



MARMARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**MAKİNE ÖĞRENMESİ TEMELLİ
FİZİKSEL AKTİVİTE KESTİRİM SİSTEMİ
TASARIM VE UYGULAMASI**

HASAN TAŞDEMİR

YÜKSEK LİSANS TEZİ
Mekatronik Anabilim Dalı

DANIŞMAN
Prof. Dr. Mustafa Caner AKÜNER

EŞ-DANIŞMAN
Dr. Öğr. Üyesi Gazi AKGÜN

İSTANBUL, 2022



MARMARA UNIVERSITY
INSTITUTE FOR GRADUATE STUDIES
IN PURE AND APPLIED SCIENCES



**DESIGN AND IMPLEMENTATION OF THE
MACHINE LEARNING BASED
PHYSICAL ACTIVITY ESTIMATION
SYSTEM**

HASAN TAŞDEMİR

MASTER THESIS

Department of Mechanical Engineering

Thesis Supervisor

Prof. Dr. Mustafa Caner AKÜNER

Thesis CO- Supervisor

Dr. Öğr. Üyesi Gazi AKGÜN

ISTANBUL, 2022

MARMARA ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

Marmara Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Öğrencisi Hasan TAŞDEMİR'in "Makine Öğrenmesi Temelli Fiziksel Aktivite Kestirim Sistemi tasarım ve uygulaması" başlıklı tez çalışması, 2022 tarihinde savunulmuş ve jüri üyeleri tarafından başarılı bulunmuştur.

Jüri Üyeleri

Prof.Dr. Mustafa Caner AKÜNER (Danışman)

Marmara Üniversitesi (İMZA).....

Dr. Öğr. Üyesi (Üye)

Marmara Üniversitesi (İMZA).....

Dr. Öğr. Üyesi (Üye)

Gedik Üniversitesi (İMZA).....

ONAY

Marmara Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun tarih ve sayılı kararı ile Hasan TAŞDEMİR'in Mekatronik Anabilim Dalı Mekatronik Programında Yüksek Lisans derecesi alması onanmıştır.

Fen Bilimleri Enstitüsü Müdürü
Prof. Dr. Bülent EKİCİ

MARMARA UNIVERSITY
INSTITUTE FOR GRADUATE STUDIES
IN PURE AND APPLIED SCIENCES

Hasan TAŞDEMİR, a Master of Science student of Marmara University Institute for Graduate Studies in Pure and Applied Sciences, defended his thesis entitled “Design and Implementation of the Machine Learning Based Physical Activity Estimation System”, on and has been found to be satisfactory by the jury members.

Jury Members

Prof.Dr. Mustafa Caner AKÜNER (Advisor)

Marmara University(SIGN)

Assist.Prof. (Jury Member)

Marmara Üniversitesi(SIGN)

Assist.Prof. (Jury Member)

Gedik Üniversitesi(SIGN)

APPROVAL

Marmara University Institute for Graduate Studies in Pure and Applied Sciences Executive Committee approves that Hasan TAŞDEMİR be granted the degree of Master of Science in Department of Mechatronics, Mechatronics Program on (Resolution no:).

Director of the Institute

Prof. Dr. Bülent EKİCİ

Bu tez çalışmasının fikir aşamasından başlayarak desteklerini esirgemeyen, yol gösteren danışmanım Sayın Prof. Dr. M. Caner AKÜNER' e

Karşılaştığım her türlü sorunda destek sağlayan, Makine Öğrenmesi ve MATLAB konularında beni yönlendiren eş danışmanım Sayın Dr. Öğr. Üyesi Gazi AKGÜN' e

Tez çalışmasındaki Sağlık konularında bilgi ve tecrübelerini bizden eksik etmeyen Üniversitemiz Sağlık Bilimleri Fakültesi, Fizyoterapi ve Rehabilitasyon Bölümünden başta Fizyoterapi Rehabilitasyon Eğitimi ve Bilişimi Anabilim Dalı başkanı sayın Prof. Dr. M. Gülden POLAT olmak üzere, Doç. Dr. İlkşan DEMİRBÜKEN, Dr. Öğr. Üyesi Eren TİMURTAŞ ve Arş. Gör. Ender Ersin AVCI' ya

Tüm bu süreçte benzer konularda birlikte çalıştığım arkadaşım Hayri MUTLU' ya

Çizim ve şekillerde katkılarından dolayı değerli Makine Mühendisi arkadaşım Ünal KÜÇÜKÖZDEMİR' e

Verilerin toplanmasında emeği geçen Selçuk Tekin, Ferda Mutlu, Alperen Uz, Yahya Samet Topdemir, Ahmet Umut, Fırat Yeşilırmak, Yahya Türker, Selma Taşdemir ve Lionel Otel Spor Tesisleri yetkilerine

Ve tez çalışması süresince sabır ve desteklerini esirgemeyen aileme teşekkürü bir borç bilirim.

İÇİNDEKİLER/

ÖZET.....	v
ABSTRACT	vi
SEMBOLLER/SYMBOLS	vii
KISALTMALAR/ABBREVIATIONS	viii
ŞEKİL	ix
TABLO LİSTESİ	x
1. GİRİŞ ve AMAÇ.....	1
2. METOD ve YÖNTEM.....	4
2.1. FATC Donanımı	4
2.1.1. Mikrodenetleyici.....	4
2.1.2. İvmeölçer Sensör	9
2.1.3. Hafıza Ünitesi.....	13
2.1.4. Güç Ünitesi	14
2.1.5. FATC Donanımı Montajı.....	15
2.2. FATC Yazılımı.....	18
2.2.1 FATC SD Kart Yazılımı	18
2.2.2 ADXL345 Verilerinin SD Karta Aktarımı	19
2.3. YAPAY ZEKÂ	21
2.3.1 Yapay Sinir Ağları	22
2.3.2 Makine Öğrenmesi	25
2.3.2 Makine Öğrenmesi Metotları	26
2.3.3 Yapay Sinir Ağının Eğitilmesi.....	28
2.3.5 FATC Veri Setinin Oluşturulması.....	29
3. Eğitim ve Test Verilerinin Elde Edilmesi	30
3.1. Verilerin Toplanması.....	30
3.2. Eğitim Verilerinin Test Edilmesi	33
3.2. Eğitimin Gerçekleştirilmesi	33
4. SONUÇ	34
KAYNAKLAR	38
ÖZGEÇMİŞ.....	42

ÖZET

MAKİNE ÖĞRENMESİ TEMELLİ FİZİKSEL AKTİVİTE KESTİRİM SİSTEMİ TASARIM VE UYGULAMASI

Bu tezde, fiziksel aktivite seviyesini tahmin etmek amacıyla bir "fiziksel aktivite tespit cihazı" (FATC) tasarlanmış ve uygulanmıştır. FATC, geniş bir lastik bant ve plastik toka yardımıyla sakral dorsal bölgeye (S1 seviyesi) sabitlenir ve dahili sensörlerden gelen üç kanallı ham ivme verilerini bir SD kartta saklar. Ayakta dururken, yürürken ve koşarken toplanan veriler, yüksek, orta ve düşük olarak sınıflandırılmıştır. Levenberg-Marquardt metodu Matlab patternnet ortamında bu verileri toplam yedi sınıfta sınıflandırmak için kullanılmıştır. Geliştirilen model ve toplanan veriler kullanılarak yapılan eğitimler sonucunda %83,3 eğitim doğruluğu ve %94,3 test doğruluğu değerlerine ulaşılmıştır.

Artan fiziksel hareketsizlik seviyeleri sağlık sistemleri, çevre, ekonomik kalkınma, toplum refahı ve yaşam kalitesi üzerinde olumsuz etkilere sahiptir. 2001 yılından bu yana küresel fiziksel aktivite seviyelerinde herhangi bir gelişme olmamıştır. Yüksek gelirli ülkelerde 2001 ve 2016 yılları arasında yetersiz aktivite %5 artmıştır (%31.6'dan % 36.8'e). Hareketsizliğin etkileri; çocuklarda ve ergenlerde, artan adipozite (kilo alımı) daha zayıf kardiyometabolik sağlık, zindelik, davranış yönetimi / pro-sosyal davranış azaltılmış uyku süresidir. Yetişkinlerde ise tüm nedenlere bağlı mortalite, kardiyovasküler hastalık mortalitesi ve kanser mortalitesi, kardiyovasküler hastalık, kanser ve tip-2 diyabet insidansıdır.

Akselerometre cihazlarının ve yazılımlarının tamamı ithal olduğundan fiyatları oldukça yüksektir. Sağlık çalışanları hizmet verdikleri kişilerin haftalık fiziksel aktivitesini ölçme konusunda maddi imkânsızlıklardan dolayı sorun yaşamaktadır. Bu çalışma kapsamında tasarımı ve uygulaması yapılan cihaz ile piyasada bulunan cihazların maliyetler, arasında %500 ila %900 oranlarında tasarımı yapılan FATC lehine maliyet farkı bulunmaktadır.

ABSTRACT

DESIGN AND IMPLEMENTATION OF THE MACHINE LEARNING BASED PHYSICAL ACTIVITY ESTIMATION SYSTEM

In this thesis, a "physical activity detection device" (FATC) has been designed and implemented for the purpose of estimating physical activity level. FATC is fixed to the sacral dorsal region (S1 level) with the aid of a wide rubber band and plastic buckle and stores three channels of raw acceleration data from internal sensors on an SD card. The pace of the data collected while standing, walking, and running was classified as high, medium, and low. Petternnet, Levenberg-Marquardt was used in the Matlab environment to classify these data into a total of seven classes. 83.3 % training accuracy and 94.3 % test accuracy values were attained at the conclusion of the trainings conducted using the developed model and the gathered data.

Growing levels of physical inactivity have negative effects on the environment, economy, quality of life, and community well-being. Since 2001, there has been no increase in the level of physical activity worldwide. Between 2001 and 2016, the percentage of underactive people in developed countries rose by 5% (from 31.6% to 36.8%). Effects of inactivity include decreased sleep time, increased adiposity (weight gain), and worse cardiometabolic health, wellness, and pro-social behavior in children and adolescents. It is the prevalence of all-cause mortality, cardiovascular disease mortality, cancer mortality, and type 2 diabetes mortality in adults.

All accelerometer hardware and software are imported, which drives up their cost. Due to financial constraints, healthcare professionals have difficulty gauging the weekly physical activity of the patients they treat. Between the cost of the device we created within the parameters of our thesis and the devices currently on the market, there is a cost difference of 500% to 900% in favor of our device.

