

**ENGELLİLER İÇİN TÜRK İŞARET DİLİNİ ÖĞRENEN VE SINIFLANDIRAN
DUYUSAL ELDİVEN TASARIMI VE UYGULAMASI**

YÜKSEK LİSANS TEZİ

Abdullah ÇAYLI

Danışman

Dr. Öğr. Üyesi Güray SONUGÜR

MAKİNE MÜHENDİSLİĞİ ANABİLİM DALI

Temmuz 2020

Bu tez çalışması 19.FENBİL.33 numaralı proje ile BAPK tarafından desteklenmiştir.

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

ENGELLİLER İÇİN TÜRK İŞARET DİLİNİ ÖĞRENEN VE
SINIFLANDIRAN DUYUSAL ELDİVEN TASARIMI VE
UYGULAMASI

Abdullah ÇAYLI

Danışman

Dr. Öğr. Üyesi Güray SONUGÜR

MAKİNE MÜHENDİSLİĞİ ANABİLİM DALI

Temmuz 2020

BİLİMSEL ETİK BİLDİRİM SAYFASI

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

08 / 06 / 2020



Abdullah ÇAYLI

ÖZET

Yüksek Lisans Tezi

ENGELLİLER İÇİN TÜRK İŞARET DİLİNİ ÖĞRENEN VE SINIFLANDIRAN DUYUSAL ELDİVEN TASARIMI VE UYGULAMASI

Abdullah ÇAYLI

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Makine Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi. Güray SONUGÜR

Bu çalışmada duyma veya konuşma engeli olan insanların iletişim sağlayabilmelerine yardımcı olabilecek bir işaret dili tanıma eldiveni tasarımı ve uygulaması yapılmıştır. Tasarımda kullanılan eldivenlerde, 12 adet esneklik algılayıcı, 2 adet ataletsel algılayıcı, 10 adet manyetik alan algılayıcı ve geliştirme kartları kullanılmıştır. Toplamda kullanılan algılayıcılardan 34 adet sinyal elde edilerek bir işaret matrisi oluşturulmuştur. Ardından işaret dili hareketlerinden oluşan matrisler varyans, basıklık, çarpıklık ve standart sapma gibi istatistiksel işlemlere tabi tutularak 272 adet öznitelikten oluşan giriş vektörüne dönüştürülmüştür. İşaret dili hareketlerini tanımak için makine öğrenmesi algoritmalarından yararlanılarak sınıflandırma yapılmıştır. Kullanılan yöntemler; Lojistik Regresyon, Yapay Sinir Ağları, Destek Vektör Makineleri, Naif Bayes, Karar Ağaçları, Rastgele Orman ve En Yakın Komşu yöntemleridir. Çalışmada 32 adet işaret dili hareketi ele alınmıştır. Sınıflandırma çalışmalarında 320 ve 960 örnekten oluşan iki ayrı veri seti kullanılmıştır. Doğru tanıma oranı ortalama ilk veri setinde 86,4%, ikinci veri setinde 96,9% olarak hesaplanmıştır.

2020, x + 78 sayfa

Anahtar Kelimeler: İşaret dili çevirici, Makine öğrenmesi, Sınıflandırma, Duyusal eldiven, Yapay sinir ağları

ABSTRACT

M.Sc. Thesis

DESING AND APPLICATION OF A SENSORY GLOVE FOR LEARNING AND CLASSIFICATION OF TURKISH SING LANGUAGE FOR DISABLED PEOPLE

Abdullah ÇAYLI

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Machine Engineering

Supervisor: Asst. Prof. Güray SONUGÜR

In this study, a sign language recognition glove design and application was made that could help people with hearing or speech disabilities be able to communicate. 12 flexibility sensors, 2 inertial sensors, 10 magnetic field sensors and development cards were used on the prototype gloves. A data matrix was created for a sign language movement with data collected from a total of 34 sensors. The features of sign language data such as variance, kurtosis, skewness and standard deviation were then extracted. In this way, an input data consisting of 8 features for each sensor data, a total of 272 features, was obtained. Classification was achieved using the methodology of machine learning to recognize sign language. The methods used are Logistic Regression, Artificial Neural Networks, Support Vector Machines, Naive Bayes, Decision Trees, Random Forest and Nearest Neighbor methods. In the analysis, 32 motion in the sign language is addressed. Two separate data sets consisting of 320 and 960 samples were used in the classification studies. The correct recognition rate was calculated as 86.4% in the first data set and 96.9% in the second data set.

2020, x + 78 pages

Keywords: Turkish Sign Language Converter, Machine Learning, Classification, Sensory Glove, Artifical Neural Network.

TEŞEKKÜR

Bu araştırmanın konusu, deneysel çalışmaların yönlendirilmesi, sonuçların değerlendirilmesi ve yazımı aşamasında yapmış olduğu büyük katkılarından dolayı tez danışmanım Sayın Dr. Öğr. Üyesi Güray SONUGÜR, çalışmanın gerçekleşmesinde 19.FENBİL.33 proje numarası ile maddi imkân sağlayan Afyon Kocatepe Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğüne (BAPK) ve eleştirileriyle yardımlarını gördüğüm hocalarıma ve arkadaşlarıma teşekkür ederim.

Bu araştırma boyunca maddi ve manevi desteklerinden dolayı aileme teşekkür ederim.

Abdullah ÇAYLI
Afyonkarahisar 2020

İÇİNDEKİLER DİZİNİ

	Sayfa
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER DİZİNİ.....	iv
SİMGELER ve KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ.....	ix
RESİMLER DİZİNİ	x
1. GİRİŞ.....	1
2. LİTERATÜR BİLGİLERİ	4
2.1 İşaret Dili Nedir?	4
2.1.1 İşaret Dilinin Kökeni.....	4
2.1.2 Türk İşaret Dili.....	5
2.1.3 Türk işaret dilinin diğerleri ile karşılaştırılması.....	5
2.2 Literatürdeki İşaret Dili Tanıma Çalışmaları.....	6
2.2.1 El ve Mimik Hareketlerinden Öznitelik Çıkarımı.....	7
2.2.2 Video Tabanlı İşaret Dili Tanıma	7
2.2.3 Literatürde Yapılmış Veri Eldivenleri	10
2.3 Literatürde Kullanılmış Tanıma Modelleri.....	12
3. MATERYAL ve METOT	15
3.1 İşaret Dili	15
3.1.1 El Eklemlerinden Öznitelik Çıkarılan Bölgeler	15
3.2 Kullanılan Materyaller.....	16
3.2.1 Esneklik Algılayıcı.....	17
3.2.2 Dönü Ölçer ve İvme Ölçer	17
3.2.3 Manyetik Alan Algılayıcı.....	19
3.2.4 Çoklayıcı (Multiplexer - MUX) Devre Elemanı ve Voltaj Düzenleyici.....	20
3.2.5 Arduino Pro Mini 5V - 16 Mhz	22
3.2.6 NVIDIA Jetson Nano Geliştirici Kit.....	23
3.2.7 Bluetooth İletişimi.....	24
3.3 Güç Kaynağı ve Güç Gereksinimleri.....	26
3.4 Kontrol Kartı Devre Şeması	27

3.5 Veri Setinin Oluřturulması	28
3.6 Eldivenin Oluřturulması	31
3.7 İstatistiksel Öznitelikler	33
3.7.1 Maksimum ve Minimum.....	33
3.7.2 Ortalama.....	34
3.7.3 Ortanca (Medyan)	35
3.7.4 Standart Sapma.....	35
3.7.5 Varyans Öznitelik Çıkarımı	36
3.7.6 Basıklık (Kurtosis) ve Çarpıklık (Skewness)	37
3.8 Veri Setinin Normalizasyonu.....	38
3.10 Verilerin Bölünmesi.....	39
3.11 Çıkış Verilerinin İkili Sayı Sistemine Dönüřtürülmesi	41
3.12 Sınıflandırma Algoritmaları.....	42
3.12.1 Lojistik Regresyon	43
3.12.2 En Yakın Komřu	45
3.12.3 Destek Vektör Makineleri	46
3.12.4 Naif Bayes.....	48
3.12.5 Karar Ağaçları	49
3.12.6 Rastgele Orman Sınıflandırması	50
3.12.7 Yapay Sinir Ağları	51
4. BULGULAR	56
4.1 Eldiven Üzerindeki Algılayıcılardan Elde Edilen Ham Veriler	56
4.2 Uygulamada Kullanılan Kelimeler	62
4.3 Metotların Karşılaştırılması ve Grafikler.....	62
5. TARTIřMA ve SONUÇ	68
6. KAYNAKLAR.....	71
ÖZGEÇMİř.....	77
EKLER	78

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

K	Komşu sayısı
---	--------------

Kısaltmalar

AİD	Amerikan işaret dili
ANN	Artifical Neural Network
AÖB	Ataletsel Ölçüm Birimi
ARM	Acorn RISC Machine
BM	Birleşmiş Milletler
BMEHS	Birleşmiş Milletler Engelli Hakları Sözleşmesi
CPU	Central Prossesing Unit
ÇKA	Çok Katmanlı Algılayıcı
DVM	Destek Vektör Makineleri
EYK	En Yakın Komşu
GPU	Graphic Precessing Unit
HİD	Hint işaret dili
HMM	Hidden Markow Models
IEEE	Institute Engineers and Everyone Else
IMU	Inertial Mesurament Unit
KA	Karar Ağaçları
LR	Lojistik Regresyon
MATLAB	Matrix Laboratory
MEB	Milli Eğitim Bakanlığı
NB	Naif Bayes
PCA	Principal Component Analysis
PCB	Printable Curcuit Board
PSO	Parçacık Sürü Optimizasyonu
RF	Radyo Frekansı
ROS	Rastgele Orman Sınıflandırma
SMM	Saklı Markow Modelleri
SPI	Serial Peripheral İnterface
SVM	Support Vector Machines
TBA	Temel Bileşen Analizi
TİD	Türk işaret dili
VDC	Doğru voltajı
YME	Yüzey montaj elemanı
YSA	Yapay Sinir Ağları

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1 İşaret dili kullananların ellerindeki öznitelik çıkarılabilecek eklemeler.....	7
Şekil 3.1 El üzerinde bulunan öznitelik çıkarılan eklemeler (İnt.Kyn.3).....	16
Şekil 3.2 Hazırlanan Kontrol kartı PCB Baskı için Eagle programında çizilmiş devre şeması	28
Şekil 3.3 Sağ elden elde edilen verilerin bir satırı ve algılayıcıların satırdaki yerleri ...	30
Şekil 3.4 Eldiveninden gelen bir işaret verisi için öznitelik çıkarıldıktan sonra matris boyutlarının değişimi.....	33
Şekil 3.5 Öznitelikleri alınarak oluşturulan veri setinin eğitim ve test olarak bölünmesi	40
Şekil 3.6 Değişken tipleri ve çıkış verilerin nominal değişkenler olarak kodlanması ...	42
Şekil 3.7 Örnek sigmoid fonksiyonu	45
Şekil 3.8 İki adet öznitelikten ve 3 adet sınıftan oluşan verilerin 4 adet komşusunun uzaklığına bakılarak sınıflandırılması (Wang ve Mao 2020).....	45
Şekil 3. 9 Verilerin çekirdek fonksiyonları yardımı ile daha yüksek boyutlara dönüştürülmesi (Kavzoğlu ve Çölkesen 2010).	47
Şekil 3.10 Doğrusal destek vektör makinelerinin basit gösterimi (Lu ve Roychowdhury 2006).....	48
Şekil 3.11 Karar Ağaçları algoritmasının en yüksek entropi değerine sahip öznitelige göre sınıflandırma mantığı (Jin vd. 2009).	50
Şekil 3.12 Karar Ağaçlarından oluşan örnek bir Rastgele Orman Sınıflandırma algoritması mantığı (Alabdulkarim vd. 2019).	51
Şekil 3. 13 YSA’ da genel olarak kullanılan aktivasyon fonksiyonları	53
Şekil 3.14 Çalışmada tasarlanan yapay sinir ağı modeli	54
Şekil 4.1 ‘Arkadaş’ kelimesine ait sağ eldivenin esneklik algılayıcılarından toplanan ham veriler görülmektedir.	57
Şekil 4.2 ‘Tekrar’ kelimesine ait sağ eldivenin esneklik algılayıcılarından toplanan ham veriler görülmektedir.	57
Şekil 4.3 ‘İyi’ kelimesine ait sağ eldivenin esneklik algılayıcılarından toplanan ham veriler görülmektedir	58

Şekil 4.4 ‘Arkadaş’ kelimesine ait sağ eldivenin manyetik alan algılayıcılarından toplanan ham veriler görülmektedir.	58
Şekil 4.5 ‘Tekrar’ kelimesine ait sağ eldivenin manyetik alan algılayıcılarından toplanan ham veriler görülmektedir.	59
Şekil 4.6 ‘İyi’ kelimesine ait sağ eldivenin manyetik alan algılayıcılarından toplanan ham veriler görülmektedir.	59
Şekil 4.7 ‘Arkadaş’ kelimesine ait AÖB algılayıcısından toplanan ham dönüölçer verileri görülmektedir.	60
Şekil 4.8 ‘Tekrar’ kelimesine ait AÖB algılayıcısından toplanan ham dönüölçer verileri görülmektedir.	60
Şekil 4.9 ‘İyi’ kelimesine ait AÖB algılayıcısından toplanan ham dönüölçer verileri görülmektedir.	61
Şekil 4.10 ‘arkadaş’, ‘tekrar’ ve ‘iyi’ kelimesine ait 272 adet istatistiksel özniteliklerden oluşturulmuş grafik.	61
Şekil 4.11 Çalışmada kullanılan tekniklerin 320 ve 960 adet veri seti ile yapılan testlerin sonuçları	67
Şekil 5.1 ‘arkadaş’, ‘tekrar’ ve ‘iyi’ kelimesine ait 272 adet istatistiksel özniteliklerden oluşturulmuş grafik.	69

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 2.1 Kishore ve Kumar‘ın işaret dili yapan farklı kişilerle eğitim sırasında gözlemledikleri sonuçlar.....	9
Çizelge 2.2 Bauer ve Kraiss‘in Alman İşaret Dilini otomatik olarak tanıma için önerdikleri modelin tanıma oranı sonuçlarıdır	10
Çizelge 2.3 Pezzuoli vd. işaret dili tanımada kullandıkları metotlar ve bu metotların doğruluk oranları	12
Çizelge 2.4 Çin fonetik alfabesi ile yapılan deneylerin sonuçları (Lei ve Dashun 2015).	13
Çizelge 3.1 Bir eldiven için algılayıcıların ve devre elemanlarının çalışma gerilimi ve tükettikleri akımlar.....	26
Çizelge 4.1 Bir eldivende bulunan algılayıcıların monte yerleri ve algılayıcı kısaltmaları	56
Çizelge 4.2 320 adet işaret örneği ile yapılan eğitim ve testlerin doğruluk sonuçları ...	63
Çizelge 4.3 960 adet işaret örneği ile yapılan eğitim ve testlerin doğruluk sonuçları ...	64
Çizelge 4.4 İşaret dili tanıma için kullanılan algoritmaların eğitim ve test doğrulukları	65

RESİMLER DİZİNİ

Sayfa

Resim 2.1 TİD ve Amerikan İşaret Dili (AİD)’ ne ait ‘A’ ile ‘R’ harflerinin kullanımı (İnt.Kyn.2 ve MEB 2015).....	6
Resim 2.2 Daha önceki yapılmış işaret dili eldiveni çalışmalarından birkaçının tasarımları. (a) , (Abualola vd. 2016); (b) , (Shukor vd. 2015); (c) , (Gupta vd. 2015); (d) , (Harish ve Poonguzhali 2015).....	11
Resim 3.1 5.5 cm uzunluğunda esneklik algılayıcı.....	17
Resim 3.2 Çalışmada kullanılan Adafruit BNO055 model AÖB algılayıcısı.....	18
Resim 3.3 Çalışmada kullanılan manyetik alan algılayıcı	19
Resim 3.4 Çalışmada kullanılan CD74HC4067 çoklayıcı (Multiplexer- MUX) devre elemanı	20
Resim 3.5 AMS 1117 elektronik voltaj düzenleyici	21
Resim 3.6 Arduino Pro Mini 5V 16MHz programlama birimi.....	23
Resim 3.7 Çalışmada kullanılan NVIDIA Jetson Nano Geliştirici Kiti	24
Resim 3.8 Çalışmada kullanılan HM-11 model bluetooth cihazı	25
Resim 3.9 Bakır levha üzerine geçirilmiş baskı devre şeması	27
Resim 3.10 ‘Ben’ işareti için sağ elden hareket süresince elde edilen örneklemelerin bir kısmı	29
Resim 3.11 (a) ; Prototip çalışması, (b) ; Eldivenlere algılayıcıların montajı ve kablolama, (c) ; Eldivendeki algılayıcılar için kontrol birimi, (d) ; Çalışmada tasarlanan sol eldiven.....	31
Resim 3.12 Avuç içlerine parmakların değdiği bazı işaretler. (a) ; “Orta” kelimesinin işaret dilindeki karşılığı, (b) ; “Tekrar” kelimesinin işaret dilindeki karşılığı (MEB 2015).	32
Resim 3.13 Elektronik devre katının üzerine montajlanmış devre elemanları	32

1. GİRİŞ

Teknoloji insanların ihtiyacı doğrultusunda şekillenerek yaşamı kolaylaştırmak ve karşılaşılan zorluklara çözüm olabilecek yollar bulmayı amaçlayarak gelişmeye devam etmektedir. İnsanlar teknolojiyi kendilerine fayda sağlayabilecek bireysel, askeri, kimya ve tıp gibi birçok alanlarda icatlar yaparak teknolojik gelişimi sürdürmektedirler. Konuşma ve duyma engelli bireylerin iletişimini kolaylaştırmayı amaçlayan cihazlar bu teknolojik gelişmelere örnek olmaktadır.

İletişim kurmanın en basit yollarından biri konuşmak ve dinlemek olduğundan insanların kolay bir biçimde vazgeçemeyeceği yetenekler arasında bulunur. Fakat bazı insanlar konuşma ve duyma yeteneklerinden doğuştan veya sonradan mahrum kalmış olabilir. Duyma ve konuşma engelli insanların etrafındakilerle iletişimini kolaylaştırmak amacı ile geçmişten günümüze pek çok çalışma yapılagelmiştir. Engelli bireylerin birbirleri ile iletişim kurabilmelerine olanak sağlayan belirli el, kol ve bilek hareketlerinden oluşan bir işaret dili alfabesi bulunmaktadır (MEB 2015).

Literatürdeki çalışmalar temelde engelli bireylerin iletişim kurmak için yaptıkları hareketlerin işaret dilindeki karşılığını tanımaya yöneliktir. İşaret dilinde yapılan hareketleri tanıyabilmek için kaynaklarda el ve kollara yerleştirilen elektrotlardan elektromiyografi sinyallerinin toplanması, görüntü işleme teknikleri ve algılayıcılar yerleştirilmiş eldiven yöntemlerinden yararlanılmıştır. Algılayıcılardan oluşan eldivenler donanım gereksinimi, sinyal çeşitliliği, sinyal belirginliği ve hız gibi özelliklerinden dolayı mevcut teknikler arasından avantajlı olması sebebi ile seçilmiştir. İşaret dilinde kol ve bilek hareketlerinin yanı sıra parmak hareketleri işaretlerin tanınmasında önemli bir rol oynamaktadır. Kaynaklarda, çoğunlukla tasarlanan işaret dili eldivenlerinde tanımayı gerçekleştirebilmek için parmakların bükülme oranından yararlanır. Bu sebep ile parmaklardaki bükülme hareketlerini algılayabilmek için esneklik algılayıcıları kullanılmıştır. İşaret dili hareketleri dikkate alındığında, işaret dilini tanımayı amaçlayarak tasarlanan eldivenler birbirlerine benzemektedir. Literatürdeki eldivenler de temel olarak esneklik algılayıcıları, ataletsel ölçüm birimi, dönüölçer (jiroskop) algılayıcıları ve tanımayı gerçekleştirebilmek için bilgisayar kullanılmıştır (Lei ve

Dashun, 2015). Literatürde kullanılan algılayıcıların eldivendeki yerleri ve sayısı değişkenlik göstermektedir. Jadhav ve Joshi (2016) tarafından tasarlanan eldivende 3 adet esneklik algılayıcı ve 1 adet ivmeölçer kullanmıştır. Algılayıcı sayısının az olduğu durumda, işaret dilindeki kelime sınıflarının çokluğuna bağlı olarak tanıma oranı olumsuz etkilenmektedir. Harish ve Poonguzhali (2015) çalışmalarında 5 adet esneklik algılayıcı ve 1 adet ivmeölçer kullanmışlardır. Tasarladıkları eldivende algılayıcıların ve kullandıkları diğer ünitelerin ayrı olması kablo kalabalığı oluşturmaktadır.

