



**T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**POZ TAHMİNİ İÇİN SENSÖR TABANLI BİR SİSTEM
TASARIMI VE UYGULAMASI**

YÜKSEK LİSANS TEZİ

Emin Berat BİLİR

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektrik-Elektronik Mühendisliği Tezli Yüksek Lisans Programı

ARALIK 2024

**T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**POZ TAHMİNİ İÇİN SENSÖR TABANLI BİR SİSTEM
TASARIMI VE UYGULAMASI**

YÜKSEK LİSANS TEZİ

**Emin Berat BİLİR
(21434981011)
ORCID: 0009-0000-4576-4301**

**Elektrik-Elektronik Mühendisliği Anabilim Dalı
Elektrik-Elektronik Mühendisliği Tezli Yüksek Lisans Programı**

**Danışman: Dr. Öğr. Üyesi Mustafa ÖZDEN
ORCID: 0000-0002-0362-4017**

ARALIK 2024



20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, Bursa Teknik Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

Bu tez, Bursa Teknik Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğünün 230Y013 numaralı projesi ile desteklenmiştir.

İNTİHAL BEYANI

Bu tezde görsel, işitsel ve yazılı biçimde sunulan tüm bilgi ve sonuçların akademik ve etik kurallara uyularak tarafımdan elde edildiğini, tez içinde yer alan ancak bu çalışmaya özgü olmayan tüm sonuç ve bilgileri tezde kaynak göstererek belgelediğimi, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Öğrencinin Adı Soyadı: Emin Berat BİLİR

İmzası:





Aileme,

ÖNSÖZ

Bu çalışmanın gerçekleşmesinde önemli katkıları olan değerli hocam Dr. Öğr. Üyesi Mustafa ÖZDEN'e en içten teşekkürlerimi sunarım. Eğitim sürecimde her zaman bana rehberlik eden, deneyimlerini cömertçe paylaşan ve tezimin oluşumunda destek sağlayan tüm katkıları için minnettarım.

Bu zorlu süreçte yanımda olan aileme ve arkadaşlarıma, sürekli motivasyon ve destekleri için içtenlikle teşekkür ederim.

Tezimin hazırlanma sürecinde, özellikle poz verilerinin alınması ve diğer aşamalarda değerli katkılarıyla bana destek olan Metehan TURAN'a içten teşekkürlerimi sunarım.

Yüksek lisans sürecimdeki destekleri için Karsan Ar-Ge'ye teşekkür ederim.

Aralık 2024

Emin Berat BİLİR
Elektrik-Elektronik Mühendisi

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	vii
İÇİNDEKİLER	viii
KISALTMALAR	x
SEMBOLLER	xi
ÇİZELGE LİSTESİ.....	xii
ŞEKİL LİSTESİ.....	xiii
ÖZET.....	xv
SUMMARY	xvi
1. GİRİŞ	1
1.1 Tezin Amacı	2
1.2 Literatür Araştırması	4
1.2.1 Sensör tabanlı ve hibrit sistemler	4
1.2.2 Görüntü tabanlı sistemler	11
2. GELİŞTİRİLEN POZ TAHMİN SİSTEMİ.....	14
2.1 Sistemle İlgili Temel Bilgiler	14
2.1.1 Gömülü sistem	14
2.1.2 Yapay zeka	16
2.1.2.1 Yapay sinir ağları	17
2.1.2.2 Yapay sinir ağlarında eğitim işlemi	18
2.1.2.3 Başarım değerlendirilmesi	21
2.2 Sistem Yapısının Aşamaları	22
2.3 Sistemin Donanımsal Yapısı	24
2.4 Sistemin Donanımsal Tasarımı	27
2.4.1 Güç devresi	27
2.4.2 Buton	28
2.4.3 Harici pinler	28
2.4.4 Mikrodenetleyici	29
2.4.5 Sensör	29
2.4.6 Programlayıcı	30
2.4.7 ESP8266 Wi-Fi modülü	30
2.4.8 Led	31
2.4.9 Baskı devre	31
2.4.10 Kartın 3B görünümü	32
2.5 Sistemin Gömülü Yazılım Tasarımı	32
2.5.1 STM32CubeIDE	32
2.5.2 Sistemin algoritma şeması	34
2.5.3 Sistemin yazılım akışı	35
2.5.3.1 Enerjilendirme ve bilgilendirme modu	35
2.5.3.2 Bekleme modu	36
2.5.3.3 Aktif çalışma modu	36

2.5.3.4 Etiket değeri seçim modu.....	37
2.5.3.5 Veri seti oluşturma modu	37
2.6 Sistemin Yapay Zeka Tasarımı	39
2.6.1 Veri setinin uygun duruma getirilmesi.....	39
2.6.2 Yapay sinir ağı modeli aracının çalıştırılması.....	42
2.7 Sistemin Arayüz Tasarımı	43
2.7.1 ThingSpeak platformu.....	44
2.7.2 Matlab app designer	44
2.7.3 Arayüz yazılımı.....	45
3. SONUÇ.....	48
4. TARTIŞMA	50
KAYNAKLAR	52
ÖZGEÇMİŞ.....	56



KISALTMALAR

AR	: Augmented Reality
CNN	: Convolutional Neural Network
EDM	: Euclidean Distance Matrices
EMI	: Electromagnetic Interference
I2C	: Inter-Integrated Circuit
IMU	: Inertial Measurement Unit
LTSM	: Long Short-Term Memory
MAE	: Mean Absolute Error
MEKF	: Multiplicative Extended Kalman Filter
MR	: Mixed Reality
MSE	: Mean Squared Error
PCB	: Printed Circuit Board
R²	: R-squared (Determination Coefficient)
RNN	: Recurrent Neural Network
SMD	: Surface-Mount Device
SVM	: Support Vector Machine
VR	: Virtual Reality

SEMBOLLER

$\hat{y}_i$	: Tahmin edilen değer
$\bar{y}$	: Gerçek değerlerin ortalaması
y_i	: Gerçek değer
n	: Toplam veri sayısı
s	: Sigmoid fonksiyonu
w	: Ağırlık değeri
x	: Giriş verileri

ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1 : Matlab yapay sinir ağı aracı eğitim sonrası performans sonuçları..... **43**



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : Poz tahmin işleminde gömülü sistemin fonksiyonu.....	15
Şekil 2.2 : Vücut bölümlerinden verilerin gömülü sistem ile alınması.	15
Şekil 2.3 : Yapay zeka alt kümeleri.	16
Şekil 2.4 : Yapay sinir hücresi.	17
Şekil 2.5 : Çoklu gizli katmanlı yapay sinir ağı modeli.	18
Şekil 2.6 : Sistemin ana aşamaları.	23
Şekil 2.7 : Sistem yapısı görselleri.	23
Şekil 2.8 : STM32G070CBT6 mikrodnetleyici.	24
Şekil 2.9 : MPU6050 eğim sensörü.	25
Şekil 2.10 : Lipo pil.	25
Şekil 2.11 : MCP1825ST voltaj regülatörü.	26
Şekil 2.12 : Butonlar.	26
Şekil 2.13 : Direnç, led, kondansatör.	27
Şekil 2.14 : Güç devresi şematik bölümü.	27
Şekil 2.15 : Buton şematik bölümü.	28
Şekil 2.16 : Harici pinler şematik bölümü.	28
Şekil 2.17 : Mikrodnetleyici şematik bölümü.	29
Şekil 2.18 : Sensör şematik bölümü.	29
Şekil 2.19 : Programlayıcı şematik bölümü.	30
Şekil 2.20 : Wi-Fi modülü şematik bölümü.	30
Şekil 2.21 : Led şematik bölümü.	31
Şekil 2.22 : Tasarımın PCB bölümü.	31
Şekil 2.23 : Kartın 3B görünümü.	32
Şekil 2.24 : STM32CubeIDE programı (Cubemx).	33
Şekil 2.25 : STM32CubeIDE programı (IDE).	33
Şekil 2.26 : Sistemin algoritma şeması.	34
Şekil 2.27 : Sistemdeki ledler ve butonlar.	35
Şekil 2.28 : Enerjilendirme ve bilgilendirme modu.	35
Şekil 2.29 : Bekleme modu.	36
Şekil 2.30 : Aktif çalışma modu.	36
Şekil 2.31 : Etiket değeri seçim modu.	37
Şekil 2.32 : Veri seti oluşturma modu.	37
Şekil 2.33 : Veri seti oluşturma modunda verinin örneklenmesi.	38
Şekil 2.34 : Veri seti oluşturma modunun tamamlanması.	38
Şekil 2.35 : Veri seti anlamlandırma akış şeması.	39
Şekil 2.36 : Mikrodnetleyici hafızasına erişim.	40
Şekil 2.37 : Sayı çevrim işlemi.	40
Şekil 2.38 : Offset çıkarma işlemi.	41
Şekil 2.39 : Sensör verilerinin son hali.	41
Şekil 2.40 : Poz verilerinin son hali.	42

Şekil 2.41 : Matlab yapay sinir ağı aracı eğitim öncesi.....	42
Şekil 2.42 : Yapay sinir ağı aracı ile eğitimin tamamlanması.	42
Şekil 2.43 : Yapay sinir ağı modelinin yapısı.....	43
Şekil 2.44 : ThingSpeak platformuna ait arayüz.	44
Şekil 2.45 : MATLAB app designer.....	45
Şekil 2.46 : Arayüz yazılım akışı.....	46
Şekil 2.47 : Arayüz programı.....	47
Şekil 3.1 : Tahmin çıktıları.	49



POZ TAHMİNİ İÇİN SENSÖR TABANLI BİR SİSTEM TASARIMI VE UYGULAMASI

ÖZET

Fiziksel hareketlerin dijital ortamlarda gerçek zamanlı olarak modellenmesi son yıllarda gelişmekte olan bir konudur. Elektronik alanındaki hızlı gelişimler, gerçekliğin dijital ortama dönüştürülmesinde kolaylık sağlamaktadır. İnsan vücudunun eklem bölgelerinin hareketlerinin dijital ortama aktarılması hem tıbbi uygulamalarda hem de insan vücudu ile senkronize çalışan diğer sistemlerde kritik bir rol oynamaktadır. Eklem hareketlerinin hassas ve hızlı bir şekilde dijital ortama aktarılması, tıbbi teşhis ve tedavi süreçlerinde daha hızlı ve doğru sonuçlar elde edilmesini sağlamaktadır. Tıbbi alanlarının dışında insan-robot etkileşimi gibi alanlarda da kullanılması önemli avantajlar sunmaktadır. İnsan vücudu ile senkronize bir şekilde çalışabilen bu sistemler, insanların zorlandığı görevleri daha yapılabilir duruma getirmekle kalmaz, aynı zamanda insanların potansiyel zarar görmesini de engelleyebilmektedir. Bu tez çalışmasında, insan vücuduna ait pozların tahmini için bir sistem geliştirilmesi amaçlanmıştır. Sistemin hem elektronik hem de yazılım bileşenleri bulunmaktadır. Tasarlanan elektronik sistem insan vücudu üzerinde on bölgeye yerleştirilecektir. Elektronik sistem üzerinde mikrodenetleyici, IMU sensör, Wi-Fi modülü ve diğer bileşenler bulunmaktadır. IMU sensörler kullanılarak insan vücudu üzerinden eğim değerleri alınarak Wi-Fi modülü ile bir veritabanına gönderilmektedir. Bilgisayar ortamında ise, tasarlanan bir arayüz programı ile bu sensör verileri veritabanından alınarak bir yapay sinir ağı modeli ile tahmin etme işlemi gerçekleştirilmektedir. Tahmin sonucunda ise, tahmin edilen pozun görsel ve sayısal bilgileri aynı arayüz programında gösterilmektedir. Tasarımda, elektronik sistemler tamamen modüler olarak kullanılmıştır. Besleme kaynağı olarak LiPo pil kullanılmıştır. Yapay zeka modeli eğitilmesi için gerekli veri setleri elektronik cihazın veri seti üretimi bölümü ile gerçekleştirilmiştir. IMU sensör verileri mikrodenetleyici hafızasında tutulmaktadır. Bu veriler yapay zeka modelinin eğitimi için girdi olarak verilmiştir. Sistemin eğitimi için 300.000 sensör verisi elde edilmiş ve sonuç olarak 10 poz için %90 doğrulukla poz tahmini gerçekleştirilmiştir.

Anahtar kelimeler: Mikrodenetleyici, IMU sensör, Wi-Fi modülü, Yapay zeka, Sistem tasarımı, Gömülü yazılım.

A SENSOR BASED SYSTEM DESIGN FOR POSE ESTIMATION AND APPLICATION

SUMMARY

The real-time modeling of physical movements in digital environments has emerged as a growing field in recent years. Advances in electronics have significantly facilitated the transformation of physical reality into digital form. Digitally capturing the motion of human joint regions plays a critical role in both medical applications and systems synchronized with the human body. The precise and rapid transfer of joint movements to a digital platform enhances the accuracy and speed of medical diagnosis and treatment processes. Beyond medical fields, such systems offer significant advantages in areas such as human-robot interaction. Systems synchronized with the human body not only make physically demanding tasks more manageable but also reduce potential risks to individuals. This thesis aims to develop a system for predicting human body poses. The proposed system encompasses both electronic and software components. The electronic system is designed to be deployed across ten regions of the human body. Key components include a microcontroller, IMU sensors, a Wi-Fi module, and other electronic elements. Using IMU sensors, angular orientation data is collected from the human body and transmitted to a database via the Wi-Fi module. On the software side, a custom-designed interface retrieves sensor data from the database and processes it using an artificial neural network (ANN) model for pose prediction. The predicted pose is then displayed both visually and numerically on the same interface. The electronic components of the system are designed to be fully modular. A LiPo battery is used as the power source. The system also features a data generation mechanism for training the AI model. IMU sensor data is stored in the microcontroller's memory and used as input for AI model training. A dataset comprising 300,000 sensor readings was collected for training, resulting in a pose prediction accuracy of 90% for 10 distinct poses.

Keywords: Microcontroller, IMU sensor, Wi-Fi module, Artificial intelligence, System design, Embedded software.

1. GİRİŞ

Teknolojinin hızlı bir şekilde gelişmesiyle birlikte, kamera ve giyilebilir teknoloji cihazlarının kullanımı da hızla artmaktadır. Bu gelişim, sadece son kullanıcıların günlük yaşamlarını kolaylaştırmakla kalmayıp, aynı zamanda çeşitli alanlarda hedeflenen sonuçlara daha hızlı ve güvenilir bir şekilde ulaşılmasını sağlamaktadır. Örneğin, insan poz tahmini birçok uygulama için önemli bir konudur. Biyomekanik, fizyoloji, psikoloji, animasyon, insan-bilgisayar etkileşimi, insan-robot etkileşimi gibi başlıca uygulama alanları buna örnek verilebilir. İlerleyen bilgisayar teknolojisi ve Metaverse teknolojisinin de hayatımıza girmesi sonucu sanal uygulamaların artmasıyla, sanal-gerçeklik (VR), artırılmış gerçeklik (AR) ve karma gerçeklik (MR) uygulamaları günümüzde de üzerinde durulan ve gelecekte daha da önemli olacak olan uygulama alanlarıdır. Bu alanlara hızlı şekilde adapte olabilmek, uygulamalar ve sistemler geliştirebilmek ilerleyen yüzyıllarda var olabilme açısından önem arz etmektedir.