SEMBOLLER/SYMBOLS

V_{xout}	: X ekseninin gerilim değeri
V_{yout}	: Y ekseninin gerilim değeri
V_{zout}	: Z ekseninin gerilim değeri
Adc_X	: X ekseninin Analog dijital çevirici çıkış değeri
Adc_Y	: Y ekseninin Analog dijital çevirici çıkış değeri
Adc_Z	: Z ekseninin Analog dijital çevirici çıkış değeri
VDD	: Besleme Gerilimi
Y	: Çıkış
X	: Giriş
W	: Ağırlık Çarpanı
B	: Bias

KISALTMALAR/ABBREVIATIONS

ADÇ	: Analog Dijital Çevirici
DAÇ	: Dijital Analog Çevirici
FA	: Fiziksel Aktivite
FATC	: Fiziksel Aktivite Tespit Cihazı
G	: Giriş
G/Ç	: Giriş/Çıkış
GA	: Genel Amaçlı
GZS	: Genel Zaman Saati
I²C	: Inter-Integrated Circuit
IDE	: Integrated Development Environment
IoT	: Internet of Things
LM	: Levenberg-Marquardt
MLP	: Multilayer Perceptron
MSE	: Mean Square Error
SD	: Secure Digital Memory
SDXC	: Secure Digital Extended Capacity
SPI	: Serial Peripheral Interface Bus
PIC	: Peripheral Interface Controller
RMS	: Root Mean Square,
YSA	: Yapay Sinir Ağları
WL	: Wave Length,

ŞEKİL LİSTESİ

Şekil 2.1. FATC Donanım Blok Şeması.	4
Şekil 2.2. Arduino Diecimila [12]	6
Şekil 2.3. Klon Arduino [12].....	6
Şekil 2.4 ESP-32 Devkit-1 [13].....	7
Şekil 2.5 İvmeölçerin Yerçekimsiz Ortamda Durumu	10
Şekil 2.6 İvmeölçerin Yerçekimsiz Ortamda Tek Yönlü Kuvvet Altında Durumu	10
Şekil 2.7 İvmeölçerin Yer çekimli Ortamda Durumu	11
Şekil 2.8 İvmeölçerin Bileşik Kuvvet Etkisi Altında Durumu.....	11
Şekil 2.9 TP4056 LiPo Pil Şarj Devresi	15
Şekil 2.10 FATC Genel Bağlantı Şeması	16
Şekil 2.11 FACT ve Şarj Ünitesi Kullanıma Hazır Hali	17
Şekil 2.12 FATC İç Görünümü	18
Şekil 2.13 FATC Program Akış Şeması.....	20
Şekil 2.14 Biyolojik Sinir Hücre Modeli	23
Şekil 2.15 Sinir Hücresi Matematiksel Modeli	23
Şekil 2.16 Yapay Sinir Ağı Genel Modeli	24
Şekil 2.17 Perceptron modeli	25
Şekil 2.18 Makine Öğrenmesi Metotları	28
Şekil 2.19 LM metodunda Marquardt parametresinin etkisi.....	29
Şekil 3.1 Eğitim Verilerinin Toplanması	31
Şekil 3.2 Test Verilerinin Koşu Bandı Yardımıyla Alınması	32
Şekil 3.3 Öğrenme Hata Matrisi.....	34
Şekil 4.1 Test Hata Matrisi.....	35
Şekil 4.2 Test Doğruluk Karşılaştırma Eğrisi	36

TABLO LİSTESİ

Tablo 2.1 ESP-32 Pin/Fonksiyon tablosu [13].....	7
Tablo 2.2 ADXL345 Karakteristikleri	12
Tablo 2.3 FATC Güç Tüketim Değerleri	16
Tablo 3.1 Eğitim Verileri Toplanan Kişilerin Fiziksel Özellikleri	30
Tablo 3.2 Kişi – Veri Türü	31
Tablo 4.1 FATC Maliyet Tablosu	36



1. GİRİŞ ve AMAÇ

Dünya Sağlık Örgütü enerji harcanmasını gerektiren ve iskelet kasları tarafından üretilen herhangi bir vücut hareketini fiziksel aktivite olarak tanımlar. Fiziksel aktivite kişinin yaş, boy, kilo gibi değerlerine bağlı olarak, fiziksel ve psikolojik sağlığı iyileştirir. Fiziksel aktivitenin sevilen çeşitleri olarak, herhangi bir özel yetenek ya da yüksek maliyetli tesis gerektirmeyen yürüyüş, bisiklete binme, basit egzersizler ile futbol, masa tenisi gibi oyunlar yer alır. Birçok fiziksel aktivite sadece sağlık için değil aynı zamanda eğlenmek için yapılabilir [1].

Yürümek, bisiklete binmek, pedal çevirmek, spor yapmak veya aktif rekreasyon gibi düzenli fiziksel aktivite sağlık için önemli faydalar sağlar. Herhangi bir fiziksel aktivite hareketsiz kalmaya ya da hiç fiziksel aktivite yapmamaya göre çok daha iyidir. İnsanlar gün boyunca, toplu taşımadan bir durak daha erken inmek, asansörü inişte kullanmamak, normal yürüyüş yerine tempolu yürüyüşü tercih etmek, akşam yemeğinden sonra basit egzersizler yapmak gibi yapılması kolay fiziksel aktiviteler ile bireysel özellikleri gereği günlük yapmaları gereken fiziksel aktivite seviyelerine kolayca ulaşabilirler.

Fiziksel hareketsizlik, bulaşıcı olmayan hastalıkların ölümleri için önde gelen risk faktörlerinden biridir. Yeterince aktif olmayan kişiler, yeterince aktif olanlara kıyasla % 20 ile % 30 daha yüksek ölüm riskine sahiptir. Kanıtlar, daha yüksek miktarlarda hareketsiz davranışın aşağıdaki kötü sağlık sonuçlarıyla ilişkili olduğunu göstermektedir:

Çocuklarda ve ergenlerde:

*Artan adipozite (kilo alımı)

*Daha zayıf kardiyometabolik sağlık, zindelik, davranış yönetimi / pro-sosyal davranış

*Azaltılmış uyku süresi

Yetişkinlerde:

*Tüm nedenlere bağlı mortalite, kardiyovasküler hastalık mortalitesi ve kanser mortalitesi

*Kanser, kalp hastalıkları ve tip-2 diyabet [1].

Dünyadaki yetişkinlerin yaklaşık %30'unun fiziksel aktivite seviyesini yeterli olmadığı görülmüştür. Tüm Dünyadaki her 3 kadından 1'i ve 4 erkekten 1'inin günlük fiziksel aktivite oranı, gerekli rakamın altındadır. Düşük fiziksel aktivite oranları ve buna

bağlı hastalıklar gelişmiş ülkelerde, gelişmemiş ülkelere göre iki kat daha fazladır. 2001 yılından bu yana küresel fiziksel aktivite seviyelerinde herhangi bir gelişme olmamıştır. Gelişmiş ülkelerde yapılan araştırmalar göre son 20 yıldır düşük fiziksel aktivite oranı % 5 artarak yaklaşık %32'den %37'ye yükselmiştir. Düşük fiziksel hareketlilik seviyelerinin ülkelerin sadece sağlık sistemleri üzerinde değil aynı zamanda çevre, finansal kalkınma, ülke refahı ve insanların kalitesi üzerinde de negatif etkileri vardır. Dünya çapında, 18 yaş ve üstü yetişkinlerin % 28'i son yıllarda yeterince aktif değildi. Bu oran erkek bireylerde % 23 iken kadın bireylerde % 32'dir. Bu verilerin makul değerlere ulaşabilmesi için haftalık bazda 2,5 saat orta düzey ya da 1 saat yüksek düzey fiziksel aktivitede bulunulması gerekmektedir. Aynı zaman dilimi aralığında, gelişmemiş ülkelerdeki fiziksel aktivite oranlarına bakıldığında ise erkek bireylerin % 12'sinin kadın bireylerin ise % 24'ünün yeterince aktif olmadığı görülmektedir. Bu veriler ışığında gelir seviyesi yükseldikçe, teknoloji ve ulaşım araçlarının sağladığı kolaylıkların fiziksel aktivite seviyesini azalttığı, başka bir deyişle aralarında negatif korelasyon olduğu görülmektedir [1].

FA seviyelerindeki azalma, boş zamanlardaki hobilerin interaktif haberleşme araçlarına yönelmesi, iş ve evdeki çalışmaların bilgisayar ortamında yapılmasından kaynaklanmaktadır. İnsanın aktif bir çaba sarf etmediği gelişmiş ulaşım yöntemlerinin de yetersiz fiziksel aktivite oranını arttırdığı görülmektedir. Global olarak, ergenlerin (11-17 yaş aralığı) % 81'i son 10 yıldır fiziksel olarak düşük aktivite değerlerine sahiptir. Yetişkinlerde olduğu gibi ergenlik çağındaki bireylerde de kadınlar, erkeklerden daha düşük fiziksel aktivite değerlerine sahiptir. Ergen kadın bireylerin % 85'i ergen erkek bireylerin ise % 78'i, Dünya Sağlık Örgütünün, günlük en az 1 saatlik orta ya da 30 dakika şiddetli fiziksel aktivite önerisini uygulamıyor. Fiziksel aktivitenin düzenli ve bilinçli yapılmasının bulaşıcı olmayan, kalp hastalığı, felç, diyabet ve kanser türlerinin bir bölümü gibi hastalıkları önlemeye veya olası etkilerini azaltmaya yardımcı olduğu tıp alanındaki çalışmalar ile kanıtlanmıştır. Düzenli yapılan egzersizler aynı zamanda vücut ve dolaşım yolundaki yağlara etki ederek hipertansiyonu önlemeye, sağlıklı vücut ağırlığını korumaya yardımcı olmakla kalmayıp zihinsel ve ruhsal sağlığı ve bireylerin yaşam kalitesini de olumlu yönde etkilemektedir [1].

Dünya Sağlık Örgütüne göre daha fazla araştırma gerektiren araştırma alanları arasında, hastalık risk profiline katkıda bulunan hareketsiz davranış, 5 yaşın altındaki çocuklarda sağlığı geliştiren fiziksel aktivite, hamile kadınlarda sağlığı geliştiren fiziksel aktivite, bulaşıcı olmayan hastalıklı (örn. Kardiyovasküler hastalık, diyabet, kanser, obezite,

akıl sađlıđı kořulları, vb.) kiřilerin klinik tedavisi iin fiziksel aktivite dozları yer almaktadır [2]. Bu arařtırmaların yapılabilmesi iin fiziksel aktivitelerin lölmesi gerekmektedir. Fiziksel aktivite lölüm yöntemleri;

- Objektif Yöntemler;
 1. Pedometreler,
 2. Akselerometreler (FATC),
 3. Direkt Gözlem,
- Sübjektif Yöntemler:
 1. Anketler,
 2. Aktivite Günlükleridir.

Sübjektif yöntemlerin güvenilirliđi oldukça düşüktür. Objektif yöntemlerden direkt gözlem oldukça yüksek vakit almakta ve özel hayatın gizliliđi ilkesi dođrultusunda bazı sorunlar oluřturmaktadır. Pedometreler ise yapılan fiziksel aktivitenin süre ve adet olarak verilerini sunmakta ancak aktivitenin türü ve diđer gerekli verileri sunamamaktadır. Mevcut seçenekler ierisinde en verimli fiziksel aktivite tespit cihazlarıdır.

Basın yörüngelerinin merkezi, en iyi bel ivmeöler verilerinden tahmin edilir. Basın yörüngelerinin merkezini tahmin etmek iin makine đrenimi algoritmaları kullanılabilir [3]. Bu sebeple FATC, sacral dorsal bölgesi yaklaşık olarak S1 hizasına yerleřtirilebilecek řekilde tasarlanması en uygundur. Geleneksel akselerometreler “fiziksel aktivite” (FA) lölümünden aktivite enerji harcamasının hesaplanması iin genellikle dođrusal regresyon analizi kullanılır [4] [5]. Veri eğrisi analizi, aktivite yoğunluđundan fiziksel aktivite kestirimi yapmak iin kullanılan diđer bir yöntemdir [6]. Bu tür yöntemler veri türünü FATC iinde belirleyip FA türünü saklayıp ham veriyi depolamamaktadır. Görece olarak geleneksel sayılabilecek bu yöntemler birbirinden ok farklı (oturma, yatma, yürüme gibi) fiziksel aktiviteleri ayırmada başarılı olsa da birbirine yakın fiziksel aktiviteleri (yüksek tempo yürüme ile düşük tempo kořu gibi) ayırt etmekte zorlanmaktadır. Ayrıca bu yöntemlerin gerek yařamdaki pek ok aktiviteyi ayırt edemediđi pek ok alıřmada vurgulanmıřtır [7], [8], [9].

Bu sebeplerden dolayı geleneksel istatistik tabanlı yöntemler yerine daha sofistike ve gelişime açık yöntemlere ihtiya duyulmaktadır. Makine đrenmesi temelli fiziksel aktivite kestirimi bu alanda geleneksel yöntemlere göre yakın verileri ayırt etme ve ok eřitli FA türlerini kestirme aısından ok daha avantajlıdır [7].

Bu alıřmada geliştirilen FATC, denetimli makine đrenmesi yöntemi ile eğitilmiş yapay


sinir ağı ile fiziksel aktiviteyi sınıflandırmayı ve sonrasında FA türünün kestirimini gerçekleştirmiştir.