Bu çalışmada literatürdeki eldiven tasarımlar incelenerek işaret dilini tanımak için bir eldiven tasarımı ve tanıma modeli önerilmiştir. Tasarımda kullanılan algılayıcı, haberleşme üniteleri ve geliştirme kartları bir bakır levha üzerine montelenmiştir. Tasarımda, 12 adet esneklik, 2 adet ataletsel ölçüm birimi, 2 dönüölçer ve 10 adet manyetik alan algılayıcıları kullanılmıştır. Bu algılayıcılar yardımı ile işaret dilinde kullanılan hareketlerin örüntüleri analog sinyaller olarak toplanmıştır. Yapılan çalışmada kullanılan tüm kelimelerin analog sinyallerden oluşan işaret dili örüntüleri tanıma algoritmalarını uygulayabilmek için bir veri seti biçiminde kaydedilmiştir. Oluşturulan veri seti 32 adet kelime içermektedir. Bu kelimelerin her birinden 75'i eğitim ve 25'i test olmak üzere toplamda 1280 adet örnek veri toplanmıştır. Oluşturulan veri seti bir takım veri ön işlemeden geçirilerek işaretlerin istatistiksel öz nitelikleri çıkarılmıştır. Tanımayı sağlayabilmek ve deneysel çalışma yapabilmek için makine öğrenmesi tekniklerinden yararlanılmıştır. Tanımayı gerçekleştirebilmek için işaretler arasında sınıflandırma işlemi yapılmıştır.

Sınıflandırmada kullanılacak teknikler, gözetimli öğrenme teknikleri olduğundan veri setine ihtiyaç duymaktadır. Çalışmada kullanılan yapay sinir ağları, destek vektör makineleri, naif Bayes, karar ağaçları, lojistik regresyon, rastgele orman ve en yakın komşu teknikleridir. Bu teknikler veri setindeki önceden oluşturulan işaretlerin örüntüleri ile eğitim yapılarak veri setini öğrenmektedirler. Bu teknikler arasında veri setine en uygun ve en başarılı tekniği belirlemek için deneysel çalışmalar gerçekleştirilmiştir. Deneyler, 32 adet kelime sınıfı içeren 320 adet ve 960 adet işaret dili hareketlerinden oluşan veri setleri ile ayrı ayrı eğitim ve test yapılmıştır. Kullanılan tekniklerin eğitim başarı yüksek olsa dahi harici bir veri seti ile test yapıldığında başarı oranı düşmektedir.

Bu sebep ile teknikler harici bir veri seti kullanılarak test edilmiştir. Veri seti 320 adet örnek ile eğitilip test edildiğinde, 96,4% eğitim başarısı ve harici bir veri seti ile test edildiğinde 86,4% test başarısı elde edilmiştir. Veri seti arttırılarak 960 adet örnek veri ile eğitildiğinde ise yapay sinir ağlarıyla 98,1% eğitim başarısı ve harici bir veri seti ile test edildiğinde 96,9% test başarısı elde edilmiştir.



2. LİTERATÜR BİLGİLERİ

2.1 İşaret Dili Nedir?

İşaret dili, işitme engellilerin kendi aralarında, işiten ama duyamayan kişilerle ve aynı zamanda normal insanlarla aralarındaki iletişimi sağlamak için tek veya çift ellerini kullandıkları bir dildir. İşaret dili kendine has doğal bir dil olup parmak, el ve yüz gibi işaret ve mimiklerden oluşan bir dildir (Karaca ve Bayır 2018). Bu dili kullanan kişiler işaretleri ve mimikleri kendi aralarında özelleştirebilirler.

2.1.1 İşaret Dilinin Kökeni

Tarihte işaret dili Hititlere (2000BC–1200BC) (Kemaloğlu 2014) kadar uzanmakla birlikte Anadolu’da ve devamında Osmanlı devletinde sağır ve dilsizler için 19. yüzyıldan sonra Avrupa ile paralel olarak işaret dili okulları açılmıştır. Her ne kadar önceden sağır ve dilsizlerin toplumdan dışlanmasını öneren bazı yunan filozofları olsa da bu engellin bireyler için dini veya kamusal bir kısıtlama olmadan eşit vecibelere sahip vatandaş olmaktadır (Kemaloğlu ve Kemaloğlu 2012, İnt.Kyn.1). İşaret dilinin bir mevzuata oturtulması henüz yeni sayılabilecek geçtiğimiz 15-20 yıl içerisinde gerçekleştirilmiştir. Milli Eğitim Bakanlığı (MEB) tarafından engellilerin işaretlerini anlayıp öğrenebileceğimiz bir işaret dili sözlüğü yayımlanmıştır (MEB 2015).

İşitme/konuşma engelliler toplumumuzun bir parçası olduğundan ve bir birey olabildiklerinden sağlıklı insanlar gibi eşit haklardan faydalanmalıdır. Günümüzde işitme/duyma engellilerini de kapsayan engellilerin bir toplum içinde diğer bireyler gibi eşit hizmetlere, olanaklara ve uygulamalara sahip olması açısından bu kişilerin için uluslararası bir sözleşme bulunmaktadır. Söz konusu sözleşme 13 Aralık 2006 tarihinde Birleşmiş Milletler (BM) genel kurulunda kabul edilmiştir. Türkiye’nin de imzaladığı, Birleşmiş Milletler Engelli Haklarına İlişkin Sözleşme’ sinin (BMEHS) amacını oluşturan birinci maddesinde de belirtildiği üzere engellilerin diğer bütün insanlar gibi hak ve temel özgürlüklerden eşit şekilde faydalanmasını amaçlamaktadır (Kemaloğlu 2014 ve İnt.Kyn.1).

2.1.2 Türk İşaret Dili

Türk İşaret Dili (TİD) kökeni Anadolu' ya kadar dayandığından bilinen en eski işaret dillerinden biri olarak kabul edilebilir (Zeshan 2003). Her ne kadar tarihi çok eskilere dayansa da nispeten genç bir dil olarak kabul edilir (Aronoff vd. 2005). TİD üzerine yapılan dil bilimsel çalışmalar çok kısıtlı olmakla birlikte (Zeshan 2003) gibi bilim insanları tarihsel ve temel yapıları hakkında çalışmalar yapmıştır. Dünyada birçok işaret dili mevcut olup bunların bazıları tarihsel açıdan birbirleriyle ilişkili olabilmektedir. TİD ilk işaret dillerinden biri olduğundan doğal bir dildir. Dolayısıyla herhangi başka bir dilden türemeyip kendine özgü bir dil olmuştur (Arık 2016). Fakat kaynaklarda TİD'nin doğal bir dil olup başka dillerden türemediği söylenmekle birlikte başka işaret dillerinden ödünç alınan işaretler olduğu ile ilgili tartışmalar vardır (Arık vd. 2016).

2.1.3 Türk işaret dilinin diğerleri ile karşılaştırılması

Türk işaret dilinde olduğu gibi diğer ülkeler de işaret dilleri kullanmaktadır. Ülkelerin konuştuğu diller arasındaki farklılığa benzer bir biçimde işaret dilleri de ülkeden ülkeye farklılık göstermektedir. Örneğin biz bilmediğimiz farklı bir dil ile konuşan biriyle karşılaştığımızda ne söylediğini nasıl anlayamıyorsak Türk işaret dilini kullanan işitme engellilerde farklı bir ülkenin işaret dili konuşan biri ile karşılaştığında onlar da anlamayabilir.

Konuşma dili ile işaret dili arasında benzerlik oluşturabilecek özelliklerinden biri her ikisinin de doğal bir dil olmasıdır. Bunu ile birlikte konuşma dilleri aynı dil ailesine mensup diğer dillerle benzerlik gösterirken, işaret dilleri benzerlik göstermemektedir. İşaret dilleri belli sınıflandırıcılardan yani yer, yön, durum ve hareketlilik bildiren anlamlardan oluşur. Belli bir ülkenin işaret dilinde karmaşık bir durumu anlatmak için bu sınıflandırıcılardan yararlanılırken bir diğer ülkede işaret dili kullananlar bu sınıflandırıcılardan yararlanmayabilir (Arık 2013). Amerikan alfabesindeki harfler, Türk alfabesindeki harfler ile benzerlik göstermesine rağmen bu harfleri oluşturan işaret dilindeki işaretler benzerlik göstermemektedir. Resim 2.1 'de Amerikan ve Türk işaret dilindeki 'A' ve 'R' harfleri görülmektedir (İnt.Kyn.2 ve MEB 2015).

Türk İşaret Dili	Amerikan İşaret Dili
	
	


Resim 2.1 TİD ve Amerikan İşaret Dili (AİD)’ ne ait ‘A’ ile ‘R’ harflerinin kullanımı (İnt.Kyn.2 ve MEB 2015).

2.2 Literatürdeki İşaret Dili Tanıma Çalışmaları

İşitme ve konuşma engellilerin çevresindeki insanlarla etkileşimini kolaylaştırmak amacı ile kaynaklar da birçok farklı çalışmalar mevcuttur. İşitme ve konuşma engellilerin iletişim kurmak için kullandığı işaret dilleri incelendiğinde çoğunlukla el hareketleri olmak üzere kaş, boyun ve ağız mimiklerini kullandıkları görülmektedir. Mevcut kaynaklar da bu hareket ve mimikler üzerine hem ayrı ayrı çalışmalar hem de kolektif biçimde çalışmalar yapılmıştır (Kındıroğlu vd. 2011). Temelde bu çalışmalar işaret dilini tanımak ve yorumlamak üzerine olmaktadır. İşaret dilini tanımak amacı ile yapılan bu çalışmalar engelli kişilerin yaptıkları el hareketleri üzerine yoğunlaşarak ilerlemeye devam etmektedir. Yapılan çalışmalar incelendiğinde, işaret dilini normal insanların anlayabileceği biçimde yorumlamak amacı ile çoğunlukla iki yöntem kullanılmıştır. Bu yöntemler video tabanlı tanıma ve veri eldiveni ile tanımadır. Veri eldiveni, çeşitli algılayıcılardan oluşan bir çeşit eldivenden oluşmaktadır (Shukor vd. 2015).

2.2.1 El ve Mimik Hareketlerinden Öznitelik Çıkarımı

Engelli kişilerin yaptığı el işaretleri, ellerinde ve bileklerinde bulunan eklemleri hareket ettirerek olur. Yapılan işaretlerin benzersizliğini bu eklem yerlerinin belli anlamlar içerecek biçimde bükülmesiyle işaret diliyle iletişim kurulabilir. Parmak ve bilek hareketlerinin yanında öteleme, dönme ve yönelimlerden oluşan hareketler de vardır (Shukor vd. 2015). Şekil 2.1’de işaret dilinde yapılan işaretleri tanımak ve anlamlandırmak için belirgin özniteliklerin çıkarılabileceği eklem yerleri görülmektedir.



Şekil 2.1 İşaret dili kullananların ellerindeki öznitelik çıkarılabilecek eklemler.

2.2.2 Video Tabanlı İşaret Dili Tanıma

Video tabanlı işaret dili temelde, bir kamera ile işaretleri yapan kişiye dönük bir biçimde, işaretlerin önceden çıkarılmış öznitelikleri ile karşılaştırarak yapılmaktadır. Tanıma işleminin yapılabilmesi için veri setine ihtiyaç duyulmaktadır. İhtiyaç duyulan veri seti kaynaklardaki mevcut hareketlerin video kaydı yapılmasıyla başlar ve ardından video kaydından hareketlerin öznitelikleri çıkarılır. Söz konusu öznitelik çıkarımı yapabilmek

için görüntü işleme tekniklerinden yararlanılır. Bu teknikler kaynaklarda kullanılan mevcut teknikler olabilmekle birlikte önerilen bir görüntü işleme algoritması da olabilmektedir. Dreuw vd. (2008) 843 cümleden oluşan RWTH-BOSTON-400 isimli çeşitli konuşmacılar ve izole edilmiş video sekanslarından oluşan bir video işaret dili veri tabanı kullanarak AİD'ni tanımaya yönelik çalışma yapmışlardır. Bu veri tabanı Boston Üniversitesi tarafından yayımlanmıştır. Aynı veri tabanı ile kafa hareketleri, yüz ifadeleri ve el takibi gibi örüntü tanıma çalışmaları yapılmıştır. Kendi önerdikleri dil modellerini bu veri seti üzerinde değerlendirmişlerdir. İşaret dili tanımada el hareketlerinden ziyade kafa hareketleri de kullanılmaktadır. Kafa hareketleri işaret dilini kullanarak anlaşma açısından faydalı olmakla birlikte bilgisayar ortamlarında işaret dilini tanıma algoritmalarında tanıma oranını yükseltmek için gerekli olup olmadığı tartışılmaktadır. Erdem ve Sclaroff (2002) yaptıkları çalışmada AİD'ndeki kafa hareketlerinin doğruluğunu arttırmak için yeni bir yaklaşım önermişlerdir. Temelde ilk yaklaşımları, bir kamera kullanarak kafanın dönme ve öteleme hareketlerini, ikinci yaklaşımları ise kafa hareketlerinin, belli zamanlarda görüntüsünü bölütleme işlemlerinden geçirerek AİD'ndeki tanıma oranlarını arttırmayı amaçlamışlardır. Sonuç olarak, önerdikleri yaklaşımlarını standart bir bilgisayar üzerinde test ederek gerçek zamanlı uygulamalarda kullanılabileceği öne sürülmüştür. Literatürde video tabanlı işaret dili tanıma üzerine birçok çalışma mevcuttur. Video üzerinde çeşitli çıkarımlar yapmak için görüntü işleme algoritmaları çokça kullanılmıştır. Buna örnek olarak Kındıroğlu vd. (2011) yaptıkları çalışmada sadece işitme ve konuşma engelliler için değil aynı zamanda farklı dillerde konuşanlar içinde iletişimlerine fayda sağlaması için çok dilli bir el alfabesi önermişlerdir. Video tabanlı olan bu çalışma belli işaretlerin olduğu veri setinden ve bu veri setinin üzerinde görüntü bölütleme, el takibi ve öznitelik çıkarımı yapılmıştır. Bu çalışma doğrultusunda sonuç olarak belirli kullanıcılar yani işlemlerin üzerinde test edilip işlendiği kullanıcılar sınıflandırmada %80 doğruluk oranı elde edilirken, kullanıcının farklı olduğu deneyde %42 doğruluk oranı elde etmişlerdir. Ayrıca çalışmaları TÜBİTAK tarafından desteklenmiştir. Kishore ve Kumar (2012) çeşitli görüntü işleme ve yapay zekâ tekniklerini kullanarak Hint İşaret Dili'nde (HİD) cümle tamamlama uygulaması yapmışlardır. Bu çalışmanın yönelik olduğu kişiler daha öncede belirttiğimiz gibi sadece konuşma yeteneğini kaybetmiş kişiler değil aynı zamanda bu kişiler ile iletişim kurmak isteyenlere yönelik olmuştur. Yazarlar işaret dili görüntü veri setini oluşturmak için

Matrix Laboratory (MATLAB) yazılımı kullanmışlardır. Ardından görüntü segmentasyonu, Fourier Transform ve Fuzzy Logic algoritmalarını kullanmışlardır. En nihayetinde video çıkarımlarından tanınan HİD hareketlerini metinden sese çeviren bir program ile ses çıktısı olarak oynatılmıştır. Bu çalışmada toplamda veri seti 80 kelime ve 10 farklı işaret dili yapan kişilerden oluşmuştur. Yapmış oldukları deneyler sonucunda önerdikleri tanıma sistemi kullandıkları veri setine bağlı olarak 96% tanıma oranı elde etmişlerdir. Çizelge, 19 kelime ve kelime grubundan oluşmuştur. Çalışma sonucundaki %96 tanıma oranı ile Çizelge 2.1’deki %92.142’lik tanıma oranı arasındaki fark, yapılan çalışmanın 80 adet kelime ve kelime grubundan oluşmasıdır.

Çizelge 2.1 Kishore ve Kumar (2012)’ın işaret dili yapan farklı kişilerle eğitim sırasında gözlemledikleri sonuçlar.

İşaretler	Doğru Tanınan İşaretler	Yanlış Tanınan İşaretler	Tanıma Oranı(%)
A	10	0	100
B	10	0	100
C	10	0	100
D	10	0	100
X	10	0	100
M	8	2	80
N	9	1	90
Y	7	3	70
İNEK	9	1	90
ÖRDEK	10	0	100
KARGA	6	4	60
ŞİŞMAN	9	1	90
KUŞ TÜYÜ	8	2	80
SEVGİ	9	1	90
BİRLİKTE	10	0	100
BURAYA GEL	7	3	70
ÖDEVİNİ YAP	6	4	60

Çizelge 2.1 (Devam) Kishore ve Kumar (2012)'ın işaret dili yapan farklı kişilerle eğitim sırasında gözlemledikleri sonuçlar.

İşaretler	Doğru Tanınan İşaretler	Yanlış Tanınan İşaretler	Tanım Oranı(%)
SAYILAR 1-10	100	0	100
YUKARI	10	0	100
TOPLAM	258	22	92.142

Farklı ülkelerde işaret dilini tanıma üzerine çalışmalar yapılmıştır. Özellikle video tabanlı tanımalarda görüntü işleme teknikleri kullanılmıştır. Bu tekniklerden Saklı Markow Modelleri (SMM) kaynaklarda çokça kullanılmıştır. Bauer ve Kraiss'in (2002) yaptıkları çalışmada Alman İşaret Dilini temel alarak otomatik bir tanıma modeli önermişlerdir. İşaret dili tanımda kişiye duyarlı tanıma ve yeni işaretlerin eklenmesi gibi sorunlara çözüm olarak SMM önermişlerdir. Bu modelleri kullanma sebeplerinden biri ise işaret dili tanıma konusuna istatistiksel olarak yaklaşımlarıdır. SMM istatistiksel sorunlara çözüm için önerilen modeller arasındadır. Yazarlar video tabanlı veri seti kullanarak modellerini hem eğitilmiş hem de eğitilmemiş verilerle test etmişlerdir. Çizelge 2.2'de sonuçlar görülmektedir.


Çizelge 2.2 Bauer ve Kraiss (2002)'in Alman İşaret Dilini otomatik olarak tanıma için önerdikleri modelin tanıma oranı sonuçlarıdır.

METOD	Doğruluk
Önceden Eğitilmiş 100 Adet İşaret	92.5 %
Önceden Eğitilmemiş 50 Adet İşaret	81.0 %

2.2.3 Literatürde Yapılmış Veri Eldivenleri

Literatürde işaret dili çalışmaları için kullanılan eldivenler genellikle aynı tip ve şekillerdedir. İşaret dili ile yapılan bir çalışma temel olarak parmakların büküm ve eğim noktalarını belirlemekten geçer. Bu çalışmada kaynaklarda sıkça kullanılan, parmakların büküm noktalarını tespit etmek için oldukça kullanışlı esneklik (flex) algılayıcıları tercih edilmiştir. Bu algılayıcılar büküm derecesine bağlı olarak bir elektriksel çıkış üretirler. Esneklik algılayıcılarının yanında belirgin özelliklerden biri olarak dönme ve öteleme

hareketini tespit etmek için dönüölçer ve ivmeölçer algılayıcıları da kullanılır. Bu algılayıcılar bir elektriksel devre içinde tümleşik olarak bulunabilmektedir. Bu tümleşik devre, piyasada çoğunlukla ataletsel ölçüm birimi (AÖB) veya Inertial Mesurament Unit (IMU) olarak bilinmektedir. AÖB, esneklik algılayıcıları, gömülü işlemci ve güç sisteminin kullanışlı olması açısından küçük boyutlarda tasarlamak gerekmektedir. Bu da oldukça zorlayıcı bir süreçtir. Ahmed vd. (2018) yapmış oldukları çalışmada daha önceki yapılmış olan eldiven tasarımları görülmektedir. Resim 2.2’de görülen eldivenler daha önceden yapılmış olan eldivenler ve eldivenlerin temel tasarım tipi görülmektedir (Ahmed vd. 2018).



Resim 2.2 Daha önceki yapılmış işaret dili eldiveni çalışmalarından birkaçının tasarımları. (a), (Abualola vd. 2016); (b), (Shukor vd. 2015); (c), (Gupta vd. 2015); (d), (Harish ve Poonguzhali 2015).