Özellikle sanal gerçeklik uygulamaları düşünüldüğünde, artık kullanıcının sadece elindeki sensörlerin ve baş hareketlerinin sanal dünyaya aktarılması ve buna göre tepki oluşturulması yeterli gelmemektedir. Kullanıcının tüm vücut pozunu veya bazı vücut parçalarının X, Y, Z konumları ve açılarının elde edilmesi ile kullanıcının avatarının gerçek zamanlı olarak sanal ortama aktarılması bu uygulamaların önünü daha da açacaktır. En basitinden silahlı askeri eğitimler bu tür bir sistem ile, yaralanma riski olmadan gerçeğe en yakın deneyimi sağlayacak şekilde sanal ortamda rahatlıkla gerçekleştirilebilir. Yine vücut pozlarının önem arz ettiği çeşitli spor dallarına ait uygulamalar bu tür bir sistem ile geliştirilebilir. Bu ve bunun gibi sistemlerde, poz verilerinin sanal ortama aktarılırken aktarılma hızı ve veri gönderilme doğruluğu da çok önemlidir. Gönderilen verilerin doğruluğu ne kadar yüksek ise, sanal ortamda da alınacak sonucun doğruluk oranı aynı oranda yüksek olacaktır. Veri güvenilirliğinin düşük olması durumunda beklenen sonucun daha altında sonuç almak kaçınılmazdır.

Yapay zeka alanındaki gelişmelerin hızlı bir şekilde artmasıyla birlikte neredeyse her alanda bir yapay zeka modelinin kullanıldığı görülmektedir. Bu yapay zeka modelleri,

sistemleri kontrol eden klasik yöntemler yerine daha verimli, hızlı ve güvenilir sonuçlar vermektedir. Sensörlerden veya kameralardan girdi olarak gelen veriler ile bir model eğitilebilir ve bu model ile daha başarılı bir sonuç elde edilebilir. Teknolojinin her alandaki gelişimi ve bu gelişimlerin birbirine olan etkisiyle beraber daha iyi sistemler elde edilebilmektedir. Yukarıda örnek gösterilen sistemlerin de sanal dünya ile ilişkilendirilmesi ve yapay zekanın birlikte kullanılması çok yüksek bir ihtimalle gerçekleştirilecektir.

Çoklu girişe sahip bu tür sistemlerin karmaşıklık seviyesi arttıkça çözüm bulunabilmesi de zorlaşmaktadır. Bu karmaşık sistemlerde yapay zekanın pratik olarak kullanılması büyük avantaj sağlamaktadır. Bu gibi avantajlarının yanında, yapay zeka modellerinin tümleşik sistemlere kolayca entegre edilebilmesi de sağladığı diğer büyük avantajlardandır. Karmaşık sistemlere bulunacak çözümlerin yüksek maliyetlerine karşı hem pratik hem de ucuz şekilde çözüm bulunabilmesi yapay zeka ile çok daha kolay olmaktadır.

1.1 Tezin Amacı

Sanal gerçekliğin kullanım alanlarının çoğalmasıyla beraber gerçek zamanlı poz tahmini alanında da çalışmalar hızla artmaktadır. Bu çalışmalarda da kamera veya atalet ölçüm (IMU) sensörleri kullanılmaktadır. Sadece kamera kullanılan sistemlerde alınan görüntüler üzerinde görüntü işleme teknikleri ve diğer yapay zeka yöntemleri kullanılarak poz tahmini yapılabilmektedir. Düşük maliyetli bu sistemlerde sonuçlar iyi çıkabilir fakat kameralar ölü bölgelerde görüntü alamayacağı için dezavantajlara sahiptir. Ayrıca, kameralı sistemler kullanıcıyı belirli bir konumda kısıtlayabilir. IMU sensör kullanılan çalışmalarda sensörün esnek yapıda olması ve hassas ölçüm yapabilme yeteneği ile daha verimli olduğu söylenebilmektedir. Bu sensörlerin maliyetinin düşük olması ve kullanımının kolay olması büyük bir avantaj sunmaktadır.

Bu tez çalışmasında sadece IMU sensörler kullanılarak yapay zeka ile birlikte 3B insan poz tahmini yapabilen bir sistem tasarımının gerçekleştirilmesi hedeflenmiştir. Tez çalışmasında sadece insan vücut parçalarının konum ve açılarının elde edilmesi ile bir arayüz programında insan pozunun gösterilmesi amaçlanmıştır. Vücut üzerinde toplam 10 adet olacak şekilde IMU sensörlü sistem yerleştirilmiştir. Bu sistemler vücut üzerinde yerleşim olarak uygun görülmüş bölümlere yerleştirilmiştir. Bu sistemler birbirinden bağımsız çalışabilse de çalışmanın amacına uygun olarak birbiriyle

bağımlı ve senkronize bir şekilde çalışması gerekmektedir. Yapay zeka modeli, insan pozisyonunu tahmin etme işlemini gerçekleştirirken, bu girdilerin de aynı anda senkronize şekilde gelmesi gerekmektedir.

IMU sensörlerden verilerin kolay bir şekilde alınabilmesi ve diğer sistemlerle beraber senkronize bir şekilde çalışabilmesi için mikrodenetleyici tabanlı bir sistem tasarımı yapılmıştır. Elde edilen sensör verilerinin yapay zeka modeline gönderilmesi için kablosuz bir haberleşme modülü kullanılmıştır. Bu sistemler beslemesini bir pil üzerinden almaktadır. Yapay zeka modelini eğitmek için gerekli veriler, tasarlanan elektronik sistem üzerinde kaydedilerek yapay zeka modeline girdi olarak verilmektedir. Bu veriler belirli sayıda hareketlerin tekrar edilerek kaydedilmesiyle oluşturulmuştur. Veri seti oluşturulurken, veriler mikrodenetleyicinin hafızasında tutulmakta ve bir araç ile bu veriler bilgisayar ortamına aktarılmaktadır. Poz tahmin etme fonksiyonu gerçekleştirilirken on adet sistemden gelecek sensör verileri Wi-Fi modülü ile bir veri tabanına gönderilmektedir. Tasarlanan arayüz programı ise, poz tahmin etme fonksiyonu çalıştırıldığında veri tabanından sensör verilerini alarak yapay zeka modeline girdi olarak verilmekte ve yapay zeka modelini çalıştırmaktadır. Çıktı olarak tahmin edilen pozun görseli ve doğruluk oranını gösterilmektedir. Tüm sensör verileri gerçek zamanlı olarak hem veri tabanından hem de arayüz programından izlenebilmektedir. Vücut üzerinde bulunan sistemin hangi bölgede bulunduğu ve hangi verileri yolladığı işaretlenmiş olarak arayüz programında görülebilmektedir. Veri gönderilmesinde bir karışıklık olması durumu sistemden kolayca izlenebilmektedir.

Kablosuz modül ile veri gönderilirken bir hata oluşması durumunda ilgili modül hata moduna düşmektedir ve bu mod sonrasında sistem kendisini resetleyebilir ve diğer sistemlerin akışını bozmadan çalışma durumuna otomatik geri dönebilmektedir. Bu sayede sistemin senkronize çalışmasını etkileyecek etkiler ortadan kaldırılması hedeflenmiştir. Vücut üzerinde modüllerin yerleştirilmesini ve bulunduğu konumu koruyabilmesi için saat kordonuna benzer bir kordon tasarlanmıştır. Bu sayede vücut üzerine kolayca takılıp çıkarılabilmektedir. Sistem tasarımı yapılırken sistemin modüler olması hedeflenmiştir. Vücut üzerine yerleştirilen her bir modülün sahip olduğu bir numara bulunmaktadır. Bu numaralar, tasarlanan cihaz üzerinden kolayca seçilebilmektedir. Bu sistemlerden birisinin bozulması durumunda yedek bir sistemi bu akışa dahil etmesi mümkün olmaktadır. Bozulan sistemin bulunduğu vücut

bölgesinin numarası yeni sistemde seçildikten sonra ilgili sistem, akışa otomatik olarak katılabilmekte ve veri akışını devam ettirebilmektedir.

Tez çalışmasındaki ilgili elektronik kart tasarımı sürecinde, kullanılacak elektronik bileşenlerin birbirleriyle olan etkileşimlerinin minimum seviyede tutulması esastır. Bu, elektromanyetik girişim (EMI) ve diğer parazitik etkilerin en aza indirilmesi açısından kritik öneme sahiptir. Ayrıca, montaj sırasında karşılaşılan zorlukların azaltılması ve üretim sürecinin kolaylaştırılması için bileşen yerleşimi dikkatle planlanmalıdır. Bu planlama, hem otomatik montaj makinelerinin verimliliğini artıracak hem de manuel montaj işlemlerini kolaylaştıracaktır. Sistem tasarımının özgün olması amaçlanmaktadır. Son kullanıcının rahat bir şekilde kullanabileceği bir sistem olması hedeflenmektedir. Bundan dolayı elektronik kart tasarımı, kart yazılımı ve bilgisayar arayüz programının yazılımı ve tasarımı özgün olarak yapılmıştır. Tez çalışması şu şekilde organize edilmiştir. Bölüm 1.2’de literatür çalışmalarına yer verilmiş, 2. bölümde geliştirilen poz tahmin sistemi açıklanmıştır. 3. bölümde ise sonuçlar sunulmuş ve 4. bölümde tartışmaya yer verilmiştir.

1.2 Literatür Araştırması

Literatürdeki 3B insan poz tahmini üzerine yapılan çalışmalar incelendiğinde birçok yöntem kullanılarak insan poz tahminin gerçekleştirildiği araştırmaların mevcut olduğu görülmüştür. IMU sensörlerin yanında farklı sensörler veya kamera modüllerinde kullanıldığı hibrit sistemlerde mevcuttur. IMU sensörler dışında görüntü verilerin üzerinde de insan poz tahmininin yapıldığı çalışmalar da bulunmaktadır.

1.2.1 Sensör tabanlı ve hibrit sistemler

Von Marcard ve diğ. (2016) 3B insan poz tahmini gerçekleştirmişlerdir. Çalışmada, video verilerinin kullanılmasının yanında IMU sensör verileri de kullanılarak hibrit bir sistem oluşturulmuştur. Video verileri hareket analizinde kullanıldığında, hızlı hareketlerde veya belirsiz durumlarda hatalara sebep olmaktadır. Bu hataların giderilmesi için IMU sensörler kullanılmıştır. Sadece IMU sensörler kullanıldığında da doğru konum bilgisi alınmamaktadır. Bu hibrit sistem ile dezavantaj durumlarının ortadan kaldırılması hedeflenmiştir.

Trumble ve diğ. (2017) çoklu açıdan video görüntüsü ve IMU sensör kullanarak 3 boyutlu konum ve poz tahmini çalışması gerçekleştirmiştir. Tahmin işlemini gerçekleştirebilmek için yapay zeka modeli olarak 3 boyutlu konvolüsyonel sinir ağı modelini kullanmışlardır. Vücut üzerinde ölçüm yapılacak belirli bölgelere IMU sensörleri yerleştirilerek veri toplama işlemi gerçekleştirmişlerdir. Ancak, bu süreçte hareket algılama sırasında veri kaymalarının meydana geldiği gözlemlenmiştir. Araştırmacılar, bu kayma sorunlarını gidermek ve veri doğruluğunu artırmak amacıyla alternatif bir yöntem önermişlerdir. Bu yöntem ile, elde edilen poz görüntüleri ile vücut üzerindeki IMU sensörlerinden elde edilen verilerin entegre edilmesiyle çift akışlı bir sinir ağı modeli sunarak bu modeli hibrit model olarak kullanmışlardır. Bu model ile kullanılan modüllerin belirsizlikleri azaltılarak, önceki yöntemlerin sonuçlarına göre daha yüksek doğruluk sağlamışlardır.

Malleson ve diğ. (2017), vücut hareket yakalama sistemi sunmuşlardır. Bu sistemde, IMU sensörleriyle birlikte kamera verilerini de kullanmışlardır. IMU sensörleri ile kamera verilerinin birleştirilmesiyle hibrit ve gerçek zamanlı bir sistem önermektedirler. Yazarlar, gelecek çalışmalarında algılama hızının artırmak için birden fazla GPU kullanmayı hedeflemektedir. Zheng ve diğ. (2018), gerçek zamanlı insan hareket yakalaması için kamera ve IMU sensör tabanlı bir sistem sunmuşlardır. Sistemin pratik yapısından dolayı gerçek zamanlı olarak artırılmış gerçeklik (AR) ve sanal gerçeklik (VR) uygulamalarında kullanılabilmesi mümkün olmaktadır.

Pathirana ve diğ. (2018) doğrusal olmayan problemlerin tahmin edilebilmesi için geleneksel yöntemlerden ziyade, poz tahmininde farklı bir yöntem sunmaktadırlar. Kullandıkları yöntem ile doğrusal olmayan problemlerin doğrusal bağlamda ele alan ölçüm tekniklerini göstermişlerdir. Bu çalışmada engelli insanların hareket bozukluklarının tespit edilebilmesi için IMU sensörler kullanılmıştır. Çalışmanın hedefi engelli bir birey olduğu için, insan vücudu üzerindeki bölgelere yerleştirilirken bu bireyleri zorlamayacak ve pratik olmasını sağlayacak şekilde en az sayı da sensör kullanımı hedeflenmiştir. Tahmin etme süreçlerinde kalman filtresi kullanılmıştır. Bu filtrenin kullanılması durumunda, tek bir sensör kullanıldığında eklem pozisyonlarının tahmin sonuçlarının daha iyi elde edildiği gösterilmiştir. Bu yöntemlerin doğruluğunun gösterilmesi için hem bilgisayar simülasyon ortamlarında hem de deneysel çalışmalarla gösterilmiştir.

Von Marcard ve diğ. (2018), IMU sensörleri ve kamera kullanarak 3B insan poz tahmini gerçekleştirmişlerdir. Çalışmada, IMU takılı kişilerde 2B ve 3B verilerin birbirine olan tutarlılığının sağlanması için grafik tabanlı yöntem kullanılmıştır. Geliştirilen yöntem TotalCapture veri seti üzerinde doğrulanmıştır. Çalışma, 3DPW adı verilen yeni bir veri seti sunmaktadır. Chan ve diğ. (2018), yaptıkları çalışmada el hareketlerinin izlenilmesini sağlayan bir sistem geliştirmişlerdir. Çalışmada, kamera, IMU ve flex sensör olmak üzere üç farklı sensör kullanmışlardır. El hareketleri gerçek zamanlı olarak bilgisayar ortamına aktarılmış ve sanal el modeli ile eş zamanlı olarak çalıştırılmaktadır.

