

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ DOKTORA PROGRAMI**

GİYİLEBİLİR SENSÖRLERLE SAĞLIK İZLEME

HAZIRLAYAN

TUNÇ AŞUROĞLU

DOKTORA TEZİ

ANKARA - 2020

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ DOKTORA PROGRAMI**

GİYİLEBİLİR SENSÖRLERLE SAĞLIK İZLEME

HAZIRLAYAN

TUNÇ AŞUROĞLU

DOKTORA TEZİ

TEZ DANIŞMANI

PROF. DR. HASAN OĞUL

ANKARA – 2020

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Doktora Programı çerçevesinde Tunç Aşuroğlu tarafından hazırlanan bu çalışma, aşağıdaki jüri tarafından Doktora Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 24 / 06 / 2020

Tez Adı: Giyilebilir Sensörlerle Sağlık İzleme

Tez Jüri Üyeleri

İmza

Prof. Dr. Hasan OĞUL, Başkent Üniversitesi

Prof. Dr. M. Ali AKCAYOL, Gazi Üniversitesi

Prof. Dr. Tolga CAN, Orta Doğu Teknik Üniversitesi

Dr. Öğr. Üyesi Emre SÜMER, Başkent Üniversitesi

Dr. Öğr. Üyesi Selda GÜNEY, Başkent Üniversitesi

ONAY

Prof. Dr. Faruk ELALDI
Fen Bilimleri Enstitüsü Müdürü

Tarih: ... / ... /

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ
DOKTORA TEZ ÇALIŞMASI ORJİNALLİK RAPORU

Tarih: 26 / 06 / 2020

Öğrencinin Adı, Soyadı : Tunç AŞUROĞLU

Öğrencinin Numarası : 21510193

Anabilim Dalı : Bilgisayar Mühendisliği

Programı : Bilgisayar Mühendisliği Doktora

Danışmanın Unvanı/Adı, Soyadı : Prof. Dr. Hasan OĞUL

Tez Başlığı : Giyilebilir Sensörlerle Sağlık İzleme

Yukarıda başlığı belirtilen Doktora tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 111 sayfalık kısmına ilişkin, 26 / 06 / 2020 tarihinde tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı %3'tür. Uygulanan filtrelemeler:

1. Kaynakça hariç
2. Alıntılar hariç
3. Beş (5) kelimeden daha az örtüşme içeren metin kısımları hariç

“Başkent Üniversitesi Enstitüleri Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Usul ve Esaslarını” inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Öğrenci İmzası:.....

ONAY

Tarih: ... / ... / 2020

Öğrenci Danışmanı Prof. Dr. Hasan OĞUL

TEŞEKKÜR

Yazar, bu çalışmanın gerçekleşmesinde katkılarından dolayı, aşağıda adı geçen kişilere içtenlikle teşekkür eder.

Sayın Prof. Dr. Hasan OĞUL'a (tez danışmanı), çalışmanın sonuca ulaştırılmasında ve karşılaşılan güçlüklerin aşılmasında her zaman yardımcı ve yol gösterici olduğu için...

Tez komitemin üyeleri olan Dr. Öğr. Üyesi Emre SÜMER ve Dr. Öğr. Üyesi Selda GÜNEY'e tez çalışmam esnasında destekleri ve yol gösterici oldukları için...

Sayın Arş. Gör. Koray AÇICI ve Arş. Gör. Çağatay Berke ERDAŞ'a, destek ve yardımlarından dolayı...

Değerli eşim Zeynep AŞUROĞLU'na bu süreçteki sabrından ve desteğinden dolayı...

Bu süreç boyunca desteklerini hiçbir zaman eksik etmeyen ve her zaman yanımda olan Annem Nilgün BEYHAN ve Babam Barbaros AŞUROĞLU'na...

Bu tez çalışması TÜBİTAK tarafından 115E451 proje numarasıyla ve Network of the European Union, Latin America and the Caribbean Countries (ERANet-LAC) tarafından ELAC2015/T09-0819 proje numarasıyla desteklenmiştir.

ÖZET

Tunç AŞUROĞLU

GIYİLEBİLİR SENSÖRLERLE SAĞLIK İZLEME

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

2020

Teknolojinin gelişmesiyle birlikte verinin toplanması, saklanması ve işlenmesi yaygınlaşmış ve bu sebepten giyilebilir sensör teknolojisi günlük hayatımızda gitgide popülerleşmeye başlamıştır. Giyilebilir sensörler ve akıllı tekstiller daha küçük, daha ucuz ve kullanıcı tarafından kolaylıkla erişilebilir hale geldikçe günlük aktivite takibi ve sağlık alanlarında yaygın olarak kullanımı artmıştır. Günümüzde giyilebilir sensör teknolojileri, sağlık alanında hastalıkları önleme, erken teşhis ve kronik durumların yönetimi için etkili bir araç olarak kullanılmaktadır. Sağlık alanında giyilebilir sensörlerin kullanılmasının asıl amacı, hastanın sağlık parametrelerinin uzaktan izlemeye bilme imkânı ve dolayısıyla hastaların bir sağlık merkezine gitmelerine gerek kalmadan evlerinde tedavi olabilmeleri ve hastalık durumunu takip edebilmesine olanak sağlamaktır. Bu bağlamda, tez çalışmada giyilebilir sensörlerle elde edilen sinyalleri kullanarak hastalık seviyesi takibi çalışmaları gerçekleştirilmiştir. Çalışmada bu amaçla, ölümcül bir enfeksiyon hastalığı olan Sepsis ve günümüzde tedavisi olmayan nörolojik bir hastalık olan Parkinson hastalığı üzerine çalışmalar yapılmıştır. Sepsis hastalığında giyilebilir sensörlerle kolayca elde edilebilen hayati belirtiler kullanılmıştır. Bu hayati belirtiler, hastalık durumunu takip etmeyi sağlayan organ yetmezliği skorunun tahmin edilmesinde kullanılmıştır. Parkinson hastalığı semptom seviyesi değer tahmini, ayağa giyilen ve ayağa uygulanan kuvveti ölçen giyilebilir sensörlerle yürüyüş analizi yapılarak gerçekleştirilmiştir. Bu tahminleri gerçekleştirmek için tez çalışmada geleneksel makine öğrenmesi yöntemlerinin yanı sıra, derin öğrenme ve tez çalışması kapsamında geliştirilen CNN ve Rastgele Orman tabanlı derin öğrenme hibrit mimarileri kullanılmıştır. Değer tahmin analizinde, geliştirilen hibrit mimarilerinin geleneksel yöntemlere göre performans artışı sağladığı gözlemlenmiştir.

ANAHTAR KELİMELER: Giyilebilir Sensör, Parkinson Hastalığı, Sepsis, Hastalık İzleme, Derin Öğrenme

ABSTRACT

Tunç AŞUROĞLU

HEALTH MONITORING VIA WEARABLE SENSORS

Baskent University Institution of Science and Engineering

Department of Computer Engineering

2020

With the development of technology, the collection, storage and processing of data has become widespread, and therefore wearable sensor technology has become increasingly popular in our daily life. As wearable sensors and smart textiles become smaller, cheaper and easily accessible by the user, they are widely used in daily activity tracking and healthcare. Wearable sensor technologies are used today as an effective tool for disease prevention, early disease detection and management of chronic conditions. The main purpose of using wearable sensors in the field of healthcare is to monitor the health parameters of patients remotely, and therefore to enable patients to be treated at home and prognose the disease status without having to go to a healthcare center. To achieve a baseline in this manner, experiments were carried out in this thesis using the signals obtained with wearable sensors to prognose diseases. For this purpose, a fatal infectious disease called Sepsis and a neurological disease without treatment called Parkinson's disease, were selected for thesis study. Vital signs that can be easily obtained with wearable sensors are used in Sepsis prognose experiments. These vital signs have been used to predict the organ failure score that allows monitoring the disease status. Parkinson's disease symptom level value estimation was performed by walking analysis with wearable shoe system that measures the force applied to the foot. In order to perform these predictions, CNN and Random Forest based deep learning hybrid architectures are developed. Also, experiments are conducted with traditional machine learning and deep learning architectures to validate the performance of this approach. In experimental results, it was observed that the developed hybrid architectures provide performance increase compared to traditional methods.

KEYWORDS: Wearable Sensors, Parkinsons Disease, Sepsis, Prognosis, Deep Learning.

İÇİNDEKİLER

Sayfa

TEŞEKKÜR.....	i
ÖZET.....	ii
ABSTRACT	iii
İÇİNDEKİLER.....	iv
TABLOLAR LİSTESİ.....	vi
ŞEKİLLER LİSTESİ.....	viii
SİMGELER VE KISALTMALAR LİSTESİ.....	xi
1. GİRİŞ.....	1
1.1. Motivasyon ve Tanım.....	1
1.2. Tez Çalışmasının Genel Katkıları.....	6
1.3. Temel Makine Öğrenmesi Yöntemleri.....	7
1.3.1. Regresyon.....	7
1.3.2. k-en yakın komşu (k-NN).....	8
1.3.3. J48 karar ağacı.....	9
1.3.4. Ayırıklaştırma ile regresyon (RBD).....	11
1.3.5. Destek vektör makinesi (SVM).....	11
1.3.6. Destek vektör regresyonu (SVR).....	13
1.3.7. Lineer regresyon (LIR).....	14
1.3.8. Naive bayes sınıflandırıcı (NB).....	14
1.3.9. Lojistik regresyon (LR).....	16
1.3.10. Rastgele orman (RF)	16
1.3.11. Çift yönlü uzun kısa süreli hafıza (Bi-LSTM)).....	18
1.3.12. Evrişimsel sinir ağı (CNN).....	21
2. GİYİLEBİLİR SENSÖRLERLE İZLENİLEN HASTALIKLAR.....	24
2.1. Parkinson Hastalığı İzleme.....	24
2.1.1. Giriş.....	24
2.1.2. İlgili çalışmalar.....	26
2.1.3. Hastalık izleme için genel yapı.....	31
2.2. Literatürde Bilgisayar Yöntemleriyle Enfeksiyon İzlenmesi.....	32
2.2.1. Giriş.....	32
2.2.2. Bilgisayar yöntemleriyle enfeksiyon izleyen çalışmalar.....	33

2.3. Sepsis Hastalığı İzleme.....	42
2.3.1. Giriş.....	42
2.3.2. İlgili çalışmalar.....	46
2.3.3. Hastalık izleme için genel yapı.....	52
3. TEZ ÇALIŞMASINDA KULLANILAN VERİ KÜMELERİ.....	53
3.1. Physionet Gait in Parkinsons Disease Veri Kümesi.....	53
3.2. MIMIC III Veri Kümesi.....	58
4. YÖNTEMLER.....	68
4.1. Yeni Öznitelik Çıkartma Yöntemleri.....	68
4.1.1. Zaman ve frekans öznitelikleri.....	68
4.1.2. Yerel ikili öznitelikler (Local Binary Patterns).....	71
4.2. Yerel Ağırlıklı Rastgele Orman (LWRF).....	75
4.3. Derin Öğrenme Hibrit Yapıları.....	76
4.3.1. Sinyal girdisi dönüştürme işlemi.....	76
4.3.2. CNN ve Bi-LSTM derin öğrenme hibrit yapısı.....	78
4.3.3. CNN ve RF / LWRF derin öğrenme hibrit yapısı.....	80
5. SONUÇLAR.....	82
5.1. Değerlendirme Ölçütleri.....	82
5.2. Deneysel Sonuçlar.....	84
5.2.1. Parkinson hastalığı.....	84
5.2.2. Sepsis hastalığı.....	91
6. TARTIŞMA VE SONUÇ.....	108
KAYNAKLAR.....	112
EKLER	

EK 1: Enfeksiyonları Bilgisayar Yöntemleriyle İnceleyen Çalışmalar

TABLÖLER LİSTESİ

	Sayfa
Tablo 3.1. Sensörlerin ayağın altındaki konumu.....	56
Tablo 3.2. MIMIC III veri kategorileri.....	58
Tablo 5.1. LBP yönteminde pencere boyutuna göre UPDRS değeri regresyon sonuçları.....	85
Tablo 5.2. LBP yönteminde pencere boyutuna göre H&Y değeri regresyon sonuçları.....	85
Tablo 5.3. UPDRS değeri regresyon sonuçları.....	87
Tablo 5.4. H&Y değeri regresyon sonuçları.....	88
Tablo 5.5. Parkinson hastalığı için sınıflandırma sonuçları.....	90
Tablo 5.6. LBP yönteminde pencere boyutuna göre SOFA skoru regresyon sonuçları.....	91
Tablo 5.7. SOFA Skoru için regresyon sonuçları (hastalık başlangıç zamanı).....	93
Tablo 5.8. Regresör modellerinin başlangıç saatine kadar olan saatlerde CC performans karşılaştırması.....	94
Tablo 5.9. Regresör modellerinin başlangıç saatine kadar olan saatlerde MAE performans karşılaştırması.....	95
Tablo 5.10. Regresör modellerinin başlangıç saatine kadar olan saatlerde RMSE performans karşılaştırması.....	97
Tablo 5.11. Sepsis hastalığı için tahmin sonuçları (hastalık başlangıç zamanı) (AUC).....	104
Tablo 5.12. Sınıflandırma modellerinin başlangıç saatine kadar olan saatlerde AUC performans karşılaştırması.....	105
Tablo 5.13. Hayati belirtilerin Sepsis tahmin performansına olan etkisi.....	106
Tablo 5.14. Hayati belirtilerin SOFA skoru tahmin performansına olan etkisi.....	107

Tablo 5.15. CNN + RF modelinin Sepsis tahmininde diğer çalışmalarla olan karşılaştırılması.....	107
---	-----



ŞEKİLLER LİSTESİ

	Sayfa
Şekil 1.1. Örnek bir karar ağacı.....	9
Şekil 1.2. RF regresörünün genel yapısı.....	18
Şekil 1.3. Bir LSTM bellek bloğu.....	19
Şekil 1.4. Genel Bi-LSTM mimarisi.....	20
Şekil 1.5. Havuzlama katmanında maksimum ve ortalama alma işlemleri.....	22
Şekil 1.6. Örnek bir sinir ağında seyreltme işlemi uygulanması.....	23
Şekil 2.1. PH semptom seviyesi için önerilen sistem.....	31
Şekil 2.2. Enfeksiyon türüne göre çalışma sayısı.....	34
Şekil 2.3. Enfeksiyon türlerinde makine öğrenme yöntemlerinin dağılımı.....	36
Şekil 2.4. Enfeksiyon türlerinde makine öğrenme özneliklerinin dağılımı.....	37
Şekil 2.5. Küçük veri probleminin çalışmalardaki etkileri.....	38
Şekil 2.6. Küçük veri problemi için önerilen çözümler.....	39
Şekil 2.7. Dengesiz veri probleminin çalışmalardaki etkileri.....	40
Şekil 2.8. Dengesiz veri problemi için önerilen çözümler.....	41
Şekil 2.9. Enfeksiyon tahmini ve izlenmesi çalışmalarında kullanılan performans ölçüm metrikleri.....	42
Şekil 2.10. SOFA skoru bileşenleri.....	45
Şekil 2.11. SOFA skoru tahmini için önerilen genel yapı.....	52
Şekil 3.1. Bir adımda oluşan GRF değerleri.....	54
Şekil 3.2. GRF ölçen örnek bir akıllı ayakkabı.....	54
Şekil 3.3. Kontrol ve Parkinson hastalığına sahip bireylerin salınım süresi-adım grafiği.....	55