2. METOD ve YÖNTEM

Fiziksel aktivite tespit cihazlarının temel bileşenleri Şekil 2.1’de görülebileceği üzere, ivmeölçer sensör, mikrokontrolör, hafıza ünitesi ve güç ünitesidir. Genel hatları ile sistemin çalışması; güç ünitesince enerjilendirilen mikrokontrolör I²C protokolü ile haberleştiği ADXL345 ivmeölçer sensöründen aldığı verileri SPI protokolü ile her 30 saniyede bir SD karta aktarmaktadır. FA ölçümü sona erdiğinde denek/hasta cihazı, ilgili fizyoterapist/doktora vermekte, ilgili kişi cihazın içerisindeki ham verilerin olduğu SD kartı bir PC’ye aktararak daha önceden eğitilmiş bir yapay zeka algoritması yardımı ile FA türü kestirimini yapabilmektedir.

2.1. FATC Donanımı

FACT donanımı Mikrodenetleyici, İvmeölçer Sensör, Hafıza Ünitesi ve Güç Ünitesi olmak üzere dört ana bölümden oluşmaktadır.



Şekil 2.1. FATC Donanım Blok Şeması.

2.1.1. Mikrodenetleyici


Mikrodenetleyiciler sıklıkla mikroişlemciler ile karıştırılmaktadır. Ancak mikrodenetleyiciler, mikroişlemcinin yapısında da bulunan CPU, önbellek ve I/O portlarının yanında seri ve paralel portlar, çeviriciler (DAC ADC vb.) ve sayıcılar da

içermektedir.

İlk mikrodnetleyici 1971 yılında Amerika Birleşik Devletleri'nde Intel Corporation tarafından geliştirilmiştir. Bu, i4004 adı verilen 4 bitlik mikro denetleyicidir. Bir Japon şirketi BUSICOM tarafından hesap makineleri için sipariş edilmiştir. Daha sonra sözleşme değiştirilmiş ve başarı ile genel amaçlı bir mikrodnetleyici olarak satılmıştır. Bundan sonra Intel Corp., "i8008", "i8080A" ve "i8085" gibi 8 bitlik mikro denetleyicilerin ardından 16 bitlik bir mikro denetleyici "8086" geliştirmiştir. Birkaç mikrodnetleyici geliştirdikten sonra, mevcut kişisel bilgisayarlarda kullanılan CPU'ları geliştirmeye devam etmişlerdir. [10].


Piyasada yaygın olarak kullanılan Harvard mimarisindeki ilk mikrodnetleyici ise "General Instruments" firması tarafından 1970'lerde üretilen Signetics 8X300 isimli üründür. Bu mikrodnetleyici CP1600 için programlanabilen G/Ç portu olarak görev almak üzere Peripheral Interface Controller (Çevreirim arayüz denetleyicisi, PIC) olarak tasarlanmıştır. Firmanın mikro elektronik bölümünü 1988 yılında satması ile Arizona Microchip Technology adıyla yeni bir firmaya dönüşmüştür. Microchip firmasının temel üretimi, günümüzde hala aktif olarak kullanılan, PIC serisi mikrodnetleyicilerdir [11]. "PIC", okunuşuyla "pik", ülkemizde piyasa dilinde, mikrodnetleyici kelimesi yerine sıklıkla kullanılmaktadır.

Mikrodnetleyiciler 2000'li yılların ortalarından itibaren tek olarak satılmak yerine yavaş yavaş yerlerini geliştirme kartlarına bırakmışlardır. Bu akımın öncüsü "Arduino" dur. 2005 yılında, Hernando Barragán'ın (Wiring'in yaratıcısı) çalışmalarına dayanarak, Massimo Banzi ve David Cuartielles, etkileşimli sanat tasarımı projeleri için kullanımı kolay programlanabilir bir cihaz olan Arduino'yu, Ivrea, İtalya'daki Etkileşim Tasarım Enstitüsü Ivrea'da geliştirmiştir. David Mellis, Wiring tabanlı Arduino yazılımını yapmıştır. Çok geçmeden, Gianluca Martino ve Tom Igoe projeye katıldı ve beşi Arduino'nun orijinal kurucuları olmuştur. Basit bir şekilde çeşitli şeylere (röleler, motorlar ve sensörler gibi) bağlanması ve programlanması kolay bir cihaz istiyorlardı. Ayrıca, öğrenciler ve amatörlerin maddi durumları belli olduğundan, ucuz olması gerekiyordu. Atmel'in AVR ailesini 8-bit mikrodnetleyici (MCU veya μC) cihazlarından seçtiler ve kullanımı kolay bağlantılara sahip bağımsız bir devre kartı tasarladılar, mikrodnetleyici için önyükleyici belenimi yazdılar ve hepsini basit bir entegre geliştirmede paketlemişlerdir. "Sketches" adı verilen programları kullanan yazılım ortamı (IDE) ile birlikte sonuç mikrodnetleyici geliştirme kartı Arduino oldu [12]. Şekil 2.2'de ilk Arduino görülmektedir.



Şekil 2.2. Arduino Diecimila [12]

Arduino geliştirme kartlarının daha uygun versiyonları ÇİN firmaları tarafından kısa süre sonra üretilip piyasaya sunulmuştur. Bu kartlar Şekil 2.3'te görüldüğü gibi orijinaline görsel olarak oldukça benzer kartlardır ve Klon olarak isimlendirilmektedir. Klon kartlarda asılları gibi Arduino IDE programı ile programlanabilmektedir. Ancak küçük bir ara yazılım gereksinimi duymaktadır.



Şekil 2.3. Klon Arduino [12]

Arduino geliştirme kartlarının başarısı sonrası birçok firma tarafından benzerleri üretilmiştir. Bazı firmalar ise Arduinoların ek donanım ile yapabildiği işleri tek başına yapabilen kartlar geliştirerek sektörün açıklarını kapatmayı hedeflemişlerdir. Bu firmaların biri de ESPRESSIF'tir.

Espressif Systems 2008 yılında kurulmuş, Çin Halk Cumhuriyeti, Çek Cumhuriyeti, Hindistan, Singapur ve Brezilya'da ofisleri bulunan, halka açık çok uluslu, bir yarı iletken şirkettir. Dünyanın her yerinden, kablosuz iletişim, düşük güç, IoT çözümleri geliştirmeye odaklanan mühendis ve bilim adamlarından oluşmaktadır. Popüler ESP32, ESP32-S, ESP32-C, ESP32-H ve ESP8266 gibi yongalar, modüller ve geliştirme kartları

oluşturmuştur. Kendi ifadeleri ile “Teknolojimizi ve çözümlerimizi açık kaynak kullanarak geliştiricilerin Espressif’in çözümlerini küresel olarak kullanmalarını ve kendi akıllı bağlantılı cihazlarını oluşturmalarını sağlamayı amaçlıyoruz”. Açık kaynak kod, düşük güç tüketimi, uygun maliyeti, erişilebilirlik, ebat ve ağırlık etkenleri göz önünde bulundurularak bu çalışmada mikrodenetleyici olarak ESP-32 seçilmiştir. ESP-32’nin bu özelliklerine ek olarak bütünleşik Wi-Fi, Bluetooth ve RTC modüllerinin olması ile çift çekirdekli yapısı da çalışmada kolaylık sağlamıştır. ESP-32’nin farklı varyasyonları bulunmakla birlikte Şekil 2.4’teki Devkit-1’in ebat olarak bu çalışmaya daha uygun olduğu görülmüştür.



Şekil 2.4 ESP-32 Devkit-1 [13]

Tablo 2.1’de ESP-32’nin Pin/Fonksiyon tablosu görülmektedir. ESP-32’nin birçok pini birden fazla fonksiyonu yerine getirebilme özelliğine sahiptir. Böylece daha az pin ile daha küçük ve hafif geliştirme kartları mümkün olmaktadır.

Tablo 2.1 ESP-32 Pin/Fonksiyon tablosu [13]

Pin	Ad	Tür	Fonksiyon
1	GND	Güç	Şase
2	3v3	Güç	3.3 V enerji kaynağı (çıkış)
3	I-36	G	GA G/Ç36, ADÇ1 KANAL0, GZS_GA G/Ç0
4	I-37	G	GA G/Ç37, ADÇ1 KANAL1, GZS_GA G/Ç1
5	I-38	G	GA G/Ç38, ADÇ1 KANAL2, GZS_GA G/Ç2
6	I-39	G	GA G/Ç39, ADÇ1 KANAL3, GZS_GA G/Ç3
7	RST	G	Reset girişi (High: enable; Low: powers off)
8	I-34	G	GA G/Ç34, ADÇ1_CH6, GZS_GA G/Ç4

9	I-35	IG	GA G/Ç35, ADÇ1_CH7, GZS_GA G/Ç5
10	IO-32	G/Ç	GA G/Ç32, 32KHz Kristal Osilatör Girişi, ADÇ1_Kanal4, Dokunmatik Uç9, GZS_GA G/Ç9
11	IO-33	G/Ç	GA G/Ç33, 32KHz Kristal Osilatör Çıkışı, ADÇ1_Kanal5, Dokunmatik Uç8, GZS_GA G/Ç8
12	IO-25	G/Ç	GA G/Ç25, DAC_1, ADÇ2_Kanal8, GZS_GA G/Ç6,
13	IO-26	G/Ç	GA G/Ç26, DAC_2, ADÇ2_Kanal9, GZS_GA G/Ç7,
14	IO-27	G/Ç	GA G/Ç27, ADÇ2_Kanal7, Dokunmatik Uç7, GZS_GA G/Ç17
15	IO-14	G/Ç	GA G/Ç14, ADÇ2_Kanal6, Dokunmatik Uç6, GZS_GA G/Ç16, MTMS, HSPI CLK, HS2CLK, SD CLK,
16	5 V	Güç	5 V Enerji Girişi
17	IO-12	G/Ç	GA G/Ç12, ADÇ2_Kanal5, Dokunmatik Uç5, GZS_GA G/Ç15, MTDI, HSPIQ, HS2_DATA2, SD Veri2,
18	IO-13	G/Ç	GA G/Ç13, ADÇ2_Kanal4, Dokunmatik Uç4, GZS_GA G/Ç14, MTCK, HSPID, HS2_DATA3, SD Veri3,
19	IO-15	G/Ç	GA G/Ç15, ADÇ2_CH3, Dokunmatik Uç3, GZS_GA G/Ç13, MTDO, HSPICS0, HS2_CMD, SD_CMD, EMAC_RXD3
20	IO-2	G/Ç	GA G/Ç2, ADÇ2_CH2, Dokunmatik Uç2, GZS_GA G/Ç12, HSPIWP, HS2_DATA0, SD Veri0
21	IO-0	G/Ç	GA G/Ç0, ADÇ2_CH1, Dokunmatik Uç1, GZS_GA G/Ç11, CLK OUT1
22	IO-4	G/Ç	GA G/Ç4, ADÇ2_CH0, Dokunmatik Uç0, GZS_GA G/Ç10, HSPIHD, HS2_DATA1, SD Veri1
23	IO-9	G/Ç	GA G/Ç9, HS1_DATA2, U1RXD, SD VERİ 2
24	IO-10	G/Ç	GA G/Ç10, HS1_DATA3, U1TXD, SD VERİ3
25	IO-5	G/Ç	GA G/Ç5, HS1_DATA6, SPI S0
26	IO-18	G/Ç	GA G/Ç18, HS1_DATA7, SPI CLK
27	IO-23	G/Ç	GA G/Ç23, HS1_STROBE, SPI D
28	IO-19	G/Ç	GA G/Ç19, SPI Q, U0CTS
29	IO-22	G/Ç	GA G/Ç22, SPI WP, U0RTS,
30	IO-21	G/Ç	GA G/Ç21, SPI HD,

31	TX-D0	G/Ç	GA G/Ç1, U0TXD, PWM3, EMAC_RXD2
32	RX-D0	G/Ç	GA G/Ç3, U0RXD, PWM2


2.1.2. İvmeölçer Sensör

İvmeölçerler, titreşim veya hareketin ivmesini ölçen cihazlardır. Titreşimden kaynaklanan ivme kuvveti, kütlenin, üzerine uygulanan kuvvetle orantılı bir elektrik yükü üreten piezoelektrik malzemeyi "sıkmasına" neden olur. Yük kuvvetle orantılı olduğundan ve kütle sabit olduğundan, yük de ivmeyle orantılıdır. Bu sensörler, en karmaşık uzay teknolojilerinden cep telefonlarına kadar çeşitli yelpazedeki cihazlarda değişik amaç ve şekillerde kullanılır. Herkesin ivmeölçer bulunan bir cihaza sahip olma ihtimali oldukça yüksektir. Örneğin mobil telefon herhangi bir yöne çevrildiğinde telefonun ekranının dönmesinin nedeni budur. Endüstriyel ortamda ise ivmeölçerler, mühendislerin bir makinenin dengesini anlamalarına yardımcı olur ve istenmeyen kuvvetleri/titreşimleri izlemelerini sağlar [14].

