden modeller geliştirmek için verilerin çeşitlendirilmesi ve veri toplama süreçlerinin iyileştirilmesi gerekmektedir. Bu çalışma, gelecekteki araştırmalara ve uygulamalara önemli bir temel oluşturmakta ve çocukların motor becerilerinin daha etkin bir şekilde analiz edilmesi yönünde değerli katkılar sunmaktadır.

KAYNAKÇA

- [1] K. and N. R. O'Shea, "An Introduction to Convolutional Neural Networks", *Int J Res Appl Sci Eng Technol*, c. 10, sy 12, 2015.
- [2] C. Szegedy vd., "Going deeper with convolutions", içinde *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, IEEE Computer Society, Eki. 2015, ss. 1-9. doi: 10.1109/CVPR.2015.7298594.
- [3] Z. Li, F. Liu, W. Yang, S. Peng, ve J. Zhou, "A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects", *IEEE Trans Neural Netw Learn Syst*, c. 33, sy 12, 2022, doi: 10.1109/TNNLS.2021.3084827.
- [4] F. Shaheen, B. Verma, ve M. Asafuddoula, "Impact of Automatic Feature Extraction in Deep Learning Architecture", içinde *2016 International Conference on Digital Image Computing: Techniques and Applications, DICTA 2016*, 2016. doi: 10.1109/DICTA.2016.7797053.
- [5] P. Khaire, P. Kumar, ve J. Imran, "Combining CNN streams of RGB-D and skeletal data for human activity recognition", *Pattern Recognit Lett*, c. 115, 2018, doi: 10.1016/j.patrec.2018.04.035.
- [6] J. Guo, Q. Zhang, H. Chai, ve Y. Li, "Obtaining lower-body Euler angle time series in an accurate way using depth camera relying on Optimized Kinect CNN", *Measurement (Lond)*, c. 188, 2022, doi: 10.1016/j.measurement.2021.110461.
- [7] S. Hochreiter ve J. Schmidhuber, "Long Short-Term Memory", *Neural Comput*, c. 9, sy 8, ss. 1735-1780, Kas. 1997, doi: 10.1162/neco.1997.9.8.1735.

- [8] J. Donahue vd., “Long-Term Recurrent Convolutional Networks for Visual Recognition and Description”, *IEEE Trans Pattern Anal Mach Intell*, c. 39, sy 4, 2017, doi: 10.1109/TPAMI.2016.2599174.
- [9] R. C. Staudemeyer ve E. R. Morris, “Understanding LSTM -- a tutorial into Long Short-Term Memory Recurrent Neural Networks”, Eyl. 2019.
- [10] Y. Yu, X. Si, C. Hu, ve J. Zhang, “A review of recurrent neural networks: Lstm cells and network architectures”, 2019. doi: 10.1162/neco_a_01199.
- [11] B. Mahasseni, M. Lam, ve S. Todorovic, “Unsupervised video summarization with adversarial LSTM networks”, içinde *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, 2017. doi: 10.1109/CVPR.2017.318.
- [12] M. van Diest, J. Stegenga, H. J. Wörtche, K. Postema, G. J. Verkerke, ve C. J. C. Lamoth, “Suitability of Kinect for measuring whole body movement patterns during exergaming”, *J Biomech*, c. 47, sy 12, 2014, doi: 10.1016/j.jbiomech.2014.07.017.
- [13] H. Y. Ting, K. S. Sim, ve F. S. Abas, “Kinect-based badminton movement recognition and analysis system”, *Int J Comput Sci Sport*, c. 14, sy 2, 2015.
- [14] R. Tsachor, “Laban Movement Analysis Using Kinect”, *International Journal of Computer, Electrical, Automation, Control and Information Engineering*, c. 9, sy 6, 2015.
- [15] C. Zerpa, C. Lees, P. Patel, ve E. Pryzsucha, “The Use of Microsoft Kinect for Human Movement Analysis”, *International Journal of Sports Science*, c. 5, sy 4, 2015.
- [16] J. K. Nichols, M. P. Sena, J. L. Hu, O. M. O'Reilly, B. T. Feeley, ve J. C. Lotz, “A Kinect-based movement assessment system: marker position comparison to Vicon”, *Comput Methods Biomech Biomed Engin*, c. 20, sy 12, 2017, doi: 10.1080/10255842.2017.1340464.
- [17] M. Jazouli, A. Majda, D. Merad, R. Aalouane, ve A. Zarghili, “Automatic detection of stereotyped movements in autistic children using the Kinect sensor”, *Int J Biomed Eng Technol*, c. 29, sy 3, 2019, doi: 10.1504/IJBET.2019.097621.