Şekil 3.4.	Her bir GRF sensörünün ayaktaki konumu.....	57
Şekil 3.5.	MIMIC III veri kümesi genel şeması.....	59
Şekil 3.6.	Kalp ritmi ölçmek için kullanılan bir ECG sensörü ve akıllı saat.....	61
Şekil 3.7.	Kan basıncını ölçen sensörler.....	62
Şekil 3.8.	Solunum hızı ölçen sensör.....	62
Şekil 3.9.	Oksijen Satürasyonu ölçen optik sensör.....	63
Şekil 3.10.	GCS skoru ve alt başlıkların puan dağılımı.....	64
Şekil 3.11.	Bilekten sıcaklık ölçen termistör tabanlı örnek sensör.....	65
Şekil 3.12.	Veri kümesine uygulanan dahil etme ölçütleri.....	66
Şekil 4.1.	İkili kod üretilme süreci.....	72
Şekil 4.2.	Örnek bir imgenin histogramının hesaplanması.....	73
Şekil 4.3.	1 boyutta LBP yönteminin uygulanması.....	74
Şekil 4.4.	Hayati belirti sinyallerinin 2 boyuta çevrilmesi.....	77
Şekil 4.5.	GRF sensörlerinden çıkartılan özniteliklerin 2 boyuta çevrilmesi.....	78
Şekil 4.6.	Önerilen CNN ve Bi-LSTM derin öğrenme modelin genel mimarisi.....	79
Şekil 4.7.	Önerilen CNN ve RF/LWRF derin öğrenme modelin genel mimarisi.....	81
Şekil 5.1.	LWRF yönteminde kullanılan k parametresinin UPDRS ve H&Y değeri tahmininde etkisi.....	89
Şekil 5.2.	k-NN yönteminde kullanılan k parametresinin UPDRS ve H&Y değeri tahmininde etkisi.....	89
Şekil 5.3.	Sepsis başlamadan önceki altı saat için regresör modellerinin CC performansı.....	94
Şekil 5.4.	Sepsis başlamadan önceki altı saat için regresör modellerinin MAE performansı.....	96

Şekil 5.5. Sepsis başlamadan önceki altı saat için regresör modellerinin RMSE performansı.....	97
Şekil 5.6. LWRF yönteminde kullanılan k parametresinin SOFA skoru tahmininde etkisi.....	98
Şekil 5.7 k-NN yönteminde kullanılan k parametresinin SOFA skoru tahmininde etkisi.....	98
Şekil 5.8. Farklı SOFA skorlarına göre GCS değerleri.....	99
Şekil 5.9. Farklı SOFA skorlarına göre diastolik kan basıncı değerleri.....	100
Şekil 5.10. Farklı SOFA skorlarına göre sistolik kan basıncı değerleri.....	100
Şekil 5.11. Farklı SOFA skorlarına göre vücut sıcaklığı değerleri.....	101
Şekil 5.12. Farklı SOFA skorlarına göre kalp ritmi değerleri.....	101
Şekil 5.13. Farklı SOFA skorlarına göre kalp ritmi değerleri.....	102
Şekil 5.14. Farklı SOFA skorlarına göre nefes alma hızı değerleri.....	102
Şekil 5.15. Sepsis başlamadan önceki altı saat için sınıflandırıcı modellerinin AUC performansı.....	105

SİMGELER VE KISALTMALAR LİSTESİ

AUC	Area Under Curve
CC	Correlation Coefficient
CNN	Evrişimsel sinir ağı (Convolutional Neural Network)
GCS	Glasgow koma skalası (Glasgow Coma Scale)
GRF	Ground Reaction Force
k-NN	k en yakın komşu(k nearest neighbour)
LBP	Yerel ikili örüntü (Local Binary Pattern)
LIR	Lineer regresyon
LR	Lojistik regresyon
LSTM	Uzun kısa süreli hafıza (Long Short Term Memory)
LWRF	Yerel Ağırlıklandırılmalı Rastgele Orman (Locally weighting Random Forest)
MAE	Mean Absolute Error
MIMIC	Medical Information Mart for Intensive Care
NB	Naive Bayes
PH	Parkinson Hastalığı
PPCA	Probabilistic Principal Component Analysis
RBD	Ayrıklaştırma ile regresyon (Regression by discretization)
RF	Rastgele orman (Random Forest)
RMSE	Root Mean Square
RNN	Tekrarlayan yapay sinir ağı (Recurrent Neural Network)
SOFA	Sequential (Sepsis Related) Organ Failure Assessment
SVM	Destek vektör makinesi (Support vector machine)
SVR	Destek vektör regresyonu(Support vector regression)

1. GİRİŞ

1.1. Motivasyon ve Tanım

Teknolojinin gelişmesiyle birlikte verinin toplanması, saklanması ve işlenmesi yaygınlaşmış ve bu sebepten giyilebilir teknoloji günlük hayatımızda gitgide popülerleşmeye başlamıştır. Giyilebilir sensörler ve akıllı tekstiller daha küçük, daha ucuz ve kullanıcı tarafından kolaylıkla erişilebilir hale geldikçe günlük aktivitelerin takibi ve hastalık takibi gibi konularda yaygın olarak kullanılmaya başlanmıştır. Giyilebilir teknoloji ilk olarak aktivite tanımada insanların günlük aktivitelerini takip etmek ve hayat kalitesini arttırmak için kullanılmaya başlanmıştır [1]. Aktivite tanımayla birlikte giyilebilir teknoloji, günlük hayatta kişi tespiti, kişiye özel reklam faaliyetleri, sağlık ve güvenlik önlemlerine kadar geniş bir yelpaze içinde kullanılmaya başlanmıştır [2] [3]. Giyilebilir teknoloji günümüzde yaygınlaştıkça insanların hayatını kolaylaştırmaya başlamıştır. Kolay bir şekilde insanlar bu teknolojiyi üzerinde taşıyabilmektedirler. Giyilebilir teknoloji bir saat veya bileklik şeklinde olmakla birlikte bir bant veya giysi içine yerleştirilmiş sensörlerden de oluşabilmektedir. Bu teknolojiler sayesinde insanlar kendi durumları hakkında hızlıca ve doğru biçimde geri bildirim alabilmektedirler.

Giyilebilir teknolojiler ayrıca rehabilitasyon ve sağlık alanında da sıkça kullanılmaktadır. Hastaların durumunu izlemeye yarayan bu teknolojiler aynı zamanda tedavi sürecini desteklemeye de yardımcı olmaktadır. Giyilebilir teknolojiler sadece günlük aktivite olarak rehabilitasyonu sağlamakla kalmayıp, anlamlı ve zamanında geri bildirimler sağlayarak, hastalara ve sağlık personeline yardımcı olmaktadır. Bu geri bildirim, motor fonksiyonlarının iyileşmesini en üst düzeye çıkarmayı amaçlayan beceri pratiğini yönlendirebilir ve geliştirebilir [4].

İlk olarak ortaya çıkan ve aktivite tanımaya dayalı giyilebilir teknoloji ivmeölçer, jiroskop ve manyetometre sensörlerinden oluşmaktadır. Bir triaksiyal ivmeölçer, bulunduğu konumun üç ekseninde değişimini algılayıp herhangi bir fiziksel aktivite sırasında veya sonrasında zamana bağlı bir konum değişim sinyali üretebilir. Jiroskop sensörü, bir nesnenin titreştiği aynı düzlemdeki titreşim eğilimini kullanarak açısal hızı ölçer. Manyetometre ise, manyetik materyalin bir ferromagnet gibi manyetizasyonu veya belirli bir konumdaki bir manyetik alanın yönü, kuvveti veya göreceli değişimi olan manyetizmayı ölçen bir araçtır [1]. Bu sensörlerin hangi aktivitenin ne zaman ve ne kadar süreyle yapıldığı, düşüş tespiti, hastalık tespiti ve tele-rehabilitasyon gibi birçok alanda yaygın olarak kullanımı mevcuttur.

Vücuda giyilen sensörler günümüzde birçok şekil ve boyuttadır: Bunlar; göğüs bölgesine giyilen kalp ritmi ölçen kayışlar, beyin aktivitesi ölçen ve başa takılan bantlar, duruş tespit eden giysiler, bebek ve hamilelerin hayati belirtilerini ölçen elektronik yapıştırılabilir parçalar gibi birçok formda olabilir [5]. Bu sensörler, kalp atış hızı, solunum hızı, oksijen saturasyonu ve kan basıncı hakkında bilgi sağlayabilir ve önemli bağlamsal bilgiler sağlayan veya kullanıcılara geri bildirim sağlayan hayati işaret anormalliklerini tespit edebilir. Akıllı saatler ve göğüs kayışları gibi hayati belirti sensörlere sahip tüketici sınıfı cihazların piyasada bulunması ve kolay erişilebilirliği sayesinde bu sensörler günümüzde birçok çalışmaya dâhil edilmekte ve kullanılmaktadır [4]. Akıllı giysiler, giysi parçalarının veya ayakkabıların parçası olarak günlük yaşama entegre olabileceği ve fizyolojik, bağlamsal veya biyometrik özellikleri izleyebildiği için giyilebilir sistem olarak kabul edilebilir. Örneğin, bir akıllı eldiven, hastaların ellerindeki hareket sorununu iyileştirmelerini sağlayabilir. Bu sistem aynı zamanda yaralanmalardan sonra iyileşmek veya diğer nörolojik bozukluklardan kaynaklanabilecek sorunlara yardımcı olmak için de kullanılabilir [5].

Giyilebilir kamera sistemleri de giyilebilir teknoloji olarak düşünülebilir. Bu kamera sistemleri rehabilitasyon çalışmalarında sıkça kullanılmaktadır. Bir çalışmada araştırmacılar, giyilebilir kameralarla birlikte hareket sensörlerini kullanarak diz bölgesinde kemik erimesi olan hastaların kendi kendine rehabilitasyon yapmasını sağlamıştır [5]. Bu sistem sayesinde bir süre sonra hastaların durumu iyileşmiş ve duruş bozukluğu giderilmiştir. 360 ° kameralar, yapay gerçeklik, yapay zekâ, derin öğrenme ve bilgisayar görme gibi yeni teknolojiler, giyilebilir kamera deneyimini geliştirerek cihazların kullanım örneklerini ve uygulamalarını muhtemel olarak genişletecektir.

Akıllı gözlük olarak ortaya çıkan ve son 2-3 yılda popülerleşen bir sistem olan arttırılmış gerçekliğe sahip gözlükler de günümüzde giyilebilir sensör kategorisinde yerini almıştır. Bu sistemler endüstriyel ve şirket ortamlarda çalışanları takip etmek ve bilgilendirmek için kullanıldığı gibi sağlık alanında da sağlık çalışanlarına da hastalar hakkında ek bilgi vermek amacıyla kullanılmaktadır. Bu sistemler günümüzde giderek daha da karmaşık hale gelmiştir, daha kapsamlı bir deneyim sağlamak ve holografik nesnelerle etkileşime olanak sağlamak için dijital bilgilerin üst üste binmesinden, konum izlemeye ve derinlik sensörlerine kadar birçok kullanım alanı bulunmaktadır. Farklı giyilebilir teknoloji sistemleriyle birleştirip çalışmalarda kullanılmıştır. Bir çalışmada Serabral Palsiye sahip çocuklarda nöromotor kabiliyetleri arttırmak için akselerometre ve kas elektrotlarına sahip bir bileklik yardımıyla arttırılmış gerçeklik tabanlı bir oyun geliştirilmiştir [6]. Başka bir

çalışmada felçli hastalara özel akıllı bir gözlük tasarlanarak egzersiz ve hasta durum takibi gerçekleştirilmiştir [7].

Giyilebilir sensörlerin kolay erişilmesi, küçülmesi ve kolay taşınmasından sonra sağlık alanında birçok amaçla sıkça kullanılmaya başlanmıştır. Sağlık alanında giyilebilir sensörlerin kullanılmasının sebebi, hastanın sağlık parametrelerinin uzaktan izlemeye bilme imkânı ve dolayısıyla hastaların ve aile bireylerinin bir sağlık merkezine gitmelerine gerek kalmamasıdır [8]. Giyilebilir sensör teknolojilerinin, sağlık alanında hastalıkları önleme, erken teşhis ve kronik durumların yönetimi için etkili bir araç olarak kullanımı yaygınlaşmıştır [9]. Sağlık alanında giyilebilir sistemlerin veri toplama ve işleme kapasitesi arttıkça hastaların uzman görüşüne gerek kalmadan rahatlıkla kendi kendilerine hastalıklarının durumunu izleyebilme imkânı da artmaktadır. Sağlık alanında üç büyük giyilebilir sensör kategorisi vardır. İlki Electrocardiography (ECG) gibi fizyolojik sinyal ölçen sensör birimleri. İkincisi, ivmeölçerler ve jiroskoplar gibi hareket sensörü birimleri. Son olarak ise video kameralar, hayati belirti ölçüleri (kalp hızı, nabız ve sıcaklık gibi) ve basınç sensörleri gibi çevresel sensör üniteleridir [10].

Fizyolojik sinyaller, belirli bir vücut bölümünün elektriksel aktivitesini yansıtır. Vücuttaki elektriksel aktiviteler ile kişinin fizyolojik durumu hakkında bilgi sağlanır. Fizyolojik durumu belirten birçok sinyal türü vardır. Bunlar Electroencephalography (EEG), Electromyography (EMG), Electrocardiography (ECG), Electrooculography (EOG) sinyalleridir [11].

EEG, deneğin kafatası üzerine elektrot olarak bilinen elektrik sensörlerinin yerleştirilmesiyle ölçülür; bu sayede beyin elektriksel aktivitesi izlenmiş olur. Bu aktivite, nöronların ateşlenmesiyle oluşan elektriksel sinyallerdir. EEG analizi; Parkinson hastalığı, Alzheimer hastalığı, epilepsi, huzursuz bacak sendromu (Restless Leg Syndrome, RLS), uyku apnesi, Huntington hastalığı ve koma hastalarında beyin ölümünün saptanmasında kullanılabileceğinden sağlık alanında önemli bir yere sahiptir [12]. EMG, iskelet kaslarının elektriksel aktivitesini ölçer. Elektrotlar ilgili kasların bulunduğu yerdeki deri üzerine yerleştirilir. EMG sinyalleri kas aktivasyonu, kas tarafından üretilen kuvvet ve kas durumunu gösterir. EMG sinyalleri genellikle Parkinson hastalığı, huzursuz bacak sendromu, nöbetler, Karpal tünel sendromu ve artrit durumları gibi nöro-kas hastalıklarını tespit etmek için analiz edilir. ECG ise elektrotların göğüs kafesi bölgesine yerleştirilmesiyle ölçülür. Bu elektrotlar insan kalbinin elektriksel aktivitesini kaydeder. Amaç, her kalp atım döngüsü sırasında kalp kaslarının depolarize olduğunda meydana gelen dakikadaki kalp atışındaki sinyal değişikliklerini yakalamaktır. Kalp atımında en sık görülen bozukluklar

arasında atriyal ve ventriküler fibrilasyon, miyokard enfarktüsü bulunmaktadır. Bu bozuklukların tespitine ECG verisi kullanılmaktadır. Kan basıncı, glikoz seviyeleri ve kalp atım hızı gibi diğer vücut parametreleri ile izlendiğinde ECG verileri, diyabet, yüksek / düşük kan basıncı ve stres seviyeleri gibi çeşitli durumların tespitinde de kullanılabilir. EOG, retina ile kornea arasındaki potansiyel farktan kaynaklanan elektriksel bir sinyaldir. Bu potansiyel fark, retinada negatif bir kutba ve korneada pozitif bir kutba sahip olarak düşünülebilen göz küresindeki elektriksel olarak aktif sinirlerin varlığından kaynaklanır. Elektriksel aktivite göz küresi hareketi ile sürekli değişmektedir. Böylece, zaman-eksenindeki potansiyelin bu değişimlerinin kaydedilmesiyle EOG sinyali elde edilir. EOG sinyalleri uyku kalitesi belirleme, yorgunluk tespiti gibi durumların tespitinde kullanılır [11].

