

**ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

DOKTORA TEZİ

**DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK
GİYİLEBİLİR SENSÖRLERDEN KİŞİ TANIMA**

Şafak KILIÇ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**ANKARA
2021**

Her hakkı saklıdır

ÖZET

Doktora Tezi

DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK GİYİLEBİLİR SENSÖRLERDEN KİŞİ TANIMA

Şafak KILIÇ

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. İman ASKERBEYLİ
Eş Danışman: Doç.Dr. Yılmaz KAYA

Son yıllarda kişi tanıma problemi ile ilgili araştırmacılar tarafından yoğun çalışmalar yapılmaktadır. Araştırmacılar kişi tanıma işlemi için bilgisayar ile görü ve sinyal işleme sistemlerini sıklıkla kullanmaktadır. Yapılan çalışmalar detaylı incelendiğinde, sensör sinyallerinden elde edilen veriler kullanarak kişi tanıma işleminin gerçekleştirildiği ancak kişinin fiziksel hareketlerinden meydana gelen sinyallerden kişi tanıma işlemi yapılmadığı görülmüştür. Bu çalışmada giyilebilir sensörlerden elde edilen veriler yardımı ile kişi tanıma işlemi gerçekleştirilmiştir.

KT işleminin en önemli aşaması elde edilen sinyallerden başarı oranı yüksek olabilecek öznelikler çıkarmaktır. Bu çalışma kapsamında, 1D-LBP ve 1D-FbLBp yöntemleri kullanılıp öznelikler çıkarılmıştır. Çıkarılan öznelikler makine öğrenmesi yöntemleri ile test edilmiştir. Çıkan sonuçlara göre, sensör sinyallerinden elde edilen veriler aracılığı ile KT işleminin başarılı olarak gerçekleştiği anlaşılmaktadır.

Çalışmamızın temellini oluşturan kısım, sinyaller elde edildikten sonra ön işlemden geçirerek derin transfer öğrenme yöntemlerinin uygulanması olmuştur. VGG, ResNet, MobileNet, DenseNet gibi sıklıkla kullanılan derin transfer öğrenme yöntemleri problemimiz doğrultusunda yeniden tasarlanmıştır. Çalışmamız daha önce yapılan çalışmalar ile kıyaslandığında, derin transfer öğrenme yöntemlerinin KT işleminde etkili olduğu anlaşılmıştır.

Çalışmamızda ek olarak, sensörlerden elde edilen veriler sayesinde, bireylerin sergilemiş olduğu fiziksel aktivitelerinden tespiti hem makine öğrenmesi hem de derin transfer öğrenme yöntemleri ile yapılmış ve başarılı sonuçlar elde edilmiştir. Sensörlerin kullanıldığı bölgeye ve sensör türlerine göre de, kişi tanıma ve hareketlerin tanınması işlemleri gerçekleştirilmiştir. Bu işlemler de elde edilen sonuçlar da daha önceden yapılan çalışmalar ile kıyaslandığında başarılı olduğu görülmüştür.

Ağustos 2021, 131 sayfa

Anahtar Kelimeler: Sensör sinyalleri, Kişi tanıma, Derin transfer öğrenme, Öznelik çıkarma

ABSTRACT

Ph.D. Thesis

USING DEEP LEARNING IN WEAREBLE SENSORS FOR PERSON RECOGNITION

Şafak KILIÇ

Ankara University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

Supervisor: Prof. Dr. İman ASKERBEYLİ
Co-Supervisor: Assoc. Prof. Dr. Yılmaz KAYA

In recent years, a large number of studies have been carried out by researchers on the person recognition (PR) problem. Researchers often use computer vision and signal processing systems for person recognition. When the previous studies were examined in detail, it was seen that the person recognition process was carried out using the data obtained from the sensor signals, but the PR process was not performed from the signals formed by the physical activities of the person. In this study, person recognition process was carried out with the help of data obtained from wearable sensors.

The most important step of the PR process is to extract features that can have a high success rate from the obtained signals. In this study, features were extracted by using 1D-LBP and 1D-FbLBp methods. Extracted features were tested with machine learning methods. According to the results, it is understood that the PR process was successful through the data obtained from the sensor signals.

After obtaining the signals, which form the basis of our study, deep transfer learning methods were applied by pre-processing. Frequently used deep transfer learning methods such as VGG, ResNet, MobileNet, DenseNet have been reconstructed in line with our problem. When our study was compared with previous studies, it was understood that deep transfer learning methods were effective in the PR process. In addition, in our study, thanks to the data obtained from the sensors, the determination of the physical activities of the individuals was made with both machine learning and deep transfer learning methods and successful results were obtained. According to the region where the sensors are used and the sensor types, person recognition and physical activities of the person are recognized. The results obtained in these procedures were also found to be successful when compared with previous studies.

August 2021, 131 pages

Keywords: Sensor signals, Person recognition, Deep transfer learning, Feature extraction

TEŞEKKÜR

Doktora öğrenim hayatım boyunca ve özellikle ile tez çalışmamda hem bilgi birikimlerini hem de manevi desteklerini esirgemeyen danışman hocam Prof. Dr. İman ASKERBEYLİ ve doktora başlamamda beni yönlendiren ve tüm aşamalarında desteğini hiç esirgemeyen ikinci danışman hocam Doç. Dr. Yılmaz KAYA'ya

Tezimin ilerleme sürecinde, tez izleme toplantılarına katılarak çalışmanın ve tezin ilerlemesine katısı sunan ve süreç içerisindeki motivasyonumu arttıran değerli hocalarım Prof. Dr. Nizami GASİLOV ve Doç. Dr. Semra GÜNDÜÇ'e

Doktora sürecine birlikte başladığım hem sınıf hem de mesai arkadaşım değerli dostum Yahya DOĞAN'a ve süreç boyunca deneyimleriyle beni yönlendiren ve destek olan kıymetli arkadaşım ve değerli dostum Doç.Dr. Mustafa KAYA'ya

Öğrenim hayatıma ilk başladığım günden bugüne kadar desteklerini esirgemeyen geleceğim için çabalayan canım aileme,

Bu süreç boyunca manevi desteklerini esirgemeyen nişanlım kıymetlim Elif'e,

Sonsuz teşekkürlerimi bir borç bilirim.

Şafak KILIÇ

Ankara, Ağustos 2021

İÇİNDEKİLER

ETİK.....	i
ÖZET.....	ii
ABSTRACT	iii
TEŞEKKÜR	iv
KISALTMALAR DİZİNİ	vii
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ	x
1. GİRİŞ.....	1
1.1 Genel Bilgiler	3
1.2 Tezin Amacı	9
1.3 Tez Kapsamında Yapılan Çalışmalar	10
1.4 Tezin Özgün Değeri	11
2. BİYOMETRİ KİŞİ TANIMA PROBLEMİ	13
2.1 Tanım	13
2.2 Biyometrik Özellikler Gereksinimleri.....	15
2.3 Biyometrik Sistem Mimarisi	16
2.4 Sensör Sinyallerinden Kişi Tanıma İle İlgili Yapılan Çalışmalar	17
2.5 Fiziksel Aktivite Tanıma	24
3. TEORİK BİLGİLER	26
3.1 Veri Seti.....	26
3.2 Sinyallerin Resime Dönüştürülmesi	28
3.3 Yerel İkili Örüntüler (YİÖ) Modeli	30
3.3.1 Bir boyutlu yerel ikili örüntü.....	32
3.3.2 Tek boyutlu özellik temelli yerel ikili örüntü	34
3.4 Makine Öğrenmesi Yöntemleri.....	36
3.4.1 Rastgele orman algoritmaları (RF).....	40
3.4.2 En yakın komşu algoritmaları (Knn).....	42
3.4.3 Lineer diskriminant analizi (LDA)	44
3.4.4 Yapay sinir ağları (YSA).....	44
3.4.5 Ortalamalı N bağımlılık tahmincileri (A1DE, A2DE).....	47
3.5 Derin Öğrenme	48

3.5.1 Evrişimsel sinir ağları	49
3.5.2 Aktivasyon fonksiyonları	57
3.5.3 Transfer öğrenme	60
3.5.3.1 Alexnet modeli	64
3.5.3.2 VGG modeli	64
3.5.3.3 ResNet modeli	65
3.5.3.4 MobileNetV1 ve MobileNetV2 modeli.....	72
3.5.3.5 Inceptionv1, Inceptionv2 ve Xception modeli.....	73
3.5.3.6 DenseNet modeli	77
3.5.4 Derin öğrenme kütüphaneleri.....	79
3.5.4.1 TensorFlow	79
3.5.4.2 Caffe.....	80
3.6 Sensör Kanallarından Elde edilen İstatistiksel Öznitleikler	83
3.7 Performans Ölçütleri	84
4. ÖNERİLEN KİŞİ TANIMA MODELLERİ.....	86
4.1 Önerilen YİÖ Modeli	86
4.2 Önerilen Transfer Öğrenmesi Modelleri	87
5. DENEYSEL SONUÇLAR	94
5.1 Klasik Yerel İkili Örüntü Sonuçları.....	94
5.2 ResNet Modeli ile Elde Edilen Sonuçlar	102
5.3 Diğer Derin Transfer Öğrenme Tekniklerine ilişkin Sonuçlar	110
6. SONUÇLAR VE ÖNERİLER.....	116
KAYNAKLAR	120
ÖZGEÇMİŞ.....	130

KISALTMALAR DİZİNİ

ACC: İvmeölçer
CNN: Evrişimsel Sinir Ağları
DL: Derin Öğrenme
ESA: Evrişimsel Sinir Ağları
FC: Tam Bağlantılı Katman
GYR: Jiroskop
HAR: İnsan Aktivite Tanıma
kNN : k En Yakın Komşu
Kt: Kişi Tanıma
Lbp: Yerel İkili Örüntü Yöntemi
LSTM: Uzun Kısa Süreli Bellek
MAG: Manyetometre
MÖ: Makine Öğrenmesi
RNN: Tekrarlayan Sinir Ağları
RO: Rastgele Orman
SVM : Destek Vektör Makinaları
UCI : Veri tabanı
YSA: Yapay Sinir Ağları

ŞEKİLLER DİZİNİ

Şekil 2.1 Biyometrik Sınıflandırma Çeşitleri.....	14
Şekil 3.1 Sensörlerin İnsan Vücudunda Yerleştirildiği Bölgeler (Kılıç vd. 2020)	28
Şekil 3.2 Sinyallerin Resme Dönüştürülmüş Hali.....	30
Şekil 3.3 YİÖ Etiketlerinin Oluşturulması.....	31
Şekil 3.4 1D-LBP Kullanılarak Öznitelik Çıkarımı, (a) Ham Sensör İşaretlerine Ait Bir Bölüm, (b) İşaretlere Ait Değerler, (c) Merkez Değerin Komşu Değerlerle Karşılaştırılarak İkili Dizginin Oluşturulması, (d) Onlu Taban Karşılığı.....	32
Şekil 3.5 Fark, İşaret ve Büyüklük Vektörlerin Elde Edilmesi.....	34
Şekil 3.6 1D-FbLBP Operatörün Hesaplanması	35
Şekil 3.7 Denetimli Öğrenme Modeli Süreci (Afrin ve Nahar, 2015).....	39
Şekil 3.8 Rastgele Orman Algoritması Örneği.....	41
Şekil 3.9 Yapay Sinir Ağı Modeli.....	47
Şekil 3.10 Yapay Zeka, Makine Öğrenmesi Ve Derin Öğrenme Arasındaki İlişki ...	49
Şekil 3.11 Bir Evrişimsel Sinir Ağı Mimarisi.....	50
Şekil 3.12 İki Adım Kaydırma İle 7x7 Boyutlu İlgili Alanı Matrisinden 3x3 Boyutlu Öznitelik Matrisinin Oluşumu (Dev 2017'den değiştirilerek alınmıştır) 53	
Şekil 3.13 1'er Çerçeve Kullanarak Yarım Dolgu Sıfır Doldurma İşlemi (Dev 2017'den değiştirilerek alınmıştır).....	54
Şekil 3.14 Havuzlama İşlemleri	56
Şekil 3.15 Çeşitli Aktivasyon Fonksiyonları	59
Şekil 3.16 Evrişimli Sinir Ağları Ve Transfer Öğrenme.....	61
Şekil 3.17 Özellik Çıkarıcı Metot	62
Şekil 3.18 Kısmi Özellik Çıkarıcı Metot.....	63
Şekil 3.19 Alexnet Mimarisi (Kızrak, 2018).....	64
Şekil 3.20 VGGNet Modellerine Ait Görseller. (a) VGG16 ve (b) VGG19	65
Şekil 3.21 Temel ResNet Bloğu (He vd. 2015)	69
Şekil 3.22 Artık (Residual) Öğrenme.....	70
Şekil 3.23 ResNet Mimarisi	71
Şekil 3.24 MobileNetV1 Mimarisi (Qin vd. 2018).....	73
Şekil 3.25 MobileNet V2 Mimarisi (Qin vd. 2018).....	74

Şekil 3.26 Naif Inception Modülü.....	74
Şekil 3.27 InceptionV1 Modelinin Yapısı	75
Şekil 3.28 5x5 Katmanı Kaldırıp 3x3 Katmanı Eklenmesi.....	76
Şekil 3.29 InceptionV2 Modelinin Yapısı	76
Şekil 3.30 Xception Modeli Yapısı.....	77
Şekil 3.31 DenseNet Mimarisi (Huang vd. 2017).....	78
Şekil 3.32 TensorFlow İşleyiş Diyagramı.....	80
Şekil 3.33 CaffeNet Örneği.....	81
Şekil 4.1 Kişi Tanıma Sistemi (Kılıç vd. 2021).....	86
Şekil 4.2 Transfer Öğrenmesi Sınıflandırma Şeması (Kılıç vd. 2020)	89
Şekil 4.3 Önerilen ResNet Modelinin Grafik Açıklaması	91
Şekil 4.4 Derin Özellik Oluşturma Vektörü Grafik Gösterimi	92
Şekil 5.1 4 Bay Ve 4 Bayan Deneğe Ait Oturma Eylemi İvme Sensörü X Eksen İşaret Örnekleri.....	95
Şekil 5.2 8 Deneğe Ait İşaretlere 1D-LBP Uygulandıktan Sonra Oluşan Yeni İşaretler.....	96
Şekil 5.3 İşaretlere 1D-LBP Uygulandıktan Sonra Oluşan Yeni İşaretlere Ait Histogramlar.....	96
Şekil 5.4 İşaretlere 1D-Fblbp Uygulandıktan Sonra Oluşan Yeni İşaretlere Ait Histogramlar.....	97
Şekil 5.5 ResNet Modellerinin Kişi Tanıma Üzerindeki Başarısı (%)	104
Şekil 5.6 Hareketlere Göre En İyi Başarı Oranları (%)	106
Şekil 5.7 Farklı ResNet Mimarilerine Göre Elde Edilen En Yüksek Başarı Oranları (%).....	108
Şekil 5.8 ResNet Modellerinin Kişi Tanıma Üzerindeki Performansları	109
Şekil 5.9 Diğer Transfer Öğrenme Yöntemlerinin Kişi Tanıma Üzerindeki Başarı Oranları (%).....	111
Şekil 5.10 Hareketlerin Kişi Tanıma Üzerindeki Etkisi Başarı Oranları (%).....	113
Şekil 5.11 Bölgelerin Kişi Tanıma Üzerine Etkisi Başarı Oranları (%)	115

ÇİZELGELER DİZİNİ

Çizelge 3.1 Hareketlerin Simgesi ve Açıklaması.....	27
Çizelge 3.2 Farklı ResNet Katman Mimarileri	72
Çizelge 3.3 İşaretlerden Elde Edilen İstatiksel Öznitelikler	83
Çizelge 3.4 Karışıklık matrisi	84
Çizelge 5.1 1D-FbLBP öznitelikler kullanılarak kişi tanıma başarı oranları (%).....	98
Çizelge 5.2 Hareketlere göre Kişi tanıma Başarı Oranları (%).....	99
Çizelge 5.3 Kişi Tanımda İstatistiksel Özniteliklerin Başarı Oranları (%).....	100
Çizelge 5.4 Sensör Türlerine Göre Kişi Tanıma Başarı Oranları (%)	101
Çizelge 5.5 Sensör Bağlantı Bölgesine göre Kişi Tanıma Başarı Oranları (%).....	102
Çizelge 5.6 ResNet Modelleri Başarı Oranları (%)	103
Çizelge 5.7 Hareketlere Göre Sınıflandırma Başarı Oranları (%)	105
Çizelge 5.8 Sensör Bağlantı Bölgesine göre Kişi Tanıma Başarı Oranları (%).....	107
Çizelge 5.9 Diğer Transfer Öğrenme Yöntemlerinin Kişi Tanıma Üzerindeki Başarı Oranları (%).....	110
Çizelge 5.10 Hareketlerin Kişi Tanıma Üzerindeki Etkisi Başarı Oranları (%).....	112
Çizelge 5.11 Bölgelerin Kişi Tanıma Üzerine Etkisi Başarı Oranları (%)	114

1. GİRİŞ

İnsanların sergilemiş olduğu fiziksel aktivitelerin tespiti araştırmacıların üzerinde yoğunlaştığı konulardan biri olmuştur. Fiziksel aktivite, yürüme, oturma, zıplama gibi günlük yaşamda meydana gelen rutin sporlar olabileceği gibi, hastalık sonucu istemsiz olarak sergilenen fiziksel eylemlerde olabilmektedir. İnsan Aktivitesi Tanıma (Human Activity Recognition, HAR) amacı ile geliştirilen sistemler, bireyin kendisi ve çevresi ile fiziksel etkileşiminden kaynaklanan değişimlerin izlenmesi sonucu meydana gelen durumların tesbitine olanak sağlayan otomatik yapılardır. Ayrıca, yukarıda belirtilen faaliyetleri gerçekleştiren kişinin kimliğinin tespit edilmesi (tanımlanması) da mümkündür.

Aktivite yapan kişileri tespit etmek en az aktivite tespiti kadar zor ve önemlidir. Günlük yaşamda, kişiselleştirilmiş reklam kampanyalarından güvenlik önlemlerine kadar geniş bir yelpazede kişisel tanımlama kullanılmaktadır (Bayat vd. 2014). Örneğin, sergilediği fiziksel faaliyeti ve kimliği bilinen bir kişi, sergilediği hareket ve/veya kişinin özel ilgi alanları ile ilgili bir reklamla karşılaşrsa, reklamın başarısı artar. Ayrıca yetkili personelin güvenlik kısıtlatmalı alanlarda bilgisayar ve benzeri araçları kullanmasına veya girmesine izin veren sistemlerde personel tanımlama önemli bir rol oynamaktadır.

Günümüzde biyometrik teknolojiler, insan güvenliğinin gerektirdiği tüm alanlarda giderek kullanımı artan bilgi güvenliği alanlarından biridir. Kişi tanıma (KT), yaş tahmini ve cinsiyet tanıma gibi konular akademik ve ticari faaliyet sergileyen alanlarda son yıllarda yaygın olarak üzerinde araştırma yapılan insan-bilgisayar etkileşimi konularındandır. KT, elde edilen biyometrik özniteliklere göre kişiyi belirleme işlemidir.

Bu çalışma kapsamında kişilerin 5 farklı bölgesine takılmış olan “ivmeölçer”, “manyetometre” ve “jiroskop” sensörlerinden elde edilen sinyaller kullanılarak ResNet transfer derin öğrenme yöntemleri ile KT işlemi gerçekleştirilmiştir. Çalışmada farklı fiziksel eylemlere göre de kişi tespiti yapıp KT’de etkin eylemler tespit edilmiştir. Bunun yanında KT’de etkin vücut bölgeleri de tespit edilmiştir. ResNet mimari ile genel olarak yüksek başarı oranları gözlenmiştir.

Bu çalışma giyilebilir ivmeölçer, jiroskop, manyetometre sensörleri sinyallerinin, kimlik sahtekârlığı saldırılarını önlemek için yeni bir biyometrik sistem olarak kullanılabileceğini göstermiştir. Özetle, önerilen yöntem giyilebilir sensör sinyallerinin biyometrik uygulamalarda etkili kullanımı için çok yararlı olabilir.

Bu tez çalışması kapsamında ise sensör sinyallerinden elde edilen veriler aracılığı ile derin öğrenme yöntemleri kullanılarak kişi tespiti işlemi gerçekleştirilmiştir. Çalışma kapsamında kullanılan UCI veri tabanından elde edilmiştir.

Tez çalışmasının birinci bölümünde kişi tanıma ile ilgili çalışmalar detaylı olarak incelenmiştir.

İkinci bölümde ise biyometrik kişi tanıma problemi üzerinde durulup sensör sinyallerinden elde edilen veriler kullanılarak kişi tanıma işlemin nasıl gerçekleşeceği hakkında bilgiler verilmiştir.

Üçüncü bölümde ise makine öğrenmesi yöntemlerinden başlanarak derin öğrenme teorik altyapısı anlatılıp tez çalışması kapsamında kullanılan özellik çıkarma yöntemi açıklanmıştır. Daha sonra transfer öğrenme modelleri açıklanmıştır.

Dördüncü bölümde tez çalışması kapsamında kullanılan veri setlerinin elde edilmesi, görüntülerin ön işlemlerden geçirilmesi ve önerilen sınıflandırma modelleri hakkında bilgi verilmiştir.

Beşinci bölümde tez çalışması kapsamında kişi tespiti için elde edilen deneysel sonuçlar karşılaştırmalı olarak verilmiştir.

Altıncı bölümde tez çalışması kapsamında elde edilen sonuçlar hakkında bilgi verilmiştir. Ayrıca çalışmanın geliştirilmesi ile ilgili öneriler ve iyileştirmeler sunulmuştur.

1.1 Genel Bilgiler

Günümüzde teknolojik gelişmelere bağlı olarak araştırmacılar, insan bilgisayar etkileşimli sistemler üzerinde yoğunlaşmaya başlamışlardır. Bu sistemlerin tasarlanmasındaki amaç, bireylere ait olan kişisel verilerin elde edilmesi ve bunların işlenmesini sağlayan otomatik sistemlerin geliştirilmesidir. Biyometrik ve biyomedikal alanındaki çalışmalar günümüzdeki insan bilgisayar etkileşiminin örnekleri olarak gösterilebilmektedir. Bu çalışma alanlarından biride insan aktivitelerinin sınıflandırılması ve bu kişilerin tanınması işlemleridir (Fuentes vd. 2012, Bayat vd. 2014).

İnsan yaşamının bir parçası olarak sürekli olarak sergilemiş oldukları fiziksel aktivitelerin tespit edilmesi birçok araştırmanın önemli konusu olmaktadır. Aynı şekilde fiziksel hareketlerden kişi tespiti ise araştırmacıların hevesini artıracak önemli bir konu olmaktadır.

Fiziksel aktivite, günlük hayatta yaptığımız "yürüme, koşma, zıplama ve oturma" gibi bir dizi eylem veya belirli sporların belirli eylemlerinden motor reflekslerin sonuçlarına kadar tüm vücut değişikliklerini içeren eylemler olarak tanımlanabilir. İnsan aktivitelerini belirleme süreci, bireylerin kendileriyle veya çevresel faktörlerle etkileşimini içeren fiziksel aktivitelerin gözlemlenmesini içerir. Ek olarak, fiziksel hareketlerin tespiti işlemi gibi, bu eylemleri sergileyen kişinin tespit edilmesinde gerçekleştirebilmektedir. Bir insan yürüdüğünde gövde, kollar ve bacaklar dâhil olmak üzere vücudun çeşitli bileşenlerinin hareketi karakteristik bir imza oluşturmaktadır (Fang vd. 2016).

Yapılan çalışmalara aktivite tespiti üzerine yoğunlaşmış olmasına rağmen, aktiviteyi gerçekleştiren kişiyi tespit etmek de zorlu ve önemli bir süreçtir. Kişi tanımlanması, insanlığın kendisi kadar eski bir amaçtır. Günümüzün de önemli sorunlarından birisi olmaya devam etmektedir. Modern dünyada teknoloji ve hizmetler geliştikçe hızlı ve güvenilir kimliğin gerekli olduğu insan faaliyetleri ve işlemleri çoğalmıştır. Örnekler arasında pasaport kontrolü, bilgisayar oturum açma kontrolü, bankamatik işlemleri, tesis içi erişim kontrolleri ve genel otomatik güvenlik işlemleri verilebilmektedir. Araştırmacılar teknolojinin gelişmesi ile teknolojiye yenilikleri bu sorunun çözümünde kullanmaya çalışmaktadır (Lavi vd. 2018).

Kişi tespiti, günlük yaşamda sağlık, güvenlik, reklam gibi birçok alandan kullanılmaktadır. İnsanları fiziksel davranışlarına göre (örneğin yürüme şekillerine göre) ayırt etme, güvenlik sistemleri aracılığıyla anormal insan faaliyetlerini tespit etme, akıllı cihazlar ve kullanıcılar arasındaki etkileşim, insan hareketlerini animasyon ve robotikte sentezleme, tıbbi rehabilitasyon, yaşlılar ve dezavantajlı bireylerin takip edilmesi gibi işlemlerde insan faaliyetlerinin otomatik olarak tanınmasını kullanabilir (Yu ve ark. 2009, Golomb ve ark. 1990). Örneğin, gerçekleştirdiği fiziksel aktivitesi ve kimliği bilinen bir kişi, faaliyet ve/veya kişinin özel ilgi alanları ile ilgili bir reklamla karşılaşarsa, reklamın başarısı artar. Ayrıca, yetkili personelin güvenlik kısıtlanmalı alanlarda bilgisayar ve benzeri araçları kullanmasına veya girmesine izin veren sistemlerde personel tanımlama önemli bir rol oynamaktadır.

Son on yıllarda bilgisayar biliminin üzerinde yoğunlaştığı bireyin aktivitesinin tanınması ve bu aktivitenin sahibi olan bireyin tespit edilmesi popülerliğini korumaktadır. Sağlık, güvenlik, spor yaşlı ve dezavantajlı bireylerin takibi insan aktivitelerinin tanınması için kullanılan alanlardan sadece birkaçıdır. Kullanılan sensörler açısından sıklıkla karşılaşılan yöntemler; insanların sergilediği aktiviteleri kaydetmek için kamera kullanılması, kişisel elektronik cihazlarda (cep telefonu veya akıllı saat gibi) sensörlerin kullanılması ve giyilebilir sensörlerin kullanılmasıdır (Bayat vd. 2014).

Giyilebilir sensörler kişi tanıma işlemleri için yapılan araştırmalarda en doğru yöntem olmakla birlikte kullanıcı konforu açısından günlük hayatta uygulanabilirlikleri düşüktür (Bayat ve ark. 2014). Maliyeti, kurulumu ve görüş açısı sınırlamaları nedeniyle kameraların kullanımı elverişli bir araç olarak sınıflandırılmamaktadır. Kurulum ve donanım maliyeti gerektirmediğinden ve bir akıllı telefonun işlem gücü toplanan verileri işlemek için yeterli olduğundan, kişisel elektronik cihazlara gömülü sensörlerin kullanılması, sensör verilerinin elde edilmesi ve faaliyetlerin ve kişilerin tanımlanması için uygun bir yöntem olarak düşünülmektedir. Kişisel mobil cihazların kullanılması ile yapılan aktivite tanıma çalışmalarında; küçük veri boyutu, hızlı tanımlama, yüksek doğruluk, gerçek zamanlı tanımlama, verimli batarya kullanımı, mobil platformlarda uygulanabilirlik, dinamik sensör seçimi gibi sürecin farklı yanları ile ilgilenilmiştir (Bayat ve ark. 2014).

Vücuda giyilebilen sensörler (Lukowicz vd. 2004, Patel vd. 2009) ve çevresel (Poppe, 2007) kaynaklardan alınan verilerin işlenmesi aracılığı ile kişi tanıma işlemleri gerçekleştirilebilir. Teknolojinin gelişmesine paralel bir şekilde mikro sensör teknolojileri de gelişme göstermekte olup, bu ilerleme aracılığı ile kablosuz sensör ağları ve kablosuz iletişim araçlarının kullanımının artması ile kişi tanıma için düşük maliyetli ve başarı oranı yüksek gizliliğe önem veren çalışmalara imkân tanımıştır. Bu gelişmeler doğrultusunda, insan vücudunda devamlı hareket halinde olan eklemler, bel, el bilekliği, göğüs gibi farklı vücut bölgelerine sensörler uygulanmış ve yüksek başarı elde edilmesi amaçlanmıştır.

Mobil teknolojilerin son on yıllarda hızlı bir şekilde gelişmesi ile birlikte, bu cihazlarda ivmeölçer, jiroskop ve manyetometre gibi sensörler yaygın olarak mevcut olmaya başlamıştır.

Triaksiyal yapıya sahip bir ivmeölçer, fiziksel bir aktivite sergilendiğinde içerisinde bulunduğu konumun eksen boyutunda zamana bağlı yön değiştirmesini hesaplayarak bir konum hareket sinyali oluşturabilmektedir. Jiroskop sensörü, açısal hız ölçüm işlemini nesnenin aynı düzlemdeki titreşim eğilimi aracılığıyla ile gerçekleştirir. Manyetometre, belirli bir konumda bulunan manyetik alan etkisini ölçmeye yarayan ve ölçtüğü manyetik alanın yönünü ve kuvvetini hesaplayan bir araçtır.

Kullanılan sensörlerin vücudun belirli bölgesine yerleştirilmesi sonucu elde edilen veriler aracılığıyla kişi tanıma ve kişinin sergilediği fiziksel aktiviteleri tanıma işlemleri gerçekleştirilebilir. Kişi tanıma problemi, son on yıllarda araştırmacıların çeşitli yöntemler kullanarak üzerinde durduğu popüler alanlardan birisi olmuştur. Araştırmacılar genel olarak, retina, parmak izi, ses gibi kişinin karakteristik özelliklerini kullanarak bu alanda çalışmaya başlamışlardır. Sinyal işleme yöntemleri kullanılarak elde edilen öznitelikler makine öğrenmesi algoritmasından yararlanılarak eğitilip sınıflandırma işlemleri yapılmaktadır.

Yüz, parmak izi, avuç içi baskısı ve ses tanıma teknikleri, kişisel tanımlamada başarıyla kullanılmasına rağmen, tek bir biyometrik özellik bazen bir kişinin kimliğini doğrulamak için yeterince kesin sonuçlar üretmeyebilmektedir. Tek bir sensörden tek bir görüşe dayanan kişisel tanımlama sistemleri, doğal bir zayıflığa sahiptir. Bu sistemler, insan

sayısı artıkça belirsizlik ile karşılaşma oranları artış göstermektedir. Çok modülü sistemler, tek modülü sistemlere göre daha iyi performans elde edebilir, çünkü farklı modüller tamamlayıcı bilgi sağlayabilmektedir. Örneğin, büyük bir nüfus arasında iki veya daha fazla insanın, özellikle ifade, ışık durumu ve konunun poz değişiklikleri nedeniyle görünüm değişiklikleri altında benzer yüzlere sahip olması muhtemeldir, ancak yürüyüş hareket ve mimikler için içine katıldığında benzer davranışlar sergilemedikleri tespit edilebilmektedir.

Giyilebilir sensör ağları, özellikle akıllı sağlık uygulamalarında insanların günlük yaşamlarını yeniden şekillendirmektedir (Fortino, 2013, Gravina vd. 2017). Bir vücut sensörü ağında, kalp atış hızı, sıcaklık ve aktivite gibi hayati belirtiler, giyilebilir bilgisayarlar tarafından sürekli olarak izlenebilir ve hem gerçek zamanlı sağlık yönetimi hem de uzun vadeli sağlık istatistikleri amacıyla kişisel cihazlar tarafından bulut altyapısına aktarılabilir. Hekim talimatlarına ve ilaç kaydına (Lounis vd. 2012) ağ üzerinden bireyler tarafından erişilebilir veya gönderilebilir. Bununla birlikte, akıllı sağlık sensörleri ve uygulamalarının artırılmasıyla birlikte, gizli biyotıp çözümlerini sağlamak, hassas hasta verilerini korumak vb. için artan güvenlik ve gizlilik gereksinimleri / zorlukları da vardır. Biyometrik tabanlı insan kimliği (ID), tanımak bu zorluğun üstesinden gelmeyi hedeflemektedir. Bireylere özgü ve kalıcılıktan yararlanan biyometrik özellikler, kimlik kartı ve kaybolan veya çalınabilecek kullanıcı adı / şifre çifti gibi geleneksel belirteç tabanlı ve bilgi tabanlı bireysel tanıma yöntemlerinden daha güvenilirdir (Unar vd. 2014).

Akıllı telefonlar ve giyilebilir cihazların hayatımıza kolaylık sağlamalarının en önemli nedenlerinden birisi de cihazların üzerinden hazır şekilde birden fazla sensörün bulunması ve bu sensörlerin elde edilen verilerin çeşitli uygulamalarda kullanılmasıdır (Bayat vd. 2014). İvmeölçer, GPS, jiroskop, kamera ve dijital pusula gibi güçlü sensörler sayesinde giyilebilir cihaz kullanıcılarına hesaplama, algılama, çeşitli uygulamaları yürütme gibi alanlarda işlem yapabilme fırsatı sunmaktadır. Giyilebilir cihazlar, bireyin sergilemekte olduğu vücut hareketlerini takip edip kaydeden ve bu verileri daha sonra kişinin sağlık durumu ve fiziksel aktivitelerini değerlendirmek için işlenmesine olanak veren ve üzerinde sensörler bulunan akıllı saat, bileklik, sağlık kolyeleri gibi cihazlardır. (Siirtola vd. 2012, Siirtola ve Röning, 2012). Birçok alanda kullanılmasının artmasından

dolayı, bu cihazların sayesinde birçok alanda, bu sensörlerden elde edilen veriler kullanılarak çalışmalar yapılmıştır.