Vu ve diğ. (2019) el pozu tahmini üzerine bir çalışma gerçekleştirmişlerdir. Bu çalışmada iki adet ivmeölçer (IMU) sensörü ve Leap Motion Kamerası (LMC) kullanılmıştır. Çalışmada kullanılan IMU sensörleri, elin arka kısmına yerleştirilen bir kutu üzerine monte edilmiştir. Poz tahmini sırasında, IMU sensörlerinden elde edilen verilerin doğruluğu için Ortalama Kare Hatası (MSE) değeri minimize edilmiştir. Çalışma, sanal gerçeklik (VR) ve artırılmış gerçeklik (MR) uygulamalarında kullanılması hedeflenmektedir. Önerilen yöntem ile el pozlarının gerçek zamanlı olarak tahmin edilmesi mümkün kılınmıştır. Yapılan çalışmada, yöntemin VR uyumlu bilgisayar ortamlarında 70 Hz yenileme hızında izlenebilir ve tahmin edilebilir olduğu gösterilmiştir. Gelecekteki çalışmalar için, el poz tahmininin doğruluğunun artırılmasını ve bilgisayarların yanında mobil akıllı telefonlarda VR/MR uygulamalarının kullanılmasını önermişlerdir.

Baldi ve diğ. (2019) insan vücudunun üst bölgesinin tahmin edilmesi üzerine bir çalışma gerçekleştirmişlerdir. Bu çalışmada tahmin işlemi için donanımsal olarak IMU sensörler kullanılmıştır. Elde edilen sensör verilerinin birleştirilmesinde Multiplicative Kalman Filtresi (MEKF) kullanılmıştır. Çalışmada, mevcut sistemlerde kullanılan sensörlerin dezavantajını kaldırmak için ivmeölçer sensörlerin kullanıldığı algoritmalar kullanılmıştır. Çalışmanın deneysel sonuçlarına bakıldığında, kullanılan yöntemin manyetik alanlardan etkilenmeyen, düşük maliyetli ve yüksek doğrulukta vücut duruş tahmini sağlandığını görülmektedir. Yapılan çalışma gerçek zamanlı olarak bilgisayar üzerinde izlenebilmektedir. Sonuç olarak, 1 kHz sinyal hızında gerçekleştirilen örnekleme işlemlerinde takip hatasının ortalama olarak 1 dereceyi aşmadığı, 100 Hz sinyal hızında yapılan örneklemeelerde ise bu hatanın 1,50 dereceden daha düşük seviyelerde kaldığı gözlemlenmiştir.

Huang ve diğ. (2020) bu çalışmada, insan pozunun 3B olarak tahmin ettirilebilmesi için bir model önermektedir. Bu model tasarımı IMU sensörler kullanılmıştır. IMU sensörlerinden elde edilen veriler ve görüntü verileri birleştirilerek insan pozunun 3B tahminini gerçekleştiren entegre bir yaklaşım geliştirmişlerdir. Bu yöntem ile hem görüntü verilerinin hem de sensör verilerinin birbirini tamamlayıcı özelliklerini kullanarak daha yüksek performans sunmaktadırlar. Önerilen model, “DeepFuse” olarak adlandırmaktadırlar. Bu model iki ana aşamadan oluşmaktadır. İlk aşamada, görüntü tabanlı poz tahmini gerçekleştirilmektedir. İkinci aşamada ise, IMU sensörlerinden elde edilen veriler ile görüntü verileri birleştirilerek daha hassas ve doğru bir 3B poz tahmini sağlanmaktadır. Yazarlar tarafından önerilen bu model, hibrit bir yapı sunarak yenilikçi ve yüksek performanslı bir çözüm sağlamaktadır.

Rohan ve diğ. (2020) gerçek zamanlı olarak insan yürüyüş analizi üzerine bir çalışma gerçekleştirmişlerdir. Bu çalışmada, yapay zeka modeli olarak derin öğrenme yöntemleri tercih edilmiştir. Bu model, insan hareketlerinin daha doğru bir şekilde analiz edilebilmesi amacıyla derin öğrenme tabanlı olarak gerçekleştirilmiştir. Modelin yanı sıra, veri toplama ve işleme süreçlerinde kameralar, IMU sensörler ve diğer teknolojiler kullanılmıştır. Kaydedilen verilerin anlamlandırılması için derin öğrenme aracı olan konvolüsyonel sinir ağı kullanılmıştır. Bu sinir ağı modeliyle, normal ve anormal insan yürüyüşleri sınıflandırılmıştır. Model eğitimi, farklı durumlarda yürüyen kişilerin verilerini toplanması ve etiketlenmesiyle gerçekleştirilmiştir. Her bir yürüyüş hareketi canlı video akışı olarak kaydedilerek veri toplama süreci gerçekleştirilmiştir. Vücut üzerinden 25 farklı bölgeden oluşan bir iskelet modeli görüntüsü gösterilmektedir. Deneylerin sonucunda %97,3 doğruluk oranı elde etmişlerdir.

Ababsa ve diğ. (2020) yapmış oldukları çalışmada Catadioptric kamera sensörü kullanarak ortam içindeki insanların pozlarını elde etmeye çalışmışlardır. Bu çalışmada insan pozlarının 3B olarak tahmin edilmesi amaçlanmaktadır. Bu çalışma karmaşık ortamlarda yapılmıştır. Tamamen kamera tabanlı 360 derece görüntü almaya dayalı bu sistemde insan poz tahmini için insan hareket modeli, SVM ve parçacık filtresi kullanılmıştır. Kullandıkları yöntem deneysel olarak denenmiştir ve farklı yöntemleri ile karşılaştırılmıştır. Elde edilen deney sonuçları ile makine öğrenimi tabanlı teknikler karşılaştırıldığında, kullanılan yöntemin olumlu sonuçlar aldığı gösterilmektedir. Yazarlar, gelecek çalışmalarda tahmin doğruluğunu arttırabilmek

için imu sensörlere benzer sensörlerin ayrıntılı bölümlerini kullanmayı ve bu sensörlerin yanında yapay zeka modelini de eklemeyi düşünmekte ve yapay zeka yöntemi olarak derin öğrenme yaklaşımını kullanmayı planlamaktadırlar.

Konak ve diğ. (2020) IMU sensörlerinden elde edilen verileri kullanarak insan hareketlerinin sınıflandırma çalışmasını gerçekleştirmişlerdir. Çalışmada farklı olarak elde edilen IMU sensör verilerinin iki boyutlu ısı haritasına dönüştürülmesi amaçlanmıştır. Sınırlı sayıda IMU sensör veri seti kullanılarak, veri miktarının sınırlı olmasına rağmen sınıflandırma performansının yüksek olduğu ortaya konmuştur. Ayrıca, daha büyük veri setleri kullanılarak bu testler tekrardan gerçekleştirilmiş ve testler sonucunda performansın daha da arttığı gözlemlenmiştir. Sınıflandırma yöntemi olarak, konvolüsyonel sinir ağı (CNN) ile uzun kısa süreli bellek (LTSM) ağının birleşimi olan ConvLSTM modeli kullanılmıştır. Yazarlar yaptıkları bu çalışma ile elde ettikleri sonuçlara ek olarak, IMU sensör değerlerinin gürültü oranının azaltılması için teknikler uygulanması gerektiğini hem IMU sensörler hem de görüntü verileri kullanılarak yüksek doğruluklu hibrit modeller oluşturulabileceğini önermektedirler.

Malleson ve diğ. (2020), video kamera ve IMU sensör kullanarak gerçek zamanlı hareket yakalama çalışması gerçekleştirmişlerdir. Kamera ve IMU verilerini birleştiren bir sistem sunmaktadırlar. Sundukları sistem ile aynı anda birden fazla kişi takip edebilmektedir. Çalışma, TotalCapture ve Human3.6M veri setlerinde iyi sonuçlar elde etmiştir. Zhang ve diğ. (2020), 3B insan poz tahmini gerçekleştirmişlerdir. Bu çalışmada, IMU sensörleri ve görüntü verileri kullanılmıştır. Elde edilen verilerle ilk önce 2B olarak poz çıkarımı yapılır ve sonrasında 3B poz çıkarımı yapılmaktadır. Yazarlar, gelecek çalışmalarında IMU sensör verilerinde meydana gelen gürültüler için filtreleme gibi yöntemleri kullanmayı hedeflemektedirler.

Butt ve diğ. (2021) 3B insan poz tahmin edilebilmesi için elektronik donanım olarak altı adet IMU sensör kullanmışlardır. Poz tahmini yapılabilmesi için derin öğrenme tabanlı bir model tercih edilmiştir. Bu model çift yönlü olarak kurgulanmıştır. Önerilen yöntem, manyetik gürültünün yoğun olduğu ortamlarda dahi etkili ve güvenilir sonuçlar üretebilme kapasitesine sahiptir. Çalışmanın sonuçları iki farklı DIP-IMU ve Total Capture veri setlerinde gösterilmiştir. Çalışmanın en önemli katkısı az sayıda sensör kullanılarak elde edilen sensör verilerinin, 3B insan pozlarının belirsizlikler ve

hatalarla olan ilişkilerinin etkili bir şekilde kalibre edilmesi sonucunda, yüksek doğrulukta bir tahmin modelinin geliştirilmesidir. Kullanılan modelin tahmin ettirme işleminin sonucunda elde edilen poz verileri, daha sonrasında Kalman filtresi gibi algoritmalarla birlikte kullanılmasını mümkün kılmaktadır.

Patil ve diğ. (2021) yaptığı çalışmada ise IMU sensörlerinin kullanımına ilave olarak insan konumunun tespit edilebilmesi için lidar sensör kullanılmıştır. Sadece IMU sensör kullanılması durumunda, bir süre sonra sensör kayması sonucunda insan poz tahminin verilerinin doğruluğunun azaldığı ifade edilmektedir. Bu problemi çözebilmek için ilk çalışmada iki lidar ve 10 IMU sensör kullanmışlardır. Sonrasında ise IMU sensör sayısı yaklaşık olarak aynı sayıda kalmıştır, fakat lidar sayısı ise bire düşürülmüştür. IMU sensörlerle beraber lidarın kullanılması birçok avantaj sağlamıştır. Bu avantajlar, hedeflenen durumun daha iyi tahmin edilebilmesi, insan hareket takibinin ve pozisyon doğruluğunda olumlu sonuçlar elde edilebilmesi olarak belirtilmektedir. Tahmin edilen insan poz verisi bilgisayar ortamında 3B avatar oluşturmak için kullanılmıştır.

Palermo ve diğ. (2021) çalışmalarında, iki adet RGB+D kamera kullanarak gerçek zamanlı, vücut duruş tahmini yapmışlardır. Bu kameralar, rehabilitasyonda kullanılan akıllı yürüteç ekipmanı üzerine konumlandırılmıştır. İnsan vücudu üzerindeki belirli noktalarının tahmini yapılırken iki aşamalı bir sinir ağı kullanmışlardır. Bu sinir ağı modelinin ilk aşamasında, vücut üzerindeki noktalar 2 boyutlu olarak tespit edilmiştir. Diğer aşamasında ise tespit edilen noktalar 3 boyutlu olarak ilişkilendirilmiştir. Veri setleri üretilirken on dört sağlıklı insan üzerinden veri alınarak üretilmiştir. Veri setlerinin üretiminden sonra bu veri setleri kullanılarak eğitilen model yürüteç ekipmanı üzerinde uygulanmıştır. Yapılan çalışma da iyi sonuçlar elde edilmiştir fakat daha iyi ve gerçekçi performanslar için veri setleri üretme işleminin yürüme bozukluğu olan insanların üzerinde fazlasıyla yapılması gerektiği sonucuna varmışlardır. Bu çalışma aynı zamanda akıllı yürüteçler konusunda yenilikçi bir yaklaşım sunmaktadır.

Ogata ve diğ. (2021), insan hareketlerinin ölçülebilmesini sağlayan bir çalışma gerçekleştirmişlerdir. Bu çalışmada, görüntü tabanlı modül ve IMU sensör verilerini birleştirerek Marker-IMU sistemini geliştirmişlerdir. Üst uzuv ve yürüme hareketlerindeki deneylerde, sistemin ölçüm işleminin başarılı olduğu gösterilmiştir. Chen ve diğ. (2021), vücudun alt bölgelerinin 3B olarak tahmin edilmesi üzerine bir çalışma gerçekleştirmişlerdir. Çalışmada, IMU sensörleri ile grafik konvolüsyon ağı

(GCN) tabanlı bir derin öğrenme mimarisi kullanılmıştır. Veriler, sağlıklı bireylerden toplandığı için anormal yürümeye sahip hastalarda model doğru tahmin edememektedir. Yazarlar, gelecek çalışmalarında önerilen sistemin ve modelin rehabilitasyon üzerindeki etkilerinin doğrulanmasını hedeflemektedirler.

Pascual-Hernandez ve diğ. (2022) gerçek zamanlı 3B insan poz tahmini üzerine yaptıkları çalışmada, insan vücudunun 3B poz ve konum tahminini daha hassas ve doğru bir şekilde yapabilmek için, sadece renkli görüntü verileri değil aynı zamanda derinlik bilgisi de içeren verilerini de kullanmışlardır. Çalışmada RGBD sensörler kullanılmıştır. Bu sensörlerle kaydedilen görüntüler ile gerçek zamanlı çalışan bir yaklaşım önermektedirler. RGBD sensör verileri ile derinlik bilgilerinin birlikte kullanılması insan vücudu tahmininin daha doğru yapılabilmesine olanak sağlamaktadır. Poz tahmini için konvolüsyonel sinir ağı mimarisi (CNN) kullanılmıştır. 2B olarak CNN mimarisi ile tahmin edilen poz verisi 3B projeksiyon yöntemi ve kalman filtre yaklaşımı ile 99 kare/sn performans ile elde edilebilmiştir. Çalışmada Kalman filtresi, poz tahminlerinin doğruluğunu artırmak ve gürültülü verileri filtrelemek amacıyla kullanılmıştır.

Kim ve Lee (2022) çalışmasında sunulan sistem, 6 adet IMU sensör, sistem baş takibi ve derin öğrenme tabanlı poz sınıflandırıcı kullanılarak geliştirilmiştir. Bu çalışma da insan poz tahmini ve konum takibi yapılmıştır. IMU sensörler, daha hassas veri ölçümü yapabildiğinden dolayı görüntü işleme tabanlı yöntemlere göre sanal gerçeklik uygulamalarında ve karmaşık ortamlarda daha iyi çalışabilmektedir. Fakat, sanal gerçeklik uygulamalarında sadece IMU sensörlerin kullanılması insan konumunun takip edilmesini zorlaştıracığı için yeterli olmamaktadır. İnsan vücudunun konumunun takip edilebilmesi için IMU sensörlerinin yanında başa monte edilen insan konumunun izlenmesi sağlayan bir sensör kullanılmıştır. Bu kullanılan yöntemin sonucunda daha yüksek tahminler elde edilmiştir. Özellikle tahmin edilmesi zor olan insan pozlarında çömelme veya eğilme gibi duruşlarda yüksek doğrulukta tahmin edildiği belirtilmiştir.