İşaret dili tanıma için uygulanan birçok metot bulunmakla birlikte bunlar arasında en çok kullanılanlar aşağıdaki gibidir;

- Destek Vektör Makineleri (DVM) - Support Vector Machines (SVM) (Pezzuoli vd. 2019, Zhi-heng vd. 2017)
- Saklı Markov Modelleri – Hidden Markow Models (HMM) (Swee vd. 2007, Gałka vd. 2016)
- Yapay Sinir Ağları (YSA) – Artifical Neural Network (ANN) (Bauer ve Kraiss 2002, Pezzuoli vd. 2019).
- Karar Ağaçları (Zhang vd. 2011, Saquib ve Rahman 2020).

Pezzuoli vd. (2019) işaret dili tanıma için temel tasarımdan yola çıkarak yaptıkları eldivenden elde ettikleri veriler sonucunda yukarıda bahsedilen metotların sonuçları çizelge 2.3’de verilmiştir. Bunula birlikte ideal bir işaret dili tanıma oranının 78.33% ile 95% olması gerektiğini vurgulamışlardır.

Çizelge 2.3 Pezzuoli vd. (2019) işaret dili tanımada kullandıkları metotlar ve bu metotların doğruluk oranları.

Teknik	En Yakın Komşular	Doğrusal DVM	YSA	Naif Bayes	Karar Ağaçları
Doğruluk	93 %	100 %	33 %	100 %	100 %

2.3 Literatürde Kullanılmış Tanıma Modelleri

Veri eldiveni tasarlayarak işaret dili tanımayı amaçlayan çalışmalar, veri elde ederken ve tanıma yaparken işlem yükü olduğundan bir bu verileri işleyecek bir işlemciye ihtiyaç duyulur. Geliştirilen tanıma modelleri kullanılan işlemcinin hızına ve yüklendikleri işlemlere bağlı olarak değişkenlik gösterebilir. Lokhande vd. (2015) görüntü tabanlı işaret dili tanıma sistemlerinin veri eldiveniyle tanıma sistemleri ile kıyaslandığında, görüntü tabanlı modellerin çok fazla işlem yükü gerektirdiğini, maliyetlerinin yüksek olabileceğini ve gerçek zamanlı uygulamalarda daha hızlı sonuç veremeyeceğini vurgulamışlardır. Literatür de en çok karşılaşılan tanıma modelleri Saklı Markov Modeli ve Yapay Zeka tabanlıdır (Bauer ve Kraiss 2002). Bu modeller haricinde araştırmacıların kendi geliştirdiği, mevcut modelleri kullandığı ve mevcut modeller üzerinde değişiklik yaparak işaret dili tanıma oranını arttırmaya yönelik çalışmalar mevcuttur. Lei ve Dashun (2015) esneklik ve AÖB algılayıcılarından oluşan basit bir eldiven tasarlamışlardır. Bunu yaparken Acorn RISC Machine (ARM) tabanlı bir işlemci ve Serial Peripheral Interface

(SPI) haberleşme yolunu kullanarak uygulama hızını artırmak istemişlerdir. Yaptıkları çalışmada işaretler Çin İşaret Dili ve ortak olarak kullanılan işaretlerdir. Tanıma modeli olarak kendi belirledikleri öznitelik çıkarımını yapmışlar ve ardından bu özniteliklerle basit bir eşleme yaparak tanıma sağlamaya çalışmışlardır. Yaptıkları çalışmada veri tabanları oldukça sınırlıdır. Çizelge 2.4’de belirtilen Çin fonetik alfabesindeki bazı harfler 30 defa tekrarlanarak deneye tabi tutulmuştur.

Çizelge 2.4 Çin fonetik alfabesi ile yapılan deneylerin sonuçları (Lei ve Dashun 2015).

Çin Fonetik Alfabesi	Başarılı Tanımlananların Sayısı	Başarılı Tanıma Oranı
A	25	83.30 %
B	26	86.70 %
C	28	93.30 %
Ch	28	93.30 %
Zh	29	96.70 %

İşaret dili için yapılan çalışmaların çoğu Amerika, Hint, Çin ve İspanyol gibi ülkelerde kendini göstermektedir. Her ne kadar ülkeler farklı olsa da yapılan çalışmaların tasarım ve modelleri benzerlik göstermektedir. Bukhani vd. (2015) AİD ile ilgili ‘SignSpeak’ adında bir eldiven tasarımı yapmışlardır. En nihayetinde amaçları AİD’ni düzgün sınıflandırmak olmuştur. Bunun için sınıflandırma sonuçlarını Radyo Frekansı yani Bluetooth yardımı ile Android telefonlara bağlanarak ses çıktısı olarak oynatmışlardır. Ayrıca Bukhani vd. (2015) piyasadaki hazır bulunan eldivenlerin aşırı pahalı fiyatına vurgu yapmışlardır. Yaptıkları çalışmada elde ettikleri verilerini 520x17 boyutunda bir matrise çevirmişlerdir. Sınıflandırma ve işaretlerin özniteliğini çıkarmak için Temel Bileşen Analiz (TBA) metodunu kullanmışlardır. Ayrıca TBA vektörlerini ve veri matrislerini düzenlemek için MATLAB programını kullanmışlardır. MATLAB programı matematiksel işlemler için oldukça geniş çaplı bir program olmasıyla birlikte asıl işlevi olan matris işlemleri kolayca çözülebilir ve gözlemlenebilir. Bu program sayesinde Bukhani vd. (2015) TBA yöntemiyle çıkardıkları öznitelik ve sınıfları, gerçek zamanlı deneylerde etkili bir sonuç olmak için Öklid Uzaklığı yöntemi kullanmışlardır. Sonuç olarak 520 adet konuşma işareti ile eğitim, test ve deneme yaparak 92% doğru tanıma oranına ulaşmışlardır.

İnsan makine ara yüzü denildiğinde akla ilk gelen klavye, fare, ekran ve oyun konsollarıdır. Bunlar insanlar ile bilgisayarların etkileşimde bulunduğu en bilinen ve yaygın örneklerdendir. Bu insan makine arabirimleri haricinde işaret dili eldivenleri de insan makine ara yüzüne en güzel örneklerden biridir. Ayrıca veri eldivenleri sadece işaret dili için değil aynı zamanda robotik araçlar için kontrol amacı ile de kullanılabilir. Örneğin bir insansız kara aracının kontrolünü sağlayabilmenin temelinde kontrol edilebilecek değişkenleri sınıflandırabilmektir. Zhi-heng vd. (2017) yaptıkları çalışmada literatürde olan işaret dili eldivenlerine benzer bir şekilde tasarlamışlardır. Eldivenleri ile bir işaret dili sınıflandırma değil kontrol sınıflandırma gerçekleştirmişlerdir. Kullandıkları sınıflandırma modeli DVM ve bu modelden türeyen modelleri kullanmışlardır. 1995 yılında J. Kennedy ve R.C. Eberhart tarafından geliştirilen standart Parçacık Sürü Optimizasyonu (PSO) ve geliştirilmiş PSO algoritmasını DVM algoritmaları ile bütünleştirerek eldiven verileri işlemişlerdir. Çalışma sonucunu test etmek için basit bir robot kontrolü sağlamışlardır.


3. MATERYAL ve METOT

3.1 İşaret Dili

İşaret dili, işitme engellilerin kendi aralarında, işiten ama duyamayan kişilerle ve aynı zamanda normal insanlarla aralarındaki iletişimi sağlamak için tek veya çift ellerini kullandıkları bir dildir. İşaret dili kendine has doğal bir dil olup parmak, el ve yüz gibi işaret ve mimiklerden oluşan bir dildir (Karaca ve Bayır 2018). İşaret dili ile iletişim kuranlar gözlemlendiğinde ve literatür incelendiğinde, iletişimin yüz mimiklerinden ziyade el hareketleri ile sağlandığı görülmüştür. Bu sebep ile iki el için bir eldiven tasarlanmıştır. Her ülkenin kendine özgü işaret dili vardır. TİD ve diğer ülkelerin işaret dilleri farklı işaretlerden oluşur. Buna örnek bölüm 2.1.3’ de verilmiştir.

3.1.1 El Eklemlerinden Öznitelik Çıkarılan Bölgeler

İşitme ve konuşma engellilerin kullandıkları işaret dili eldeki eklemlerin bükülmesi ve ellerin yönelimi ile gerçekleşir. Ellerde bulunan eklemler yapılan işaretin özelliğine göre ellerde bulunan bir veya birden fazla eklem aynı anda bükülebilir. Bunun ile birlikte birçok işaret dili hareketi sadece eklemlerin bükülmesi yeterli değildir. Hareketin yapılışına göre ellerin yönelimi ve ivmelenme vektörü de önemlidir. İşaret dili hareketlerini yapmak için temelde eldeki hareket ettirilen eklemler şekil 3.1’de gösterilmiştir. Genelde uç, orta ve yakın eklemler el hareketlerini yaparken hareket ettirilen eklemlerdir. Eklemler, işaret dilinden oluşan hareketler yapılırken farklı oranlarda bükülmektedir. Eklemlerin bükülme oranlarını tespit etmek amacı ile şekil 3.1’de gösterilen eklemlerin her birinde esneklik (flex) algılayıcılar kullanılmaktadır. Esneklik algılayıcıların bükülme oranına bağlı olarak iç dirençleri değişmektedir. Bu sebep ile parmak eklemlerindeki bükülmeleri tespit etmek için en uygun algılayıcıdır. Uç ve orta kemikler parmak uç kemikleri olarak isimlendirilirken tarak kemikleri ve yakın kemiklerin bağlandığı eklem parmak kökü eklemi olarak da isimlendirilir (İnt.Kyn.3), (Şekil 3.1). El bileği kemikleri ise el yönelimini sağlayan kemiklerdendir. Ellerde oluşan yönelme ve ivmelenmeyi tespit edebilmek amacı ile tarak kemikleri üzerine denk gelecek biçimde ivmeölçer ve dönüölçer algılayıcıları kullanılmıştır.



Şekil 3.1 El üzerinde bulunan öznitelik çıkarılan eklemler (İnt.Kyn.3).

3.2 Kullanılan Materyaller

Projede kullanılan materyaller daha önceki yapılmış çalışmalar incelenerek seçilmiştir. Literatürde işaret dili tanıma üzerine yapılan çalışmalar incelendiğinde üç tip çalışma yoğunluk göstermiştir. Bu çalışmalar video tabanlı işaret dili tanıma, veri eldiveni kullanılarak yapılan tanımlar ve her ikisinin de kullanıldığı hibrit tabanlı çalışmalardır. Veri eldiveni kullanılarak yapılan çalışmalarda kullanıcı tarafından giyilebilen bir eldiven söz konusudur. Eldivende işaretleri algılamak amacı ile çeşitli algılayıcılar bulunmaktadır. Bu algılayıcılar temelde esneklik ve AÖB algılayıcılarından oluşmaktadır. Veri seti oluşturmak amacı ile deneklerden veriler toplanır ve ardından çeşitli tanıma algoritmaları kullanılarak tanıma işlemi gerçekleştirilir. Tanınan işaretler bir metinden ses çevirici veya bir kişi tarafından önceden oluşturulmuş ses dosyalarına karşılık olarak ses çıktısı olarak oynatılır. Hibrit tabanlı yapılan çalışmalarda ise hem video hem de algılayıcılardan oluşmuş eldivenler kullanılmaktadır. Video tabanlı ve algılayıcılardan oluşan eldivenlere benzer şekilde veri seti hazırlanır. Daha sonra görüntü işleme ve tanıma algoritmaları ile birlikte eldivenden toplanan verilerde kullanılarak tanıma işlemi gerçekleştirilir.

3.2.1 Esneklik Algılayıcı

Esneklik algılayıcı, kıvrılmaya bağlı olarak direnci değişebilen Polimer veya Asetat gibi malzemelerden oluşturulmuş genellikle şeritler şeklinde bir devre elemanıdır (Ahmed vd. 2018). İç dirençleri kıvrılma ile doğru orantılı biçimde değişebilir. Piyasada çoğunlukla 5.5 cm ve 11.4 cm uzunluklarında bulunurlar. Esneklik algılayıcılarının çalışma prensibi belli bir iç dirence sahip şeritlerin bükülme oranı ile doğru orantılıdır. Bükülme oranı arttıkça algılayıcının iç direnci de buna bağlı olarak artmaktadır. Yapmış olduğumuz bu çalışmada parmakların büküm ve eğimlerini tespit etmek için 10 adet 11.4 cm ve 2 adet 5.5 cm uzunluğunda esneklik algılayıcı şerit kullanılmıştır. Kullanılan esneklik algılayıcının temel özellikleri şu şekildedir (Zhi-heng vd. 2017);

- Kıvrılma ömrü: > 1 Milyon
- Çalışma sıcaklığı: -35 C - +80 C
- Düz haldeki direnci: 10 Kohm
- Kıvrılma direnç aralığı: 1 Kohm – 20 Kohm
- Sürekli durumda güç durumu: 0.5 Wat




Resim 3.1 5.5 cm uzunluğunda esneklik algılayıcı.

3.2.2 Dönü Ölçer ve İvme Ölçer

AÖB temel olarak içinde açısal hız ve doğrusal ivmelenme verilerini toplayan algılayıcıların bulunduğu tek bir elektronik parçadır. İvmeölçer uzaydaki 3 eksen için ivmelenme verisi sağlar. Her eksen için bağlı bulunduğu işlemci birimine göre 8, 10, 12 bit türünde analog sinyal üretir. Örneğin 10 bitlik çözünürlüğe sahip bir işlemciye bağlı olan ivmeölçer 0 ve 1023 arasında analog sinyal üretir. Dinamik olarak ani hızlanma ve

durma ivmelenmesini ölçebilmektedir. İvmeölçerler durağan olarak yer çekiminden etkilenebilmektedirler. Bundan dolayı yer çekimi etkisini sıfırlamak için algılayıcılar kalibre edilmesi gerekmektedir. AÖB tümleşik elektronik parçasının içinde bulunan diğer bir algılayıcı ise uzaydaki dönme hareketlerini algılayan jiroskop 'dur. Jiroskop açısal olarak dönmeyi algılayabilen ve buna bağlı olarak çıkış sinyali üretebilen algılayıcılardır. Bu iki algılayıcı tek başlarına kullanıldıklarında yeterli ve istenilen bilgileri sağlayamamaktadır. Birlikte kullanıldıklarında ise hız ve pozisyon gibi bilgileri sağlayabilmektedirler (Chandra 2019). AÖB algılayıcıları kullanılırken küçük titreşimlerden çok fazla etkilenebileceğinden kalman filtresi, medyan filtresi vb. filtrelerden geçirilerek kullanılması uygundur. Ayrıca bu AÖB'lerin kullanım alanları oldukça geniştir. Bu sebeple piyasada oldukça fazla çeşitleri bulunabilir. Bu çalışmada ellerin dönme ve yönelimi tespit etmek için kullanılan AÖB, Bosch markası tarafından desteklenen Adafruit BNO055 modelidir. Bu model AÖB'nin kullanılma sebebi ise daha hassas ve doğru ölçüm yapabilmedir. Ayrıca BNO055 üzerinde ARM Cortex-M0 işlemciye sahip olduğundan işlem hızı oldukça fazladır. BNO055 AÖB algılayıcısının özelliklerini şu şekilde sıralanabilir;

- Ağırlık: 3gr
- İletişim: I2C
- Açısal hız ve ivme vektörü ölçümü
- Doğrusal ivme vektörü ölçümü
- Sıcaklık ölçümü
- Manyetik alan şiddeti ölçümü
- Yer çekimi vektörü ölçümü



Resim 3.2 Çalışmada kullanılan Adafruit BNO055 model AÖB algılayıcısı.

3.2.3 Manyetik Alan Algılayıcı

Manyetik alan algılayıcıları ortamdaki manyetik alan değişimini algılayıp buna bağlı olarak çıkış gerilimi üreten algılayıcılardır. Bu algılayıcılar otomasyon, güvenlik, konumlandırma, anahtarlama vb. alanlarda kullanılır. Manyetik alan algılayıcılarının endüstride kullanılan birçok çeşidi bulunmaktadır. Temelde iki çeşit manyetik alan algılayıcısı bulunmaktadır. Bunlar doğrusal manyetik alan ve eşik manyetik alan algılayıcısıdır. Doğrusal manyetik alan algılayıcı, istenilen bit çözünürlüğü arasında manyetik alanın kuzey ve güney kutbuna bağlı olarak analog sinyal üretebilmektedir. Ayrıca üretilen bu sinyal manyetik alanın yoğunluğu ile doğru orantılı olarak değişmektedir (Ahmed vd. 2018). Eşik manyetik alan algılayıcı ise ayarlanan belli bir çözünürlükten sonra sinyal seviyesinde keskin düşüslere sahiptir. Diğer bir değiş ile Smith-Trigger devrelerine benzer devreler sayesinde '1' veya '0' olarak sinyal üretilmektedir. Bu çalışmada kullanılan manyetik alan algılayıcı, SS49E model doğrusal algılayıcıdır. İşaret dilindeki hareketlerden bazıları avuç kapatma ve ellerin birbirlerine temas ettirilmesi ile oluşmaktadır. Bu hareketleri tespit edebilmek için manyetik alan algılayıcıları kullanılmıştır. Algılayıcıların manyetik alan ile etkileşimde bulunabilmesi için eldivenin avuç içlerine mıknatıs montelenmiştir. Bobin içerisinde indüklenen manyetik alanların yanında manyetik alan algılayıcı durağan olan manyetik akıyı ölçebilmektedir (Resim 3.3). Kullanılan manyetik alan algılayıcı 3.3 volt (V) gerilim ile çalışmaktadır. Bu algılayıcı manyetik alana çift yönlü tepki verebilmektedir. Yani manyetik alan algılayıcısından doğrusal olarak Kuzey (N) kutbu akışı sağlandığında çıkış direnci artmaktadır. Algılayıcı üzerinden Güney (S) kutbu manyetik akış sağlandığında çıkış direnci düşmektedir.




Resim 3.3 Çalışmada kullanılan manyetik alan algılayıcı.

3.2.4 Çoklayıcı (Multiplexer - MUX) Devre Elemanı ve Voltaj Düzenleyici

Sinyal çoklayıcı devre elemanlarının lojik kapılardan oluşan veya sinyal yükseltici gibi çeşitli özellikteki türleri mevcuttur. Yapmış olduğumuz çalışmada kullandığımız sinyal çoklayıcı devre elemanı modeli CD74HC4067'dir. Sinyal çoklayıcı devre elemanının kullanılma sebebi, geliştirme kartı üzerindeki analog giriş çıkış (I/O) bağlantılarının esneklik ve manyetik alan algılayıcıları için yetersiz kalmasıdır. Kullanılan sinyal çoklayıcı modeli bir adet sinyali lojik kapılar sayesinde 16 adet giriş-çıkış sinyaline dönüştürebilmektedir. Çalışma mantığı ise devre elemanı üzerinde bulunan 4'ü lojik kapılar için dijital giriş sinyali ve 1'i çoklanacak olan analog veya dijital sinyal için giriş-çıkış olan toplam 5 adet kontrol bağlantısı bulunmaktadır. Lojik kapıları açıp kapatmak için ikilik sayı sistemi kullanılır. Bu sayede tek bir sinyal 16 adet giriş-çıkış sinyali olarak kullanılabilir. Çoklayıcı devre elemanı kullanarak 16 adet giriş-çıkışdan analog sinyal okuması yapmak için çoklayıcı üzerinde bulunan 4 adet lojik kapının sırası ile döngü içinde hızlıca açılıp kapatılması gerekmektedir. CD74HC4067 çoklayıcı devre elemanının özellikleri aşağıdaki şekildedir;

- Çalışma voltajı: 4.5 Volt – 5 Volt
- Çalışma sıcaklığı: -55 Derece – +125 Derece
- Lojik kapı hızları: 5 Voltta – 450 Nanosaniye
- Boş kapı 'AÇIK' direnci: 65 Ohm



Resim 3.4 Çalışmada kullanılan CD74HC4067 çoklayıcı (Multiplexer- MUX) devre elemanı.