Geleneksel olarak, medikal veriler uzmanlar tarafından bir takım kararlar vermede kullanılmaktadır. Bu kararlar teşhis, hastalık seviyesi belirleme, tedavi izlemesi, ilaç etkinliği ve yaşam kalitesine ilişkin sonuçlar çıkarılmasına olanak sağlar. Fakat uzman bilgisiyle bile, el ile medikal verilerin yorumlanması kişiden kişiye değişiklik göstermektedir. Dahası, bir medikal veri olan hastalardan elde edilen sinyallerin yorumlanması insan hatalarına açık ve yorucu bir süreçtir. Bilgisayar destekli medikal veri yorumlama, yorulma ile ilgili hatalardan etkilenmez ve sübjektif yorum sorununu ortadan kaldırabilir. Bu sorunları ortadan kaldırmak için klinik desteği sağlayan uzman sistemler ortaya çıkmıştır. Fakat uzman sistemler var olan bilgiyi kullanarak tanımlanan bir takım kurallarla karar vermektedir ve çoğu durumda yetersiz ve yanlış kararlar vermektedirler. Bu dezavantajı aşmak için medikal verilerin makine öğrenmesi yöntemleriyle işlenmesi gerekmektedir. Makine öğrenmesi var olan bilgiyi kullanmak yerine örneklerden öznitelikler çıkararak saklı kalmış bilgiyi karar aşamasında kullanır [12].

Medikal alanda makine öğrenmesi genel olarak üç işlevde kullanılmaktadır. Bunlar uzaktan izleme, hastalık teşhisi ve hastalık semptom seviyesi izlemedir. Uzaktan izleme yaklaşımında, hastalardan alınan girdi sinyalleri rehabilitasyon ve hasta durum bilgisinin alınması gibi amaçlarla makine öğrenmesi yöntemleriyle işlenir. Hastalık teşhisinde, makine öğrenmesi girdi olarak verilen mevcut verileri kullanarak hastalığın var olup olmadığını sınıflandırma yaklaşımıyla tahmin eder. Son olarak hastalık semptom seviyesi tespiti ise hastalığın ilerleyişini takip etmek için yapılan bir analizdir. Hastalığın tahmin edilmesi yerine hastalığın seviyesinin değer tahmini regresyon yöntemleriyle yapılır. Yani hasta olan bir kişi ne kadar hasta ve hastalığı nasıl ilerliyor sorularına cevap bulunmaya çalışılır. Hastalık seviyesi belirlenmesi genellikle sağlık personelinin yaptığı çeşitli testlerle gerçekleşir. Bu süreç zaman alan, medikal uzmanlık gerektiren ve yorucu bir süreçtir.

Dolayısıyla makine öğrenmesi ile hasta verileri işlenerek süreç hızlandırılıp, doğru bir şekilde hastalık seviyesi değeri tahminiyle medikal personele yardımcı olunabilir. Bu sürecin bir diğer boyutu ise giyilebilir sensörlerle bu analizi gerçekleştirebilmektedir. Giyilebilir sensörlerin günümüzde kolayca kullanılabilir ve erişilebilir hale gelmesiyle hastalar rahatlıkla bu sensör sistemleriyle izlenip, makine öğrenmesi yöntemleriyle hastalık seviyesi takibi yapılabilir. Yani hastalar herhangi bir sağlık merkezine gitmelerine gerek kalmadan hastalık durumu izlenebilir.

Hastalık durumu, birden fazla giyilebilir sensör kaynağından faydalanarak daha gürbüz ve doğru bir biçimde izlenebilir. Elimizde n sayıda giyilebilir sensör olduğu varsayılırsa, bu n sayıda giyilebilir sensörden alınan zaman serisi sinyalleri $n_1 + n_2 + \dots + n_n$ şeklinde birleştirilerek bir nicel değer olan hastalık seviyesi tahmini çeşitli regresyon yöntemleriyle tahmin edilebilir. Bu bağlamda, tez çalışmasında giyilebilir sensörlerle elde edilen sinyalleri kullanarak hastalık seviyesi değeri tahmini çalışmaları gerçekleştirilmiştir. Çalışmada bu amaçla ölümcül bir enfeksiyon hastalığı olan Sepsis ve günümüzde tedavisi olmayan nörolojik bir hastalık olan Parkinson hastalığı üzerine çalışmalar yapılmıştır. Ayrıca enfeksiyon hastalıklarının bilgisayar yöntemleri kullanarak izlenilmesi üzerine bir literatür çalışması gerçekleştirilmiştir. Bu literatür çalışmasının amacı, hangi enfeksiyon tipinde en çok çalışmanın olduğunu görmek, hangi hayati belirti değerlerinin çalışmalarda daha etkin kullanıldığını belirlemek ve hangi makine öğrenmesi yöntemlerinin en çok kullanıldığını ve etkisini tespit etmektir. Bu literatür taraması sonucunda literatürde son zamanlarda en çok çalışılan ve incelenen enfeksiyon tipinin Sepsis olduğu tespit edilmiştir. Bu sebeple tez çalışmasında en ölümcül enfeksiyon tipi olan Sepsis hastalığı üzerine kapsamlı deneyler gerçekleştirilmiştir. Sepsis hastalığında giyilebilir sensörlerle kolayca elde edilebilen kalp ritmi, kan basıncı ve oksijen saturasyonu gibi hayati belirtiler kullanılmıştır. Bu değerler, hastalık durumunu takip etmeyi sağlayan organ yetmezliği skorunun tahmin edilmesinde kullanılmıştır. Parkinson hastalığı semptom seviyesi değeri tahmini, ayağa giyilen ve ayağa uygulanan kuvveti ölçen giyilebilir sensörlerle yürüyüş analizi yapılarak gerçekleştirilmiştir. Hastalık seviyesi için çeşitli testler sonucunda oluşturulan skora sistemleri kullanılmıştır. Bu tahminleri gerçekleştirmek için tez çalışmasında geleneksel makine öğrenmesi yöntemlerinin yanı sıra, derin öğrenme ve tez çalışması kapsamında geliştirilen CNN ve Rastgele Orman tabanlı derin öğrenme hibrit mimarileri kullanılmıştır. Değeri tahmin analizinde, geliştirilen hibrit mimarilerinin geleneksel yöntemlere göre performans artışı sağladığı gözlemlenmiştir. Hastalık seviyesi tahminiyle birlikte her iki hastalık içinde hastalık teşhisi çalışmaları da gerçekleştirilmiştir.

1.2. Tez Çalışmasının Genel Katkıları

Tez çalışmasının genel katkıları için teze dört yönden bakılabilir. İlki, şimdiye kadar ki bilgisayar teknikleri kullanan sağlık alanındaki çalışmaların çoğu genel olarak hastalık teşhisi veya hastalığın var olup olmadığını tahmin etmeye odaklanmıştır. Bu odaklanma aslında önemli bir konu olan hastalık durumunun takibi yani hastalık semptom seviyesi izlenmesi konusunu gölgede bırakmıştır. Hastalık durumunu takip etmek, birçok önlemin önceden alınmasını ve tedavi sürecinin erken başlamasını sağlayabilir. Hastalık gidişatının belirlenebilmesi ve hastalığın derecesinin bilinmesi, sağlık çalışanları açısından bakıldığında hastanın hangi evrede olduğunu ve bu evreye göre hangi ilaç ve rehabilitasyon tedavilerine başvurulabileceği hakkında klinik olarak yardımcı olabilme imkanı sağlar. Bu bağlamda tez çalışmasında bir sınıflandırma problemi olan hastalık tahmini yerine bir regresyon problemi olan hastalık derecesi veya semptom şiddeti tahmini gerçekleştirilmiştir. Çeşitli regresyon yöntemleri ile Parkinson ve Sepsis hastalığında kullanılan hastalık durum değerlendirme ölçütlerinin kesin değerinin tahmini üzerine çalışmalar gerçekleştirilmiştir. Bu değerlerin bilgisayar yöntemleri ile tahmin edilmesi, zaman ve iş gücü bakımından sağlık çalışanlarına kolaylık sağlayacaktır.

Tezin ikinci genel katkısı ise hastalık durum takibini laboratuvar ölçümleri ve kan alma gibi invazif yöntemleri kullanmak yerine giyilebilir sensörlerle elde edilebilecek invazif olmayan ölçüm yöntemleri ile gerçekleştirmektir. Bu yaklaşımın önemi, hastane ve tıbbi bir ortama gerek kalmadan gerekirse hastanın evinde giyilebilir yaklaşımlarla rahatlıkla elde edilebilecek ölçümleri kullanarak hastalık takibi yapabilmektir. Bu bağlamda Parkinson hastalığı için ayakkabılar içine yerleştirilen sensörler kullanılarak yürüyüş analizliyle hastalık durum takibi üzerine çalışmalar yapılmıştır. Sepsis hastalığı izlenmesi için ise kalp ritmi, kan basıncı, sıcaklık değeri gibi giyilebilir sensörlerle kolaylıkla ölçülebilen hayati belirti değerleri ile hastalık durum takibi üzerine çalışmalar yapılmıştır.

Tezin üçüncü değer genel katkısı ise günümüzde çok önemli bir konu olan ve bir çok çalışmanın gerçekleştirildiği enfeksiyon hastalıklarının bilgisayar yöntemleriyle takibi üzerine detaylı bir literatür çalışması gerçekleştirilmiştir. Bu literatür çalışmasında son 15 yıl içindeki çalışmalar incelenmiş ve bu çalışmalarda kullanılan makine öğrenme yöntemleri, kullanılan öznelilikler, performans ölçütleri gibi bir çok konu hakkında veriler toplanmıştır. Tez çalışmasının bu literatür taraması bölümü, enfeksiyon hastalıklarının bilgisayar ile takibi üzerine ileride yapılacak olan çalışmalar için bir rehber olarak yol göstererek katkıda bulunacaktır.

Tez çalışmasının son değer katkısı ise regresyon probleminde giyilebilir sensörlerle elde edilen girdilerin yerel ağırlıklandırılmalı rastgele orman yöntemiyle (LWRF) ve hibrit derin öğrenme yöntemleriyle işlenmesidir. Hibrit yöntemlerle verinin işlenebilmesi için sinyal verileri bir dönüşüm şemasıyla 2 boyutlu verilere dönüştürülmektedir. İki boyutlu verilere dönüşen sinyaller hibrit mimari kapsamında CNN yapısıyla anlamlı yerel öznitelikler çıkartılarak karar ağacı tabanlı yöntemlerle işlenmiştir. Hibrit mimarilerin geleneksel makine öğrenme ve derin öğrenme yöntemlerinden daha iyi performans gösterdiği tez çalışmasında kanıtlanmıştır. Tez çalışmasında önerilen LWRF yönteminde yerel ağırlıklandırmanın regresyon ve sınıflandırma performansını arttırdığı kanıtlanmıştır. Ek olarak bu tez çalışması, 1 boyutta LBP özniteliklerini hastalık zaman serisi sinyallerine uygulayan ilk çalışmadır.

1.3. Temel Makine Öğrenmesi Yöntemleri

1.3.1 Regresyon

Sınıflandırmada, yeni bir örneğin kategorisi (sınıfı), aşağıdaki forma (1.1) sahip bir eğitim kümesi [13] incelenerek belirlenebilir:

$$y_c = f_c(X, \theta_c), y_c \in Z \quad (1.1)$$

X gözlenen öznitelik vektörü, y_c öznitelik vektörünün sınıfı, $f_c(.)$ eğitilen modelin fonksiyonu, θ_c sınıflandırıcının parametreleri ve Z bütün sınıf etiketlerini temsil eder.

Tez çalışmasında, basit bir sınıflandırma sistemi ile uygulanamayan UDPRS ve H & Y ölçeğine göre PH semptomlarının ve Sepsis hastalığının tespitinde kullanılan SOFA skorlarının kesin değerini tahmin etmek istenmektedir. Bunu gerçekleştirmek için gözlemlenen öznitelik vektörünü, bir sürekli değişkene atamak için regresyon modeli kullanılmıştır. Regresyon analizi, çıktı ve girdi değişkenleri arasında fonksiyonel bir ilişki (model) bulma yöntemini belirtir. Sınıflamanın aksine, regresyon, ayrı kategorilerle uğraşmaz, ancak sürekli değerler ile verilir (1.2):

$$y_r = f_r(X, \theta_r), y_r \in R \quad (1.2)$$

y_r öngörülen sürekli değeri gösterir, $f_r(.)$, regresörün fonksiyonudur, θ_r , regresörün parametrelerini belirtir ve R , gerçel sayılar kümesini temsil eder. Parkinson hastalığı problemi için; X , GRF sinyallerinden çıkarılan sayısal öznitelikler kümesini gösterir ve y_r

UPDRS veya H & Y ölçeği değeri şeklinde tahmin edilecek olan PH semptomuna karşılık gelir. Sepsis hastalığı problemi için; X , Hayati belirtilerden çıkarılan sayısal öznitelikler kümesini gösterir ve y , SOFA skor değeri şeklinde tahmin edilecek olan sepsis semptomuna karşılık gelmektedir.

1.3.2. k-en yakın komşu (k-NN)

k-en yakın komşu (k-Nearest Neighbour (k-NN)) parametrik olmayan örnek tabanlı bir algoritmadır Basitliğine rağmen çoğu makine öğrenmesi probleminde etkili sonuçlar elde edilmiştir [14]. En yakın komşu algoritmaları benzerliğe dayalı bir öğrenme üzerine kurulmuştur, verilen bir test örneği var olan benzer eğitim örnekleriyle karşılaştırılır. Eğitim örnekleri n tane öznitelikle temsil edilmektedir. Her bir örnek n boyutlu bir uzayda birer nokta olarak gösterilmektedir. Bu dönüşüm yoluyla bütün eğitim verileri n boyutlu bir örüntü uzayında saklanabilmektedirler. Bilinmeyen bir örneğe etiket ataması yapılırken bir k en yakın komşu sınıflandırıcısı, n boyutlu örüntü uzayında test örneğine en yakın k tane eğitim örneğini aramaktadır. Bu k eğitim örneği, bilinmeyen test örneğinin en yakın k komşusudur [15].