Bao ve diğ. (2022) 3B insan poz tahmini üzerine gerçekleştirdikleri çalışmada giysi üzerine yerleştirilen sensörler ile veriler toplanmaktadır. Elde edilen bu sensör verileri ile görüntü verilerini birleştirerek bir sistem tasarımı gerçekleştirilmiştir. Bu sistem tasarımı ile, yalnızca görüntü verilerine dayalı poz tahminine kıyasla, sensör ve görüntü verilerini birleştirerek daha hassas ve güvenilir bir poz tahmin modeli

oluşturmuşlardır. Toplanan veriler üzerinde doğruluğun artırılması için kalman filtresi uygulanmıştır. Bu kalman filtresi ile verilerdeki gürültüler azaltılarak tahmin işleminde daha güvenilir bir poz tahmin sistemi gerçekleştirilmiştir. Çalışmada, sensör ve görüntü verilerinin birlikte kullanılması, sistemin belirsiz ve tahmin edilmesi zor olan pozlarda dahi yüksek performans ve doğruluğun elde edilmesine olanak sağlamaktadır. Görüntü verilerinin yetersiz kalması durumunda sensör verilerinin birleştirilmesiye sonuç daha güvenli olmaktadır.

Zhou ve diğ. (2023), insan poz tahmini çalışması gerçekleştirmişlerdir. MD-Pose adlı bu sistemde, tek kanallı UWB radar kullanılmıştır. Çalışmada, radar verisinden elde edilen veriler ile insan vücudu üzerinde 14 bölgeyi tahmin edebilmektedir. MD-Pose sisteminin tek kanallı UWB radar ile insan poz tahminin etkili bir şekilde gerçekleştirdiği gösterilmektedir. Dahiya ve diğ. (2024), el hareketi tanıma üzerine bir çalışma gerçekleştirmişlerdir. Çalışmada, IMU tabanlı bir sistem kullanmışlardır. IMU sensörünün yanında CNN modeli de kullanılmıştır. Modelin doğruluk oranı %97,88 olarak gösterilmiştir. Yazarlar, sistemin güvenilirliğinin artırılması için EMG/MMG gibi ek sensörlerin entegrasyonunu önermektedirler.

1.2.2 Görüntü tabanlı sistemler

Andriluka ve diğ. (2010), 3B insan poz tahmini ve takibi için bir çalışma gerçekleştirmişlerdir. Bu çalışma kalabalık sokak koşullarında gerçekleştirilmiştir. Yazarlar, kalabalık ortamlarda insan poz tahmininin mevcut yöntemlerle tahmin edilmesinde zorluk yaşanmasında dolayı, bu zorluklara çözüm olabilecek bir çalışma gerçekleştirmişlerdir. 3B pozun elde edilebilmesi için üç aşamalı bir sistem geliştirilmiş ve HumanEva II veri setinde test sonucunda başarılı olduğu belirtilmiştir. Pons-Moll ve diğ. (2014), görüntü üzerinden 3B insan poz tahmini üzerine bir çalışma gerçekleştirmişlerdir. Geliştirdikleri bu yönteme Posebits adı verilmiştir. Çalışmada poz tahmininin gerçekleştirilebilmesi için SVM model kullanılmıştır. Yazarlar gelecek çalışmalarda, daha fazla veri seti kullanarak tahmin uygulamalarını gerçekleştirmeyi hedeflemektedirler.

Pfister ve diğ. (2015) çalışmalarında, videolardan insan poz tahmini gerçekleştirilmiştir. Yöntem olarak, optik akış ve derin öğrenme modeli kullanılmıştır. Vücut eklemlerinin ısı haritaları oluşturulmuştur. Model, BBC Pose, ChaLearn ve

Poses in the Wild gibi veri setlerinde test edilmiş ve zor eklem pozisyonlarında yüksek doğruluklu bir tahmin sonucu elde edilmiştir.

Dib ve Charpillet (2015) RGB-D kameralar kullanarak insan vücudunun poz tahminini gerçekleştirmiştir. Sistem üç aşamadan oluşmaktadır ve gerçek zamanlı çalıştırılmaktadır. Model, HumanEva ve Qualisys veri setlerinde test edilmiş ve elde edilen sonucun diğer yöntemlere göre daha iyi performans verdiği ortaya koyulmuştur.

Belagiannis ve diğ. (2015) 3B insan poz tahmini yapabilmek için kameralar kullanmışlardır. Farklı kamera görüntüleri üzerinde problemleri ortadan kaldırmak için 3D Pictorial Structures modeli önerilmiştir. Model, HumanEva, Campus ve Shelf veri setlerinde test edilmiştir. Test sonrasındaki sonuçlar, mevcut yöntemlere göre daha iyi performans göstermiştir.

Bogo ve diğ. (2016), yaptıkları çalışmada insan vücudunun 3B olarak poz tahmini gerçekleştirmişlerdir. Kullanılan yöntemde CNN tabanlı bir model kullanmışlardır. Çalışmada, ilk olarak 2B tahmin gerçekleştirilmiş ve sonrasında bu tahmin değerlerine göre 3B tahmin gerçekleştirilmiştir. Kullanılan yöntem ile, Leeds Sports, HumanEva ve Human3.6M veri setlerinde poz doğruluğunun yüksek olduğu gösterilmiştir. Tome ve diğ. (2017), bir RGB görüntüsünden 3B insan poz tahmini gerçekleştirmişlerdir. Tahmin işlemi ilk olarak 2B olarak yapılmıştır ve 2B veriler kullanılarak 3B tahmin gerçekleştirilmiştir. Kullanılan yöntem, Human3.6M veri setinde iyi sonuçlar elde ettiği gösterilmiştir.

Moreno-Noguer (2017) bir RGB görüntü üzerinden 3B insan poz tahmini gerçekleştirmiştir. Poz tahmini için Öklid Uzaklık Matrisi (EDM) kullanılmıştır. HumanEva ve Human3.6M veri setleri üzerinde testler gerçekleştirilmiştir. Bu testler sonucunda iyi sonuçlar elde edildiği ortaya konulmuştur.

Mehta ve diğ. (2017) elde edilen görüntüler üzerinde 3B insan poz tahmini yapılmışlardır. Poz tahmini için CNN tabanlı bir yöntem kullanılmıştır. 2B pozisyonlarının tespit edilebilmesi için 2DPoseNet, 3B pozların tahmin edilebilmesi için 3DPoseNet kullanılmıştır. Model, Human3.6M veri seti üzerinde test edilmiştir. Test sonuçlarına göre tahmin işlemde iyi performans görülmüştür.

Fang ve diğ. (2018) 3B insan vücut poz tahmini gerçekleştirmişlerdir. Yöntem olarak Pose Grammar modeli geliştirilmiştir. Bu model ile 2B görüntülerden 3B görüntülere çevriminin sağlanması amaçlanmaktadır. Model, Human3.6M ve HumanEva veri

setlerinde test edilmiştir. Test sonuçlarında performansının yüksek olduğu gösterilmiştir.

Luvizon ve diğ. (2018), insan poz tahmini ile hareket tanımayı birleştiren bir çalışma gerçekleştirmişlerdir. Kullanılan yöntem ile RGB görüntülerinden 2B ve 3B poz tahmini yapılabilmektedir. Önerilen yöntem MPII, Human3.6M, Penn Action ve NTU veri setlerinde denenmiş ve elde edilen sonuçların başarılı olduğu söylenmektedir. Pavlakos ve diğ. (2018), yaptıkları çalışmada renkli bir görüntü üzerinden 3B insan poz tahminini gerçekleştirmişlerdir. Yazarlar bu çalışmada, konvolüsyonel ağların (ConvNets) yetersiz kalması durumunda daha verimli ve etkili olmasını sağlayacak bir tahmin yöntemi önermektedirler.

Pavlo ve diğ. (2019) videolar üzerinde 3B insan poz tahmini yapmışlardır. Çalışmada 2B noktalar üzerinden 3B pozlara geçiş yapılmıştır. RNN tabanlı yöntemler yerine evrişimli modeller daha performanslıdır. Son olarak model, Human3.6M ve HumanEva veri setleri üzerinde test edilmiş ve mevcut yöntemlere göre %11 daha düşük hata oranı elde edilmiştir.

2. GELİŞTİRİLEN POZ TAHMİN SİSTEMİ

Geliştirilen poz tahmin sistemi, sensörden alınan eğim verilerinin aktarılabilmesi için özel olarak tasarlanan elektronik kart, eğim verilerinden poz tahminini gerçekleştiren yapay sinir ağı tabanlı tahmin modeli ve bilgisayar arayüz ekranı bileşenlerinden oluşmaktadır. Bu bölümde, sistemi oluşturan bu bileşenler detaylı olarak açıklanacaktır.


2.1 Sistemle İlgili Temel Bilgiler

Poz tahmininin yapılabilmesi için vücut bölümlerinin eğim verilerinin alınması gerekmektedir. Bu iş için geliştirilen sensörler bulunmakta ancak bu verilerin senkronize olarak alınabilmesi için ilave donanımlara ihtiyaç duyulmaktadır. Bu veriler alındıktan sonra da işlenip değerlendirilerek poz tahmini yapılabilmesi için matematiksel modellere ihtiyaç duyulmaktadır. Bu tez çalışmasında, sözü edilen ilave donanım ihtiyacı özgün olarak tasarlanan elektronik sistem ile giderilmiştir. Poz tahmini için ihtiyaç duyulan matematiksel modelleme yerine de yapay sinir ağı tabanlı bir sistem kullanılmıştır. 2.1.1 bölümünde gömülü sistemin poz tahminindeki önemi açıklanmıştır. 2.1.2 bölümünde ise, yapay zeka ile ilgili temel bilgiler verilmiş olup çalışmaya esas teşkil eden matematiksel denklemler ve performans kriterleri de açıklanmıştır.

2.1.1 Gömülü sistem


Sensör tabanlı poz tahmin sistemlerinde sensörlerden alınan verilerin ön işlemlerden geçirilmesi, hafızada saklanması, senkron/asenkron şekilde kablolu veya kablosuz olarak gönderilmesi işlemlerine ihtiyaç duyulmaktadır (Kim, 2022; Zheng, 2018; Trumble, 2017). Verilerin alınması aşamasında her sensör verisi bir bağlantı ile bilgisayara aktarılabilir. Ancak verilerin çok olması ve bağlantı konusundaki kısıtlamalar sisteme ilave dezavantajlar getirmektedir. Bu dezavantajları ortadan kaldırmak için mikrodenetleyici tabanlı sistemler kullanılmaktadır. Bu sistemler,

sensör verilerinin alınıp ön işlenmesi ve poz tahmini sistemine aktarılması işlemlerini hızlı ve hassas bir şekilde yapabilmektedir.



Şekil 2.1 : Poz tahmin işleminde gömülü sistemin fonksiyonu.

Poz tahmin işleminde verilerin alınarak poz tahmin sistemine aktarılması aşamasında gömülü sistemin fonksiyonu Şekil 2.1’de gösterilmiştir. Şekilde, sarı kutu ile gösterilen bölüm verilerin alınmasından, ön işlenmesinden, gerekiyorsa hafızada saklanmasından ve kontrollü şekilde poz tahmin sistemine aktarılmasından sorumlu gömülü sistemi ifade etmektedir.




Şekil 2.2 : Vücut bölümlerinden verilerin gömülü sistem ile alınması.

Şekil 2.2’de poz verilerinin alınması için gömülü sistemin nasıl kullanılacağı gösterilmektedir. Şekilde, eksenel vektörlerin olduğu noktalara gömülü sistemler yerleştirilmiştir (Zheng ve diğ, 2018).

2.1.2 Yapay zeka

Yapay zeka, insan beyninin fizyolojik yapısını baz alan bir sistem dalıdır. Temel yapısı nöronlara benzetilerek oluşturulmuştur. İlk temelleri 1943 yılında bilim insanları Warren McCulloch ve Walter Pitts'in nöronların çalışma mekanizmasının matematiksel olarak ifade edilmesiyle atılmıştır. Bir diğer bilim insanı Turing, yazmış olduğu bir makalesinde bilgisayarların insanların zekasını taklit edilemeyeceğini sorgulamıştır. Bu sorgulamanın yapılabilmesi için bir yöntem önermiştir. Bu sayede, ilk yapay zeka uygulaması ortaya çıkmıştır. Teknolojinin gelişmesiyle beraber yapay zeka, başlıca matematik, mühendislik, tıp ve finans gibi alanlarda çok sık kullanılmaya başlanmıştır.

Günümüzde yapay zeka, nesnelerin interneti, veri analizi, bulut sistemleri ve yüksek hesaplama gerektiren sistemlerle birlikte çalışmaktadır. Günlük yaşamdan endüstriyel alana kadar çok geniş yelpaze de kullanılmaktadır. Birçok sektörde insan gücüne ek olarak gelişmiş yapay zeka sistemlerinin kullanılması, verimliliği arttırmakla beraber dijital dönüşümün başlamasına olanak sağlamıştır.




Şekil 2.3 : Yapay zeka alt kümeleri.

Şekil 2.3'te yapay zekanın alt kümeleri gösterilmiştir. Büyük verilerin ortaya çıkmasıyla birlikte yapay zekanın bir alt kümesi olan makine öğrenmesi kullanılmaya başlanmıştır. Makine öğrenmesi algoritmaları, elde edilen verileri işleyerek yüksek doğruluklu sonuçlar ortaya çıkarmıştır. Daha sonrasında bu bilgiler makine içerisine

yazılımsal olarak gömülmüştür. Makine öğrenmesinin de bir alt kümesi olan derin öğrenme, yapay sinir ağlarını baz almaktadır. Bu yöntem ise daha karmaşık verilerde çözüm olarak kullanılmaktadır.

2.1.2.1 Yapay sinir ağları


Yapay sinir hücreleri, insandaki sinir hücrelerine benzer yapıdadır. Yapay nöronlar giriş sinyallerini topladıktan sonra işleyerek bir çıktı oluşturmaktadır. Bir yapay sinir hücresinin yapısı, girdi, ağırlık, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktı katmanıyla birlikte toplam beş ayrı bölümden oluşmaktadır. Şekil 2.4'te bu bölümler gösterilmiştir.



Şekil 2.4 : Yapay sinir hücresi.

Girdi bölümündeki veriler, nöronlara gelen verilerden oluşmaktadır. Bu girdi verileri, sensörlerden alınan veriler veya görüntülerden elde edilen veriler olabilmektedir. Ağırlıklar ise, her bir girdinin çıktı üzerindeki etkisini göstermektedir. Toplama bölümüne gelmeden önce, her girdi kendi ağırlık katsayısı ile çarpılmaktadır. Toplama fonksiyonu bölümünde ise, ağırlıklarla çarpılan girdiler toplanarak o hücrenin toplam girdisi elde edilmektedir. Toplam girdiler, bir aktivasyon fonksiyonu kullanarak çıkışa aktarılmaktadır. Aktivasyon fonksiyonu olarak, Sigmoid, ReLU, Hyperbolic Tangent ve Leaky ReLU örnek verilebilir. Çıktı ise, aktivasyon fonksiyonundan sonra üretilen sonuçtur. Her hücrenin bir çıktı bulunmaktadır. Bu çıktıların birden fazla girdisi olabilmektedir.

Yapay sinir hücrelerinin birleşimiyle yapay sinir ağları oluşmaktadır. Sinir ağlarının yapısı üç katmandan meydana gelmektedir. Şekil 2.5'te bu yapı gösterilmektedir.



Şekil 2.5 : Çoklu gizli katmanlı yapay sinir ağı modeli.

İlk katman girdi katmanıdır. Giriş verileri bu katmana aktarılmaktadır. Bu katmanda, ağırlık değerleri girdi verileriyle çarpılmaktadır. Çıktıların doğru olabilmesi için ağırlık değerlerinin doğru seçilmesi gerekmektedir.