Voltaj düzenleyici, gerilimi belirli bir seviyede sabit tutmak için kullanılır. Elektronik cihazlar gerilimdeki oluşan dalgalanmalara karşı korumasız olduğundan voltaj düzenleyici kullanılır. Düzenleyiciler yangın güvenlik sistemleri, otomasyon ekipmanları gibi birçok yerde kullanılırlar. Düzenleyiciler servo, statik ve mikroişlemci gibi tipleri bulunmaktadır. Temel olarak trafo olarak da bilinirler. Giriş ve çıkış sargılarının oranı değiştirilerek gerilim seviyesi değiştirilebilir. Düzenleyici gerilim, akım, frekans gibi özelliklerin hem sabit tutulmasında hem de ani oluşan değişimlerin devrelere zarar vermesini engellemek amacı ile kullanılır. Yapmış olduğumuz çalışmada kullandığımız güç kaynağı 7.4 Volt'dur. Tasarlamış olduğumuz kontrol kartında 5 Volt ve 3.3 Volt gerilim ile çalışan devre elemanları bulunmaktadır. Bu sebeple iki adet elektronik voltaj düzenleyici devresi kullanılmaktadır. Kullanılan düzenleyici modeli AMS1117 5V ve AMS1117 3.3V modeli kullanılmıştır. Özellikleri şu şekilde sıralayabiliriz;

AMS1117 5V

- Giriş voltajı: 6 VDC – 12 VDC
- Çıkış akımı: 5 VDC
- Maximum çıkış akımı: 800 mA

AMS1117 3.3V

- Giriş voltajı: 4.5 VDC – 7 VDC
- Çıkış akımı: 3.3 VDC
- Maximum çıkış akımı: 800 mA




Resim 3.5 AMS 1117 elektronik voltaj düzenleyici.

3.2.5 Arduino Pro Mini 5V - 16 Mhz

Arduino, 7'den 77'ye birçok insana hitap eden elektronik ve yazılımsal projelerde kullanılabilen bir mikro denetleyici geliştirme kartıdır. Arduino geliştirme kartlarının Nano, Uno, Mega, Leonardo gibi farklı boyutlarda ve özelliklerde modelleri bulunmaktadır. Temel olarak benzer işlemci yapılarına sahip olsa da farklı uygulamalar için özelleştirilmiş modelleri bulunur. Arduino kartlarının üzerinde 8 bitlik yüksek performanslı ve düşük güç tüketimine sahip olan bir ATmega mikro denetleyici çipi bulunmaktadır. ATmega denetleyicileri model yapılarına göre elektronik Printed Circuit Board (PCB) kart üzerine monte edilmiştir. Elektronik projelerde kullanılmak amacı ile üretilen Arduino modelleri üzerinde çoğunlukla elektronik devrelere zarar vermemek ve yanlış voltaj beslemelerinden kaçınmak için voltaj düzenleyicileri bulunur. Projede kullanmış olduğumuz Arduino modeli Arduino Pro Mini 5V 16 MHz modelidir. Bu kartın projede kullanılma sebebi ise Arduino modelleri arasında küçük boyutlarda olması ve aynı zamanda 16 MHz işlem hızına erişebilme yeteneğidir. Boyutunun vermiş olduğu avantajın yanı sıra giriş-çıkış bağlantılarının azlığı ve bu model üzerinde voltaj düzenleyicinin bulunmaması birer dezavantajdır. Bu sorunlar ile başa çıkabilmek amacı ile bağlantı çoğaltıcı devre (çoklayıcı) kullanılmıştır. Arduino kartının 5 Volt sabit bir doğru gerilime ihtiyacı olduğundan karta güç vermek için harici bir voltaj düzenleyici kullanılmıştır. Arduino Pro Mini 5V 16 MHz modelinin özellikleri şu şekildedir;

- Çalışma gerilimi: 5 VDC
- Giriş-Çıkış bağlantı sayısı: 16 Adet
- PWM bağlantı sayısı: 6 Adet
- Haberleşme: UART, I2C, SPI
- Analog bağlantı sayısı: 6 Adet
- Bağlantı başına kullanılan doğru akım: 40 mA
- Flash Bellek: 32 KB
- SRAM: 2 KB
- EEPROM: 1 KB
- Saat hızı: 16 MHz




Resim 3.6 Arduino Pro Mini 5V 16MHz programlama birimi.

3.2.6 NVIDIA Jetson Nano Geliştirici Kit

Geliştirici kitler üzerinde programlama, elektronik projeler, denemeler yapabilmeye imkân sağlayan işlemci ve arabirimlerden oluşan elektronik karttır. NVIDIA tarafından üretilen Jetson Nano geliştirme kartı bu tip kartlara örnek olarak gösterilebilir. Graphic Processing Unit (GPU), normal işlemcilerden farklı olarak cihazlardaki görüntü, video, oyun vb. işlemlerde devreye girer ve Central Processing Unit (CPU)'lardan daha etkin kılar. Temelde depolama ve bellek yönetimi gibi işlemleri CPU yönetir. Ancak son zamanlarda grafik işlemcileri oldukça geliştiğinden CPU'ların yapabileceği işlemleri de yüklenebilmektedir. Son dönemlerde piyasaya girmeye başlayan bu tip grafik işlemcileri üzerinde CPU ile birlikte üretilmektedir. Jetson Nano, üzerindeki görüntü ünitesi ve CPU ile birlikte küçük ve güçlü bir bilgisayar olarak son kullanıcıya sunulmaktadır. Jetson Nano üzerindeki GPU sayesinde görüntü işleme, görüntü bölütleme, yapay zekâ algoritmaları vb. yüksek kapasite gerektiren işlemler hızlı bir şekilde gerçekleştirilebilmektedir. Paralel işleme yeteneği sayesinde birden fazla yapay zekâ algoritmasını ve algılayıcıları aynı anda çalıştırabilmektedir. Çalışmamızda Jetson Nano geliştirme kartını kullanmamızın sebebi boyutları ve yeteneklerinin yanı sıra işaret dili hareketlerini tanımak için farklı yapay zekâ modelleri test edebilmektir. Eldivenlerden bluetooth ile gelen işaret dili verileri bu birimde işlemlere taabi tutularak tanıma işlemi gerçekleştirilmiştir. Jetson Nano geliştirme kartının özellikleri şu şekilde sıralanabilir (İnt.Kyn.5);

- Güç: Mikro USB (5 Volt, 2 Amper) – DC güç bağlantısı (5 Volt, 4 Amper)
- CPU: 1.4GHz 4 Çekirdekli ARM Cortex A57
- GPU: 128 Çekirdekli Maxwell
- Bellek: 4GB 64Bit LPDDR4
- Depolama: Mikro SD (Harici)
- Ekran: HDMI ve Display Port
- Arabirimler: Gigabit Ethernet kartı, 4 adet USB 3.0 1 adet USB 2.0, CSI Kamera
- Diğer iletişim: GPIO, I2C, I2S, SPI, UART
- Boyut: 100mm x 80mm x 29mm




Resim 3.7 Çalışmada kullanılan NVIDIA Jetson Nano Geliştirici Kiti.

3.2.7 Bluetooth İletişimi

Bluetooth, cihazlar arası kablolama sistemini ortadan kaldıran bir kısa dalga radyo frekansdır (Çıbuk ve Maraşlı 2015). Cihazlar arasında haberleşme, kablolar olmadan yürütülerek kablo kalabalığını ortadan kaldırmış ve böylelikle görsel olarak bir ergonomi sağlanmış olur. Bluetooth teknolojisi 2.4 GHz frekans bandında iletişimi sağlar ve bluetooth modellerine göre iletişim mesafeleri 10 – 100 metre arasındandır. Bluetooth cihazları Institute of Engineers and Everyone Else (IEEE) tarafından belirlenen bir IEEE 802.15.1 standardı içerisinde yer almaktadır. Radyo frekansları (RF), görüntü, veri ve ses gibi bilgilerin yüksek frekanslı bir elektromanyetik dalga tarafından yayımlanan sinyaldir.

RF'larını üreten devre elamanları sayesinde ilgili frekanstaki alıcılara sinyal gönderilir. Radyo ve televizyon gibi cihazlara karasal, uydu vb. yayın türüne göre belirli frekans aralıklarında sinyaller gönderilerek veya alınarak bu tip cihazların çalışması idame ettirilir. Cihazlarda kullanılan bluetooth modelleri farklılık göstermek ile birlikte bluetooth'lar farklı boyutlarda üretilebilir. Okullarda eğitim amacı ile kullanılan bluetooth modelleri çoğunlukla HC-01, HC-05 ve HC-06 modelleridir. Bunun haricinde Yüzey Montaj Devre Elemanı (YME) adı verilen küçük boyutlu bluetooth'lar da piyasada bulunur. Yapmış olduğumuz çalışmada kullandığımız bluetooth küçük boyutlu bir devre elemanı olup piyasada HM-11 olarak bulunabilir. Bluetooth, veri seti oluşturulurken iki elde de bulunan eldivenler arasındaki haberleşmeyi sağlamak ve tanıma işlemini gerçekleştirirken Jetson Nano ile haberleşmeyi sağlamak amacı ile kullanılmıştır. HM-11 model bluetooth'larda otomatik cihaz arama, tekrar bağlanma ve efendi-köle gibi birçok işlevinin bulunması ve küçük olması HM-11 modelini kullanışlı hale getirmektedir. HM-11 bluetooth modelinin özelliklerini aşağıdaki gibi sıralayabiliriz;

- Çalışma frekansı: 2.4GHz ISM bandı
- Ara yüz: Seri port
- Modülasyon: Gauss Frekans Slider Key (GFSK)
- İletim gücü: 0-26 DBM (ayarlanabilir)
- Güç: 3.3 VDC, 50 mA
- Bluetooth protokolü: V4.0 BLE



Resim 3.8 Çalışmada kullanılan HM-11 model bluetooth cihazı.

3.3 Güç Kaynağı ve Güç Gereksinimleri

Yaptığımız projede eldivenlerden verileri toplamak ve işaret dili tanımak için bluetooth, AÖB, devre elemanları, esneklik ve manyetik alan algılayıcılarının çalışabilmesi için güç sistemine ihtiyaç duyulmaktadır. Kullanılan algılayıcılar ve devre elemanları düz kaynaklı elektriksel akım kaynağına ihtiyaç duymaktadırlar. Bunu sağlamak için Lityum İon (Li-Ion), Nikel-Kadmiyum (Ni-Cd), Nikel-Metal Hibrit (Ni-MH) ve Lityum Polimer (Li-Po) gibi çeşitli türde piller kullanılabilir. Yapmış olduğumuz çalışmada Lityum Polimer (Li-Po) pil tercih edilmiştir. Bunu sebebi ise Li-Po pillerin farklı boyutlarda ve yassı hücrelere sahip olmasıdır. Bu projede kullanılan 2 hücreli 30 gramlık 7.4 Volt üretebilen ve sisteme 750 mA akım verebilen Li-Po pil kullanılmıştır. Bu pil seçimini yaparken kurulan eldiven devresinin tükettiği akım ve ne kadar süre çalışacağı çizelge 3.1’de gösterilmiştir.

Çizelge 3.1 Bir eldiven için algılayıcıların ve devre elemanlarının çalışma gerilimi ve tükettikleri akımlar

Adet	Eleman	Çalışma Gerilimi	Çektiği Akım
6	Esneklik Algılayıcı	5 V	$0.25 \times 6 = 150\text{mA}$
5	Manyetik Alan Algılayıcı	3.3 V	$5 \times 3 = 15\text{mA}$
1	AÖB	5 V	12.5mA
1	Arduino Pro Mini	5 V	Her I/O için $40 \times 5 = 200\text{mA}$
1	Bluetooth HM-11	3.3 V	15mA
3	Led	3.3 V	$20 \times 3 = 60\text{mA}$
1	Buzzer	5 V	30mA
1	Bağlantı Çoklayıcı	5 V	71mA
1	MikroSD Kart Okuyucu	5 V	15mA
TOPLAM			600mA


İşaret dili tanıma için kullanılan algılayıcıların ve devre elemanlarının çalışma voltajları ve çektiği akımlar çizelge 3.1’de gösterilmiştir. Toplamda bir el için eldivenin çekebileceği maksimum akım 600mA’dır.

$$Pil (saat) = \frac{Pil Kapasitesi (mAh)}{\text{Çekilen Akım (mA)}} \times 0,707 \quad (3.1)$$


Pil kullanım ömrünü hesaplamak için denklem 3.1’de sistemin akım değeri yerine konulduğunda eldivenin çalışma süresi 53.02 dakika olarak hesaplanır. Bu değer yaklaşık bir değer olup kullanılan pilin ve sistemin çalışma durumuna göre değişiklik gösterebilmektedir.

3.4 Kontrol Kartı Devre Şeması

Eldivenden verilerin toplanabilmesi ve kayıt edilip Jetson Nano’ ya gönderilebilmesi için Arduino Pro Mini mikro denetleyicisi kullanılarak bir kontrol kartı tasarlanmıştır. Kontrol kartı çoklayıcı devre elemanı, bluetooth, Arduino Pro Mini ve devre elemanlarından oluşmaktadır. Çalışmada kullanılan malzemeler tek bir bakır levha kart üzerinde toplanarak yerlerin montajlanmıştır. Bakır levha, üzerine devre şeması çizilebilen ve devre elemanları montajlanabilen yalıtkan bir malzeme ile ince bir bakır tabakanın birleştirilmesiyle elde edilir. Bakır levha teoride oluşturulan elektriksel devreyi veya devre şemasını pratikte gerçekleştirmek amacıyla kullanılır. Devre şeması Ek.1’de gösterilmiştir. Bakır levha için baskı devresi Eagle (sürüm 7.7.0) programı kullanılarak oluşturulmuştur (Şekil 3.2).



Resim 3.9 Bakır levha üzerine geçirilmiş baskı devre şeması.



Şekil 3.2 Hazırlanan Kontrol kartı PCB Baskı için Eagle programında çizilmiş devre şeması.

3.5 Veri Setinin Oluşturulması


Veriler esneklik algılayıcı, manyetik alan algılayıcısı ve AÖB'lerden işaretin oluşturulma süresince veriler toplanır. Bu algılayıcılardan belirli sayıda örnekler alınarak hafıza kartına kaydedilir veya bluetooth kullanılarak 115200bps hızında Jetson Nano'ya aktarılır. Esneklik algılayıcılarından oluşturulan veri, Arduino Pro Mini'nin çözünürlük değerine bağlı olarak 0 ve 1023 aralığında sayılar olarak toplamda 1024 sayı ile kaydedilir. Çözünürlük, basit olarak bir bütünü kaç parçaya böleceğimiz anlamına gelmektedir. Yani Arduino Pro Mini sahip olduğu maksimum 5 Volt çıkış sağlayabilen analog bağlantıların voltajını 1024 defa parçalayabilir. Bunu $\mathcal{C}_{anlg} = \frac{5v}{1024}$ olarak analog çıkış değerini hesaplayabiliriz. Dolayısıyla Arduino Pro Mini analog giriş voltajını da bu

şekilde 1024' e tamamlayarak giriş voltaj değerini nümerik bilgiye dönüştürebilmektedir. Arduino Pro Mini'den farklı geliştirme kartları farklı çözünürlük değerlerine sahip olabilir. Ayrıca bu çözünürlük değerleri kullanıcı tarafından 2'nin kuvvetleri şeklinde değiştirilebilir. Manyetik alan algılayıcıları, manyetik alan şiddetine ve polaritesine bağlı olarak analog sinyal üretir. Bu durumda manyetik alan algılayıcıları, esneklik algılayıcıları gibi analog olarak 0 - 1023 arasında sayılara dönüştürülür. AÖB, bir işlemci birimine sahip olmak ile birlikte ivmeölçer ve dönüölçer algılayıcılarına de sahiptir. AÖB'nin mikro işlemcisi kendi devre kartı üzerinde bulunan algılayıcılardan verileri okur ve diğer bir okumaya kadar mikro işlemci kendi geçici belleğine yazar. Ardından bu geçici belleklere anlık olarak kaydettiği veriler farklı bir işlemci veya bir haberleşme birimi ile geçici belleklerden okunur. AÖB' nin işlemcisinden okunan ivme ölçer verisi, yer çekimi ivmesi de dikkate alınarak kalibre edilir. Ardından buna bağlı olarak veriler yeniden düzenlenerek hafıza kartınıza kaydedilir veya bluetooth ile gerekli birime iletilir. Resim 3.10' da sağ eldivenden elde edilen örnek yalnızca “ben” işareti için elde edilen örnek veridir. Veriler Resim 3.10'da gösterilen formatta toplanarak ardından istatistiksel öznitelik çıkarımı işlemleri gerçekleştirilir.

```
842,586,575,637,595,658,347,337,344,336,337,4,-5,-1,232,8,93
843,584,572,625,593,654,347,336,344,335,337,5,-5,-2,245,13,93
844,582,571,624,590,651,347,336,344,335,337,5,-5,-3,255,17,91
840,580,571,623,589,649,347,337,344,335,337,6,-5,-2,270,24,88
832,579,571,624,589,648,347,337,344,335,337,7,-6,-2,281,29,86
828,580,571,624,589,646,347,336,344,335,337,8,-6,-2,296,36,78
825,581,570,624,589,644,347,336,344,335,337,8,-5,-1,304,40,70
821,582,570,624,588,643,347,336,344,335,337,9,-4,0,314,45,58
816,583,571,624,588,642,347,337,344,335,337,11,-5,1,320,48,50
811,584,571,624,588,642,347,336,344,335,337,11,-3,1,329,54,37
805,587,571,624,588,642,347,336,344,335,337,12,-3,1,335,57,27
801,590,571,624,588,642,347,336,344,335,337,12,-1,2,341,60,11
799,592,571,624,587,641,347,337,344,336,337,12,0,2,345,61,1
797,594,571,623,585,641,347,336,344,335,337,13,2,3,351,62,-11
794,595,570,622,584,641,347,336,344,335,337,14,1,4,355,63,-16
793,596,570,621,582,640,347,336,344,335,337,15,0,4,4,64,-23
793,596,569,620,579,640,347,337,344,335,337,14,-3,4,10,64,-28
794,596,568,618,577,639,347,336,344,335,337,14,-4,4,18,63,-36
794,597,567,616,576,638,347,336,344,335,337,12,-4,5,22,62,-41
794,597,567,615,574,637,347,337,344,336,337,10,-1,4,24,61,-45
794,597,566,614,574,636,347,337,344,335,337,9,1,4,24,60,-44
794,597,566,613,573,636,347,337,344,335,337,9,1,5,24,61,-42
793,597,566,613,573,636,347,337,344,335,337,8,0,5,23,61,-34
793,597,566,614,574,637,347,337,344,335,337,8,0,4,24,61,-30
```

Resim 3.10 ‘Ben’ işareti için sağ elden hareket süresince elde edilen örneklemlerin bir kısmı.

Resim 3.10'da sağ elin her bir parmakğından toplanan veriler görülmektedir. Veriler arasında ayırıcı olarak virgül kullanılmıştır. Resim 3.3'de 17 adet algılayıcı verisi görülmektedir. Kelimelerin örneklem sayısı pil durumuna bağlı olarak 80 - 120 adet arasında değişmektedir. Sırası ile soldan sağa doğru, 1-6 arası sütunlar esneklik algılayıcı verilerini, 7-11 arası sütunlar manyetik alan algılayıcı verilerini, 12-14 arası sütunlar oluşan ivmeyi ve 15-17 arası sütunlar yönelimi ifade etmektedir.




Şekil 3.3 Sağ elden elde edilen verilerin bir satırı ve algılayıcıların satırdaki yerleri.

Öznitelik matrisimiz oluşturulduktan sonra bu işlem tüm veri seti için tekrarlanır (Şekil 3.5). Yani bir öznitelik matrisi en nihayetinde 1x272 boyutunda bir matristen oluşur. Bu çalışmada COVID-19 salgını sebebi ile üniversitelerin tatil olması ve öğrencilerin evlerine dönmesi nedeniyle örnek veri toplamada sorunlar ortaya çıkmıştır. Örnek sayısının azalması nedeniyle toplamda 32 adet kelime üzerinde sınıflandırma yapılmıştır. Her bir kelimedenden 30 adet veri toplanarak veri seti oluşturulmuştur. Veri setini oluşturabilmek için öznitelik çıkarımı 32 kelimedenden 30'ar örneklem toplanarak toplamda 960 adet veri içi yapılmıştır. Veri setimiz 960x272 boyutunda işaretleri içeren özniteliklerden oluşmuş bir matristir. Bu veri seti öznitelik matrislerimizin her biri bozuk verileri azaltmak, verileri belirli bir aralıkta değerlendirmek ve tanıma oranını arttırmak için standardize edilmiştir. Veri seti standardize edilirken ortalaması 0 ve standart sapması 1 olacak şekilde standardize edilmiştir. Standardizasyon işlemi Python (sürüm 3.7.6) kullanılarak tüm veri setine uygulanmıştır.