Thang ve arkadaşları tarafından yapılan çalışmada kullanıcıların kimlik doğrulamasını sağlamak amacıyla akıllı telefonun ivmeölçer sensörü kullanılırken (Thang vd. 2012), Zhong ve arkadaşlarının çalışmasında ise akıllı telefonlarda entegre halinden bulunan ivme ölçer jiroskop sensörlerinden yararlanmıştır (Zhong ve Deng, 2014). Yürüyüş biyometrisinden kullanıcıların doğrulamasını sağlamak için yapılan çalışmada giyilebilir cihazlar üzerindeki sensörlerden elde edilen verilerden yararlanılmıştır (Zhong ve Deng, 2014, Zhang vd. 2014).

Weiss ve arkadaşlarının çalışmasında telefonun dahili ivmeölçer sensörü kullanılarak toplanan verilerin işlenmesi ile cinsiyet, boy ve kilo gibi fiziksel özniteliklerin tahmini 43 istatistiksel özellik kullanılarak yapılmıştır. (Weiss ve Lockhart, 2011).

Kuncan ve arkadaşları tarafından yapılan çalışmada; fiziksel hareketlerin sergilenmesi sonucu elde edilen sinyallerden yararlanarak öznitelik çıkarma işlemi gerçekleştirilmiş ve bunun sonucunda elde edilen öznitelikler ile sensör sinyallerine dayalı bir kişinin cinsiyet tanıma işlemi oluşturulmuştur. Başarı oranları benzer amaç için yapılan çalışmalar ile kıyaslandığında, daha önceki cinsiyet tanıma modellerine, insanların fiziksel aktivitelerinden elde edilen sinyallerin de kişinin cinsiyet tanımada etkili olduğunu göstermiştir (Kuncan vd. 2019).

Mobil cihazlardaki sensörler yardımı ile verilerin elde edilmesi ve toplanan verilerin işlenmesi çeşitli aşamalardan geçerek gerçekleşmektedir; bu sürecin sıralaması ise ilk olarak verilerin toplanması, toplanan verilerin belirli bir ön işleminden geçmesi, elde edilen özniteliklerin değerlendirilmesi ve son olarak öznitelik çıkarılıp sınıflandırma işleminin yapılmasıdır. Sensörler yardımıyla ham verilerin elde edilmesi sürecin ilk aşamasını oluşturmaktadır.

Ham verilerin toplanması sürecinde, aktiviteyi sergileyecek kişilerin hangi aktiviteyi yaptığı detaylı olarak belirtilerek sisteme kaydedilmelidir. İvmeölçer aracılığı ile ham veri elde edilirken yüksek ve düşük boyutlu sinyaller gelmektedir; yüksek boyutlu frekansa sahip sinyaller kişinin aktiviteyi sergilerken oluşan sinyaller olmakta iken düşük

boyutlu frekanslara sahip olan sinyaller ise yerçekiminden kaynaklanmaktadır (Ravi vd. 2005). Verinin ön işleme süreci bu nedenden dolayı önem kazanmaktadır.

Veri ön işleme aşamasında hangi sinyallerin kişinin sergilediği harekete ait olduğu ve hangi sinyallerin dış etkenlerden kaynaklandığı doğru bir şekilde tespit edilmelidir. Ön işlemedeki bu ayrım için genellikle yüksek geçir genlikli filtreler kullanılmaktadır ve yapılan çalışmaların çoğunda veri öznelik çıkarmadan önce kayan pencereler yönteminden yararlanılmıştır. Bu metodun kullanılmasının amacı ise ham verilerden gelen daha küçük sinyallere bölerek, sürekli gelen büyük veri parçalarının ayırt edilmesini sağlamaktır. Küçük boyutlara bölünmüş sinyallerden öznelik çıkarma işlemi, tüm veriler kullanılarak öznelik çıkarmaya göre daha başarılı sonuçlar çıkarılmasını sağladığından ve daha kolay olmasından dolayı bu yöntem etkili olmaktadır (Ravi vd.2005).

Hayatımıza yıllar önce giren gün geçtikçe kullanılması artan akıllı telefonlar, sadece iletişim sağlamamakta olup birçok alandan faydalı olmaktadır (Lee vd. 2006). Günümüzde iletişim teknolojisinin gelişmesi ile birlikte, farklı marka ve modellerde çeşitli akıllı telefonlar ve bu cihazların kullandığı farklı işletim sistemleri mevcuttur. Kullanılan işletim sistemlerine göre sıralaması yapılırken en çok kullanılan akıllı telefon işletim sistemi %85'lik oran ile Android, %14,1 ile İos ve %0,3 ile Windows Phone olarak görülmektedir (Permin vd. 2019). Haberleşme, akıllı telefonların günümüzde kullanım amaçlarından sadece biri olmuştur. Bu cihazların hayatımızda önemli bir rol üstlenmesinin nedenleri arasında cihazlarda bulunan sensörler ve bunlardan elde edilen verilerin işlenmesi ile çalışan uygulamaların insanlara kolaylık sağlamasıdır (Bayat vd. 2014).

Günümüzdeki akıllı telefonların büyük çoğunluğunda GPS, manyetometre, ivme ölçer gibi sensörler dahili olarak bulunmaktadır (Permin vd. 2019). İvmeölçer, GPS, jiroskop, kamera ve dijital pusula gibi güçlü sensörler sayesinde akıllı telefonlar kullanıcılarına hesaplama, algılama, çeşitli uygulamaları yürütme gibi alanlarda işlem yapabilme fırsatı sunmaktadır (Quiad ve Jalal, 2019).

Akıllı telefonların kullanılmasının yaygınlaşması ve insanlara sağladığı yaralardan sonra bu sensörler giyilebilir sensör ürünleri olarak da yaygın olarak piyasaya çıkmaya

kullanılmaya başlanmıştır. Giyilebilir cihazlar olarak adlandırılan üzerinde manyometre, jiroskop, ivmeölçer gibi birçok sensör bulundurmaları sayesinde fiziksel davranışlarını ve sağlık durumlarının takip edilip izlenmesine imkân vermektedir (Siirtola ve Rönning, 2012).

Mobil cihazlardaki sensörler yardımı ile verilerin elde edilmesi ve toplanan verilerin işlenmesi çeşitli aşamalardan geçerek gerçekleşmektedir; bu sürecin sıralaması ile ilk olarak verilerin toplanması, toplanan verilerin belirli bir ön işleminden geçmesi, elde edilen özniteliklerin değerlendirilmesi ve son olarak öznitelik çıkarılıp sınıflandırma işleminin yapılmasıdır. Sensörler yardımıyla ham verilerin elde edilmesi sürecin ilk aşamasını oluşturmaktadır. Ham verilerin toplanması sürecinde, aktiviteyi sergileyecek kişilerin hangi aktiviteyi yaptığı detaylı olarak belirtilerek sisteme kaydedilmelidir. İvmeölçer aracılığı ile ham veri elde edilirken yüksek ve düşük boyutlu sinyaller gelmektedir; yüksek boyutlu frekansa sahip sinyaller kişinin aktiviteyi sergilerken oluşan sinyaller olmakta iken düşük boyutlu frekanslara sahip olan sinyaller ise yerçekiminden kaynaklanmaktadır (Ravi vd. 2005).

Verinin ön işleme süreci bu nedenden dolayı önem kazanmaktadır. Veri ön işleme aşamasında hangi sinyallerin kişinin sergilediği harekete ait olduğu ve hangi sinyallerin dış etkenlerden kaynaklandığı doğru bir şekilde tespit edilmelidir. Ön işlemedeki bu ayırım için genellikle yüksek geçir genlikli filtreler kullanılmaktadır ve yapılan çalışmaların çoğunda veri öznitelik çıkarmadan önce kayan pencereler yönteminden yararlanılmıştır. Bu metodun kullanılmasının amacı ise ham verilerden gelen daha küçük sinyallere bölerek, sürekli gelen büyük veri parçalarının ayırt edilmesini sağlamaktır. Küçük boyutlara bölünmüş sinyallerden öznitelik çıkarmak, tüm veriden öznitelik çıkarmaya göre daha başarılı sonuçlar çıkarılmasını sağladığından ve daha kolay olmasından dolayı bu yöntem etkili olmaktadır (Ravi vd.2005).

1.2 Tezin Amacı

Bu çalışmada açam giyilebilirsensör işaretlerinden kişi tespiti gerçekleştirmektir. İşaretler kişilerin farklı aktivilerine göre elde edilmiştir. Bu amaçla kişi tanıma için iki farklı

yaklaşım önerilmiştir. Birinci yaklaşımın ile öznitelik çıkarım işleminin önemi üzerinde durulurken, ikinci yaklaşımda derin öğrenme yöntemlerinin KT’da etkinliği ortaya konulmuştur.

- Çalışma kapsamında, 4 bay ve 4 bayan katılımcının seçilerek cinsiyet dağılımının eşit şekilde ve yaş dağılımının rasgele seçildiği veri setinden yararlanılmıştır.
- Öznitelik seçimi aşamasında birden fazla öznitelik çıkartılarak sonuçlar irdelenmiş ve karşılaştırılması yapılmıştır.
- Daha önce yapılan çalışmalara da genel olarak manyetometre, jiroskop ve ivemeölçer sensörler kişinin sergilediği hareket sınıflandırması işleminde yaygın olarak kullanılmış olup bizim çalışmamızda buna ek olarak literatürde ilk olarak kişinin tespiti işlemi de yapılmıştır. Ayrıca, her bir bölgeye yerleştirilen sensörlerin kişi aktivitesini tanıma ve kişi tanıma problemine katkısı da literatürde ilk olarak yapılmıştır.
- Makine öğrenmesinin son yıllarda popüler olan alanlarından, derin öğrenme transfer yöntemleri düzenlenmiş ve performansları karşılaştırılmıştır.

1.3 Tez Kapsamında Yapılan Çalışmalar

Yaptığımız bu çalışmada önce veri setinden elde edilen sensör sinyalleri aracılığı ile kişilerin sunduğu hareketler ve bu hareketlerin tespiti olmuştur. Bu açıdan olaya baktığımızda şu ana kadar mevcut çalışmalar kişinin gösterdiği hareketleri sınıflandırmak ve tespit etmek üzerinde olmaktadır. Biz bu çalışma kapsamında, öncelikle hareketleri sınıflandırıp daha sonrasında kişi tespitini de sınıflandırmış bulunmaktayız. Yöntem olarak seçtiğimiz transfer derin öğrenme yöntemleri aracılığı ile sensör sinyallerinden kişi tespiti literatürde ilk olarak yer almaktadır.

Çalışma kapsamında ilk olarak öznitelik çıkarma işlemleri yapılmıştır. Sensör sinyalleri aracılığı ile elde edilen verilerin kişi tespitinde başarılı olup olmadığını tespit etmek amacı

ile özellikle ham verilerden öznitelik çıkarmak için iki boyutlu olarak görüntü işlemede yoğun olarak kullanılan “yerel ikili örüntü” yönteminin tek boyuta indirgenmesi ile oluşturulan bir yöntem geliştirilmiştir. Geliştirilen yöntem doğrultusunda veri seti ile denenmiş ve sonuçları sunulmuştur.

- Çalışmamızın etkinliğini değerlendirmek amacı ile 4 bay ve 4 bayanın manyetometre, jiroskop ve ivmeölçer sensörlerin bulunduğu giyilebilir cihaz ile sergilediği veri seti seçilmiştir.
- Öznitelik çıkarma işleminin problemimizin çözümüne ne derecede katkı sağlayacağını bulmak için LBP yöntemi geliştirilmiş ve başarısı test edilmiştir.
- Literatürce yaygın olarak kullanılan makine öğrenme yöntemleri çıkardığımız öznitelikler ile denemiştir.
- Bahsi geçen sensörlerden elde edilen sinyaller işlenerek, gerçekleştirdiğimiz yöntemleri ile kişinin tespiti ve kişinin sergilediği hareketlerin tespiti işlemleri yapılmıştır. Sensörlerin yerleştirildiği bölgeye göre başarıları da karşılaştırılmış olup etkinliği hesaplanmıştır. Sensörlerden elde edilen veriler aracılığıyla kişi tespiti işlemi ilk defa yapılmıştır.
- Sıklıkla kullanılan, derin öğrenme transfer yöntemleri düzenlenmiş ve performansları karşılaştırılmıştır.

1.4 Tezin Özgün Değeri

Mevcut literatür analiz ettiğimizde giyilebilir sensörlerden elde edilmiş veriler ile fiziksel aktivite tanımlama yapılmış ancak kişi tanıma problemine değinilmemiştir. Fiziksel hareketleri tanıma işlemi ise sadece klasik makine öğrenmesi yöntemleri kullanılarak gerçekleştirilmeye çalışılmıştır. Ek olarak, giyilebilir sensörlerde bulunan her bir sensör için sınıflandırma yapılan çalışmalar literatürde yer almaktadır. Ayrıca, sensör sayısını ve çeşidini artırarak elde edilecek veriler sayesinde tanıma işleminin gerçekleşmesi de mümkündür. Yaptığımız çalışmada giyilebilir sensörler ivmeölçer, jiroskop ve

manyetometre sensörlerine sahiptir ve biz bu sensörlerden elde edilen bilgiler aracılığı ile hem fiziksel aktivitenin tanınması hem de aktiviteyi gerçekleştiren kişinin tanınması sağlanmıştır. Çalışma kapsamında birbirinden farklı 19 temel fiziksel aktivite seçilmiştir.

Yaptığımız çalışmasının özgünlük değerleri aşağıda listelenmiştir:

- İvmeölçer, manyetometre ve jiroskop sensörlerinden aynı anda elde edilen veriler çalışmamızda kullanılmış olup verilerin kombinasyonu aracılığıyla da başarı elde edilmiştir.
- Veri setinden elde edilen bilgiler doğrultusunda sınıflandırma işlemleri için hem yerel ikili örüntüler hem de transfer derin öğrenme ağları tasarlanmış ve problemimizin çözümü için başarı oranları tespit edilmiştir.
- Sensörlerin vücuda yerleştirildiği bölgeye göre kişi tanıma ve fiziksel aktivitenin tanımlanması da yapılmış olup insan vücudunun hangi bölgelerinden gelen hareketlerin tanımlama için daha başarılı olduğu bulunmuştur.

2. BİYOMETRİ KİŞİ TANIMA PROBLEMİ

Biyometri, kişileri tanımak için otomatik bir araç olarak, insanların diğer insanları mükemmel bir şekilde tanınma sürecini taklit etmeyi amaçlamaktadır.

İnsanın tanıdık bir yüzü, sesi, yürüme biçimi ve bir kişiyi tanıma yeteneği başlangıçta gözlemlenen özne hakkında bazı özellikleri yakalayıp depolayan ve ihtiyaç durumunda kabul edilebilir bir sürede geri çağıran saf bir zihinsel örüntü tanıma sürecidir. Biyometri, kişi tanımlamada daha da ileri gitmiştir; sadece tanımlama sürecini hızlandırmakla kalmamış, aynı zamanda insan tanıma tarafından kendi imkânları ile tanımada başarısız olduğu iris, damarlar ve EEG gibi bazı yeni modalitelerde de tanımlama imkânı sunmaktadır. Verimlilik, hız ve çeşitlilik, insanları diğer kişileri kendi imkânları ile tanımaya kıyasla biyometrinin en önemli katma değerleridir.

Bu bölümde, biyometrinin temel kavramlarını tanıtlıyoruz. Biyometrik sistemlerin performans açısından nasıl değerlendirildiğini tartışmak için, bir biyometrik sistemin nasıl çalıştığına, klasik tanımlama sistemlerine neden verimli bir alternatif olduğuna dair kısa bir genel bakış dâhil olmak üzere, tanıma sürecinin ayrıntılı bir tanımını sunup en çok kullanılan yöntemleri karşılaştıracacağız. Son olarak, biyometrinin ilginç bir seçim olduğu bazı uygulamalardan alıntı yapıyoruz.

2.1 Tanım


Uluslararası Standardizasyon Organizasyonu (ISO), biyometri veya biyometrik tanıma terimini "bireylerin biyolojik ve davranışsal özelliklerine göre otomatik olarak tanınması" olarak tanımlamaktadır" (ISO / IEC2382-37, 2012).

Tanım, bireyleri tanımak için bir makine sistemi tarafından yürütülecek algoritmaların tasarımını ima etmek için "otomatik" kelimesini kullanır. Sistem daha iyi sonuçlar almak için bir insan tarafından desteklenebilir." Tanıma", bir kişiyi, vücut parçaları tarafından içsel olarak sergilenen bazı fiziksel özelliklere ve / veya vücut tarafından yaratılan bazı davranış özelliklerine dayalı olarak bir kişiyle ilişkilendirmeyi amaçlamaktadır. Bu

özelliklere "tanımlayıcılar" veya "özellikler" denir. Fiziksel özelliklerin örnekleri arasında şunlar yer alır: parmak izleri, yüz, iris, vb. öte yandan, davranış özelliklerine şunları: imza, ses, tuş vuruşu dinamikleri vb. örnek verebiliriz.

Bir bireyin kimliğini bildiklerine (şifreler gibi gizli bilgiler) ve / veya sahip olduklarına (jetonlar, akıllı kartlar, lisanslar gibi nesnelere sahip olma) dayalı olarak oluşturan klasik kimlik sistemlerinden farklı olarak; biyometrik sistemler kişinin ne olduğuna (biyolojik nitelikler) ve / veya ne yaptığına (davranışsal nitelikler) dayanır. Bu tanımlayıcılar doğrudan bireyle ilgilidir, bu nedenle unutulamaz, kopyalanamaz ve iletilemez.

Biyometrik sistemler parmak izi, yüz, kulak, iris, retina, avuç içi izi, damar, ses, imza, yürüyüş, koku gibi çeşitli biyometrik özelliklerden (veya çeşitlerinden) yararlanır. En önde gelen biyometrik sınıflandırma çeşitleri Şekil 2.1'de listelenmiştir.



Şekil 2.1 Biyometrik Sınıflandırma Çeşitleri.

2.2 Biyometrik Özellikler Gereksinimleri

Biyometrik bir özellik (veya özellik), bir bireyin ayırt edilebilen ölçülebilir bir fiziksel veya davranışsal özelliğidir. Bir bireyin nasıl tanınacağını belirler. Pratik bir biyometrik sistem tasarlarırken önemli bir konu şu soruyu yanıtlamaktır: Sistem, bireysel kimlik hakkında karar vermek için hangi özellikleri kullanılmalıdır? Her biyometrik özelliğin kendi güçlü ve zayıf yönleri vardır, seçim tipik olarak uygulama alanına ve bazen tanımlanması amaçlanan popülasyona bağlıdır. Bazı durumlarda birden fazla özellik seçilir (Jain vd. 2007). Tipik bir biyometrik özelliklerin karşılaması gereken bazı gereksinimleri belirlemiştir:

- **Evrensellik:** Uygulamaya erişen her birey bu özelliklere sahip olmalıdır. Örnek olarak, nüfusun çoğunun yazmadığı bir ortamda imzayı kullanamayacağımızdan, kör kişileri tanımlamak için iris özelliklerini kullanamayız.
- **Benzersizlik:** Temel özellikler, iki kişiyi ayırt edebilmek için bireyler arasında yeterince farklı olmalıdır.
- **Kalıcılık:** Biyometrik özellikler, en azından işletim tanıma sistemi süresine göre zamanla değişmeye dayanıklı olmalıdır. Zamanla önemli ölçüde değişen bir özellik, yararlı bir biyometrik değildir.
- **Ölçülebilirlik:** Biyometrik özellikler, bir makine tarafından daha fazla işlenebilmesi için nicel olarak ölçülebilir olmalıdır. Makineye bağlanan uygun cihazlar, daha sonra tanıma sistemine aktarılacak biyometrik özelliği elde etmek ve sayısallaştırmak için kullanılabilir.
 - **Performans:** Biyometrik özellikleri kullanan uygulama, kabul edilebilir düzeyde performans sağlamalıdır. Bu, eşleşen doğruluğu / zamanı ve genel tanıma sistemini oluşturmak için ayrılan kaynakları içerir.
 - **Kabul edilebilirlik:** Bu, bu özellikleri kullanarak tanımlanması amaçlanan kişilerin ne kadarının biyometriklerini sunarak sistemle iş birliği yapmaya istekli olduğunu gösterir.
 - **Atlatma:** Sistemin sağlamlığını ölçer; Sistemin doğru kararlar alıp biyometrik verilerin doğru bir şekilde işlendiğini gösterir.

Tüm gereksinimleri karşılayan tek bir biyometrik özellik bulmak zordur. Pratik bir biyometrik sistem, makul kaynak gereksinimleri ile kabul edilebilir bir tanıma doğruluğuna ve hızına sahip olmalı, kullanıcılar için zararsız, hedeflenen nüfus tarafından kabul edilmiş ve çeşitli hileli saldırılara karşı yeterince sağlam olmalıdır (Maltoni vd. 2009).

2.3 Biyometrik Sistem Mimarisi

Tipik bir biyometrik sistem, dört ana modülden meydana gelmektedir. Bunlar detaylı bir şekilde verilmiştir.

- **Biyometrik sensör:** Biyometrik konudan biyometrik özelliklerin yakalanmasından ve sonraki modüle aktarılacak üzere dijital bir forma dönüştürülmesinden sorumludur. Genel sürecin performansı, büyük ölçüde elde edilen ham verilerin kalitesine bağlıdır. Aslında, bu veriler, gerçek bir sürekli fenomeni (bir yüz gibi) dijital bir sağduyulu forma (yüz görüntüsü) dönüştürerek veri kaybına neden olur. Elde edilen verilerin kalitesi, okuyucunun teknolojisine, eklenen gürültüye ve kullanıcının sistemle birlikte çalışabilirlik derecesine bağlıdır.
- **Kayıt:** Elde edilen ham veriler önce kalitesini artırmak için ön işleme tabi tutulur. Bundan sonra, biyometrik özellikleri verimli bir şekilde sürdüren "şablon" adı verilen kompakt bir temsil oluşturmak için çıkarıcı alt modülü tarafından bazı ilgili ayırt edici özellikler çıkarılır. Oluşturulan şablon daha sonra depolama sistemine gönderilir. Genel olarak, kayıt aşaması, biyometrik tanıma sisteminin çalışma ortamındaki gerçek kişilerin kimliklerini öğrenmesine izin verir.
- **Depolama sistemi:** Depolama sistemi, bir SGBD tarafından yönetilen büyük bir veri tabanı olabileceğinden, basit bir akıllı kartta basit bir dosya olabilir. Oluşturulan şablonla bağlantılı olarak bazı biyografik bilgiler (ad, şifreler, adres vb.) Saklanabilir. Her durumda, ilgilenilmesi gereken önemli faktör, depolanan şablonun güvenliğidir. Uzlaşmış bir şablon, gerçek bir tehdit oluşturan orijinal biyometrik özelliklerin yeniden yapılandırılmasına yardımcı olabilir.

- **Eşleştirme modülü:** İşletim aşamasında sistemden bir kişiyi tanımlaması istenir. Kayıt adımı olduğu gibi, çıkarıcı alt modülünü kullanarak ayırt edici özelliklerini çıkarmaya devam eder. Çıkarılan bu özelliklere sorgu özellikleri denir. Bundan sonra, depolanan şablon sorguyla karşılaştırılmak üzere iptal edilir. Karşılaştırma hem sorgu hem de şablon özelliklerinin aynı biyometrik konudan (kişiden) kaynaklandığını doğrulamayı amaçlamaktadır. Genel olarak, karşılaştırma sonucu, sistemin kullanıcının kimliği hakkında uygun kararı almasına izin veren, 0 (toplam uyumsuzluk) ile 1 (mükemmel eşleşme) arasında değişen bir benzerlik derecesidir.

2.4 Sensör Sinyallerinden Kişi Tanıma İle İlgili Yapılan Çalışmalar

Sensör sinyallerinden elde edilen veriler insanların fizyolojik ve davranışsal özelliklerine göre elde edilmektedir. Zaman içinden sabit kalan çevreye göre değişmeyen özellikler fizyolojik olarak sınıflandırırken mekân ve zamana göre değişebilen özellikler davranışsal özellikler olarak sınıflandırılmaktadır. Son yıllarda yapılan biyometrik çalışmalar, bireylerin kişisel özellikleri olan göz retinası, yüz, parmak izi gibi fizyolojik özelliklere dayalı yada yürüme, koşma ve imza gibi davranışsal özellikleri temel alan araştırmalar olmuştur. Bununla birlikte, bu yöntemler taklit edilebileceklerinden dolayı büyük bir dezavantaja sahiptir (Matsumoto vd. 2002, Yu vd. 2009, Yu vd. 2009). Sesin taklidi, irisden kopyalanan lenslerin kullanımı ve yapay kılık bu sahtekârlıklara örnek olarak gösterilebilmektedir.

Bu yüzden son yıllarda kişinin farklı bölgelerinden ölçülen sinyallere dayalı kişinin davranışına veya biyometrik olarak adlandırılan özelliklere dayanan başka tanımlayıcı sistemler gerçekleştirilmiştir (Galbally vd. 2014, Rodrigues vd. 2016). Literatürü incelediğimizde, sensör sinyallerinden kişi tanımadan ziyade aktivite tanıma üzerinde problemler hakkında çalışma daha çok bulunmaktadır. Bizim çalışmamız aktivitelerden kişi tanıma olduğundan dolayı literatürde yer alan sensörler aracılığı ile aktivite tanımlarına yer verip kişi tanıma ile olan sınırlı sayıda ki çalışmalar hakkında da bilgi sunacağız.

Makine öğrenmesinin son yıllardaki popüler araştırma yöntemi olan derin öğrenme yöntemleri, araştırmacıya hem öznitelik çıkartma hem de sınıflandırma imkânı vermesinden dolayı bilimsel çalışmalarda yoğun olarak kullanılmaktadır. (Krizhevsky vd. 2012, Krizhevsky vd. 2012). Birçok alanda kullanılması ile birlikte insan hareketlerini tanıma işlemlerinde de derin öğrenme yöntemleri sıklıkla kullanılmaya başlanmıştır. Ji ve arkadaşları tarafından yapılmış olan çalışmada; insan hareketlerinin tanınması işlemlerinde derin öğrenme yöntemlerinden faydalanılmıştır. Yüzde 90,2'lik başarıya ulaşılan çalışmada, ham verilerden öznitelik çıkarma işlemini otomatik olarak yapan ve ham veri girişlerini direk işleme alınmasını sağlayan 3D-KSA modeli sunulmuştur (Ji vd. 2012).

Rahmani ve arkadaşları tarafından yapılmış olan çalışmada; insan hareketlerini tanımlama işler iriden sıklıkla karşılaşılan ve tespit edilemeyen açı problemleri üzerine yoğunlaşmış bu problemi gidermek için bir derin öğrenme yaklaşımı gerçekleştirilmiştir (Rahmani vd. 2017). Jaderbeg ise Simonyan ve arkadaşlarının yaptığı çalışmayı inceleyip, video görüntülerin kullanılarak insan hareketlerinin tespiti için kullanılan makine öğrenmesi yöntemlerini incelemiştir (Jaderberg vd. 2015).

Zhu ve arkadaşları tarafından yapılan çalışmada, derin transfer öğrenme yöntemlerinin insanın günlük hayattaki hareketlerinden elde edilen veriler aracılığı ile kişi tespitinden başarılı olup olmayacağı üzerinde çalışmalar yapmışlardır. Çalışma kapsamında bireylerin kahve içme hareketinden yola çıkarak kişi tespiti yapmaya çalışmışlardır ve kişi tespiti için derin transfer yaklaşımlarının daha önceki çalışmalara göre daha başarılı olduğu sonucuna ulaşmışlardır (Zhu vd. 2020).

Suppes'un 2009 yılında yaptığı çalışmaya göre insanların yalnızca yürüyüşlerine dayanarak belirli bir mesafeden insanların tanıma kabiliyetine sahip olunabileceği savunulmuştur ve bunun için bir model geliştirilmiştir. Çalışma sonucunda örneklem sayısı artırılması ve 500'e ulaşılması ile birlikte %85 oranında başarı görülmüştür. Bunun sonucunda yazar, kişi tanıma işlemlerinden yürüme eyleminin kişi tanımda karakteristik bir özellik olacağını savunmaktadır (Suppes, 2009).

Zhang ve arkadaşları tarafından 2016 yılında yapılan çalışmada WIFI-ID ismi ile geliştirdikleri sistem sayesinde insan aktivitelerinden kişi tanıma işlemini

gerçekleştirmişlerdir. Kişi tanıma işlemi sonucunda %77 ile %93 arasında sonuçlar elde edilmiştir. Bu sonuçlardan sonra araştırmacılar kişi aktivitelerinin biyometrik karakteristik ayırt edici özellik olarak kullanılabileceğini savunmaktadırlar (Zhang vd. 2014).

Gümüşcü tarafından yapılan çalışmada, insanların günlük hayatta sergiledikleri en sık hareketlerinden biri olan ve biyolojik ayırt edilebilir karakteristik özelliğe sahip olmasından dolayı yürüyüşten kişi tanıma problem üzerine yoğunlaşmıştır. 9 erkek ve 7 kadın tarafından her yürüyüşün üçer defa tekrar edilip kayıt altına alınması ile oluşturulan veriler ile KNN algoritması kullanılarak kişi tespiti gerçekleştirilmiştir. Elde ettikleri başarı oranı %97,9 oranına ulaşmıştır (Gümüşcü, 2019).

Çalışmalara bakıldığında farklı medikal sinyaller de biyometrik veri olarak kullanılmıştır. EEG (Marcel ve Millán, 2007, Dai vd. 2015, Rodrigues vd. 2016, Sun vd. 2019), EKG (Sun vd. 2005) (Irvine ve Cheng, 2005, Deng vd. 2018) (Goshvarpour ve Goshvarpour, 2019, Su, 2019) (Sufi ve Khalil, 2011, Chang vd. 2002), ivmeölçer (San-Segundo vd. 2016, San-Segundo vd. 2017) gibi sinyaller biyometrik sistemlerin geliştirilmesinde kullanılmıştır. Medikal sinyallerin kişiye özgü olduklarına dair çalışmalar gerçekleştirilmiştir (Dai vd. 2015, Boulgouris vd. 2009, Israel vd. 2005).

Alyasseri ve arkadaşlarının (Alyasseri vd. 2020) çalışmasında çok kanallı EEG sinyalleri kullanılarak kişi tanıma gerçekleştirilmiştir. Çalışmada ayrıca etkin EEG kanalları tespit edilmiştir. EEG sinyallerini kullanarak Sun ve arkadaşlarının yaptıkları çalışmada da kişi tanıma işlemi gerçekleştirilmiştir (Sun vd. 2019). 16 kanallı EEG sinyallerine geleneksel 1D-LSTM derin öğrenme yöntemini uygulayarak %99,56 gibi bir başarı oranını rapor etmişlerdir. Rodrigues ve arkadaşları EEG sinyallerini kullanarak kişi tanıma için gerçekleştirdikleri çalışmada %87 gibi bir başarı oranını rapor etmişler (Rodrigues vd. 2016).

Altan ve arkadaşları ECG sinyalleri kullanarak biyometrik bir sistem geliştirmişlerdir (Altan vd. 2019). İnsanların genel fiziksel durumu, stres seviyesi, aktivite seviyesi ve daha fazla spesifikasyonu ECG'deki dalgaları önemli ölçüde değiştirebilir. Dalga formları ve bununla birlikte zamansal özellikler her zaman farklı kişiler üzerinde farklı özelliklere sahip olduklarını göstermişlerdir (Altan vd. 2019). Diğer bir çalışmada

yazarlar ECG sinyalleri içindeki kardiyak dinamiklerini öznetelik olarak RBF ile kullanılarak kişi tanıma işlemi gerçekleştirmişlerdir (Deng vd. 2018). ECG sinyallerinin zamansal ilişkileri ve şekillerinin her birey için birbirinden farklı olduklarını ortaya koyarak biyometrik bir bilgi olarak kullanılabileceğini göstermişlerdir.

Lie ve arkadaşlarının yaptıkları çalışmada PhysioNet veri tabanından aldıkları beş ECG veri seti aracılığı ile evrişimsel sinir ağları (CNN) kullanılarak kişi tanıma gerçekleştirilmiştir (Li vd. 2017). Ortalama başarı oranını %94,3 olarak rapor etmişlerdir.

Goshvarpour ve Goshvarpour yaptıkları çalışmada ECG sinyallerinin MP (matching pursuit) katsayılarını PNN, Knn, LDA gibi farklı makine öğrenmesi yöntemler ile kullanarak biyometrik bir sistem geliştirmişlerdir. Sistemin başarısını %99,68 olarak rapor etmişlerdir (Goshvarpour ve Goshvarpour, 2019). Bir diğer çalışmada bir zeminde yürütülen kişilerin yere yapılan basınç sinyallerini değerlendirilerek kişi tanıma işlemi gerçekleştirilmiştir (Suutala ve Röning, 2016). Belirtilen çalışmada %92 başarı oranı gözlenmiştir.