İkinci katman ise, gizli katman olarak adlandırılmaktadır. Bu katmanda, girdi katmanından gelen veriler toplanır ve bu verilere bias değeri eklenmektedir. Tüm hepsinin toplanması sonrasında aktivasyon fonksiyonu uygulanmaktadır ve sonrasına bir eşik değeri çıkmaktadır. Bu değer çıkış katmanına aktarılmaktadır. Gizli katman, tek katmanlı ve çok katmanlı olarak ikiye ayrılmaktadır. Tek katmanlı sinir ağı yapısı, karmaşık olmayan basit yapıları çalışmalarda sıklıkla tercih edilmektedir. Bu yapı, doğrusal olarak ayrılabilen problemlerde kullanılmaktadır. Çok katmanlı sinir ağı yapısı ise, doğrusal olmayan ve karmaşık sistemlerde kullanılmaktadır. Birden fazla ara katman bulunmaktadır.

Son katman ise, çıkış katmanı olarak adlandırılır. Bu katmanda, önceki katmanların gerçekleştirdiği durumlar sonrasında ortaya çıkan sonucun gösterilmesi gerçekleşmektedir.

2.1.2.2 Yapay sinir ağlarında eğitim işlemi

Model eğitiminde, çoklu gizli katmanlı yapı kullanılacaktır. Bu yapı genellikle lineer olmayan sistemleri çözmek için kullanılmaktadır. Gizli katman sayısının artırılması, parametre sayısının artırılmasına sebep olmaktadır ve bununla birlikte uyum kapasitesi artmaktadır. Gizli katman sayısı, probleme göre değişiklik göstermektedir.

Eşitlik 2.1’de x giriş verilerinin, w ağırlıklarla çarpılıp toplanması sonucu f giriş katmanını ifade edilmektedir.

$$f_q^t = \sum_{j=1}^n w_{qj} x_j^t \quad (2.1)$$

Eşitlik 2.2’de f giriş katmanından gelen bilginin bir s sigmoid fonksiyonundan geçirildikten sonra o katmana ait v ağırlıkları ile çarpılıp toplanması h ikinci katman çıktısı olarak ifade edilmektedir.

$$h_l^t = \sum_{q=1}^k v_{lq} s(f_q^t) \quad (2.2)$$

Eşitlik 2.3’te h ara katmandan gelen bilginin, yine aynı şekilde bir s sigmoid fonksiyonundan geçirildikten sonra çıkış katmanındaki u ağırlık değerleri ile çarpılıp toplanması y ile ifade edilmektedir. Bu sonuç, modelin tahmin ettiği değerdir.

$$\bar{y}_i^t = \sum_{l=1}^r u_{il} s(h_l^t) \quad (2.3)$$

Katmanlara ait hata değerinin hesaplanması için eşitlikler kullanılmaktadır. Bu eşitliklere ait parametrelerin, ilgili katmana ait olması gerekmektedir.

Eşitlik 2.4, çıkış katmanının hata değerini hesaplamak için kullanılır.

$$E_{it}^4 = (y_i^t - s(\bar{y}_i^t)) s'(\bar{y}_i^t) \quad (2.4)$$

- E_{it}^4 : Çıkıştaki hata değeri
- y_i^t : En son tahmin edilen değer
- s : Sigmoid fonksiyonu
- s' : Sigmoid fonksiyonunun türevi
- $\bar{y}_i^t$: Bir önceki tahmin edilen değer

Eşitlik 2.5, ikinci katmanının hata değerini hesaplama işlemini gösterir.

$$E_{lt}^3 = \left(\sum_{i=1} E_{it}^4 u_{il} \right) s'(h_l^t) \quad (2.5)$$

- E_{lt}^3 : İkinci katmandaki hata değeri
- E_{it}^4 : Çıkıştaki hata değeri
- u : Ağırlık değeri
- h : İkinci katmandaki değer

Eşitlik 2.6, birinci katmanın hata değerini hesaplamak için kullanılır.

$$E_{qt}^2 = \left(\sum_{l=1}^r E_{lt}^3 v_{lq} \right) s'(f_q^t) \quad (2.6)$$

- E_{qt}^2 : Birinci katmandaki hata değeri
- E_{lt}^3 : İkinci katmandaki hata değeri
- v : Ağırlık değeri
- f : Birinci katmandaki değer

Aşağıdaki eşitliklerin kullanılması ile ağırlık değerlerinin optimizasyonu sağlanmaktadır. Elde edilen her bir değer, bir önceki değer yerine kullanılarak hesaplamaların tekrar edilmesini gerektirmektedir. Belirlenen eşik değerine ulaşıldığında, modeldeki ağırlık değerlerinin optimum değere ulaştığı anlaşılmaktadır.

Eşitlik 2.7, çıkış katmanının yeni ağırlık değerlerinin hesaplanması için kullanılmaktadır.

$$u_{il}(yen_i) = u_{il}(eski) + \alpha \sum_{t=1}^p \left(E_{it}^4 s(h_l^t) \right) \quad (2.7)$$

- u : Ağırlık değeri
- α : Adım genişliği
- E_{it}^4 : Çıkıştaki hata değeri
- s : Sigmoid fonksiyonu

- h : İkinci katmandaki değer

Eşitlik 2.8, ikinci katmanın yeni ağırlık değerini hesaplamak için kullanılmaktadır.

$$v_{lq}(yen_i) = v_{lq}(eski) + \alpha \sum_{t=1}^p (E_{il}^3 s(f_q^t)) \quad (2.8)$$

- v : Ağırlık değeri
- α : Adım genişliği
- E_{il}^3 : İkinci katmandaki hata değeri
- f : Birinci katmandaki değer

Eşitlik 2.9, birinci katmanın yeni ağırlık değerini hesaplamak için kullanılır.

$$w_{qj}(yen_i) = w_{qj}(eski) + \alpha \sum_{t=1}^p (E_{qt}^2 x_j^t) \quad (2.9)$$

- w : Ağırlık değeri
- α : Adım genişliği
- E_{qt}^2 : Birinci katmandaki hata değeri
- x : Birinci katmandaki değer

2.1.2.3 Başarım değerlendirilmesi

Denetimli öğrenmede iki farklı model kullanılmaktadır. İlk model regresyon modeli, sonuç olarak sayısal ve sürekli bir değer döndürmektedir. Diğer model ise, sınıflandırma modelidir. Bu modelde, kategorik ve ayrık olarak bir sonuç döndürmektedir. Bu modeller, içerisinde farklı algoritmalara sahiptir. Modelin eğitilmesinden sonra ise, başarım değerlendirmesi için farklı istatistiksel ölçüler kullanılmalıdır. Bu tez çalışmasında regresyon modeli kullanılmıştır.

Regresyon modelinin değerlendirilmesinde birinci yöntem R^2 'dir. Eşitlik 2.10'da gösterilmiştir. Bu yöntem, doğrusal regresyon için yakınsallık ölçüsüdür. Doğru tahmin için, yüksek R^2 değeri gereklidir. Bu modelinin başarımını gösteren tek bir ölçüt değildir.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2.10)$$

- R^2 : Determinasyon katsayısı
- n : Toplam veri sayısı
- y_i : Gerçek değer
- $\hat{y}_i$: Tahmin edilen değer
- $\bar{y}$: Gerçek değerlerin ortalaması

Bir diğer yöntem ise ortalama mutlak hatadır. Eşitlik 2.11’de gösterilmiştir. Tahmin ile gerçek değer arasındaki farkı ifade etmektedir. Gerçek değer ile tahmin değeri arasındaki farkın mutlak değerlerinin ortalamasıdır. Bu değer ne kadar düşük ise, model başarımı o kadar yüksektir.


$$MAE = \frac{1}{n} \sum_{i=0}^n |y_i - \hat{y}_i| \quad (2.11)$$

Son yöntem ise, ortalama kare hatasıdır (Eşitlik 2.12). Gerçek değer ile tahmin edilen değeri arasındaki farkın karelerinin toplamının örnek sayısına bölünmesini ifade etmektedir. Bu değer ne kadar düşük ise, sonuç o kadar doğrudur.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.12)$$

2.2 Sistem Yapısının Aşamaları


Sistem yapısının ana aşamaları Şekil 2.6 ile gösterilmiştir. Sistem akışının ilk aşaması olan verilerin alınması ve gönderilmesi bölümünde, insan poz verilerinin IMU sensör ile mikrodenetleyici kullanılarak alınması ve bu verilerin Wi-Fi modülü ile veri tabanına kablosuz bir şekilde gönderilmesi olarak açıklanabilir. Kullanılan elektronik kartın yapıtaşları ise, elektronik komponentler, pil ve diğer mekanik parçalardır. Bu parçaların her birisinin bir görevi bulunmaktadır. Küçük alt sistemler büyük bir sistemi oluşturmaktadır.



Şekil 2.6 : Sistemin ana aşamaları.

Sistem akışının bir diğer aşaması ise, alınan verilerin işlenmesi ve yapay zeka modelinin tahmin işleminin gerçekleştirilmesidir. Bu bölümde, elektronik karttan gelen sensör verilerinin veri tabanından alınması ve sonrasında ise yapay zeka modeline girdi olarak verilmesi gerçekleştirilmektedir. Bu bölümdeki tüm süreçler, tasarlanan bir arayüz programında gerçekleştirilmektedir. Alınan sensör verileri anlık olarak arayüz programında izlenebilmektedir.

Sistem yapısının ana bileşenleri Şekil 2.7 ile görselleştirilmiştir. Sistemin ilk aşamasında, elektronik sistem insan vücudu üzerinde uygun pozisyonlara yerleştirilmektedir. Sonrasında ise, bu bölgelerden sensör verileri aktif olarak okunur ve Wi-Fi aracılığıyla veri tabanına gönderilir. Sistemin ikinci aşamasında ise, veri tabanından alınan veriler yapay zeka modeli ile işlenmektedir. Sistemin son aşamasında ise, sensör verileri veri tabanında anlık olarak alınır ve insan vücudu pozisyon bilgilerine göre bu değerler gösterilmektedir. Gösterim sonrasında ise, yapay zeka modelinin tahmin sonucunda ki değerlere göre pozisyon görseli ve sayısal değer gösterilmektedir.




Şekil 2.7 : Sistem yapısı görselleri.

2.3 Sistemin Donanımsal Yapısı


Elektronik kartı oluşturan birçok komponent bulunmaktadır. Bu komponentlerin özelliği sistemin ihtiyacına göre belirlenmiştir. Sistem tasarımı yapılırken bu komponentlerin birbirine olan etkileri de dikkate alınması gerekmektedir. Bu bölümde, elektronik kartta kullanılan komponentler açıklanacaktır.

Şekil 2.8’de tasarlanan elektronik kart ve bu kart üzerinde işaretlenmiş olan komponent ise, devrede kullanılan mikrodnetleyicidir. Mikrodnetleyiciler, işlemci, bellek, giriş-çıkış birimlerini bulunduran bir entegre devredir. Yeniden programlanabilir olması sayesinde birçok alanda kullanılabilirler. Genellikle otomotiv, ev aletleri ve tıbbi cihazlarda kullanılırlar. Bu tez çalışmasında ST firmasının üretmiş olduğu STM32G070CBT6 mikrodnetleyici kullanılmıştır. Bu mikrodnetleyici 64 Mhz saat hızı, 128 KB hafıza, 36 KB ram ve toplam 43 giriş-çıkış birimine sahiptir. 2 V ile 3.6 V arasında çalışabilmektedir. Oldukça hızlı ve güçlü bir mikrodnetleyicidir.



Şekil 2.8 : STM32G070CBT6 mikrodnetleyici.

Şekil 2.9’da işaretlenmiş olan komponent, eğim sensörüdür. Bu sensör, hassas olarak eğim ölçebilmektedir. Genellikle hava araçlarında, denge kontrol edilen ürünlerde kullanılırlar. Fiyat olarak ucuz ama oldukça güçlü bir sensördür. Sensör, 3 V ile 5 V arasında çalışabilmektedir. Ölçülen sensör değerlerini başka bir birime I2C haberleşmesi ile gönderebilmektedir. Hazır modül olarak bulunabilir. Küçük devrelerde ise direkt olarak entegre devre kullanılabilir. Bu tez çalışmasında direkt olarak entegrenin kendisi kullanılmıştır.




Şekil 2.9 : MPU6050 eğim sensörü.

Elektronik sistemde kullanılmış olan pil Şekil 2.10’da gösterilmiştir. Lityum polimer piller, yüksek enerjili şarj edilebilir bataryalardır. Taşınabilir elektronikte çok sık kullanılmaktadır. Bu tez çalışmasında 3.7 V 250 mAh değerlerine sahip Power-Xtra marka bir batarya kullanılmıştır.



Şekil 2.10 : Lipo pil.

Şekil 2.11’de işaretlenmiş olan komponent voltaj regülatörüdür. Voltaj regülatörleri, devrede girişi yüksek olan voltajları istenen seviyeye getirmekle görevlidir. Bu tez çalışmasında MCP1825ST kodlu regülatör kullanılmıştır. Devrenin voltajını 3.3 V’ta tutmakla görevlidir.




Şekil 2.13 : Direnç, led, kondansatör.

2.4 Sistemin Donanımsal Tasarımı

Sistemin donanımsal tasarımı yapılmaya başlanmadan önce devrede kullanılacak komponentlerin listesi belirlenmiştir. Bu liste genellikle devrenin ihtiyacı olan eleman sayısı kadar belirlenir ya da ileriye dönük ihtiyaç olması halinde adet miktarı fazla eklenerek bir liste çıkarılabilir. Bu bölümde, devrenin şematik tasarımındaki bağlantılar açıklanacaktır.

2.4.1 Güç devresi


Şekil 2.14’te görülen güç devresi şematiğinde J3, lipo pilin bağlanacağı ve enerjinin buradan dağılacığı bir konnektördür. Lipo pilden gelen enerjinin kısa devre olmasına karşı güvenlik amaçlı R20 sembolü sigorta bulunmaktadır. Sigortadan çıkan enerji bir anahtar ile devreye beslenip beslenmeyeceği kontrol edilmektedir. Beslemenin stabil olabilmesi için kondansatörler eklenmiştir. Devrede enerji olduğunu göstermek içinde bir led diyot eklenmiştir. TP1 ve TP2 kart üzerinde multimetre ile kolay bir şekilde voltaj ölçümü yapılabilmesi için eklenmiş padlerdir.



Şekil 2.14 : Güç devresi şematik bölümü.

2.4.2 Buton


Şekil 2.15'te verilen şematikte toplam üç adet buton kullanılmıştır. Sistemdeki geçişleri ya da belli bir görevleri gerçekleştirmek için kullanılmıştır. Buton pininin bir tanesi direkt olarak GND'ye bağlanmaktadır. Diğer pini ise mikrodnetleyici pinine gitmektedir. Mikrodnetleyici pini, dahili olarak Pull-Up (+3V3) seçilmiştir. Butona basılmadığı durumda, mikrodnetleyici pini Lojik-1 (+3V3) olarak okumaktadır. Butona basılması durumunda ise, bu pin Lojik-0 (GND) olarak okumaktadır. Bu yöntem sayesinde butona basılıp basılmadığı okunabilmektedir.