3.6 Eldivenin Oluşturulması

İşaret dilini tanımak için yapılan bu çalışmada üzerine algılayıcılar montelenmiş bir çift eldiven tasarlanmıştır. Her bir eldiven üzerinde 1 adet AÖB, 6 adet esneklik algılayıcı ve 5 adet manyetik alan algılayıcı bulunmaktadır. İşaret dilinde kullanılan işaretlerin dönme ve yönelimini belirlemek için AÖB kullanılmıştır. AÖB 3 eksen dönme ve 3 eksen de yönelim olmak üzere işaretlerin durumu hakkında toplam 6 adet veri sağlamaktadır. İşaret dilinde kullanılan parmak büküm hareketlerini algılamak için 5 parmağa ayrı ayrı ve 1 adet de başparmak ve işaret parmağı arasına olmak üzere 6 adet analog veri sağlayabilen esneklik algılayıcıları yerleştirilmiştir. Esneklik algılayıcıları ve manyetik alan algılayıcıları eldivenin parmak kısımlarına montajlanmıştır. Algılayıcılar görüntü estetiğini bozmamak ve kablo kalabalığı oluşturmamak için dışarıdan görünmeyecek bir şekilde eldivenin iç kısımlarına montajlanmıştır. Esneklik algılayıcılarının bükülme oranını kısıtlamamak amacıyla lastikler kullanılarak eldivene montajı yapılmıştır. Manyetik alan algılayıcıları, parmakların kapatıldığında avuç içine değen uç kısımlarına eldivenin iç tarafından montajı yapılmıştır.




Resim 3.11 (a); Prototip çalışması, (b); Eldivenlere algılayıcıların montajı ve kablolama, (c); Eldivendeki algılayıcılar için kontrol birimi, (d); Çalışmada tasarlanan sol eldiven.

Bazı işaret dili kelimelerinde eller birbirleri ile temas etmektedir (Resim 3.12). Parmakların avuç içine ve diğer elin avuç içine dokunmasını algılamak için ise her parmak ucuna birer adet analog çıkış verebilen manyetik alan algılayıcıları kullanılmıştır.



Resim 3.12 Avuç içlerine parmakların değdiği bazı işaretler. **(a)**; “Orta” kelimesinin işaret dilindeki karşılığı, **(b)**; “Tekrar” kelimesinin işaret dilindeki karşılığı (MEB 2015).


Eldivenden algılayıcı verilerini toplamak için ise boyutları, yeterli derecede işlemci hızı ve kullanım kolaylığı açısından Arduino Pro Mini modeli kullanılmıştır. Ayrıca verileri kaydetmek ve iletişim sağlamak için hafıza kart ve bluetooth birimleri kullanılmıştır. Bu birimleri bir arada toplamak için PCB devre kartı tasarlanmıştır. Tasarlanan PCB kart üzerinde Arduino Pro Mini, hafıza kart birimi, bluetooth birimi, analog giriş/çıkılları çoğaltmak için 1x16 çoklayıcı devre elemanı ve yüzey montaj elemanları bulunmaktadır. Resim 3.13’de tasarlanan PCB kart ve elemanlar görülmektedir.



Resim 3.13 Elektronik devre katının üzerine montajlanmış devre elemanları.

3.7 İstatistiksel Öznitelikler

Her iki eldivenden veriler işaret dili verileri toplanarak veri seti oluşturmak için veri ön işlemeye taabi tutulmuştur. Bu aşamada toplanan veriler üzerinde öznitelik çıkarımı yapılmıştır. Birçok öznitelik çıkarım yöntemi olmakla birlikte elde ettiğimiz verilere uygun olabilecek öznitelik çıkarımı seçilmiştir. Temel olarak eldivenlerdeki her bir algılayıcıdan elde edilen veriler bir özniteliktir. Uygulayacağımız projenin başarımını arttırmak için elde edilen verilerden istatistiksel olarak bir kez daha öznitelik çıkarımı yapılmıştır. Bu aşama da sütunlar eldiven üzerindeki algılayıcılardan gelen her bir işaret verisini ve satırlar ise istatistiksel özniteliklere ifade etmektedir. Şekil 3.4’de işaret matrisinin, öznitelik matrisine dönüştürülme şeması görülmektedir.



Şekil 3.4 Eldivenden gelen bir işaret verisi için öznitelik çıkarıldıktan sonra matris boyutlarının değişimi.

3.7.1 Maksimum ve Minimum

Veri seti oluşturmak için veriler toplandıktan sonra bu verilerden öznitelik çıkarımı yapılmaktadır. Bir işareti yapmak için geçen sürede belirli aralıklarla örneklemeler alınır. Sonuç olarak eldiven üzerindeki algılayıcıların her biri bir sütun oluşturacak şekilde ve

örneklem sayıları ise işaretin yapıldığı sürede satırları oluşturacak biçimde düzenlendiğinde, toplam 34 adet algılayıcı ve 80-120 arasında örneklem sayısı (80-120)x34 boyutunda bir matris oluşmaktadır. İstatistiksel olarak Minimum, değer aralığındaki sayıların en küçük olanını ifade etmektedir. Maksimum ise belirli bir aralıktaki değerlerin en büyük olanını ifade etmektedir. Bir işaret matrisindeki 34 adet algılayıcı için ayrı ayrı minimum ve maksimum değerleri hesaplanır. Oluşturulan (80-120)x34 boyutunda işaret matrisi bu aşamada, her bir sütun için maksimum alındığından 1x34'lük diziye dönüşür. Her bir sütunun minimum değerleri alındığında ise 2x34'lük matrise dönüşür.

3.7.2 Ortalama

İstatistiksel olarak üçüncü öznitelik çıkarımı olan aritmetik ortalama, bir aralıktaki değerlerin toplanarak aralıktaki değerlerin sayısına bölünmesi ile bulunur. İstatistikte ortalamalar olarak bilinen geometrik ortalama, harmonik ortalama, ağırlıklı aritmetik ortalama gibi ortalamalar da mevcuttur. Bu kısım da istatistiksel ortalamalardan bir tane ortalama seçmek yeterli olacaktır. Diğer ortalamaları da öznitelik çıkarımına eklemek bize ek işlem maliyeti getireceğinden yalnızca aritmetik ortalama seçilmiştir. Aritmetik ortalamanın matematiksel formülü aşağıdaki gibidir;

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{N} = \frac{x_1 + x_2 + x_3 + \dots + x_n}{N} \quad (3.2)$$

$\bar{x}$: Aritmetik Ortalama

N : Toplam veri sayısı

x : Veri değeri

Eldivenden gelen (80-120)x34'lük matrisin her bir sütununun aritmetik ortalaması alınarak en nihayetinde 1x34'lük dizi elde edilir ve bu da öznitelik matrisi ile birleştirilerek bu kısma kadar 3x34'lük bir matris elde edilmiş olur.

3.7.3 Ortanca (Medyan)

İstatistiksel öznitelik matrisimizdeki dördüncü satırda olan ortanca özniteliğidir. Ortanca yani medyan olarak bilinen ve istatistikte çoğunlukla demetleme amacı ile kullanılan bir yöntemdir. Ortanca, bir aralıktaki sayıları oluşturan elemanların ortada olanıdır. Yani 15 elemanlık bir serideki ortanca değerimiz 7. sıradaki elemandır. Ortanca değer hesaplanırken tek sayılı eleman serilerinde ortanca değer kolayca bulunurken çift elemanlı serilerde ortanca eleman yoktur. Buna çözüm olarak hesaplamayı yapan istatistikçi veya kişiler bireysel olarak çift elemanlı serilerde ortanca elemanı 2 adet kabul edebilir. Diğer bir çözüm ise 2 adet olan ortanca elemanların aritmetik ortalamasını alarak tek bir eleman elde edilebilir. Bu çalışmada bize gerekli olan yöntem çift olarak çıkan ortanca elemanların aritmetik ortalaması alınarak tek bir elemana ulaşılmasıdır. Eldivenden elde edilen veriler aritmetik ortalamadaki gibi her bir sütun için ayrı ayrı ortanca değer hesaplanır. Ardından bu hesaplanan değerler 1x34'lük öznitelik dizisine dönüştürülür ve bir önceki öznitelik matrisleri ile birleştirilerek 4x34'lük bir matris elde edilir. Bir serideki ortanca elemanın konumunu bulan matematiksel formül aşağıdaki gibidir;

$$X_{Ortanca} = \frac{(n + 1)}{2} \quad (3.3)$$

$X_{Ortanca}$: Ortanca değer konumu

n : Serideki eleman sayısı

Ortanca elemanı bulmak için yukarıdaki formül kullanılarak bir serideki ortadaki elemanın konumu bulunur. Elemanlar çift ise ortadaki elemanların değerlerinin aritmetik ortalaması alınarak ortanca değere ulaşılır.

3.7.4 Standart Sapma

Standart sapma, dağılım ölçü birimlerinden biridir. Bir aralıktaki sayıların dağılımı hakkında bilgi sağlayarak verilerin özetlenmesine yardımcı olur. Veri bilimi ile uğraşan

birçok alanda çoğunlukla kullanılır. Standart sapmanın sonucu verilerin yorumlanmasına yardımcı olmaktadır. Çarpıklık, basıklık, aritmetik ortalama gibi dağılım ve yayılım ölçütleri arasındaki fark irdelenerek verilerin tahmin başarısı hakkında bilgi edinilebilmektedir. Standart sapma oldukça keskin biçimde öznitelik belirtmektedir. Eldivenlerden elde edilen matrisin sütunlarının her biri ayrı ayrı standart sapması alınarak bir işaret için toplamda 34 adet standart sapma özniteliği çıkarılır. Standart sapması alınan veriler 1x34'lük bir diziye dönüşür. Ardından özniteliklerimizin beşincisi olarak öznitelik matrisine eklenerek 5x34'lük matris oluşur. Standart sapmanın matematiksel formülü aşağıdaki gibidir;

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n - 1}}$$

$$= \sqrt{\frac{(x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + (x_3 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n - 1}} \quad (3.4)$$

σ : Standart Sapma

$\bar{x}$: Aritmetik ortalama

x_i : i .sıradaki eleman

n : Serideki eleman sayısı

3.7.5 Varyans Öznitelik Çıkarımı

Varyans, standart sapmada olduğu gibi bir dağılım ölçüsüdür. Verilerin dağılım ve yayılımları hakkında bilgi sağlarlar. Varyans, bir aralıktaki değerlerin dağılımın ortalamasından ne kadar uzak olduğu ile ilgilidir. Varyans, bir serideki değerlerin beklenen değere olan uzaklığı olarak tanımlanmaktadır. Beklenen değer ise serideki sayıların aritmetik ortalamasıdır. Literatürde varyans kare sapması olarak da bilinmektedir. Varyans aynı zamanda standart sapmanın karesidir. Matematiksel formülü aşağıdaki denklem 3.5' deki gibidir;

$$\sigma^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n - 1} = \frac{(x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + (x_3 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n - 1} \quad (3.5)$$

σ^2 : Varyans

$\bar{x}$: Aritmetik ortalama

x_i : i . sıradaki eleman

n : Serideki eleman sayısı

Eldivenlerden gelen verilerin her bir sütunu ayrı ayrı varyansı hesaplanarak 1x34 boyutunda bir öznitelik matrisi satırına dönüştürülmüştür. Ardından öznitelik matrisine eklenerek altıncı öznitelik satırını oluşturmaktadır. Böylelikle 6x34 boyutunda öznitelik matrisi meydana gelmiş bulunmaktadır.

3.7.6 Basıklık (Kurtosis) ve Çarpıklık (Skewness)

Basıklık ve çarpıklık eğrileri, veriler üzerinde analiz yaparak tahmin yürütebilmeye imkân sağlayan istatistik bilimi ölçülerindendir. Bu iki eğri üzerinde normal dağılıma göre pozitif-negatif basıklık veya sağa-sola çarpık analizi yapılarak veriler üzerinde tahmin yürütülür. Çarpıklık, bir veri seti dağılımının simetriklikten ayrılış derecesi olarak tanımlanabilir. Yani veri setindeki değerlerin asimetri derecesi olarak açıklanabilir.

$$\zeta K = \frac{\frac{\sum_{i=1}^n (x_i - \bar{x})^3}{n}}{\sigma^3} \quad (3.6)$$

ζK : Çarpıklık Katsayısı

x_i : i . sıradaki eleman

σ^3 : Standart sapmanın 3. kuvveti

n : Serideki eleman sayısı

Çarpıklık Katsayısı = 0 ise ilgili aralıktaki verilerin dağılımı simetriktir.

Çarpıklık Katsayısı < 0 ise ilgili aralıktaki verilerin dağılımı sola çarpıktır.

Çarpıklık Katsayısı > 0 ise ilgili aralıktaki verilerin dağılımı sağa çarpıktır.

Basıklık, veri setindeki değerlerin sivrilik derecesi olarak nitelendirilebilir. Basıklık, normal dağılım ile karşılaştırılarak negatif basık veya pozitif basık olarak analizi yapılır. Normal dağılım aynı zaman da bir veri setindeki sayı aralıklarının normal dağılım olup olmadığı basıklık ve çarpıklık katsayılarına bakılarak yapılır. Basıklık katsayısı 3 ve çarpıklık 0'a ne kadar yakın olursa veriler o derece normal dağılıma yakındır.

$$BK = \frac{\sum_{i=1}^n (x_i - \bar{x})^4}{n \sigma^4} \quad (3.7)$$

BK : Basıklık katsayısı

x_i : i. sıradaki eleman

σ^4 : Standart sapmanın dördüncü kuvveti

n : Serideki eleman sayısı

Basıklık Katsayısı = 3 ise ilgili aralıktaki verilerin dağılımı normal dağılıma eşittir.

Basıklık Katsayısı < 3 ise ilgili aralıktaki verilerin dağılımı normale göre sivridir.

Basıklık Katsayısı > 3 ise ilgili aralıktaki verilerin dağılımı normale göre basıktır.

Basıklık ve çarpıklık hesaplaması eldivenlerden elde edilen verilerin her bir sütunu için ayrı ayrı hesaplanmıştır. Basıklık yedinci ve çarpıklık sekizinci istatistiksel öznitelik olarak kabul edilmiştir. Basıklık katsayıları 1x34 ve çarpıklık katsayıları 1x34'lük dizi oluşturmuştur. Ardından Öznitelik matrisimize yedinci ve sekizinci satır olarak eklenmiştir. En nihayetinde 8x34 boyutlarında istatistiksel özniteliklerden oluşan veri setimiz oluşmuştur.

3.8 Veri Setinin Normalizasyonu

Veri seti oluşturulurken her bir istatistiksel özellik farklı aralıklarda sayılar oluşturarak veri setinin bozulmasına yol açmaktadır. Bu sebeple verileri tek bir aralıkta normalize

ederek veri seti düzenlenmiştir. Veri setindeki her bir işaretin öznitelikleri ayrı ayrı normalize edilerek tüm işaret dili veri seti '0' ve '1' aralığında değerlere dönüştürülmüştür. Verileri normalize edebilecek ondalık normalizasyon, z-score normalizasyon gibi birçok türetilmiş normalizasyon türleri mevcuttur. Bu çalışmada kullanılan normalizasyon modeli minimum-maksimum normalizasyondur. Minimum-Maksimum normalizasyon formülü denklem 3.8 gibidir;

$$X_{Normalize} = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (3.8)$$

$X_{Normalize}$: Minimum – Maksimum normalizasyon

X_i : i. sıradaki eleman

X_{min} : Seride bulunan elemanların en küçüğü


X_{max} : Seride bulunan elemanların en büyüğü

3.10 Verilerin Bölünmesi

Veri tabanı, istatistiksel öznitelik çıkarımı yapıldıktan ve veri ön işlemlerini bitirildikten sonra kullanacağımız modeller için veri setinin bölünmesi gerekmektedir. Bunun sebebi oluşturacağımız sınıflandırma modelimizi kendi veri setimiz ile eğitip test edebilmemize olanak sağlamasıdır. Öğretici öğrenmeli algoritmalar uygulanacağından sisteme gerçek çıkışı bildiğimiz veri seti ile eğitim ve test yapılmaktadır. Eğitim ve test için 960 adet veri seti kullanılmıştır. Bu veri setinden haricinde eğitilen sistemi doğrulamak için her işareten 10'ar adet örnek alınarak ayrı bir veri seti ile doğrulama yapılmıştır. Öğretici öğrenmede genellikle sınıflandırma algoritmalarını tasarlarlarken veri seti dörde bölünmektedir. Bunlar;

- Girdi verisi
- Çıkış verisi
- Test girdisi verisi
- Test çıktısı verisi

Veri seti ve çıktı sınıfları ile birlikte toplamda dörde bölünerek oluşturulacak modeller için hazırlık yapılır. Model eğitimi için girdi ve çıktı verisi ayrılır. Modelin kendi başarımını test edilebilmesi için ise test girdisi ve test çıktısı olarak ayrılır. Yani veri setimiz girdi ve test girdisi olmak üzere iki adet girdiden oluşur. Çıkış ve test çıktısı olmak üzere iki adet çıktıdan oluşur. Veri seti en nihayetinde eğitim ve test olarak ikiye bölünür. Veri seti bölünürken tüm veri setine dörde 1 oranla bölünmüştür. Yani 960 adet işaret örneği ve işaret sınıfı, 720 adet eğitim verisine ve 240 adet test verisine bölünmektedir. Veri seti bölünürken test verilerinin tamamı baştan veya sondan sıralı şekilde alınmamalıdır. Bu durum eğitim başarısını olumsuz yönde etkilemektedir. Bu sebep ile veri seti bölümü 960 işaret içerisinde rastgele olarak 240 adet veri seçilerek bölünmelidir. Bunu açıklamak gerekirse, veri setinden blok halinde veri bölmek bazı sınıfların kaybolabileceği ve oluşturulan modele hiç bilmediği bir işaret sınıfını sınıflandırması isteneceği anlamına gelir. Dolayısıyla bu şekilde eğitilen model test için ayrılmış 240 adet veriyi yanlış sınıflandırması anlamına gelmektedir. Şekil 3.5’de veri setinin test ve eğitim için bölünmesi görülmektedir.




Şekil 3.5 Öznitelikleri alınarak oluşturulan veri setinin eğitim ve test olarak bölünmesi.

3.11 Çıkış Verilerinin İkili Sayı Sistemine Dönüştürülmesi

İşaret dilinin her bir hareketi için bir dizi veri toplanmaktadır. İşaret dilinde yapılan hareket bir kelimeye veya bir anlama denk gelmektedir. İşaret dili ile ifade edilen her bir kelime için girdi veri seti ile beraber bir de çıktı veri seti oluşturulur. Tahmin ve sınıflandırma algoritmaların da çıkış sınıflarını kullanabilmek için ya kategorik (isim, renk, şehir, kadın-erkek) ya da nümerik (yaş, sıcaklık, otomobil sayısı) olarak çıkışlar belirlenmelidir. Bu çalışmada sınıflandırma algoritmaları kullanacağımız için çıkış sınıfları kategorik olarak belirtilmelidir. Sınıflandırmada kategorik olarak nitelendirilen ikili ve çoklu sınıflandırma mevcuttur (Cheng ve Hüllermeier 2009).

- **İkili sınıflandırma:** Çıktı sınıflarının binominal olarak belirtildiği sınıflandırma biçimidir. Çıkış sınıfları '1' ve '0'lerden oluşan sadece iki sınıfın olduğu sınıflandırma çeşididir. Örnek olarak bazı bilgileri verilen insanları kadın veya erkek olarak sınıflandırılması ikili sınıflandırmadır. Diğer bir örnek olarak bir kişinin ekonomik durumu verilerine bakılarak kredi verilir veya verilmez olarak sınıflara ayrılabilir.
- **Çoklu sınıflandırma:** Çıktı sınıflarının 2'den çok sınıflardan oluştuğu durumlarda kullanılır. Sınıflar '1' veya '0' olarak nitelendirilemeyecek kadar çok olduğunda sınıflar ikilik kod şeklinde düzenlenir. Yani bir sınıf '0 0 1' olarak nitelendirilirken diğer bir sınıf '0 1 0' olarak nitelendirilir. Sınıf sayısı arttıkça o sınıfa ait ikilik kod eleman sayısı da artar. Örneğin bir futbol takımının önceki verilerine bakılarak galibiyet, mağlubiyet veya beraberlik gibi sınıflara ayrılması çoklu sınıflandırmaya örnek olarak verilebilir.

Yapmış olduğumuz bu çalışma da işaret dili ikiden fazla sınıf içerdiğinden çoklu sınıflandırma kullanılmıştır. Oluşturulan model 32 adet sınıftan meydana gelmektedir. Şekil 3.6'da ikili ve çoklu sınıflandırma arasında ilişki gösterilmiştir.



Şekil 3.6 Değişken tipleri ve çıkış verilerin nominal değişkenler olarak kodlanması.

Veri setinde bulunan çıkış verilerini nominal olarak kodlayabilmek için Python platformu kullanılmıştır. Bu çalışmada çıkış sınıflarını kodlayabilen Python platformu için geliştirilmiş bir makine öğrenmesi kütüphanesi olan ‘Scikit-Learn’ içinden ‘OneHotEncoder’ fonksiyonu kullanılmıştır.