Dünya yüzeyi üzerinde sensöre etki eden kuvvet, $1g$ lik yerçekimi kuvvetidir. Yerçekimi kuvveti $1g = 9.8m/s^2$ değerine eşittir. Ancak bu durum deniz seviyesine göre yüksekliğinize ve ekvator dan kutuplara doğru bulunduğunuz noktaya göre değişiklik göstermektedir. G kuvveti çekim etkisi sürekli olduğundan ivmeölçerler sürekli ölçüm yapabilmektedir. İvmeölçerin sadece bir eksen de ölçüm yapabilen, iki eksenli ve üç eksenli ölçüm yapabilen olmak üzere üç temel çeşidi mevcuttur. ADXL345 üç eksenli bir ivmeölçerdir [15].


İvmeölçer sensörlerin temel çalışma prensipleri bir küre ve küp yardımı ile incelenecek olursa;

Durum 1: Herhangi bir çekim etkisi yok ise; Şekil 2.5'teki kırmızı küre hiçbir yüzeye temas etmez/kuvvet uygulamaz. Başka bir deyişle küre kutunun merkezine yerleştirildiğinden bir çekim ya da kuvvet etkisi olmadığından dolayı küre, kareye ait herhangi bir yüzeye dokunmadan ya da herhangi bir kuvvet uygulamadan hareketsiz bir şekilde duracaktır. Dolayısı ile tüm yüzeylerdeki kuvvet 0 olacaktır.




Şekil 2.5 İvmeölçerin Yerçekimsiz Ortamda Durumu

Durum 2- Yer çekimsiz ortamda bir yönden kuvvet geliyor ise: Şekil 2.6'daki gibi kutu +X yönüne bir F kuvveti hareket etmesi durumunda kırmızı küre ivmelenecek ve $-X$ yüzeyine F kuvvetine eşit bir kuvvet ile çarpıp kırmızı çember ile işaretlenen alana etki edecektir.




Şekil 2.6 İvmeölçerin Yerçekimsiz Ortamda Tek Yönlü Kuvvet Altında Durumu

Durum 3- Yer çekimli ortamda ek kuvvet yok ise: Şekil 2.7'de görüldüğü üzere yer çekimi etkisi ile kırmızı küre +Y yüzeyinde kırmızı çember içindeki alana "g" kuvveti ile etki edecektir.



Şekil 2.7 İvmeölçerin Yer çekimli Ortamda Durumu

Durum 4- Bileşik kuvvet etkisi altında ise: Şekil 2.8’deki gibi ivmeölçer iki eksenli bileşik bir kuvvet ile ivmelendiğinde kırmızı küre hem $-X$ hem de $-Z$ yüzeylerinde kırmızı daire ile gösterilen alanlara etki edecektir. Eğer eğim şekildeki gibi tam 45 derece ise her bir yüzeydeki kuvvet F kuvvetinin 0,707 katına eşit olacaktır.



Şekil 2.8 İvmeölçerin Bileşik Kuvvet Etkisi Altında Durumu

İvmeölçerler yukarıdaki durumlarda temel olarak anlatılan prensiple çalışmaktadır. İçerisinde kuvvet veya manyetik alana tepki veren yüzeyler bulunmaktadır. Sensör bu tepkinin şiddetine göre çözünürlüğü ile doğru orantılı olarak bir sayısal değer üretmektedir. Çözünürlük arttıkça bu değerin maksimum seviyesi artmakta ve daha hassas ölçümler

yapılabilmektedir. Sensörün Dünya ile arasındaki açının değişmesiyle sensörün iç yüzeylerine uygulanan kuvvet değerleri de değişecektir.

İvmeölçerden binary (ikili) olarak elde edilen veriler X,Y ve Z eksenleri için ayrı ayrı ADC yardımı ile -512 +512 değer aralığındaki ondalık sayılara dönüştürülür. Fonksiyonel formüllere dayalı geleneksel yöntemlere dayalı çalışmalarda genellikle elde edilen bu ham değerler ile işlem yapılmaz. Öncelikle g değeri elde edilir. “ g ” değerini bulmak için ise ADC’den okunan ham değerler önce voltaj türünden ifade edilmelidir. Ham verileri elektrik gerilimi türünden verilere çevirmek için ham değerlerin tümünün tek tek besleme gerilimi (VDD) ile çarpılması ve 2 üzeri ADC çözünürlüğü ile bölünmesi gerekmektedir [16].

$$V_{xout} = AdcX * \frac{VDD}{2^{\wedge} \text{çözünürlük}} \quad (2.1)$$

$$V_{yout} = AdcY * \frac{VDD}{2^{\wedge} \text{çözünürlük}} \quad (2.2)$$

$$V_{zout} = AdcZ * \frac{VDD}{2^{\wedge} \text{çözünürlük}} \quad (2.3)$$

Denklem 2.1’de V_{xout} X eksen verisinin gerilim cinsinden değeri, $AdcX$ analog dijital çeviricinin X eksen için ikili sayı sisteminden onluğa çevirdiği değeri VDD ise besleme gerilimini ifade etmektedir. Denklem 2.2 ve 2.3 ise bunun Y ve Z eksenleri için kullanılan versiyonlarıdır.

Ancak bu çalışmada geleneksel metotlar yerine makine öğrenmesi kullanıldığı için bu işleme ihtiyaç duyulmadığı çalışma sırasında görülmüş ve yazılımdan çıkarılmıştır.

Bu çalışmada ADXL345 kullanılmasının sebepleri I²C ve SPI veri iletişim protokollerini desteklemesi, erişilebilir olması, ebat ve ağırlık olarak çalışmaya uygunluğu ve makul fiyatıdır. Sensörden gelen bilgiler I²C protokolü kullanılarak mikrokontrolöre aktarılmıştır. Sensör ile ilgili bazı karakteristikler Tablo 2.2’de sunulmuştur.

Tablo 2.2 ADXL345 Karakteristikleri

Çalışma Gerilimi	1.8 – 3.6VDC
Çalışma Akımı (2.5V’ta)	25 – 130 uA
Eksenler	X, Y, Z
Çalışma Frekans Aralığı	0.1 – 3200 Hz

Çalışma Sıcaklığı	-40, +85 °C
Çözünürlük	13 Bit

2.1.3. Hafıza Ünitesi

Cihazın hafıza ünitesi birer adet SD kart modülü ve SD karttan oluşmaktadır. ESP-32 3.3V ile çalıştığından SD kart modülü yerine SD kart yuvasının da sorunsuzca çalıştığı deneyimlenmiştir.

SD kartlar 1999'da SanDisk, Matsushita ve Toshiba tarafından ortaklaşa geliştirilmiştir. Sony'nin Memory Stick'iği olan MultiMediaCard'ın (MMC) daha kompakt bir alternatif olması amaçlanmıştır. MultiMediaCard'ın halefi olarak piyasaya çıktı ve piyasanın değişmezleri arasındaki yerini aldı. Elektronik endüstrisi geliştikçe, daha yüksek kapasitelere ve hızlara imkan vermek için orijinal SD kart spesifikasyonu birkaç kez güncellenmiştir. Günümüzde SD kartların pek çok versiyonu bulunmaktadır. Bunlar;

- **SD:** Orijinal SD kart artık sınırlı sayıda bulunmaktadır. SD türündeki kartlar maksimum 2 GB kapasiteye sahip ve FAT16 dosya sistemini kullanmaktadır.
- **SDHC:** Secure Digital High Capacity (SDHC) kartı 2006'da piyasaya çıkmıştır. 32 GB'a kadar kapasiteleri destekleyen ve FAT32 dosya sistemini kullanan SD kart türüdür.
- **SDXC:** Secure Digital eXtended Capacity (SDXC) formatı 2009'da başlamıştır. exFAT dosya sisteminde 2 TB'a kadar depolayabilen SD kart türüdür.
- **SDUC:** Secure Digital Ultra Capacity (SDUC) kartları 2018'de piyasaya çıkmış ve exFAT kullanarak maksimum 128 TB'ı destekleyebilir kapasitedeki gelişmiş SD kart türüdür.

Standart bir SD kart 32 mm x 24 mm x 2,1 mm ölçülerinde ve yaklaşık 2 gram ağırlığındayken, miniSD ve microSD kartlar fiziksel olarak çok daha küçüktür ancak benzer bir bellek kapasitesine sahiptir. SD kartların kapasitelerinin yanı sıra hızları da farklı birimler ile sınıflandırılır. Günümüzde yaygın olarak kullanılan 3 hız sınıfı vardır. Bunlar;

Birinci hız sınıfı, “C” sembolüyle gösterilen ve orijinal hız sınıfı olarak bilinendir. Birinci hız sınıfı kategorisinde dört farklı değer bulunmaktadır:

- C2 Sınıfı: 2 MB/s yazma ve okuma hızı
- C4 Sınıfı: 4 MB/s yazma ve okuma hızı
- C6 Sınıfı: 6 MB/s yazma ve okuma hızı


- C10 Sınıfı 10 MB/s yazma ve okuma hızıdır.

İkinci hız sınıfı ise UHS'dir. Bu hız sınıfında U harfi içerisinde 1 ve 3 harfleri, sırası ile 10MB/s ve 30MB/s minimum yazma hızına tekabül etmektedir.

Üçüncü hız sınıfı Video Hız Sınıfıdır. Bu hız sınıfı V harfinin sağ yanına gelen 6,10,30,60 ve 90'dan oluşmaktadır. Bu hız sınıfında yine sırası ile 6MB/s, 10MB/s, 30MB/s, 60MB/s ve 90MB/s minimum yazma hızı ile standart hale getirilmiştir [17].

2.1.4. Güç Ünitesi

Güç ünitesi, Li-Po pil ve şarj ünitesinden oluşmaktadır. Li-Po terimi Lityum Polimer kelimelerinin kısaltmasından oluşmaktadır. Sıvı elektrolit kullanımı yerine polimer elektroliti kullanılan bu pil türü şarj edilebilir hücrelerden oluşmaktadır. 1S, 2S, 3S, 4S, 5S VE 6S türleri mevcuttur. Li-Po pillerde her S 3.7V gerilim değerini gösterir. Üzerlerinde bulunan C değeri ise maksimum akımı belirler. Örneğin 2S 1000mAh 10C etiketine sahip bir Li-Po pil 7.4V gerilim ve 10A akım değerlerine sahiptir. Bu çalışmada FATC için kullandığımız plastik kutu ebatları göz önünde bulundurularak 3.7V 450mAh'lık piller kullanılmıştır. Şekil 2.9'da görülen TP4056 Mikro USB 3.7 V 1S Li-Po şarj ünitesi uygun fiyat ve ebatları itibari ile güç ünitesinin diğer kısmını oluşturmuştur. Bu çalışmada şarj ünitesi cihazın içine yer almayıp ayrı bir aparat olarak tasarlanmıştır. Böylece ebat ve ağırlıktan tasarruf edilmiştir. Şarj kısmı için 3.5 mm dişi ve erkek stereo jack kullanılmış böylece farklı gerilim ve akım değerlerine sahip şarj aletlerinin yanlışlıkla FATC takılması zorlaştırılmıştır. Ayrıca stereo jack sayesinde ileride eklenebilecek farklı sensör ve benzeri geliştirmeler için cihaza ilave bağlantı noktası sağlanmıştır.