Kişi tanımda ivmeölçer sinyalleri de kullanılmıştır. San-Segundo ve arkadaşlarının yaptıkları çalışmada akıllı telefonlarının ivmeölçer sensörlerinden aldıkları sinyaller üzerinden biyometrik bir sistem geliştirdiler (San-Sengundo vd. 2016). Kişileri yürüterek elde ettikleri sinyallere Gauss karışımı modelleri uygulayarak kişi tanıma işlemi gerçekleştirmişlerdir. Aynı yazarlara ait diğer bir çalışmada aynı veri seti üzerinde i-vector analizi ve PLDA tabanlı bir yaklaşım önererek kişi tanıma işlemi gerçekleştirilmiştir (San-Segundo vd. 2017).

Wilaiprasitporn ve arkadaşlarının 2019 yılında yaptığı çalışmada, EEG tabanlı KT sistemlerinin genel olarak bir kişi motor kontrolü gibi zihinsel bir görevi yerine getirirken elde edilen sinyallerden yapılığını ama kişinin duyuşsal bir eylemi yerine getirirken elde edilen sinyaller aracılığı ile de KT işleminin yapılabileceği üzerinde durmuşlardır. Derin öğrenme yaklaşımı kullanarak duyuşsal EEG tabanlı KT sisteminin performansını ölçmüşlerdir. Yazarlar çalışmasında, “Evrişimsel Sinir Ağları (CNN'ler)” ve “Tekrarlayan Sinir Ağları (RNN'ler)” kombinasyonunu kullanarak bir derin öğrenme kademesi önermişlerdir. CNN'ler, EEG'den uzamsal bilgileri işlemek için kullanılırken, RNN'ler zamansal bilgileri çıkarır. “Uzun Kısa Süreli Bellek (LSTM)” ve Kapılı

Tekrarlayan Birim (GRU) olmak üzere iki tür RNN'yi değerlendirilmiştir. Önerilen yöntem, en son teknolojiye sahip duyuşsal veri kümesi DEAP üzerinde değerlendirilmiştir. Sonuçlar, CNN-GRU ve CNN-LSTM'nin farklı duyuşsal durumlardan KT gerçekleştirebildiğini ve %99,90-100'e kadar ortalama doğru tanıma oranına ulaşabildiğini göstermektedir (Wilaiprasitporn, T vd. 2019).

Zhang ve arkadaşları tarafından 2018 yılında yapılan çalışmada, yüksek doğruluk ve sağlam performans elde etmek amacıyla EEG tabanlı bir biyometrik tanımlama yaklaşımı olan MindID'yi önermişlerdir. İlk olarak, EEG veri kalıpları analiz edilmiş ve sonuçlar Delta kalıbının kullanıcı tanımlaması için en ayırt edici bilgiyi içerdiğini göstermiştir. Daha sonra, ayrıştırılmış Delta sinyalleri, önemlerine göre farklı EEG kanallarına değişen dikkat ağırlıkları atayan, dikkat tabanlı bir Kodlayıcı-Dekoder RNN'leri (Tekrarlayan Sinir Ağları) beslemiştir. Dikkate dayalı RNN'den öğrenilen ayırt edici temsiller, kullanıcıyı bir hızlandırıcı sınıflandırıcı aracılığıyla tanımlamak için kullanılmıştır. Önerilen yaklaşım 3 veri seti (iki yerel ve bir genel) üzerinden değerlendirilmiştir. Performans değerlendirmesi için bir yerel veri seti (EID-M) kullanılmış ve sonuçlar, modelin %98,2 doğruluk elde ettiğini belirtmişlerdir. Modelin sağlamlığını ve uyarılabilirliğini göstermek için ikinci yerel veri kümesi (EID-S) ve bir genel veri kümesi (EEG-S) kullanılmıştır. Sonuçlar, önerilen yaklaşımın pratik ortamlarda yaygın olarak uygulanma potansiyeline sahip olduğunu göstermektedir (Zhang vd. 2018).

Sun ve arkadaşlarının 2019 yılında yaptığı çalışmada, 1 boyutlu evrişimli LSTM sinir ağını kullanan yeni bir EEG tabanlı kimlik doğrulama sistemi önermişlerdir. Önerilen 1D-Evrişimsel LSTM'nin CNN ve LSTM kimlik doğrulama sistemlerine karşı performansını değerlendirmek için, halka açık bir veri tabanı kullanılarak 109 denneğin EEG verileriyle karşılaştırmalı bir çalışma yapılmıştır. 16 kanallı 1D-Convolutional LSTM kimlik doğrulama sisteminin Rank-1 doğruluğu ve EER'si sırasıyla %99,58 ve %0,41'dir ve bu, literatürdeki son teknoloji EEG tabanlı kimlik doğrulama sistemlerinden daha iyi performans gösterdiğinin ispatıdır. DeneySEL sonuçlar, 1D-Evrişimsel LSTM'nin, farklı konuları ayırt etmek için ek özellikler sağlayarak, EEG kanallarında bulunan uzamsal bilgilerden yararlanabileceğini göstermektedir. Ek olarak, 1D-Convolutional LSTM ile benzer performans elde etmek için daha az sayıda elektrot kullanılabilir

olduğunu ve bu da EEG tabanlı biyometrik kimlik doğrulama sistemlerinin maliyetini önemli ölçüde azaltılabileceği üzerinde durulmuştur (Sun vd. 2019).

Monsy ve Vinod tarafından 2020 yılında yapılan çalışmada, frekans ağırlıklı güç (FWP) adı verilen ve son teknoloji EEG özelliklerine kıyasla kişi tanımlamasında daha yüksek ayırım sunan yeni bir özellik kullanan EEG tabanlı bir biyometrik tanımlama tekniği önerilmiştir. FWP, belirli bir frekans bandının gücünün eşdeğer bir temsilidir, belirli frekansın karşılık gelen güç yoğunluğu değeriyle çarpılması ve belirli bir bant üzerinde toplanmasıyla elde edilir. Önerilen yöntemin etkinliği, çevrimiçi PhysioNet veri tabanından dinlenme durumu EEG'sinin yanı sıra deney sırasında laboratuvarında 16 denekten elde edilen dinlenme durumu EEG verileri kullanılarak doğrulanmıştır. Korelasyon tabanlı bir sınıflandırıcı kullanarak, önerilen yöntem, 20 elektrot kullanarak gözler kapalı dinlenme durumu EEG sinyallerinden 0,0039 eşit hata oranına (EER) ulaşır; bu, raporda bildirilen elektrot sayısı için literatür en iyi yöntemle elde edilen EER'nin yaklaşık beşte birine karşılık gelerek yöntemin başarısı ispatlanmıştır (Monsy ve Vinod, 2020).

Wang ve arkadaşları tarafından 2020 yılında yapılan çalışmada, farklı entropiye ve sürekli evrişim sinir ağı (CNN) sınıflandırıcısına sahip yeni bir EEG tabanlı tanımlama sistemi önerilmiştir. Önerilen yöntemin performansı, duygusal EEG verileri aracılığıyla deneysel olarak değerlendirilmiştir. Yürütülen deney, önerilen yöntemin ortalama olarak %99,7'lik doğruluğa (ACC) yaklaştığını ve DE-CNN modelini hızla eğitip güncelleyebildiğini göstermektedir. Daha sonra farklı duyguların etkileri ve farklı zaman aralıklarının tanımlama performansı üzerindeki etkisi araştırılmıştır. Elde edilen sonuçlar, negatif ve nötr duygu durum EEG'sinin pozitif duygulardan daha sağlam olduğu durumlarda, farklı duyguların tanımlama doğruluğunu etkilediğini göstermektedir. EEG uyarıcısı olarak bir video sinyali için, 0-75 Hz ile önerilen yöntemin tek bir banttan daha sağlam olduğu, 15-32 Hz bandının ise aşırıya kaçma gösterdiği ve çapraz duygu testinin doğruluğunu azalttığı bulunmuştur. Zaman aralığının doğruluğu azalttığı ve zayıflama açısından 15-32 Hz bandının en iyi uyumluluğa sahip olduğu sonucuna varılmıştır (Wang vd. 2020).

Mairona'nın yaptığı çalışmada, tıbbi değişkenleri tahmin ederek EKG sinyallerine dayalı kişisel bir biyometrik tanıma sistemi tasarlamayı amaçlamıştır. Önerilen EEG temsilleri ve ağ mimarileri, yaklaşık 20 saniye süren tanımlama oturumları için %96'dan daha büyük ve kayıttan itibaren bir yıldan daha uzun bir zaman aralığında alınan ilginç IR'ler elde etmeyi mümkün kılmıştır. Gerçekleştirilen zihinsel görev, bu nedenle, gerçek hayattaki pratik uygulamalarda dikkate alınan biyometrik modalitenin kullanımını motive eden sağlam bir temel sağlamaktadır. Gerçekleştirilen testler ayrıca, doğrudan ham verilerin kendileri yerine, elde edilen EEG verilerinden çıkarılan el yapımı özellikler üzerinden CNN'lerin ve RNN'lerin eğitiminin yararlılığını göstermiştir. Bu nedenle bu çalışma, hem sinir ağlarının girdileri olarak kullanılacak ayırt edici el yapımı özelliklerin tanımının araştırılmasının hem de tam olarak yararlanmak için etkili bir şekilde eğitilebilecek yeni uçtan uca derin öğrenme yaklaşımlarının tasarlanmasının gerekliliğini vurgulamaktadır (Mairona 2020).

Sepahvand ve Abdali-Mohammadi tarafından yapılan çalışmada bir insan biyometri sistemi tasarlamak için çok uçlu EKG sinyallerindeki fonksiyonel ve yapısal bağımlılıkları analiz edilmesi amaçlanmıştır. Bu amaçla, genetik programlamada frekans bantları ve multi-CNN-geninin korelasyonu analiz edilerek hibrit bir öğrenme modeli ortaya konmuştur. Özellikle, iç korelasyon ve çapraz korelasyon, fonksiyonel bağımlılıkları tahmin etmek için ilk olarak çok uçlu EKG sinyallerinde belirlenmiştir. Daha sonra genişletilmiş komşuluk matrisleri olarak temsil edilmiştir. Çoklu CNN geni ayrıca genişletilmiş komşuluk matrisleri aracılığıyla yapısal bağımlılık bilgilerinin otomatik tahmini için genetik programlamaya dahil edilmiştir. Eğitim aşamasında çıkarılan fonksiyonel ve yapısal özelliklerin kapalı küme tanımlaması, daha sonra tamamen bağlı bir sinir ağına gönderilmiş ve kullanıcı kimliği tespit edilmiştir. Çıkarılan özellikleri karşılaştırmak için doğrulama aşamasında bir biyometrik eşleştirici kullanılmıştır. Deneysel sonuçlara göre, önerilen yöntem, PTB “(PTB Diagnostic ECG Database)” ve CYBHi “(Check Your Biosignals Here Initiative)” olarak adlandırılan iki iyi bilinen EKG veri seti üzerinde düzgün bir şekilde gerçekleştirilmiştir (Sepahvand ve Abdali-Mohammadi, 2021).

2.5 Fiziksel Aktivite Tanıma

İnsan organizması sürekli hareket etme eğiliminde olduğundan, yaşam koşullarıyla mücadele ederken, vücudunu koruyan ve olası zor durumlarda ihtiyaçlarını karşılayan bir yapı ile donatılarak oluşturulur (Çınar, 2012). Fiziksel aktivite kavramını açıklamak için yaptığımız literatür çalışmasında birden fazla tanım ile karşılaşılmıştır. En yaygın ve basit şekilde fiziksel aktivite tanımı olarak, enerjiden faydalanılarak vücudun hareket ettirilmesi işlemi olarak ifade edilebilir.

İnsanların mobil cihazları kullanmasının her geçtiğimiz gün artması ile birlikte, bu cihazlardan elde edilen veriler aracılığıyla insan fiziksel aktivitelerinin (FA) tanımlanması popüler bir konu olmuştur. Bu tanımlama işleminin otomatik olarak sağlanması ise güvenlikten sağlık sektörüne kadar birçok disipline fayda sağlamaktadır ve bundan dolayı insan fiziksel aktivite tanıma işlemleri bu disiplinlerin araştırma alanlarına girmiştir.

Fiziksel bilgiler, giyilebilir sensörler aracılığıyla elde edilebilir ve işlenebilirler. Ek olarak, cep telefonun sağlayacağı veriden daha fazla bilgiyi giyilebilir sensörler sayesinde elde edebiliriz (Seneviratne vd. 2017). İnsanlar FA gerçekleştirirken, sergilediği hareketin doğruluğu yaşam kalitesine pozitif etki sunmaktadır giyilebilir sensörler bu noktada insanlara katkı sağlamaktadır. Çocuklar ve yaşlılar FA sergiledikleri zaman bazen kaslarını yetersizliğinden dolayı hareketi yanlış sergileyebilmekte ve düşme tehlikesi ile karşı karşıya gelmektedirler bunun gibi durumlar da giyilebilir sensörler insanlara yardımcı olabilmektedir (Su vd. 2014). Bu cihazlardan elde edilen veriler sayesinde kişilerin gün içinde kaç adım attıkları, hangi fiziksel eylemleri gerçekleştirdiklerinin de ne kadar efor sarf ettikleri hesaplanabilmektedir. FA tanımla işlemlerinde geleneksel örüntü tanıma yöntemleri ciddi ölçüde başarı sağlamıştır (Bulling vd. 2014).

Geleneksel yöntemlerin başarılı olmasında rağmen, öznetelik çıkarma aşamasında alan bilgisi yeterli olan uzmanlara ihtiyaç duyulması en önemli dezavantajlarından birisi olmaktadır. Yürüme, koşma gibi daha basit düzeyde olan fiziksel aktivitelerin

tanımlanmasında işe yarayabilirken daha karmaşık hareketlerde geleneksel yöntemlerin de ötesine gidilerek yeni yaklaşımlar denenmemledir (Yang, 2009).

Derin öğrenme karmaşık problemlerde başarılı sonuçlar üretmesi ile ismini duyuran bir sistemdir ve FA probleminde de karmaşık yapılarda başarılı olabilmektedir ve literatürde geniş bir yelpazede çalışmalar bulunmaktadır (He vd. 2019, Ordóñez ve Roggen, 2016, Ha ve Choi, 2016).

He ve arkadaşları tarafından yapılan çalışmada UCI veri tabanında geleneksel insan fiziksel aktiviteleri veri seti ve bu verilerin zayıf etiketlenmiş halleri olmak üzere iki veri seti kullanarak tekrarlayan dikkat öğrenme modeli aracılığı ile FA tanımlama işlemi gerçekleştirmişlerdir (He vd. 2019).

Ordóñez ve Roggen ise yapıları çalışmada, FA tanıma işlemleri için evrişimli sinir ağlarında tekrarlayan sinir ağlarının kullanılması ile oluşturdukları DeepConvLSTM'yi önermiştir (Ordóñez ve Roggen, 2016). İvmeölçer (ACC – Accelerometer), Magnetometre (MAG) ve Jiroskop (GYR - Gyroscope) sensörleri FA ve birçok problemin çözümünden fayda sağlamıştır. Wang vd. tarafından yapılan çalışmada, ampirik mod ayırma yöntemi ile ACC’ den elde edilen 3 eksenli veriler aracılığı ile FA işlemi gerçekleştirilmiştir. Sensörler ayak bileği ve bele takılmış ve öznetelik çıkarmak için oyun teorisi yöntemi seçilmiştir. Sınıflandırma işlemleri için se geleneksel makine öğrenme yöntemlerinden en çok kullanılan “SVM (Destek Vektör Makinaları [Support Vector Machine])” ve “kNN (k En Yakın Komşu [k nearest neighbor])” seçilmiştir. Daha önceden tanımlanmış olan 9 farklı aktivitenin sınıflandırma işleminde ise yüzde 80 oranında başarı elde edilmiştir (Wang vd. 2016).

ACC sensörleri kullanılarak yapılan diğer bir çalışmada, Lv ve arkadaşları tarafından, yarı denetimli bir öğrenme yöntemi geliştirilerek insan FA tanıma işlemleri gerçekleştirilmiştir (Lv vd. 2018). Benzer şekilde ACC sensörlerinden yararlanan Fullerton ve arkadaşları, bu sensörleri insan vücudunun 9 farklı bölgesine takarak sinyalleri elde etmiş ve bu sinyalleri geleneksel makine öğrenme yöntemleri olan SWM ve KNN algoritmaları aracılığıyla işleyip sınıflandırma işlemini %97 başarı oranı ile gerçekleştirmişlerdir (Fullerton vd. 2017).

3. TEORİK BİLGİLER

Bu bölümde amaç çalışmamızda kullandığımız yöntemler, veri seti hakkında genel bilgiler sunmaktır. Kullanılan veri seti detaylı bir şekilde açıklanmış verilerin hangi işlemlerden geçtiği hakkında bilgiler verilmiştir. Ek olarak, problemimizin doğrultusunda çözüme gitmek için yararlanılan yöntemler hakkında kısa bilgilerde eklenmiştir. Buradaki amaç, literatürde bulunan bilgileri çok detaylı bir şekilde sunmak değil çalışma için kullanılan yöntem hakkında bilgi sahibi olunmasını sağlamaktır.

3.1 Veri Seti

Çalışmamızda oluşturduğumuz yöntemlerin başarısını doğrulamak amacıyla UCI veri tabanı aracılığıyla elde ettiğimiz “*Daily and Sports Activities Data Set*” veri seti kullanılmıştır (Altun ve Yüksek, 2010, Altun vd. 2010, Barshan ve Yüksek, 2014).


İnsanların belirlenen bölgelerine takılan sensörler aracılığıyla, daha önceden belirlenmiş 19 farklı harekete (aktive) ait veriler bu çalışma için oluşturulmuştur. Sensörler deneklerin 5 farklı bölgesine monte edilerek veriler toplanmıştır. Sensörlerin vücutta bulunduğu noktalar ise göğüs hizasında, sağ el bileğinde, sol el bileğinde, sağ (diz üstü) ve sol bacaklarında (diz üstü) olarak belirlenmiştir. Çalışmada kullanılan veri setindeki veriler elde edilirken önceden belirlenen 19 farklı hareketin 4 kadın 4 erkek tarafından sergilenmesi ile elde edilmiştir. Denekler 5 dakika boyunca belirlenen hareketleri sergilemişlerdir. Sergilenen 19 farklı hareket Çizelge 3.1’de verilmiştir.

Çizelge 3.1 Hareketlerin Simgesi ve Açıklaması.

Hareket Kodu	Hareket Adı
A1	“Oturma Hareketi”
A2	“Ayakta Durma Hareketi”
A3	“Sırt Üstü Yatma Hareketi”
A4	“Sağ Tarafa Yatma Hareketi”
A5	“Merdiven Çıkma Hareketi”
A6	“Merdiven İnme Hareketi”
A7	“Asansörde Ayakta Durma Hareketi”
A8	“Asansör Hareket Halindeyken Ayakta Durma Hareketi”
A9	“Otoparkta Yürüme Hareketi”
A10	“4km/S Hızla Yere Paralel Koşu Bandında Yürüyüş Hareketi”
A11	“4km/S Hızla Yere 15 Derecelik Açılışla Koşu Bandında Yürüyüş Hareketi”
A12	“8km / Saatlik Hızla Koşma Hareketi”
A13	“Step Egzersiz Yapma Hareketi”
A14	“Eliptik Bisiklet Hareketi”
A15	“Yatay Pozisyonda Bisiklet Sürme Hareketi”
A16	“Dikey Pozisyonda Bisiklet Sürme Hareketi”
A17	“Kürek Çekme Hareketi”
A18	“Sıçrama Hareketi”
A19	“Basketbol Oynama Hareketi”

Çalışmada veri toplamak amacı ile oluşturulan sensör birimleri üç eksenli jiroskop, ivmeölçer ve manyetometreden meydana gelmektedir. Her bir sensör ünitesi üç adet üç

eksenli cihaza sahip olduğundan dolayı toplam dokuz adet işaret kaydedilmektedir. Kaydedilen 9 işaret değer sırasıyla x,y,z eksenleri ivme (sensör ünitesi içinde yer alan ivmeölçer sayesinde), x,y,z eksenleri dönüş hızı (sensör ünitesi içinde yer alan jiroskop sayesinde) ve x,y,z eksenleri manyetik alan (sensör ünitesi içinde yer alan manyotemetre sayesinde) bilgileridir. Bu çalışmada kullanılan veriler, sensörlerin Şekli 3.1'deki gibi insanlara takılması sonucu elde edilmiştir.



Şekil 3.1 Sensörlerin İnsan Vücudunda Yerleştirildiği Bölgeler (Kılıç vd. 2020).

3.2 Sinyallerin Resime Dönüştürülmesi

Bu çalışmada sensör sinyallerini giriş verisi olarak kullandık. Geliştirdiğimiz sistem derin transfer öğrenme yöntemli bir sistem üzerine yoğunlaşmaktadır ve bu yüzden sensör sinyallerinden elde ettiğimiz 1D boyutlu verimizi 2D boyutlu matrislere dönüştürmüş bunların spektrektogramlarını çıkarmış bulunmaktayız.

Çıktı: Gri level 125*45 boyutlu resim (Im)

1: count =1;

2: **for** i=1 to 125 **do**

3: **for** j=1 to 45 **do**

4: $Im(i,j) = S(count)$;

5: count=count+1;


6: **end for** j;

7: **end for** i;

8: min maks normalizasyonu ile Im i normalize et

Yukarıdaki algorithmadan görüldüğü gibi, 1D ham sinyal 125×45 boyutlu görüntüye dönüştürülmüştür. Bunun sebebi, kullanılan veri kümesi metin dosyalarından oluşması ve her metin dosyası 125 satır ve 45 sütun içermesidir. Bu nedenle matris boyutu olarak 125×45 'i seçilmiştir. Bu aşamanın matematiksel açıklaması da Denklem 3.2.1' de gösterilmiştir ve sinyallerin resme dönüştürülmüş hali Şekil 3.2 de verilmiştir.

$$Im = \text{vec2mat}(S, [125 \times 45]) \quad (3.2.1)$$



Şekil 3.2 Sinyallerin Resme Dönüştürülmüş Hali.

3.3 Yerel İkili Örüntüler (YİÖ) Modeli

Yerel İkili Örüntüler (YİÖ), merkez piksel ile onu çevreleyen piksel (komşu pikseller) arasındaki yoğunluktaki yerel farklılıkları hesaplayarak görüntüden yerel özellikleri çıkarmak için geliştirilmiş istatistiksel bir yaklaşımdır. Yerel ikili modelin amacı, komşu pikseller ile merkez pikseli arasındaki farkları kullanarak farklı desenleri tespit etmektir. Desenler daha sonra tüm görüntüyü tanımlamak için bir araya getirilir. Sonuç olarak, LBP (Kaya vd. 2015) doku analizi, doku sınıflandırması (Ojala vd. 2002), tıbbi görüntü açıklama (Caputo, 2014), yüz tanıma (Ahonen, Hadid ve Pietikäinen, 2004), parmak izi tanımlama (Malathi ve Meena, 2010) ve tıbbi görüntü sınıflandırması (Nanni Lumini ve Brahnam, 2010) gibi muazzam uygulamalarda kullanılmıştır.


YİÖ operatörü iki boyutlu bir görüntüdeki pikselleri kendi etrafındaki pikseller ile karşılaştırarak örüntüler elde etmektedir. YİÖ operatörü, bir merkez piksel seçerek 3 x3 komşuluğun da (P_C) ve çevresindeki pikselleri (P_i) ($i = 0, 1, \dots, 7$) karşılaştırma işlemi sonucu her bir piksel için $S(f_p - f_c)$ değeri oluşturmaktadır (Kaya vd. 2014, Kaya vd. 2015).

Karşılaştırma sonucunda merkez piksel için ikilik tabanda yeni bir değer elde edilmektedir. İkilik tabanda elde edilen bu değer onluk tabana dönüştürülerek merkez piksel bu onluk değer ile etiketlenmektedir. Daha sonra tüm görüntüdeki her piksel tek

tek merkez piksel olarak kabul ederek tüm pikseller için yeni onluk etiketler oluşturulmaktadır. Anlatılan bu yerel ikili operatörü işleminin görsel süreci Şekil 3.3’de sunulmuştur. Denklem 3.3.1’ de resim üzerindeki her pikselin merkez piksel kabul edilmesi le komşuları arasındaki korelasyon sonucu elde edilen YİÖ değerlerinin hesaplanması işlemini matematiksel olarak ifade edilmiştir (Kahadiri vd. 2018).

$$YİÖ_{P,R}(x_c) = \sum_{p=0}^{P-1} \mu(x_p - x_c)2^p, \quad \mu(y) = \begin{cases} 1, y \geq 0 \text{ ise} \\ 0, y < 0 \text{ ise} \end{cases} \quad (3.3.1)$$

YİÖ_{P,R} biçimindeki operatörde, R yarıçapı komşu piksellerin merkez piksel ile arasındaki uzaklığını temsil ederken, P ise işleme alınan komşu piksel sayısını belirtmektedir (Lui vd. 2012). Şekil 3.3’deki örnekte R yarıçap bir(1) alınırken, komşu sayısı P ise sekiz(8) alınmıştır.




Şekil 3.3 YİÖ etiketlerinin oluşturulması.

Görüntülerdeki yüzeylerinin büyük bir kısmı uniform örüntülerden oluşmaktadır. İkili YİÖ kodunda 0’dan 1’e veya 1’den 0’a geçiş sayısı 2 veya daha az ise bu örüntüler uniform örüntülerdir. İkili kodunda 00000000 ve 11111111 örüntülerinde 0 geçiş sayısı, 01100000 ve 11000011 örüntülerinde 2 geçiş sayısı olduğundan bu örüntüler uniform örüntülerdir. Uniform örüntüler kullanılarak bir görüntüdeki kenar, spot, köşe gibi genel basit dokular belirlenebilmektedir. Bir görüntüde $(P-1)P+2$ sayısı kadar uniform örüntü vardır (Kaya vd. 2015, Smolka vd. 2015, Lumn vd. 2017).

3.3.1 Bir boyutlu yerel ikili örüntü

Bu çalışmada ham işaretlerden öznitelik çıkarmak için genel olarak iki boyutlu olarak görüntü işlemede yoğun olarak kullanılan yerel ikili örüntü yönteminin tek boyuta indirgenmesi ile oluşturulan bir yöntem geliştirilmiştir (Banan vd. 2020). 1D-LBP yöntemi çeşitli çalışmalar da sinyalleri sınıflandırmak için kullanılmıştır (Banan vd. 2020, Fan vd. 2020, Kaya vd. 2014, Kuncan vd. 2019). Bu tez kapsamında ise, bu yöntem sensör sinyallerinden elde edilen veriler sayesinde kişi tespiti işlemi gerçekleştirilmiştir. Bu amaç ile, çeşitli sensör gruplarından kayıt edilen işaretler analiz edilerek bu işaretlerdeki öznitelikler geliştirilen “Bir (1) Boyutlu Yerel İkili Örüntü (1B-YİÖ)” yöntemi kullanılarak çıkarılmıştır. Aşağıdaki Şekil 3.4’de 1D-LBP yöntemi kullanılarak öznitelik çıkarımı basamaklar şeklinde gösterilmiştir (Kaya vd. 2014, Banan vd. 2020).



Şekil 3.4 1D-LBP kullanılarak öznitelik çıkarımı, (a) ham sensör işaretlerine ait bir bölüm, (b) İşaretlere ait değerler, (c) merkez değerin komşu değerlerle karşılaştırılarak ikili dizinin oluşturulması, (d) onlu taban karşılığı.

1D-LBP yöntemindeki ilk aşama Şekil 3.4’ de gösterildiği gibi sinyaller üzerinde bulunan her bir noktanın kendi konumundan önceki ve sonraki komşuları ile karşılaştırılması adımıdır. Kıyaslama işleminde elde edilen sonuçlar ikili dizge halindedir ve bu ikili dizge onluk tabana dönüştürülerek 1D-LBP etiketleri elde edilmektedir. P kadar komşu alınarak ikili dizge oluşturulmaktadır. Bir sonraki aşamada ise, Şekil 3.4 (c)’ de gösterildiği gibi, belirlenen P_c merkez sinyalinin öncesi ve sonrasında ki $P/2$ kadar nokta seçilmektedir (Şekil 3.4 (b)). Şekil 3.4 (c) ‘ de P_c merkez noktasının $P=8$ değeri için öncesinde (P_0 , P_1 , P_2 , P_3) ve sonrasında (P_4 , P_5 , P_6 , P_7) komşu değer alınması işlemi gösterilmiştir. Merkez nokta tüm komşuları ile kıyaslanmaktadır. Kıyaslama işlemi yapılırken r komşu (P_i) değer merkez (P_c) değerden büyük ise “1” değil ise “0” olarak sonuç üretilmektedir. (Şekil 3.4 (c)). Kıyaslama işleminin matematiksel ifadesi Denklem 3.3.1.1’de verilmiştir. Kıyaslama işlemi sonucunda, x sinyal üzerinde ki herhangi bir nokta olmak üzere, Denklem 3.3.1.2’ den yararlanılarak 1D-1LBP işlemi sağlanmaktadır.

$$t = P_i - P_c \quad (3.3.1.1)$$

$$1D - LBP (x) = \sum_{i=0}^P F(t)2^i \quad \text{where} \quad F(t) = \begin{cases} 1, t \geq 0 \\ 0, t < 0 \end{cases} \quad (3.3.1.2)$$

P_i komşu değerleri ve P_c merkez değeri ifadesi için kullanılmış olup, Denklem 3.3.1.1 yardımı ile ikili dizge oluşturulup ardından oluşturulan bu ikili dizge onluk tabana çevrilip P_c değerinin 1B-YİÖ hali olarak işaretlenmektedir (Şekil 3.4 (d)). Bu işlemler sinyal üzerindeki tüm noktalara uygulanmaktadır.

Tüm sinyallere bu işlemlerin uygulanması sonucu elde edilen değerler 0-255 arasındaki değerlere dönüşmektedir. Son olarak elde edilen değerler yerel ikili örüntüler olarak tanımlanmaktadır. Her bir frekans değeri yeni bir örüntüyü temsil etmiş olur. Oluşturulan 1B-YİÖ’nün histogramını alıp incelediğimizde elimize 256 adet birbirinden farklı örüntünün olduğu görülür.

3.3.2 Tek boyutlu özellik temelli yerel ikili örüntü

1D-FbLBP yöntemi ilk kez bu çalışmada kişi tanıma için kullanılmıştır. Bu yöntem Pan ve arkadaşları tarafından görüntü işlemede doku analizi için kullanılmıştır (Pan vd. 2017). Bu çalışmada, bu yöntem tek boyutlu hale getirilmiş ve ilk kez giyilebilir sensör sinyallerinden kişi tanımlamak için kullanılmıştır

Geleneksel 1B-LBP yönteminde yerel etiketler fark vektörü Denklem 3.3.2.1’de ki gibidir.

$$dP = [P0-Pc, P1-Pc, P2-Pc, P3-Pc, P4-Pc, P5-Pc, P6-Pc, P7-Pc,] \quad (3.3.2.1)$$

Denklem 3.3.2.1 kullanılarak ifade edilir. dP vektörü Şekil 3.5’de gösterildiği gibi işaret (Sp) ve büyüklük (Mp) vektörlerine dönüştürülebilir. Geleneksel 1D-LBP yönteminde sadece işaret vektörü kullanılırken 1D-FbLBP yöntemi ise büyüklük vektörünü de kullanmaktadır. Büyüklük vektörü Denklem 3.3.2.2’ de ki gibi hesaplanmaktadır.

$$MP = [|P0-Pc|, |P1-Pc|, |P2-Pc|, |P3-Pc|, |P4-Pc|, |P5-Pc|, |P6-Pc|, |P7-Pc|] \quad (3.3.2.2)$$

P0	P1	P2	P3	Pc	P4	P5	P6	P7	
8.3123	8.3038	9.3193	9.4587	8.8541	9.0400	7.9797	7.7207	10.053	(a)
-0.5418	-0.5503	0.4652	0.6046	8.8541	0.1859	-1.1334	-0.8744	1.1989	(b)
1	1	0	0	8.8541	0	1	1	0	(c)
0.5418	0.5503	0.4652	0.6046	8.8541	0.1859	1.1334	0.8744	1.1989	(d)


Şekil 3.5 Fark, İşaret ve Büyüklük Vektörlerin Elde Edilmesi.