3.12 Sınıflandırma Algoritmaları

Sınıflandırma algoritmaları satış, bankacılık, medikal ve mühendislik alanlarında insanlara yardımcı olmaktadır. Sınıflandırma bir grup veriyi belirli bir amaca (risk, güvenlik vb.) bağlı olarak analiz etmektir. Sınıflandırma algoritmaları temelde öğrenme ve sınıflama olarak iki adımda gerçekleşmektedir (Han vd. 2011s327-328). Verilerin tahmini ve sınıflandırılmasında istatistiksel yöntemler mühendislik disiplinleri ile iç içe geçmiştir. Bu çalışmada kullanılan istatistiksel sınıflandırma yöntemlerinden bazıları ve yapay sinir ağları ile sınıflandırma kullanılmıştır.

3.12.1 Lojistik Regresyon

Lojistik regresyon bir sınıflandırma algoritmasıdır. Regresyon kelime olarak bağlanım anlamındadır. Veriler arasındaki ilişkiyi tanımlamak için kullanılmaktadır. Lojistik regresyon sayısal verileri tahmin edebilen algoritmalarda kullanıldığı gibi sayısal olmayan kategorik değişkenleri sınıflandırmak için kullanılır. Regresyon modeli sınıflandırmalar genellikle sınıf grubunun az olduğu durumlarda başarılıdır. Regresyon modeli sınıfları türevleri hariç temelde 2 grupta incelenirler. Bunlar doğrusal regresyon ve lojistik regresyondur. Bu modeller olay uzayındaki sınıfları bir doğru veya bir logit tipi fonksiyon ile sınıflandırmaya çalışırlar (Dreiseitl ve Ohno-Machado 2002).

- **Doğrusal regresyon:** Doğrusal regresyon, veri kümesinin aşırı karmaşık olmadığı durumlarda başarılı sonuçlar vermektedir. Doğrusal olarak olay uzayındaki sınıfları bir doğru ile ayırmaya çalışarak sınıflandırır. Doğrusal regresyon sınıflandırmayı yaparken her defasında hata oranını hesaplayarak doğru fonksiyonu en az hata ile sınıfları ayıracak şekilde belirler. Doğrusal regresyon modelinin hesaplayacağı doğru fonksiyonu ve hata güncelleme formülü aşağıdaki gibidir (Denklem 3.9). Hata güncellemesi, noktaların bulunan doğruya uzaklığıdır. Noktaların doğruya olan uzaklıkları en aza indirilene kadar hata güncellemesi devam etmektedir (Hope 2020).

İki boyutlu olay uzayı için;

$$y = ax + b \quad (3.9)$$

y : y boyutundaki veriler

x : x boyutundaki veriler

a : fonksiyon katsayısı (eğim)

b : fonksiyon sabiti (kesen)

$$HKT = \sum_{i=1}^n h_i^2 = \sum_{i=1}^n (y_i - b - ax_i)^2 \quad (3.10)$$

a : Fonksiyon katsayısı (Eğim)

b : Fonksiyon sabiti (kesen)

HKT : Hata kareler toplamı

n : Eleman sayısı

i : i . sıradaki eleman

Doğrusal regresyon eğimi (a) ve kesen değeri (b) hesaplanırken bu tip modellerin doğru fonksiyonu sabit olup hata hesaplama formülleri değişkenlik gösterebilir. Bunlar en küçük kareler yöntemi, korelasyon matris yöntemi veya hata varyansı yöntemi gibi hata hesaplama yöntemleri vardır. Model başarısı hatanın güncellenme sayısına, süresine ve formülüne bağlı olarak hesaplanır.

- **Lojistik regresyon:** Lojistik regresyon verilerin sayısal veya kategorik olması durumunda sınıflandırma için kullanılabilen modeldir. Doğrusal regresyondan farklı olarak bu tip modeller sınıf düzlemini bir sigmoid fonksiyonu ile ayırabilir (Şekil 3.7). Lojistik regresyon makine öğrenmesi uygulamalarında sıkça kullanılır. Sigmoid fonksiyonunu oluşturan katsayılar, hata değeri en düşük olana kadar ilgili veri seti için güncellenmektedir. Bu sayede veri seti için en uygun sınıflandırma fonksiyonu oluşur. Lojistik regresyon için bir bağımsız değişkenli genel denklem şu şekildedir (Gasso 2019, Abramovich vd. 2020);

$$f(t) = \frac{e^t}{e^t + 1} = \frac{1}{1 + e^{-t}} \quad (3.11)$$

$$t = ax + b \quad (3.12)$$


$$f(x) = \frac{1}{1 + e^{-(ax+b)}} \quad (3.13)$$

t : Doğru fonksiyonu

a : Fonksiyon katsayısı (Eğim)

b : Fonksiyon sabiti (Kesen)


$f(x)$: x 'e bağlı sigmoid fonksiyonu



Şekil 3.7 Örnek sigmoid fonksiyonu.

3.12.2 En Yakın Komşu

En yakın komşuluk (EYK) algoritmaları sınıflandırma ve tahmin için kullanılır. Literatürde ve piyasa da çoğunlukla sınıflandırmalarda kullanılır. Algoritma, sınıflandırma için kullanıldığında veri setinin sınıfları belirli olması gerekmektedir. K (komşu sayısı) EYK algoritmaları, önceden veri tabanındaki verilerin sınıflandırılarak gruplanması ile başlamaktadır. Ardından yeni veri, en yakın K tane olan sınıflandırılmış verilerin uzaklığına bakılarak en yakın sınıfa dâhil olur (Shah vd. 2020). Kısaca özniteliklere bağlı olarak gelen yeni veri K adet veriye bakarak hangisine uzaklık olarak yakın ise o gruba dâhil olarak sınıflandırılmış olur. Şekil 3.8’de üç sınıftan oluşan EYK algoritmasının sınıflandırma mantığı görülmektedir.



Şekil 3.8 İki adet öznitelikten ve 3 adet sınıftan oluşan verilerin 4 adet komşusunun uzaklığına bakılarak sınıflandırılması (Wang ve Mao 2020).

Şekil 3.8’de iki boyutlu düzlem de veriler dağıtılmıştır. Bu veriler 3 sınıfa ayrılmıştır. Sınıflar kendi arasında gruplanarak küme merkezi belirlenmiştir. EYK algoritması gözetimli yani kullanıcı sayesinde öğrenen bir algoritmadır. Veri seti ile eğitilen bir EYK algoritması sonradan gelen yeni veriyi gruplandırmak için bir K yani komşu sayısı belirlenir. Gelen yeni veri K adet sayıda en yakın komşusunun uzunluğuna bakılarak hangi sınıfa dâhil olacağı belirlenir. Şekil 3.8’de gelen yeni veri için belirlenen en yakın komşu sayısı 4 olduğundan komşularına olan uzaklığı belirlenir ve en yakın ve en baskın sınıfa dâhil olur. EYK algoritmalarında komşularına olan uzaklıklar farklı uzaklık fonksiyonları ile belirlenir. Bu uzaklıklar fonksiyonlarından en sık kullanılanı Öklid uzaklığı olmak ile birlikte Manhattan uzaklığı ve Minkowski uzaklığıda kullanılmaktadır. Bu çalışmada Öklid uzaklık fonksiyonu kullanılmıştır. Bu fonksiyon denkelm 3.14’de ifade edilmiştir.

$$d(x, y) = \sqrt{\sum_{i=1}^n (y_i - x_i)^2} = \sqrt{(y_1 - x_1)^2 + (y_2 - x_2)^2 + \dots + (y_n - x_n)^2} \quad (3.14)$$

$d(x, y)$: x ile y arasındaki Öklid uzaklığı


n : Boyut sayısı

i : i . sıradaki boyut

3.12.3 Destek Vektör Makineleri

Destek vektör makineleri bir çeşit sınıflandırma algoritmasıdır. Temelde doğrusal regresyon da olduğu gibi sınıfları ayırabilen bir doğru fonksiyonu bulmaya çalışan algoritmadır. SVM sınıfların olduğu gurubu bir doğru fonksiyonu, polinom fonksiyonu veya üssel bir fonksiyon gibi doğru veya eğriler ile ayırmaktadır. Sınıfları ayıran birden fazla doğru ve eğri fonksiyonu olabilir. DVM’nin regresyondan farklı olarak sınıfların ayırımı için oluşturulan fonksiyonların en doğru olanını bulmaktadır. DVM doğrusal DVM ve doğrusal olmayan DVM olmak üzere ikiye ayrılır. Doğrusal DVM iki sınıftan oluşan verileri sınıflandırmada başarılıdır. Doğrusal olmayan DVM için farklı çekirdek

fonksiyonları kullanılır. Bu da verilerin sahip olduğu boyutu arttırarak sınıfların ayrılmasına olanak sağlar. Veri sınıflarının çok olduğu ve doğrusal olmadığı durumlarda kullanılır. Literatürde doğrusal olmayan DVM ile ilgili farklı çekirdek fonksiyon denemeleri mevcuttur. DVM bir veri sınıfını ayırt eden en iyi doğruyu veya doğru düzlemini bulmak için bu doğru veya düzlemlere paralel sınır düzlemi veya doğrusu belirler. Bu sınıf doğruları arasında kalan düzleme hiper düzlem denir. Sınır düzlemleri marjin aralığı en geniş şekilde belirlenir (Gopi vd. 2020). Yani sınır düzlemi bir veya birkaç sınıf vektörüne değene kadar genişletilir. Böylelikle sınır düzlemleri sınıf vektörlerinden destek alarak hiper düzlem aralığını belirler. DVM'ler temel olarak 2 boyutlu uzaydaki problemleri çözebilmek için geliştirilmiştir. Şekil 3.10'da basit bir doğrusal DVM örnek ayırımı gösterilmiştir. Ardından problemler belirli kurallara göre boyutları arttırılarak giriş uzayında karmaşık gibi görülen problemleri daha kolay ayırt edilmektedir. Uygulanacak olan DVM için seçilen çekirdek fonksiyonu ile 2 boyutlu uzaydan sonsuz sayıda boyutlara çıkarılabilmektedir. Şekil 3.9'da verilerin çekirdek fonksiyonları yardımı ile daha yüksek boyutlara dönüştürülmesi örneklenmiştir.




Şekil 3. 9 Verilerin çekirdek fonksiyonları yardımı ile daha yüksek boyutlara dönüştürülmesi (Kavzoğlu ve Çölkesen 2010).

Literatürde DVM'lerde kullanılan en yaygın çekirdek fonksiyonları radyal tabanlı fonksiyonlar, polinom tabanlı ve Pearson VII fonksiyonlarıdır. Yapmış olduğumuz çalışmada işaret sınıflarını ayırt edebilmek için polinom çekirdek fonksiyonu olan bir DVM algoritması kurulmuştur. Polinom çekirdek fonksiyonun matematiksel formülü şu şekildedir;

$$K(x, y) = ((x \cdot y) + 1)^d \quad (3.15)$$

Polinom çekirdek fonksiyonu oldukça basit görünsede polinomun derecesindeki artışa bağlı olarak karmaşıklashaabilmektedir. Bunu sonucu olarak da sınıflandırma doğruluğunda düşüşlere sebep olabilmektedir (Kavzoğlu ve Çölkesen 2010).



Şekil 3.10 Doğrusal destek vektör makinelerinin basit gösterimi (Lu ve Roychowdhury 2006).

3.12.4 Naif Bayes

Naif Bayes (NB) sınıflandırmasının temeli Bayes teoremine dayanır. Bayes teoremi, 1812’de Thomas Bayes tarafından ortaya atılan bir koşullu olasılık teoremidir. Bayes teoremi bir bağımsız değişken için koşullu olasılık dağılımı içerisindeki koşullu olasılık ve uç olasılık arasındaki ilişkiyi gösterir (Li Q. ve Li T. 2020). NB sınıflandırma, bir test verisi için veri seti içindeki her durumun olasılığını hesaplar ve en yüksek olasılığa göre sınıflandırır. Makine öğrenmesinde kullanılan algoritmalar gözetimli veya gözetimsiz olabilmektedir. NB bir veri seti ile eğitildiğinden gözetimli makine öğrenmesi algoritmalarına girmektedir. Fakat bu algoritma gelen her bir veri için veri setini tarayarak olasılıkları hesaplar. Bu sebep ile gelen verinin veri setine eklenmesi veri setindeki önceki ve şimdiki sınıfların olasılığını değiştirebilmektedir. Yani NB algoritması her seferinde veri tabanını kullanmaya ihtiyacı vardır. Dolayısı ile her bir test verisi için veri setinin yeniden eğitilmesi gerekmektedir. Fakat şu andaki verinin sınıflandırılması için ise

önceki verilere ihtiyacı vardır. Literatürde NB sınıflandırıcı, her defasında veri setini kullanması sebebi ile tembel öğrenme olarak nitelendirilmiştir. NB algoritması verilerin tiplerine göre farklı algoritmalar kullanmaktadır. Verilerin reel veya ondalıklı olması durumunda Gaussian NB, verilerin nominal değerlerden oluştuğu durumda multinominal ve verilerin ikili sınıflardan oluştuğu durumda ise Bernoulli NB sınıflandırması kullanılır. Veriler, öznelikten oluşan veri tabanı değiştirilmeden sınıflar yeniden düzenlenerek Gaussian NB algoritması kullanılmıştır. NB sınıflandırıcının matematiksel olasılık formülü aşağıdaki gibidir (D'Agostini 1995);

Bayes teoremi:

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (3.16)$$

$P(A|B)$: A olayı gerçekleştiğinde B olayının gerçekleşme olasılığı


$P(A)$: A olayının gerçekleşme olasılığı

$P(B|A)$: B olayı gerçekleştiğinde A olayının gerçekleşme olasılığı

$P(B)$: B olayının gerçekleşme olasılığı

3.12.5 Karar Ağaçları

Karar Ağaçları (KA) algoritmaları gözetimli öğrenme tabanlı algoritmalarlardır. Bu algoritmalar temel olarak veriyi belli kurallar dâhilinde sınıflara böler. Böylelikle bütün bir veri tabanı küçük gruplardan oluşur. KA, regresyon sınıflandırmalarından farklı bir biçimde veriyi gruplara ayırmaktadır. Veri tabanının da bulunan sınıflara bağlı olarak grup sayısı artmaktadır. Bu algoritmalar istatistik, mühendislik ve veri madenciliği gibi alanlarda aktif olarak kullanılan algoritmalarlardır. Şekil 3.11'de örnek bir KA algoritmasının veriyi gruplara ayırma mantığı görülmektedir.




Şekil 3.11 Karar Ağaçları algoritmasının en yüksek entropi değerine sahip öz niteliğe göre sınıflandırma mantığı (Jin vd. 2009).

KA algoritmalarında veriyi nerden ve nasıl olarak bölündüğü algoritmanın başarısı etkileyen en önemli faktörlerdendir. Bölme işlemi verinin tipine bağlı olarak (kategorik veya sürekli) entropi, Gini, sınıflandırma hatası veya en küçük kareler yöntemleri ile gerçekleştirilir. KA bölme işlemini başlatırken en sık kullanılan bölme algoritması her bir bağımsız değişken için entropi hesaplayarak başlar (Shahbazi, 2020). Entropi, çoğunlukla bir sistemdeki rastgelelik ve düzensizlik olarak tanımlanır. Yani diğer bir deyişle belirsizliğin ölçülmesi anlamındadır. Entropi değerinin 0'a yakın olması sistemdeki belirsizliğin az olduğunu göstermektedir. En nihayetinde en yüksek entropi değerine sahip bağımsız değişken ile karar ağacı başlar. Bu çalışmada karar ağacı algoritmasında bölme düğümleri entropi hesaplanarak oluşturulmuştur.

3.12.6 Rastgele Orman Sınıflandırması

Rastgele Orman Sınıflandırması (ROS) regresyon ve sınıflandırma problemleri için kullanılan algoritmalar. Temeli KA algoritmalarından alan ROS algoritmaları, KA'ndaki aşırı öğrenme yani ezberleme sorununa çözüm olarak sunulmuştur. ROS algoritmaları, veri setini farklı parçalara bölerek bu kısımlara KA algoritmalarını

uygulamaktadır. En nihayetinde birden fazla KA oluşturulmuş olur. Her bir KA farklı tahminler oluşturur. Ardından sayısal tahmin yani regresyon problemleri için her bir KA'nın ortalaması alınır. Problemi sınıflandırırken ise KA arasında en çok oy alan seçilir. Şekil 3.11'de örnek bir ROS algoritmasının çalışma mantığı görülmektedir.



Şekil 3.12 Karar Ağaçlarından oluşan örnek bir Rastgele Orman Sınıflandırma algoritması mantığı (Alabdulkarim vd. 2019).

3.12.7 Yapay Sinir Ağları


YSA, insanlarda olduğu gibi eğitilip öğrenebilen ve kendi kendine organize olup bilgiyi değerlendirebilen bir ağıdır. Yapısı itibarı ile insandaki sinir hücrelerini andırmaktadır (Hoq vd. 2020). İnsan sinir hücresi, insanlarda bulunan karar verme yeteneğini etkilemektedir. Temelde bilim insanları, insanlarda bulunan sinir ağının işleyişini modellemeye çalışarak yapay sinir ağı oluşturmuşlardır. Sinir hücresinin bölümleri ile yapay sinir ağını oluşturan kısımlar arasında benzerlik kurulmuştur. Sinir hücresi ve basit bir YSA arasındaki ilişki şu şekildedir;

- Akson: Sinir hücrelerindeki çıkış sinyallerini oluşturur. YSA'daki karşılığı çıkış katmanıdır.
- Dendritler: Hücreler den gelen sinyalleri alır. YSA' daki karşılı giriş katmanıdır.
- Sinaps: Dendrit ve akson arasındaki bağlantıyı sağlar. YSA'daki karşılığı benzer şekilde katmanlar arasındaki bağlantıya karşılık gelir.
- Çekirdek: Akson boyunca periyodik işaret üretir. YSA'daki karşılığı aktivasyon fonksiyonlarıdır.

YSA, katmanlardan ve aktivasyon fonksiyonlarından oluşur. Her bir katman sinir hücresinde bulunan dendritler gibi nöronlardan oluşur. Bu nöronlar bilgileri aktivasyon fonksiyonuna yani sinir hücresindeki karar mekanizmasını oluşturan hücre merkezine iletilir. Ardından aktivasyon fonksiyonun kararına yönelik bir çıkış üretilir. YSA, sinir hücresindeki gibi hücreler arası bağlantıyı sağlamak için bağlantı yolları içerir. Bu bağlantı yolları hücrenin karar vermesi açısından öneme sahiptir. Bilgi bu bağlantı yollarından akarken önem kazanabilir veya kaybedebilmektedir. YSA'lar ilk zamanlarda 'perceptron' ve 'adaline' gibi tek katmanlı algılayıcılardan oluşmaktaydı. Zaman için de birden fazla katmandan oluşan çok katmanlı ağlara geçiş yapılmıştır. Tek katmanlı ağlardan çok katmanlı ağlara geçişin en önemli sebeplerinden biri XOR mantıksal problemine aranan çözüm olmuştur. Tek katmanlı ağlar XOR problemini çözmeden yetersiz kalınca uzun bir süre YSA durgunluk yaşamıştır. Ardından çok katmanlı ağlar bu problemi çözdüğünde tekrar YSA ile ilgili çalışmalar yapılmaya başlanmıştır. YSA bilgisayar donanımlarının gelişmesi ile birlikte önemli ilerlemeler kaydetmiştir. Hali hazırda telefonlardan askeri alanlara kadar birçok alanda kullanılmaktadır.


Çok katmanlı algılayıcılar (ÇKA), sınıflandırma ve genelleme yapma durumlarında iyi çalışırlar. ÇKA'da bir problemi çözmek için bir nöron yeterli olmadığından birden fazla nörona ihtiyaç duyulmaktadır. ÇKA'larda birden fazla katman olduğundan nöronlar paralel işlem yapabilmektedir. Tek katmanlı algılayıcılardan farklı olarak ÇKA'larda giriş katmanından gelen veriler bir sonraki gizli katmanlara aktarılarak problem çözülür. Katman ve nöron sayısı probleme ve ihtiyaca göre değiştiğinden farklı ağ topolojileri kullanılarak deneme yanılma yöntemi ile tespit edilebilmektedir. ÇKA'larda her bir gizli katman için farklı aktivasyon fonksiyonları kullanılmaktadır. Bu çalışmada kullanmış

olduğumuz YSA yapısı bir ÇKA'dır. Oluşturulan ağ 3 adet katmandan oluşmaktadır. İlk katman giriş katmanıdır ve 272 adet giriş nöronundan oluşmaktadır. Gizli katman sayısı 1 adetten oluşmaktadır. Katmanlarda kullanılan fonksiyonlar genel olarak sigmoid, tanh, signum, step, linear, softmax ve rectifier linear unit (ReLU) fonksiyonlarıdır (Şekil 3.13).