Şekil 2.9 TP4056 LiPo Pil Şarj Devresi


Donanım tasarımı sırasında Li-Po pilin cihaz aktifken veya mikrokontrolör güç katı üzerinden şarjının pilin gömülü şarj ünitesinin bulunmasına rağmen, pile ve mikrokontrolöre zarar verdiği görülmüş tasarıma Şekil 2.10'daki FACT genel bağlantı şemasında da görülebileceği gibi üç bacaklı toggle anahtar eklenerek cihaz çalışır durumda iken şarj edilmesi engellenmiştir.

2.1.5. FATC Donanımı Montajı

FATC genel bağlantı şeması Şekil 2.10'da görülmekle birlikte ESP-32 geliştirme kartlarının diğer muadilleri kadar tek düze olmadığı ve bağlantı ve pin yapısı olarak kart üreticilerine göre değişiklik gösterdiği sürekli göz önünde bulundurulmalıdır. İlgili şekillerde (2.4 ve 2.10) parlak gümüş renkli gözükten ESP-32 mikrodenetleyicinin kendisidir. Ancak mikrodenetleyiciler tek başına (stand alone) çalışabilen devre elemanları değildir. Başta osilatör, gerilim regülatörü ve programlama ara birimleri olmak üzere çeşitli çevre birimlere ihtiyaç duyarlar ilgili şekillerde (2.4 ve 2.10) ESP-32'nin altında siyah renkte görülen kart, geliştirme kartı olarak adlandırılır ve ESP-32'nin programlanıp çalışabilmesi için gerekli çevre birimleri içerir. Geliştirme kartı seçilirken, çektiği akım, desteklediği maksimum akım, regülasyon değerleri, ebat, ağırlık gibi verilere dikkat edilmelidir. Tablo 2.3'te FATC güç tüketim değerleri görülmektedir

Tablo 2.3 FATC Güç Tüketim Değerleri

Cihaz	Akım	Gerilim	Güç Tüketimi
Esp-32	150mA	3.3V	495mW
ADXL345	25uA	3.6V	0.09mW
SD Kart	150uA	3.3V	0.495mW
Toplam			495.585mW



Şekil 2.10 FATC Genel Bağlantı Şeması


Şekil 2.11’de cihazın son hali görülmektedir. Şekilde görülen siyah lastik bandın uç bölümüne plastik kemer tokası dikilerek cihazın, sakral dorsal bölgeye (S1 seviyesi) sabitlenmesi sağlanmıştır. Aynı şekilde, 2.1.4 Güç Ünitesi bölümünde bahsi geçen 3.5

stereo jack TP4056 Li-Po pil şarj ünitesine monteli ayrı bir ünite olarak görülmektedir. Şekildeki mini USB – USB kablo yardımı ile herhangi bir kaynaktan rahatça şarj edilebilmektedir.



Şekil 2.11 FACT ve Şarj Ünitesi Kullanıma Hazır Hali

Şekil 2.12’de ise FATC donanımının kutu içerisindeki montajlı hali görülmektedir.



Şekil 2.12 FATC İç Görünümü

2.2. FATC Yazılımı

Fiziksel Aktivite Tespit Cihazı yazılımının akış diyagramı Şekil 2.13’de görülmektedir.


2.2.1 FATC SD Kart Yazılımı

Yazılım aşamasında ekstra dikkat edilecek unsurlardan ilki SD kart tanıma bölümüdür. Yaptığımız denemelerde ESP-32’nin üretici firması olan Espressif’in SD kart kütüphanesi haricindeki kütüphanelerin bazı çalışmalarda kullanıldığı görülse de bu çalışmada işlevsiz görülmüştür [18] [19]. Diğer kütüphanelerin SDHC türündeki kartları tanımaması SDXC türündeki kartların da hafıza boyutlarını zaman zaman yanlış algılaması sorunları ile karşılaşmıştır. ESP-IDF programındaki örnek kodların kullanılması ise bir diğer önemli etkidir. Bu kodlar yardımı ile yaptığımız çalışmalarda SD kart kaynaklı sorunların sıfıra yaklaştığı görülmüştür.

2.2.2 ADXL345 Verilerinin SD Karta Aktarımı

Tamponlama (buffering) işlemi verilerin önce geçici bir bellekte saklanıp daha sonra toplu halde gönderilmesi olarak özetlenebilir. Bu işlem özellikle sensörlerden uzun süreli veri toplama işlemlerinde elzemdir ve benzer çalışmalarda da kullanılmıştır [20]. Tamponlama işlemi yapılmaması durumunda, yazılım aşamasında karşılaşılabilecek önemli bir sorun SD kartın, uzun veri toplama çalışmalarında bozulacak olmasıdır. SD kartların Lifespan olarak adlandırılan bir okuma/yazma ömrü vardır. Bu ömür marka, model, kart türü, kullanılan teknoloji, hafıza boyutu gibi değişkenlere bağlı olmakla birlikte ortalama 100 000'dir [21]. Zaman, X, Y ve Z bilgilerinin 4Hz ile sürekli yazılması kartın kullanım ömrünü 6.94 saat içerisinde bitirecektir. Bu sorunun çözümü verilerin diziler halinde tamponlanmasıdır. Şekil 3'ün sol alt kısmında da görülebileceği üzere tüm dizilerin tek bir değişkene atanıp, bu değişkenin SD karta yazdırılması kullanım ömrünü önemli ölçüde arttırmıştır. Bu yöntem ile 240 veri her 15 saniyede bir atandığından kartın kullanım ömrü 416,6 saate çıkmıştır.

Tamponlama işlemi de yazılımda sorun oluşturabilecek diğer bir husustur. Bu sorunun iki ayağı vardır. Birincisi tamponlama işleminin gereğinden uzun yapılması durumunda son veri bloğunun kaybolacağı ve cihazın gerçekte olduğundan daha az FA bildirecek olmasıdır [22]. Diğer sorun ise ESP-32 ile ilgilidir. Tamponlama işlemi sırasında kullanılan hafıza oranı belli bir boyutu aştığında verilerin karıştığı, programda kullanılan değişken değerlerinin bile tutarsızlaştığı görülmüştür.



Şekil 2.13 FATC Program Akış Şeması

2.3. YAPAY ZEKÂ

“Makineler de öğrenebilir mi?” sorusu günümüzde gerek bilim kurgu filmlerinde gerekse tartışma programlarında konu alınsa da günümüzden tam 72 yıl önce sorulmuştur. Yapay zekâ ile ilgili bilinen ilk yayın 1950 yılında Mind dergisinde yayınlanan “Computing Machinery and Intelligence” (Bilgisayar Makineleri ve Zekâ) adlı makaledir. Makalede “Makineler Düşünebilir mi?” sorusu ilk kez bilim dünyasının gündemine sokulmuştur [23]. Bilgisayar Makineleri ve Zekâ isimli makalesinde Alan Turing “Imitation Game” (Taklit Oyunu) ismini verdiği oyununu üç kişiden oluşturmuştur [24]. Taklit oyunundaki oyuncular, ilki erkek (A), ikincisi kadın (B) ve üçüncüsü sorgulayıcı (C) olarak tasvir edilmiştir. Sorgulayıcı oyuncu diğer ikisini göremeyeceği bir yerde bulunur. Sorgulayıcı oyuncunun, sorduğu sorulara Erkek ve Kadın oyuncu ses tonlarında kimin cevap verdiğinin anlaşılabilmesi için sözlü değil yazılı olarak cevap vermektedir. Verilen yazılı cevaplardan C oyuncusu hangi cevabın kime ait olduğunu tahmin etmeye çalışmaktadır. Oyunda Erkek (A) oyuncunun hedefi sorgulayıcı olan (C) oyuncusunu yanıltmaktır. Kadın (B) oyuncunun hedefi ise sorgulayıcı oyuncuya yardımcı olmaktır. Alan Turing'in bu oyundaki amacı kişilere bir makine eklenirse C kişinin bunu tespit edip edemeyeceği sorusudur [25]. Makinelerin öğrenmesi üzerine ortaya konan bu çalışma yapay zekâ çalışmalarının ilki olarak kabul görür.

Beş yıl sonra ise John McCharthy “A proposal for the dartmouth summer research project on artificial intelligence” (Yapay zekâ üzerine dartmouth yaz araştırma projesi için bir öneri) adlı makalesinde ilk kez yapay zeka terimini kullanarak bu terimi literatüre sokmuştur [26]. Ancak kendisi de "What is Artificial Intelligence? " (Yapay Zekâ Nedir?) adlı makalesinde yapay zekâ üzerine çalışma yapan ilk kişinin Alan Turing olduğuna vurgu yapmıştır. Ayrıca yapay zekânın makineler yapmanın değil de özel programlanmış işlemciler ile araştırma ve karar verme mekanizmaları oluşturulabileceği konusunun öncüsünün de Alan Turing olduğunu da açıkça ifade etmiştir [27]. Yapay Sinir Ağlarının (YSA) temelini oluşturan “The perceptron: a probabilistic model for information storage and organization in the brain”(Algılayıcı: beyinde bilgi depolama ve organizasyon için olasılıksal bir model) makalesi 1958 yılında Frank Rosenblatt tarafından yayınlanmıştır [28]. “Perceptron” algılayıcı anlamına gelmekte olup bir katmanlı olan YSA'nın en temel birimini oluşturmaktadır. Başka bir deyiş ile eğitilebilecek en küçük yapay sinir hücresidir.

Minsky'nin XOR problemi 1969 yılında, tek katmanlı ağ yapılarının bu tür

problemlere çözüm üretilmesinde yetersiz kaldığını göstermiştir. Böylece çok katmanlı yapay sinir ağı mimarilerinin temelini atmıştır [29]. Yapay zekânın kendisine verilen veri ile yeni bilgiler edinebileceği veya kararlar verebileceği 1987 yılında Plaut ve Hinton'un "Learning sets of filters using back-propagation" (Geri yayılım kullanan filtrelerin öğrenme setleri) isimli çalışması ile ortaya atılmıştır [30]. Bu çalışma ile ortaya atılan yayılım algoritması, tahmin ve/veya öğrenme başarısını önemli oranda arttırıp, bilimsel alanda kabul edilebilir rakamlara ulaştırmıştır. Bugün kullandığımız yapay zekâ algoritmalarının temelini ise 1998 yılında "Evaluation of convolutional neural networks for visual recognition" (Görsel tanımlama için evrişimli sinir ağlarının değerlendirilmesi) adlı makaledeki evrişimli sinir ağları modeli oluşturmaktadır. Bu çalışma ile rakamları sınıflandıran bir model geliştirilerek yüksek oranda tahmin ve eğitim başarısı sağlanmıştır [31].


167 farklı ülkenin ortaklığı ile "IMAGENET" veri setinin 2009 yılında herkese açılmasıyla ve mikroçip teknolojilerindeki hem hız hem de erişilebilir fiyat yönündeki gelişmeler yapay zekâ algoritmalarında kullanılan karmaşık matematik fonksiyonlarını hızlı bir şekilde çözülebilir hale getirmiş ve böylece gelişmiş ve endüstriyel yapay zeka çalışmalarının önünü tamamen açmıştır [32].