Guo'nun çalışmasında (2010) fark vektörünün işaret vektörü sP 'nin, büyüklük vektöründen (Mp) daha ayrıştırıcı bilgi içerdiğini belirtmiştir. Ancak Mp büyüklük vektörü doğrudan atılamaz. Mp vektörü farklı biçimlerden kullanarak daha ayrıştırıcı özniteliklerin elde edilmesi sağlanabilir. Önerilen bu yaklaşımda doğrudan Mp vektörünü kullanmak yerine bu vektörün varyansı kullanılabilir. Burada varyans yerel işaretlerdeki değişimi ifade etmektedir. Büyüklük vektörün ortalama ve varyansı aşağıdaki gibi hesaplanmaktadır.

$$\mu_M = \frac{\sum_{p=0}^{P-1} M_p}{P} \quad (3.3.2.3)$$

$$\delta_M^2 = \frac{\sum_{p=0}^{P-1} (M_p - \mu_M)^2}{P} \quad (3.3.2.4)$$

Burada μ_M büyüklük vektörün ortalaması ve δ_M^2 büyüklük vektörün varyansını göstermektedir. μ_M merkez P_c değer ile komşu P_i değerler arasındaki ortalama farkı temsil eder. δ_M^2 ise büyüklük vektöründeki değişimleri ifade eder. 1D-FbLBP yöntemin örnek işaret üzerindeki hesabı aşağıdaki şekilde gösterilmiştir.



Şekil 3.6 1D-FbLBP operatörün hesaplanması.

Şekil 3.6'daki işlemleri tüm sinyallere uygularız ve uygulama sonucundan sinyal değerleri 0 ile 1023 arasında bir değere dönüşmektedir. Yeni oluşan bu değerler 1D-FbLBP olarak adlandırılır. Her bir frekans değeri bir örüntüyü temsil etmektedir. 1D-FbLBP sinyalin histogramı alındığında 1024 tane farklı örüntü meydana geldiği anlaşılmaktadır.

3.4 Makine Öğrenmesi Yöntemleri

Listenin amacı, makine öğrenimi uygulamalarını literatüre sunmak değil, olası yöntem kombinasyonlarının ne kadar geniş olduğuna dair bir fikir vermektir. Bu çalışmanın kapsamı, derin öğrenme yöntemleri kullanılarak kişi tespiti olduğu için ilk başta makine öğrenmesi algoritmalarına odaklanılmış ve kullanılan makine öğrenme yöntemlerine göre kategorize edilmiş ve örnek çalışmalar kısaca tartışılmıştır. Görüntü bölümlleme ve öznitelik çıkarma yöntemleri, birlikte kullanıldıkları makine öğrenme yöntemleriyle ilişkili olarak tartışılmıştır. Özelleştirilmiş yöntemler arasındaki tek istisna, görüntü bölümlleme ve öznitelik çıkarma adımlarını kendi içinde birleştirdiği için evrişimli sinir ağlarıdır (CNN); dolayısıyla sinir ağlarından farklı şekilde çalışır ve bu istisnadan yola çıkarak geliştirdiğimiz modeller CNN temelli transfer öğrenmeye dayalı modeller olmaktadır ve bunun ile ilgili bilgiler bir bölümde verilecektir.

Makine öğrenimi (MÖ), bir veri kümesine dayalı olarak akıllı tahminler gerçekleştiren geniş bir algoritma yelpazesini ifade eden genel bir terimdir. MÖ, olasılık teorisi, istatistik, hesaplama karmaşıklığı teorisi, yaklaşım teorisi ve diğer birçok bilgisayar bilimi konularını içeren disiplinler arası bir çalışma alanıdır. Yeni bilgi veya beceriler kazanmak için bilgisayar simülasyonu veya insan davranışının gerçekleştirilmesi ve performanslarını sürekli iyileştirmek için mevcut bilgi yapılarının tanınması çalışmasıdır. Yapay zekânın çekirdeği olarak, uygulamalarının çeşitli alanlarında özetleyerek ve sentezleyerek bilgisayarları akıllı hale getirmenin temel bir yoludur (Bishop, 2006, Kohav vd. 1998).

Bu veri kümeleri genellikle büyüktür ve milyonlarca benzersiz veri noktasından oluşabilmektedir. Makine öğrenimindeki son gelişmeler, insani bir anlamsal anlayış ve

bilgi çıkarma seviyesi gibi görünen bir seviyeye ve bazı çalışmalar da ise soyut kavramlar da insanlardan daha iyi başarı elde etmeyi başarmıştır.

İstatistiksel modellemede klasik tekniklere dayanan modern makine öğrenimi, büyük ölçüde artan veri hacimleri, hesaplama gücündeki iyileşmeler ve web endüstrilerinin ihtiyaçları tarafından yönlendirilen algoritma tasarımındaki ilerlemeler nedeniyle güçlü bir araç olarak yapay sinir ağlarının bir kolu olarak yer almaktadır.

Günümüzde çok sayıda makine öğrenmesi yöntemleri bulunmaktadır. Bunların her biri model olarak adlandırılmaktadır. Belirli bir problem için belirli bir modelin seçimi, verilerin özelliklerine ve istenen sonucun türüne göre belirlenir. Dikkat edilmesi gereken birincil nokta, veri kümemizin boyutu olmalıdır. Örnek verecek olursak, 10^6 boyutunda büyük veri kümeleri için makine öğrenme yöntemleri kullanacaksa derin öğrenme modellerine yoğunlaşabileceğimiz gibi daha az boyutlu veriler ile çözüme ulaşmak istediğimiz problemlerde ise “En Yakın Komşu (KNN)” ve “Rastgele Orman (RO)” gibi geleneksel makine öğrenmesi modellerine yoğunlaşmalıyız.


Diğer bir seçim ise denetimli öğrenme ile denetimsiz öğrenme arasındadır. Denetimli öğrenme, adından da anlaşılacağı gibi, modele hâlihazırda kendisiyle ilişkilendirilmiş doğru çıktıya sahip bir dizi girdi verisi ile öğretmeyi içerir. Denetimli öğrenme, görüntü sınıflandırma görevlerinde daha geniş bir şekilde kullanılır. Denetimsiz öğrenme, bir modelin kendisini bir anlamda veri üzerinde eğittiği yerdir. Tipik olarak, bu, küme algılama veya çeşitli model tanıma biçimleri gibi görevleri içerebilir. Google'ın sinir ağı modeli yarışması için geliştirdiği AlphaGo Zero (Silver vd. 2017), Go oyununda kazanan hamleleri öğrenmek denetimsiz öğrenmenin kullanıldığı en güzel örneklerden birisidir. Sadece 3 günlük pekiştirmeli öğrenmeden sonra, AlphaGo Zero 2016'nın ilk denetimli öğrenme modeli olan AlphaGo Lee'nin seviyesini geçti ve 40 günlük kendi kendine öğrenmenin ardından, insan müdahalesi olmadan tüm zamanların en iyi Go oyuncusu oldu.

Yapay zekânın bir alanı olarak makine öğrenmesi, günümüzde verilerin git gide gelişerek artmasıyla birlikte, problemleri çözmek için verilerden yararlanan ve kendi kendine öğrenmeyi gerçekleştiren sistemler olarak günümüzde yaygın olarak kullanılmaktadır. Günümüzde artan veriler insanların manuel olarak sonuçlar çıkarmasını

zorlaştırmaktadır. Bu noktada, makine öğrenmesi bu verilerden anlamlı sonuçlar çıkartarak verilerin daha verimli ve etkin bir şekilde değerlendirilmesi ve problemlerimiz üzerinden sonuca ulaşırken çeşitli düzenlemeler yaparak başarıımızı artırmaya katkı sağlamaktadır. Makine öğrenmesi ile çözeceğimiz problemlerde verileri kullanırken 3 kısıma ayırırız. Bunlar, modeli eğitmek için kullandığımız eğitim verisi, modelin performansını ölçmek için doğrulama (validation) ve modelin eğitim aşamasında parametrelerini iyileştirmek için kullanacağımız test verileridir.

Makine öğrenmesinde, öğrenme algoritmaları verinin keşfedilmesi ve işlenmesinde yoğun olarak kullanıldığından dolayı, makine öğrenmesi için veri vazgeçilmez bir öneme sahiptir (Chao, 2011). Etiketli ve etiketsiz olmak üzere iki tip veri bulunmaktadır. Etiketli veriler algoritmayı eğitmek için seçilir iken etiketsiz veriler daha önceden eğitilmiş modeli test etmek için seçilmektedir. Bu amacından dolayı bu veri türlerine eğitim ve test verileri de denilebilmektedir. MÖ yöntemlerinden faydalanılarak oluşturulan sistemler genel olarak denetimli ve denetimsiz olarak iki sınıfa ayrılmaktadır. Ek olarak, bu iki sınıfın karma olarak kullanılması ile oluşturulan MÖ modelleri de yaygın olarak kullanılmaya başlanmıştır (Gentleman vd. 2008).

Denetimli öğrenme: Supervised Machine Learning olarak ifade edilen Denetimli Makine Öğrenme (SML), sistemi etiketli verilerle eğiterek öğrenme sağlar. Sistem eğitimi sırasında, veri setindeki her örnek için girdiler ve çıktılar sağlanır. Metin sınıflandırma çalışmalarında girdi metnin içeriğini, çıktı ise o kategoriyi temsil eder. Test veri seti, sistemi doğrulamak için kullanılır. Sistem doğrulaması sırasında, eğitim algoritması kategorisi, belirsiz test verilerine eğitim verisi çıktılarından birini atar (Kotsiantis vd. 2007). Denetimli öğrenme modelinin süreci Şekil 3.7' de gösterildiği gibidir (Afrin ve Nahar, 2015).



Şekil 3.7 Denetimli Öğrenme Modeli Süreci (Afrin ve Nahar, 2015).

Genel olarak denetimli öğrenme tabanlı makine öğrenme yöntemlerinin ele aldığı problemler sınıflandırma problemleri olarak görüldüğü için veri setindeki test için ayrılmış kısım tanımlama işlemini gerçekleştirmek için sistemde kullanılır (Chao, 2011). Denetimli makine öğrenmesi tabanlı sistemler oluşturulurken kullanılabilecek çok sayıda yöntem vardır ama genel olarak bilimsel ve ticari çalışmalarda en çok kullanılan yöntemler: “Yapay Sinir Ağları”, “k-En Yakın Komşu Algoritmaları”, “Karar Ağaçları”, “Destek Vektör Makinesi”, “Lojistik Regresyon” olarak literatürde görülmektedir (Caruana ve Niculescu-Mizil, 2006).

Bu yöntemlerin hangisini seçileceği belirlenirken problem odaklı bir yaklaşım izlenerek problemin çözümü ve sonuca en iyi başarı oranı ve en az maliyet ile ulaştıracak yöntem tercih edilir. Sınıflandırma problemlerinde sonuçlar tek etiketli üretilebileceği gibi çok etiketli bir şekilde de üretilebilmektedir. Bu işlem ise mevcut etiket üzerinden test etiketine bir veya birden fazla etiket belirlenmesi uygulanarak gerçekleşmektedir. İkili sınıflandırma işlemleri de tek etiketleme işleminin bir dalı olmakla birlikte iki kategori arasından birini atanması ile oluşmaktadır (Sebastiani, 2002).


Denetimsiz öğrenme: Unsupervised Machine Learning olarak adlandırılan denetimsiz öğrenme modeli sistemin eğitim safhasında etiketsiz verilerin tercih edilerek işlemlerin gerçekleştirildiği süreç olarak tanımlanmaktadır. Bu model sınıflandırma ve tanımlanan işlemlerinden veri setinin çıkışlarının bilinmemesinden dolayı başarılı sonuçlar üretmemesinden tercih edilmemektedir. Bunların yerine aralarında ilişki saptanması gereken olasılık, yoğunluk, boyut azaltma gibi problemlerde başarısının yüksek olmasından dolayı tercih edilmektedir. Ek olarak denetimsiz öğrenme sonucu elde edilen sonuçlar denetimli eğitim modellerine verilerek de yeni sonuçlar üretilmektedir (Chao, 2011). Denetimsiz öğrenme modelinde kullanılan yöntemler ise genel olarak parçalayıcı ve hiyerarşik kümeleme algoritmaları olmaktadır (Özgür, 2004).

3.4.1 Rastgele orman algoritmaları (RF)

Rastgele orman (RO) algoritmaları denetimli öğrenme yöntemini kullanan sınıflandırma ve regresyonda başarılı sonuçlar elde eden bir yapıya sahiptir. Breiman tarafından 2001 yılında sınıflandırma ve regresyon problemleri için RO kullanmaya başlanmasından önce de RO algoritması çeşitli problemin çözümü için 1963 yılında Morgan ve Sonquistin karar ağaçlarının geliştirilmesi ile birlikte günümüze kadar kullanılmaktadır (Breiman, 2001). Rastgele ormanlar, çok çeşitli veri kümelerindeki sağlam performans nedeniyle muazzam bir popülerlik kazanmıştır. Algoritma genellikle düşük genelleme hatasıyla ilgili olarak sınıfının en iyisi performansı elde etme yeteneğine sahiptir ve ayar parametrelerinin seçimine çok duyarlı değildir, bu da onu birçok uygulama için kullanıma hazır bir araç haline getirir. Karmaşık bir problemi çözmek ve modelin performansını iyileştirmek için çoklu sınıflandırıcıları birleştirme süreci olan toplu öğrenme kavramına dayanmaktadır.

Adından da anlaşılacağı gibi, "Random Forest, verilen veri kümesinin çeşitli alt kümelerinde bir dizi karar ağacı içeren ve bu veri kümesinin tahmin doğruluğunu iyileştirmek için ortalama alan bir sınıflandırıcıdır." Bir karar ağacına güvenmek yerine, rastgele orman her ağaçtan tahmini alır ve tahminlerin çoğunluk oylarına dayanarak nihai çıktıyı tahmin eder. Ormandaki ağaç sayısının artması, daha yüksek doğruluk sağlar ve

aşırı uyum sorununu önler. Aşağıdaki Şekil 3.8’de diyagram Rastgele Orman algoritmasının çalışmasını açıklamaktadır:



Şekil 3.8 Rastgele Orman Algoritması Örneği.

Rastgele orman, veri kümesinin sınıfını tahmin etmek için birden çok ağacı birleştirdiğinden, bazı karar ağaçlarının doğru çıktıyı tahmin etmesi olasıyken, diğerleri doğru çıktıyı tahmin etmekte başarılı olmayabilir. Ancak birlikte, tüm ağaçlar doğru çıktıyı tahmin edebilmektedir. Bu nedenle, aşağıda daha iyi bir Rastgele orman sınıflandırıcısı için iki varsayım verilmiştir:

Sınıflandırıcının tahmin edilen bir sonuç yerine doğru sonuçları tahmin edebilmesi için, veri kümesinin özellik değişkeninde bazı gerçek değerler bulunmalıdır. Her ağaçtan gelen tahminler çok düşük korelasyonlara sahip olmalıdır. Rastgele Orman algoritmasını neden kullanmamız gerektiğini açıklayan bazı noktalar aşağıda sunulmuştur:

Diğer algoritmalarla kıyasla daha az eğitim süresi alır. Verimli çalıştığı büyük veri kümeleri için bile çıktıyı yüksek doğrulukla tahmin eder. Ayrıca, büyük miktarda veri eksik olduğunda doğruluğu da koruyabilmektedir. Sınıflandırma problemlerinde, verileri bölmek için kullanılan ana kurallar Denklem 3.4.1.1’de y_l ve y_r sırasıyla sol ve sağ düğümlerde bulunan verilerin ortalamasını gösteren) ve Denklem 3.4.1.2’de yer alan G_{ini} ve regresyon kriterleridir. Denklem 3.4.1.1’de y_l ve y_r sırasıyla sol ve sağ düğümlerde bulunan verilerin ortalamasını göstermektedir. Denklem 3.4.1.2’de N_l ve N_r sırasıyla sağ

düğümde ve sol düğümde bulunan elemanların sayılarını p_{kl} ve p_{kr} parametreleri ise sırasıyla sağ ve sol bölümlerdeki sınıfların oranıdır.

$$R_{ss} = \sum_{\text{sol}} (y_i - y_l)^2 + \sum_{\text{sag}} (y_i - y_r)^2 \quad (3.4.1.1)$$

$$G_{ini} = N_l \sum_{k=1}^K p_{kl}(1-p_{kl}) + N_r \sum_{k=1}^M p_{kr}(1-p_{kr}) \quad (3.4.1.2)$$

Rastgele ormanlar, birçok sınıflandırma ve regresyon ağacı oluşturmak için yinelemeli bölümlmeyi kullanır ve ardından sonuçları bir araya getirir. Her ağaç, eğitim verilerinden bir önyükleme örneği kullanılarak bağımsız olarak oluşturulur. Rastgele ormanın son tahminleri, her bir ağacın tahminlerinin ortalaması alınarak yapılır. Çok sayıda karar ağacı için bu tür oylama mekanizması, az miktarda eğitim verisi, hızlı eğitim (training), daha az manuel müdahale, gürültülü ve eksik değerli verilere karşı sağlamlık içeren eğitim modellerini kolaylıkla oluşturabilir. Böylelikle modelin tahmin doğruluğu da iyileşmiştir olur.

Eğitim aşamasında X 'in eğitim veri setindeki objeleri temsil ettiği göz önüne alındığında (bir $N \times M$ matrisi, burada N eğitim verilerinin sayısı ve M , her verinin boyutudur); L bir $N \times 1$ matrisin eğitim setinin etiketlerini temsil eder. N_{tree} , ormandaki ağaç sayısı anlamına gelen topluluk büyüklüğünü temsil eder. θ_k (rastgele ormanlardaki her rastgele ağaç, $k = 1, 2, \dots, N_{tree}$); M_{try} , bölünmek üzere rastgele seçilen özelliklerin sayısını temsil eder. RO , birden çok karar ağacı sınıflandırıcıdan oluşan bütünleşik bir sınıflandırıcıdır ve Denklem 3.4.1.3'deki gibi tanımlanabilir:

$$h(X, \theta_k), k = 1, 2, \dots, N_{tree} \quad (3.4.1.3)$$

3.4.2 En yakın komşu algoritmaları (Knn)

En yakın komşu algoritması, en basit makine öğrenme algoritmalarından biri olmak ile birlikte hem sınıflandırma hem de regresyon için kullanıl maktadır. Parametrik

olmayan bir tekniktir (Cover ve Hart, 1967): Makine öğrenimindeki en basit yöntemlerden biri olan K-NN çerçeveleri, yalnızca etiketli giriş verileriyle eğitilir. Etiketlenmemiş bir veri eğitim verilerine göre sınıflandırıldığında, kullanıcı tarafından belirlenen bir sayı olan komşu k veri noktası bulunur ve veri noktalarının çoğu etiketlenmemiş test verilerinin sınıfını belirler.

Algoritmanın daha iyi anlaşılabilmesi için kullanılan terimler aşağıda açıklanmaya çalışılmıştır:

İki nesne arasındaki mesafeyi hesaplamak için genel olarak Öklid mesafesi kullanılmaktadır. Öklid mesafesi hesaplanırken, her bir nesne konum vektörü olarak alınmaktadır. $\vec{x}$ ve $\vec{y}$ vektörleri p özellikleri $(x_1, x_2, \dots, x_p)$ olan iki girdi örneği olmak üzere, örnek $\vec{x}$ ve örnek $\vec{y}$ arasındaki Öklid mesafesi Denklem 3.4.2.1' de olduğu gibi hesaplanmaktadır.

$$d(\vec{x}, \vec{y}) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_p - y_p)^2} \quad (3.4.2.1)$$

k – NN algoritmasında k parametresi en yakın komşu sayısını belirlemektedir. Birbirine yakın nesnelerin aynı kategoriye alınması ile sınıflandırma işlemi gerçekleştirilmektedir. Test verileri en yakınlarındaki k adet komşular ile uzaklığı hesaplanarak sınıf etiketlerine bakılarak sınıflandırılır. Bu uzaklıklar bir bellekte kaydedilir. Daha sonra k adet uzaklıktaki eğitim verisi hangi sınıfa ait ise test verisi o sınıfa ait olarak oylanır ve bu test verisine o sınıf etiketi verilir. k-NN algoritması uygulama aşamaları aşağıdaki gibidir:

- Rastgele bir k parametresi belirlenir.
- Bu parametre doğrultusunda test noktasının k adet en yakın komşuları belirlenir.
- Test noktası ile belirlenen noktalar arasındaki uzaklık hesaplanır.
- Uzaklık hesaplanırken n boyutlu $X = (x_1, x_2, \dots, x_n)$ ve $M = (m_1, m_2, \dots, m_n)$ noktaları arasındaki Öklid uzaklığı Denklem 3.4.2.2'deki gibi hesaplanır.

$$\sqrt{\sum_{i=1}^n (x_i - m_i)^2} = \sqrt{(x_1 - m_1)^2 + (x_2 - m_2)^2 + \dots + (x_n - m_n)^2} \quad (3.4.2.2)$$

- Denklem 3.4.2.2’de uzaklıklar hesaplandıktan sonra ek küçük k adet uzaklık seçilir.
- Seçilen k adet örnek arasında en çok hangi sınıf etiketi var ise test edilen yeni veri o örnek etiketini alması için oy çokluğu yöntemi ile etiketlenir.

3.4.3 Lineer diskriminant analizi (LDA)

LDA, difransiyel fonksiyonların analizi olarak Türkçeye çevirebiliriz. Taşıdıkları özelliklere göre veri setindeki verileri değişken gruplara atayarak ayırt etme işlemini gerçekleştirir. Ayırım işlemi gerçekleştirilirken, bağımlı değişken ve bağımsız değişken arasındaki analiz sonucu gerçekleşir. Bu işlem, etkileyen bağımlı değişkenlere bağlı olarak bağımsız değişkenlerin hangi gruba geçeceğinin karar verilmesi sürecidir.

3.4.4 Yapay sinir ağları (YSA)

Biyolojik sinir ağı, insan beyninin önemli bir parçasıdır. Büyük miktarda bilgiyi aynı anda işleme yeteneği olan oldukça karmaşık bir sistemdir. Biyolojik ağlar, farklı görsel girdileri herhangi bir modern ileri teknoloji bilgisayardan çok daha hızlı tanıma ve işleme kapasitesine sahiptir. Örneğin, insan beyni tanıdık yüzü yaklaşık 100-200 ms içinde tanıyabilirken, modern bilgisayarın aynı sorunu çözmesi için dakikalar hatta saatler gerekmektedir. Genel olarak, insan beyninin birçok görevde bilgisayarlardan çok daha verimli olduğu bilinen bir gerçektir.

"Öğretmenden" alınan örneklerle ve geri bildirimlere dayanarak, beynimiz bir elmayı turuncudan nasıl ayırt edeceğimizi veya harfleri nasıl tanıyacağımızı öğrenmemizi sağlamaktadır. Beynimiz öğrenme işlemini tamamladığında, öğretmen olmadan benzer nesneler sınıflandırmayı başarabilmektedir. İnsan beyninin bu ve diğer güçlü yönleri bilim insanlarını heyecanlandırmış ve insanlar için ortak olan görevler üzerinden makinelerin nasıl kullanılabileceği üzerinde araştırmalar yaparak, beyinin işleyiş

süreçleri taklit edilmeye başlanmıştır. Bu araştırmaların sonucunda ortaya çıkan kavramlardan biri de Yapay sinir ağı (YSA) kavramıdır.

YSA teorisinin ilk adımları 1943'te nöro-fizyolog Warren McCulloch ve matematikçi Walter Pitts tarafından atılmıştır. Ağlara yerleştirilebilecek eşikli yapay nöronlar tanımlanmıştır ve matematiksel olarak ifade edilmiştir ve aşağıda bu matematiksel ifadenin denklemi anlatılmaktadır. Birkaç yıl sonra, 1949'da, psikolog Donald Hebb tarafından yapay sinir ağları için ilk öğrenme kuralını - Hebb'in kuralı - sunmuştur. Hebb'in kuralının temeli, iki nöronun aynı anda aktif olması durumunda, aralarındaki bağlantının gücünün artırılması gerektiğidir. 1960'lı yıllara gelinmesi ile birlikte algılayıcıların keşfedilmesi daha fazla YSA mimarilerinin üretilmesine ön ayak oldu. Bu gelişmeye paralel olarak daha güçlü bilgisayarların piyasaya çıkması ile kendi kendini düzenleme kapasitesine sahip aralarında ilişkisel ağlar olan mimariler üretilmeye başlanmıştır. YSA, birçok basit sinir hücresinin birleşiminden oluşan karmaşık bir sinir ağıdır (Lippmann, 1987). YSA'nın önemli özellikleri doğrusal olmayan problemleri çözme, dağıtık paralel yapıya sahip olma, öğrenme, hata toleransı ve genellemedir.

Walter ve Pitts Denklemi 3.4.4.1 numaralı eşitlikteki gibidir.

$$y_i = \psi(g(x)) = \psi\left(\sum_{j=0}^n w_{ij}x_j - Q_i\right); x_i = (x_0, x_1, \dots, x_n) \quad (3.4.4.1)$$

Denklem 3.4.4.2'de, y_i çıkış değerini, $\psi(\cdot)$ aktivasyon fonksiyonunu, $g(\cdot)$ toplama işlemini, w_{ij} ağırlık katsayılarını ve Q_i ise i. sinir hücresinin eşik değerini belirtmektedir.

$$\psi(\cdot) = \begin{cases} 1 & g(\cdot) \geq 0 \\ 0 & g(\cdot) < 0 \end{cases} \quad (3.4.4.2)$$

Denklem 3.4.4.3'de $g(\cdot)$ toplama fonksiyonu olduğundan x_j gösterimi girişlerin doğrusal bir bileşimini temsil etmektedir.


$$g(.) = \sum_{j=0}^n w_{ij} x_j - Q_i \quad (3.4.4.3)$$

Yapay sinir ağıları, işlevsel girdi / çıktı eşleştirmelerini gerçekleştirebilen etkili ve güvenilir algoritmalarıdır. Paralel yapılara sahip olmaları, çok parametrik karakterleri ve hesaplama hızları, özellikle altta yatan fiziksel-matematiksel modeller karmaşık olduğunda onları güçlü bir hesaplama aracı haline getirir. YSA'lar aynı zamanda evrensel tahmin ediciler olarak da bilinir. Bilgi, algoritmik olmayan bir şekilde işlenir. Bilgi öğrenme yoluyla elde edilir, bu da YSA'ların matematiksel açıklamaların bulunmadığı karmaşık sistemleri modellemek için kullanılabileceği anlamına gelir (Rajpal vd. 2006).

Bu özellikleri sayesinde birçok alanda kullanılmaktadır. YSA'nın önemli özelliklerinden biri de öğrenmek ve bu öğrenmeyi yaygınlaştırmaktır. Ağa verilen girdiler ve çıktılar arasındaki ilişkiyi keşfederek tanınmayan verilere karşı uygun çıktılar üretebilmektedir (Garip, 2011).

YSA, canlı sinir sisteminin işleyişini modelleyen bir yapıya sahiptir. Canlı sinir sisteminde sinir hücreleri sinyalleri alır ve aldıkları sinyale göre sinyal iletimini gerçekleştirir (Şekil x). Alınan sinyaller hücrenin merkezine (hücre gövdesine) iletilir. Toplanan sinyaller eşiği aştığında, sinyal akson aracılığıyla diğer sinir hücrelerine iletilir (Akkaya, 2011). YSA, birçok yapay sinir hücresinin birleşmesiyle oluşur. Bu birleşim rastgele olmamakla birlikte katmanlar halinde gerçekleşir (Akkaya, 2011).

Birbirine bağlı birçok hücrenin ağırlık katsayıları ile birlikte bir araya gelmesini sağlayan matematiksel sistemler YSA olarak tanımlanabilmektedir. Sinir hücreler, sinyalleri diğer sinir hücrelerinden alarak birleştirir ve bu sinyaller doğrusal olmayan bir biçime dönüştürülüp sayısal sonuçlar oluşturulur. Sinir hücrelerinin bir ağ içinde birbirine bağlanması ile birlikte sinir ağı oluşmaktadır. Bütün ağ modelleri, veri alarak işlemler yapıp sonuçlar üreten sinir hücrelerine sahiptirler



Şekil 3.9 Yapay Sinir Ağı Modeli.

Şekil 3.9’da bir yapay sinir ağı modeli verilmiştir. Yapay sinir ağı modelleri kullanılarak tasarlanan öğrenme sürecinde, giriş verilerinin aktivasyon fonksiyonu aracılığı ile işlenmesi ile oluşturulan çıkış verisinin üretilmesi işlemi olarak ifade edilebilir. Bu çıkış verilerinin daha önceden eğitilmiş çıkış verileri ile mukayese işleminin sonucunda bir hata oranı elde edilir. Gerçek çıkışa ulaşmak için gerekli öğrenme algoritmaları kullanarak hata oranı en aza indirilir. Bu işlemler sürecinde modelin ağırlıklarının her bir seferde yenilenmesi ile hata oranı azaltılmış olur. Giriş ve çıkış sonuçları kıyaslanarak amaca ulaşıp ulaşılmadığına bakılır eğer istenilen sonuca ulaşılmış ise ağırlık değeri sabit tutulur. Bu işlemden sonra oluşturulan yapay sinir ağı modeli öğrenme işlemini tamamlamış olur ve daha önce sisteme verilmeyen girişler verilmeye başlanır. Elde edilen sonuçlar irdelenerek ağıın öğrenme işleminin başarı ile sonuçlanıp sonuçlanmadığı tespit edilir.

3.4.5 Ortalamalı N bağımlılık tahmincileri (A1DE, A2DE)


A1DE, saf Bayes'ten daha zayıf (ve dolayısıyla daha az zararlı) bağımsızlık varsayımlarına sahip olan alternatif naif-Bayes benzeri modellerin tümünün ortalamasını alarak oldukça hassas bir sınıflandırma elde eder. Ortaya çıkan algoritma, birçok öğrenme

görevinde yüksek doğrulukta sınıflandırma sağlarken hesaplama açısından etkilidir (Webb vd. 2005, Webb vd. 2012).

3.5 Derin Öğrenme

Derin öğrenme, hiyerarşik mimarileri kullanarak verilerdeki üst düzey soyutlamaları öğrenmeye çalışan makine öğreniminin bir alt alanıdır. Derin öğrenme; görüntüler, metinler veya sesler gibi verilerden özellik çıkaran makine öğrenme tekniğidir. Bu teknikle çıkarılan özellikler öğrenilir ve sonraki görevler için kullanılabilir. Makine öğrenimi ile derin öğrenme arasındaki en büyük fark özellik çıkarımının derin öğrenmenin kendi kendine gerçekleştirmesidir. Daha sınıflandırma veya tahmin kısmı ise tam bağlı katmanlar ile YSA modeline benzer şekilde gerçekleştirilir (Goodfellow vd. 2016).

Derin öğrenme, birden çok işlem katmanının hesaplama modellerinin, beynin çok modülü bilgileri nasıl algıladığını ve anladığını taklit eden birden çok soyutlama düzeyiyle verileri öğrenmesine ve temsil etmesine olanak tanır, böylece dolaylı olarak büyük ölçekli verilerin karmaşık yapılarını yakalar. Derin öğrenme, sinir ağlarını, hiyerarşik olasılık modellerini ve çeşitli denetimsiz ve denetimli özellik öğrenme algoritmalarını kapsayan zengin bir yöntem ailesidir. Gelişmekte olan bir yaklaşımdır ve anlamsal ayrıştırma, aktarım öğrenimi, doğal dil işleme, bilgisayarla görme ve çok daha fazlası gibi geleneksel yapay zeka alanlarında yaygın olarak uygulanmıştır (Yu vd. 2014, Dogan ve Keles, 2020). Derin öğrenme yöntemlerine olan ilginin son zamanlarda artması, çeşitli görevlerde önceki son teknoloji tekniklerden daha iyi performans göstermelerinin yanı sıra farklı kaynaklardan (ör. görsel, işitsel, tıbbi) gelen karmaşık verilerin bolluğundan kaynaklanmaktadır (Jia vd. 2014).




Şekil 3.10 Yapay Zeka, Makine Öğrenmesi Ve Derin Öğrenme Arasındaki İlişki.

Derin öğrenmedeki en önemli atılımlardan biri 2006 yılında Hinton ve arkadaşlarının, çok katmanlı Kısıtlı Boltzmann Makineleri ile her seferinde bir katmanı denetimsiz bir şekilde açgözlülükle eğiten Derin İnanç Ağı'nı tanıtmalarıyla başlamıştır. Her düzeyde yerel olarak gerçekleştirilen denetimsiz öğrenmeyi kullanarak orta düzey temsil düzeylerinin eğitimine rehberlik etmek, son on yılda derin mimariler ve derin öğrenme algoritmalarındaki artışı sağlayan bir dizi gelişmenin arkasındaki ana ilkeyi oluşturmuştur.

3.5.1 Evrişimsel sinir ağları

“Evrişimsel Sinir Ağları (ESA)” adını matematiksel bir işlem olan evrişimden alan, veriyi işlerken kullandığı ızgara benzeri bir topolojiye sahip olan bir sinir ağı türüdür. Evrişimsel sinir ağları katmanlarından birinde genel matris çarpımı yerine lineer bir işlem olan evrişimi kullanır (Goodfellow vd. 2016). 2012 yılından sonra artan bir ivmeyle bu ağlar ile başarılı çalışmalar yapılmıştır. ESA bilgisayarlı görü alanında baskın ve güçlü bir ağ mimarisi türü olmuştur. Amazon ürün önerilerinde, Google fotoğraf aramalarında ve Facebook otomatik etiketleme algoritmalarında benzer şekilde ESA kullanılmaktadır (Dev 2017).