Şekil 3. 13 YSA ' da genel olarak kullanılan aktivasyon fonksiyonları.

Gizli katmanda bulunan fonksiyon ReLU ve çıkış katmanı fonksiyonu olarak sigmoid seçilmiştir. (Şekil 3.14).



Şekil 3.14 Sigmoid ve ReLU aktivasyon fonksiyonu.

Çıkış sayısı işaret sınıfının sayısı kadar olduğundan çıkış katmanı 32 adet nörona sahiptir. Şekil 3.14’de oluşturulan YSA modeli ve çizelge 3.2’de denemesi yapılan ağ parametreleri görülmektedir.



Şekil 3.14 Çalışmada tasarlanan yapay sinir ağı modeli.

Çizelge 3.2 YSA oluşturmak için denemesi yapılan parametreler.

Gizli Katman Sayısı	1. GKNS	2. GKNS	3. GKNS	ÇK	Eğitim Doğruluğu (%)	Test Doğruluğu (%)
1	3 (ReLU)	-	-	32 (Sigmoid)	37,74	30,93
1	3 (Sigmoid)	-	-	32 (Sigmoid)	14,90	12,18
1	3 (Sigmoid)	-	-	32 (Softmax)	20,91	17,50

GKNS: Gizli katmandaki nöron sayısı, ÇK: Çıkış katmanı, Kullanılan aktivasyon fonksiyonları parantez içerisinde verilmiştir.

Çizelge 3.2 (Devam) YSA oluşturmak için denemesi yapılan parametreler.

Gizli Katman Sayısı	1. GKNS	2. GKNS	3. GKNS	ÇK	Eğitim Doğruluğu (%)	Test Doğruluğu (%)
1	10 (ReLU)	-	-	32 (Sigmoid)	96,63	95,31
1	10 (Sigmoid)	-	-	32 (Sigmoid)	61,06	56,25
1	20 (ReLU)	-	-	32 (Sigmoid)	97,60	96,85
2	10 (ReLU)	5 (ReLU)	-	32 (Sigmoid)	83,89	81,25
2	10 (ReLU)	5 (Sigmoid)	-	32 (Sigmoid)	21,38	18,75
2	20 (Sigmoid)	10 (Sigmoid)	-	32 (Softmax)	25,00	23,43
2	10 (Sigmoid)	10 (Sigmoid)	-	32 (Sigmoid)	10,58	8,12
3	5 (ReLU)	5 (ReLU)	5 (ReLU)	32 (Sigmoid)	10,34	8,16
3	30 (ReLU)	10 (ReLU)	5 (ReLU)	32 (Sigmoid)	72,84	67,5

GKNS: Gizli katmandaki nöron sayısı, ÇK: Çıkış katmanı, Kullanılan aktivasyon fonksiyonları parantez içerisinde verilmiştir.

4. BULGULAR

Bu çalışmada 4 farklı kişiden tasarlanan eldiven ile 32 adet işaret dili verisi toplanmıştır. Kişilerden bir işaret dili hareketinden 10 ‘ar adet tekrarlayarak toplamda 1280 işaret dili verisi elde edilmiştir. Veriler istatistiksel yöntemler kullanılarak öznitelikleri çıkarımı ve veri ön işleme (normalizasyon, standardizasyon) yapılmıştır. Verilerin 960 adedi sınıflandırma algoritmalarında eğitim ve doğrulama, 320 adedi ise modelleri test etmek için kullanılmıştır. 320 adet işaret verisi modeller eğitilirken hiç kullanılmamıştır.

4.1 Eldiven Üzerindeki Algılayıcılardan Elde Edilen Ham Veriler


Kelimelerin işaret dili karşılıklarını yapan kullanıcılardan eldiven üzerinde bulunan algılayıcılar sayesinde analog veriler toplanmıştır. Veriler, eldivene montelenmiş halde bulunan esneklik, manyetik alan ve AÖB algılayıcılarından elde edilmiştir. Kullanılan algılayıcıların eldivendeki yerleri ve kısaltmaları Çizelge 4.1’deki gibi belirlenmiştir. ‘Arkadaş’, ‘tekrar’ ve ‘iyi’ olmak üzere üç adet kelimeden elde edilen esneklik algılayıcı, manyetik alan algılayıcı ve dönme verilerinde göz ile ayırt edilebilecek farkları bulunmaktadır. Bu üç kelimenin parmak hareketleri esneklik algılayıcılar tarafından tespit edilmiştir (Şekil 4.1, Şekil 4.2 ve Şekil 4.3).

Çizelge 4.1 Bir eldivende bulunan algılayıcıların monte yerleri ve algılayıcı kısaltmaları.


Algılayıcı	Konumu	Kısaltma
Esneklik Algılayıcı	Baş Parmak	F1
Esneklik Algılayıcı	Baş Parmak ile İşaret Parmağı arası	F2
Esneklik Algılayıcı	İşaret Parmağı	F3
Esneklik Algılayıcı	Orta Parmak	F4
Esneklik Algılayıcı	Yüzük Parmağı	F5
Esneklik Algılayıcı	Serçe Parmak	F6
Manyetik Alan Algılayıcı	Baş Parmak Ucu	MAS1
Manyetik Alan Algılayıcı	İşaret Parmağı Ucu	MAS2
Manyetik Alan Algılayıcı	Orta Parmak Ucu	MAS3
Manyetik Alan Algılayıcı	Yüzük Parmağı Ucu	MAS4

Çizelge 4.1 (Devam) Bir eldivende bulunan algılayıcıların monte yerleri ve algılayıcı kısaltmaları.


Algılayıcı	Konumu	Kısaltma
Manyetik Alan Algılayıcı	Serçe Parmağı Ucu	MAS5
Dönüölçer	El Üstü	Gx
Dönüölçer	El Üstü	Gy
Dönüölçer	El Üstü	Gz
İvmeölçer	El Üstü	Ax
İvmeölçer	El Üstü	Ay
İvmeölçer	El Üstü	Az



Şekil 4.1 ‘Arkadaş’ kelimesine ait sağ eldivenin esneklik algılayıcılarından toplanan ham veriler görülmektedir.




Şekil 4.2 ‘Tekrar’ kelimesine ait sağ eldivenin esneklik algılayıcılarından toplanan ham veriler görülmektedir.




Şekil 4.3 ‘İyi’ kelimesine ait sağ eldivenin esneklik algılayıcılarından toplanan ham veriler görülmektedir


İşaret dilindeki bazı kelimeler dönme ve yönelim hareketleri hariç parmak hareketleri birbirlerine benzeyebilmektedir. Örnek olarak Şekil 4’2’de ki ‘tekrar’ kelimesi ve Şekil 4.3’deki ‘iyi’ kelimelerinin parmak hareketlerinin esneklik algılayıcılardan elde edilen verilerinin birbirlerine benzediği görülebilmektedir. Şekil 4.4, Şekil 4.5 ve Şekil 4.6’ de ‘arkadaş’, ‘tekrar’ ve ‘iyi’ işaretlerinin manyetik alan algılayıcılarından toplanan ham veriler görülmektedir.



Şekil 4.4 ‘Arkadaş’ kelimesine ait sağ eldivenin manyetik alan algılayıcılarından toplanan ham veriler görülmektedir.




Şekil 4.5 ‘Tekrar’ kelimesine ait sağ eldivenin manyetik alan algılayıcılarından toplanan ham veriler görülmektedir.




Şekil 4.6 ‘İyi’ kelimesine ait sağ eldivenin manyetik alan algılayıcılarından toplanan ham veriler görülmektedir.


Manyetik alan algılayıcıları eldivenin parmak uçlarına montelenmiştir. Manyetik alan algılayıcılarının kullanım amacı işaret dilinde kullanılan avuç kapatma hareketini ve parmakların hangi avuç içine değdiğini tespit etmektir. Bu sebep ile manyetik alan algılayıcılarının çalışabilmesi için her için elin avuç içine zıt kutuplar dışa bakacak şekilde birer güçlü mıknatıs yerleştirilmiştir. Şekil 4.5’ de ‘tekrar’ kelimesinin manyetik alan algılayıcılarından anlaşıldığı gibi işaret dilindeki karşılığında avuçlar kapatılmaktadır. Şekil 4.7, Şekil 4.8 ve Şekil 4.9’da kelimelerin dönüölçer algılayıcısından elde edilen ham veriler görülmektedir.



Şekil 4.7 ‘Arkadaş’ kelimesine ait AÖB algılayıcısından toplanan ham dönüölçer verileri görülmektedir.




Şekil 4.8 ‘Tekrar’ kelimesine ait AÖB algılayıcısından toplanan ham dönüölçer verileri görülmektedir.



Şekil 4.9 'İyi' kelimesine ait AÖB algılayıcısından toplanan ham dönüölçer verileri görülmektedir.

Dönüölçer verilerinden anlaşıldığı gibi her bir kelimenin dönme hareketi farklıdır. İşaret dili kelimelerinin en belirgin ayırt edici özellikleri arasında işareti yaparken elin dönme açısıdır. Bu sebeple literatürde işaret dili için tasarlanan birçok eldivende AÖB algılayıcıları kullanılmıştır. Ham veriler eldivenlerden elde edildikten sonra verilerin istatistiksel öznitelik çıkarımı yapılmıştır. Şekil 4.10'da 'arkadaş', 'tekrar' ve 'iyi' kelimelerinin istatistiksel öznitelik çıkarımı yapıldıktan sonraki grafikleri görülmektedir.



Şekil 4.10 'arkadaş', 'tekrar' ve 'iyi' kelimesine ait 272 adet istatistiksel özniteliklerden oluşturulmuş grafik.

4.2 Uygulamada Kullanılan Kelimeler

Makine öğrenim algoritmalarının sınıflandırmada kullanılabilmesi için eğitimin sağlıklı bir biçim de olması gerekmektedir. Eğitimin sağlıklı olması sınıflara ait yeteri kadar eğitim verisi olmasına bağlıdır. Denetimli makine öğrenmesi algoritmaları sınıflara ait az örnek veriden öğrenmeye çalıştığında öğrenimin test başarısı düşmektedir. Yani sınıf sayısı çok ve örnek sayısı az olduğunda öğrenim başarısı az olmaktadır. Bir kelime sınıfı için tek bir kullanıcıdan işaret verisi toplamak sadece o kişinin hareketlerini öğrenmek demektir. Yani tek bir kullanıcıyla bir öğrenme olmaktadır. Bunun anlamı tasarlanan eldivenler bir kişinin yaptığı işaretleri tanıması demektir. Algoritmaların tek kullanıcının hareketlerini ezberlemesini önlemek için farklı kişilerden işaret örnekleri toplanmalıdır. Böylelikle eldivenin kullanıcı sayısı tek bir kişiye bağlı olmamaktadır. Bu çalışmada 32 adet kelime sınıfı kullanılmıştır. Covid-19 sebebi ile işaret dili kelimelerini yapmak için örnek toplanacak kullanıcı bulmakta zorluk yaşanmıştır. Bu sebep ile seçilen kelimelerin işaretleri 4 farklı kullanıcı tarafından 10'ar defa tekrarlanmıştır. Her bir kelime için 1 kullanıcı 10 defa işaret yapmıştır. Toplam bir işareten 40 adet örnek toplanarak 32 kelimeden 1280 adet örnek toplanmıştır. Bu örneklerin 960 'ı algoritmalar da eğitim ve 320 tanesi simülasyon testi için kullanılmıştır. Algoritmaları uygularken 960 adet veri kendi içerisinde eğitim ve test olarak ayrı biçimde bölünmüştür. Yani 320 adet simülasyon test verisini algoritma hiç görmemiştir.

4.3 Metotların Karşılaştırılması ve Grafikler

Makine öğrenmesi algoritmaları 32 adet kelimenin her birinden 10'ar adet olmak üzere 320 adet işaret dili örneği ile eğitim yapılmıştır. Algoritmaları test etmek için 32 adet işaret dili kelimesinden 10'ar adet olmak üzere 320 adet örnek teste tabi tutulmuştur. Ardından her bir kelimeden 30'ar adet örnek olmak üzere 960 adet örnek ile yeniden eğitim yapılmıştır. Örnek sayısı ile algoritmaların doğruluk oranları karşılaştırılmıştır. Çizelge 4.2'de 320 örnek eğitim verisi ile makine öğrenmesi algoritmalarının doğruluk oranları gösterilmiştir.

Çizelge 4.2 320 adet işaret örneği ile yapılan eğitim ve testlerin doğruluk sonuçları.

Kelimeler	LR		EYK		DVM		NB		KA		ROS		YSA	
	E	T	E	T	E	T	E	T	E	T	E	T	E	T
Merhaba	100	100	100	60	100	100	100	100	100	100	100	100	98,5	100
Nasıl	100	70	100	92,1	92	50	100	0	95	0	100	70	98,5	100
Ben	100	80,2	100	0	92,4	0	100	0	96,2	50	99	100	98,5	0
Benim	100	100	100	86,7	92,4	50	100	100	99	100	100	80	98,5	36,8
İyi	100	96,4	100	80,3	92,4	0	100	0	93,3	50	100	70	98,5	0
Arkadaş	100	85,7	100	90	92,4	0	100	0	90	100	100	60	98,5	100
Gitmek	100	90,6	100	86,2	92,4	0	100	0	100	0	100	100	98,5	69,7
Zaman	100	84,8	100	30,2	94,4	100	100	0	98,1	50	100	10	98,5	0
Çok	100	89,2	100	78,2	92,4	50	100	0	94,3	40	100	100	98,5	60,4
Teşekkür	100	100	100	52,1	92,4	0	100	0	97,1	0	100	0	98,5	100
Sen	100	95,2	100	87,2	92,4	0	100	0	93,3	0	100	0	98,5	70,9
Ne	100	80,9	100	90,3	92,4	50	100	0	89,6	100	100	100	98,5	100
Düşünmek	100	96,5	100	85,2	92,4	50	100	100	95,2	100	100	70	98,5	100
Tekrar	100	98,8	100	90	92,4	100	100	100	95,2	0	100	60	98,5	40,7
Lütfen	100	100	100	86,5	92,4	100	100	0	95,2	100	100	100	98,5	100
Her	100	90	100	84,2	92,4	0	100	0	93,3	0	100	0	98,5	80,6
Şey	100	60,4	100	72,3	92,4	90	100	100	96,2	0	100	0	98,5	74,5
Öğrenci	100	100	100	85,2	92,4	100	100	0	94,3	100	100	100	98,5	100
Yarın	100	75,7	100	90	92,4	100	100	100	97,1	50	100	90	98,5	100
Büyük	100	100	100	87,4	92,4	50	100	50	96,2	70	98,1	100	98,5	100
Sınav	100	90	100	80	92,4	0	100	50	99	0	100	100	98,5	100
Var	100	90	100	76,8	92,4	0	100	0	97,1	50	100	100	98,5	50,7
Vermek	100	80	100	90	92,4	0	100	0	89,6	30	100	50	98,5	70
Not	100	96,8	100	60,2	92,4	100	100	0	92,4	50	100	50	98,5	100
Orta	100	100	100	60	92,4	0	100	0	94,3	50	100	100	98,5	100
Siz	100	65,1	100	78,2	92,4	0	100	100	94,3	0	100	70	98,5	0
Tanışma	100	80,6	100	74,3	92,4	0	100	0	100	0	100	60	98,5	100
Kendi	100	100	100	63,7	92,4	0	100	0	96,2	50	96,2	50	98,5	0
Memnun	100	60,4	100	65,4	92,4	0	100	0	95,2	50	97,1	70	98,5	0
Olmak	100	30,9	100	60	92,4	0	100	0	92,4	50	100	100	98,5	47,8
Güzel	100	100	100	89,7	92,4	100	100	0	92,4	100	100	100	98,5	100
Konu	100	70	100	86,4	92,4	0	100	0	93,3	100	100	100	98,5	100

E: Eğitim Doğruluğu T: Test Doğruluğu

Çizelge 4.2 incelendiğinde ROS, LR ve YSA teknikleri oldukça iyi sonuçlar vermektedir. Algoritmalar 320 adet veri ile eğitilmiştir. Çizelge 4.3’de 960 adet veri seti kullanılarak algoritmalar tekrar eğitilmiştir.

Çizelge 4.3 960 adet işaret örneği ile yapılan eğitim ve testlerin doğruluk sonuçları.

Kelimeler	LR		EYK		DVM		NB		KA		ROS		YSA	
	E	T	E	T	E	T	E	T	E	T	E	T	E	T
Merhaba	100	100	100	86,2	96,2	100	100	100	98,7	100	100	100	100	100
Nasıl	100	78,6	100	100	96,2	80	100	100	100	60	100	80	100	100
Ben	100	90	100	80	96,2	50	100	100	98,7	80	100	100	100	70,8
Benim	100	100	100	92,7	96,2	100	100	0	99,3	100	100	90	100	95,4
İyi	100	100	100	90,7	96,2	0	100	100	99	90	100	100	100	100
Arkadaş	100	92,6	100	94,4	96,2	0	100	100	99	100	100	90	100	100
Gitmek	100	98,7	100	89,6	96,2	100	100	0	100	60	100	100	100	100
Zaman	100	96,4	100	60,1	96,2	80	100	0	98,7	80	100	60	100	65,4
Çok	100	92,5	100	84,6	96,2	100	100	0	97,7	70	100	100	100	100
Teşekkür	100	100	100	74,2	96,2	100	100	100	99,6	80	100	60	100	100
Sen	100	96,4	100	93,5	96,2	0	100	100	100	100	100	70	100	84,5
Ne	100	95,2	100	93,1	96,2	100	100	100	99,6	100	100	100	100	100
Düşünmek	100	100	100	90,5	96,2	80	100	0	97,1	100	100	80	100	100
Tekrar	100	100	100	94,7	96,2	100	100	0	100	50	100	90	100	68,7
Lütfen	100	100	100	88,2	96,2	40	100	100	100	100	100	100	100	100
Her	100	96,8	100	90,4	96,2	0	100	0	99	80	100	60	100	87,6
Şey	100	80,4	100	84,6	96,2	100	100	100	100	90	100	50	100	95,2
Öğrenci	100	100	100	87,1	96,2	50	100	0	98,4	100	100	100	100	100
Yarın	100	85,2	100	96,7	96,2	80	100	100	96,8	80	100	90	100	100
Büyük	100	96,7	100	90	96,2	100	100	0	99	90	100	100	100	100
Sınav	100	96,8	100	100	96,2	50	100	100	100	100	100	100	100	100
Var	100	92,1	100	84,7	96,2	0	100	0	97,7	80	100	100	100	60,4
Vermek	100	88,4	100	92,1	96,2	80	100	100	99,3	60	50	80	100	87,2
Not	100	100	100	74,6	96,2	100	100	100	99,6	70	60	70	100	100
Orta	100	100	100	80,4	96,2	100	100	0	99	80	100	100	100	100
Siz	100	75,8	100	83,4	96,2	60	100	100	99,3	100	80	90	100	79,2
Tanışmak	100	90,4	100	96,8	96,2	100	100	0	100	80	60	100	100	100
Kendi	100	100	100	70,7	96,2	80	100	100	100	80	70	80	100	65,1

E: Eğitim Doğruluğu T: Test Doğruluğu

Çizelge 4.3 (Devam) 960 adet işaret örneği ile yapılan eğitim ve testlerin doğruluk sonuçları.

Kelimeler	LR		EYK		DVM		NB		KA		ROS		YSA	
	E	T	E	T	E	T	E	T	E	T	E	T	E	T
Memnun	100	70,4	100	86,4	96,2	100	100	100	100	70	80	90	100	74,3
Olmak	100	60,4	100	86,1	96,2	100	100	0	99	90	100	100	100	78,4
Güzel	100	100	100	100	96,2	80	100	0	99	100	100	100	100	100
Konu	100	86,4	100	93,7	96,2	100	100	100	99	100	100	100	100	100

E: Eğitim Doğruluğu T: Test Doğruluğu

Çizelge 4.3’de veri seti arttırılarak 960 adet işaret dili hareketlerinden oluşan veri örnekleri ile eğitim yapılmıştır. Eğitim yapıldıktan sonra 10’ar adet veri ile test edilmiştir. Çizelge 4.2’de görüldüğü üzere az veri seti ile eğitim yapıldığında hem doğruluk oranı hem de az veri setine uygun olmayan algoritmaların başarımı düşüktür. Veri seti arttırıldığında algoritmalar kararlı hale geçerek doğruluk oranları artmıştır. Buradan veri setindeki verilerin arttırılması tanıma oranını arttırmaktadır. Veri setinin sınıflandırılma başarısı eldivenden toplanan veri setindeki verilerin özniteliklerinin iyi bir biçimde çıkarılmasına bağlıdır. İstatistiksel yöntemlerden elde edilen öznitelikler sınıflandırma başarısına katkı sağlamıştır. Öte yandan gereksiz veri oluşturabilecek kaçınılmıştır. Veri setindeki sınıflar çok ve örnekler az olduğunda algoritmaların başarısı düşmektedir. Bu durumda algoritmanın eğitim başarısı yüksek olabilmektedir. Ancak test başarısı düşük olmaktadır. Böyle bir durum algoritmanın öğrenmeden çok veri setindeki verileri ezberlediğinin göstergesidir. Yani başka bir test verisi ile algoritma test edildiğinde veriler düzgün sınıflandırılmamaktadır.