Yakınlık çeşitli uzaklık ölçütleriyle değerlendirilmektedir. Bunlar Öklid uzaklığı, Manhattan uzaklığı ve Mahalanobis uzaklığı olabilir. En sık kullanılan uzaklık ölçütü ise Öklid uzaklığıdır. $X_1 = (x_{11}, x_{12}, \dots, x_{1n})$ ve $X_2 = (x_{21}, x_{22}, \dots, x_{2n})$ ile temsil edilen iki nokta veya iki örnek arasındaki Öklid uzaklığı Eşitlik 1.3 ile verilen denklemle ifade edilmektedir:

$$D(X_1, X_2) = \sqrt{\sum_{i=1}^n (x_{1i} - x_{2i})^2} \quad (1.3)$$

Bu denklemi açıklamak gerekirse her bir öznitelik için iki örneğin (X_1, X_2) farkı bulunur, karesi alınır ve tüm öznitelikler arasındaki farkı bulmak için toplanır. k en yakın komşu sınıflandırıcısında bilinmeyen bir örneğin sınıf değeri, k en yakın komşusunda en çok bulunan sınıf olarak atanır. $k=1$ seçildiğinde bilinmeyen örnek, eğitim kümesinde en yakındakinin sınıfına atanır. En yakın sınıflandırıcılar regresyon yani gerçel değer tahmininde de kullanılabilmektedir. Bu durumda sınıflandırıcı bilinmeyen örneğe değer atarken, en yakın k eğitim örneğinin gerçel değerlerinin ortalamasını alır [15].

1.3.3. J48 karar ağacı

Karar Ağaçları önceden belirlenmiş hedef değişkenlere (özniteliklere) sahiptir. Yapısal olarak bakıldığında yukarıdan aşağıya doğru bir strateji izlenir. Karar ağacı, çok sayıda kayıt içeren bir veri kümesini, bir takım karar kuralları uygulayarak daha küçük kümelere bölmek için kullanılan bir yapıya sahiptir [16]. Başka bir deyişle, basit karar verme adımları uygulayarak büyük miktarlardaki kayıtların çok küçük kayıt gruplarına bölünmesiyle kullanılan bir yapıdır. Şekil 1.1. ile örnek bir karar ağacı verilmiştir. Kök ve iç düğümler bir değişkeni (öznitelik) temsil etmektedir. Yaprak düğümler ise sınıfları temsil etmektedir. Farklı algoritmalara göre karar ağacının yapısı ve düğümlerin içeriği değişmektedir.



Şekil 1.1. Örnek bir karar ağacı

J48 algoritması karar ağaçlarını kullanarak, sınıfı kesin bir şekilde eğitim verileri üzerinden ayıran bir öznitelik bulmaya çalışır. Veri örnekleri hakkında en fazla bilgiyi veren öznitelik, en yüksek bilgi kazanım (Information Gain) değerine sahiptir. Bu özniteliğin olası değerlerine bakarak J48 ağacı budar ve hedef değer ataması yapar. Daha sonra J48 en yüksek bilgi kazanımı olan diğer öznitelikleri arar. Bu süreç, bir hedef değeri belirlemek için belirli bir kuralı veren özniteliklerin kombinasyonu ile ilgili kesin bir karar alınıncaya kadar devam eder. Bu karar ağacının yardımıyla bütün ilgili öznitelikler kontrol edilir ve sonuç olarak yeni örneklerin hedef değerleri tahmin edilir [17]. Bu algoritmada kullanılan bilgi kazanımı ile öznitelik bulma yöntemi 4 aşamadan oluşmaktadır [18].

- S veri kümesini temsil etmek üzere ilk olarak bilgi entropisi hesaplanır (1.4).

$$Entropi(S) = - \sum_{i=1}^m p_i \log_2 p_i \quad (1.4)$$

p_i i sınıfına sahip örneklerin tüm örneklerle olan oranını temsil etmektedir. m sınıf sayısını göstermektedir. Eğer veri kümesindeki her bir örnek aynı sınıf etiketine sahip olsaydı, $m = 1$ ve $p_i = 1$ olurdu bu durumda ise entropi 0 olurdu. Eğer veri kümesindeki her bir örneğin ayrı sınıf etiketi olsaydı $p_i = \frac{1}{m}$ olurdu ve entropi en yüksek değere ulaşırdı ($Entropi(S) = \log_2 m$).

- İkinci olarak S veri kümesinde ayrışma entropisi hesaplanır.

S veri kümesinde öznitelikler S_L ve S_R olarak ayrıldığı varsayılırsa. Ayrıştırma entropisi her bir alt kümenin ağırlıklandırılmış entropisi olarak hesaplanır (1.5).

$$Entropi_A(S) = \frac{|S_L|}{|S|} Entropi(S_L) + \frac{|S_R|}{|S|} Entropi(S_R) \quad (1.5)$$

Burada A bütün öznitelikler içerisinde seçilen herhangi bir özniteliktir, S_L ve S_R A ile ayrıştırılmış S veri kümesinin alt kümeleridir. $|S|$ S veri kümesinde bulunan toplam örnek sayısıdır. $|S_L|$ ve $|S_R|$ ise aynı şekilde sırasıyla S_L ve S_R alt kümelerinde bulunan örnek sayılarıdır.

- Üçüncü olarak A özniteliğinin bilgi kazanımı hesaplanır.

Seçilen A özniteliğinin toplam entropiyi etkili bir şekilde azaltmasını sağlamak için önce A özniteliğinin bilgi kazanımı Eşitlik 1.6 ile hesaplanır.

$$Kazanım(A) = Entropi(S) - Entropi_A(S) \quad (1.6)$$

Yüksek bilgi kazanımının anlamı daha düşük entropi ve dolayısıyla veriyi temsil etmekte kullanılabilecek daha iyi öznitelik demektir.

- Son olarak bilgi kazanım oranı hesaplanır.

J48 algoritması overfitting durumundan kaçınmak ve bilgi kazanımı normalize etmek için ayrışma bilgisi hesaplanır. Ayrışma bilgisi Eşitlik 1.7 ile verilen denklemle hesaplanır:

$$Ayrışma\ Bilgisi(A) = - \sum_{i=1}^k \frac{|S_i|}{|S|} \log_2 \frac{|S_i|}{|S|} \quad (1.7)$$

A özniteliği için bilgi kazanım oranı Eşitlik 1.8 ile verilmiştir:

$$Oran(A) = \frac{Kazanım(A)}{Ayrışma Bilgisi(A)} \quad (1.8)$$

Bilgi kazanım oranı karar ağacındaki her bir düğüm için hesaplanmaktadır. En yüksek orana sahip öznitelikler seçilir ve karara ağacında düğümleri oluşturur. S veri kümesi bu yöntem tekrarlı olarak kullanılarak birden çok alt kümeye bölünebilir.

1.3.4. Ayırıklaştırma ile regresyon (RBD)

Ayırıklaştırma ile regresyon (Regression By Discretization (RBD)) yaklaşımı, regresyon problemini çok sınıflı bir sınıflandırma problemine dönüştürür [19]. Çıkış özniteliği önce ayırıklaştırılır ve işlem sırasında bir sınıflandırıcı kullanılır. Ayırıklaştırma için farklı yöntemler mevcuttur. Eşit frekanslı ayırıklaştırmanın kullanılması olası bir yoldur. Amaç her bir sınıfta eşit sayıda eğitim verisi olmasıdır. Tahmin aralığı koşullu yoğunluk tahmininden elde edilebilir [20]. Ayırıklaştırmaya dayalı koşullu yoğunluk tahmini herhangi bir makine öğrenme sınıflandırma algoritmasına uygulanabilir ve regresyon için kullanılabilir. Tez çalışmasında bu makine öğrenme algoritması rastgele orman olarak seçilmiştir.

1.3.5. Destek vektör makinesi (SVM)

Destek vektör makinesi (Support Vector Machine (SVM)) en çok kullanılan ikili sınıflandırıcılardan biridir. Destek Vektör makinesi hem doğrusal hem de doğrusal olmayan verilerin sınıflandırmasında kullanılabilir. SVM hiperuzay adında bir sınır çizgisi ile farklı sınıfa ait örnekleri ayırarak sınıflandırma gerçekleştirir [21]. SVM bir ikili sınıflandırıcı olmasına rağmen, bire karşı bir (one against one) ve bire karşı herkes (one against all) yöntemlerini kullanarak çoklu sınıflandırma problemlerine de uyarlanmıştır [22]. Bire karşı herkeste, her model bir sınıfı diğerlerinden ayırır ve öyle değerlendirir. Öte yandan, bire karşı bir yöntemi tüm sınıf ikilileri için modeller oluşturur.

SVM yapısında sınıflandırma farklı sınıflara ait örnekleri hiper düzlem ile ayırır. Optimal sınıflandırma için hiper düzlem her iki sınıfa ait örneklerden mümkün olduğunca uzak olmalıdır [21]. Optimal bir hiper düzlem Eşitlik 1.9 ile ifade edilmektedir:

$$y_i(w \cdot x_i + b) \geq 1 \text{ ve } 1 \leq i \leq n, w \in R^d, b \in R \quad (1.9)$$

x_i örnekleri, y_i örneklere karşılık gelen sınıfları, b durdurma (intercept) terimi, w hiper düzlemin normal vektörü, d her bir örneğin öznitelik sayısı ve giriş vektörünün boyutu, n ise örnek sayısını temsil etmektedir. Hiper düzlem aslında ona en yakın olan örneklerle tanımlanmaktadır. Bu en yakın örneklere destek vektörü adı verilmektedir.

SVM modeli ilk tanımına bakıldığında, aynı sınıfa ait örneklerin hepsi hiper düzlemin sağında ve sınırın dışında (destek vektörlerinin arasındaki boşlukta) olmasını gerektirmektedir. Gerçek hayattaki problemler bu özelliklere sahip değildir. Gerçek veri genellikle insan hatalarından ve makine ölçüm hatalarından dolayı aykırı değerler içermektedir. Bu yüzden aynı sınıfa sahip örnekler aynı değerlere sahip olmamaktadır [22]. Bu gibi problemler için SVM yapısının ilk tanımına (sert sınırda denilmektedir) uygun değildir. Bu problemlere uygulayabilmek ve gerçek veriye adapte olabilmek için SVM yapısının yumuşak sınır tanımı ortaya çıkmıştır. Eşitlik 1.9 ile verilen ifade genişletilerek hiper düzlem Eşitlik 1.10 ile tekrar tanımlanmıştır:

$$y_i(w \cdot x_i + b) \geq 1 - \epsilon_i \quad \epsilon \geq 0, \quad 1 \leq i \leq n \quad (1.10)$$

ϵ_i sınır dışında kalan örnekleri dahil etmek için kullanılan değişkenlerdir. Optimal hiper düzlemi bulmak için, Eşitlik 1.11 ile verilen kuadratik programlama problemi çözülmelidir:

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \epsilon_i \quad (1.11)$$

C ifadesi yumuşak sınırın hata (cost) fonksiyonunu temsil etmektedir. SVM modelinin kalitesi büyük ölçüde bu parametrenin seçimine bağlıdır. Büyük C değerleri sert sınır değerleri modeline yakın bir model oluşmasını sağlamaktadır.

SVM modelinde ilk tanımdan kaynaklı problem yumuşak sınırlarla çözülmüştür. Fakat yumuşak sınır çözümünün sadece doğrusal olarak ayrışabilen verilere uygulanmasından kaynaklı yeni bir problem ortaya çıkmaktadır. Gerçek dünya problemlerinde veri çoğu zaman doğrusal olarak ayrılamamaktadır. Yeni oluşan bu problemin çözümü nokta çarpımı yerine çekirdek (kernel) fonksiyonu kullanılmasıdır. Çekirdek fonksiyon örnekleri daha yüksek bir uzaya çıkararak örneklerin doğrusal olarak ayrıştırılmasını sağlar. Yaygın olarak kullanılan çekirdek fonksiyonları polinomsal, Gauss (Radyal tabanlı fonksiyon (Radial Basis Function (RBF))) ve sigmoid fonksiyonlarıdır [22]. RBF çekirdek fonksiyonu aşağıdaki gibi ifade edilmektedir (1.12):

$$K(x_i, x_j) = \exp(-\delta \|x_i - x_j\|^2) \quad (1.12)$$

δ sınıflandırma doğruluğunu etkileyen serbest bir parametredir. Bu parametre her bir eğitim örneğini etkilemektedir. Düşük değerler sınıra daha uzaktaki eğitim örneklerini dikkate alırken yüksek değerler daha yakındakilere odaklanılmasını sağlar. Tez çalışmasında Radyal tabanlı çekirdek fonksiyonuna sahip Destek vektör makinası kullanılmıştır.

1.3.6. Destek vektör regresyonu (SVR)

Destek vektör regresyonu (Support Vector Regression (SVR)), var olan uzayda doğrusal olarak ayrıştırılamayan verileri, çekirdek fonksiyonu kullanarak daha yüksek boyutlu bir alana eşleyerek verileri ayırmaya çalışan Destek Vektör Makinesi sınıflandırıcısının bir uzantısıdır [23][24]. SVR algoritmasının temel amacı, giriş ve çıkış değişkenlerinin ortak dağılımının bilinmemesi ilkesine dayanarak giriş ve çıkış rastgele değişkenleri arasındaki fonksiyonel ilişkiyi ortaya çıkarmaktır [24]. SVR ile oluşturulan model, eğitim verisinin sadece bir altkümeye bağımlıdır. Çünkü modeli oluşturan hata (cost) fonksiyonu ϵ eşik değerine yakın bütün eğitim verisi örneklerini göz ardı eder. Regresyon hesaplanması, eğitim kümesine bağlı bir fonksiyon tahmini olarak formüle edilebilir. Eğitim kümesi $X = \{(x_i, d_i), i = 1, \dots, l\}$ ve bağlantılı fonksiyon $y = f(x)$ ile temsil edilmektedir. $x_i \in R^n$ i inci eğitim örneğinin i inci giriş vektörü, $d_i \in R$ eğitim örneğinin hedef değeri ve l sayısı eğitim veri örneğinin sayısıdır. Bir destek vektör regresyonunun eğitilmesi için Eşitlik 1.13 ile ifade edilen bir regresyon fonksiyonunun bulunması gerekmektedir:

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) k(x_i, x) + b \quad (1.13)$$

$k(x_i, x)$ pozitif sonlu çekirdek (kernel) fonksiyonunu temsil etmektedir. $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_l)^T$, $\alpha^* = (\alpha_1^*, \alpha_2^*, \dots, \alpha_l^*)^T$ ve b modelin parametrelerini göstermektedir. α_i, α_i^* parametrelerini bulmak için Eşitlik 1.14 ile verilen objektif fonksiyonunu minimize etmek gerekmektedir:

$$\frac{1}{2} \sum_{i,j=1}^l (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) k(x_i, x_j) + \epsilon \sum_{i=1}^l (\alpha_i + \alpha_i^*) - d \sum_{i=1}^l (\alpha_i - \alpha_i^*) \quad (1.14)$$

Bu objektif fonksiyonu $\sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0$ ve $\alpha_i, \alpha_i^* \in [0, C]$ ifadesine bağımlıdır (ϵ ve C). $k(x_i, x)$ çekirdek değeri farklı formlarda olabilir, bunlardan en çok kullanılanları Gauss ve radyal tabanlı fonksiyon çekirdek fonksiyonlarıdır. SVR eğitilirken 2 parametre ile

1.14 ile verilen kuadratik optimizasyon problemini çözmektedir. Eğer $\alpha_i - \alpha_i^* \neq 0$ olduğunda x_i (örnek), destek vektörü (support vector) olur. Eğer $0 < |\alpha_i - \alpha_i^*| < C$ olursa x_i sınırlandırılmamış (unbounded) destek vektörü olur. Eğer $|\alpha_i - \alpha_i^*| = C$ ise x_i sınırlandırılmış (bounded) destek vektörü olur ve son olarak eğer $|\alpha_i - \alpha_i^*| = 0$ ise x_i destek vermeyen (non support) vektör olmaktadır. Bu bilgileri dikkate alarak destek vektörünün (DV) denklemsel ifadesi Eşitlik 1.15 ile verilmiştir.

$$f(x) = \sum_{x_i \in DV}^l (\alpha_i - \alpha_i^*) k(x_i, x) + b \quad (1.15)$$

Tez çalışmasında Radyal tabanlı çekirdek fonksiyonuna sahip Destek vektör regresyonu kullanılmıştır.