Temel bir ESA giriş, evrişim ve havuzlama tam bağlaşımlı katmanlarından oluşmaktadır. Bu katmanlar istenirse evrişim, havuzlama gibi katmanlar tekrar edilerek derinleştirilebilir. Şekil 3.11’de örnek bir ESA ağ mimarisi verilmiştir.



Şekil 3.11 Bir Evrişimsel Sinir Ağı Mimarisi.

Evrişim katmanı: Evrişim işlemi ayrık zamanda Denklem 3.5.1.1 ile ifade edilmektedir.

$$s(t) = (x * w)(t) = \sum_{a=-\infty}^{\infty} x(a)w(t - a) \quad (3.5.1.1)$$

Denklem 3.5.1.1’de kernel w , giriş x , zaman t , sonuç s olarak ifade edilmiştir. Evrişim işlemi; girişten alınan verinin belirli bir kernel (süzgeç, nöron) ile evrişim işlemi uygulanıp daha küçük boyutlarda yeni bir giriş elde etmesini sağlar. Evrişim işlemi uygulanan alana ise alıcı alan (receptive field) denmektedir. Evrişim için kullanılan süzgeç bir dizi sayıdır, bu sayılara ağırlıklar da denebilir. Buradaki önemli bir nokta da kernelin derinliği giriş verisinin derinliği ile aynı olma zorunluluğudur.

Evrişim işlemi derin öğrenmenin performansını arttıracak 3 önemli özellik içermektedir. Bunlar seyrek bağlantı, parametre paylaşımı ve eşdeğerlik temsilcileridir.

Belirtildiği üzere geleneksel sinir ağıları giriş katmanı ve çıkış katmanı arasındaki bağlantıyı açıklaması için her biri farklı bir parametre olan parametre matrislerinin çarpımlarını kullanır. Seyrek bağlantı ya da seyrek ağırlıkları; giriş verisine uygulanan kernelin girişten küçük olmasını böylece zaman sorununun önüne geçmeyi amaçlar. Çoğunlukla derin öğrenme verileri binlerce, milyonlarca pikselden oluşur ve ağı bu piksellerin tümünü kullanarak işlem yapması hem zaman hem de hafıza açısından zordur. Eldeki verilerde elde edilmek istenen kısımlar köşeler, basit renkler ya da kıvrımlardır ve büyük miktarda veriden ağı kullanacağı küçük miktardaki bu verilerin elde edilmesi evrişim katmanı ile mümkün olmaktadır.

Parametre paylaşımı, bir parametrenin modeldeki birden çok işlevde kullanılması olarak tanımlanır (Goodfellow vd. 2016). Sinirsel ağlarda ağırlık matrisindeki her bir eleman katmanın çıkışı hesaplanırken birer kez kullanılır, giriş katmanı ile çarpılır ve sonra tekrar kullanılmaz. Parametre paylaşımına eş anlamlı olarak bağlı ağırlıklar terimi de kullanılabilir çünkü bir girişe uygulanacak olan değer başka girişe uygulanacak olan değer ile ilişkilidir. ESA'da kernelin her bir elemanı girişin her bir pikseliyle işleme alınmaktadır. Kısaca ESA'da kullanılan parametre paylaşımı her konum için ayrı bir parametreyi öğrenmek yerine sadece bir set parametre öğrenileceği anlamına gelmektedir.

Eşdeğerlik temsilcileri; bir eşdeğerlik işlevi çıkışın girişle aynı şekilde değiştiği işlev olarak tanımlanır. Matematiksel olarak Denklem 3.5.1.2 ile gösterilebilir.

$$f(g \cdot x) = g \cdot f(x) \quad (3.5.1.2)$$

Evrişim işlemi uygulanması parametre paylaşımı ile beraber katmanın eşdeğerlik özelliği göstermesine neden olur. Örneğin $I(.)$ işlevi burada resmin herhangi bir koordinattaki parlaklığını gösterebilir. $g(.)$ işlevi Denklem 3.5.1.3 ve Denklem 3.5.1.4'de gösterildiği üzere üzerindeki her pikseli bir birim sağa kaydıran bir işlevdir.

$$I' = g(I) \quad (3.5.1.3)$$

$$I'(x, y) = I(x - 1, y) \quad (3.5.1.4)$$

Eğer bu dönüşümü I üzerinde uygulandıktan sonra evrişim işlevi uygularsak elde edilen sonuç, I' üzerinde evrişim uygulayıp çıkışa g işlevi uygulamakla aynı sonucu verecektir. Bu da evrişim işlevinin eşdeğerlik özelliği göstermesindendir.


Evrişim katmanı için üst parametreler derinlik, adım ve sıfır doldurmadır. Bu parametrelerin değerlerinin seçiminde belirli bir standart bulunmamaktadır ancak daha önce kullanılmış değerler referans alınabilir.

Derinlik; her öğrenme iterasyonunda giriş katmanına uygulanan filtre sayısı olarak tanımlanabilir. Her bir filtre ayrı ayrı giriş verisindeki farklı bir özelliği arar. Bu durumda işlenmemiş ilk veri giriş katmanı ise derinlik boyutu boyunca birden fazla nöron çeşitli renklerin lekeleri ya da farklı yönlü köşelerde aktifleşebilir (Dev 2017). Girişin aynı bölgesindeki nöron dizileri sütun derinliği olarak adlandırılır.

Adım; genel anlamıyla giriş katmanında kernelin evrişim esnasında kayma boyutunun ölçüsüdür. Her adım bir piksele denk gelmektedir. Bu adım bir sonraki katmana aktarılan piksel büyüklüğünü belirlemede yardımcı olur. Küçük seçilen adımlarda kayma esnasında örtüşme fazladır bu da boyutun büyümesine neden olur.

Şekil 3.12’de ikişer adımlık kaydırmalar (her farklı renkteki çerçeve kaydırmayı göstermektedir) ile 7x7 boyutlu resim üzerinde 3x3 boyutlu kernelin uygulanması ve 3x3 boyutlu ilgi alanı matrisinin oluşumu gösterilmiştir. Her farklı renk kaydırılmış kernelin uygulandığı alıcı alanı ve oluşan yeni matriste elde edildiği alanı göstermektedir.

Evrişim işlemi sonrasında boyutta olan küçülmeler derin ağlarda boyutun çok küçülmesi nedeniyle istenmeyen durumlar yaratabilir. Bunu önlemek için bazı katmanlarda evrişim sonrasında giriş verisinin çerçevesine sıfır doldurma işlemi uygulanabilir.




Şekil 3.12 İki Adım Kaydırma İle 7x7 Boyutlu İlgili Alanı Matrisinden 3x3 Boyutlu Öznitelik Matrisinin Oluşumu (Dev 2017'den değiştirilerek alınmıştır).

Sonuç olarak bu 3 üst değişken (hyperparameter) de giriş verisinin boyutuna etki etmektedir bunu Denklem 3.5.1.5'de gösterecek olursak;

$$o = \frac{(w - k + 2P)}{S + 1} \quad (3.5.1.5)$$

Burada o çıkış katmanının bir boyutunun büyüklüğünü, w giriş verisinin büyüklüğünü, k kernel süzgeç büyüklüğünü, s adım büyüklüğünü ve p de sıfır doldurma büyüklüğünü ifade etmektedir. Şekil 3.13'de örnek olarak 6x6x3'lük bir matrise 1'er çerçeve sıfır doldurma işlemi uygulanmış olup 8x8x3 boyutlarında matrise çevrilmiştir.



Şekil 3.13 1'er Çerçeve Kullanarak Yarım Dolgu Sıfır Doldurma İşlemi (Dev 2017'den değiştirilerek alınmıştır).

Parametrelerin büyüklükleri seçilirken çıkış verisinin bir tamsayı olarak elde edileceği büyüklüklerin seçimine özen gösterilmelidir bu ayarlamayı yapmak için daha çok sıfır doldurma üst parametresi tercih edilebilir.

Doğrultulmuş doğrusal ünite (ReLU): Evrişim katmanında yapılan lineer işlemler olan, toplama ve çarpma işlemleri sonrasında derin ağlarda genellikle bir aktivasyon fonksiyonu uygulanması gerekir. Çünkü fonksiyon kas kat bir sistem oluşturan derin ağlardaki lineerliği bozarak daha etkili bir model oluşturulur. Bu nedenle evrişim işleminden sonra bir aktivasyon fonksiyonu uygulanır ki bu derin öğrenme sistemlerinde genellikle ReLU olmaktadır. Denklem 3.5.1.6'de görüleceği üzere işlev giriş (x) için pozitif değerleri çıkışa aktarır.

$$f(x) = \max(0, x) \quad (3.5.1.6)$$


Yapay sinir ağlarında kullanılan “hiperbolik” “tanjant”, “sigmoid” gibi işlevlerin yerine “ReLU” kullanılmasıdaki nedenlerden biri sistemin kullanılan diğer aktivasyon fonksiyonlarına göre daha hızlı çalıştığının gözlemlenmesidir.

Mass vd. 2013 yapılan bir çalışmada, sızdıran “ReLU” adıyla belirtilen fonksiyon Denklem 3.5.1.7 ile verilmiştir.

$$\text{Sızdıran ReLU}(x) = \max(0, x) + \alpha \min(0, x) \quad (3.5.1.7)$$

Burada α önceden tanımlanmış ($\alpha=0.01$) bir parametredir. 2015 yılında yapılan bir başka çalışmada aktivasyon fonksiyonu parametrik “ReLU” adıyla ve α eğitilebilen bir parametre olarak tanımlanmıştır (He vd. 2015).

Havuzlama katmanı: Alt örnekleme katmanı olarak da bilinen havuzlama katmanının birincil işlevi, ağın çıkışını, komşu çıkışların özetlenmiş bir istatistiği ile belirli bir konumda değiştirmektir. Bu katmanda genellikle 2x2 boyutlarında seçilen süzgeç yine 2 adımlık kaydırmalarla giriş verisi üzerinde gezdirilir. Seçilen yöntemle göre ya maksimum değer ya da ortalama gibi değerler bir sonraki katmana iletilir. Böylelikle tüm pikselleri iletmeye gerek kalmadan hem bölge içindeki değer hem de kısmen piksel konumu bir sonraki katmana iletilmiş olur. Bu da parametrelerin çoğunun elenmesine ve aşırı öğrenmenin önlenmesine yardımcı olur. Bu katman için kullanılabilecek yöntemlerden bazıları maksimum havuzlama, ortalama havuzlama ve L-norm havuzlamadır. Ek olarak, bazı yapay sinir ağlarında havuzlama katmanı bulunmamaktadır. Havuzlama işlemlerinin matematiksel ifadesi aşağıda verilmiştir



Şekil 3.14 Havuzlama İşlemleri.

$$\text{Üretilen Görüntünün Boyutu} = G2 \times Y2 \times D2 \quad (3.5.1.8)$$

$$G2 = (G1 - F) / A + 1 \quad (3.5.1.9)$$

$$Y2 = (H1 - F) / A + 1 \quad (3.5.1.10)$$

$$D2 = D1 \quad (3.5.1.11)$$

$G1$ = Giriş görüntü boyutunun genişlik değeri

$Y1$ = Giriş görüntü boyutunun yükseklik değeri

$D1$ = Giriş görüntü boyutunun derinlik değeri

F = Filtre boyutu

A = Adım sayısı

Havuzlama işleminde çoğunlukla $F=2$ ve $A=2$ olarak seçilir.

3.5.2 Aktivasyon fonksiyonları

Aktivasyon fonksiyonlarını, YSA modellerinde girdi verileri üzerinden işlemler yapılan bu işlem sonucu elde edilecek olan net çıktıları elde etmemizi sağlar. Bu fonksiyonlar nadiren doğrusal fonksiyonlar olsa da genellikle doğrusal olmayan fonksiyonlardan oluşmaktadır. Doğrusal olmayan fonksiyonların seçilmesinin sebebi ise modelin doğrusal olmayan bir problemin çözümünde de başarılı sonuçlar üretilmesi içindir. Ek olarak; fonksiyonlar ağıın başarısını arttırmakla birlikte hızına da etki etmektedir. Modelimizde aktivasyon fonksiyonu uygulamadığımız durumlarda, çıkış sinyallimiz basit bir fonksiyon halini almaktadır. Bu basit fonksiyonlar da tek dereceli bir polinomdur. Bu durumda özellikle derin öğrenme ağlarında ağıın öznelilik çıkarma işlemlerinden engel olmaktadır. Bunun için doğrusal olmayan bir aktivasyon fonksiyonu seçilerek ağıın başarılı sonuçlar elde etmesi sağlanır. Aşağıda YSA modellerinden özellikle derin ve transfer öğrenme yöntemlerinde kullanılan aktivasyon fonksiyonları verilmiştir.

Sigmoid fonksiyonu: Sigmoid fonksiyonu en çok kullanılan aktivasyon fonksiyonudur. Çıkış değeri 0 ile 1 arasında olmaktadır. Eğer sonuç sıfırdan küçük ise 0'a, sonuç değeri 0' dan büyük olması durumunda 1' e sonucu eşitlemektedir. Fonksiyonun uç noktalarına doğru tepki verme azalır ve bunun sonucunda yumuşak bir eğri (gradient) meydana gelir. Bu noktalarda türev değerleri 0 a yaklaşır bunun sonucunda gradient kaybolması yaşanır. Sonucunda ise, ağıın öğrenmeye tepki vermesi azalır ve doğru tahmin elde edilmesi için geçen süre artar. Bu durumun oluştuğu ağlar da, sigmoid fonksiyonu yerine hiperbolik tanjant fonksiyonu seçilebilir.

Şekil 3.15'de gösterilmiştir. Sigmoid fonksiyonu Denklem 3.5.2.1 kullanılarak hesaplanabilir.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.5.2.1)$$

Hiperbolik tanjant (tanh) fonksiyonu: Sigmoid fonksiyonuna alternatif olarak kullanılmasına rağmen, benzer bir yapıya sahiptir. Ancak bu fonksiyonda değerler -1 ile +1 aralığında olmaktadır. Bu aralıkta, fonksiyonun 0 merkezli olmasını ve pozitif ve negatif değerlere sahip girdilerin daha güçlü modellenmesini sağlamaktadır.

Hiperbolik tanjantın fonksiyonu Denklem 3.5.2.2 kullanılarak tanh aktivasyon fonksiyonu elde edilebilir. Şekil 3.15 ile tanh fonksiyon grafiği verilmiştir.

$$f(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (3.5.2.2)$$

ReLU (Rectified Linear Unit) fonksiyonu: Derim öğrenme uygulamalarında evrişim katmanından sonra kullanılmak için en çok tercih edilen fonksiyondur. Hesaplama işlemleri yapılırken üstel fonksiyonların tercih edilmemesi de maliyet açısından diğer fonksiyonlara göre daha avantajlı hale getirir. İşlemler gerçekleşirken pozitif değerler aynen alınıp, negatif değerler 0 a eşitlenir. Doğrusal bir yapıya sahip olmasına rağmen doğrusal olmayan problemlerde de başarılı bir sonuç verdiği için dolayı tercih edilir. Doğrusal yapıya sahip olmasından dolayı girdiler sifıra yaklaştığından ağıda nöron kayıpları meydana gelir.

ReLU fonksiyonu Denklem 3.5.2.3'deki gibi elde edilebilir. Şekil 3.15'de ReLu grafiği çizdirilmiştir.


$$f(x) = \max(0, x) \quad (3.5.2.3)$$

Sızıntı ReLu (Leaky ReLu) fonksiyonu: ReLu fonksiyonunun dezavantajı olan nöronların kaybolması problemini çözmek için geliştirilmiştir. Bu işlemde negatif alanlarda 0 değeri yerine küçük bir eğim kullanılarak gerçekleştirir ama bu da negatif değerler de tutarsız sonuçlar doğurabilir.

Şekil 3.15'de farklı a değerleri için fonksiyon grafiği verilmiştir.

Denklem 3.5.2.4'de, sızıntı ReLu formülü verilmiştir.

$$f(x) = \max(ax, x), \quad 0 < a < 1 \quad (3.5.2.4)$$



Şekil 3.15 Çeşitli Aktivasyon Fonksiyonları.

Softmax aktivasyon fonksiyonu: Softmax, bir sayı vektörünü bir olasılık vektörüne dönüştüren matematiksel bir fonksiyondur; burada her bir değerin olasılığı, vektördeki her bir değerin göreceli ölçeğiyle orantılıdır. Softmax fonksiyonunun uygulamalı makine öğreniminde en yaygın kullanımı, bir sinir ağı modelinde aktivasyon fonksiyonu olarak kullanılmasıdır. Spesifik olarak, ağı, sınıflandırma görevindeki her sınıf için bir tane olmak üzere N değerleri verecek şekilde yapılandırılmıştır ve softmax işlevi, çıktıları normalleştirmek için kullanılır ve bunları ağırlıklı toplam değerlerden toplamı bir olan olasılıklara dönüştürür. softmax fonksiyonunun çıktısındaki her değer, her sınıf için üyelik olasılığı olarak yorumlanır.

Evriřim katmanlarında genellikle ReLu fonksiyonu tercih edilirken tam baęlantılı katmanlarda hiperbolik tanjant (tanh) ve son katmanında softmax fonksiyonu kullanılmaktadır.

3.5.3 Transfer öğrenme


Gerçekte, büyük boyutlu veri kümesi nadiren mevcut olduğundan, çok az kiři tüm modeli baştan eğitebilir. Bununla birlikte, birçok arařtırmacı, modeli ImageNet gibi büyük bir veri kümesinde önceden eğitmeyi ve ardından ondan özellikleri çıkarmayı tercih ediyor. Transfer öğrenme, zamandan tasarruf etmek ve aynı zamanda daha iyi performans elde etmek için (Pan ve Yang, 2009), bilgi aktarımının öğrenme performansını artıracağını ve verileri hatırlama çabasını azaltacağını sunan bir optimizasyondur (Pan ve Yang, 2009).

"Neyin aktarılacağı", "nasıl aktarılacağı" ve "ne zaman aktarılacağı" gibi üç konuyu örnekleemektedir. "Ne aktarılmalı", "nasıl aktarılır" sorununa karşılık gelen etki alanları arasında aktarılacak belirli bölüm anlamına gelir. "Ne zaman aktarılmalı", belirli bir durumda yapılacak aktarım öğrenimi anlamına gelir. Yukarıdaki nokta, projeme göre transfer öğrenmeyi nasıl düşüneceğim fikrini vermektedir. Transfer öğrenmenin amacı, kaynak-görevden alınan bilgi verilen hedef görevdeki öğrenme becerilerini geliřtirmektir.

Transfer öğrenmedeki zorluklardan biri, ilgili görevler arasında negatif transferden kaçınırken pozitif transfer üretmektir. Negatif transferin var olmasının nedeni, kaynak görev ile hedef görev arasındaki ilişkinin zayıf olmasıdır. Bu nedenle, hedef görevi öğrenirken kötü bilgileri tanımak ve reddetmek önemlidir. Bu durumda, transfer öğrenmesindeki performans en azından onsuz olduğundan daha kötü olmamaktadır. Bu durum çalışmamda transfer öğrenmeyi dikkatlice düşünme ve olumsuz aktarımdan kaçınma fikrini sunmaktadır (Torrey ve Shavali, 2010).

Transfer öğrenme, önceden öğrenilmiş olan ilgili bir görevden bilgi transferine dayanan yeni bir görevdeki öğrenmenin geliştirilmesidir (Torrey ve Shavali, 2010). Bilgisayarla görmede, dâhil olmak üzere transfer öğrenme örnekleri, nesne sınıflandırması için önemli ölçüde geliştirilmiş sonuçlara yol açar (Oquab vd. 2014, You vd. 2015). Neyse ki, bazı yöntemler arasında bırakma ve sinir aęının aşırı uyum sağlamasını engellemeye çalışan


veri artırma bulunur (You vd. 2015, Yao ve Doretto, 2010, Srivastava ve Hinton, 2014, Perez ve Wang, 2017).



Şekil 3.16 Evrişimli sinir ağı ve transfer öğrenme.

Şekil 3.16’da görüldüğü gibi araç, tır, bisiklet vb. sınıflandırması evrişimli sinir ağı ile gerçekleştirmek istenirse bu sınıflardan belirli sayıda eğitim verisi ile ESA eğitilmelidir. Transfer öğrenmesinde ise tanımlı objeler için eğitim yapılmasına gerek yoktur. Dış dünyadan elde edilen kedi, köpek vb. sınıflara ait resimler kolaylıkla sınıflandırılabilir. Farklı uygulamalar için ise önceden eğitilmiş modellerin belirli katmanları değiştirilerek ağırlıklar ve bias güncellenmesi yapılır. Veri kümeleri birbirine benzer ve birbiriyle alakalı olduğunda, ancak yeni veri kümesi küçük olduğunda, transfer öğrenimi aşağıdaki gibi uygulanabilir:


Özellik Çıkarıcı Metot: Kendi problemimizi çözmek için belirlediğimiz yeni bir ESA modelini, daha önceden eğitilmiş bir ESA modelinden evrişim katmanının ağırlık değerlerini alarak, sınıflandırma katmanında eğitim işleminin yapıldığı yaklaşımdır. Sınıflandırma işlemlerinin yapılması için sadece yapay sinir ağı değil aynı zamanda lineer sınıflandırıcılarda kullanılabilmektedir. Bunun sonucunda, daha önceden eğitilmiş modelin özellik çıkarma yeteneği kendi modelimize aktarılmış olmaktadır. Aşağıdaki şekilde işlemin görsel olarak ifade edilmiş hali sunulmaktadır.



Şekil 3.17 Özellik Çıkarıcı Metot.

Üretilen imgeler üst üste dizilir ve bu dizilim kademeli olarak imgelerin çözünürlüğünün azaltılması ve arttırılması ile yapılır. İmgelerin üst üste dizilmesi ise piramitleme olarak adlandırılır.

Kısmi Özellik Çıkarıcı Metot: Bu metottun amacı daha önceden eğitilmiş ESA modelinin evrişim katmanının bütün ağırlıklarını almak yerine sadece belirli bir bölümünün yeni modele aktarılması ve yeni modeldeki evrişim katmanının boş bölümlerinin ve sınıflandırıcı katmanın kendi problemimize göre güncellenmesi ile oluşmaktadır. Şekil 3.18’de bu ifadenin görselleştirilmiş hali sunulmaktadır.




Şekil 3.18 Kısmi Özellik Çıkarıcı Metot.

Ön eğitim Modeli: Günümüzde en çok tercih edilen transfer öğrenme yaklaşımıdır. Buradaki amaç daha önce büyük veri setleri ile eğitimi tamamlanmış ve başarısı kanıtlanmış modellerin ağırlıklarının kullanılmasıdır. İmagenet veri seti yarışmalarında her yıl modelleri önerilmekte ve bu modeller alanından çok önemli başarıya devasa büyüklükteki veri setleri ile sahip olmaktadır. Örnek verecek olursak, İmagenet yarışmasında birinci olan AlexNet ağı, çok katmanlı yapıya sahip olup eğitilmesi ise Gpu destekli bilgisayarlarda bile günlerce sürmektedir, bu ağ eğitildikten sonra kullanılması için açık erişimle sunulmaktadır. Araştırmacılar daha sonra bu ağı ağırlık değerlerini kullanarak, kendi problemlerine göre revize ederek çözüme daha kolay ulaşabilmektedirler.

3.5.3.1 Alexnet modeli

AlexNet, Alex Krizhevsky ve diğerleri tarafından 2012 yılında geliştirilen derin bir sinir ağıdır. ImageNet büyük ölçekli görsel tanıma yarışması “(The ImageNet Large Scale Visual Recognition Challenge, ILSVRC)” 2012 veri seti ile eğitilmiş ve sınıflandırılması amacıyla tasarlanmıştır. Ayrıca birden fazla GPU ile çalıştırılmıştır. Renkli boyutlu görüntüleri ($227 \times 227 \times 3$) 1000 kategoriye sınıflandırmak için inşa edilmiştir. AlexNet, 8 katmanlı derinliğe sahip ileri beslemeli bir CNN türüdür. 5 evrişim katmanı ve 3 maksimum ortaklama katmanı ve 3 tam bağlantılı katman içermektedir. Toplamda 61 milyonun üzerinde eğitilebilir parametreye sahiptir. Alt örnekleme sırasında maksimum ortaklama (3×3 filtre) ve ReLu aktivasyon fonksiyonlarını kullanır. Konvolüsyonlar için (11×11), (5×5) veya (3×3) boyutunda filtreler kullanılmaktadır. Şekil 3.19’da Alexnet mimarisi görülmektedir.




Şekil 3.19 Alexnet mimarisi (Kızrak, 2018).

3.5.3.2 VGG modeli

VGGNet, Oxford Üniversitesi'nde bulunan VGG (Görsel Geometri Grubu) üyeleri Simonyan ve Zisserman tarafından önerilmiştir. 14 milyondan fazla verinin ve 1000 sınıfın bulunduğu ILSVRC 2014 yarışmasında TOP-5 seviyesinde önemli bir sonuç elde

etmiştir (Simonyan ve Zisserman, 2014). Modelin yapısı ALEXNet yapısına çok benzemektedir ve ALEXNetin 11x11 ve 5x5 boyutlarındaki filtre yapısını 3x3 boyutlarında küçültmektedir. VGGNet 16 ve 19 katman olarak iki farklı modele sahiptir. VGGNet16 modelinde 13 evrişim ve 3 tam bağlı katman bulunurken VGGNet19 modelinde 16 evrişim ve 3 tam bağlı katman yer almaktadır (Mateen vd. 2019). Çalışma kapsamında VGGNet19 modeli kullanılmıştır ve bu model Şekil 3.20’de gösterilmektedir.



Şekil 3.20 VGGNet Modellerine Ait Görseller. (a) VGG16 ve (b) VGG19.

3.5.3.3 ResNet modeli

Derin öğrenme mimarilerini geleneksel yapay sinir ağları modellerinden ayırt eden en önemli özelliği derin ağların kendi içerisinde bulunmakta olan katmanların veriye ait olan öznetelik haritasını çıkarabilmesi özelliğidir. Bu mimariler sayesinde veri içerisinde farklı boyutlarda ve sayılarda filtreler uygulanarak elde edilen öznetelik haritalarının analiz

edile bilinmesi sağlanmaktadır. Bunun neticesinde test için görüntü sorgulandığında hangi görüntüye sahip olduğu tahmin edilebilmektedir (He vd. 2016). 2012

ImageNet yarışmasının sonucunda “AlexNet”in göstermiş olduğu başarıyla birlikte (Krizhevsky vd. 2012) ortaya çıkan mimariden sonra, Konvansiyonel Sinir ağları nesne algılama, görüntü segmentasyonu, görüntü sınıflandırma, yüz tanıma, insan poz tahmini ve izleme gibi alanlarda büyük performans sergilemeye başlamışlardır. Bu gelişmelerin yanı sıra ağ mimarilerinin evrimiyle birlikte, oluşturulabilecek yeni mimariler için en iyi uygulamaların yapılmasında izlenmesi gereken önemli noktalar öne sürülmüştür (He vd.2015, Simonyan ve Zisserman, 2014, Szegedy vd. 2015).

Son yıllarda derin evrişimli sinir ağları, görüntü sınıflandırmaları alanında bir dizi atılım gerçekleştirmiştir (Krizhevsky vd. 2012, Sermanet vd. 2013, Zeiler ve Fergus, 2014). Hubel ve Wiesel tarafından nörobilimdeki basit hücrelerden ve alıcı alan keşiflerinden esinlenilmiştir (Hubel ve Wiesel, 1968) Derin evrişimli sinir ağları (CNN'ler) katmanlı bir yapıya sahiptir ve her tabaka evrişimsel filtrelerden oluşur. Bu filtreleri giriş görüntüsü ile birleştirerek, bir sonraki katman için özellik vektörleri üretilir ve parametreleri paylaşarak kolayca öğrenilebilirler. Evrişimli sinir ağlarındaki ilk katmanlar, kenarlar ve renk kontrastları gibi düşük düzeyli yerel özellikleri temsil ederken, daha derin katmanlar daha karmaşık şekiller yakalamaya çalışır ve daha spesifiklerdir (Sermanet vd. 2013). Modeli derinleştirerek bu evrişimsel filtrelerin çeşitliliğini ve özgünlüğünü zenginleştirerek CNN'lerin sınıflandırma performansını geliştirebilir (Simonyan vd. Zisserman, 2013).

Derin ağlar çoğu zaman sınıflandırmada daha iyi performans gösterebilse de, esas olarak iki nedenden dolayı eğitilmesi daha zordur: Birincisi yok olan / patlayan gradyanlar: bazen bir nöron eğitim sürecinde ölür ve aktivasyon fonksiyonuna bağlı olarak asla geri gelmeyebilir (Glorot ve Bengio, 2010) . Bu sorun, optimizasyon sürecini aktif bir nöron seti ile başlatmaya çalışan başlatma teknikleri ile giderilebilir.

İkincisi ise daha zor optimizasyon: model daha fazla parametre getirdiğinde, ağı eğitmek zorlaşır. Bu bazen aşırı uyum sorunu değildir, çünkü bazen daha fazla katman eklemek daha da fazla eğitim hatasına yol açar (Srivastava vd. 2015)

Bu nedenle, daha iyi sınıflandırma performansına sahip olmasına rağmen, derin CNN'lerin eğitilmesi daha zordur. Önerilen bu problemleri çözmenin etkili bir yolu ResNet Ağlar'dır (ResNets) (He vd. 2015). ResNets'teki temel fark, normal evrişimli katmanlarına paralel kısa yol bağlantılarına sahip olmalarıdır. Evrişim katmanlarının aksine, bu kısa yol bağlantıları her zaman canlıdır ve degradeler kolayca geri yayılabilir, bu da daha hızlı bir eğitim ile sonuçlanmaktadır.


ResNets ve normal ConvNets arasında basit bir fark vardır. Amaç, gradyanların ağırlık katmanlarına yayılması için açık bir yol sağlamaktır. Bu, kaybolan gradyan probleminden veya ölü nöronlardan kaçınarak öğrenme sürecini daha hızlı hale getirmektedir. Kaybolan gradyan problemlerine çözüm getirerek, 2015 yılından yapılan IMAGENET yarışmasında birinciliği elde etmiştir. Ek olarak, bilgisayar ile görüşmeleri yapılırken hata oranları %5 ile %10 arasında olmakta iken bu ağ ile bu oran %3.57'ye ulaşmıştır (Dai vd. 2015).

ResNet tasarımcıları 2015 yılında VGG-19 modelinden esinlenerek bu mimariyi geliştirmişlerdir. ImageNet veri seti için geliştirilen en derin mimarilerden bir tanesidir. Genellikle bir CNN'de birkaç katman birbirine bağlanır ve çeşitli görevleri yerine getirmek için eğitilir. Ağ, katmanlarının sonunda birkaç düzeyde özellik öğrenir. Bu modeldeki evrişimli katmanların boyutu çoğunlukla 33 filtreye sahiptir. ResNet'te, katmanlar aynı çıkış öznelik haritası boyutu için aynı sayıda filtreye sahiptir. Her katman için zaman karmaşıklığını korumak amacıyla öznelik harita boyutu yarıya indirilirse filtre sayısı iki katına çıkar. Katmanları iki adımda evrişimle işleminden geçirerek alt örnekleme doğrudan gerçekleştirir. ResNet son katmanında global bir ortalama ortaklama katmanı ve SoftMax ile etkinleştirilen, tamamen bağlı bir katman bulunur.

Artık (residual) öğrenme, bu katmandan öğrenilen girdi özelliklerinin çıkarılması olarak tanımlanabilir. ResNet öğrenme sürecini her 33 filtre çiftine kısa yol bağlantılarını k . katmanın girişini $(k+x)$ katmana doğrudan bağlayarak gerçekleştirir. Katmanları atlamanın arkasındaki sebep, önceki katmandan gelen aktivasyonları yeniden kullanarak şimdiki katmanın ağırlıklarını öğrenene kadar gradyanların kaybolması sorununu ortadan kaldırmaktır. Ağı eğitirken, ağırlıklar mevcut olanın yanındaki katmanı güçlendirecek ve

ayrıca önceki katmanı sessize alacak şekilde ayarlanacaktır. Bu ağı eğitmenin basit derin evrişimli sinir ağlarını eğitmekten daha kolay olduğu görülmüştür. Aynı zamanda doğruluk azalması sorununu da çözmektedir (He vd. 2015).

ResNet seri olarak çoklu birbirine bağlanan temel bloklar olarak tanımlanabilir ve her bir temel bloğa paralel kısa yol bağlantıları vardır ve bunlarda çıkışına eklenebilmektedir. Şekil 1 'de ResNet'in temel bir bloğu gösterilmektedir (He vd. 2015). Temel bir blok için giriş ve çıkış boyutu eşitse kısa yol bağlantısı basitçe bir ayırt edici matrisidir. Aksi takdirde, boyutu ayarlamak için ortalama havuzlama (küçültme için) ve sıfır dolgu (büyütme için) kullanılabilir. ResNets'teki bir kısa yol bağlantısı için farklı temel blokları karşılaştırmıştır (Şekil 21) ve eklemekten sonra parametrelili bir katman eklemenin ResNet avantajlarını zayıflatabildiğini gösterir, çünkü gradyanların artık çoğalmaları için hızlı bir yol bulunmamaktadır. Ancak bu koşul göz önüne alındığında, ekleme modülünden sonra ReLU veya bırakma gibi parametrelenmemiş bir katman eklemek büyük bir avantaj veya dezavantaj sağlamamaktadır.