Çizelge 4.4 İşaret dili tanıma için kullanılan algoritmaların eğitim ve test doğrulukları.

Veri Seti (adet)	Test Verisi (adet)	Algoritmalar	Eğitim Doğruluğu(%)	Test Doğruluğu(%)
320	96	Lojistik Regresyon	100 %	76,8 %
		En Yakın Komşu	100%	80,7%
		Destek Vektör Makineleri	92,4%	34,3%

Çizelge 4.4 (Devam) İşaret dili tanıma için kullanılan algoritmaların eğitim ve test doğrulukları.

Veri Seti (adet)	Test Verisi (adet)	Algoritmalar	Eğitim Doğruluğu(%)	Test Doğruluğu(%)
320	96	Naif Bayes	100%	22,9%
		Karar Ağaçları	94,3%	47,9%
		Rastgele Orman Sınıflandırma	100%	84,6%
		Yapay Sinir Ağları	96,4%	86,4%
960	320	Lojistik Regresyon	100 %	90,4 %
		En Yakın Komşu	100%	92,1%
		Destek Vektör Makineleri	96,2%	93,3%
		Naif Bayes	100%	78,7%
		Karar Ağaçları	98,4%	88,5%
		Rastgele Orman Sınıflandırma	100%	91,7%
		Yapay Sinir Ağları	98,1%	96,9%

Çizelge 4.4’de modellerin farklı eğitim ve test sayıları ile deneyip karşılaştırılmıştır. Sınıf sayısı 32 adet olduğu her iki durumda az sayıda veri seti ile eğitim yapıldığında çoğu algoritma tam olarak başarı sağlayamamaktadır. Bunu sebebi ise bazı algoritmaların daha fazla veri setine ihtiyaç duymasıdır. Bu sebep ile eğitim örnek sayısı artırılarak tekrarlanmıştır. Sonuç olarak az veri seti ile eğitim yapıldığından, başarı yüzdeleri yüksek olan algoritmalar veri seti arttırıldığında başarı yüzdeleri artmıştır. DVM ve NB algoritmalarının başarı yüzdesi oldukça yükselmiştir. Kullanılan tekniklerin 960 ve 320 adet veri setleri ile ayrı ayrı eğitim yapılarak test edilmiştir. Çizelge 4.4’de kullanılan tekniklerin test sonuçları görülmektedir.



Şekil 4.11 Çalışmada kullanılan tekniklerin 320 ve 960 adet veri seti ile yapılan testlerin sonuçları.

5. TARTIŞMA ve SONUÇ


Bu çalışmada işaret dilinde yapılan hareketlerin örüntülerini tanıyan bir eldiven tasarımı önerilmiştir. Eldiven üzerinde 1 adet AÖB, 6 adet esneklik algılayıcı, 5 adet manyetik alan algılayıcı bulunmaktadır. Bir eldivenden toplamda 6'sı esneklik algılayıcılar, 5'i manyetik alan algılayıcıları, 3'ü ivmeölçer ve 3'ü dönüölçer olmak 17 adet algılayıcı verisi elde edilmiştir. Oluşturulan tasarım her iki el için uygulanmıştır. Eldivende bulunan algılayıcıların tümü dış kısımdan görünmeyecek biçimde, eldivenin iç tarafına monte edilmiştir. Böylelikle giyilebilir olan eldivende görsel estetiği bozabilecek herhangi bir kablo kalabalığı bulunmamaktadır. Tasarlanan eldivende algılayıcılar ile yapılan kablo bağlantısı ve bağlantı noktaları önemli olmak ile birlikte kullanılan bağlantı kablosunun özelliğide önemlidir. Kullanılan kablonun çok sert olması durumunda, kullanıcı işaret dili hareketlerini yapmakda zorluk yaşamaktadır. Ayrıca kablonun, işaret dili hareketleri yapılırken yumuşayarak kopması sorun oluşturmuştur. Bu sebep ile algılayıcılar ve mikro denetleyici arasında kullanılan kablonun esnek ve kırılarak kopmalara karşı dayanıklı olması gerekmektedir. Seçilen kablonun kalınlığının ince olması kabloların montaj esnasında daha az yer kaplamasına fayda sağlamaktadır.

Algılayıcılardan işaret dilinde yapılan hareketlerin verileri toplanırken belli bir formatta toplanmalıdır. Oluşturulacak veri toplama formatı tanıma algoritmalarının veri kullanımına uygun bir biçimde olmalıdır. Bu sebep ile veri seti oluştururken algılayıcılardan toplanan verilerin hafıza kartına formatlı ve düzgün bir biçimde kaydedilmelidir. Kullanılan olan mikro denetleyici sayesinde verilerin hangi formatta ve nasıl kayıt edileceği belirlenmiştir. Veriler tanıma algoritmalarında kullanılacak bir biçimde toplanmadığında ise veri setini yeniden düzenlemek ek uğraş gerektirecektir. Veriler toplandıktan sonra incelenmeli ve gerekli ise öznitelik çıkarımı yapılarak veri seti yeniden düzenlenmelidir. Veri ön işlemede gereksiz ya da veri setinin tanıma doğruluğunun bozan veriler elenmeli veya tekrar düzenlenmelidir. Yapmış olduğumuz çalışmada eldivenden toplanan verilerden öznitelik çıkarımı yapılmıştır. Çalışma sayısal veriler üzerinde seyrettiğinden kullanılan öznitelik çıkarımları istatistiksel öznitelikler olarak belirlenmiştir. Kullanılan istatistiksel öznitelikler;

- Maksimum ve minimum
- Ortalama
- Ortanca (Medyan)
- Standart Sapma
- Varyans
- Basıklık (Kurtosis)
- Çarpıklık (Skewness)

Öznitelik çıkarımı yapıldıktan sonra veri seti, tanıma algoritmalarında kullanılmak üzere her bir işaret verisinin bir dizi olacak biçimde düzenlenmiştir (Şekil 3.4 ve Bölüm 3.7).

Her bir işaret dili hareketi için iki eldivenden toplamda 34 adet algılayıcı verisi toplanmaktadır. Bu veriler istatistiksel öznitelikleri çıkarılarak her bir işaretin tek bir diziden oluşması sağlanmıştır (Şekil 5.1).



Şekil 5.1 'arkadaş', 'tekrar' ve 'iyi' kelimesine ait 272 adet istatistiksel özniteliklerden oluşturulmuş grafik.

İşaret dili veri seti 32 adet kelimedenden oluşmaktadır. Veri seti dört kişiden her bir işaret için 10'ar örnek olmak üzere toplamda 1280 adet örnek toplanarak oluşturulmuştur.

Oluşturulan veri setindeki her bir örneklem için istatistiksel öznitelik çıkarımı yapılmıştır. Yapılan işaretleri tanımak için kullanılan teknikler;

- Lojistik Regresyon (Logistic Regression)
- Karar Ağaçları (Decision Trees)
- Naif Bayes (Naive Bayes)
- Rastgele Orman (Random Forest)
- Destek Vektör Makineleri (Support Vector Machines)
- En Yakın Komşu (K - Nearest Neighbor)
- Yapay Sinir Ağları (Artificial Neural Networks)

Kullanılan teknikler veri setinin az veya çok olmasından etkilenmektedir. Teknikler farklı sayıda veri setleri ile eğitim yapılarak test edilmiştir. Farklı veri setleri ile eğitim yapıldığında az olan veri setinin işaretleri sınıflandırma başarısı çok olan veri setine göre düşük olduğu tespit edilmiştir (Şekil 4.11). Veri setleri ile test yapılırken tanınacak işaretlerin sayısı sabit tutulmuştur. Veri setleri ile testler sonucunda tanınacak olan işaretlerin sayısı arttıkça veri setinde bulunan verilerin arttırılması gerekmektedir. Kullanılan her bir tekniğin tanıma oranı veri setinin sayına bağlı olarak değişiklik göstermektedir. Örneğin destek vektör makineleri ve lojistik regresyon 320 adet veri seti ile eğitildiğinde tanıma oranları 34,3% ve 76,8% olmaktadır. Destek vektör makineleri ve naif Bayes gibi bazı teknikler az olan veriler için uygun olmamak ile birlikte lojistik regresyon vb. teknikler az olan veriler içinde uygun olabilmektedir.

Kullanılan teknikler arasından yapay zeka algoritmaları seçilerek tanıma işlemleri gerçekleştirilmiştir (Şekil 4.11). Oluşturulan yapay sinir ağı denemeler sonucunda en iyi eğitim ve test doğruluğu veren model, 272 giriş katmanı, 1 adet gizli katman ve 32 adet çıkış katmanından oluşmuştur (Şekil 3.14 ve Çizelge 3.12). Denemeler genişletilebilmekle birlikte farklı aktivasyon fonksiyonları denenerek eğitim ve test doğruluğu arttırılabilir. Sınıflandırma çalışmalarında 320 ve 960 örnekten oluşan iki ayrı veri seti kullanılmıştır. Doğru tanıma oranı ortalama ilk veri setinde 86,4%, ikinci veri setinde 96,9% olarak hesaplanmıştır.

6. KAYNAKLAR

- Abramovich F, Grinshtein V, Levy T, 2020, Multiclass classification by sparse multinomial logistic regression, Cornell University, 1-21.
- Abualola H, Al Ghothani H, Eddin A N, Almoosa N, Poon K, 2016, Flexible gesture recognition using wearable inertial sensors, In 2016 IEEE 59th International Midwest Symposium on Circuits and Systems (MWSCAS), 1-4.
- Ahmed M A, Zaidan B B, Zaidan A A, Salih M M, Lakulu M M B, 2018, A Review on Systems-Based Sensory Gloves for Sign Language Recognition State of The Art Between 2007 and 2017, Sensors, 18, 1-44.
- Aksoy B, Ghazal Z, Şenol R, Ersoy M, 2020, Ses ve Metin Olarak Girilen İşaret Dili Hareketlerinin Robot Kol Tarafından Gerçekleştirilmesi, Düzce Üniversitesi Bilim ve Teknoloji Dergisi, 8, 220-232.
- Alabdulkarim A, Al-Rodhaan M, Tian Y, Al-Dhelaan A, 2019, A privacy-preserving algorithm for clinical decision-support systems using random forest. CMC Comput. Mater, 58, 585-601.
- Arık E, 2013, Türk İşaret Dilinde Sınıflandırıcılar Üzerine Bir Çalışma, Bilig, 67, 1-24.
- Arık E, 2016, Geçmişten Geleceğe Türk İşaret Dili Araştırmaları1, Medipol Üniversitesi, İstanbul, 1-16.
- Arık E, Makaroğlu B, Dikyüva H, 2016a, İşaret Dilleri ve Sözlükler, In H. Develi & M. Gürlek, I. ve II. Uluslararası Sözlükbilimi Sempozyumu. İstanbul, İstanbul Büyükşehir Belediyesi Yayınları, 1-11.
- Aronoff M, Meir I, Sandler W, 2005, The Paradox of Sign Language Morphology. Language, 81, 301, 1-50.
- Bauer B, Kraiss K F, 2002, Video-Based Sign Recognition Using Self-Organizing Subunits, In Object Recognition Supported by User Interaction for Service Robots, 2, 434-437.

- Bukhari J, Rehman M, Malik S I, Kamboh A M, Salman A, 2015, American Sign Language Translation Through Sensory Glove; Signspeak, International Journal of u-and e-Service, Science and Technology, 8, 131-142.
- Chandra M M, Rajkumar S, Kumar L S, 2019, Sign Languages to Speech Conversion Prototype using the SVM Classifier. In TENCON 2019-2019 IEEE Region 10 Conference (TENCON), 1803-1807.
- Cheng W, Hüllermeier E, 2009, Combining Instance-Based Learning and Logistic Regression for Multilabel Classification. Machine Learning, 76, 211-225.
- Çıbuk M, Maraşlı F, 2015, RFID Teknolojisi ve Kullanım Alanları. Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 4, 249-275.
- D'Agostini G, 1995, A multidimensional unfolding method based on Bayes' theorem. Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment, 362, 487-498.
- Dreiseitl S, Ohno-Machado L, 2002, Logistic Regression and Artificial Neural Network Classification Models: A Methodology Review. Journal of Biomedical Informatics, 35, 352-359.
- Dreuw P, Neidle C, Athitsos V, Sclaroff S, Ney H, 2008, Benchmark Databases for Video-Based Automatic Sign Language Recognition, In LREC, 1-6.
- Erdem U M, Sclaroff S, 2002, Automatic Detection of Relevant Head Gestures in American Sign Language Communication, In Object Recognition Supported by User Interaction for Service Robots, 1, 460-463.
- Gafka J, Maşior M, Zaborski M, Barczewska K, 2016, Inertial motion sensing glove for sign language gesture acquisition and recognition. IEEE Sensors Journal, 16, 6310-6316.
- Gasso G, 2019, Logistic regression, INSA Rouen - ASI Departement Laboratory LITIS, 1-24.
- Gopi A P, Jyothi R N S, Narayana V L, Sandeep K S, 2020, Classification of Tweets Data Based on Polarity Using Improved RBF Kernel of SVM. International Journal of Information Technology, 1-16.

- Gupta D, Singh P, Pandey K, Solanki J, 2015, Design and development of a low cost Electronic Hand Glove for deaf and blind. In 2015 2nd International Conference on Computing for Sustainable Global Development (INDIACom), 1607-1611.
- Han J, Pei J, Kamber M, 2011, Data mining: concepts and techniques, Elsevier, 327-328.
- Harish N, Poonguzhali S, 2015, Design and development of hand gesture recognition system for speech impaired people. In 2015 International Conference on Industrial Instrumentation and Control (ICIC), 1129-1133.
- Hope T M, 2020, Linear regression. In Machine Learning, Academic Press, 67-81.
- Hoq M N, Islam M M, Nipa N A, Akbar M M, 2020, A Comparative Overview of Classification Algorithm for Bangla Handwritten Digit Recognition. In Proceedings of International Joint Conference on Computational Intelligence, 265-277.
- Jadhav A J, Joshi, M P, 2016, AVR based embedded system for speech impaired people. In 2016 International Conference on Automatic Control and Dynamic Optimization Techniques (Icacadot), 844-848.
- Jin C, De-Lin L, Fen-Xiang M, 2009, An improved ID3 decision tree algorithm. In 2009 4th International Conference on Computer Science & Education, 27-130.
- Karaca M F, Bayır Ş, 2018, Türk İşaret Dili İncelemesi: İletişim ve Dil Bilgisi, Ulusal Eğitim Akademisi Dergisi, 2, 35-58.
- Kavzoğlu T, Çölkesen İ, 2010, Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi. Harita Dergisi, 144, 73-82.
- Kemaloğlu Y K, 2008, Konuşamayan İşitme Engellilerin (Sağırların) Tarihi, Türkiye Klinikleri J Int Med Sci, 4, 1-15.
- Kemaloğlu Y K, Kemaloğlu P Y, 2012, The history of sign language and deaf education in Turkey. Kulak Burun Boğaz İhtisas Dergisi, 22, 65-76.
- Kemaloğlu Y K, 2014, Engellilik, Kulak Burun Boğaz (KBB) Hekimliği ve İşaret Dili, Bozok Tıp Dergisi, 1, 38-53.

- Kındıroğlu A A, Yalçın H, Akarun L, 2011, Öznitelik Birleştirmeye Dayalı Çok-Dilde El Alfabeti Tanıma, IEEE 19. Sinyal İşleme ve Uygulamaları Konferansı (SIU), Antalya, 1-4.
- Kishore P V V, Kumar P R, 2012, A Video Based Indian Sign Language Recognition System (INSLR) Using Wavelet Transform and Fuzzy Logic, International Journal of Engineering and Technology, 4, 537, 1-6.
- Lei L, Dashun Q, 2015, Design of Data-Glove and Chinese Sign Language Recognition System Based on ARM9, In 2015 12th IEEE International Conference on Electronic Measurement & Instruments (ICEMI), 3, 1130-1134.
- Li Q N, Li T H, 2020, Research on the Application of Naive Bayes and Support Vector Machine Algorithm on Exercises Classification, In Journal of Physics: Conference Series, 1437, 1-7.
- Lokhande P, Prajapati R, Pansare S, 2015, Data Gloves for Sign Language Recognition System, International Journal of Computer Applications, 1-14.
- Lu Y, Roychowdhury V, 2006, Parallel randomized support vector machine. In Pacific-Asia Conference on Knowledge Discovery and Data Mining, Berlin, Heidelberg, 205-214.
- MEB, 2015 Türk İşaret Dili Sözlüğü, Ankara, 1-90.
- Pezzuoli F, Corona D, Corradini M L, 2019, Improvements in a Wearable Device for Sign Language Translation. In International Conference on Applied Human Factors and Ergonomics, Springer, Cham, 70-81.
- Saqib N, Rahman A, 2020, Application of machine learning techniques for real-time sign language detection using wearable sensors. In Proceedings of the 11th ACM Multimedia Systems Conference, 178-189.
- Shah K, Patel H, Sanghvi D, Shah M, 2020, A Comparative Analysis of Logistic Regression, Random Forest and KNN Models for The Text Classification. Augmented Human Research, 5, 1-16.
- Shahbazi F, 2020, Using Decision Tree Classification Algorithm to Design and Construct the Credit Rating Model for Banking Customers. IOSR Journal of Business and

Management, 21, 24-28.

- Shukor A Z, Miskon M F, Jamaluddin M H, bin Ali F, Asyraf M F, bin Bahar M B, 2015, A New Data Glove Approach for Malaysian Sign Language Detection. *Procedia Computer Science*, 76, 60-67.
- Swee T T, Salleh S H, Ariff A K, Ting C M, Seng S K, Huat L S, 2007, Malay sign language gesture recognition system. In 2007 International Conference on Intelligent and Advanced Systems, 982-985.
- Wang B, Mao Z, 2020, A dynamic ensemble outlier detection model based on an adaptive k-nearest neighbor rule. *Information Fusion*, 30-40.
- Zeshan U, 2003, Aspects of Türk İşaret Dili (Turkish Sign Language), *Sign Language & Linguistics*, 6, 43-75.
- Zhang X, Chen X, Li Y, Lantz V, Wang K, Yang J, 2011, A framework for hand gesture recognition based on accelerometer and EMG sensors. *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, 41, 1064-1076.
- Zhi-heng W, Jiang-tao C, Jin-guo L, Zi-qi Z, 2017, Design of Human-Computer Interaction Control System Based on Hand-Gesture Recognition, In 2017 32nd Youth Academic Annual Conference of Chinese Association of Automation (YAC), 143-147.

İnternet Kaynakları

- 1- <http://classics.mit.edu/Aristotle/politics.7.seven.html>, 03.03.2020
- 2- <https://www.resmigazete.gov.tr/eskiler/2009/07/20090714-1.htm>, 26.02.2020
- 3- <https://www.blausen.com>, 09.03.2020
- 4- <https://www.sparkfun.com/datasheets/Sensors/Flex/>, 12.05.2020
- 5- www.nvidia.com/tr-tr/autonomous-machines/embedded-systems/jetson-nano/, 16.04.2020



ÖZGEÇMİŞ

Adı Soyadı : Abdullah ÇAYLI
Doğum Yeri ve Tarihi : Alaçam, 1995
Yabancı Dili : İngilizce
İletişim (Telefon / e-posta) :05413659289 / acayli@usr.aku.edu.tr

Eğitim Durumu (Kurum ve Yıl)

Lise : Alaçam Çok Programlı Lisesi (2010– 2013)
Lisans : Afyon Kocatepe Üniversitesi, Mekatronik Mühendisliği
Böl., (2014–2018)
Yüksek Lisans : Afyon Kocatepe Üniversitesi, Fen Bilimleri Ens., Makine
Mühendisliği ABD, (2018 – 2020)

EKLER

EK 1. Hazırlanan kontrol kartı devre şeması