1.3.7. Lineer regresyon (LIR)

İstatistiksel regresyon analizinin bir parçası olan lineer regresyon birçok makine öğrenme algoritmasının yapıtaşısıdır [25]. Lineer regresyonun çalışma mantığı, seçilen bağımsız değişkenlerin bir bağımlı değişken üzerindeki etkisini modellemeye çalışmaktadır. Bu yöntem, eğitim kümesine ait verilen örnek noktaları lineer bir eğriye oturtulmasıyla bir model oluşturur. Değişkenlerin lineer bağımlılığı değerlendirilir.

Lineer regresyon modeli, bilinmeyen sayıdaki y değişkeni ile bilinen x kadar değişkenle, rastgele gürültü ε ve çeşitli parametrelerle birlikte ilişki kurar. Lineer regresyon tahmin modelleri Eşitlik 1.16 ile ifade edilir:

$$y_t = X_t \beta + \varepsilon_t \quad (1.16)$$

y_t , t zamanında tahmin edilen değer, $X_t = (1, x_{1t}, x_{2t}, \dots, x_{kt})$ t zamanında bilinen k tane değişkeni temsil etmektedir. $\beta = (\beta_0, \beta_1, \dots, \beta_k)^t$ katsayı vektörü, ε_t ise t zamanındaki rastgele hata terimini temsil etmektedir ($t = (1, \dots, N)$).

1.3.8. Naive bayes sınıflandırıcı (NB)

Naive Bayes (NB) yöntemi, bir örneğin belirli bir sınıfa ait olma olasılığı gibi sınıf üyeliği olasılıklarını öngören istatistiksel bir yöntemdir. Yöntem, Bayes teoremi üzerine kurulmuştur. Bu teorem, belirli bir öznitelik değerinin, sınıf değişkeni verilen herhangi bir öznitelik değerinden bağımsız olduğunu varsayar [26].

Naive Bayes sınıflandırıcısının çalışma adımları aşağıdaki gibidir [15]:

1. D eğitim setindeki örnekleri ve o örneklerle ilişkilendirilmiş sınıf etiketlerini temsil etmektedir. Her bir örnek n boyutlu öznitelik vektöründen oluşmaktadır $X = (x_1, x_2, \dots, x_n)$, bir örneğe ait n tane özniteliğin gösterimi $A_1, A_2, \dots, A_n$ şeklindedir.
2. m tane sınıf olduğu varsayılırsa $(C_1, C_2, \dots, C_m)$ verilen bir örneği (X), sınıflandırıcı X üzerinde koşullu (posterior) olasılık değeri en yüksek olana göre sınıflar. Naive Bayes sınıflandırıcı örneğin sınıf değerini C_i olarak atama yapar ancak ve ancak aşağıdaki koşul doğru olursa:

$$P(C_i|X) > P(C_j|X) \quad 1 \leq j \leq m, j \neq i \quad (1.17)$$

Bu durum $P(C_i|X)$ ifadesini maksimize edilmesiyle gerçekleştirilir. Bu sebepten dolayı $P(C_i|X)$ ifadesine maksimum koşullu hipotezi adı verilmektedir. Bayes teoremi bu koşula uygulanırsa:

$$P(C_i|X) = \frac{P(X|C_i)P(C_i)}{P(X)} \quad (1.18)$$

$P(X)$ ifadesi bütün sınıflarda sabit olduğu için sadece $P(X|C_i)P(C_i)$ ifadesini maksimum yapılması gerekmektedir.

3. Çok büyük sayıda öznitelik içeren veri kümelerinde $P(X|C_i)$ ifadesinin hesaplanması hesaplamsal olarak karmaşık olabilmektedir. Bu karmaşıklığı azaltmak için “sınıf koşullu bağımsızlık ilkesi” Naive Bayes tarafından uygulanır. Bu ilke, örneklerin sınıfları göz önüne alındığında, özniteliklerin değerleri şartlı olarak birbirinden bağımsız olduğunu kabul eder (yani, öznitelikler aralarında hiçbir bağımlılık ilişkisi yoktur). Bu ilke aşağıdaki ifade ile temsil edilir:

$$P(X|C_i) = \prod_{k=1}^n P(x_k|C_i) = P(x_1|C_i) \times P(x_2|C_i) \times \dots \times P(x_n|C_i) \quad (1.19)$$

Bu ifadeden özniteliklerin koşullu olasılıkları kolaylıkla elde edilebilir.

4. X örneğinin sınıf etiketini tahmin etmek için $P(X|C_i)P(C_i)$ ifadesi her bir sınıf için değerlendirilir. Sonuç olarak örneğin tahmin edilen sınıf değeri (C_i), $P(X|C_i)P(C_i)$ ifadesini maksimum yapan sınıf olarak atanır.

1.3.9. Lojistik regresyon (LR)

Lojistik regresyon yöntemi bağımlı değişkenin ikili olduğu veri kümelerini analiz etmek için kullanılan istatistiksel bir yöntemdir. Lojistik regresyon, bir bağımlı ikili değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi bulmak için kullanılır [27]. Lojistik regresyon, genellikle ikili sınıflandırma için belirli bir sınıf için ön eşik belirler ve bu eşik ile modelin çıktısını karşılaştırır. Lojistik regresyon modeli Eşitlik 1.20 ile formüle edilmiştir [28]:

$$\Pr(y = 0,1 | x, \beta) = \sigma(y\beta^T x) = \frac{1}{1+e^{(-y\beta^T x)}} \quad (1.20)$$

$\beta = (\beta_0, \dots, \beta_d)$ vektörü model parametrelerini, y sınıf etiketini ve $x = (1, x_1, \dots, x_d) \in R^{d+1}$ vektörü ortak değişkenleri temsil etmektedir. Lojistik regresyon sınıfları tahmin etmek yerine olasılıkları tahmin etmektedir bu yüzden model log-likelihood fonksiyonu ile ifade edilmektedir. Modelin eğitilmesi bir eğitim kümesiyle başlar $(X, y) = [(x_1, y_1), \dots, (x_n, y_n)]$. $x_i = (1, x_{i,1}, \dots, x_{i,d}) \in R^{d+1}$ n tane eğitim vektörünü ve $y_i \in \{0,1\}$ gözlenen sınıf değerlerini temsil etmektedir. Lojistik regresyonda amaç, log-likelihood fonksiyonunu maksimum yapan parametre vektörünü (β) bulmaktır. Bu parametre vektörü Eşitlik 1.21 ile verilmiştir.

$$l(\beta) = -\sum_{i=1}^n \log(1 + e^{(-y_i\beta^T x_i)}) \quad (1.21)$$

β parametreleri belirlendiğinde yeni veri vektörlerini Eşitlik 1.22 ile verilen eşik değer denkleminde göre sınıflandırmada kullanılabilirler $(x^{yeni} = (1, x_1^{yeni}, \dots, x_d^{yeni}) \in R^{d+1})$.

$$y^{yeni} = \begin{cases} 1 & \text{eğer } p(y = 1 | x^{yeni}, \beta) \geq \tau \\ 0 & \text{eğer } p(y = 1 | x^{yeni}, \beta) < \tau \end{cases} \quad (1.22)$$

τ ifadesi 0 ile 1 arasında olan bir eşik değerini temsil etmektedir genellikle 0.5 seçilir [28].

1.3.10. Rastgele orman (RF) ve Yerel Ağırlıklandırılmalı RF (LWRF)

Karar ağacı tabanlı yöntemler sağlık verilerinin analizinde doğru ve etkin bir yoldur [29, 30, 31]. Özellikle, karar ağaçlarının gelişmiş bir versiyonu olan Rastgele Orman (Random Forest (RF)) yöntemi, diğer alanlarda başarılı olduğu bilinen birçok güçlü öğrenme algoritmalarından daha iyi performans göstermiştir [29, 30]. Bu nedenle, yürüyüş örüntüleri

ve PH semptomları arasındaki ilişkiyi modellemek için RF yönteminin kullanılması tercih edilmiştir, aynı durum hayati belirti örüntüleriyle Sepsis semptomlarının modellenmesi için de söz konusudur.


RF, birçok karar ağacında, torbalama (bagging) olarak adlandırılan bir topluluk öğrenme stratejisini izler. Torbalamada, her ağaç bir bootstrap örneği kullanılarak bağımsız olarak organize edilir. Sonuç olarak, sınıflandırma için ağırlıksız çoğunluk oyu hesaplanır ve regresyon için ise ortalama hesaplanır. Her bir değişkeni tüm değişkenler arasından en iyi dalı kullanarak bölmek yerine, RF bunu rastgele seçilmiş değişkenler aracılığıyla yapar [32].

Genel RF algoritması aşağıdaki gibidir [33]:

- Her bir RF ağacını eğitim kümesinden bir bootstrap örneğine göre oluşturulur.
- Her düğümde bir ağaç büyürken, mevcut N 'den rastgele n örnek seçilir.
- $n = \lfloor \log_2(N) + 1 \rfloor$ ile başlanır. Torba dışı (out of bag) veri kümesi için minimum hata elde edilene kadar n azaltılır ve artırılır. Her düğümde, seçilen n 'den en iyi bölünmeyi sağlayan yalnızca bir değişken kullanılır.

Kısaca özetlemek gerekirse rastgele orman yapısı, giriş verilerinden bir bootstrap örneği bölümü seçerek ve her bölme için açıklayıcı değişkenlerin (öznitelikler) bir alt kümesini seçerek ikili karar ağacı koleksiyonunu oluşturur. Süreçte, aynı örnek birkaç kez seçilebilir, diğerleri asla seçilemeyebilir. Her karar ağacı bir tahmin değeri döndürür. Rastgele orman, her karar ağacının oluşturduğu çoğunluk oylama kuralına dayanarak nihai tahminde (sınıflandırma için kategorisi ve regresyon için gerçel bir değer) bulunur.

Şekil 1.2. RF regresörünün genel yapısını göstermektedir, X test örneğini, B ağaç sayısını, and k_i i 'inci ağaç için üretilen gerçel değerdir (sınıflandırma için sınıf bilgisi).




Şekil 1.2. RF regresörünün genel yapısı [33].

1.3.11. Çift yönlü uzun kısa süreli hafıza (Bi-LSTM)

Uzun kısa süreli hafıza (Long Short Term Memory (LSTM)) genel derin öğrenme yapısı Tekrarlayan yapay sinir ağı (Recurrent Neural Network (RNN)) yapısının farklı bir versiyonudur. Son çalışmalar, bu mimarilerin, sinyal kategorilerini sınıflandırırken diğer derin öğrenme mimarilerine kıyasla daha iyi performans sergilediğini raporlamaktadır [34] [35]. Genel olarak, RNN'ler değişken uzunluktaki verilerle ilgilenir, ancak genellikle uzun vadeli bağımlılıkları tanımakta ve işlemede başarısız olurlar. LSTM mimarisi, RNN yapısındaki gizli katmana, özel bellek blokları ve yeni bağlantılar ekleyerek, zaman serisi verilerini modeller. Böylelikle LSTM mimarisi, önceki versiyonundan daha gürbüz bir yapı oluşturarak bu sorunun üstesinden gelir. Bellek blokları, ağdaki her iterasyonda ağın durumunu kaydeden çoklu bağlantılara sahip bellek hücrelerine sahiptir. Ek olarak, LSTM yapısındaki kapılar ağın bellek hücresinden diğer hücrelere bilgi aktarma yeteneğini çarpma ile genişletir. Giriş kapısı, bilgilerin mimariye nasıl dâhil edildiğini, unut kapısı hangi bilgilerin silindiğini ve çıkış kapısı hangi bilgilerin bir sonraki katmana geçeceğini belirler [34]. Örnek bir LSTM bellek bloğu Şekil 1.3. ile gösterilmiştir.

Short Term Memory (Bi-LSTM)) yapısı ortaya çıkmıştır [36]. Bu yapı, belirli bir zamanda geçmiş ve gelecekteki giriş verileriyle eğitilmiştir. Bi-LSTM yapısı nöron durumlarını pozitif ve negatif zaman yönlerine dönüştürür. Böylelikle mimari, çıktıları ileri ve geri durumlar olarak ayarlayabilir. Bu yapıyla birlikte Bi-LSTM mimarisi bir geri bildirim mekanizması kazanır ve uzun veri dizilerini başarıyla işleyebilir [35]. Bi-LSTM genel yapısı Şekil 1.4. ile gösterilmektedir.



Şekil 1.4. Genel Bi-LSTM mimarisi

İleri durumlardaki hücreler tek yönlü LSTM olarak davranırlar. İleri ve geri durum ağları birbirine bağlı olmadığından dolayı ağların eğitilmesi tek yönlü LSTM yapısındaki gibidir [37]. Bi-LSTM yapısının eğitilmesi aşamaları genellikle ilk olarak ileri durum geçişi ile başlar. Bir zaman aralığındaki ($1 \leq t \leq T$) tüm girdi verileri Bi-LSTM yapısından geçer ve tahmin edilen çıktılar belirlenir. $t = 1$ den $t = T$ ye kadar ileri geçişler gerçekleşir ve $t = T$ den $t = 1$ e kadar ise geriye doğru geçişler gerçekleşir. Bu geçişler sırasında ayrıca çıkış nöronları için bir ileri geçiş de tamamlanmıştır. Geriye doğru geçişte, ileri geçişte kullanılan zaman dilimi ($1 \leq t \leq T$) için hata fonksiyonunun türevi hesaplanır. Çıkış hücreleri için bir geriye doğru geçiş gerçekleştirilir ve $t = T$ den $t = 1$ e kadar olan ileri geçişlere ve $t = 1$ den $t = T$ ye kadar olan geriye doğru geçişlere tekrar geriye doğru bir geçiş uygulanır. Bu işlemler sonunda ağırlıklar güncellenir ve eğitim tamamlanmış olur [37].

1.3.12. Evrişimsel sinir ağı (CNN)

20 yıl önce hayvanların görsel hafızasını temel alarak ortaya çıkan Evrişimsel sinir ağı (Convolutional Neural Network (CNN)) yapıları, çok katmanlı perseptron modellerinin farklı bir versiyonudur. Genel motivasyon, memelilerdeki görsel korteksin basit hücreler ve kompleks hücrelerden oluşması ve bir görüntü korteks yoluyla işlenirken, görüntünün her bir katmanda giderek daha anlamlı özniteliklerin tespit edilmesidir [38]. CNN'ler, evrişim katmanları (basit hücreler) ve havuzlama (pooling) katmanları (kompleks hücreler) yığınlarından oluşur ve evrişim katmanlardaki filtreler kullanılarak aşamalı olarak daha yüksek seviyedeki öznitelikleri öğrendikleri tespit edilmiştir. Bu özelliğinden dolayı CNN yapısı derin öğrenme mimarisi, görüntü işleme araştırma alanında son yıllarda çokça kullanılan popüler bir araç haline gelmiştir [39][40]. CNN'ler, ızgara (2-3 boyutlu) benzeri yapıdaki verileri işlemek için özellikle uygundur. Bu verilere örnek 2 boyutlu görüntüler, 2-3 boyutlu videolar ve sinyallerin 2 boyutu çevrilmiş halleri örnek verilebilir. CNN yapısı ham veri üzerindeki yerel bağlantıları ortaya çıkarmaktadır. CNN yapısındaki nöronlar giriş olarak verilen görüntüyü “reseptör alanı” adındaki birçok küçük alana bölerek bu alanlardan öznitelik çıkararak çalışmaktadır.