Şekil 3.21 Temel ResNet Bloğu (He vd. 2015).

Klasik evrişimli sinir ağının derinliği arttıkça, aşırı uyumdan dolayı belirli sayıda adımdan sonra hatanın artmaya başladığı gözlemlenmiştir. Bu modelde bunun olmasını önlemek için "Residual Block" adı verilen yeni bir yöntem tanıtılmıştır. Diğer mimarilerden ayıran en büyük özelliği, modele bir sonraki katmanı besleyen bloklar eklenerek artık değer oluşmasıdır. Bu yöntemde, x girişi, $F(x)$ adlı bir çıktı elde etmek için evrişim işlemine uygulanır. Bu çıktı doğrudan başka bir bloğa sağlanmaz. Diğer blok için ise $x + F(x)$ sonucunun ReLU işlemine eklenmesiyle elde edilen çıktı verilir. Bu çıktı $H(x)$ ile temsil edilir. Bu mimaride her katman, Şekil 3'te gösterildiği gibi giriş " x " değeri ile birleştirilir, elde edilen " $f(x)$ " değeri bir sonraki katmana iletilir ve matematiksel ifadesi ise Denklem 3.5.3.1' de ifade edilmiştir. (Kızırak ve ark. 2018).

$$H(x) = F(x) + x \quad (3.5.3.1)$$

$F(x)$ 'in çıkışı başka bir bloğa verilmeden önce, x girişi ile birleştirilir ve ReLu fonksiyonuna eklenir. Bu değer, lineer ve ReLu aktivasyon kodları arasına her iki katmanda bir eklenir. $a^{(l)}$ değeri ise bir önceki katmandan gelip, bir sonraki $a^{(l+2)}$ hesabına eklenmektedir (Kızırak vd. 2018).


Genel olarak, bir modeldeki katman sayısını artırmak, performansın artacağı anlamına gelir, ancak gerçekte durum değişmektedir. Bu nedenle, $w^{(l+2)}=0$ olduğunda, yeni teoriye göre, $a^{(l+2)}=b^{(l+2)}$. Bu türevin sıfır değeri üretmesi problemlere neden olur. Bu hoş karşılanmayan bir durumdur (He vd. 2015). Ancak, ilk iki katmandaki $a^{(l)}$ değeri sıfır olsa ve ağ daha hızlı çalışsa da, artık değer beslemesi yeni çıktı denklemini optimize eder. Artık (Residual) blokların içyapısı Şekil 3.22 'de gösterilmektedir.



Şekil 3.22 Artık (Residual) Öğrenme.

Şekil 3.22'yi incelediğimizde “ $\times$ ” girişi değeri ağırlık (W) katmanından geçirilerek “ $F(x)$ ” değeri oluşturulur ve bu sürecin sonunda “ x ” parametresine “ $f(x)$ ” parametresi eklenir (He vd. 2015).

Ana ResNet makalesinde yazarlar 18, 34, 50, 101 ve 152 katmanlı farklı ResNets model konfigürasyonları önermişlerdir. Şekil 3.23’de ResNet 50 mimarisinin görsel olarak ifade edilmiş hali verilmiştir.



Şekil 3.23 ResNet Mimarisi.

Çizelge 3.2’de ResNet katman mimarileri verilmiştir. ResNet mimarileri aktivasyon fonksiyonlarının bloklardan önce ve sonra kullanılmasına göre V1 ve V2 olmak üzere iki versiyonu bulunmaktadır.


Çizelge 3.2 Farklı ResNet Katman Mimarileri.

Katman Adı	Çıkış Büyükliği	18 Katman	34 Katman	50 Katman	101 Katman	152 Katman
Evrişim 1	112x112	7x7,64, Kaydırma Adımı 2				
Evrişim 2	56x56	3x3 Maksimum Havuzlama, Kaydırma Adımı 2				
		3x3,64	3x3,64	1x1,64	1x1,64	1x1,64
		3x3,64 x2	3x3,64	3x3,64	3x3,64	3x3,64
				1x1,256 x 3	1x1,256 x 3	1x1,256 x 3
Evrişim 3	28x28	3x3,128	3x3,128	1x1,128	1x1,128	1x1,128
		3x3,128 x2	3x3,128	3x3,128	3x3,128	3x3,128
				1x1,512 x 4	1x1,512 x 4	1x1,512 x 8
Evrişim 4	14x14	3x3,256	3x3,256	1x1,256	1x1,256	1x1,256
		3x3,256 x2	3x3,256	3x3,256	3x3,256	3x3,256
				1x1,1024x6	1x1,1024x23	1x1,1024x36
Evrişim 5	7x7	3x3,512	3x3,512	1x1,512	1x1,512	1x1,512
		3x3,512x2	3x3,512	3x3,512	3x3,512	3x3,512
				1x1,2028x3	1x1,2028x3	1x1,2028 x3
	1x1	Ortalama Havuzlama 1000 Tamamen bağlı softmax				

3.5.3.4 MobileNetV1 ve MobileNetV2 modeli


Google tarafından geliştirilen MobileNet mimarisi, mobil ve gömülü sistemlerde bilgisayarla görme çalışmaları için başarı sonuçlar üretmesi amaçlanmıştır. Evrişim katmanlarının derinlemesine ayrıştırılabilirliği ile oluşturulmuş bu mimaride bulunan hiperparametreler sayesinde başarı ve modelin hızı arasında seçim yapılabilmesine olanak sağlamaktadır. Parametreler aracılığı ile, araştırmacılar kendi problemleri doğrultusunda ağı istedikleri şekilde değiştirerek sonuca ulaşabilmektedirler. İki farklı MobileNet mimarisi bulunmakta olup, bu mimariler genel olarak benzer olmak ile birlikte aralarından kayda değer fark ise “residual” olarak adlandırılan ters yapılarıdır (Qin vd.

2018). Şekil 3.24 ve Şekil 3.35’de sırası ile MobileNetV1 ve MobileNetV2 mimarisi verilmiştir.



Şekil 3.24 MobileNetV1 Mimarisi

(Qin vd. 2018).




Şekil 3.25 MobileNet V2 Mimarisi

(Qin vd. 2018).


3.5.3.5 Inceptionv1, Inceptionv2 ve Xception modeli

Google araştırmacıları tarafından 2015 yılında, ağ içindeki ağ yapısıyla, kendisinden önce geliştirilen modellere kıyasla diğer modellerden daha iyi bir genişlik imkânı sunan model olarak sunulmuştur (Guo vd. 2016). Inception olarak isimlendirilen bloklar aracılığı ile modelin yapısında kullanılan genişlik işlemleri sağlanmaktadır. Bu işlem ağın derinlik işlemlerini üst üste istiflenen evrişim katmanını yerine inception bloğunun kullanılması ile meydana getirilmesi ile meydana gelmektedir. Naif Inception Modülü olarak isimlendirilen bir blok aracılığı ile 1x1, 3x3, 5x5 evrişim bloklarına aynı anda 3x3 havuzlama işlemini yapmasına olanak tanımaktadır (Szegedy vd. 2015). Yapıla bu

işlemin görsel hali Şekil 3.26’da verilmiştir. Model kendisinden önce geliştirilen modeller ile kıyaslandığında yüksek başarı imkânı sunmasına rağmen bazı dezavantajlara sahiptir. Bunlar sırası ile işlem karmaşıklığı, çıkış boyutu fazlalığı ve parametre sayısıdır. Bunların meydana gelmesinin sebebi ise evrişim katmanlarının fazla olmasıdır. Karşılaşılan bu sorunları gidermek için araştırmacılar, 1x1 evrişim katmanını boyut küçültmek amacı ile Naif Inception bloğunun evrişim işlemlerinden önce kullanmaya başlamışlar ve bu işlemden sonra ReLu aktivasyon fonksiyonunu uygulamışlardır. Bu işlem sonucunda oluşan model InceptionV1 olarak isimlendirilmiştir. Şekil 3.27’de bu modelin yapılı verilmiştir.




Şekil 3.26 Naif Inception Modülü.




Şekil 3.27 InceptionV1 Modelinin Yapısı.

Araştırmacılar, Inceptionv1 ağına başarılı sonuçlarına karşın işlem yükünün halen fazla olmasından dolayı InceptionV2 ağını geliştirmişlerdir. Geliştirilen yeni model ile ilk modelde bulunan 5x5 katmanı kaldırıp bunun yerine yeni mimariye 2 adet 3x3 boyutlu katmanı ekleyerek evrişim işlemini gerçekleştirmişlerdir. Yapılan bu işlem Şekil 3.28’de sunulmuştur. Eklenen 3x3 boyutlu evrişim işlemi 3 katman olacak şekilde 3x1 lik katmanlara bölünmüş ve 3 çıkışlı bir hale gelmiştir. Ağına başarı oranı incelendiğinde ilk katmanlarda başarı oranı az olmakta iken orta katmanlara gelindiğinde başarı oranı artmaktadır. Ek olarak ağda batch normalizasyon ve droup out katmanlarının bulunmasında başarısında pozitif etki göstermiştir. InceptionV2 modelinin yapısı Şekil 3.29’da gösterilmiştir.




Şekil 3.28 5x5 Katmanı Kaldırıp 3x3 Katmanı Eklenmesi



Şekil 3.29 InceptionV2 Modelinin Yapısı.

Xception ağı ise inception modellerinde küçük katkılar yapılarak geliştirilmiş bir yapıya sahiptir. Eklediği katkı ise 1x1 evrişim çıkış kanalına tekrardan evrişim işlemi uygulamasıdır. Ek olarak, bu mimari, Inceptiton bloğunun yerine derinlemesine ayrıştırılabilir bir evrişim bloğu getirilmesi ile oluşan bir Inception modeli olmasıdır. ReLu aktivasyon fonksiyonu kullanılmadığı durumlarda daha başarılı sonuçlar üretmektedir. Genel olarak Inception modeli ise benzer parametrelere sahip olmaktadır. Şekil 3.30'da Xception modeli verilmiştir.




Şekil 3.30 Xception Modeli Yapısı.

3.5.3.6 DenseNet modeli

DenseNet, Huang ve arkadaşları tarafından CNN modellerinde ilk katmanlar ile sonraki katmanlar arasındaki kısa bağlantıların daha derin, daha doğru ve verimli olabileceği öngörüsüyle geliştirilmiştir (Huang vd. 2017). DenseNet klasik CNN modelindeki her katman ile sonraki katmanı arasında bir tane olmak üzere, birbirine tam bağlı katmanlardan oluşur. Normal bir N katmanlı CNN de N adet bağlantı bulunurken DenseNet modelinde her katman kendinden sonra gelen her katmana bağlı olduğundan $N(N+1)/2$ bağlantıdan oluşur. Her katman için, önceki tüm katmanların özellik haritaları girdi olarak kullanılır ve kendi özellik haritaları sonraki tüm katmanlara girdi olarak gönderilir.

Bu sayede DenseNets, ResNet gibi iniş yok olması (vanishing gradient) problemine çözüm getirmeye çalışır, özellik yayılımını güçlendirir, özelliklerin yeniden kullanılmasını teşvik eder ve parametrelerin sayısını önemli ölçüde azaltır. DenseNet'in 121, 169, 201, 264 katmana sahip olan türleri vardır. Yazarların tanıttığı DenseNet modeline ait görsel Şekil 3.31'de verilmiştir.



Şekil 3.31 DenseNet Mimarisi (Huang vd. 2017).


3.5.4 Derin öğrenme kütüphaneleri

3.5.4.1 TensorFlow

Google Brain olarak bilinen, ilk olarak da Distbelief makine öğrenme sisteminin geliştirilmesini sağlayan, Google araştırma ekibi tarafından TensorFlow 2011 yılında geliştirilmiştir (Abadi vd. 2016).

Geliştirilen ilk DistBelief makine öğrenmesi ortamı, konuşma tanıma (Hinton vd. 2012, Zeiler vd. 2013) dil çevrimi (Mikolov vd. 2013, Vinyals vd. 2015), dizi tahmini (Sutskever, 2014), video sınıflandırması (Karpathy v. 2014), dil çevrimi (Mikolov vd. 2013) (Vinyals vd. 2015), görüntü sınıflandırması ve nesne tespiti (Frome vd. 2013), yaya saptama (Angelova vd. 2015), öğretmensiz öğrenme, aktiviteli öğrenme (Nair vd. 2015) gibi birçok alanda kullanılmıştır.

Bu kütüphaneden sonra, makine öğrenmesini daha verimli ve daha çok alanda kullanmak için TensorFlow kütüphanesi geliştirilmiştir. Bu kütüphanenin temelini ise bir dizi matematiksel ifadeler ve bu ifadelerin temsil edildiği akış grafikleri oluşturmaktadır. Akış grafiklerinin temelini her biri 0 veya daha fazla girişe ve 0 veya daha fazla çıkışa sahip olan düğümler oluşturmaktadır. Akış Diyagramları bu düğümlerin durumunu saptamak, güncellemek ve döngü işlemlerindeki kontrolleri sağlamak için veri akış işlemlerini hesaplama imkânı vermektedir.




Şekil 3.32 TensorFlow İşleyiş Diyagramı.

Kütüphanenin açık kaynak kodlu olmasından dolayı geniş çaplı bir kullanıcı kitlesine hitap etmeyi başarmıştır. GPU altyapısına sahip cihazlardan mobil aletler ve tabletlere kadar birçok cihaz üzerinden hesaplama aygıtlarında herhangi bir değişiklik yapılmaksızın kullanılabilmesi mümkündür (Abadi vd. 2016).

3.5.4.2 Caffe

Caffe (Convolution Architecture For Feature Extraction) açık kaynak kodlu bir yazılım olup Berkeley üniversitesi tarafından derin öğrenme uygulamaları için geliştirilmiş bir kütüphanedir. Açık kaynak kodlu olmasından dolayı birçok alandan kullanılma imkânı sunmaktadır.

CaffeNet evrimsel bir ağ için gerekli olan tüm işlemlere olanak veren evrişim, havuzlama, gizli katmanlar, aktivasyon fonksiyonları gibi birçok bileşene imkân vermektedir Jia vd. 2014). Şekil 3.33'te bir CaffeNet örneği gösterilmektedir.



Şekil 3.33 CaffeNet Örneği.

CaffeNet kütüphanesi daha önceden eğitilmiş Model Zoo adında önceden eğitilmiş bir kütüphaneye sahip olup, CUDA, Matlap, Python ve C++ gibi yazılımlarda yer almaktadır.

Theano kütüphanesi LISA laboratuvarı tarafından makine öğrenmesini daha etkili olarak kullanmak için geliştirilen diğer bir yazılımdır. Theano, çok boyutlu matrisler üzerinde verimli işlemler yapmasını ve matematiksel optimizasyonları verimlendirmesi açısından başarılı bir çalışma olmuştur. Python temelli ve açık kaynak kodlu olması tercih edilebilirliğini artırmaktadır. Sınıf oluşturma imkânı sunarak derin öğretici oluşturmaya yapay sinir ağı oluşturmaya tercih etmektedir. (The Theano Development Team, 2016)(Bastien vd. 2012).

Thorch kütüphanesi se açık kaynak kodlu olarak makine ve derin öğrenmeye katkı sunması için Ronan Collobert ve arkadaşları tarafından geliştirilmiştir. Sayısal optimizasyon ve derin öğrenme yapısını birkaç satır kod ile yapabilme imkânını

vermektedir (Collobert vd. 2011). Araştırma merkezler ve üniversitelerden Facebook, Google gibi birçok kuruluş tarafından açık kaynak kodlu olmasından dolayı tercih edilmiştir.

DeepLearning4j(DL4J) uygulaması ile Java ve Scala gibi programların derin öğrenme çalışmalarında kullanılabilmesi için geliştirilmiş bir kütüphanedir (Team D.J.D. 2016). Matlab, Python, C++ gibi dillerde yazılanların aksine java ortamında yer almaktadır. Pek çok derin öğrenme mimarilerine alternatif bir dil ile makine öğrenimine destek verir. Dağıtık CPU ve GPU platformlarında kullanılmak üzere tasarlanmıştır (Kochura vd. 2017).

Keras, Francois Chollet tarafından Phyton dili kullanılarak TensorFlow ve Theano tarafından kullanılması için yazılmıştır. Algoritmaları optimize etmekten aktivasyon fonksiyonlarının seçimine kadar birçok rutine olanak sağlamaktadır. TensorFlow ve Theano kütüphaneleri tarafından desteklenmesine rağmen giriş verilerinin boyutlarının farklı olmasından dolayı başarılı sonuçlar alınması ve arka planda doğru bir şekilde çalışabilmesi için parametrelerine çok dikkat edilerek tasarlanmalıdır (Chollet, 2016).

Lasagne yazılımı ise Thenao yazılımının kullanılmasını kolaylaştırmak için Keras'a alternatif olarak Pyhton kodu ile geliştirilmiştir. Performansı Theano ile aynıdır (Jones, 2015).

Cognitive Network Toolkit (CNTK) kütüphanesi Visuoal Studio'da derin öğrenme uygulamaları geliştirilebilmesi için Microsoft firması tarafından geliştirilmiştir. Evrişimsel sinir ağlarından geri beslemeli sinir ağlarına kadar birçok modelin uygulanmasına olanak sağlamaktadır (Yu vd. 2014).

DIGIT, Derin öğrenme ağlarının geliştirilmesinde kullanılması için Nvida firması tarafından web tabanlı olarak sunulmuştur. Temelinde programlama dilleri bulunmamaktadır, bunun yerine bir içinde ağın yapısının tanımını barındıran bir metin dosyası içermektedir. Görselleştirme araçlarına sahip olması ağın görselleştirilerek çözüm yolu sunmasına imkân sağlamaktadır (Nvidia, 2016).

Pylearn2, Montreal üniversitesi LISA laboratuvarında geliştirilen makine öğrenme kütüphanesidir. Makine öğrenme algoritmalarının yanı sıra Python'da yazılan derin öğrenme koleksiyonu sunar. Bu kütüphane ile genişletilebilirlik ve esnekliğe odaklanılmıştır. Hedef kullanıcıları makine öğrenimi üzerine çalışmalar yapan kişilerdir (Goodfellow vd. 2013).

3.6 Sensör Kanallarından Elde edilen İstatistiksel Öznitelikler

Sırasıyla S ve N sinyali ve uzunluğunu temsil etmek üzere, sinyallere bölüm 3.3’ de bahsedilen YİÖ işlemleri uygulandıktan sonra elde edilen yeni sinyalin sahip olduğu değerler $X = \{X_1, X_2, \dots, X_N\}$ kabul edilerek, sahip olunan istatistiksel öznitelikler Çizelge 3.3’de verilmiştir.

Çizelge 3.3 İşaretlerden Elde Edilen İstatistiksel Öznitelikler.

No	Öznitelik	Formül
1	“Ortalama”	$f1 = \frac{\sum_{i=1}^N X_i}{N}$
2	“Standart Sapma”	$f2 = \sqrt{\frac{\sum_{i=1}^N (X_i - f1)^2}{N}}$
3	“Enerji”	$f3 = \sqrt{\frac{\sum_{i=1}^N (X_i)^2}{N}}$
4	“Entropi”	$f4 = - \sum_{i=1}^N \frac{X_i}{f3} \log\left(\frac{X_i}{f3}\right)$
5	“Korelasyon”	$f5 = \frac{\sum_{i=1}^N i * X_i - f1}{\sigma_x}$
6	“Ardışık mutlak farklar”	$f6 = \frac{\sum_{i=1}^N X_{i+1} - X_i }{N}$
7	“Basıklık”	$f7 = \frac{\sqrt{N(N-1)}}{N-2} \left(\frac{\frac{1}{N} \sum_{x=1}^N (X_i - f1)^3}{\frac{1}{N} \sum_{x=1}^N (X_i - f1)^2} \right)^{3/2}$

No	Öznitelik	Formül
8	“Çarpıklık”	$f8 = \frac{N-1}{(N-2)(N-3)} \left[(N+1) \left(\frac{\frac{1}{N} \sum_{x=1}^N (X_i - f1)^4}{\frac{1}{N} \sum_{x=1}^N (X_i - f1)^2} - 3 \right) + 6 \right]$
9	“Medyan”	$F9 = (n+1)/2$
10	“Minimum”	$f10 = \min\{X_1, X_2, X_3, X_4, \dots, X_N\}$
11	“Maksimum”	$f11 = \max\{X_1, X_2, X_3, X_4, \dots, X_N\}$
12	“Varyasyon katsayısı”	$f12 = \frac{f1}{f2}$

3.7 Performans Ölçütleri

Bu tez kapsamında yapılan çalışmanın başarısının teyidi için çalışma makine öğrenmede sıklıkla kullanılan karşılık matrisi ile yapılmıştır. Çizelge 3.4’de ikili sınıflandırma için oluşturulmuş karışıklık matrisi verilmiştir.

Çizelge 3.4 Karışıklık matrisi.

Sınıflar		Gerçek sınıf	
		Pozitif (1)	Negatif (0)
Tahmin edilen sınıf	Pozitif (1)	DP	YP
	Negatif (0)	YN	DN

- Çizelge 3.4’deki DP (Doğru Pozitif), gerçek sınıfı pozitif ve pozitif olarak sınıflandırılan örnekleri,
- YN (Yanlış Negatif), gerçek sınıfı pozitif olan ve negatif olarak sınıflandırılan örnekleri

- YP (Yanlış Pozitif) ise gerçek sınıfı negatif olan ancak modelin pozitif sınıflandırdığı örnekleri,
- DN (Doğru Negatif): gerçek sınıfı negatif olan ve negatif olarak sınıflandırılan örnekleri temsil etmektedir.

Karışıklık matrisi bulunduğundan sonra değerlendirme ölçütleri bu matris yardımıyla bulunabilir:

- Doğruluk (Accuracy): Model değerlendirme kriterleri arasında en belirleyici ölçüttür. Modelin doğru yapılan tahmin sayısının tüm örnek sayısına bölünmesiyle elde edilir. Doğruluk değeri Denklem 3.7.5'deki eşitlikle hesaplanabilir.

$$\text{Doğruluk oranı} = \frac{DP + DN}{DP + DN + YP + YN} \quad (3.7.5)$$

- Kesinlik (Precision): Modelin doğru tahmin ettiği pozitif sınıf sayısının tüm pozitif sınıf sayısına bölünmesiyle bulunabilir. Hassasiyet değeri Denklem 3.7.6'deki eşitlikle hesaplanabilir.

$$\text{Kesinlik (P)} = \frac{DP}{DP + YP} \quad (3.7.6)$$

- Hassasiyet (Recall/sensitivity): Modelin doğru pozitif sınıf olarak tahmin ettiği sayının, toplam pozitif tahmin edilen sınıf sayısına bölünmesiyle bulunur. Kesinlik değeri Denklem 3.7.7'deki eşitlikle hesaplanabilir.

$$\text{Hassasiyet (R)} = \frac{DP}{DP + YN} \quad (3.7.7)$$

- F-ölçütü (f-score): Kesinlik ve hassasiyet değerlerinin daha anlamlı bir ölçüt olabilmesi için kesinlik ve hassasiyet değerlerinin ağırlıklı ortalamasıyla f ölçütü hesaplanır. Doğruluk değerinden sonra en çok kullanılan değerlendirme ölçütüdür. F-ölçütü Denklem 3.7.8'deki eşitlikle hesaplanabilir.


$$F - \text{Ölçütü} (F - \text{Measure}) = 2(\text{Kesinlik} * \text{Hassasiyet}) / (\text{Kesinlik} + \text{Hassasiyet}) \quad (3.7.8)$$

4. ÖNERİLEN KİŞİ TANIMA MODELLERİ

Önerdiğimiz kişi tanıma modelleri bu aşamada verilmiştir. Geliştirildiğimiz modeller yerel ikili örüntü ve derin transfer öğrenme tabanlı iki farklı kısımdan oluştuğundan bu kısımda ki bölüme ayrılarak teker teker aşamaları ile anlatılmıştır.

4.1 Önerilen YİÖ Modeli

Çalışmamızın bu kısmında yerel ikili örüntüler kullanarak öznitelikler elde edilmiş ve bu öznitelikler doğrultusunda **literatürde ilk defa** sensör sinyalleri kullanarak kişi tespiti işlemi gerçekleştirilmiştir. Kişi tespiti işlemi ile birlikte kişilerin sergilediği hareketleri de tespit edilmesi işlemleri gerçekleştirilmiştir. Tez kapsamından yapılan bu çalışmada önerdiğimiz kişi tanıma sisteminin görsel hali Şekil 4.1’de sunulmuştur. Geliştirilen sistem 5 aşamadan meydana gelmektedir. Her bir aşamasının kısa açıklaması da şeklin aşağısında verilmiştir.



Şekil 4.1 Kişi Tanıma Sistemi (Kılıç vd. 2021).

Aşama 1-2: Çalışmanın ilk kısmını oluşturan bu bölümde 4 bay ve 4 bayan bireyin (vücutta bulunduğu noktalar ise göğüs hizasında, sağ el bileğinde, sol el bileğinde, sağ (diz üstü) ve sol bacaklarında (diz üstü) olarak belirlenmiştir) sensörler (manyetometre, jiroskop ve ivmeölçer) giydirilmiştir. Bireylerin 19 farklı hareketi sergilemesi sağlanmış ve elde edilen sinyaller kayıt altına alınmıştır.

Aşama 3: Geliştirilen 1D-LBP ve 1D-FbLBP yöntemler ilk elde edilen sinyallere uygulanmış ve dönüşümler yapılarak farklı sinyaller üretilmiştir. Üretilen yeni sinyaller üzerinden ki değerler ise 0 ile 255 arasındaki değerlerden oluşmaktadır.

Aşama 4: 1D-LBP ve 1D-FbLBP işlemleri uygulandıktan sonra elde edilen yeni sinyallerin histograma dönüştürülmesi bu aşamanın temelini oluşturmıştır.

Aşama 5: Oluşturulan histogramdan öznitelik elde edilmesi bu aşamada gerçekleştirilmiştir. Bu öznitelikler Çizelge 3.3’de verilmiştir.

Blok 6: Elde edilen öznitelikler “Karar Destek Vektörleri (SVM)”, “Random Forest(RF)”, “Yapay Sinir Ağları(YSA)”, “K en yakın komşu (Knn)” gibi farklı makine öğrenmesi yöntemler ile 10 katlı çapraz geçerlilik testine göre sınıflandırma işlemleri gerçekleştirilmiştir.

4.2 Önerilen Transfer Öğrenmesi Modelleri

Bu çalışmada Xsens MTx sensörler aracılığıyla elde edilen ivmeölçer, jiroskop ve manyetometre sinyalleri kullanılarak transfer derin öğrenme yöntemleri ile bir biyometrik sistem geliştirilmiştir.

Transfer derin öğrenme yöntemleri, bilgisayarların daha fazla veriyi daha az zamanda işlemeye başlaması ve özellikle GPU destekli bilgisayarların yaygınlaşması ve gelişmesi ile birlikte makine öğrenmesinin temel yapı taşlarından biri haline gelmiştir. Büyük veri kümeleri için, derin öğrenme yöntemleri yüksek başarı oranlarına ulaşmıştır.

Derin öğrenme; el yazısı tanıma, obje sınıflandırma, obje bulma, sahne anlama, yüz tanıma gibi pek çok bilgisayarla görü ve kişi tanıma probleminde büyük başarılar elde etmektedir. Bununla birlikte, milyonlarca parametre derin öğrenme yöntemlerinde ayarlanmalıdır ve grafik işlem birimi, tensör işlem birimi gibi yüksek maliyetli donanıma da ihtiyaç duymaktadır.

Derin ağların en önemli sorunlarından biri ağırlık atamasıdır. Derin öğrenme yöntemleri, doğru ağırlık atamak için büyük veri kümesine ihtiyaç duymaktadır ve bu işlemin


yürütme süresi uzundur. Bu sorunun üstesinden gelmek için önceden eğitilmiş ağlar kullanılmaktadır ve bu ağlar genellikle ImageNet veri kümesinde eğitilmektedir. Önceden eğitilmiş ağlarda, hesaplanan nihai ağırlıklar kullanılmaktadır. Bu nedenle, önceden eğitilmiş ağ kullanılarak kısa bir yürütme zamanında yüksek sınıflandırma oranları elde edilebilmektedir.

Bu çalışmada hem büyük ve hem de küçük veri setleri için sinyallerden kişi tespitini büyük bir başarı ve doğruluk ile sağlanması amaçlanmıştır. Sensörlerden elde edilen sinyaller öncelikle görüntülere dönüştürülmüş daha sonra derin transfer yöntemler kullanılarak kişi tanıma işlemi gerçekleştirilmiştir.

Bu çalışmada, kişi tanıma için sıklıkla kullanılmakta olan ResNet, VGG, MobileNet, DenseNET, Inception ve Xception evrimsel sinir ağı modellerinin, başarılı sonuçlar vermesinden dolayı kişi tanımlama problemi için de uygun olabileceği öngörülmüştür.

Seçilen sinir ağları mevcut katman ağırlıklarıyla beraber alınıp sonra veri setimiz ile transfer öğrenme (transfer learning) işlemleri gerçekleştirilmiştir. Küçük veri kümelerine sahip problemler için de derin öğrenme yaklaşımının kullanılabileceği gösterilmektedir. Bu şekilde nesne sınıflandırma ve tanıma için sıklıkla tercih edilen mimariler, kişi tanıma problemini çözüme ulaştırmak için de başarılı sonuçlar üretecek hale getirilmiştir.

Bu çalışmanın ana katkıları giyilebilir sensörlerden (ivmeölçer, jiroskop ve manyetometre) ölçülen sinyallerden biyometrik bir sistem geliştirilmiştir. Biyometrik sistem için yeni bir yaklaşım önerilmiştir. Kişi tanıma için transfer derin öğrenme yöntemleri kullanılmıştır. Özellik seçimi ve sınıflandırma işlemleri için de Relief özellik çıkarma işlemleri gerçekleştirilerek sınıflandırma yapılmıştır.



Şekil 4.2 Transfer Öğrenmesi Sınıflandırma Şeması (Kılıç vd. 2020).

Bu çalışmada sensör sinyalleri giriş olarak kullanılmıştır. Bununla birlikte, özellik çıkarıcı olarak önceden eğitilmiş derin evrişimli ağlar seçilmiştir. Bu nedenle kullanılan 1D sensör sinyalleri 2D matrise dönüştürülmesi veya spektrumları çıkarılması sağlanmalıdır. Bu çalışmada önişleme yöntemi olarak vektörden matrise dönüşüm seçilmiştir. Kullanılan vektörden matrise dönüşümün sözde kodu, Algoritma olarak aşağıda verilmiştir.

Giriş : Ham 1D (boyutlu) 5625 adet sensör sinyali (S)

Çıktı: Gri level 125*45 boyutlu resim (Im)

```

1: count =1;

2: for i=1 to 125 do

3: forj=1 to 45 do

4:  $Im(i,j) = S(count)$ ;

5: count=count+1;

6: end for j;

7: end for i;
```

8: min maks normalizasyonu ile Im i normalize et

Yukarıdaki algorithmadan görüldüğü gibi, 1D ham sinyal 125×45 boyutlu görüntüye dönüştürülmüştür. Bunun sebebi, kullanılan veri kümesi metin dosyalarından oluşması ve her metin dosyası 125 satır ve 45 sütun içermesidir. Bu nedenle matris boyutu olarak 125×45 'i seçilmiştir. Bu aşamanın matematiksel açıklaması da aşağıda gösterilmiştir.

$$Im = \text{vec2mat}(S, [125 \times 45])$$

$$New X_i = \text{round} \left(\left[\frac{X_i - \text{Min}(X)}{\text{Max}(X) - \text{Min}(X)} \right] \times 255 \right)$$

$\text{vec2mat} (..)$ vektörden matrise dönüşümü temsil eder ve ikinci denklem min – maks normalizasyonu tanımlar. Sensör sinyallerinden 8 bitlik gri ölçekli görüntüyü hesaplamak için min-maks normalleştirme kullanılmıştır.


Bu işlem sonucunda 9120 adet görsel elde edilmiştir. Bu görsel problemimiz doğrultusunda kişilere, kişilerin sergilediği aktivitelere, sensörlerin bulunduğu bölgelere ve her bir sensöre göre etiketlenilerek sınıflandırma işlemleri için hazır hale getirilmiştir. Veri setinde bulunan görüntüler kullanılacak modellere göre ayarlamalar ile çalışmanın diğer aşamasına geçilmiştir.

Elde edilen görüntülerden sonra transfer derin öğrenme de sıklıkla kullanılan VGG, ResNet, MobileNet, DneseNet, Inception ve Xception modelleri ağı yüklenmiştir. Hazır modeldeki katmanlarda kenar, köşe, çizgi, renk gibi görüntüler için düşük öznetelik olarak adlandırılan genel özellikler bulunurken, daha yüksek katmanlarda probleme özel yüksek öznetelikler bulunmaktadır.