- [18] P. Li, "Research on robot boxing movement simulation based on kinect sensor", *EURASIP J Wirel Commun Netw*, c. 2020, sy 1, 2020, doi: 10.1186/s13638-020-01761-x.
- [19] P. F. Dajime, H. Smith, ve Y. Zhang, "Automated classification of movement quality using the Microsoft Kinect V2 sensor", *Comput Biol Med*, c. 125, 2020, doi: 10.1016/j.compbimed.2020.104021.
- [20] T. Tran, T. Ruppert, G. Eigner, ve J. Abonyi, "Assessing human worker performance by pattern mining of Kinect sensor skeleton data", *J Manuf Syst*, c. 70, ss. 538-556, Eki. 2023, doi: 10.1016/j.jmsy.2023.08.010.
- [21] T. Y. Shih vd., "Comparative effects of kinect-based versus therapist-based constraint-induced movement therapy on motor control and daily motor function in children with unilateral cerebral palsy: a randomized control trial", *J Neuroeng Rehabil*, c. 20, sy 1, 2023, doi: 10.1186/s12984-023-01135-6.
- [22] B. Açış ve S. Güney, "Classification of human movements by using Kinect sensor", *Biomed Signal Process Control*, c. 81, 2023, doi: 10.1016/j.bspc.2022.104417.
- [23] H. A. Salim, M. Alaziz, ve T. Y. Abdalla, "Human Activity Recognition Using The Human Skeleton Provided by Kinect", *Iraqi Journal for Electrical and Electronic Engineering*, c. 17, sy 2, 2021, doi: 10.37917/ijeee.17.2.20.
- [24] J. Han, L. Shao, D. Xu, ve J. Shotton, "Enhanced computer vision with Microsoft Kinect sensor: A review", *IEEE Trans Cybern*, c. 43, sy 5, 2013, doi: 10.1109/TCYB.2013.2265378.
- [25] S. Asteriadis, A. Chatzitofis, D. Zarpalas, D. S. Alexiadis, ve P. Daras, "Estimating human motion from multiple Kinect sensors", içinde *ACM International Conference Proceeding Series*, 2013. doi: 10.1145/2466715.2466727.

EKLER

EK-1. Etik Kurul Kararı

Evrak Tarih ve Sayısı: 29.04.2022-E.45851



T.C.
SAKARYA UYGULAMALI BİLİMLER ÜNİVERSİTESİ REKTÖRLÜĞÜ
Etik Kurulu

Sayı : E-26428519-044-45851
Konu : Etik Kurul Kararı 22/9 "Doç. Dr. Nurgül
TEZCAN KARDAŞ"

29.04.2022

Sayın Doç. Dr. Nurgül TEZCAN KARDAŞ

Etik Kurulunun **29/04/2022** tarih ve **22 no**'lu toplantısında alınıp olduğu dokuzuncu maddesine (**madde 9**) ilişkin karar örneği aşağıda sunulmuştur.

Madde 9 –Doç. Dr. Nurgül TEZCAN KARDAŞ' in 28/04/2022 tarihli ve 46041 sayılı dilekçesi ve ekleri görüşmeye açıldı.

Yapılan görüşmeler sonunda Spor Bilimleri Fakültesi Öğretim Üyesi **Doç. Dr. Nurgül TEZCAN KARDAŞ'** in hazırladığı "**Temel Hareket Becerileri Analizinde Kullanılacak Yapay Zeka Temelli Ölçüm Aracının Geliştirilmesi: AIMove**" başlıklı TÜBİTAK 1001 projesi çalışmasının Etik açıdan uygun olduğuna oy birliğiyle karar verilmiştir.

Prof. Dr. Yusuf ÇAY
Etik Kurulu Başkanı

Ek: Başvuru dilekçesi ve ekleri (42 sayfa)

EK-2. Proje Kabul Yazısı

Sayın ,

Kurumumuza önerilen '121E688' numaralı ve 'Temel Hareket Becerileri Analizinde Kullanılacak Yapay Zekâ Temelli Ölçüm Aracının Geliştirilmesi: Aimize' başlıklı projenizin, Araştırma Destek Grubu ve panel değerlendirmeleri çerçevesinde desteği uygun görülen kalemler üzerinden nihai bütçesi belirlenmiştir. Sonuç olarak projenizin 24 ay süre ve toplam 326918TL ödenekle desteklenmesine karar verilmiş olup, taraflarca imzalanmış proje sözleşmesi ve ekleri ARDEB Proje Takip Sistemi'ne (<https://ardeb-pts.tubitak.gov.tr/>) pdf formatında yüklenmiştir.