CNN mimarisi bir giriş, bir çıkış ve çok sayıda gizli katmandan oluşmaktadır [41]. CNN yapısındaki gizli katmanlar çok katmanlı bir yapıya sahiptir. Bu çoklu katmanda evrişim, havuzlama ve tam bağlaşımlı (fully connected) adında katmanlar bulunmaktadır. Evrişim ve havuzlama katmanları derin öğrenme alanında sadece CNN mimarisine özgüdür. Evrişim katmanında girdi verisi çok sayıda filtre ile işlenir. Bu çok sayıda filtrenin çıktılarına öznitelik haritası (feature map) adı verilir. Bu öznitelik haritaları, reseptör alanlarından çıkartılan anlamlı ve değerli yerel öznitelikleri içermektedir. Evrişim işleminde, $n \times n$ boyutundaki filtre (F) (ağırlık matrisi de denilebilir) ve girdi görüntüsünün $n \times n$ boyutundaki bir parçası (I) aşağıdaki matrislerle temsil edilmektedir.


$$F = \begin{bmatrix} w_{11} & \cdots & w_{1n} \\ \vdots & \ddots & \vdots \\ w_{n1} & \cdots & w_{nn} \end{bmatrix}, I = \begin{bmatrix} i_{11} & \cdots & i_{1n} \\ \vdots & \ddots & \vdots \\ i_{n1} & \cdots & i_{nn} \end{bmatrix} \quad (1.29)$$

Bu durumda evrişim işlemi Eşitlik 1.30 ile gösterildiği gibi ifade edilebilir:

$$F * I = \sum_{j=1}^n \sum_{k=1}^n w_{jk} i_{jk} \quad (1.30)$$

Havuzlama katmanı genellikle evrişim katmanlarından sonra uygulanmaktadır [40]. Bu katman, çıkarılan öznitelik haritalarının boyutunu azaltmak için kullanılan bir araçtır. Bu

azaltma sonucu parametre sayısı ve hesaplama zamanı da azalmaktadır çünkü bir sonraki katmana öz nitelik haritalarının daha küçük bir sürümü gönderilmektedir. Diğer bir deyişle öz nitelik haritalarını daha küçük olacak şekilde örnekler [42]. Havuzlama katmanı her bir öz nitelik haritası için bağımsız çalışır. Bir aktivasyon fonksiyonuna ve öğrenmesi gereken ağırlıklara sahip değildir. Ayrıca havuzlama katmanı, girdinin küçük ötelenmelerinden etkilenmez hale gelir, çünkü küçük bir ötelenme, havuzlama katmanının çıktılarının değerlerinde çoğunlukla değişiklik göstermez. En çok kullanılan havuzlama katmanları, maksimum ve ortalamadır. Maksimumda belirli bir büyüklükte filtre gezdirilerek maksimum değer seçilir. Ortalama katmanında ise aynı şekilde filtre gezdirilerek değerlerin ortalaması alınır [42]. Havuzlama katmanının yaptığı işleme örnek Şekil 1.5. ile verilmiştir. Şekilde 4x4 boyutundaki görüntünün bir parçasına 2x2 boyutunda bir filtre ile maksimum ve ortalama alma işlemleri uygulanmıştır.



Şekil 1.5. Havuzlama katmanında maksimum ve ortalama alma işlemleri

Tam bağlaşımlı katmanı, bir nöron ve bir sonraki katmandaki tüm nöronlar arasında bir köprü görevi görür. CNN mimarisi ayrıca paket (batch) normalization ve Rectified Linear Unit (ReLU) adında özel katmanlara sahiptir.

Paket normalization katmanı gradyanları normalleştirir ve böylece CNN yapısının eğitim aşamasını hızlandırır [40]. Paket normalizasyon katmanının kullanılmasının asıl sebebi, her bir katmandaki ağırlıkların değişmesinden kaynaklı tutarsızlıkları ortadan kaldırmaktır. Bu tutarsızlık, önceki katmanların güncellenmesi sırasında girdi dağılımını değiştirmektedir. Bu katman, girdi verilerini küçük parçalara ayırarak normalizasyon uygular ve eğitime öyle devam edilir [42]. Normalizasyon işlemi Eşitlik 1.31 ile verilmiştir:


$$\mu = \frac{1}{m} \sum_{i=1}^m x_i, \sigma^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu)^2 \text{ ve } \tilde{x}_i = \frac{x_i - \mu}{\sqrt{\sigma^2 + \epsilon}} \quad (1.31)$$

μ ve σ^2 ifadeleri ortalama ve standart sapmayı göstermektedir. $\tilde{x}_i$ ifadesi girdinin normalize olmuş halini ve m ise parçanın boyutunu temsil etmektedir. Bu işlem sonunda $\tilde{x}_i$ ortalaması 0 ve standart sapması 1 olacak şekilde normalize edilir.

ReLU katmanı, negatif değerleri sıfıra dönüştüren ve pozitif değerleri bozulmadan bırakan doğrusal olmayan bir aktivasyon fonksiyonu içerir [42]. Bu katmanın kullanılmasının sebebi CNN mimarisinde eğitim aşamasını hızlandırmaktır. Genellikle CNN mimarilerinde normalizasyon katmanından sonra ReLU katmanı gelmektedir [41]. ReLU katmanını yaptığı işlem Eşitlik 1.32 ile verilmiştir (z girdi değeri):

$$\sigma(z) = \max(0, z) = \begin{cases} 0, & \text{eğer } z < 0 \\ z & \text{eğer } z \geq 0 \end{cases} \quad (1.32)$$

Bazı durumlarda ise CNN performansını arttırmak için seyreltme (dropout) katmanı da kullanılabilir. Seyreltme katmanı sinir ağları için geliştirilen bir düzenleme (regularization) yöntemidir [42]. Amaç, nöronların eğitim aşamasının her iterasyonu sırasında rasgele olarak atılıp diğer nöronlarla işlem yapılmasıdır. Bu durum atılan nöronların ve onların bağlantılarının sıfır olması anlamına gelmektedir. Bu işlem sonucunda nöronların beraber adapte olup hatayı artırma oranı azaltılmaktadır. Seyreltme katmanı, modelin bir alt kümesinin eğitimi olarak görülebilir. Her iterasyon farklı bir sürüm oluşturur ve her ağırlık başka bir ağırlık kümesi ile güncellenir [40]. Örnek bir sinir ağının eğitimi sırasında seyreltme işlemi Şekil 1.6. ile gösterilmiştir. Eğitim sırasında ağdaki bazı nöronların ve bağlantıların göz ardı edildiği görülmektedir.



Şekil 1.6. Örnek bir sinir ağında seyreltme işlemi uygulanması

2. GİYİLEBİLİR SENSÖRLERLE İZLENİLEN HASTALIKLAR

2.1. Parkinson Hastalığı

2.1.1. Giriş

Parkinson hastalığı (PH) nörodejeneratif, hızlı ilerleyen, karmaşık ve nörolojik bir hastalıktır. Yaşa bağlı nörodejeneratif hastalıklar arasında Parkinson Hastalığı (PH) en sıklıkla görülen ikinci hastalıktır. Bu hastalık dünya nüfusunun %0.1 - %0.2 'sini etkilemekte ve etkilenen insanların %2'si ise 80 yaştan üstüdür [43, 44]. Hastalığın nedenlerinden biri beyinde yeterli dopamin bulunmamasıdır. PH beyindeki “substantia nigra pars compacta” adlı bölgedeki nöronlara zarar vererek dopamin üretimini azaltmaktadır. Patolojik incelemeler sonucunda bu alandaki hücre kaybı %30 ve %70 arasında değişmektedir [45]. Bu sebeple uygulanan tedaviler dopamin alıcılarını aktive etmeye yönelik ilaçları içermektedir [46]. Fakat bu tedaviler kısa zaman için başarılı olsa da kalıcı bir çözüm sağlamamaktadır. Dopaminerjik tedaviler duruş bozukluğu, konuşma kabiliyetinin kaybedilmesi gibi motor semptomların tedavisinde etkili olamamaktadır [47]. Diğer motor semptomlar titreme (tremor), bradikinezi (Bradykinesia), yürümede bozukluk, mikrografi ve yüz ifadelerinde donukluktur. Şu an için hastalığın herhangi bir tedavisi olmadığından hastaların yaşam kalitesini arttırmak önemli bir iştir [48, 49, 50, 51]. Medikal müdahaleler hastalığın ilerlemesini tamamen durdurmaz fakat hastalığın ilerleyişini yavaşlatır.

Medikal alanda, hastaların hangi motor özelliklerini kaybettiğini belirlemek için doktorlar muayenede veya ev ziyaretinde nörolojik muayeneler gerçekleştirir ve bu muayenelerde hastalar veya hastabakıcılar tarafından tutulan günlüklere danışılır. Fakat kısa süreli muayene sonrası fazla veri elde edilemez aynı şekilde tutulan günlükler de subjektif veriler içermektedir. Daha objektif veriler elde edebilmek için birkaç ölçüt kullanılmaktadır. Bunlardan birisi ve en yaygın şekilde kullanılan Unified Parkinson's Disease Rating Scale (UPDRS) 'dir. Dört bölümden oluşur: (1) mentasyon, davranış ve ruh hali; (2) günlük yaşam aktiviteleri; (3) motor muayenesi; ve (4) terapinin komplikasyonları [52]. Bu dört bölümün birçok alt kategorisi vardır, bu alt kategoriler puanlanarak toplam skor hesaplanır. Normal ve problem yoksa 0, minimal problemlerde 1, hafif problemlerde 2, orta derece problemlerde 3 ve ağır problemlerde 4 puan verilir. Ölçeği 0 ile 199 arasında değişir. Bu ölçeği belirlemek için doktorlar hastalara bir takım testler uygularlar. Bu testler sonucunda bir UPDRS formu

[53] doldurur ve bu form sonucunda oluşan değerle hastaları değerlendirir. Yüksek UPDRS değeri ileri derece PH belirtisidir. UPDRS değer aralıkları ile hastalığın şiddeti tespit edilir.

Ne yazık ki, UPDRS sadece hastaneye yapılan bir ziyaret sırasında kullanılabilir. Bu zorlukların üstesinden gelebilmek için, PH 'nın motor semptomlarını günlük olarak izlemeye yönelik sistemler literatürde bulunmaktadır. Bunlara örnek olarak PERFORM [54], Physilog [55], Portable Motus System [56], The Kinesia [57], Opal movement monitor [58], Lift Pulse and Lift Stride [59] verilebilir. Ayrıca literatürde motor özellik performansı arttıran ve daha sonra rehabilitasyon programları oluşturan sistemler de bulunmaktadır. Bu sistemler sesli geri bildirim, interaktif görüntülü konferans ve kinematik analiz yöntemlerini kullanmaktadır. Bunlara örnek olarak The Rescue Project [60], PARREHA (PARKinsonian REHAbilitation) [61], INDIGO (INDependent I GO) [62], DAPHNE (Detection of Activity Performance for Health with New Equipment) [63], The HELP (Home-based Empowered Living for Parkinson's Disease) [64], CuPiD (Closed-loop system for personalized and at-home rehabilitation of people with Parkinson's disease) [65], and REMPARK (Personal Health Device for the Remote and Autonomous Management of Parkinson's Disease) [66] verilebilir.

H & Y ölçeği, PH için yaygın olarak kullanılan başka bir derecelendirme aracıdır. Motor fonksiyonunun geniş kategorilerini [67], 1 ile 5 arasında değişen bir ölçekte tanımlar. H&Y ölçeği UPDRS sisteminden önce ortaya çıkmıştır günümüzde hala genel bir Parkinson şiddet tanısı konması için kullanılmaktadır [68]. H&Y değerlerinin anlamları [67]: 1: Genellikle minimal veya hiç fonksiyonel sakatlığı olmayan tek taraflı tutulum. 2: Denge bozukluğu olmadan iki taraflı veya orta hat tutulumu. 3: Bilateral hastalık: bozulmuş postural reflekslerle hafif ila orta derecede sakatlık; fiziksel olarak bağımsız. 4: Şiddetli sakatlık durumu; yardımsız yürüyemiyor veya kalkamıyor. 5: Yardım edilmedikçe yatağa veya tekerlekli sandalyeye bağlı kalma.

Motor kabiliyetlerin kaybolması PH hastalarının ana problemidir. Hastalara tatmin edici bir şekilde ev bakımı ve klinik bakım sağlanırken durumlarını uzaktan izlemek önem kazanmaktadır. Bu konudaki araştırmalar günlük yaşam aktivitelerini hareket sensörleriyle tanıyan algoritmalar ve sistemler geliştirmek üzerine kurulmuştur. [47, 69, 14, 70, 71]. Bu araştırmalar yürüyüş analizi çalışmalarını da içermektedir [72]. Yürüyüş analizi PH tedavisi için önemli ve bilgilendirici bir tedavidir çünkü hastalık sürekli izleme gerektirmektedir. Analizi gerçekleştirmek için hastalar yürüyüş laboratuvarına sahip hastanelere veya merkezlerine gitmek zorundadır. Standart yürüyüş laboratuvarları yürüyüşü değerlendirecek altyapısına sahip olmalıdır. Altyapı, hastanın görüntülerini kaydetmek için bir video sistemi

ve hareketleri izlemek için bir hareket yakalama sisteminden oluşur. Bu sistem GRF (Ground Reaction Force) 'yi ölçmek için güç plakaları ve kas aktivitesini kaydetmek için EMG sisteminden oluşur [73]. Sensör ve mobil teknoloji ucuzladıkça ve yaygınlaştıkça, son zamanda yapılan çalışmalar yürüyüş analizini altyapı gerektirmeden gerçekleştirilebileceğini göstermektedir [74–85]. Böylelikle profesyonel yardım ihtiyacı mümkün olduğu kadar azalmıştır.

Tez çalışmasında PH motor semptomlarının nicel olarak izlenebildiği bir hesaplamsal yaklaşım gerçekleştirilmiştir. Yaklaşım, ayağa giyilen GRF 'yi ölçen sensörlerle etkili prognoz çözümleri sağlayabilir. Bu amaçla, PH semptomlarının şiddetinin kesin değerini tahmin edilmesini çeşitli makine öğrenme ve derin öğrenme modelleriyle yapılabileceği gösterilmiştir. Önerilen yaklaşım, hastaların yürüme modellerindeki farklılıkların etkilerini ortadan kaldırmaya yardımcı olmaktadır. Yürüyüş sensörleri ile elde edilen GRF sinyallerinin regresyona dayalı analizinin, PH şiddet ölçüm metrikleri olan UPDRS ve Hoehn ve Yahr (H & Y) ölçeği açısından doğru bir şekilde tahmin edilebileceği gösterilmektedir. Çeşitli makine öğrenme ve derin öğrenme yaklaşımlarının Parkinson hastalığı şiddetini tespit etme performansı regresyon deneyleriyle değerlendirilmiştir. Ayrıca, tez çalışmasında denenen modeller mevcut Parkinson Hastalığı tahmin modelleri ile karşılaştırılarak çeşitli deneyler yapılmıştır.