Yapay zekânın genel kabul görmüş kesin bir tanımı olmamakla birlikte, gelişmiş canlılara özgü öğrenme özelliğini taklit edebilen, geçmiş bilgileri kullanıp yeni bilgiler öğrenebilen ve edindiği yeni bilgileri yorumlayıp sonuçlar üretebilen akıllı algoritma sistemleri olarak tanımlanabilir. "LISP" yapay zekâda kullanılan programlama dillerinden biridir. LISP dilini geliştiren John McCarthy, eş zamanlı erişim sistemi ile bugünkü bulut ile sunucu sistemlerinin temellerini atmış ve "yapay zekâ" terimini ilk olarak kullanan kişi olmuştur. "What is Artificial Intelligence?" adlı makale 2004 yılında yayınlanmıştır. Yapay zekayı "Akıllı makineler, özellikle akıllı bilgisayar programları yapma bilimi ve mühendisliğidir." olarak tanımlamaktadır [33]. Yapay zekânın öncüleri John McCarthy ve M. Lee Minsk'e göre ise "yapay zeka insanlar tarafından yapılabilen ve zeka gerektiren şeyleri makineler yapma bilimidir" [34].

2.3.1 Yapay Sinir Ağları

Şekil 2.14'teki gibi canlılarda bulunan sinir hücreleri, temel olarak çekirdek, dentrit ve aksonlardan oluşmaktadır. Dentritler sensör görevi görerek bilgi toplar, gelen bilgiler çekirdeğe aktarılırak burada işlenir, bu bilgiler daha sonra akson aracılığı ile diğer sinirlere


aktarılır.



Şekil 2.14 Biyolojik Sinir Hücre Modeli


Yapay sinir ağları, canlı sinir sistemlerinde bulunan sinirlerin çalışma mekanizmasını taklit eden algoritmalara verilen addır. Bu ağlar, canlı sinir ağlarındaki gibi birbirlerine sinaps benzeri sistemler ile bağlı yapay nöronlardan meydana gelmektedir. Her bir nöron arasında, o nörondan diğerine bilgi taşıyan bağlantılar mevcuttur. Bilgiyi alan nöron sorumlu olduğu işlemi yaparak, işlenmiş bilgiyi sıradaki nörona aktarır [35].

Şekil 2.15'te bir sinir hücresinin matematiksel olarak modellenmiş hali görülmektedir. Modelde girişe gelen X_i değeri dentritlerden ya da bir önceki hücreden gelir. Dentrit kısmında bulunan W_i değeriyle çarpılır, W_i ağırlık değeridir. Elde edilen değer sinirin hücre bölümüne iletilir. Çekirdekte dentritlerden gelen bütün verilerin X ve W çarpımları toplanır. Çarpım değerlerinin toplamına " b " değeri eklenir. b değeri eklenmiş sonuç bir fonksiyonundan geçirilir ve sonra çıkış aksonuna gönderilir. Gönderilen değer bir diğer nöronun girişi ya da sonuç olur [36].




Şekil 2.15 Sinir Hücresi Matematiksel Modeli

Tüm nöronlar bu fonksiyonları yerine getirir. Yapay sinir ağındaki nöronların tamamı birbirlerine bağlıdır. Bu durum Şekil 2.16’da gösterilmiştir. Yapay sinir ağlarının katmanları; giriş katmanı, gizli katman ve çıkış katmanı olmak üzere üç çeşittir. Bir modelde birer adet giriş ve çıkış bulunuyor ise bu model tek katmanlı olarak isimlendirilir. Katman sayısının birden fazla olduğu modeller ise çok katmanlı olarak isimlendirilir. Çok katmanlı olan yapay sinir ağlarına literatürde multilayer perceptron (MLP) adı verilmektedir. MLP’ler birbirlerine bağlanma türlerine göre ayrıca birçok sınıfa ayrılmaktadır. Veriler, giriş katmanından yapay sinir ağlarına girer. Veriler daha sonra gizli katmanda sinir ağı matematiksel modelinden de hatırlanabileceği üzere ağırlıklar (W) ile çarpılır. Elde edilen yeni veri aktivasyon fonksiyonundan geçer. Gizli katmandan geçerek çıkış katmanına ulaşan veriler bu katmanda sonuca dönüşür [37].



Şekil 2.16 Yapay Sinir Ağı Genel Modeli

Fark ROSENBLATT’ın “Perceptron” modeli yapay sinir ağının matematiksel modeli Şekil 2.17’de görülmektedir.



Şekil 2.17 Perceptron modeli

Perceptron modelinin matematiksel fonksiyonu aşağıdaki denklem 2.4'te görülmektedir.

$$y = f\left(\sum_{i=0}^n (x_i w_i) + b\right) \quad 2.4$$

2.4 numaralı formülde; “y” çıkış “x” giriş “w” ağırlık çarpanı ve “b” bias fonksiyonlarının sembolleri olarak kullanılmıştır [38].

2.3.2 Makine Öğrenmesi

Yapay zekâ çalışmalarının ve sanal oyun alanının öncülerinden olan Arthur Lee Samuel Makine Öğrenmesi terimi "IBM Journal of Research and Development" dergisinde 1959 yılında yayınlanan "Some Studies in Machine Learning Using the Game of Checkers" (Dama Oyunu Kullanılarak Makine Öğreniminde Bazı Çalışmalar) isimli makalesinde ilk olarak kullanan kişidir [39]. Makalesinde dama oyununun bazı özellikleri üzerinden makine öğrenmesinin yol ve yöntemlerini araştırmış, yazılımın oyunun kurallarının verilmesiyle o dönem koşullarıyla görece kısa zamanda öğrenmekle kalmayıp bilgisayarın oyunu, oyunun kendi yazılımcıdan daha iyi oynadığını doğrulamıştır. Aynı çalışmada, başarılı fonksiyonların, başka işlevlerde de kullanılabileceğini belirtmiştir [40].

Makine öğrenmesi, yapay zekânın alt dallarından biridir. Makine öğrenmesi, bilgisayar sistemlerinin, geçmiş veri tecrübeleri yardımıyla, performanslarını otomatik

olarak geliřtirmesini hedefler. G n m zde, makine  ğrenmesi algoritmalarının,  eřitli alanlar i in  zel geliřtirilmiř bir ok s r m  mevcuttur. Hepsinin de temel amacı daha iyi  ğrenme y zdelerine sahip ve daha yetenekli sistemler geliřtirmektir [41].

Uzun vadede makine  ğrenmesi teknolojisinin, standart yazılımcılığ  g re  ok daha avantajlı olacağı  n g r lmektedir. Klasik programlarının aksine, makine  ğrenmesi temelli sistemler deneyimle s rekli olarak geliřip, yeni bir yazılımı t r ne evrilebilirler. Makine  ğrenimi arařtırmalarının teknolojik geliřimler ve bu alandaki ilerlemelerin de desteğı ile  alıřmayı  ğrenen robotlar dıřında kendi kendini programlayabilen bilgisayar sistemleri de  retebileceğı  n g r lmektedir.

Makine  ğrenimi arařtırmasının ana amacı,  ok  eřitli bilgisayar uygulamaları i in etki alanından bağımsız bir etkinleřtirme teknolojisi  retmektir. Makine  ğreniminde yařanabilecek basit bir atılım, robotik, bilgisayar destekli tasarım, akıllı veri tabanları ve bilgi tabanlı danıřmanlık gibi  ok geniř yelpazedeki uygulamalarda  nemli bir etkiye sahip olabilir. Bilgisayar d nyasındaki bir ok uygulaması giderek daha fazla bilgi ve database gereksinimi doğurmaktadır. Makine  ğrenimi, performansı sınırlayan ve geliřtirmeyi yavařlatan bu durumu ortadan kaldırma potansiyeli sunar [41]. Bu t r sistemler i in maliyetlerin ve gerekli kalifiye insan g c n n d ř r lmesinde  ok etkili bir y ntemdir ve geliřmelerle verimliliğı katlanarak artmaktadır.

2.3.2 Makine  ğrenmesi Metotları

Makine  ğrenmesinin temel olarak d rt metodu mevcuttur. Bunlar:

- Denetimli  ğrenme
- Denetimsiz  ğrenme
- Yarı-Denetimli  ğrenme
- Takviyeli  ğrenme


Denetimli  ğrenme: Etiketlenmiř veri k melerinin, verilerin sınıflandırılması yada sonu ların doğru bir řekilde tahmin edilmesi i in, YSA'da kullanılan algoritmaları eğıtmek i in kullanılmasıyla oluřan makine  ğrenmesi metodudur. Bu modelde girdi verileri ile model beslenir ve eğıtim bařlatılır.  apraz doğrulama s recinin sonucunda model verilerin ağırlıklarını ayarlar daha sonra ise s recin t r ne g re sınıflandırma yada regresyon s reci

başlar [42].

Denetimsiz Öğrenme: Bu metotta veri kümeleri denetimli öğrenmenin aksine etiketlenmez. Etiketlenmemiş veri kümelerini analiz etmek ve kümelemek için daha farklı makine öğrenimi algoritmalarını kullanılır. Bu algoritmalar, insan müdahalesine ihtiyaç duymadan gizli yapıları veya veri kümelerini keşfeder. Bilgilerdeki benzerlikleri ve farklılıkları keşfetme yeteneği, denetimsiz öğrenme metodunu keşifsel veri analizi (exploratory data analysis), çapraz satış stratejileri, müşteri sınıflandırması ve görüntü tanıma için ideal çözüm haline getirir [43].

Yarı Denetimli Öğrenme: Bu metotta, belirli öğrenme görevlerini gerçekleştirmek için hem etiketlenmemiş veriler hem de etiketli veriler kullanılır. İsminden de anlaşılacağı üzere denetimli ve denetimsiz öğrenme arasında konumlanmış olup, birçok kullanım durumunda mevcut olan büyük miktarda etiketlenmemiş verinin, tipik olarak daha küçük etiketli veri kümeleriyle birlikte kullanılmasına izin verir [44].

Takviyeli Öğrenme: Hem fen hem de sosyal bilimlerde ve mühendislikte çok çeşitli alanlarda ardışık karar verme problemleri için, deneme yanılma yoluyla, çevre ile etkileşime giren, optimal öğrenen bir makine öğrenmesi metodudur [45]. Takviyeli öğrenmede de bir eğitmen bulunur ancak denetimli öğrenme metodundaki gibi çok veri içermez. Bunun nedeni genellikle yeterli verinin bulunmaması veya eldeki verilerin güvenilirlik kat sayılarının düşüklüğüdür. Bunun yerini takviyeli öğrenmede, sistem bir karar verdiğinde bu kararın doğru olduğu durumlar için sisteme pozitif veya kararın yanlış olduğu durumlar için negatif geri besleme yapılır.



Şekil 2.18 Makine Öğrenmesi Metotları

2.3.3 Yapay Sinir Ağı'nın Eğitilmesi

Yapay Sinir Ağı'nda bulunan tüm sinir ağı yapılarında ağırlık değerleri bulunur. YSA'nın eğitimi, aktivasyon fonksiyonları ve bias (b) katsayılarının bulunması için yapılan işlemlere verilen addır. Eğitim için öncelikle veri setinde ait yerel minimumun değerinin bulunması gerekmektedir. Yerel Minimum hesaplamada kullanılan birçok farklı yöntem vardır. Newton algoritmasının farklı bir versiyonu olan LM algoritması yapay sinir ağlarının, ileri beslemeli geriye yayımlı algoritmalar kategorisinde yer almaktadır. LM algoritmasının avantajları hızlı işlem hızı, kendi içerisinde az parametre gereksinimi ve türev olarak sadece birinci dereceden kısmi türevleri kullanmasıdır [46]. Tüm bu sebepler ile bu çalışmada tercih ettiğimiz Levenberg-Marquardt'ın formülü 2.5'te görülmektedir.

$$\Delta w = (J^T J + \mu I)^{-1} J^T e \quad (2.5)$$

Formülde "w" "ağırlık vektörünü," "I" birim matrisini," μ ise kombinasyon katsayısını temsil etmektedir." e" değeri için gerekli olan denklem 2.7'de görüldüğü üzere hata matrisi ve "J" (denklem 2.6'da görülmektedir) ise Jakobien matrisini ifade etmektedir. Denklem, hata matrisinin birinci derece türevlerinden oluşmaktadır [46].


$$J = (PxM)xN \quad (2.6)$$

Denklem 2.6’da “P” eğitim örnek sayısını, “M” çıkış sayısını, “N” ise gizli katman nöron sayısı temsil eder.

$$e = (PxM)xI \quad (2.7)$$

Denklem 2.7’de “P” eğitim örnek sayısını, “M” çıkış sayısını, “I” ise birim matris hata vektörünü temsil etmektedir.