Şekil 2.15 : Buton şematik bölümü.

2.4.3 Harici pinler


Şekil 2.16'da verilen şematikte 2x5 toplam 10 pinli bir pin header kullanılmıştır. Bu headerler, bir kablounun ya da başka header grubunun birbirine bağlantısını oluşturmak için kullanılır. Bu çalışmada ise, mikrodnetleyicinin bazı pinleri bu headerlara bağlanmıştır. Tez çalışması yapılırken, bir ihtiyaç olması durumunda hızlı bir şekilde devreye alınabilmektedir. Bu pinlere mikrodnetleyicinin haberleşme pinleri bağlanmıştır. Örneğin, tez çalışmasında SD kart modülü kullanılması ihtiyacı duyulduğunda bu haberleşme pinleri ile SD kart modülü birbirine bağlanabilir ve modül kullanılabilir.



Şekil 2.16 : Harici pinler şematik bölümü.

2.4.4 Mikrodenetleyici


Şekil 2.17’de verilen şematikte mikrodenetleyici olarak ST firmasının STM32G070CBT6 kodlu ürünü kullanılmıştır. Bu mikrodenetleyici oldukça güçlü, hızlı ve ucuzdur. Besleme ve diğer modüllere giden pinler için bağlantılar yapılmıştır. MHx isimli semboller kart üzerindeki montaj delikleri olup vidalama için kullanılmaktadır. FIDx isimli semboller ise, kart üzerinde SMD dizgi yapılabilmesi için kullanılan referans padlerdir. Dizgi makineleri bu padlere göre referans alır ve ilgili koordinatlara componentleri yerleştirmektedirler.



Şekil 2.17 : Mikrodenetleyici şematik bölümü.

2.4.5 Sensör


Şekil 2.18’de verilen şematikte ivme ve gyro sensörü olarak MPU6050 kullanılmıştır. Hassas ölçüm yapabilen ve ucuz bir sensördür. Sensörün teknik dökümanında önerilen tasarıma göre bağlantı şeması oluşturulmuştur.



Şekil 2.18 : Sensör şematik bölümü.

2.4.6 Programlayıcı


Şekil 2.19’da verilen şematikte mikrodenetleyiciye program atılabilmesi için gerekli pinler gösterilmektedir. Bu pinler 1×5 headera bağlanmıştır. ST-LINK programlayıcı kabloları bu pinlere bağlanarak mikrodenetleyiciye program yüklenebilmektedir. Tez çalışmasındaki bir sistemin özelliği olan veri seti üretimi için X, Y, Z verilerinin depolandığı hafıza biriminden bu pinler ile veriler bilgisayar tarafından okunabilmektedir.



Şekil 2.19 : Programlayıcı şematik bölümü.

2.4.7 ESP8266 Wi-Fi modülü


Şekil 2.20’de verilen şematikte Wi-Fi modülünün bağlantıları gösterilmektedir. Elde edilen sensör verilerinin, veri tabanına gönderilmesi için Wi-Fi modülü kullanılmaktadır. Bu modül ESP8266’dır. Kullanımı kolay olup maliyeti düşüktür.



Şekil 2.20 : Wi-Fi modülü şematik bölümü.

2.4.8 Led


Şekil 2.21’de verilen şematikte led bağlantıları gösterilmektedir. Sistem çalışırken hangi aşamada olduğunu bilgi vermek amaçlı bu ledler kullanılmıştır. Bir ledin ilgili aşamada birden fazla görevi olabilmektedir. Ledin eksi ucu mikrodnetleyi pinine gitmektedir. Mikrodenetleyici pinine lojik-0 verildiğinde led ışık vermektedir. Lojik-1 verilmesi durumunda led sönmektedir.



Şekil 2.21 : Led şematik bölümü.

2.4.9 Baskı devre


Şekil 2.22’de verilen çizimde, elektronik kartın PCB tarafı gösterilmektedir. Şematik çizim tamamlandıktan sonra PCB çizim için ilgili araç açılmış ve şematik bilgileri buraya aktarılmıştır. Kart boyutunun belirlenmesinin ardından eleman yerleşimi yapılmıştır. Eleman yerleşimi yapılırken ürünün kendisi ve yan komponentlerinin birbirine yakın olmasına dikkat edilmiştir. Kartın seri üretimi yapılırken üretim aşamalarının kolay bir şekilde tamamlanabilmesi için üretimi zorlaştıracak yerleşimler kaçınılmıştır.



Şekil 2.22 : Tasarımın PCB bölümü.

2.4.10 Kartın 3B görünümü

Şekil 2.23'te kartın 3B görünümü gösterilmektedir. PCB çizimi bittikten sonra kontrol yapılırken 3B görünümde yapılabilmesi ve kontrol edilmesini kolaylaştırmaktadır. Kontrol dışında ise, kartın nasıl görüldüğü gösterilmekte ve isteğe göre kart renkleri de değiştirilebilmektedir.



Şekil 2.23 : Kartın 3B görünümü.


2.5 Sistemin Gömülü Yazılım Tasarımı

Sistemin gömülü yazılımı geliştirilmeye başlanırken tasarımı yapılan donanım incelenmiş ve yazılım aşamalarının ana hatları belirlenmiştir. Donanımda kullanılan komponentlerin nasıl kullanılacağı analiz edilmiştir. Sonrasında ise yazılımın geliştirileceği geliştirme ortamı belirlenmiştir. Yazılımın algoritma şeması da belirlendikten sonra sistemin yazılımı geliştirilmeye başlanmıştır. Bu bölümde, kullanılacak olan geliştirme ortamı, yazılım algoritma şeması ve sistemin yazılım akışları açıklanacaktır.

2.5.1 STM32CubeIDE

Bu tez çalışmasında geliştirilen elektronik kartın yazılımı için STM32CubeIDE geliştirme ortamı tercih edilmiştir. STM32CubeIDE programı, ST firması tarafından geliştirilen ve STM32 mikrodeneleyicileri için kullanılan bir geliştirme ortamıdır. Bu geliştirme ortamı sayesinde, STM32 mikrodeneleyicilerinin geliştirilmesi ve programlanması kolaylaştırılmıştır. Bu program aynı zamanda ST firmasının geliştirmiş olduğu diğer program Cubemx programını da kapsamaktadır. ST firması

Şekil 2.26’da sistemin algoritma şeması verilmiştir. Algoritmada sistemin durumları arasındaki geçişler, sistem aşamaları ve bunlarla ilgili akışlar gösterilmiştir. Buradaki akışların detayları bir sonraki bölümde tasarlanan elektronik kart ile ilişkili olarak açıklanacaktır.




Şekil 2.26 : Sistemin algoritma şeması.

2.5.3 Sistemin yazılım akışı

Bu bölümde, elektronik sistemin akışını oluşturan aşamalar açıklanmıştır. Elektronik sistemi oluşturan yazılımsal aşamalar görsellerle desteklenerek detaylandırılmıştır. Elektronik kart sisteminin kullanılması sürecinde, işlem aşamalarını meydana getiren fonksiyonların ve bunlara karşı oluşturulan çıktıların bilinmesi gerekmektedir.

Şekil 2.27’de sistem akışında kullanılan ledler ve butonlar numaralandırılmıştır. Bu numaralar kullanılarak sistemin mevcut durumları açıklanacaktır.



Şekil 2.27 : Sistemdeki ledler ve butonlar.

2.5.3.1 Enerjilendirme ve bilgilendirme modu

Şekil 2.28’de görülen sistem durumu kartın ilk başlama durumudur. Karta enerji verildikten sonra ilk olarak kartın etiket değeri kaç ise iki saniye boyunca bu bilgi 5-6-7-8 nolu işaretlenmiş yerdeki ledler ile gösterilmektedir. Bu ledlerin yanma durumu, etiket değerine göre değişmektedir. Sürenin sonunda bekleme moduna geçiş yapmaktadır. Kartın 9 nolu besleme ledi ise kart enerjilendiğinden itibaren yeşil renkte yanmaktadır.



Şekil 2.28 : Enerjilendirme ve bilgilendirme modu.

2.5.3.2 Bekleme modu

Şekil 2.29’da gösterilen sistem durumu kartın bekleme modudur. Bu mod, aktif olarak çalışacak fonksiyonların durdurulduğu moddur. Bekleme modunda olduğunun gösterilmesi için 1 nolu led kullanılmaktadır. Bu moddan diğer modlara geçiş butonlar kullanır. 10 nolu buton ile sistemin aktif olarak çalışacağı moda geçiş yapılır. 11 nolu buton ile sistemin etiket değeri seçim moduna geçiş yapılır. 12 no’lu buton ile veri seti oluşturma moduna geçiş yapılır.



Şekil 2.29 : Bekleme modu.

2.5.3.3 Aktif çalışma modu

Şekil 2.30’da görülen sistem modu kartın aktif çalışma modudur. 2 nolu led ile sistemin bu modda olduğu gösterilmektedir. 5 nolu led ile sensörün, 6 nolu led ile Wi-Fi modülünün aktif olduğu gösterilmektedir. 7 nolu led ile Wi-Fi verisinin gönderildiği bilgisi verilmektedir. Wi-Fi modülü ile bağlantı kurulamaması durumunda, sistem hata moduna geçiş yapar. 11 nolu butona basıldığında Wi-Fi modülü resetlenir ve tekrar bağlantı kurup akışa devam etmesi sağlanmaktadır. 10 nolu buton ile idle moduna geçiş yapılabilir.



Şekil 2.30 : Aktif çalışma modu.

2.5.3.4 Etiket değeri seçim modu

Şekil 2.31’de görülen sistem modu kartın etiket değeri seçim modudur. Bu modda, elektronik cihazın insan vücudu üzerinde hangi pozisyona yerleştirileceği seçilmektedir. 3 nolu led ile sistemin bu modda olduğu gösterilmektedir. 5-6-7-8 nolu ledler ile etiket değeri gösterilmektedir. 10 nolu buton ile bu numaranın etiket değeri arttırılmaktadır. 12 nolu buton ile etiket değeri azaltılmaktadır. 11 nolu buton ile etiket değeri onaylanır ve hafızaya kaydedilir.



Şekil 2.31 : Etiket değeri seçim modu.

2.5.3.5 Veri seti oluşturma modu

Bu mod, veri seti oluşturmak için geliştirilmiş olup beş farklı süreçten oluşmaktadır. Bu süreçlerin her birisi ledler ile gösterilmektedir. Şekil 2.32’de görülen aşama hazırlık sürecini göstermekte ve bu aşamada herhangi bir işlem yapılmamaktadır. 30 saniye boyunca sistem hazırlık için beklemektedir. Süre sonunda sistem otomatik olarak diğer aşamaya geçmektedir. Veri seti oluşturma modunun aktif olduğunun gösterilmesi için 5-6-7-8 nolu ledler sürekli bir şekilde yanmaktadır. Hazırlık aşamasında olduğunun gösterilmesi için de 1-2-3-4 nolu ledler yanmamaktadır.



Şekil 2.32 : Veri seti oluşturma modu.

Şekil 2.33'te görülen aşama örnekleme sürecidir. Bu aşamada, X, Y ve Z sensör verilerinden 1.000'er adet örnek alınmaktadır. Her örnek 200 ms'de bir alınmaktadır. Bu örnekleme süreci toplam 200 saniye sürmektedir. Örnekleme işlemi yapılırken, ilgili pozisyon için vücut hareket ettirilebilir. Örnekleme işlemi tamamlandıktan sonra otomatik olarak sonraki aşamaya geçilmektedir. 1 nolu led, örnekleme aşamasını göstermektedir.



Şekil 2.33 : Veri seti oluşturma modunda verinin örneklenmesi.

Şekil 2.34'te görülen aşama verileri kaydetme ve bekleme aşamasıdır. Örnekleme aşaması tamamlandıktan sonra veriler otomatik olarak mikrodenetleyicinin hafızasına kaydedilmektedir. Bu işlem tamamlandıktan sonra bekleme aşamasına geçilir. Bu aşamada 11 nolu butona basılması beklenir. Butona basıldıktan sonra sistem bekleme moduna geri dönmektedir. 4 nolu led ile bu aşama gösterilmektedir. Verilerin mikrodenetleyicinin hafızasında ilgili adreslere birbirleriyle karışmadan kaydedilmektedir. Bu hafızadaki veriler bir yazılım sayesinde kolayca erişilebilmektedir.



Şekil 2.34 : Veri seti oluşturma modunun tamamlanması.

2.6 Sistemin Yapay Zeka Tasarımı

Yapay zeka modelinin eğitilebilmesi için kullanılacak olan veri setleri tasarlanmış olan gömülü sistem ile üretilmiştir. Bu elektronik sistem ile veri setinin üretilmesi 2.5 Sistemin Gömülü Yazılım Tasarımı bölümünde açıklanmıştır. Yapay zeka modelinin eğitilmesi için Matlab programının yapay zeka çalışmaları için oluşturduğu araçlar kullanılmıştır. Eğitim işlemi tamamlandıktan sonra yapay zeka modeli, tasarlanmış olan arayüz programı bölümüne eklenerek çalışması sağlanmıştır. Tasarlanmış olan elektronik sistemler, vücudun ilgili bölümlerine konumlandırılarak her bir poz için 200 sn boyunca veri alınarak mikrodenetleyicinin hafızasına kaydedilip sonrasında bilgisayar ortamına aktararak veri seti oluşturma aşaması tamamlanmıştır. Veri setinin kullanılacak olan yapay zeka modelinin girdi ve çıktılarına uygun olarak şekillendirilmesi ve eğitilmesi aşamaları aşağıda açıklanmıştır.

2.6.1 Veri setinin uygun duruma getirilmesi

Gömülü sistem tasarımında veri seti üretimi için özel bir yazılım geliştirilmiştir. Belirli bir süre örnekleme işlemi yapıldıktan sonra alınan bu veriler kullanılan mikrodenetleyicinin hafızasına kaydedilmektedir. Kaydedilen verilerin, yapay zeka modelinin eğitiminde kullanılabilmesi için birkaç işlemden geçirilerek hazır duruma getirilmesi gerekmektedir. Şekil 2.35'te veri setlerinin anlamlandırma akış şeması gösterilmiştir.



Şekil 2.35 : Veri seti anlamlandırma akış şeması.

İlk adım olan verilerin okunması aşamasında, mikrodnetleyiciye yazılım yükleme ya da mikrodnetleyicideki yazılımın okuma işlemlerinin yapıldığı ST-Link Utility programı kullanılarak mikrodnetleyicinin hafızasına erişim sağlanmaktadır. Erişim sağlandıktan sonra örneklenmiş sensör verilerinin bulunduğu hafıza alanından veriler kopyalanarak özel olarak hazırlanmış excel dosyası içerisine eklenmektedir. Şekil 2.36’da hafızaya erişim sonrası örneklenmiş veriler gösterilmiştir.