Sonraki aşamada, kullanılan hazır modeller ImageNet veri setini sınıflandırmak için eğitilmişlerdir. Imaganet veri setinin seçilmiş olması başarısının kanıtlamış ve büyük bir veri seti olmasından dolayı transfer öğrenme problemlerinde sıklıkla kullanılmasındandır. Imagenet veri setinde 1000 sınıf bulunmaktadır. Sınıflandırma problemine özel olarak son softmax istediğimiz şekilde sınıf sınıflandırabilecek şekilde değiştirilmiştir ve bu

katman problemimiz sınıflandırma olduğu için sınıflandırma katmanı olarak seçilmiştir. En sonunda sınıflandırma işlemi gerçekleştirilmiştir.

Bu çalışmada örnek olarak verdiğimiz, önceden eğitilmiş ResNet (ResNet50, ResNet101, ResNet152) kullanılmıştır. Bu ağlar ImageNet üzerinde önceden eğitilmiştir. Bu ağlar sırasıyla 50 (177 alt katman), 101 (347 alt katman) ve 152 (347 alt katman) katmana sahiptir. Bu ağlar, bu çalışmada öznetelik çıkarıcılar olarak kullanılmıştır. Bu nedenle, bu ağların softmax ve sınıflandırma katmanları kullanılmamaktadır. Bu ağların tümü tamamen bağlı (FC) 1000 katmana sahiptir. Önerilen ResNet topluluğunun grafik açıklaması Şekil Şekil 4.3'de gösterilmektedir.



Şekil 4.3 Önerilen ResNet Modelinin Grafik Açıklaması.


Şekil 4.3'de görüldüğü gibi 1000 özellik çıkarılmıştır. Daha sonra bu özellikler birleştirilerek 3000 son özellik elde edilir. Bu bölümün matematiksel açıklaması şöyledir:

$$F_1 = \text{ResNet50}(\text{Im})$$

$$F_2 = \text{ResNet101}(\text{Im})$$

$$F_3 = \text{ResNet152}(\text{Im})$$

ResNet50, ResNet101 ve ResNet152, özellik çıkarma yönteminin çıkarma işlevini içermektedir. Bunların FC1000 (tam bağlantı) katmanını kullanmıştır ve her özellik çıkarma işlevi 1000 özellik üretir. F1, F2 ve F3, sırasıyla derin ResNet50, ResNet101 ve ResNet152 özellik oluşturma yöntemlerinin özellik vektörleridir.



Şekil 4.4 Derin Özellik Oluşturma Vektörü Grafik Gösterimi.

Daha önceki çalışmalar aktivitelerin tanımlanması görevini çözmek için transfer öğrenme yerine, genellikle SVM ve kNN algoritması gibi geleneksel makine öğrenimi yöntemleri kullanılmıştır. Bu çalışmaların çoğu, el yapımı istatistiksel özellikleri girdi veri setinin ana parçası olarak ele almıştır; bu durum da büyük veri setlerinden aktivite tanıma işlemlerinde büyük maliyete sebep olmuştur. Bu konudaki, önceki çalışmalara göre, hem

tahmin dođruluđu hem de tanıma dođruluđu pratik gereksinimleri karşılamaktaydı. Çalışmamızda aktivite tanıma görevini bu iki yönden çözmeyi başardık. Dahası, literatürde ilk olarak hareketlerden kişi tanıma işleminide transfer derin öğrenme yöntemleri ile yapmış bulunmaktayız.



5. DENEYSEL SONUÇLAR


Bu tez çalışması kapsamında, günümüzde kullanılması git gide artmakta olan mobil telefonlardan giyilebilir sensörlere kadar insanların taşımış oldukları sensörler aracılığı ile elde edilen verilerin kişileri tanıma üzerindeki etkisi ortaya çıkarılmaya çalışılmıştır. Çalışma kapsamında elde edilen sinyallerden öznitelikler çıkarılması amacı ile ilk etapta görüntü işlemede sıklıkla kullanılan yerel ikili örüntü (LBP) yöntemi üzerinden öznitelik çıkarılmıştır. Sensör sinyallerinin yerel ikili yöntemlerinden “One Dimensional Local Binary Pattern” ve “1D Feature Based Local Binar Pattern” yöntemlerine uygulanması ilk bizim tarafımızdan yapılmış olup bu yöntemler ile ilk olarak da sinyaller aracılığı ile kişi tespiti yapılmıştır. Seçtiğimiz veri seti giyilebilir sensörler aracılığı ile günlük yaşamdan sıklıkla kullanılan hareketler olduğu için geliştirdiğimiz yöntemlerde kişi tanınmasına ek olarak hareketlerin de tespiti yapılmıştır.

LBP yöntemleri ile yaptığımız çalışmamızda başarılı sonuçlar elde ettiğimizde tezin amacı olan sensör sinyallerinden elde edilen veriler ile kişi tespitinin derin öğrenme algoritmaları ile yapılması üzerine yoğunlaşmıştır. CNN algoritmaları derin öğrenmenin en popüler örneklerinden olması ve transfer öğrenmelerine uygunluğundan dolayı CNN temelli derin öğrenme algoritmalarına yoğunlaşmıştır. VGG ve ResNet’ten MobileNet e kadar birçok algoritma transfer öğrenme yöntemleri kullanarak problemimize uygun olarak geliştirilmiş ve sonuçları verilmiştir.


5.1 Klasik Yerel İkili Örüntü Sonuçları

Bu tez çalışması kapsamında kullanılmış olan veri seti, 4 erkek ve 4 kadın olmak üzere 8 bireyin günlük yaşamda sıklıkla sergilenen 19 farklı fiziksel aktivitenin sergilenmesi ile elde edilen sinyalleri içermektedir. Her eylem 60 bölüme ayrılmıştır. Bu nedenle veri seti $19 \times 8 \times 60 = 9120$ işretden oluşmaktadır. İlk olarak, işaretlere 1D-LBP ve 1D-FbLBP yöntemleri uygulanarak yeni işaretlerden istatistiksel özellikler oluşturulmuştur. Önerilen yöntemin işaretler üzerindeki etkisi aşağıdaki örnekte verilmiştir. Şekil 5.1’ de, 8 deneğe (4 bay ve 4 bayan) bağlı aynı sensörden (ivmeölçer X eksen) ölçülen işaretleri


göstermektedir. Daha sonra bu işaretlere 1D-LBP uygulanarak oluşturulan işaret Şekil 5.2'de gösterilmiştir. 1D-LBP ve 1D-FbLBP uygulandıktan sonra elde edilen yeni işaretlerin histogramları Şekil 5.3 ve Şekil 5.4'de gösterilmektedir. Histograma baktığımızda 1D-LBP ve 1D-FbLBP modellerinin farklı desen dağılımlarına sahip olduğunu görebiliriz.




Şekil 5.1 4 bay ve 4 bayan deneğe ait oturma eylemi ivme sensörü X eksenî işaret örnekleri.



Şekil 5.2 8 deneğe ait işaretlere 1D-LBP uygulandıktan sonra oluşan yeni işaretler.



Şekil 5.3 İşaretlere 1D-LBP uygulandıktan sonra oluşan yeni işaretlere ait histogramlar.



Şekil 5.4 İşaretlere 1D-FbLBP uygulandıktan sonra oluşan yeni işaretlere ait histogramlar.

Şekil 5.3 ve Şekil 5.4’de 8 deneğin gövdesinde bulunan ivme sensörün X ekseninden elde edilmiş işaretler ve yeni elde edilen işaretlere önerdiğimiz yöntemin uygulanması sonucu oluşan 1D-LBP ve 1D-FbLBP işaretlerin histogramları bulunmaktadır. Histogramda her değer bir örüntüyü ifade eder. İşaretlere bakıldığında örüntülerin her birey için farklı olduğu görülmektedir. Kişi tanıma için farklı örüntülerin elde edilmesi önemli olmaktadır.

Giyilebilir işaretlerin kişi tanıma probleminin çözümü için 10 kat çapraz doğrulama testine göre sınıflandırma işlemi için farklı makine öğrenmesi yöntemleri (Knn, RF, A1DE, A2DE ve ANN gibi) kullanılmaktadır. Sınıflandırma aşamasında Weka açık kaynak yazılımı kullanılmıştır. Çizelge 5.1’de, 1D-LBP ve 1D-FbLBP işaretçilerinden elde edilen özellikleri kullanarak gözlemlenen başarı oranını göstermektedir.

Çizelge 5.1 1D-FbLBP öznitelikler kullanılarak kişi tanıma başarı oranları (%).

Öznitelikler	Knn	RF	A1DE	A2DE	ANN
1D-FbLBP	81.3268	88.0702	91.8281	73.9145	81.1404
1D-LBP	77.8838	88.4649	86.9408	66.7434	74.6145

Çizelge 5.1 incelendiğinde en yüksek başarı oranı her iki öznitelik grubu için RF makine öğrenmesi yöntem ile elde edilmiştir. 1D-FbLBP öznitelikler ile kişi tanıma başarısı %91.8281 olarak gözlenmiştir. 1D-LBP öznitelikler ile ise en yüksek başarı oranı %88.4649 olarak Knn ile elde edilmiştir.

1D-FbLBP yöntemi 1D-LBP yöntemine göre daha ayrıştırıcı öznitelikler sunmaktadır. Bu nedenle 1D-FbLBP yönteminin sağladığı öznitelikler aşağıda farklı şartlar için incelenmiştir. Çizelge 3.1’ de belirtilen 19 farklı harekete ait işaretlerin tümünün kullanılması ile kişi tanıma gerçekleştirilmiştir.

Her hareketin kişi tanıma üzerindeki etkisini belirtmek için gerçekleştirilen her hareket için kişi tanıma işlemi gerçekleştirilmiştir. Her hareket için elde edilen kişi tanıma performans değerleri Çizelge 5.2’de sunulmuştur.

Çizelge 5.2 Hareketlere göre Kişi tanıma Başarı Oranları (%).

Hareket	Accuracy	Precision	Recall	F-Measure
A1	96.88	97.1	96.9	96,9
A2	98.13	98.2	98.1	98,1
A3	98.13	98.2	98.1	98.1
A4	99.79	99,8	99.8	99.8
A5	98.33	98.4	98.3	98.3
A6	99.38	99.4	99.4	99.4
A7	91.04	91.1	91	91
A8	75.00	75.3	75	74.8
A9	99.58	99.6	99.6	99.6
A10	100.00	100.0	100	100
A11	99.79	99.8	99.8	99.8
A12	100.00	100.0	100	100
A13	99.38	99.4	99.4	99.4
A14	99.79	99.8	99.8	99.8
A15	99.38	99.4	99.4	99.4
A16	98.96	99	99	99
A17	97.08	97.8	97.9	97.9
A18	98.33	98.4	98.3	98.3
A19	82.08	81.9	82.1	81.9

Çizelge 5.2 incelendiğinde önerdiğimiz öznelilik çıkarım yöntemi ile kişi tanıma başarılı sonuçlar elde edildiği anlaşılmaktadır. A10 (4km/s hızla koşu bandında yürüme) ve A12 (8km/s hızla koşma hareketi) hareketleri için %100 başarı elde edilmiştir.

En düşük başarı A8 (asansör hareket halindeyken ayakta durma hareketi) hareketi için gözlenmiştir. Asansörde hareket halindeyken ayakta durmak kişi tanıma %75 başarı göstermiştir. Genel olarak diğer tüm hareketler için kişi tanıma başarılı sonuçlar gözlenmiştir.

Giyilebilir sensör işaretlere 1D-FbLBP yöntemi uygulandıktan sonra 12 farklı istatistiksel öznitelik elde edilmiştir. Veri seti 45 farklı kanaldan elde edilen işaretlerden oluşturulmuştur. Dolayısıyla her kanal için istatistiksel öznitelikler elde edilmiştir. Her istatistiksel öznitelik her kanal için alınmıştır. Dolayısıyla her istatistiksel öznitelikten 45 adet bulunmaktadır. Hangi öz niteliğin kişi tanımda etkin olduğunu belirtmek için her öznitelik için sınıflandırma işlemi gerçekleştirilmiştir. Başarı oranları Çizelge 5.3’de sunulmuştur. Sınıflandırma işlemi için RF metodu kullanılmıştır.

Çizelge 5.3 Kişi Tanımda İstatistiksel Özniteliklerin Başarı Oranları (%).

Öznitelik	Öznitelik	1B-FbLBP
Ortalama	45	32.5
Standart Sapma	45	82.2
Enerji	45	81.9
Entropi	45	83.4
Korelasyon	45	82.3
Ardışık mutlak farklar	45	91.6
Medyan	45	32.5
Basıklık	45	73.7
Çarpıklık	45	71.2
Minimum	45	45.7
Maksimum	45	62.4
Varyasyon katsayısı	45	81.8

Çizelge 5.3’e bakıldığında kişi tanıma en etkin öz niteliğin ardışık mutlak farklar öz niteliği oluğu görülmektedir. Sadece bu öz niteliğin kullanılması ile %91.6886 başarı oranı gözlemlenmiştir. Giyilebilir sensör işaretlerinden sadece bu öz niteliğin elde edilmesi ile kişi tanıma gerçekleştirilebilir. En az başarılı özellikler, ortalama, ortanca ve en küçük özelliklerin yer aldığı Çizelge 5.3’de görülebilir. Veri seti ivmeölçer, jiroskop

ve manyetometre sensörlerinden elde edilen sinyalleri içermektedir. 5 birim sensör grubunun tamamında ivmeölçer, jiroskop ve manyetometre sensörleri bulunur. Her sensör tipi aynı sayıda kullanılır. Sensör türünün kişi tanıma etkili olduğunu göstermek için her sensörden elde edilen özniteliklerin kullanılması ile meydana gelen başarı oranları Çizelge 5.4’de sunulmuştur. Her sensör grubu için 180’ar öznitelik bulunmaktadır. Sınıflandırma işlemleri RF ile gerçekleştirilmiştir.

Çizelge 5.4 Sensör Türlerine Göre Kişi Tanıma Başarı Oranları (%).

Sensör Türü	Öznitelik	1D-FbLBP
İvmeölçer	180	87.6
Jiroskop	180	73.4
Manyetometre	180	83.5

Çizelge 5.4 incelendiğinde en başarılı sonuçların ivmeölçer sensörünün elde ettiği işaretlerden oluşan öznitelikler meydana geldiği anlaşılmaktadır. İvmeölçer sensöründen elde edilen özniteliklerin kullanılması ile %87.6 başarı oranı gözlenmiştir. En az başarılı sonuçlar ise Jiroskop sensöründen elde edilen öznitelikler ile %73.4 başarı oranı gözlenmiştir. Genel olarak başarılı bir kişi tanıma sistemi için tüm sensör türlerin birlikte kullanılması gerekmektedir. Sensörler deneklerin göğüs, kollar ve bacakları olmak üzere 5 farklı bölgeye takılmıştır. Hangi bölgeden elde edilen özniteliklerin daha başarılı olduğunu incelemek için her bölgeden elde edilen sinyallerin öznitelikleri oluşturulmuştur. Bölgelere göre 1D-MLBP özniteliklerin RF ile başarı oranları Çizelge 5.5’de verilmiştir. Her bağlantı bölgesi için 108’er öznitelik bulunmaktadır. Sınıflandırma işlemleri RF ile gerçekleştirilmiştir.

Çizelge 5.5 Sensör Bağlantı Bölgesine göre Kişi Tanıma Başarı Oranları (%).

Bağlantı Bölgesi	Öznitelik	1D-FbLBP
Gövde	108	76.9
Sağ Kol	108	74.7
Sol Kol	108	71.6
Sağ Bacak	108	77.8
Sol Bacak	108	74.9

Çizelge 5.5 incelendiğinde kişi tanıma işlemi için en başarılı özniteliklerin sağ bacağı takılı sensörlerden elde edildiği anlaşılmaktadır. Sağ bacak bölümünden elde edilen işaretler kişi tanıma için daha ayırt edici bilgiler sağlamıştır. Bu öznitelikler ile %77.8 başarı oranı gözlenmiştir. Genel olarak tüm bölgeler kişi tanımada birbirine yakın başarı oranları göstermiştir.


5.2 ResNet Modeli ile Elde Edilen Sonuçlar

Bu tez çalışması kapsamında kullanılmış olan veri seti, 4 erkek ve 4 kadın olmak üzere 8 bireyin günlük yaşamda sıklıkla sergilenen 19 farklı fiziksel aktivitenin sergilenmesi ile elde edilen sinyalleri içermektedir. Her hareket 60 segmente bölünmüştür. Dolayısıyla veri seti $19 \times 8 \times 60 = 9120$ sinyal matrislerinden oluşmaktadır. Bu sinyal matrisleri görüntülere dönüştürüldükten sonra ResNet derin transfer öğrenme teknikleri kullanılmıştır. Sonuç olarak sistemimizin başarısını test etmek için 9120 tane resim elde edilmiştir. 5 farklı ResNet mimarisi kullanılmıştır.

Başarı oranları ($100 * \frac{\# True\ classified}{\# True\ classified + \# False\ classified}$ (%)) olarak hesaplanmıştır. Kişi tanıma için ResNet versiyon 1 (ResNetV1) ve ResNet versiyon 2 (ResNetV2) mimarileri kullanılarak elde edilen başarı oranları Çizelge 5.6’da sunulmuştur.

Çizelge 5.6 ResNet Modelleri Başarı Oranları (%).

Model	ResNetV1 Modelleri	ResNetV2 Modelleri
ResNet-18	89.29	89.49
ResNet-34	91.40	91.43
ResNet-50	92.38	92.82
ResNet-101	93.20	93.61
ResNet-152	93.61	94.21




Şekil 5.5 ResNet Modellerinin Kişi Tanıma Üzerindeki Başarısı (%).

Çizelge 5.6 ve Şekil 5.5’de ResNet V1 ve V2 yöntemler ile 19 farklı harekete ait sinyallerin tümünün kullanılması ile kişi tanıma gerçekleştirilmiştir. ResNet ağların iterasyon sayısı arttıkça öğrenmenin iyileştiği görülmektedir. Tüm hareketlere ait görüntüler kullanılarak en iyi sonuç %94.21 olarak 2.versiyon ResNet-152 ile gözlenmiştir. Birinci versiyon ResNet (V1-ResNet) ağlarda en iyi sonuç %93.61 olarak ResNet-152 ile elde edilmiştir.

Her hareketin kişi tanıma üzerindeki etkisini belirtmek için gerçekleştirilen her hareket için kişi tanıma işlemi gerçekleştirilmiştir. Her harekete ait 480 görüntü bulunmaktadır. Her hareket için elde edilen kişi tanıma performans değerleri Çizelge 5.7’de verilmiştir. Her hareket için en iyi sonuçlar grafiksel olarak Şekil 5.6’da verilmiştir.

Çizelge 5.7 Hareketlere Göre Sınıflandırma Başarı Oranları (%).

Aktivite	Resnet50	ResNet101	ResNet152	ResNet50V2	ResNet101V2	ResNet152V2
A1	98.00	98.00	98.00	98.00	98.00	100.00
A2	100.00	98.00	100.00	98.00	100.00	100.00
A3	100.00	98.00	85.00	100.00	100.00	100.00
A4	99.00	98.00	99.00	94.00	100.00	100.00
A5	98.00	96.00	98.00	96.00	98.00	98.00
A6	96.00	99.00	96.00	99.00	88.00	96.00
A7	98.00	100.00	100.00	98.00	96.00	98.00
A8	88.00	86.00	92.00	69.00	86.00	82.00
A9	99.00	99.00	99.00	98.00	98.00	100.00
A10	98.00	98.00	98.00	100.00	96.00	98.00
A11	98.00	100.00	99.00	92.00	100.00	100.00
A12	100.00	100.00	96.00	98.00	96.00	100.00
A13	100.00	98.00	98.00	98.00	96.00	100.00
A14	99.00	96.00	98.00	98.00	94.00	96.00
A15	98.00	100.00	96.00	100.00	98.00	98.00
A16	98.00	100.00	98.00	98.00	92.00	100.00
A17	81.00	90.00	81.00	90.00	86.00	90.00
A18	84.00	81.00	80.00	69.00	71.00	84.00
A19	56.00	60.00	75.00	56.00	65.00	63.00



Şekil 5.6 Hareketlere Göre En İyi Başarı Oranları (%).

Çizelge 5.7’ e bakıldığında farklı mimarideki ResNet transfer derin öğrenme metotları ile kişi tanıma yüksek sonuçlar elde edildiği görülmektedir. Neredeyse tüm hareketler için kişi tanıma başarı oranı %100 olarak gözlenmiştir. Farklı mimarideki ResNet mimarilerine bakıldığında en başarılı tekniğin ResNet-152V2 olduğu görülmektedir.


Bu yöntem ile A1(“oturma”), A2(“ayakta durma”), A3(“sırt üstü yatma”), A4(“sağ tarafa yatma”), A9(“otoparkta yürüme”), A11(“4km/s hızla yere 15 derecelik açı ile koşu bandı yürüyüş”), A12(“8km/s hızla koşma”), A13(“step egzersiz yapma”) ve A16(“dikey pozisyonda bisiklet sürme”) hareketleri için %100 başarı oranı gözlenmiştir. Sonuçlara bakıldığında A8(asansör hareket halindeyken ayakta durma), A17(“kürek çekme”),

A18(“sıçrama”) ve A19(“basketbol oynama”) hareketleri için kişi tanımda diğer hareketlere göre daha az başarılı bulunmuştur.

Sensörler deneklerin göğüs, kollar ve bacaklar olmak üzere 5 farklı bölgeye takılmıştır. Bölgelerin kişi tanıma işlemi üzerindeki başarısını tespit etmek için her bölgeden elde edilen sinyaller görüntülere dönüştürüldükten sonra ResNet derin transfer teknikleri uygulanmıştır. Bölgelere göre görüntüler kullanıldığında görüntü boyutları 125x9 olarak daha düşük boyutta kullanılmıştır. Elde edilen başarı oranları Çizelge 5.8’de verilmiştir. Farklı ResNet mimarilerine göre elde edilen en yüksek başarı oranları da Şekil 5.7’de verilmiştir.


Çizelge 5.8 Sensör Bağlantı Bölgesine göre Kişi Tanıma Başarı Oranları (%).

Bölge	ResNet50	ResNet101	ResNet152	ResNet50v 2	ResNet101v 2	ResNet152v 2
Göğüs	91.00	94.00	95.00	93.00	94.00	93.00
Sağ kol	93.00	94.00	92.00	93.00	92.00	94.00
Sol Kol	91.00	90.00	92.00	91.00	90.00	89.00
Sağ Bacak	92.00	93.00	95.00	95.00	94.00	93.00
Sol Bacak	92.00	95.00	91.00	91.00	95.00	94.00



Şekil 5.7 Farklı ResNet Mimarilerine Göre Elde Edilen En Yüksek Başarı Oranları (%).

Çizelge 5.8’de görüldüğü gibi kişi tanıma için en iyi başarı sağ bacak bölümündeki sensörlerden oluşturulmuş görüntülerden elde edilmiştir. Sağ bacak bölümünden elde edilen sinyaller kişi tanıma için daha ayırt edici bilgiler sağlamıştır. Bu bölümdeki görüntüler ile %95 başarı oranı gözlenmiştir. Genel olarak tüm bölgeler kişi tanımada birbirine yakın başarı oranları göstermiştir.



Şekil 5.8 ResNet Modellerinin Kişi Tanıma Üzerindeki Performansları.

Şekil 5.8’de kişi tanıma problemi üzerinde ResNet Versiyon 1 ve Versiyon 2 modellerinin kişi tanıma üzerindeki başarısı model doğruluk performansına göre sunulmuştur. Sol kısımdaki grafikler versiyon 1’i sağ taraftaki grafikler versiyon 2’yi temsil etmektedir. A ResNet 50’yi, B ResNet 101’i ve C ResNet152’yi ifade etmektedir


5.3 Diğer Derin Transfer Öğrenme Tekniklerine ilişkin Sonuçlar

Derin transfer öğrenme teknikleri ile kişilerin sınıflandırılması işlemi VGG16, VGG19, MobileNetV1, MobileNetV2, DenseNet121, DenseNet169, DenseNet201, InceptionV3 ve Xception derin transfer öğrenme teknikleri kullanılarak da yapılmıştır. Kişi tanıma problemimize göre revize edilen bu ağlara ait başarılı sonuçlar da elde edilmiştir.

Yaptığımız bu tez çalışması kapsamında kullanılmış olan veri seti 4 bay ve 4 bayan olmak üzere toplam 8 bireyin günlük hayatta sıklıkla kullanılan 19 farklı hareketi sergilemesi ile elde edilen sinyallerden meydana gelmektedir. Her hareket 60 segmente bölünmüştür. Dolayısıyla veri seti $19 \times 8 \times 60 = 9120$ sinyal matrislerinden oluşmaktadır. Bu sinyal matrisleri görüntülere dönüştürüldükten sonra derin transfer öğrenme teknikleri kullanılmıştır. Sonuç olarak sistemimizin başarısını test etmek için 9120 tane resim elde edilmiştir. 9 farklı derin öğrenme mimarisi kullanılmıştır. Başarı oranları $100 * \frac{\# True\ classified}{\# True\ classified + \# False\ classified}$ (%) olarak hesaplanmıştır. Kişi tanıma için kullanılan mimariler kullanılarak elde edilen başarı oranları Çizelge 5.9’da ve Şekil 5.9’da sunulmuştur.

Çizelge 5.9 Diğer Transfer Öğrenme Yöntemlerinin Kişi Tanıma Üzerindeki Başarı Oranları (%).

Kullanılan Model	Başarı Oranı %
Vgg16	12.06
Vgg19	10.52
Mobilenetv1	96.82
Mobilenetv2	98.46
Densenet121	98.46
Densenet169	98.79
Densenet201	98.68
Inceptionv3	97.36
Xception	97.58




Şekil 5.9 Diğer Transfer Öğrenme Yöntemlerinin Kişi Tanıma Üzerindeki Başarı Oranları (%).

Çizelge 5.9'da belirtilen derin öğrenme yöntemleri ile kişilerin sergilemiş olduğu 19 farklı harekete ait tüm sinyallerin kullanılması ile elde edilen başarı oranları Çizelge 5.9 ve Şekil 5.0'da sunulmuştur. Sonuçlara bakıldığında %98.79 başarı oranı DenseNet169 ağına ait olmaktadır. VGG ağlarının kişi tanıma problemi üzerinde başarısız olduğu saptanmıştır. Başarı oranları genel olarak Derin öğrenme transfer yöntemlerinin kişi tanıma da etkili bir çalışma sunduğu görülmektedir.

Çizelge 5.10 Hareketlerin Kişi Tanıma Üzerindeki Etkisi Başarı Oranları (%).

Aktivite	VGG16	VGG19	MobileNetV1	MobileNetV2	DenseNet121	DenseNet169	DenseNet201	InceptionV3	Xception
A1	12.50	10.40	100.00	64.50	100.00	100.00	100.00	93.70	93.20
A2	10.40	10.40	100.00	12.50	100.00	97.90	97.90	100.00	100.00
A3	8.30	97.90	97.90	25.00	100.00	97.90	100.00	100.00	100.00
A4	100	45.83	93.75	47.91	100.00	100.00	97.90	97.90	97.90
A5	14.50	95.80	93.70	18.70	91.60	97.90	93.70	95.80	95.80
A6	10.40	91.60	95.80	22.90	97.90	95.80	97.90	93.70	97.90
A7	18.70	8.30	97.90	6.20	97.90	97.90	100.00	100.00	100.00
A8	8.30	10.40	62.50	16.60	77.00	91.60	85.40	75.00	83.30
A9	10.40	8.30	95.80	4.10	89.50	100.00	100.00	87.50	100.00
A10	8.30	10.40	100.00	10.40	100.00	100.00	93.70	100.00	97.90
A11	16.60	2.00	100.00	16.60	97.90	100.00	97.90	97.90	95.80
A12	100.00	100.00	100.00	16.60	100.00	100.00	95.83	95.80	100.00
A13	100.00	97.90	95.80	95.80	93.70	100.00	93.70	100.00	100.00
A14	18.70	97.90	97.90	22.90	100.00	100.00	100.00	97.90	97.90
A15	100	100.00	91.60	18.70	97.90	95.80	97.90	95.80	93.70
A16	12.50	12.50	95.80	16.60	93.70	97.90	91.60	83.30	100.00
A17	10.40	89.50	87.50	27.00	79.10	79.10	79.10	75.00	93.70
A18	68.70	95.80	79.10	27.00	87.50	75.00	81.20	58.30	87.50
A19	6.20	6.20	75.00	56.20	52.00	64.50	66.60	95.80	66.60




Şekil 5.10 Hareketlerin Kişi Tanıma Üzerindeki Etkisi Başarı Oranları (%).

Çalışmamızın diğer bir kısmını da her hareketin kişi tanıma üzerindeki etkisini tespit etmek oluşturmaktadır. Her harekete ait 480 görüntü bulunmaktadır. Her hareket için elde edilen kişi tanıma performans değerleri Çizelge 5.10’de verilmiştir. Şekil 5.10’da her hareketin kişi tanıma üzerindeki en iyi sonuçları sunulmuştur. Şekil 5.10’a bakıldığında hareketlerin çoğunun %100 oranında başarı sağladığı geriye kalan hareketlerinin de yüksek başarı oranına sahip olduğu anlaşılmaktadır. Çizelge 5.10 incelendiğinde en

başarılı derin öğrenme transfer yönteminin DenseNet169 olduğu gözlenmektedir. Bu yöntem ile “oturma hareketi”, “sağ tarafa yatma hareketi”, “otoparkta yürüme hareketi”, “4km/s hızla yere paralel koşu bandında yürüyüş hareketi”, “4km/s hızla yere 15 derecelik açı ile koşu bandı yürüyüş hareketi”, “8km /s hızla koşma hareketi”, “step egzersiz yapma hareketi” ve “eliptik bisiklet hareketi” %100 başarı oranı ile tespit edilmiştir. Basketbol oynama hareketinin tespiti transfer derin öğrenme yöntemlerinde genel olarak daha az başarı göstermesine rağmen Inception V3 modeli bu hareketin tespitinde başarılı olmuştur.

Çizelge 5.11 Bölgelerin Kişi Tanıma Üzerine Etkisi Başarı Oranları (%).

Bölge	VGG16	VGG19	MobileNetV1	MobileNetV2	DenseNet121	DenseNet169	DenseNet201	InceptionV3	Xception
Göğüs	92.20	11.10	94.50	93.80	94.40	94.50	94.40	94.62	95.80
Sağ Kol	11.00	93.80	92.10	92.10	93.09	93.20	92.43	92.10	100.00
Sol Kol	11.90	11.00	91.10	89.90	92.20	92.20	91.80	90.40	93.70
Sağ Bacak	11.80	13.40	93.60	92.30	96.20	95.20	93.60	93.80	97.90
Sol Bacak	15.80	12.00	91.90	92.00	95.60	94.90	94.60	93.40	94.40



Şekil 5.11 Bölgelerin Kişi Tanıma Üzerine Etkisi Başarı Oranları (%).

Bölgelerin kişi tanıma işlemi üzerindeki etkisini saptamak amacıyla her bölgeden elde edilen sinyaller görüntülere dönüştürüldükten sonra derin transfer öğrenme teknikleri uygulanmıştır. Bölgelere göre görüntüler kullanıldığında görüntü boyutları 125x9 olarak daha düşük boyutta kullanılmıştır. Elde edilen başarı oranları Çizelge 5.11’de verilmiştir. Farklı derin öğrenme mimarilerine göre elde edilen en yüksek başarı oranları da Şekil 5.11’de verilmiştir. Sağ bacakta bulunan sensörden elde edilen veriler kişi tanıma da en yüksek etkiye sahip verileri oluşturduğu gözlemlenmiştir.

6. SONUÇLAR VE ÖNERİLER

Son zamanlarda, sayıları giderek artan araştırmacılar biyometrik kimlik sistemlerinin başarısını artırmak amacıyla yaş, cinsiyet gibi yumuşak biyometrik özelliklere yoğunlaşmışlardır. Yapılan çalışmalar incelendiğinde, kişi tanıma işlemleri güvenlik, sağlık, reklam faaliyetler ve insan makine etkileşimi gibi uygulamalarda sıklıkla rastlanmaktadır. Bireyin yüz ifadesi, ses tonu ve hareket biçimi gibi karakteristik özellikleri sayesinde bir kişi diğer kişilerden ayırt edilebilmektedir. Fakat bilgisayar sistemleri ile bu ayırımı yapmak halen zor bir problem olarak görülmektedir. Yaptığımız çalışmada, sensör sinyallerinden elde edilen veriler aracılığıyla kişi tanıma problemine bir çözüm yolu sunulmuştur.

Bu amaç ile sensör işaretlerinden 1D-LBP ve 1D-FbLBP şeklinde yeni öznitelik çıkarım yaklaşımları önerilmiştir. İşaretlerden kişi tanıma için etkin öznitelikler elde edilmiştir. İşaretlerden öznitelik çıkarma işlemi kişi tanıma problemi çözüm sürecinin en önemli basamaklarından biri olmaktadır.

Kişi tanıma işlemin başarılı sonuçlar üretmesi elde edilen öznitelikler ile doğru orantılıdır. Önerilen yaklaşımlar sonucu meydana gelen öznitelikler çeşitli makine öğrenmesi metotları kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Başarı oranı en yüksek olan sınıflandırma yöntemi RF olarak tespit edilmiştir. RF kullanarak 1D-FbLBP ile 91.8281 başarı oranı gözlenmiştir. 1D-FbLBP ile 1D-LBP yöntemini kıyasladığımızda, 1D-FbLBP yönteminin kişi tanıma problemi için daha başarılı öznitelikler sunduğu görülmüştür.