Projenizin harcamaları proje sözleşmesinde imzası bulunan Kuruluşunuz tarafından gerçekleştirilecek ve takip edilecektir. Proje sözleşmesi dosyasında eklenen 'Dönem Bazında Onaylanan Bütçe Transfer Tablosu'nda dönemler itibariyle belirlenen proje ödenekleriniz, gelişme raporlarının kabul edilmesini takiben, Kuruluşunuzun proje adına açtığı özel banka hesabına transfer edilecektir.

Proje özel hesabına transfer edilecek ödeneklerin harcamaları; Projenin yürütüldüğü kuruluş, kamu kuruluşu ise, Maliye Bakanlığı ve TÜBİTAK tarafından hazırlanan 'TÜBİTAK Kaynaklarından Genel Bütçe Kapsamındaki Kamu İdareleri ile Özel Bütçeli İdarelere Proje Karşılığı Aktarılacak Tutarların Harcanması ve TÜBİTAK Tarafından Yürütülen Dış Destekli Projelerin Harcamalarının Gerçekleştirilmesine İlişkin Esas ve Usuller' çerçevesinde, projenin yürütüldüğü kuruluş, vakıf üniversitesi veya özel kuruluş ise, 'TÜBİTAK Tarafından Özel Kuruluşlar ve Vakıf Üniversitelerine Proje Karşılığı Aktarılacak Tutarların Transferi, Harcanması, Muhasebeleştirilmesi ve Denetimine İlişkin Esaslar' ve genel olarak da 'Araştırma Projelerinde Uygulanacak İdari ve Mali Esaslar' çerçevesinde gerçekleştirilecektir.

Yukarıda belirtilen esaslar, projenizin yürütülmesi sırasında dikkat edilecek hususlar ve kullanılacak olan diğer doküman ve formlar <http://www.tubitak.gov.tr/tr/destekler/akademik/uygulamalar-ve-yonergeler/tts/icerik-yardimci-belgeler> adresinden temin edebilirsiniz. Projenizin yürütülmesi sırasında sözleşme, yönetmelik, esasların dikkate alınması ve ilgili

formların kullanılması ortak alıřmamızı nemli lde kolaylařtıracaktır. 'Dnem Bazında Bte Transfer Tablosu'nda belirtilen projenin ilk dnem btesi, projeniz adına aılarak Kuruluřunuz tarafından, TBİTAK'a bildirilen zel banka hesabına en kısa srede aktarılacak ve iřlemler tamamlandıėında size e-mail ile bilgi iletilecektir.

Gereėini bilgilerinize saygılarımızla sunarız.

Mali Denetleme ve Szleřmeler Mdrlė



EK-3. Veli Onam Formu

Sayın Veli;

Çocuğunuzun katılacağı bu çalışma, “Temel Hareket Becerileri Analizinde Kullanılacak Yapay Zeka Temelli Ölçüm Aracının Geliştirilmesi: AIMove ” adıyla, 01.07.2022 ile 01.07.2024. tarihleri arasında yapılacak bir araştırma uygulamasıdır.

Araştırmanın Hedefi: Alan yazında tipik ve atipik çocukların temel hareket becerilerinin ölçümlerinde kullanılan değerlendirme testleri incelendiğinde, bireyleri laboratuvar ortamına gerek duyulmadan norm değerler çerçevesinde ölçebilen ve kinematik değerlendirme sonuçları verebilen, kolay ulaşılabilir, işlevsel, düşük maliyetli ve taşınabilir vb. özellikleri tek bir platformda toplayan ölçüm aracı ile karşılaşılmamıştır. Bu durumda ulaşılabilir efektif kullanıma uygun geçerli ve güvenilir bir ölçüm aracı ihtiyacı ortaya çıkmaktadır. Bu bağlamda; özel gereksinimlerin tespiti ve erken önlem alma ile **Toplumsal bütünleşme**; Özel yeteneklerin tespiti ile **sportif başarının artması** gibi alt hedeflere ulaşmaya katkı sağlaması hedeflenmektedir. Ayrıca ekonomik ve ticari etki boyutunda ise **bilim teknoloji** alanına yeni ölçüm aracı üretilmesi ile alana özgü **dijital dönüşüme katkı sağlanması** beklenmektedir.

Araştırma Uygulaması: Uygulama şeklindedir. Ölçüm aracının geliştirilmesi için araştırmanın tüm sürecinde toplam 150 katılımcıdan veri toplanacaktır. Veriler, “yürüme, yatay atlama, topu yakalama, ayakla topa vurma” uygulaması yaptırılarak alınacaktır.