Address	0	4	8	C	ASCII
0x00000000	00001154	00000000	00001164	00000000	
0x00000010	0000115E	00000000	00001158	00000000	
0x00000020	00000B33	00000000	00000B45	00000000	
0x00000030	00000C0D	00000000	00000C0E	00000000	
0x00000040	00000C19	00000000	00000C17	00000000	
0x00000050	00000C16	00000000	00000B19	00000000	
0x00000060	00000C14	00000000	00000B49	00000000	
0x00000070	00000B58	00000000	00000B5C	00000000	
0x00000080	00000B5F	00000000	00000B55	00000000	
0x00000090	00000B47	00000000	00000B38	00000000	
0x000000A0	00000FE4	00000000	00000FF1	00000000	
0x000000B0	00000FF5	00000000	00000FE0	00000000	
0x000000C0	00000FDD	00000000	00000B4E	00000000	
0x000000D0	00000D91	00000000	00000B6C	00000000	
0x000000E0	00000D99	00000000	00000D91	00000000	
0x000000F0	00000D94	00000000	00001165	00000000	
0x00000100	00001159	00000000	00001171	00000000	
0x00000110	00001155	00000000	00001163	00000000	
0x00000120	0000116A	00000000	00000B3E	00000000	
0x00000130	00000B29	00000000	00000B4A	00000000	
0x00000140	00000B4C	00000000	00000B48	00000000	
0x00000150	00000B48	00000000	00000B24	00000000	
0x00000160	00000E49	00000000	00000F55	00000000	
0x00000170	00000B35	00000000	00000B44	00000000	
0x00000180	00000B4E	00000000	00000C56	00000000	

Şekil 2.36 : Mikrodnetleyici hafızasına erişim.

İkinci adımda ise, Excel tablosuna kaydedilen bu verilerin, 16’lık sayı sisteminden 10’luk sayı sistemine çevrilmesi için programın mevcut araçları kullanılmıştır. Böylece bu sayılar orijinal değerlerine getirilmektedir. Şekil 2.37’de sayı dönüşümünün gerçekleştirilmiş durumu gösterilmiştir.

	A	B	C	D	E	F	G	H	I	J
1	M1-A		M1-B			ALL			HEX2DEC	
2	00001164		00001164			00001164			=HEX2DEC(F2)	
3	0000115E		00001158			0000115E			(HEX2DEC(sayı))	
4	00000B33		00000B45			00000B33			2867	
5	00000C0D		00000C0E			00000C0D			3085	
6	00000C19		00000C17			00000C19			3097	
7	00000C16		00000B19			00000C16			3094	
8	00000C14		00000B49			00000C14			3092	
9	00000B58		00000B5C			00000B58			2907	
10	00000B5F		00000B65			00000B5F			2911	
11	00000B47		00000B50			00000B47			2887	
12	00000FE4		00000FF1			00000FE4			4068	
13	00000FF5		00000FE0			00000FF5			4085	
14	00000FDD		00000B4E			00000FDD			4061	
15	00000D91		00000D8C			00000D91			3473	
16	00000D99		00000D91			00000D99			3481	
17	00000D94		00001165			00000D94			3476	
18	00001169		00001171			00001169			4457	

Şekil 2.37 : Sayı çevrim işlemi.

Çevrim işlemi tamamlandıktan sonra bu sayılardan offset değeri olarak 5.000 değeri çıkarılması gerekmektedir. Bunun sebebi ise sensörlerden negatif değerler geldiği için hafızaya olduğu şekliyle kaydedilememesidir. Bu problemi çözebilmek için elektronik sistemde bu veriler pozitif bir offset değeri ile toplanmaktadır. Excel tablosu üzerinde ise bu offset değerleri çıkarılarak sensörün gerçek değerine ulaşılmaktadır. Şekil 2.38’de offset değerinin çıkarılmış durumu gösterilmiştir.

Hizalama				Sayı	Stiller	Hücreler					
E	F	G	H	I	J	K	L	M	N	O	P
	ALL			HEX2DEC			VALUE(X)				OFFSET
	00001164			4452			=I2:I2001-P2				5000
	0000115E			4446			-554				
	00000B33			2867			-2133				
	00000C0D			3085			-1915				
	00000C19			3097			-1903				
	00000C16			3094			-1906				
	00000C14			3092			-1908				
	00000B58			2907			-2093				
	00000B5F			2911			-2089				
	00000B47			2887			-2113				
	00000FE4			4068			-932				
	00000FF5			4085			-915				
	00000FDD			4061			-939				
	00000D91			3473			-1527				
	00000D99			3481			-1519				
	00000D94			3476			-1524				
	00001169			4457			-543				
	00001165			4453			-547				
	0000116A			4458			-542				
	00000B28			2859			-2141				
	00000E4C			3660			-1340				
	00000E40			3648			-1352				
	00000E49			3657			-1343				
	00000E55			3669			-1331				
	nnnnnnfAF			3662			-1338				

Şekil 2.38 : Offset çıkarma işlemi.

Son aşamada ise belirli işlemlerden geçmiş sensör verilerinin Matlab programında anlaşılabilir olması için bir düzen uygulanarak dosya formatında kaydedilmektedir. Sensör verileri girdi ve poz değerleri ise çıktı olarak oluşturulmaktadır. Sensör verilerinin son aşaması Şekil 2.39’da gösterilmiştir.

1	A	B	C	D	E	F	G	H	I	J	K	L	M	N
2	-5000	-5000	-700	-740	-739	-704	-715	-711	-707	-689	-700	-681	-676	-70
3	-482	-491	-495	-489	-489	-483	-488	-488	-471	-478	-531	-481	-480	-48
4	390	384	167	170	170	174	169	172	177	174	176	175	175	172
5	-5000	-5000	-744	-742	-733	-754	-755	-741	-5000	46	66	58	69	63
6	-637	-638	-636	-631	-633	-631	-627	-628	-2235	-2225	-2225	-2228	-2232	-223
7	277	273	56	58	63	64	64	64	66	68	69	68	65	65
8	-5000	-5000	-609	-613	-621	-610	-614	-613	-618	-623	-624	-619	-619	-61
9	-626	-628	-629	-625	-627	-632	-635	-640	-640	-644	-640	-644	-640	-63
10	263	271	52	52	51	51	40	40	43	38	41	42	40	37
11	-5000	-5000	-704	-688	-705	-717	-731	-725	-712	-721	-715	-703	-709	-70
12	-636	-640	-642	-637	-645	-653	-645	-645	-647	-645	-641	-644	-646	-64
13	266	267	44	50	47	50	44	49	47	48	46	45	47	50
14	-5000	-5000	-983	-982	-977	-977	-983	-979	-975	-975	-977	-972	-971	-98
15	-699	-701	-687	-693	-690	-693	-690	-692	-694	-696	-693	-696	-695	-69
16	204	221	15	20	24	7	18	18	14	11	11	6	8	12
17	-5000	-5000	-5000	-263	-266	-258	-267	-272	-313	-253	-302	-274	-292	-27
18	-765	-747	-2335	-739	-740	-739	-737	-742	-740	-749	-741	-748	-749	-75
19	181	183	-59	-39	-47	-44	-51	-46	-38	-49	-41	-53	-51	-53
20	-5000	-5000	-856	-856	-863	-859	-859	-863	-863	-856	-857	-857	-857	-86
21	-909	-909	-906	-907	-911	-905	-911	-910	-912	-911	-908	-911	-913	-91
22	13	15	-191	-197	-195	-195	-201	-195	-199	-195	-201	-201	-194	-19

Şekil 2.39 : Sensör verilerinin son hali.


Poz verilerinin son aşaması Şekil 2.40'ta gösterilmiştir.

BXU	BXV	BXW	BXX	BXY	BXZ	BYA	BYB	BYC	BYD	BYE	BYF
1	1	1	1	2	2	2	2	2	2	2	2

Şekil 2.40 : Poz verilerinin son hali.


2.6.2 Yapay sinir ağı modeli aracının çalıştırılması

Veri setlerini oluşturduktan sonra modelin eğitimi için Matlab konsol ekranında nnstart yazılarak model araç açılmaktadır. Import butonu ile oluşturulan veri setleri çalışmaya dahil edilmektedir. Bu veri setlerinin %70'i eğitim verisi olarak kullanılmıştır. Kalan %15'i validasyon ve %15'i ise test için kullanılmıştır. Katman sayısı olarak örnek üzerinde 20 değeri girilmiştir. Bu hazırlıklar tamamlandıktan sonra train butonuna basılarak model eğitim işlemi başlatılmaktadır. Şekil 2.41'de bu aracın ekranı gösterilmektedir.



Şekil 2.41 : Matlab yapay sinir ağı aracı eğitim öncesi.

Model eğitme işlemi tamamlandıktan sonra eğitimle ilgili bilgiler ekranda gösterilmektedir. Bu bilgiler sonraki aşamada anlatılacaktır. Şekil 2.42'de eğitimin tamamlandığı durum gösterilmiştir.




Şekil 2.42 : Yapay sinir ağı aracı ile eğitimin tamamlanması.

Tasarlanan yapay sinir ağı üç gizli katmandan oluşmaktadır. Bu katmanlardaki nöron sayıları değiştirilerek elde edilen sonuçlar Çizelge 2.1’de gösterilmiştir. Modelin başarımlı değerlendirilmesi için performans değeri incelenmiştir. Performans değerlerine bakıldığında başarılı olan modelin $2,77 \times 10^{-14}$ değeri üreten 8 nolu model olduğu görülmektedir. Performans değerlendirilmesi MSE yöntemine göre yapılmıştır.

Çizelge 2.1 : Matlab yapay sinir ağı aracı eğitim sonrası performans sonuçları.

Model No	Katman-1	Katman-2	Katman-3	Fonksiyon	Performans
1	20	40	10	Purelin	0.311
2	20	40	10	Tansig	$1,09 \times 10^{-11}$
3	20	40	20	Purelin	0.308
4	20	40	20	Tansig	$1,34 \times 10^{-11}$
5	30	40	10	Purelin	0.309
6	30	40	10	Tansig	$2,33 \times 10^{-11}$
7	30	40	20	Purelin	0.317
8	30	40	20	Tansig	$2,77 \times 10^{-14}$
9	40	40	10	Purelin	0.316
10	40	40	10	Tansig	$3,73 \times 10^{-12}$
11	40	40	20	Purelin	0.309
12	40	40	20	Tansig	$1,643 \times 10^{-11}$



Şekil 2.43 : Yapay sinir ağı modelinin yapısı.

Eğitilen modelin iç yapısı Şekil 2.43’te verilmiştir. Katmanlardaki nöron sayılarının değiştirilmesiyle elde edilen performans değerleri Çizelge 2.1’de verilmiştir.


2.7 Sistemin Arayüz Tasarımı

Arayüz programları yazılım geliştirme süreçlerinde çeşitli avantajlar sağlamaktadır. Modülerlik ve kullanım kolaylığı sayesinde kullanımı oldukça fazladır. Birden fazla sistemin kolay bir şekilde yönetilmesine olanak sağlamaktadır. Bu bölümde, elektronik sistemle birlikte senkronize olarak çalışacak olan arayüz programının detayları açıklanacaktır.

2.7.1 ThingSpeak platformu

MathWorks firması tarafından geliştirilen bu platform bulut tabanlı veri toplama, depolama ve görsel sonuçlar sunmaktadır. Daha çok nesnelerin interneti projelerinde kullanılan bu platform için akıllı ev sistemleri, akıllı sulama sistemleri gibi örnekler verilebilir. Bu platform, verilerin gerçek zamanlı analiz edilmesine de olanak sağlamaktadır.

Şekil 2.44'te tez çalışmasında kullanılan elektronik ürünün yolladığı sensör verilerinin grafikleri bulunmaktadır. Bu sensör verileri bulut üzerinde depolanabilmektedir.




Şekil 2.44 : ThingSpeak platformuna ait arayüz.

2.7.2 Matlab app designer

MATLAB app designer, MATLAB yazılımı içerisinde bulunan bir uygulama geliştirme aracıdır. Bu araç sayesinde kolay bir şekilde grafiksel kullanıcı arayüzü oluşturulabilmektedir. Bu tez çalışmasında, ThingSpeak üzerinden sensör verileri alınarak yapay zeka modeli çalıştırılmaktadır. Yapay zeka modelinin tahmin sonuçları görsel bir şekilde bir arayüz programı ile gösterilmektedir. Arayüz tasarımı MATLAB

app designer ile yapılmıştır. Bu arayüz programında sensör verileri aktif olarak izlenebilmektedir.

Şekil 2.45'te MATLAB app designer aracı gösterilmektedir. Sahip olduğu araçların kullanılması oldukça kolay ve pratiktir.




Şekil 2.45 : MATLAB app designer.

2.7.3 Arayüz yazılımı

Sensör verileri elektronik cihaz kullanılarak Wi-Fi modülüyle ThingSpeak platformuna gönderilmektedir. Bu platformda her sensör için ayrı kanallar oluşturulmuştur. Bu sayede veriler birbirine karışmamaktadır. Veritabanının özelliğinden dolayı en son gelen veriler kayıt alınmaktadır. Arayüz programının kullanılmasının amacı arka planda tüm analizlerin yapılması ve bu analiz sonuçlarının da görsel olarak gösterilmesidir.

Vücut üzerindeki bölgeler ve etiket numaraları arayüz programı üzerinden görülebilmekte ve hangi elektronik cihazın veri gönderdiği izlenebilmektedir. Arayüz programı üzerinde bir buton bulunmaktadır. Yapay zeka modelinin tahmin etme işlemini gerçekleştirmesi için bu butona basılması gerekmektedir. Sistemin sürekli bir şekilde çalışması ve arka planda sistem akışının meşgul edilmemesi hedeflenmektedir.


Şekil 2.46'da arayüz yazılımının akışı verilmiştir. Oldukça basit ve hızlı bir çıktı vermektedir.



Şekil 2.46 : Arayüz yazılım akışı.

Şekil 2.47’de arayüz yazılımının son durumu verilmiştir. Uygulama çalıştırıldığında aktif olarak çalışacak bölüm bu kısımdır. Uygulamanın sol tarafında vücut üzerinde hangi bölgelerde cihazların olacağını ve cihazların etiket numaraları yer almaktadır. Arayüzde X, Y ve Z sensör verileri veritabanından alınarak ilgili kutucuklara yazılmaktadır. Uygulamanın sağ tarafında ise yapay zeka modelini çalıştıran bir buton ve sistem çalışırken hangi aşamada olduğunu bildiren bir yazı bulunmaktadır. Sonuç olarak ise modelin tahmin ettiği poz değeri ve bu poz değerinin görseli ekranda

gösterilmektedir. Verilerin izlenebilmesi ve bu verilere göre yapay zeka modelinin çalışması kolaylıkla gerçekleştirilebilmektedir.




Şekil 2.47 : Arayüz programı.

3. SONUÇ

Bu tez çalışmasında, IMU sensörleri kullanılarak yapay sinir ağı tabanlı bir model ile 3B insan poz tahmini çalışması gerçekleştirilmiştir. Toplamda 10 adet poz görüntüsü üzerine model eğitilmiştir. Model eğitimi sürecinde her poz için 30.000 veri seti, toplamda 300.000 veri seti kullanılmıştır. Kullanılan veri setleri tamamen özgün olarak üretilmiştir. Veri seti üretimi için özgün olarak tasarlanan elektronik sistem kullanılmıştır. Gerçek zamanlı olarak sensör verilerinin gönderilmesi için elektronik sistem üzerinde Wi-Fi modülü kullanılmıştır. Bu modül sayesinde sensör verileri kablosuz olarak ThingSpeak platformuna gönderilmektedir.