2.1.2. İlgili çalışmalar

Makine öğrenmesi yöntemleri kullanılarak Parkinson Hastalığı tahmini üzerine son yıllarda literatürde birçok çalışma bulunmaktadır. Fakat bu çalışmalar hastalık tahmini üzerine sadece ikili karar verme biçiminde çalışmışlardır. Çalışmalarda hastalığı tahmin etmek için GRF, IMU, ses, Manyetik rezonans görüntüsü gibi farklı tipte veri kaynakları kullanılmıştır. Literatürde Parkinson Hastalığı üzerine çalışmalar bu bölümde incelenmiştir.

Tunca ve diğerleri [86] ayağa takılabilen bir atalet (Inertial) sensörü tabanlı yürüme analizi sistemi önermişlerdir. Önerilen sistem tamamen mobil olup, sadece iki atalet ölçüm birimi (Inertial Measurement Unit (IMU) içerir. Bir IMU genel olarak akselerometre, jiroskop ve manyetometreden oluşur. Düz yürüme tespit etmeye ek olarak; sistemleri yan, geri ve dönüş adımlarında da çalışmaktadır. Çalışmada, adım uzunluğu, kadans (cadence), devir süresi, duruş zamanı, salınım zamanı, duruş oranı, hız ve maksimum / dönme hızı gibi uzamsal zamansal yürüyüş ölçüleri çıkarılmıştır.

Aktivitenin tanınması genel anlamda yararlı olsa da, uzmanlar için yeterli klinik yardım sağlamamaktadır. Araştırmaların ikinci yönü, hastalığı otomatik olarak teşhis etmek için farklı algılama yöntemleriyle hesaplama yöntemlerini tasarlamaktadır.

Lee ve Lim [87] yürüyüş karakteristiklerini kullanarak PH sınıflandırması gerçekleştirmişlerdir. Hastaları sınıflandırmak için GRF sensörleri ile toplanan yürüme sinyallerinden dalgacık özniteliklerini çıkarmışlardır. Hastaların PH ve sağlıklı deneklerden ayrıştırılması için ağırlıklı bulanık üyelik fonksiyonlarına sahip bir sinir ağı önerilmiştir. Daliri [88] GRF sinyallerinden öznitelikleri çıkarmak için Kısa Süreli Fourier Dönüşümü uygulamıştır. Sınıflandırma aşamasında Ki-kare (Chi-square) mesafe tabanlı DVM çekirdeği kullanmışlardır. Jane ve diğerleri [89] yürüyüş sinyali sınıflandırması için geri yayımlı zaman gecikmeli bir nöral ağ yapısı önermişlerdir.

Ertuğrul ve diğerleri [90] öznitelik gösterimi için yürüme sinyalleri üzerinden Local Binary Pattern (LBP) yöntemini kullanmışlardır. LBP histogramlarından istatistiksel özellikler çıkarmış ve son öznitelik vektörünü elde etmek için ise ilgileşim temelli bir öznitelik seçim yöntemi kullanmışlardır. Tahmin performansları için farklı sınıflandırıcılar ve farklı öznitelik uzaylarını değerlendirmişlerdir. Çok katmanlı bir Perceptron (Multi Layer Perceptron (MLP)) ile en yüksek sınıflandırma doğruluğuna ulaşmışlardır.

Zeng ve diğerleri [91] yürüme analizi kullanarak PH teşhisi için iki fazlı bir sınıflandırma yaklaşımı önermişlerdir. Sınıflandırmada kullanılmak üzere öznitelikler çıkarmışlardır. Bu öznitelikler sensörlerin sol ayak ve sağ ayak altındaki çıkışı arasındaki farkı, sol ayak sensörlerinin çıktısının toplanması ve sağ ayak sensörlerinin çıktısının toplamıdır. Öznitelik vektörlerini radyal temelli fonksiyona sahip bir sinir ağı kullanarak sınıflandırmışlardır. Acici ve diğerleri [29] PH teşhisi için bir Rastgele Orman (Random Forest (RF)) yaklaşımı önermişlerdir. RF sınıflandırıcısını beslemek için yürüyüş sinyallerinden zaman ve frekans uzayındaki öznitelikleri çıkarmışlar ve literatürdeki önceki yöntemlere kıyasla daha yüksek doğruluk elde edilebildiğini bildirmişlerdir.

Perumal ve diğerleri [92], başlangıç evresinde Parkinson hastalığını saptamak ve izlemek için yürüyüş ve titreme öznitelikleri çıkarmış ve kullanmışlardır. Çalışmanın katkısı, yürüyüşün (kinetik ve uzaysal) ve titreme özniteliklerinin ilk defa araştırılıp analiz edilmesidir. Yürüyüş parametrelerini tespit etmek için Doğrusal Diskriminant Analizi sınıflandırıcısı kullanmışlardır. Aynı zamanda DVM ve Yapay Sinir Ağı sınıflandırıcıları ile karşılaştırmalar yapmışlardır. Adım mesafesi, duruş ve sallanma fazları kullanılarak topuk ve normalize edilmiş topuk kuvvetlerinin diğer özniteliklere kıyasla daha iyi sınıflandırma doğruluğu sağladığı çalışmada bildirilmiştir. Tremor (titreme) analizi için; genlik, güç

dağılımı, frekans dağılımı ve ortanca frekans özniteliklerinin çıkarılması ile titremenin atipik Parkinsonizm titremesi mi yoksa normal PH titremesi mi olduğu tespitini yapmışlardır.

Giyilebilir sensörler aracılığıyla otomatik semptom analizi için yapılan çalışmalardan biri, Patel ve diğerlerinin çalışmasıdır ve bu çalışmada ivmeölçerler kullanılarak PH semptom şiddetini tahmin edilmesini gerçekleştirilmiştir [51]. Titreme, bradikinezi ve diskinezi gibi farklı semptomların şiddeti, ivmeölçer verisine uygulanan bir Destek Vektör Makinesi (DVM) ile sınıflandırılmıştır. PH hastalarının 8 farklı bölgesinde bulunan ivmeölçer sensörleri ile elde edilen sonuçlar, üç farklı semptom için umut verici sonuçlar vermiştir. Fakat bu yaklaşım, PH semptomlarının niceliksel bir değerlendirmesinden ziyade hala kategorik bir tahmin sağlamaktadır.

Martinez ve diğerleri [93] medikal görüntülerden PH hastalarını tespit eden bilgisayar yardımlı bir teşhis sistemi geliştirmişlerdir. Sistem ön işleme, voksel seçimi, öznitelik çıkarma ve sınıflandırma dâhil olmak üzere dört adımdan oluşur. Öznitelikleri temsil etmek için Voxel-As-Features (VAF) yaklaşımı ve örnekleri sınıflandırmak için bir Destek Vektör Makinesi (DVM) kullanmışlardır. Tang ve diğerleri [94] fonksiyonel manyetik rezonans görüntüleme (RS-fMRI) ile PH teşhisini incelemiştir. SVM kullanarak kan oksijen seviyesi sinyalinde dinlenme dalgalanmalarını kullanarak PH varlığını tahmin etmeye çalışmışlardır.

Naren ve diğerleri [95] Manyetik Rezonans görüntüleri kullanarak Parkinson Hastalığı tespiti gerçekleştirmişlerdir. Çalışmalarında Parkinson's Progression Markers Initiative (PPMI) veri kümesini kullanmışlardır. Bu veri kümesinden alınan görüntüler üzerinden öznitelikler çıkarmışlar ve Naive Bayes, DVM, AdaBoost, Rastgele Orman makine öğrenme yapılarıyla sınıflandırma performanslarını incelemişlerdir. Rastgele Ormanın diğer modellere göre daha iyi sonuç verdiğini kanıtlamışlardır.

Shinde ve diğerleri [96] Nöromelanin içerikli Manyetik Rezonans görüntüleriyle Parkinson için biyobelirteç çıkarımı ve hastalık tahmini gerçekleştirmişlerdir. Kullandıkları veri kümesi, Hindistan'da bir hastanenin nöroloji departmanından elde edilen görüntülerden oluşmaktadır. Literatürde mevcut öznitelik yöntemlerinin eksikliğinden bahsedip CNN derin öğrenme yapısıyla bu eksikliklerin kapanmasını sağlamayı amaçlamışlardır. Çalışmada çok katmanlı bir CNN derin öğrenme yapısı kullanmışlardır. Farklı öznitelik şemalarıyla yöntemlerini karşılaştırmış ve sonuçları raporlamışlardır. Deneyler sonucunda önerdikleri modelin diğer modellere göre üstün doğruluk değeri elde etmişlerdir. Ayrıca nöromelanin yapısının Manyetik Rezonans görüntülerinde güçlü bir biyobelirteç olduğunu raporlamışlardır.

Adeli ve diğerkleri [97] Parkinson Hastalığı tespitinde manyetik rezonans görüntüleri üzerinden çıkartılacak önemli öznitelikleri tespit eden bir yöntem geliştirmişleridir. Bu yönteme joint feature-sample selection (JFSS) adını vermişlerdir. Bu yöntemi önemsiz örnekleri ve alakasız öznitelikleri eleyen bir önışlem aşaması olarak açıklamışlardır. Çalışmalarında PPMI veri kümesini kullanmışlardır. Önerdikleri öznitelik şemasını Destek Vektör Makineleri ve Lineer diskriminant analizi (Linear Discriminant Analysis) yöntemleriyle birleştirip deneyler yapmışlardır. Deneyler sonucunda LDA ve JFSS yapısının birlikte kullanılması ile en yüksek Parkinson Hastalığı tespit performansına ulaşmışır. Çalışmalarında ayrıca farklı öznitelik seçim yöntemleriyle karşılaştırmalar yapmış ve önerdikleri öznitelik seçme yönteminin en iyisi performansı verdiğini raporlamışlardır.

Pompili ve diğerkleri [98] Parkinson Hastalığı semptomlarını tespit etmek için konuşma verileri üzerinden sınıflandırma gerçekleştirmişlerdir. FraLusoPark ses veri kümesini çalışmalarında kullanmışlardır. Bu veri kümesinde bulunan kelime okuma, hikâye okuma gibi 8 konuşma görevini kullanarak hangi görevin Parkinson Hastalığı tespitinde daha etkili olduğunu tespit etmeye çalışmışlardır. Ses verilerinden akustik öznitelikler çıkarmışlar ve bu öznitelikleri Rastgele Orman algoritmasına girdi olarak vermişlerdir. Farklı konuşma görevlerini oluşturdukları bu makine öğrenmesi şemasıyla denemiş ve sonuçları raporlamışlardır. Deneyler sonucunda prozodik kelimelerin okunmasının en ayırt edici kategori olduğunu tespit etmişlerdir.

Hemmerling ve diğerkleri [99] çalışmalarında Parkinson Hastalığında söylem (articulatory) ve ses çıkarma (phonatory) bozukluklarıyla hastalığı modellemeye ve tahmin etme üzerine deneyler yapmışlardır. Çalışmalarında PH ve kontrol grubuna ait ses verilerine sahip PC-GITA adında bir veri kümesi kullanmışlardır. Bu veri kümesinde değışken ses seviyelerinde kelimeler ve söylemler çıkarılmış ve analiz edilmiştir. Kelime ve söylem için verilerden ortalama, standart sapma MFCC (mel-frequency cepstral coefficients) gibi birtakım öznitelikler çıkartmışlardır. Ayrıca PCA (Principal Component Analysis) yöntemiyle özniteliklerde boyut azaltmışlardır. Hastalık sınıflandırma için karar ağaaları kullanılmışır. Söylem ve ses çıkarma özniteliklerinin birleştirilmesiyle oluşturulan öznitelik vektörü, ikisinin tek tek kullanılmasına göre daha iyi doğrulukta PH sınıflandırma yapmışır. Ayrıca PCA yönteminin sınıflandırma performansını arttırdığını raporlamışlardır. Deneyleri sonucunda değışken ses seviyelerindeki kelimelerin Parkinson hastası ve sağılıklı bireyleri ayırt etmeye uygun olduğunu kanıtlamışlardır.

Patra ve diğerleri [100] ses verilerinden Parkinson Hastalığı tahmin edilebilir kabulüyle çeşitli çalışmalar yapmışlardır. UCI Parkinson Disease veri kümesinden hasta ve kontrol gruplarına ait ses özniteliklerini çalışmalarında kullanmışlardır. PH tahmin edilmesi için karar ağaçları, lojistik regresyon ve rastgele orman gibi birçok makine öğrenmesi yöntemi üzerinde deneyler yapmışlardır. Deneyler sonucunda rastgele orman algoritmasının en iyi sınıflandırma performansı gösterdiğini raporlamışlardır. Ayrıca kullandıkları öznitelikleri de sıralamış ve en anlamlı öznitelikleri ortaya çıkartmışlardır. Temel frekans değişimleri adındaki özniteliklerin Parkinson hastalığı tespit etmede en etkili öznitelik olduğunu raporlamışlardır.

Pereria ve diğerleri [101] Parkinson hastalığı tespiti için sıkça kullanılan bir test olan spiral çizme testinde çizim sırasında akselerometre sinyalleri ölçen bir kalem tasarlamışlardır. Bu kalemle Parkinson ve kontrol grubundan alınan ölçümlerle açık erişim bir veri kümesi tasarlamışlardır. Daha sonra bu ölçümleri kullanarak Parkinson hastalığı tespiti gerçekleştirmişlerdir. Çalışmalarında literatürde sıkça kullanılan ve bilinen CNN (Convolutional Neural Network) derin öğrenme mimarileriyle deneyler yapmışlardır. Sinyallerin CNN yapısında kullanılabilmesi için iki boyutu dönüştürme işlemi gerçekleştirmişlerdir. OPF CNN özel mimarisinin Parkinson hastalığı tespitinde diğer mimarilere göre daha başarılı sonuçlar aldığını raporlamışlardır.


Yassir ve diğerleri [102] Parkinson hastalığı tespitinde kullanılan spiral test çizim görüntülerini kullanarak hastalık tespiti gerçekleştirmişlerdir. Kullandıkları veri kümesi NewHandPD adında yazarların önceki çalışmalarında oluşturdukları bir veri kümesidir. Bu veri kümesinde hasta ve kontrol gruplarına ait bireylerin çizim görüntüleri vardır. Bu görüntülerden tanjant vektörü ve spiralın çapı gibi birtakım öznitelikler çıkartmışlardır. Daha sonra Naive Bayes, Destek Vektör Makinesi ve OPF CNN makine öğrenme yapılarıyla deneyler yapmışlardır. Deneyler sonucunda daha önceki çalışmalarından sınıflandırma performansı olarak daha iyi sonuç elde etmişlerdir. Ayrıca çoğunluk oylaması yöntemiyle diğer yöntemlere göre en yüksek sınıflandırma performansına ulaşmışlardır.