“μ” Marquardt parametresini sembolize eder. “μ” değeri Levenberg-Marquardt yönteminde herhangi bir ilk değer seçilerek kullanılmaya başlanan ancak her bir iterasyonda güncellenip değişen bir parametredir. “μ” parametresi, çok küçükse yöntemin Newton metodu benzeri, çok büyükse ise dik iniş metodu benzeri davranmasını sağlamaktadır [47].



Şekil 2.19 LM metodunda Marquardt parametresinin etkisi

2.3.5 FATC Veri Setinin Oluşturulması

Veri seti oluşturulmasında hazırlamış olduğumuz Matlab fonksiyonları ile Matlab’a aktarılan verilerin etiketlenmesi sağlanmıştır. Ayrıca farklı bir fonksiyon yardımı ile elde FATC’den elde edilen -512 + 512 aralığındaki verilerin -1 ila +1 arasına dizimi işlemini de yapılmıştır. Normalizasyon işleminden sonra elde edilen yeni verilerin özelliklerini üretmek için yine bir matlab fonksiyonundan yararlanılmıştır. Veri özelliklerini üretmede ilk önce verilerin, karekök ortalaması (RMS) sonra ise dalga boyu (WL) kullanılmıştır. Bu işlem ile ilgili formüller denklem 2.8 ve 2.9’da görülmektedir [48].

$$x_{rms} = \sqrt{\frac{\sum_{i=1}^n x_i^2}{n}} \quad (2.8)$$

$$x_{wl} = \sum_{i=1}^n |x_i - x_{i-1}| \quad (2.9)$$

3. EĞİTİM VE TEST VERİLERİNİN ELDE EDİLMESİ

FATC çalışmamızda denetimli öğrenme metodu ile sınıflandırma yapılacağı için öncelikle eğitim verilerinin kendi tasarladığımız cihaz ile toplanıp denenmiştir. Daha sonra bir kronometre yardımı ile test verileri alınmış ve sisteme sokulmuştur.


3.1. Verilerin Toplanması

Eğitim için kullandığımız veriler 9 ayrı kişiden toplanmıştır. Boy, kilo, yaş, cinsiyet gibi özellikleri tablo 3.1’de yer almaktadır.

Tablo 3.1 Eğitim Verileri Toplanan Kişilerin Fiziksel Özellikleri

Kişi	Cins.	Boy	Kilo	Yaş
1	E	179	85	38
2	K	167	60	38
3	E	186	80	17
4	E	175	76	17
5	E	170	65	18
6	E	180	92	18
7	E	176	70	18
8	E	168	81	41
9	K	160	50	36

Veriler şekil 3.1’de solda açık ortamda veri toplanması ortada kapalı ortamda veri toplanması ve sağda koşu bandında veri toplanması olmak üzere üç farklı fiziksel ortamda veri toplanmıştır.



Şekil 3.1 Eğitim Verilerinin Toplanması

Tezimizde 7 tür fiziksel aktivite üzerinde çalışma yapılmıştır. Bunlar;

1. Yüksek Tempo Koşma (8.5Km/Saat),
2. Orta Tempo Koşma (7.2Km/Saat),
3. Düşük Tempo Koşma (6.2Km/Saat),
4. Yüksek Tempo Yürüme (5Km/Saat),
5. Orta Tempo Yürüme (3.5Km/Saat),
6. Düşük Tempo Yürüme (2.5Km/Saat),
7. Oturmadır.


Fiziksel aktivite türlerinin sınıflandırılmasında bir çok ayrı görüş ve değer olmakla birlikte, yukarıda belirttiğimiz km/saat cinsinden değerleri Beşiktaş spor akademisi eğitmenlerinden ve “Walking, running, and resting under time, distance, and average speed constraints: optimality of walk–run–rest mixtures” (Yürüme, koşma ve dinlenmenin zaman, mesafe ve ortalama hız değişkenleri altında: yürüme koşma ve dinlenme veri karışımlarının optimalliği) isimli makaleden elde ettiğimiz bilgiler ışında karar verilmiştir [49].

Tablo 3.2 Kişi – Veri Türü

Kişi/Veri	YTK	OTK	DTK	YTY	OTY	DTY	Oturma
1		+	+	+	+	+	+
2			+	+	+	+	+
3	+	+	+	+	+	+	+

4	+	+	+	+	+	+	+
5	+	+	+	+	+	+	+
6	+	+	+	+	+	+	+
7	+	+	+	+	+	+	+
8	+	+	+	+	+	+	+
9			+	+	+	+	+

Tablo 3.2’de hangi kiřiden hangi verilerin alındığı görölmektedir. Özellikle YTK verilerinin toplanmasında herkesin bu veri türü için yeterli olmadığı görölmüřtür. Eğitim verileri 5’er dakikalık test verileri ise 1’er dakikalık setler halinde toplanmıřtır.



řekil 3.2 Test Verilerinin Kořu Bandı Yardımıyla Alınması

řekil 3.2’de Test verilerinin elde edilmesi görölmektedir. Buradaki deney düzeneğinde FA ham verilerinin daha doğru toplanması için hız ve eğim ayarlı kořu bandı

kullanılmıştır. Test verileri YSA’da hiçbir şekilde eğitim verisi olarak kullanılmamıştır. Böylece doğruluk oranı daha gerçekçi bir şekilde bulunmuştur.

3.2. Eğitim Verilerinin Test Edilmesi

Çalışmamızda deneklerden ham veriler 5’er dakikalık eğitim setleri ve 1’er dakikalık test verileri olarak toplanmıştır. Özellikle 5 dakikalık eğitim verilerinin elde edilmesi sırasında gönüllülerin, yorgunluk, cep telefonuna bildiri gelmesi, çevresel uyarıcılar ve dikkat dağılması gibi nedenlerle tempo ve hızlarının değiştiği görülmüştür.

Hiçbir eleme yapılmadan tüm veriler YSA’ya sokularak ilk eğitim gerçekleştirilmiştir. Ancak veri kaynağının insan olmasından kaynaklı oluşan hataları elemine etmek için eğitim verilerinin doğrulanması adına bu veriler sistemde test edilerek doğruluk oranları tespit edilmiştir. Doğruluk oranı düşük verilerin test sonuçları kontrol edildiğinde olgunun veri toplama süresinde sabit hareket edemediği, örneğin orta tempo yürüme verisinin toplandığı süreçte yüksek tempo ya da düşük tempo yürüme gibi bir üst ya da bir alt seviyedeki fiziksel aktiviteyi gerçekleştirdiği görülmüştür. Doğruluk oranı %50’nin altındaki eğitim verileri sistemden çıkarılarak eğitim çalışması tekrar yapılmıştır. Bu çalışma sonucunda daha yüksek doğruluk oranı yakalanmıştır.

3.2. Eğitimin Gerçekleştirilmesi

FATC tarafından toplanan ham veriler YSA eğitiminden önce Matlab tarafından daha kolay işlenebilmesi için -1 ile +1 aralığına eşitlenmiştir. Normalize edilen bu verilerin RMS ve WL değerleri hesaplanmıştır. RMS ve WL değerlerin hesaplanırken örnekleme alanı 48 değerden oluşturulmuştur. Daha sonra örnekleme alanı 24 veri atlanarak eğitim veri setinin %70’ini kapsayacak şekilde tekrarlı olarak hesaplanmıştır.

Yapay sinir ağının eğitiminde, iki katmanlı ve ileri beslemeli bir Neural Net kullanılmıştır. Verilerin sınıflandırılması işlemi için programda bulunan Neural Net sınıflandırma aracından yararlanılmıştır. Veri eğitimi sonucunda Şekil 3.3’te verilmiş olan hata matrisi ile verilmiş olan sınıflandırma başarısına ulaşılmıştır.


Training Confusion Matrix								
Output Class	1	2	3	4	5	6	7	
	237 11.6%	29 1.4%	4 0.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	87.8% 12.2%
	41 2.0%	252 12.4%	30 1.5%	12 0.6%	0 0.0%	0 0.0%	2 0.1%	74.8% 25.2%
	0 0.0%	18 0.9%	176 8.6%	14 0.7%	1 0.0%	0 0.0%	0 0.0%	84.2% 15.8%
	2 0.1%	21 1.0%	27 1.3%	277 13.6%	13 0.6%	5 0.2%	12 0.6%	77.6% 22.4%
	0 0.0%	0 0.0%	3 0.1%	7 0.3%	237 11.6%	35 1.7%	12 0.6%	80.6% 19.4%
	0 0.0%	0 0.0%	0 0.0%	10 0.5%	29 1.4%	280 13.7%	14 0.7%	84.1% 15.9%
	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	240 11.8%	100% 0.0%
	84.6% 15.4%	78.8% 21.3%	73.3% 26.7%	86.6% 13.4%	84.6% 15.4%	87.5% 12.5%	85.7% 14.3%	83.3% 16.7%
		1	2	3	4	5	6	7
		84.6% 15.4%	78.8% 21.3%	73.3% 26.7%	86.6% 13.4%	84.6% 15.4%	87.5% 12.5%	85.7% 14.3%

	1	2	3	4	5	6	7	
1	10 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	9 12.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
3	0 0.0%	1 1.4%	10 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	90.9% 9.1%
4	0 0.0%	0 0.0%	0 0.0%	8 11.4%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
5	0 0.0%	0 0.0%	0 0.0%	2 2.9%	9 12.9%	0 0.0%	0 0.0%	81.8% 18.2%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 1.4%	10 14.3%	0 0.0%	90.9% 9.1%
7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10 14.3%	100% 0.0%
	100% 0.0%	90.0% 10.0%	100% 0.0%	80.0% 20.0%	90.0% 10.0%	100% 0.0%	100% 0.0%	94.3% 5.7%
	1	2	3	4	5	6	7	

Şekil 4.1 Test Hata Matrisi

Yapılan çalışmada karışan verilerin bir üst ya da bir alt FA'ya ait olduğu görülmektedir. Bunun temel nedeni insan faktörüdür. Hızlanma ya da yavaşlama sırasında yapılan hareket ara sınıf olduğu için YSA bu hareketleri karıştırmaktadır. Deneklerin zaman içerisinde hareketlerindeki değişimlerden kaynaklı veriler karışmaktadır. Şekil 4.1'de hangi veri sınıflarının karıştığı görülmektedir. Örneğin yüksek tempo koşu sınıflandırma sırasında 41 veride Orta tempo koşu ile 2 veride ise yüksek tempo koşu ile karışmıştır. Ayrıca veri elde edilmesi sırasında özellikle boy faktörünün veri türünü etkilediği görülmüştür.

Şekil 4.2’de ise karışma zaman aralıkları görülmektedir. Özellikle bir fiziksel aktiviteden diğerine geçilirken hareket hızının aşağı ya da yukarı ivmelenmesi sırasında oluşan ara değerler istenen ile elde edilen değerlerin eşit olmamasına neden olmuştur.



Şekil 4.2 Test Doğruluk Karşılaştırma Eğrisi

Cihazın toplam maliyeti ise piyasada bulunan ürünlere oranla oldukça düşüktür. Piyasada standart olarak kullanılan ürünler seçildiğinden fiyat çok makul çıkmıştır. Ayrıca ürünlerin perakende alımda daha pahalı olduğu, toplu alımlarda hem yerli firmalarca daha yüksek iskonto yapıldığı hem de birim adedi belli bir sayıyı geçtiğinde yurt dışından alımlarda bayi fiyatı uygulandığı göz önünde bulundurulur ise maliyetin daha da aşağı çekilebileceği görülmüştür. Tablo 4.1’de maliyet tablosu görülmektedir.