Araştırma T.C. Milli Eğitim Bakanlığı’nın ve okul yönetiminin de izni ile gerçekleştirilmektedir. Araştırma uygulamasına katılım tamamıyla gönüllülük esasına dayalı olmaktadır. Çocuğunuz çalışmaya katılıp katılmamakta özgürdür. Araştırma çocuğunuz için herhangi bir istenmeyen etki ya da risk taşımamaktadır. Çocuğunuzun katılımı **tamamen sizin isteğinize bağlıdır**, reddedebilir ya da herhangi bir aşamasında ayrılabilirsiniz. Araştırmaya katılmamama veya araştırmadan ayrılma durumunda öğrencilerin akademik başarıları, okul ve öğretmenleriyle olan ilişkileri etkilemeyecektir.

Çalışmada öğrencilerden kimlik belirleyici hiçbir bilgi istenmemektedir. Cevaplar tamamıyla gizli tutulacak ve sadece araştırmacılar tarafından değerlendirilecektir.

Uygulamalar, genel olarak kişisel rahatsızlık verecek sorular ve durumlar içermemektedir. Ancak, katılım sırasında sorulardan ya da herhangi başka bir nedenden çocuğunuz kendisini rahatsız hissederse cevaplama işini yarıda bırakıp çıkmakta özgürdür. Bu durumda rahatsızlığın giderilmesi için gereken yardım sağlanacaktır. Çocuğunuz çalışmaya katıldıktan sonra istediği an vazgeçebilir. Böyle bir durumda veri toplama aracını uygulayan kişiye, çalışmayı tamamlamayacağını söylemesi yeterli olacaktır. Anket çalışmasına katılmamak ya da katıldıktan sonra vazgeçmek çocuğunuza hiçbir sorumluluk getirmeyecektir.

Onay vermeden önce sormak istediğiniz herhangi bir konu varsa sormaktan çekinmeyiniz. Çalışma bittikten sonra bizlere telefon veya e-posta ile ulaşarak soru sorabilir, sonuçlar hakkında bilgi isteyebilirsiniz. Saygılarımızla,

Velisi bulunduğum sınıfı numaralı öğrencisi 'in yukarıda açıklanan araştırmaya katılmasına izin veriyorum. (Lütfen formu imzaladıktan sonra çocuğunuzla okula geri gönderiniz*).

...../...../.....

İsim-Soyisim İmza:

Veli Adı-Soyadı :

Telefon Numarası :

EK-4. Oluşturulan JSON Dosya Formatı

```
1 {
2   "record": {
3     "uuid": "0aad489c-6318-4d21-bd41-429eb495c871",
4     "dataset_id": 3,
5     "user": {
6       "uuid": "f208d26f-69e0-4024-a33e-3d0296a3238c",
7       "name_surname": "KATILIMCI İSİM SOYİSİM",
8       "weight": "35",
9       "height": "135",
10      "birthdate": "2014-05-29"
11    },
12    "movement": 3,
13    "labels": {"1": 3, "2": 3, "3": 2, "4": 1, "5": 1},
14    "timestamp": 1715084713262
15  },
16  "frames": [ // Her bir frame bir karedeki vücutların bilgilerini içerir
17    {
18      "timestamp": 1715084704863,
19      "bodyFrame": {
20        "bodies": [
21          {
22            "bodyIndex": 0,
23            "tracked": true,
24            "trackingId": "72057594037932283",
25            "leftHandState": 1,
26            "rightHandState": 1,
27            "joints": [ // Her bir nokta için kordinat bilgilerini içerir
28              {
29                "depthX": 0.6762003898620605,
30                "depthY": 0.4889526665210724,
31                "colorX": 0.6417778730392456,
32                "colorY": 0.5094642639160156,
33                "cameraX": 0.6298976540565491,
34                "cameraY": 0.006765195168554783,
35                "cameraZ": 2.7287986278533936,
36                "orientationX": -0.00015188459656201303,
37                "orientationY": 0.9920203685760498,
38                "orientationZ": 0.0010315027320757508,
39                "orientationW": 0.12607339024543762,
40                "jointType": 0,
41                "trackingState": 2
42              },
43              ...
44            ]
45          },
46          { "bodyIndex": 1, "tracked": false },
47          { "bodyIndex": 2, "tracked": false },
48          { "bodyIndex": 3, "tracked": false },
49          { "bodyIndex": 4, "tracked": false },
50          { "bodyIndex": 5, "tracked": false }
51        ],
52        "floorClipPlane": {
53          "x": 0.02390817180275917,
54          "y": 0.9987489581108093,
55          "z": -0.04392083361744881,
56          "w": 0.8487550616264343
57        }
58      }
59    },
60    ...
61  ]
62 }
```