Ek olarak, çalışmada veri setinden bulunan tüm hareketler için kişi tanıma işlemi gerçekleştirilmiştir. Tüm hareketler için kabul edilebilir yüksek başarı oranları elde edilmiştir. A10 (“4km/s hızla yere paralel koşu bandında yürüyüş hareketi”) ve, A12 (“8km/s hızla koşma hareketi”) hareketlerinin kişi tanımada %100 başarı gösterdiği gözlenmiştir. Asansörde hareket halindeyken ayakta durmak kişi tanımada %75 başarı göstermiştir. Genel olarak diğer tüm hareketler için kişi tanımada başarılı sonuçlar gözlenmiştir. İstatiksel hesaplamalar kullanılarak, 12 farklı öznitelik işaretlerinden elde edilmiştir. İstatiksel özniteliklerin başarısıda kendi arasından kıyaslanmış en başarılı sonucu ise %91.68 ile mutlak farklar özniteliği olduğu görülmüştür.

Çalışmamızın bir kısmında hangi sensörün kişi tanıma probleminin etkisinin daha çok olduğunu tespit etmek olmuştur. Bunun için, ivmeölçer, jiroskop ve manyotemetre sensörlerinden elde edilen verilere kişi tanıma işlemleri uygulanmıştır. Başarı sonuçları %87.0066, %73.4211 ve %83.5855 olarak sırası ile gözlemlenmiştir. Sensörlerin ayrı ayrı değil de birlikte kullanılmasının daha avantajlı olduğu anlaşılmıştır.

Sensörlerin takıldığı her bir bölgenin kişi tanıma işlemi üzerinde ki etkisini incelemek de çalışmamızın bir kısmını oluşturmaktadır. Sol bacağa takılan sensörlerden elde edilen işaretlerin kişi tanımada diğer göre daha etkin öznelilikler sağladığı görülmüştür. Bu sol bacak bölgesinden elde edilen özellikler kullanılarak % 77,8838 başarı oranı elde edildiği görülmüştür.

Son olarak 1D-LBP ve 1D-FbLBP yöntemleriyle elde edilen özelliklerin başarı oranları Zaman ve Frekans alanlarından elde edilen istatistiksel özelliklerle karşılaştırılmıştır. Önerilen yöntemlerin başarılı sonuçlar elde ettiği saptanmıştır. Önerilen öznelilik çıkarma işlemlerinin kişi tanıma probleminin çözümü için başarılı öznelilikler çıkardığı sonuç olarak söylene bilinir.

Sensörlerden elde edilen sinyaller görüntülere dönüştürüldükten sonra ResNet transfer derin öğrenme mimarileri ile kişi tahmin edilmiştir. 19 farklı harekete ait görüntülerin tümü birlikte kullanıldığında en yüksek başarı %94.21 olarak gözlenmiştir. Ayrıca, geliştirilen sistemde kişi eylemlerine göre de kişi tespiti gerçekleştirilmiştir.

“Oturma”, “ayakta durma”, “sırt üstü yatma”, “sağ tarafa yatma”, “otoparkta yürüme”, “4km/s hızla yere 15 derecelik açı ile koşu bandı yürüyüş”, “8km/s hızla koşma”, “step egzersiz yapma ve dikey pozisyonda bisiklet sürme eylemleri” için %100 başarı oranı gözlenmiştir. “Asansör hareket halindeyken ayakta durma”, “kürek çekme”, “sıçrama ve basketbol oynama eylemleri” için kişi tanımada diğer hareketlere göre daha az başarılı bulunmuştur. Çalışmada ayrıca sinyallerin elde edildikleri bölgelere göre kişi tespiti gerçekleştirilmiştir. Sağ bacak bölümünden elde edilen sinyaller kişi tanıma için daha ayırt edici bilgiler sağlamıştır. Bu bölümdeki görüntüler ile %95 başarı oranı gözlenmiştir.

Derin transfer öğrenme yöntemlerinde kullanılan CNN yöntemleri genel olarak başarılı sonuçlar vermesine rağmen VGG ağlarından başarı pek istenilen boyutta sağlanamamıştır.

Bu çalışmada, giyilebilir sensör (ivmeölçer, jiroskop ve manyetometre) sinyalleri kullanan KT için yeni bir yaklaşım önerilmiştir. Sensör sinyallerinden ayırt edici özellikler elde etmek için derin öğrenme yöntemleri kullanarak ve derin öğrenmenin transfer öğrenme yöntemlerinden yararlanılarak KT işlemi gerçekleştirilmiş ve başarılı sonuçlar elde edilmiştir. Elde edilen sonuçlara göre yöntemin diğer tıbbi sinyaller için kullanılabilecek etkili bir yöntem olacağı düşünülmektedir.

Bu çalışmada, kişi hareketlerinden kişi tanıma işlemi de 19 farklı fiziksel aktiviteye göre gerçekleştirilmiştir. KT konusunda etkili faaliyetler gösterilmiştir. Örneğin 4 km/s hızda yere paralel koşu bandında yürüme aktivitesi ve 8 km / saat hızda koşu aktivitesinde KT'de% 100 başarı oranına sahip olduğu sonucuna varılmıştır.

Aynı şekilde asansörde hareket halindeyken ayağa kalkma aktivitesi için en düşük başarı oranı gözlenmektedir. Bu çalışmanın KT'ya bir diğer katkısı da KT sürecinin sensör tiplerine göre yürütülmesidir. İvmeölçer, jiroskop ve manyetometre sensörlerinden elde edilen sinyallerin KH üzerine etkisi ortaya çıktı. Bu çalışmada ayrıca KT'de sinyalin vücudun hangi bölgelerinden alınması gerektiği de ortaya konmuştur.

Önerilen yöntemin farklı sinyallerin sınıflandırılmasında kullanılabileceği düşünülmektedir. Bundan sonraki çalışmalarımızda KT işlemi kişilerden alınan EEG, EMG, EKG gibi farklı sinyaller ile gerçekleştirilecektir.

Bu çalışmanın sınırlaması, veri kümesindeki az sayıda insan olmasıdır. İleride yapılacak çalışmalarda, veri setindeki insan sayısı artırılacaktır. Ek olarak, veri setindeki örnek sayısı artırılacaktır.

Sonuç olarak kişilerin gerçekleştirildikleri fiziksel hareketlere göre biyometrik sistemler parmak izi, yüz, avuç içi, iris gibi diğer sistemlere göre daha güvenli olabilirler. Çünkü parmak izi yüz, avuç içi gibi sistemlerde kopyalama işlemi daha kolaydır.

Günümüzde insanlar farkına varmadan birçok yere biyometrik özelliklerini bıraktıklarından ve bilgi saklama ve güvenliği işlemleri git gide zorlu duruma dönüştüğünden parmak izi ve göz retinaları izi gibi özellikler cep telefonları kilit sistemi dâhilinde kaydedilmekte ve bu bilgiler çalınıp kopyalanabilmektedir. Yürüyüş ve benzeri fiziksel hareketlerin taklit edilmesi daha zordur. Bu sebepten dolayı ileride insan hareketlerinden kişi tespiti birçok alanda kullanılmaya başlanacaktır.



KAYNAKLAR

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., ... & Ghemawat, S. (2016). Tensorflow: Large-scale machine learning on heterogeneous distributed systems. arXiv preprint arXiv:1603.04467
- Afrin, F. , Nahar, I. , 2015. Incremental learning based intelligent job search system, Doktora Tezi. BRAC Üniversitesi.
- Ahonen, T., Hadid, A., & Pietikäinen, M. (2004, May). Face recognition with local binary patterns. In European conference on computer vision (pp. 469-481). Springer, Berlin, Heidelberg.
- Alpaydın E., Introduction to Machine Learning, 2nd edition, The MIT Press, London, 2010.
- Altan, G., Kutlu, Y., & Yeniad, M. (2019). ECG based human identification using Second Order Difference Plots. Computer Methods and programs in Biomedicine, 170, 81-93.
- Altun, K.; Barshan, B.: Human activity recognition using inertial/magnetic sensor units. In: International Workshop on Human Behavior Understanding, Springer, pp 38–51 (2010)
- Altun, K.; Barshan, B.; Tunçel, O.: Comparative study on classifying human activities with miniature inertial and magnetic sensors. Pattern Recogn. 43(10), 3605–3620 (2010)
- Alyasseri Z. A. A., Khader A. T., Al-Betar M. A., and Alomari O. A., “Person Identification using EEG Channel Selection with Hybrid Flower Pollination Algorithm,” Pattern Recognit., p. 107393, 2020.
- Banan, A.; Nasiri, A.; Taheri-Garavand, A.: Deep learning-based appearance features extraction for automated carp species identification. Aquacultural Engineering. 89, 102053 (2020).
- Barshan, B.; Yükses, M.C.: Recognizing daily and sports activities in two open source machine learning environments using body-worn sensor units. Computer J. 57(11), 1649–1667 (2014)
- Bastien, F., Lamblin, P., Pascanu, R., Bergstra, J., Goodfellow, I., Bergeron, A., ... & Bengio, Y. (2012). Theano: new features and speed improvements. arXiv preprint arXiv:1211.5590.
- Bayat A, Pomplun M, Tran DA (2014) A study on human activity recognition using accelerometer data from smartphones Procedia Computer Science 34:450-457
- Bengio, Y & LeCun, Yann & Hinton, Geoffrey. (2015). Deep Learning. Nature. 521. 436-44. 10.1038/nature14539.

- Bishop, C.M., Pattern recognition and machine learning. Vol. 4. 2006: springer New York
- Boulgouris, N. V., Plataniotis, K. N., & Micheli-Tzanakou, E. (Eds.). (2009). Biometrics: theory, methods, and applications (Vol. 9). John Wiley & Sons.
- Breiman L., Random forests, Machine learning, 2001, 45, 5–32.
- Bulling, A., Blanke, U., & Schiele, B. (2014). A tutorial on human activity recognition using body-worn inertial sensors. ACM Computing Surveys (CSUR), 46(3), 1-33.
- Caputo, B. (2014). Medical image annotation. In Multimodal Interactive Systems Management (pp. 205-217). EPFL Press
- Chang, W., Wang, H., Yan, G., & Liu, C. (2020). An EEG based familiar and unfamiliar person identification and classification system using feature extraction and directed functional brain network. Expert Systems with Applications, 158, 113448.
- Chao, W. L. , 2011. Machine Learning Tutorial.
- Collobert, R., Kavukcuoglu, K., & Farabet, C. (2011). Torch7: A matlab-like environment for machine learning. In BigLearn, NIPS workshop (No. EPFL-CONF-192376).
- Cover, T. and Hart, P. (1967) ‘Nearest neighbor pattern classification’, IEEE Transactions on Information Theory, 13(1), pp. 21–27. doi: 10.1109/TIT.1967.1053964.
- Dai, Y., Wang, X., Li, X., & Tan, Y. (2015). Sparse EEG compressive sensing for web-enabled person identification. Measurement, 74, 11-20.
- Deng, M., Wang, C., Tang, M., & Zheng, T. (2018). Extracting cardiac dynamics within ECG signal for human identification and cardiovascular diseases classification. Neural Networks, 100, 70-83.A.
- Dogan, Y., & Keles, H. Y. (2020). Semi-supervised image attribute editing using generative adversarial networks. Neurocomputing, 401, 338-352.
- El Khadiri I., Kas M., El Merabet Y., Ruichek Y., Touahni, R., Repulsive-and-attractive local binary gradient contours: New and efficient feature descriptors for texture classification, Information Sciences, 2018, 467, 634-653.
- Sufi F. and Khalil I., “Faster person identification using compressed ECG in time critical wireless telecardiology applications,” J. Netw. Comput. Appl., vol. 34, no. 1, pp. 282–293, 2011.
- Fan, Y.; Xu, K.; Wu, H.; Zheng, Y.; Tao, B.: Spatiotemporal Modeling for Nonlinear Distributed Thermal Processes Based on KL Decomposition, MLP and LSTM Network. IEEE Access. 8, 25111-25121 (2020).
- Fang, J.-S., Hao, Q., Brady, D. J., Guenther, B. D. & Hsu, K. Y. Real-time human identification using a pyroelectric infrared detector array and hidden Markov models. Opt. Express 14, 6643 (2006).

- Fortino, G. (2013). Embedded computing frameworks for body sensor networks. IEEE Life Sciences Newsletter
- Fuentes, D.; Gonzalez-Abril, L.; Angulo, C.; Ortega, J. A.: Online motion recognition using an accelerometer in a mobile device. Expert systems with applications. 39(3), 2461-2465 (2012)
- Fukushima, K., 1980. Neocognitron: A Self-organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position. Biological Cybernetics, 193–202.
- Fullerton, E., Heller, B., & Munoz-Organero, M. (2017). Recognizing human activity in free-living using multiple body-worn accelerometers. IEEE Sensors Journal, 17(16), 5290-5297.
- Galbally, J., Marcel, S., & Fierrez, J. (2014). Biometric antispoofing methods: A survey in face recognition. IEEE Access, 2, 1530-1552
- Gentleman, R. , Huber, W. , Carey, V. J. , 2008. Supervised machine learning - In Bioconductor Case Studies (pp. 121-136), Springer, New York.
- Glorot, X., & Bengio, Y. (2010, March). Understanding the difficulty of training deep feedforward neural networks. In Proceedings of the thirteenth international conference on artificial intelligence and statistics (pp. 249-256).
- Golomb, B. A., Lawrence, D. T. & Sejnowski, T. J. Sexnet: A Neural Network Identifies Sex from Human Faces. Adv. neural Inf. Process. Syst. 3 572–577 (1990).
- Goodfellow I., Bengio Y., Courville A., Bengio Y., 1st Ed., Deep learning, MIT press, Cambridge, U.K., 2016.
- Goodfellow, I., Bergeron, A., ... & Bengio, Y. (2012). Theano: new features and speed improvements. arXiv preprint arXiv:1211.5590.
- Goshvarpour, A., & Goshvarpour, A. (2019). Human identification using a new matching pursuit-based feature set of ECG. Computer methods and programs in biomedicine, 172, 87-94.
- Gravina, R., Alinia, P., Ghasemzadeh, H., & Fortino, G. (2017). Multi-sensor fusion in body sensor networks: State-of-the-art and research challenges. Information Fusion, 35, 68-80
- Gümüşçü, A . (2019). Giyilebilir Yürüyüş Analiz Sensörü ile Kişi Sınıflandırmasının Öznitelik Seçme Algoritmaları ile İyileştirilmesi . Fırat Üniversitesi Mühendislik Bilimleri Dergisi , 31 (2) , 463-471 . DOI: 10.35234/fumbd.554789
- Ha, S., & Choi, S. (2016, July). Convolutional neural networks for human activity recognition using multiple accelerometer and gyroscope sensors. In 2016 International Joint Conference on Neural Networks (IJCNN) (pp. 381-388). IEEE.

- He, J., Zhang, Q., Wang, L., & Pei, L. (2018). Weakly supervised human activity recognition from wearable sensors by recurrent attention learning. *IEEE Sensors Journal*, 19(6), 2287-2297.
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. In *Proceedings of the IEEE international conference on computer vision* (pp. 1026-1034).
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708).
- Hubel, D. H., & Wiesel, T. N. (1968). Receptive fields and functional architecture of monkey striate cortex. *The Journal of physiology*, 195(1), 215-243.
- Israel, S. A., Irvine, J. M., Cheng, A., Wiederhold, M. D., & Wiederhold, B. K. (2005). ECG to identify individuals. *Pattern recognition*, 38(1), 133-142.
- Jaderberg, M., Simonyan, K., Zisserman, A., & Kavukcuoglu, K. (2015). Spatial transformer networks. *arXiv preprint arXiv:1506.02025*.
- Jain, A. K., Flynn, P., & Ross, A. A. (Eds.). (2007). *Handbook of biometrics*. Springer Science & Business Media.
- Ji, S., Xu, W., Yang, M., & Yu, K. (2012). 3D convolutional neural networks for human action recognition. *IEEE transactions on pattern analysis and machine intelligence*, 35(1), 221-231.
- Jia, Y., Shelhamer, E., Donahue, J., Karayev, S., Long, J., Girshick, R., ... & Darrell, T. (2014). Caffe: Convolutional architecture for fast feature embedding. In *Proceedings of the 22nd ACM international conference on Multimedia* (pp. 675-678). ACM.
- Jones, M. S. (2015). Convolutional autoencoders in python/theano/lasagne. Blog post (retrieved February 17, 2016), April.
- Kaya Y., Ertuğrul Ö. F. and Tekin R., Two novel local binary pattern descriptors for texture analysis, *Applied Soft Computing*, 2015, 34, 728-735.
- Kaya, Y.: Uyar, M.: Tekin, R.: Yıldırım, S.: 1D-local binary pattern-based feature extraction for classification of epileptic EEG signals. *Applied Mathematics and Computation*. 243,209-21 (2014)
- Kılıç, Ş., Kaya, Y., & Askerbeyli, I. (2021). A New Approach for Human Recognition Through Wearable Sensor Signals. *Arabian Journal for Science and Engineering*, 46(4), 4175-4189.

- Kızrak, M. A., & Bolat, B. (2018). Derin öğrenme ile kalabalık analizi üzerine detaylı bir araştırma. *Bilişim Teknolojileri Dergisi*, 11(3), 263-286.
- Kiliç, Ş., Askerzade, İ., & Kaya, Y. (2020). Using ResNet Transfer Deep Learning Methods in Person Identification According to Physical Actions. *IEEE Access*, 8, 220364-220373.
- Kochura, Y., Stirenko, S., Rojbi, A., Alienin, O., Novotarskiy, M., & Gordienko, Y. (2017). Comparative analysis of open source frameworks for machine learning with use case in single-threaded and multi-threaded modes. *arXiv preprint arXiv:1706.02248*.
- Kohavi, R. and F. Provost, Glossary of terms. *Machine Learning*, 1998. 30(2-3): p. 271-274
- Kotsiantis, S. B. , Zaharakis, I. , Pintelas, P. , 2007. Supervised machine learning: A review of classification techniques.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems* (pp. 1097-1105).
- Kuncan, F., Kaya, Y., & Kuncan, M. (2019). New approaches based on local binary patterns for gender identification from sensor signals. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34(4), 2173-2185.
- Lavi, B., And, M. F. S. & Ullah, I. Survey on Deep Learning Techniques for Person Re-Identification Task. *CoRR abs/1807.0*, (2018).
- LeCun, Y., Bengio, Y. & Hinton, G. Deep learning. *Nature* 521, 436–444 (2015). <https://doi.org/10.1038/nature14539>
- Lecun, Y., Bottou, L., Bengio, Y., Haffner, P., 1998. Gradient-based Learning Applied to Document Recognition. *Proc. IEEE*, 86(11), 2278–2324.
- Lee MJ, Zheng J, Hu X, Juan H-h, Zhu C, Liu Y, Yoon JS, Saadawi TN (2006) A new taxonomy of routing algorithms for wireless mobile ad hoc networks: the component approach. *IEEE Communications Magazine* 44 (11):116-123
- Li, D., Zhang, J., Zhang, Q., & Wei, X. (2017, October). Classification of ECG signals based on 1D convolution neural network. In *2017 IEEE 19th International Conference on e-Health Networking, Applications and Services (Healthcom)* (pp. 1-6). IEEE.
- Liu L., Zhao L., Long Y., Kuang G., Fieguth P., Extended local binary patterns for texture classification, *Image and Vision Computing*, 2012, 30(2), 86-99.
- Lounis, A., Hadjidj, A., Bouabdallah, A., & Challal, Y. (2012, July). Secure and scalable cloud-based architecture for e-health wireless sensor networks. In *2012 21st International Conference on Computer Communications and Networks (ICCCN)* (pp. 1-7). IEEE.

- Lukowicz, P., Ward, J.A., Junker, H., Stager M., Tröster G., Atrash A., Starner, T., Recognizing Workshop Activity Using Body Worn Microphones and Accelerometers, Second International Conference on Pervasive Computing, Linz/Vienna, Austria, 21-23 Nisan, 2004.
- Lumini A., Nanni L., Brahnam S., Ensemble of texture descriptors and classifiers for face recognition, *Applied Computing and Informatics*, 2017, 13(1), 79-91.
- Lv, M., Chen, L., Chen, T., & Chen, G. (2018). Bi-view semi-supervised learning based semantic human activity recognition using accelerometers. *IEEE Transactions on Mobile Computing*, 17(9), 1991-2001.
- Maiorana, E. (2020). Deep learning for EEG-based biometric recognition. *Neurocomputing*, 410, 374-386.
- Malathi, S., & Meena, C. (2010). An efficient method for partial fingerprint recognition based on Local Binary Pattern. In *Communication Control and Computing Technologies (ICCCCT)*, 2010 IEEE International Conference on (pp. 569-572). IEEE
- Maltoni, D., Maio, D., Jain, A. K., & Prabhakar, S. (2009). *Handbook of fingerprint recognition*. Springer Science & Business Media.
- Marcel, S., & Millán, J. D. R. (2007). Person authentication using brainwaves (EEG) and maximum a posteriori model adaptation. *IEEE transactions on pattern analysis and machine intelligence*, 29(4), 743-752.
- Mateen, M., Wen, J., Song, S., & Huang, Z. (2019). Fundus image classification using VGG-19 architecture with PCA and SVD. *Symmetry*, 11(1), 1.
- Matsumoto, H. Matsumoto, K. Yamada and S. Hoshino, "Impact of artificial gummy fingers on fingerprint systems", *Opt. Secur. Counterfeit Deterrence Techn.*, vol. 4677, pp. 275-289, Dec. 2002.
- Monsy, J. C., & Vinod, A. P. (2020). EEG-based biometric identification using frequency-weighted power feature. *IET Biometrics*, 9(6), 251-258.
- Nanni, L., Lumini, A., & Brahnam, S. (2010). Local binary patterns variants as texture descriptors for medical image analysis. *Artificial intelligence in medicine*, 49(2), 117-125
- Nvidia, 2016. Nvidia deep learning gpu training system. <https://developer.nvidia.com/digits>. Erişim: 17.04.2021.
- Ojala, T., Pietikäinen, M., & Mäenpää, T. (2000, June). Gray scale and rotation invariant texture classification with local binary patterns. In *European Conference on Computer Vision* (pp. 404-420). Springer, Berlin, Heidelberg.
- Oquab, M., Bottou, L., Laptev, I., & Sivic, J. (2014). Learning and transferring mid-level image representations using convolutional neural networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1717-1724).

- Ordóñez, F. J., & Roggen, D. (2016). Deep convolutional and lstm recurrent neural networks for multimodal wearable activity recognition. *Sensors*, 16(1), 115.
- Özgür, A. , 2004. Supervised and unsupervised machine learning techniques for text document categorization, Doktora Tezi-Bogaziçi Üniversitesi.
- Pan, S. J., & Yang, Q. (2009). A survey on transfer learning. *IEEE Transactions on knowledge and data engineering*, 22(10), 1345-1359.
- Pan, Z.; Li, Z.; Fan, H.; Wu, X.: Feature based local binary pattern for rotation invariant texture classification. *Expert Systems with Applications*. 88, 238-248 (2017)
- Patel, S., Lorincz, K., Hughes, R., Huggins, N., Growdon, J., Standaert, D., Akay, M., Dy, J., Welsh, M., and Bonato, P., Monitoring motor fluctuations in patients with Parkinson's disease using wearable sensors, *IEEE Transactions on Information Technology in Biomedicine* vol.13, no.6, s.864- 873, 2009.
- Perez, L., & Wang, J. (2017). The effectiveness of data augmentation in image classification using deep learning. *arXiv preprint arXiv:1712.04621*.
- Permin E, Lindner F, Kostyszyn K, Grunert D, Lossie K, Schmitt R, Plutz M (2019) Smart Devices in Production System Maintenance. In: Predictive Maintenance in Dynamic Systems. Springer, pp 25-51
- Poppe, R., Vision-based human motion analysis, An overview, *Computer Vision and Image Understanding*, vol.108, no.1-2, s.4–18, 2007.
- Preece, S. J. et al. Activity identification using body-mounted sensors - A review of classification techniques. *Physiol. Meas.* 30, (2009).
- Quaid MAK, Jalal A (2019) Wearable sensors based human behavioral pattern recognition using statistical features and reweighted genetic algorithm. *Multimedia Tools and Applications*:1-23
- Rahmani, H., Mian, A., & Shah, M. (2017). Learning a deep model for human action recognition from novel viewpoints. *IEEE transactions on pattern analysis and machine intelligence*, 40(3), 667-681.
- Ravi, N., Dandekar, N., Mysore, P., Littman, M.L., Activity recognition from s.1541–1546, 2005.
- Rodrigues, D., Silva, G. F., Papa, J. P., Marana, A. N., & Yang, X. S. (2016). EEG-based person identification through binary flower pollination algorithm. *Expert Systems with Applications*, 62, 81-90.
- San-Segundo, R., Cordoba, R., Ferreiros, J., & D'Haro-Enriquez, L. F. (2016). Frequency features and GMM-UBM approach for gait-based person identification using smartphone inertial signals. *Pattern Recognition Letters*, 73, 60-67.
- San-Segundo, R., Echeverry-Correa, J. D., Salamea-Palacios, C., Lutfi, S. L., & Pardo, J. M. (2017). I-vector analysis for gait-based person identification using smartphone inertial signals. *Pervasive and Mobile Computing*, 38, 140-153.

- Sebastiani, F. , 2002. Machine learning in automated text categorization, ACM computing surveys (CSUR), 34(1), 1-47.
- Seneviratne, S., Hu, Y., Nguyen, T., Lan, G., Khalifa, S., Thilakarathna, K., ... & Seneviratne, A. (2017). A survey of wearable devices and challenges. IEEE Communications Surveys & Tutorials, 19(4), 2573-2620.
- Sepahvand, M., & Abdali-Mohammadi, F. (2021). A novel multi-lead ECG personal recognition based on signals functional and structural dependencies using time-frequency representation and evolutionary morphological CNN. Biomedical Signal Processing and Control, 68, 102766.
- Sermanet, P., Eigen, D., Zhang, X., Mathieu, M., Fergus, R., & LeCun, Y. (2013). Overfeat: Integrated recognition, localization and detection using convolutional networks. arXiv preprint arXiv:1312.6229
- Siirtola P, Rönning J (2012) Recognizing human activities user-independently on smartphones based on accelerometer data IJIMAI 1:38-45
- Silver, D., Schrittwieser, J., Simonyan, K., Antonoglou, I., Huang, A., Guez, A., ... & Hassabis, D. (2017). Mastering the game of go without human knowledge. nature, 550(7676), 354-359.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556
- Siva Raja, P. M., Rani A. V., Brain tumor classification using a hybrid deep autoencoder with Bayesian fuzzy clustering-based segmentation approach, Biocybernetics and Biomedical Engineering, 2020, 40(1), 440-453.
- Smolka B., Nurzynska K., Power LBP: A novel texture operator for smiling and neutral facial display classification, Procedia Computer Science, 2015, 51, 1555-1564.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. The journal of machine learning research, 15(1), 1929-1958.
- Srivastava, R. K., Greff, K., & Schmidhuber, J. (2015). Training very deep networks. In Advances in neural information processing systems (pp. 2377-2385).
- Su, K., Yang, G., Wu, B., Yang, L., Li, D., Su, P., & Yin, Y. (2019). Human identification using finger vein and ECG signals. Neurocomputing, 332, 111-118.
- Su, X., Tong, H., & Ji, P. (2014). Activity recognition with smartphone sensors. Tsinghua science and technology, 19(3), 235-249.
- Sun, Y., Lo, F. P. W., & Lo, B. (2019). EEG-based user identification system using 1D-convolutional long short-term memory neural networks. Expert Systems with Applications, 125, 259-267.
- Suppes, A. E. Human identification using pyroelectric infrared sensors. (2009).

- Sutskever, I., Martens, J., Dahl, G., & Hinton, G. (2013, February). On the importance of initialization and momentum in deep learning. In International conference on machine learning (pp. 1139-1147).
- Suutala, J., & Rönning, J. (2008). Methods for person identification on a pressure-sensitive floor: Experiments with multiple classifiers and reject option. *Information Fusion*, 9(1), 21-40.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions.
- Team, T. T. D., Al-Rfou, R., Alain, G., Almahairi, A., Angermueller, C., Bahdanau, D., ... & Belopolsky, A. (2016). Theano: A Python framework for fast computation of mathematical expressions. arXiv preprint arXiv:1605.02688.
- Thang HM, Viet VQ, Thuc ND, Choi D Gait identification using accelerometer on mobile phone. In: 2012 International Conference on Control, Automation and Information Sciences (ICCAIS), 2012. IEEE, pp 344-348
- Torrey, L., & Shavlik, J. (2010). Transfer learning. In *Handbook of research on machine learning applications and trends: algorithms, methods, and techniques* (pp. 242-264). IGI global.
- Unar, J., Senga, W., Abbasia, A., 2014. A Review of Biometric Technology Along with Trends and Prospects, *Pattern identification*, vol. 47, pp.2673-2688.
- Wang, Y., Wu, Q., Wang, C., & Ruan, Q. (2020). DE-CNN: an improved identity recognition algorithm based on the emotional electroencephalography. *Computational and Mathematical Methods in Medicine*, 2020.
- Wang, Z., Wu, D., Chen, J., Ghoneim, A., & Hossain, M. A. (2016). A triaxial accelerometer-based human activity recognition via EEMD-based features and game-theory-based feature selection. *IEEE Sensors Journal*, 16(9), 3198-3207.
- Webb, G. I.; Boughton, J. R.; Wang, Z.: Not so naive Bayes: aggregating one-dependence estimators. *Machine learning*. 58(1), 5-24 (2005).
- Webb, G. I.; Boughton, J. R.; Zheng, F.; Ting, K. M.; Salem, H.: Learning by extrapolation from marginal to full-multivariate probability distributions: decreasingly naive Bayesian classification. *Machine learning*. 86(2), 233-272 (2012)
- Weiss GM, Lockhart JW Identifying user traits by mining smart phone accelerometer data. In: *Proceedings of the fifth international workshop on knowledge discovery from sensor data*, 2011. ACM, pp 61-69
- Wilaiprasitporn, T., Ditthaporn, A., Matchaparn, K., Tongbuasirilai, T., Banluesombatkul, N., & Chuangsuwanich, E. (2019). Affective EEG-based person identification using the deep learning approach. *IEEE Transactions on Cognitive and Developmental Systems*, 12(3), 486-496.

- Dai Y., Wang X., Li X., and Tan Y., "Sparse EEG compressive sensing for web-enabled person identification," *Measurement*, vol. 74, pp. 11–20, 2015
- Yang J. B. vd., "Deep convolutional neural networks on multichannel time series for human activity recognition," in *IJCAI, Argentina*, 2015, pp. 25–31.
- Yao, Y., & Doretto, G. (2010, June). Boosting for transfer learning with multiple sources. In *2010 IEEE computer society conference on computer vision and pattern recognition* (pp. 1855-1862). IEEE.
- You, Q., Luo, J., Jin, H., & Yang, J. (2015, February). Robust image sentiment analysis using progressively trained and domain transferred deep networks. In *Twenty-ninth AAAI conference on artificial intelligence*.
- Yu, C. Fang, J. Xu, E.-C. Chang and Z. Li, "ID repetition in Kad", *Proc. IEEE 9th Int. Conf. Peer Comput.*, pp. 111-120, Dec. 2009.
- Yu, D., and Li D., *Automatic speech recognition: A deep learning approach*. Springer, 2014.
- Yu, D., Eversole, A., Seltzer, M., Yao, K., Huang, Z., Guenter, B., ... & Droppo, J. (2014). An introduction to computational networks and the computational network toolkit. *Microsoft Technical Report MSR-TR-2014-112*.
- Yu, S., Tan, T., Huang, K., Jia, K. & Wu, X. A study on gait-based gender classification. *IEEE Trans. Image Process.* 18, 1905–1910 (2009).
- Zeiler, M. D., & Fergus, R. (2014, September). Visualizing and understanding convolutional networks. In *European conference on computer vision* (pp. 818-833). Springer, Cham.
- Zhang Y, Pan G, Jia K, Lu M, Wang Y, Wu Z (2014) Accelerometer-based gait recognition by sparse representation of signature points with clusters. *IEEE transactions on cybernetics* 45 (9):1864-1875
- Zhang, X., Yao, L., Kanhere, S. S., Liu, Y., Gu, T., & Chen, K. (2017). MindID: Person identification from brain waves through attention-based recurrent neural network. *arXiv preprint arXiv:1711.06149*.
- Zhong Y, Deng Y Sensor orientation invariant mobile gait biometrics. In: *IEEE International Joint Conference on Biometrics*, 2014. IEEE, pp 1-8
- Zhu, H., Samtani, S., Chen, H., & Nunamaker, J. F. (2020). Human Identification for Activities of Daily Living: A Deep Transfer Learning Approach. *Journal of Management Information Systems*, 37(2), 457-483. <https://doi.org/10.1080/07421222.2020.1759961>