Tablo 4.1 FATC Maliyet Tablosu

Ürün	Birim Fiyat	Adet	Maliyet
ESP-32	150	1	150
ADXL345	60	1	60
SD Kart Modülü	20	1	20
SD Kart (32Gb)	90	2	180
Plastik Kutu	15	1	15
Toplam Maliyet			425₺

Gelecek alıřmalarda daha fazla eęitim verisi ve elektronik spor aletleri yardımı ile cihazın sınıflandırabildięi fiziksel aktivite türleri arttırılabilir. Ayrıca cihaza solunum, nabız gibi ilave algılayıcılar eklenerek ivmeöler verileri ile kolerasyonu incelenerek daha yüksek eęitim ve test başarısı saęlanabilir. Ancak bu sensörlerin eklenmesinin cihazın kullanılabilirliğini düşürebileceęi de göz önünde bulundurulmalıdır. Özellikle 65 yař üstü bireylerde eklenecek her ek aparatın kullanıcı kaynaklı sorunları arttıracağı ön görölmektedir. Ayrıca eęitim verilerinin alınması sırasında sadece profesyonel sporcuların kullanılması ve veri toplanması sırasında hız ile nabız verilerinin alınması başarı oranını arttıracaktır.



KAYNAKLAR

- [1] World Health Organization (2020, Nov 26). Physical activity.<https://www.who.int/newsroom/factsheets/detail/physical-activity>.
- [2] Centers for Disease Control and Prevention (2022, June 16).<https://www.cdc.gov/physicalactivity/basics/pa-health/index.htm>.
- [3] Chen, V. C., & Chen, S. W. (2018). Establishing the waist as the better location for attaching a single accelerometer to estimate center of pressure trajectories. *Clinical Biomechanics*, 60, 30-38..
- [4] D.R. Bassett Jr, A.V. Rowlands, S.G. Trost, Calibration and validation of wearable monitors, *Med. Sci. Sports Exerc.* 44 (2012) S32–S38..
- [5] S.J. Strath, K.A. Pfeiffer, M.C. Whitt-Glover, Accelerometer use with children, older adults, and adults with functional limitations, *Med. Sci. Sports Exerc.* 44 (2012) S77–S85..
- [6] M. de Almeida Mendes, I.C.M. da Silva, V.V. Ramires, F.F. Reichert, R.C. Martins, E. Tomasi, Calibration of raw accelerometer data to measure physical activity: asystematic review, *Gait Posture* 61 (2018) 98–110..
- [7] Farrahi, V., Niemelä, M., Kangas, M., Korpelainen, R., & Jämsä, T. (2019). Calibration and validation of accelerometer-based activity monitors: A systematic review of machine-learning approaches. *Gait & posture*, 68, 285-299..
- [8] X. Janssen, D.P. Cliff, Issues related to measuring and interpreting objectively measured sedentary behavior data, *Meas. Phys. Educ. Exerc. Sci.* 19 (2015) 116–124..
- [9] Y. Kim, M.W. Beets, G.J. Welk, Everything you wanted to know about selecting the “right” Actigraph accelerometer cut-points for youth, but: a systematic review, *J.Sci. Med. Sport* 15 (2012) 311–321..
- [10] Toshiba (2022, 08 03) History of Microcontrollers <https://toshiba.semicon-storage.com/ap-en/semiconductor/knowledge/e-learning/micro-intro/chapter2/history-microcontroller.html>.
- [11] Dinçer, S. (2009). Dijital görüntü işleme teknikleri ile Matlab ve mikrokontrolör kullanılarak iki boyutlu görüntünün çizdirilmesi (Doctoral dissertation, Fen Bilimleri

Enstitüsü)..

- [12] O'Reilly (2022, 08 03) Arduino: A Technical Reference by J. M. Hughes
<https://www.oreilly.com/library/view/arduino-a-technical/9781491934319/ch01.html>.
- [13] ESPRESSIF (2022, 08 10),
https://www.espressif.com/sites/default/files/documentation/esp32_datasheet_en.pdf.
- [14] OMEGA (2022, 08 03) How to Measure Accelaration <https://www.omega.com/en-us/resources/accelerometers>.
- [15] Yüksekaya, M., Yayla, B., Menteş, M. M., & Haberal, O. E. (2019). Düşme Algılama Sistemi Tasarımı. Avrupa Bilim ve Teknoloji Dergisi, 361-366..
- [16] Songül, S. (2013). Tank namlusu stabilizasyon sisteminin arduino ile uygulanması ve deneysel düzeneğinin hazırlanması (Master's thesis, Trakya Üniversitesi Fen Bilimleri Enstitüsü)..
- [17] KINGSTON (2022, 08 03) SD ve microSD kartlar için Hız Sınıfları Kılavuzu
<https://www.kingston.com/tr/blog/personal-storage/memory-card-speed-classes>.
- [18] Babiuch, M., Foltýnek, P., & Smutný, P. (2019, May). Using the ESP32 microcontroller for data processing. In 2019 20th International Carpathian Control Conference (ICCC) (pp. 1-6). IEEE..
- [19] Allafi, I., & Iqbal, T. (2017, October). Design and implementation of a low cost web server using ESP32 for real-time photovoltaic system monitoring. In 2017 IEEE electrical power and energy conference (EPEC) (pp. 1-5). IEEE..
- [20] Mukati, M. R., Kocatürk, S., Kocatürk, M., & Baykaş, T. (2017, January). A microcontroller-based wireless multichannel neural data transmission system. In 2017 21st National Biomedical Engineering Meeting (BIYOMUT) (pp. i-iv). IEEE..
- [21] Zhang, T., Zuck, A., Porter, D. E., & Tsafirir, D. (2017, May). Flash drive lifespan* is* a problem. In Proceedings of the 16th Workshop on Hot Topics in Operating Systems (pp. 42-49)..
- [22] Vafeiadis, T., Nizamis, A., Alexopoulos, N., Ntinis, C., Mastos, T., Papadopoulos, A., ... & Tzovaras, D. (2018, September). Data analytics and data modeling for predictive maintenance and automated waste management: An integrated (IoT-Industry 4.0) senso.

- [23] Turing, A. M., & Haugeland, J. (1950). Computing machinery and intelligence. The Turing Test: Verbal Behavior as the Hallmark of Intelligence, 29-56..
- [24] P. H. Winston, "On Computing Machinery and Intelligence," Bost. Stud. Philos. Hist. Sci., vol. 324, pp. 265–278, 2017, doi: 10.1007/978-3-319-53280-6_11..
- [25] Gürsoy, G. (2022). Makine öğrenmesi algoritmaları ile kalp hastalığı tahmini (Master's thesis, Maltepe Üniversitesi, Lisansüstü Eğitim Enstitüsü)..
- [26] McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. AI magazine, 27(4), 12-12..
- [27] A. Entwistle, "What Is Artificial Intelligence?," Eng. Mater. Des., vol. 32, no. 3, pp. 1–14, 1988, doi: 10.7551/mitpress/12518.003.0004.
- [28] Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. Psychological review, 65(6), 386..
- [29] Minsky, M. L. and Papert, S. A., "Review of 'Perceptrons: An Introduction to Computational Geometry'", IEEE Press, 15 (6), 738-739, (1969)..
- [30] Plaut, D. C., & Hinton, G. E. (1987). Learning sets of filters using back-propagation. Computer Speech & Language, 2(1), 35-61..
- [31] Nebauer, C. (1998). Evaluation of convolutional neural networks for visual recognition. IEEE transactions on neural networks, 9(4), 685-696..
- [32] Yavuz, A. (2021). Derin öğrenme algoritmaları ile trafik işaret ve levhalarının tanımlanması (Master's thesis, Pamukkale Üniversitesi Fen Bilimleri Enstitüsü)..
- [33] Entwistle, A. (1988). What is artificial intelligence?. Engineering Materials and Design, 32, 26..
- [34] T. Rademacher, "Artificial intelligence and law enforcement," Regul. Artif. Intell., vol. 35, no. 4, pp. 225–254, 2019, doi: 10.1007/978-3-030-32361-5_10..
- [35] «Alan, M. (2020)Derin öğrenme ile biyosinyal sınıflandırma ve hastalık tahmini. Yüksek Lisans Tezi, Marmara Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, Türkiye.».
- [36] Smolen, P., Baxter, D. A., & Byrne, J. H. (2000). Mathematical modeling of gene networks. Neuron, 26(3), 567-580..

- [37] Alan, M. (2020)Derin öğrenme ile biyosinyal sınıflandırma ve hastalık tahmini. Yüksek Lisans Tezi, Marmara Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, Türkiye.
- [38] Haykin, S. S. (2009). Neural networks and learning machines/Simon Haykin..
- [39] A. H. Jackson, “Machine learning,” Expert Syst., vol. 5, no. 2, pp. 132–150, 1988, doi: 10.1111/j.1468-0394.1988.tb00341..
- [40] Samuel, A. L. (1988). Some studies in machine learning using the game of checkers. II—recent progress. Computer Games I, 366-400..
- [41] Mitchell, T., Buchanan, B., DeJong, G., Dietterich, T., Rosenbloom, P., & Waibel, A. (1990). Machine learning. Annual review of computer science, 4(1), 417-433..
- [42] Cunningham, P., Cord, M., & Delany, S. J. (2008). Supervised learning. In Machine learning techniques for multimedia (pp. 21-49). Springer, Berlin, Heidelberg..
- [43] IBM (2020, Sep 21) Unsupervised Learning <https://www.ibm.com/cloud/learn/unsupervised-learning>.
- [44] Van Engelen, J. E., & Hoos, H. H. (2020). A survey on semi-supervised learning. Machine Learning, 109(2), 373-440..
- [45] Sutton, R. S., Maei, H. R., Precup, D., Bhatnagar, S., Silver, D., Szepesvári, C., and Wiewiora, E. (2009a). Fast gradient-descent methods for temporal-difference learning with linear function approximation. In the International Conference on.
- [46] OKKAN, U., SERBEŞ, Z. A., & GEDİK, N. (2018). MATLAB ile Levenberg-Marquardt algoritması tabanlı YSA uygulaması: Aylık yağış-akış modellemesi. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 9(1), 351-362.
- [47] «Çavuşlu, M. A., Becerikli, Y., & Karakuzu, C. (2012). Levenberg-Marquardt algoritması ile YSA eğitiminin donanımsal gerçekleştirilmesi. Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi, 5(1).».
- [48] Mutlu, H., AKUNER, C., & AKGÜN, G. An Intelligent Machine Condition Monitoring Model for Servo Systems. Balkan Journal of Electrical and Computer Engineering, 10(1), 23-29.
- [49] Long III, L. L., & Srinivasan, M. (2013). Walking, running, and resting under time, distance, and average speed constraints: optimality of walk–run–rest mixtures. Journal of The Royal Society Interface, 10(81), 20120980..

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Hasan TAŞDEMİR

EĞİTİM BİLGİLERİ

2003 - 2008	Marmara Üniversitesi Teknik Eğitim Fakültesi, İstanbul Lisans, Elektronik ve Bilgisayar Eğitimi, Elektronik ve Haberleşme Öğr. Prog. (İngilizce)
1998 – 2003	Tekirdağ Anadolu Meslek Lisesi (Elektronik Bölümü)

İŞ TECRÜBESİ

2014 -	T.C. Milli Eğitim Bakanlığı Elektrik-Elektronik Teknolojisi Alanı, Teknik Öğretmen
2009 - 2014	T.C. Adalet Bakanlığı Bakırköy Cumhuriyet Başsavcılığı Sistem Odası Sorumlusu
2008 - 2009	İnter Teknoloji LTD. Proje Departmanı, Zayıf Akım Proje Mühendisi