Yapay zeka modeli olarak 4 katmanlı bir yapay sinir ağı kullanılmıştır. Üretilen veri setleri ile eğitilen model, doğruluğu %90 olarak yüksek tahminler gerçekleştirebilmektedir. Katmanlardaki nöron sayıları sırayla 30, 40 ve 20 olarak oluşturulmuştur. Model eğitimi için Matlab programının yapay sinir ağı eğitim fonksiyon ve araçları kullanılmıştır. Tasarlanan arayüz programı, veritabanından sensör verilerini aldıktan sonra eğitilmiş modele girdi olarak vermektedir. İlgili pozun tahmin edilen görseli ekranda avatar olarak gösterilmektedir.

Model eğitimi tamamlandıktan sonra gerçek zamanlı olarak test işlemi de tamamlanmıştır. Toplam 10 poz için ölçümler alınarak sonuçlar tahmin ettirilmiştir. Sonuç değerleri en yakın sayıya yuvarlanarak tam sayı değeri alınmaktadır. Sonuçtaki sayısal değeri poz numarası ile eşleşmektedir. 10 poz verisinden 9'u başarılı şekilde tahmin ettirilmiştir. Sadece 10 numaralı poz hatalı olarak tahmin edilmiştir. Sonuç değerine bakıldığında bu değer ortada bir değer olduğu görülmektedir. Tahmin sonuçları Şekil 3.1'de mavi renkli görseller ile temsil edilmiştir. Sonuçlara göre tasarlanan sistemin tahmin işlemini başarılı şekilde gerçekleştirdiği gösterilmiştir. Sistemde kullanılan bileşenlerin özgün olarak tasarlanması benzer çalışmalara göre özgünlük ve yenilik katmaktadır. Tasarlanan sistemin daha başarılı olabilmesi için tekrar veri setleri üretilmeli ve model eğitimi tekrarlanmalı veya daha farklı yapay zeka modelleri denenmelidir.



Şekil 3.1 : Tahmin çıktıları.

4. TARTIŞMA

Sanal dünya ile gerçek dünya arasında bağlantı sağlamanın bir basamağının gerçekleştirilmesinin hedeflendiği bu tez çalışmasında, 3B insan poz tahmini yapılabilmesi için IMU sensörler ve yapay sinir ağı tabanlı bir model kullanılmıştır. Yapay sinir ağı modelinin eğitilmesi sürecinde ara katman sayısının üç olması ve katmanlardaki nöron sayılarının değiştirilerek en iyi sonucu veren modelin, tahmin modeli olarak kullanılması hedeflenmiştir. Yapay sinir ağı modeli eğitiminde, çıkış katmanında iki adet transfer fonksiyonu test edilmiştir. Tansig transfer fonksiyonunun Purelin transfer fonksiyonuna göre bu problemin çözümünde daha uygun olduğu görülmüştür.

Poz verilerinin alınması için tasarlanan elektronik sistemde, sensör verilerinin okunması, sensör verilerinin Wi-Fi modülüyle veritabanına gönderilmesi, veri seti üretilmesi gibi işlemler başarıyla gerçekleştirilmiştir. Elektronik sistem bir batarya ile çalışmaktadır. Bataryanın kapasitesi test süreçleri için yeterli olmakla birlikte, bataryanın şarj işlemi bataryanın bulunduğu plastik parçanın elektronik sistemden sökülüp harici bir devreye bağlanmasıyla gerçekleştirilmektedir. Şarj sürecinin iyileştirilebilmesi için, elektronik sistem üzerine batarya şarj edici devre eklenebilir. Böylece elektronik sistemde tak-çıkart yapılmadan bataryanın şarj edilmesi sağlanabilecektir.

Veri seti üretimi, tasarlanan elektronik sistem ile gerçekleştirilmektedir. Veri setleri kullanılan mikrodenetleyicinin hafızasına kaydedilmektedir. Sonrasında ise bu veriler bilgisayar programı ile bağlantı kurularak alınır ve veri dönüşümü yapıldıktan sonra sensör verilerine çevrilmiş olur. Bu yöntem de verimli bir yöntemdir ancak yöntemin iyileştirilmesi ve daha hızlı olabilmesi için bu verilerin kablosuz şekilde bilgisayar ortamına gönderilmesi daha pratik olacaktır. Diğer bir yöntem ise elektronik sistem üzerinde hafıza kartı modülünün kullanılması olabilir. Böylece sensör verileri hafıza kartına kaydedilir ve hızlı bir şekilde bilgisayar ortamına aktarılabilir.

Poz tahmini gerçek zamanlı olarak gerçekleştirilirken, sensör verilerinin yapay zeka modeline gönderilmesi için Wi-Fi modülü kullanılmaktadır. Tez çalışmasında, sensör

verileri sađlıklı bir řekilde kablosuz olarak modele g nderilmiř ve poz tahmini gerekleřtirilebilmiřtir. Bununla birlikte, Wi-Fi mod l n n kablosuz ađa bađlanması ve veri g ndermesi zaman alan bir iřlemdir. Bu mod l yerine daha hızlı haberleřme sađlayacak mod ller tercih edilebilir.

Poz tahmini iřleminin gerekleřtirilebilmesi iin yapay zeka modelinin bilgisayar tabanlı bir ortamda gerekleřtirilmesi gerekmektedir. Sens r verilerinin elde edilmesinden sonra tahmin sistemine g nderilmesi iin geen s renin uzun olduđu g zlemlenmiřtir. Model eđitimi tamamlandıktan sonra tahmin modeli elektronik sistem ierisine entegre edilebilirse sistem daha hızlı ve efektif alıřabilecektir.



KAYNAKLAR

- Ababsa, F., Hadj-Abdelkader, H., & Boui, M.** (2020). 3d human pose estimation with a catadioptric sensor in unconstrained environments using an annealed particle filter, *Sensors*, 20(23), 6985.
- Andriluka, M., Roth, S., & Schiele, B.** (2010). Monocular 3d pose estimation and tracking by detection, *In 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, (pp. 623-630). IEEE.
- Baldi, T. L., Farina, F., Garulli, A., Giannitrapani, A., & Prattichizzo, D.** (2019). Upper body pose estimation using wearable inertial sensors and multiplicative kalman filter, *IEEE Sensors Journal*, 20(1), 492-500.
- Bao, Y., Zhao, X., & Qian, D.** (2022). FusePose: IMU-vision sensor fusion in kinematic space for parametric human pose estimation, *IEEE Transactions on Multimedia*, 25, 7736-7746.
- Belagiannis, V., Amin, S., Andriluka, M., Schiele, B., Navab, N., & Ilic, S.** (2015). 3d pictorial structures revisited: Multiple human pose estimation, *IEEE transactions on pattern analysis and machine intelligence*, 38(10), 1929-1942.
- Bogo, F., Kanazawa, A., Lassner, C., Gehler, P., Romero, J., & Black, M. J.** (2016). Keep it SMPL: Automatic estimation of 3D human pose and shape from a single image, *In Computer Vision–ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11-14, 2016, Proceedings, Part V 14*, (pp. 561-578). Springer International Publishing.
- Butt, H. T., Taetz, B., Musahl, M., Sanchez, M. A., Murthy, P., & Stricker, D.** (2021). Magnetometer robust deep human pose regression with uncertainty prediction using sparse body worn magnetic inertial measurement units, *IEEE Access*, 9, 36657-36673.
- Chan, T. K., Yu, Y. K., Kam, H. C., & Wong, K. H.** (2018). Robust hand gesture input using computer vision, inertial measurement unit (IMU) and flex sensors, *In 2018 IEEE International Conference on Mechatronics, Robotics and Automation (ICMRA)*, (pp. 95-99). IEEE.
- Chen, Y. L., Yang, I. J., Fu, L. C., Lai, J. S., Liang, H. W., & Lu, L.** (2021). IMU-based estimation of lower limb motion trajectory with graph convolution network, *IEEE Sensors Journal*, 21(21), 24549-24557.
- Dahiya, A., Wadhwa, D., Katti, R., & Occhipinti, L. G.** (2024). Efficient hand gesture recognition using artificial intelligence and IMU based wearable device, *IEEE Sensors Letters*.
- Dib, A., & Charpillet, F.** (2015). Pose estimation for a partially observable human body from RGB-D cameras, *In 2015 IEEE/RSJ International*

- Conference on Intelligent Robots and Systems (IROS)*, (pp. 4915-4922). IEEE.
- Fang, H. S., Xu, Y., Wang, W., Liu, X., & Zhu, S. C.** (2018). Learning pose grammar to encode human body configuration for 3d pose estimation, *In Proceedings of the AAAI conference on artificial intelligence*, (Vol. 32, No. 1).
- Huang, F., Zeng, A., Liu, M., Lai, Q., & Xu, Q.** (2020). DeepFuse: An IMU-aware network for real-time 3D human pose estimation from multi-view image, *In Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*, (pp. 429-438).
- Kim, M., & Lee, S.** (2022). Fusion poser: 3D human pose estimation using sparse IMUs and head trackers in real time, *Sensors*, 22(13), 4846.
- Konak, O., Wegner, P., & Arnrich, B.** (2020). IMU-based movement trajectory heatmaps for human activity recognition, *Sensors*, 20(24), 7179.
- Luvizon, D. C., Picard, D., & Tabia, H.** (2018). 2d/3d pose estimation and action recognition using multitask deep learning, *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, (pp. 5137-5146).
- Malleson, C., Collomosse, J., & Hilton, A.** (2020). Real-time multi-person motion capture from multi-view video and IMUs, *International Journal of Computer Vision*, 128(6), 1594-1611.
- Malleson, C., Gilbert, A., Trumble, M., Collomosse, J., Hilton, A., & Volino, M.** (2017). Real-time full-body motion capture from video and imus, *In 2017 International Conference on 3D Vision (3DV)*, (pp. 449-457). IEEE.
- Mehta, D., Rhodin, H., Casas, D., Fua, P., Sotnychenko, O., Xu, W., & Theobalt, C.** (2017). Monocular 3d human pose estimation in the wild using improved cnn supervision, *In 2017 international conference on 3D vision (3DV)*, (pp. 506-516). IEEE.
- Moreno-Noguer, F.** (2017). 3d human pose estimation from a single image via distance matrix regression, *In Proceedings of the IEEE conference on computer vision and pattern recognition*, (pp. 2823-2832).
- Ogata, K., Tanaka, H., & Matsumoto, Y.** (2021). Simple three-dimensional motion measurement system using marker-IMU system, *In 2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, (pp. 7073-7076). IEEE.
- Palermo, M., Moccia, S., Migliorelli, L., Frontoni, E., & Santos, C. P.** (2021). Real-time human pose estimation on a smart walker using convolutional neural networks, *Expert Systems with Applications*, 184, 115498.
- Pascual-Hernández, D., de Frutos, N. O., Mora-Jiménez, I., & Canas-Plaza, J. M.** (2022). Efficient 3D human pose estimation from RGBD sensors, *Displays*, 74, 102225.
- Pathirana, P. N., Karunarathne, M. S., Williams, G. L., Nam, P. T., & Durrant-Whyte, H.** (2018). Robust and accurate capture of human joint pose

using an inertial sensor, *IEEE journal of translational engineering in health and medicine*, 6, 1-11.

- Patil, A. K., Balasubramanyam, A., Ryu, J. Y., Chakravarthi, B., & Chai, Y. H.** (2021). An open-source platform for human pose estimation and tracking using a heterogeneous multi-sensor system, *Sensors*, 21(7), 2340.
- Pavlakos, G., Zhu, L., Zhou, X., & Daniilidis, K.** (2018). Learning to estimate 3D human pose and shape from a single color image, *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, (pp. 459-468).
- Pavlo, D., Feichtenhofer, C., Grangier, D., & Auli, M.** (2019). 3d human pose estimation in video with temporal convolutions and semi-supervised training, *In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, (pp. 7753-7762).
- Pfister, T., Charles, J., & Zisserman, A.** (2015). Flowing convnets for human pose estimation in videos, *In Proceedings of the IEEE international conference on computer vision*, (pp. 1913-1921).
- Pons-Moll, G., Fleet, D. J., & Rosenhahn, B.** (2014). Posebits for monocular human pose estimation, *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, (pp. 2337-2344).
- Rohan, A., Rabah, M., Hosny, T., & Kim, S. H.** (2020). Human pose estimation-based real-time gait analysis using convolutional neural network, *IEEE access*, 8, 191542-191550.
- Tome, D., Russell, C., & Agapito, L.** (2017). Lifting from the deep: Convolutional 3d pose estimation from a single image, *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, (pp. 2500-2509).
- Trumble, M., Gilbert, A., Malleon, C., Hilton, A., & Collomosse, J. P.** (2017). Total capture: 3D human pose estimation fusing video and inertial sensors, *In BMVC*, (Vol. 2, No. 5, pp. 1-13).
- Von Marcard, T., Henschel, R., Black, M. J., Rosenhahn, B., & Pons-Moll, G.** (2018). Recovering accurate 3d human pose in the wild using imus and a moving camera, *In Proceedings of the European conference on computer vision (ECCV)*, (pp. 601-617).
- Von Marcard, T., Pons-Moll, G., & Rosenhahn, B.** (2016). Human pose estimation from video and imus, *IEEE transactions on pattern analysis and machine intelligence*, 38(8), 1533-1547.
- Vu, L. C., & You, B. J.** (2019). Hand pose detection in hmd environments by sensor fusion using multi-layer perceptron, *In 2019 International Conference on Artificial Intelligence in Information and Communication (ICAIC)*, (pp. 218-223). IEEE.
- Zhang, Z., Wang, C., Qin, W., & Zeng, W.** (2020). Fusing wearable imus with multi-view images for human pose estimation: A geometric approach, *In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, (pp. 2200-2209).

- Zheng, Z., Yu, T., Li, H., Guo, K., Dai, Q., Fang, L., & Liu, Y.** (2018). Hybridfusion: Real-time performance capture using a single depth sensor and sparse imus, *In Proceedings of the European Conference on Computer Vision (ECCV)*, (pp. 384-400).
- Zhou, X., Jin, T., Dai, Y., Song, Y., & Qiu, Z.** (2023). Md-pose: Human pose estimation for single-channel uwb radar, *IEEE Transactions on Biometrics, Behavior, and Identity Science*, 5(4), 449-463.




ÖZGEÇMİŞ

Ad-Soyad : Emin Berat BİLİR

Doğum Tarihi ve Yeri :

E-posta :



ÖĞRENİM DURUMU:

- **Lisans** : 2020, Düzce Üniversitesi, Teknoloji Fakültesi, Elektrik-Elektronik Mühendisliği
- **Yüksek Lisans** : 2024, Bursa Teknik Üniversitesi, Elektrik-Elektronik ABD, Elektrik-Elektronik Mühendisliği

TEZDEN TÜRETİLEN ESERLER, SUNUMLAR VE PATENTLER:

- **Bilir, E. B., & Özden, M.** (2024). 3 Boyutlu Gerçek Zamanlı İnsan Poz Tahmini, *4. Uluslararası Mühendislik ve Fen Bilimleri Kongresi*, (s. 156-162). İstanbul, Türkiye, 27-28 Temmuz.