Cioppa ve diğerleri [103] spiral çizme testi ile Parkinson hastalığının otomatik olarak tespit edilmesini sağlayan bir yöntem geliştirmişlerdir. PaHaW veri kümesini kullanmışlardır. Bu veri kümesinde hasta ve kontrol spiral testi yaptırılırken bir akıllı kalem yardımıyla çeşitli ölçümler yapılmıştır. Bu ölçümlerden yazarlar yatay, dikey yazma hızı gibi öznitelikler çıkarmışlardır. Cartesian Genetic Programming adında genetik programlama tabanlı bir sınıflandırma yöntemi geliştirmişlerdir. Geliştirdikleri bu yöntemi Destek vektör makinesi, Rasgele orman, Naive Bayes gibi makine öğrenme yöntemleriyle

karşılaştırmış ve bu yöntemlerden daha iyi Parkinson hastalığı tespit performansı gösterdiğini raporlamışlardır.

2.1.3. Hastalık izleme için genel yapı

Yürüyüş analizi, ayağın altında bulunan GRF sensörleri kullanılarak gerçekleştirilir. GRF, vücudun temas ettiği bölgeye uygulanan kuvvettir. Ayaklardaki bu reaksiyon kuvveti, kişisel yürüme alışkanlıklarına dayalı yürüme aktivitesi sırasında zamanla değiştiğinden, bireysel yürüyüş analizi için uygun bir kaynak olduğu düşünülmektedir [59]. Önerilen sistem, ayağa takılan sensörlerden elde edilen çoklu GRF sinyallerini alır ve yürüyüş örüntülerini PH semptomlarıyla ilişkilendirmek için bir regresyon modeli kullanır. Çalışmada eğitim ve tahmin aşamalarından oluşan denetimli regresyon modeli kullanılmıştır (Şekil 2.1.).



Şekil 2.1. PH semptom seviyesi için önerilen sistem.

İlk olarak, veri kümesinden etiketlenmiş yürüyüş sinyalleri kullanılarak çeşitli öznitelikler çıkarılır. Bu öznitelikler denekleri temsil etmektedir (PH veya kontrol) ve öznitelik vektörü olarak adlandırılır. İkinci adım olarak oluşturulan öznitelik vektörleri bir regresör/sınıflandırıcı ile eğitilir. Öznitelik vektörlerinin her biri, UPDRS ve H & Y ölçek düzeylerinin tam bir değerine sahiptir ve ayrıca regresyon ve sınıflandırma amacına göre bir

etikete (PH veya kontrol / sağlıklı) sahiptir. Bu aşamalardan sonra eğitilmiş veriden bir model oluşturulur. Üçüncü olarak, semptom seviyesi ve sınıf etiketinin tam değerini değerlendirmek için modele bir test örneği verilir.

2.2. Literatürde Bilgisayar Yöntemleriyle Enfeksiyon İzlenmesi

2.2.1. Giriş

Enfeksiyonel hastalıklar, vücutta yaşaması beklenmeyen virüsler, bakteriler, mantarlar veya parazitler gibi yabancı mikroorganizmalar tarafından vücudun istila edildiği durumlardır. Birçok farklı enfeksiyon türü vardır ve etkileri önemli ölçüde değişiklik gösterebilir: Bazı enfeksiyon türleri semptom göstermeyebilir ve hastanın sağlığı üzerinde göz ardı edilebilir bir etki yaparken, diğerleri ölümle sonuçlanabilir. Enfeksiyonlar yerel bir bölgede başlayıp orada kalabilir veya vücudun farklı bölgelerine yayılabilir.

Çoğunlukla mikroorganizmalar vücutta hızlı bir şekilde ürer, enfekte olan dokuda kolonize olup çoğalır ve hastalığın semptomlarını ortaya çıkarır. Bazı durumlarda, enfeksiyonun erken teşhisi sayesinde, tıbbi ekipler durumu düzelterek enfeksiyona son verebilecek bir tedavi (antibiyotik reçetesi gibi) sağlayarak hızlı bir şekilde iyileşme sağlayabilir. Hastanın seyri tıbbi bakım ile değiştirilemese bile, enfeksiyonun hava, sıvı veya doğrudan temas yoluyla yayılabildiği durumlarda erken teşhis konulması, enfekte olmuş hastaları düzgün bir şekilde izole ederek hastalığın yayılmasını ve salgının oluşmasını önleyebilir.

Modern tıp, enfeksiyonları teşhis etmek için çeşitli mekanizmalar geliştirmiştir. En yaygın teknikler kan veya idrar testleri, dışkı veya tükürük örnekleri ve beyin omurilik sıvısı örneğinin alınması gibi laboratuvar teknikleridir. Bazı durumlarda, bir teşhisin düzgün şekilde gerçekleştirilmesi için görüntüleme taramaları veya biyopsiler gibi daha spesifik testlerin yapılması gerekebilir. Bu tekniklerin ana dezavantajı, çoğu durumda hastaların sadece ateş gibi semptomlar geçirdikten sonra doktora başvurmalarıdır. Fakat enfeksiyonlar, hastalığın asemptomatik kaldığı bir kuluçka dönemine sahiptir. Çoğu durumda bu dönem bir kaç gün sürer fakat bazı enfeksiyonlar asemptomatik kalır ve yıllar boyunca çok az ve çok ağır olmayan belirtiler gösterirler. Bu tarz enfeksiyonlara örnek HIV (Human immunodeficiency virus) gösterilebilir.

Böylelikle, bazı enfeksiyonel hastalıklar için erken alarm verebilen otomatik teşhis tekniklerine duyulan ihtiyaç ortaya çıkmaktadır. En iyi durumda, enfeksiyonlar semptomlar oluşmadan önce tahmin edilebilir ve böylelikle daha iyi bir tedavi süreci ve hastanın zamanında izole edilmesi gerçekleşebilir. Bu bağlamda, bilgisayar yöntemleri hastalardaki bir enfeksiyonun varlığını tahmin edebilen ve tıbbi ekiplere yardımcı olabilen bir klinik karar destek sisteminin bir parçası olarak entegre edilen tanı araçlarının geliştirilmesinde yardımcı olabilir. Araçlar sadece girdi olarak giyilebilir aygıtlardan alınan fizyolojik sinyalleri alıp, belirli tıbbi testler yapılmadan önce hastalığı tespit edip bildirebilir.

Bilgisayar yöntemleri denildiğinde hem uzman sistemler hem de makine öğrenme yöntemlerinden bahsedilmektedir. Uzman sistemlerde, uzman bilgisi kurallar biçiminde sisteme dâhil edilir ve sisteme veriler girdi olarak verildiğinde bu bilgiyi karar vermek için kullanır. Makine öğrenme, etiketli veri kümesinden bir modeli (örn. tahmin modeli) otomatik olarak elde etmek için özel algoritmalar kullanılır ve bu nedenle eğitim verilerinin etiketlenmesinin ötesinde açık bir uzman bilgisine gerek yoktur.

Tez çalışmasının bu bölümünde, bir literatür taraması prosedürü aracılığıyla, enfeksiyon tahmini ve takibinde teknolojinin durumu hakkında bir analiz yürütülmüştür. Bu literatür taramasının amacı, enfeksiyon ile ilgili olan problemin üstesinden gelmek için makine öğrenme ve uzman sistem ile ilgili olarak kullanılan yöntemlerin son durumunu ve farklı teknolojilerle elde edilen performanslarını incelemektedir. Ayrıca bu bölümde, enfeksiyonel hastalıklarda hangi özniteliklerin kullanıldığını, çalışmaların amacı, deneysel kurulumu ve hangi performans metriklerinin kullanıldığı raporlanmıştır. Ek olarak, makine öğrenme perspektifinden kaynaklanan az sayıda veri problemi veya dengesiz veri sorunu gibi bazı sorunlar incelenip önerilen çözümler raporlanmıştır.


2.2.2. Bilgisayar yöntemleriyle enfeksiyon izleyen çalışmalar

Literatürde bilgisayar yöntemleriyle enfeksiyon takibi yapan çalışmaları tespit edebilmek için belirli bir protokolle literatür tarandı. Bu protokolda çalışmaların makine öğrenmesi veya uzman sistem kullanması, enfeksiyon tahmini veya takibi içermesi, bir performans sonucu raporlaması ve son 15 yıl içinde yayınlanmış olması kriterleri dikkate alınarak incelendi. Bu kriterleri sağlayan toplamda 101 tane çalışma elde edilmiş ve incelenmiştir [104-204]. Bu çalışmaların detaylı şekilde incelendiği tablo EK 1 ile verilmiştir. Bu tabloda çalışmaların incelediği enfeksiyon tipi, amacı, kullanılabileceği ortamı, kullanılan bilgisayar yöntemi, veri kümesi, kullanılan öznitelikler ve rapor edilen

performans ölçütü bilgileri yer almaktadır. Tez çalışması kapsamında bu tablodan birkaç istatistiksel bilgi çıkartılıp incelenmiştir.

Literatürde, 19 farklı spesifik bulaşıcı hastalık tipinin hesaplamalı yöntemlerle öngörülmesi bildirilmiştir. Altı çalışma belirli bir türden ziyade genel enfeksiyonları hedef almaktadır: bu çalışmalar algoritmalarını birkaç farklı tür üzerinde test etmişlerdir.


Şekil 2.2. ile her bir enfeksiyon türü için çalışma sayısı grafiği verilmiştir. Hesaplamalı yöntemlerle erken tahmin bağlamında en sık görülen enfeksiyon türü, kan dolaşımı yoluyla yayılan ve ciddi bir enfeksiyon olan kan zehirlenmesi olarak da adlandırılan Sepsistir. Cerrahi Bölge Enfeksiyonu (Surgical Site Infection (SSI)), spesifik biyolojik bir türe atıfta bulunmamakla birlikte, ameliyat sırasında yayılmış olan herhangi bir enfeksiyona işaret eder, sık görülen ikinci tiptir. Clostridium difficile enfeksiyonu (Clostridium difficile infection (CDI)), bu bağlamda ele alınan en yaygın üçüncü enfeksiyondur. CDI hayatı tehdit eden iltihaplanmalara neden olabilecek bakteriyel bir enfeksiyondur. Influenza enfeksiyonu beş farklı çalışmada ele alınmıştır. Influenza, genellikle grip olarak adlandırılan viral bir enfeksiyondur. Üçten az makale tarafından incelenen enfeksiyon tipleri “Diğer” olarak etiketlenmiştir. Diğer enfeksiyonların tam listesi aşağıdaki gibidir: Kateterle İlişkili İdrar Yolu Enfeksiyonu (CAUTI), Sağlıkla İlişkili Enfeksiyonlar, Kan Akışı Enfeksiyonu, Merkezi Venöz Kateter (CVC), Dang Ateşi, Ebola ve Marburg Virüsleri, Cerrahi bölge enfeksiyonu, Sıtma, Menenjit ve Ensefalit, Metisiline Dirençli Staphylococcus Aureus (MRSA), Patojene Maruz Kalma, Üst Solunum Yolu Enfeksiyonu, Pnömoni.



Şekil 2.2. Enfeksiyon türüne göre çalışma sayısı

Çalışmalarda enfeksiyon tahmini için kullanılan makine öğrenme yöntemleri incelenmiştir. Çalışmalardan bazıları, birden fazla sınıflandırma algoritmasıyla gerçekleştirilen deneysel sonuçları rapor etmektedir. En yaygın algoritma, toplam 33 çalışmada kullanılan Lojistik Regresyondur (LR (Logistic Regression)). Bunu sırasıyla 21 ve 18 kullanım sayılarıyla Destek Vektör Makinesi (SVM) ve Rastgele Orman (RF) izlemektedir. Diğer kısaltmalar şunlardır: Gizli Markov Modeli (Hidden Markov Model (HMM)), Doğrusal Diskriminant Analizi (Linear Discriminant Analysis (LDA)), Naive Bayes (NB), k-en yakın komşu (k-Nearest Neighbour (k-NN)), Yapay Sinir Ağları (Artificial Neural Network (ANN)), Bayesian Ağı (Bayesian Network (BN)), Uzun Kısa Süreli Bellek (Long Short Term Memory (LSTM)), Gradyan Artırılmış Ağaçlar (Gradient Boosted Trees (GBT)), Olasılık Tablosu (Contingency Table (CT)), Kuadratik Diskriminant Analiz (Quadratic Discriminant Analysis (QDA)), Doğrusal Dinamik Sistem (Linear Discriminant System (LDS)), Gauss Süreci / Gauss Karışım Modeli (GP), AdaBoost (AB), Toplu öğrenme (Ensemble Learning (EL)), Evrişimsel Sinir Ağları (Convolutional Neural Network (CNN)), Topik Modelleri (Gizli Dirichlet Ataması (Latent Dirichlet Allocation) veya çeşitleri için kullanılan (TM)), Doğal Dil İşleme (Natural Language Processing (NLP) ve Doğrusal Regresyon (Linear Regression (LiR)).

Sınıflandırma algoritmasının tercihi, dikkate alınan enfeksiyon tipine göre değişebilir. Şekil 2.3., literatürde, sadece en az üç çalışmada kullanılmış algoritmaların için oluşturulmuştur. Sepsis tahmini için benzer sıklıkta LR ve SVM tercih edilmiştir. LR, CDI tahmininde en yaygın kullanılanıdır.




Enfeksiyon Türü

Şekil 2.3. Enfeksiyon türlerinde makine öğrenme yöntemlerinin dağılımı

Mevcut araştırmalar, enfeksiyon türü için temsili olduğuna inanılan birkaç sayısal öznitelik kullanmaktadır. Bu öznitelikler 9 grupta toplanabilir. Demografik, yaş, cinsiyet vb. kişisel bilgileri tanımlar. Hayati belirtiler, vücudun ne kadar iyi çalıştığını görmek için rutin olarak izlenen temel ölçümleri ifade eder. Bütün enfeksiyon tiplerinde yaygın olarak kullanılan beş hayati belirti (kalp ritmi, sıcaklık, solunum hızı, oksijen satürasyonu ve kan basıncı) vardır. Laboratuvar testleri kandan veya idrardan alınan analizleri içermektedir. Elektrokardiyogram (Electrocardiogram (ECG)) gibi elektronik ölçümler veya herhangi bir görüntüleme yönteminden elde edilen görüntüler basitçe biyomedikal sinyaller olarak adlandırılır. Hastaların muayenesi veya tedavisi sırasında kullanılan reçeteleri, ilaçları veya prosedürleri tanımlamak için “klinik veri” terimini kullanılmıştır. Lojistik veriler, hastaneye giriş süresi, kalış süresi vb. hastaların idari süreçleriyle ilgili bilgileri temsil eder. Mikrobiyoloji verileri, biyobelirteçler gibi genotip bilgileri ile ilgilidir. Risk faktörleri, bazı klinik risklerin ciddiyetini tanımlamak için diğer verilerden türetilen özniteliklerdir. Çalışmaların bazıları, kullandıkları öznitelikleri soyutlamak için Elektronik Sağlık / Tıbbi Kayıtlar terimini kullanmayı tercih etmektedir. Bu öznitelikler açıkça belirtilmediğinden, bu özniteliklere atıfta bulunmak için EHR (Electronic Health Records) terimini kullanılmıştır. Çalışmalarda kullanılma sayısına bakılarak, üç hayati belirtinin enfeksiyon tahmini için


yaygın bir şekilde kullanıldığı tespit edilmiştir bunlar, kalp ritmi, sıcaklık ve solunum hızıdır. Laboratuvar testleri, demografik veriler ve klinik verileri de yaygın olarak kullanılmaktadır. Sınıflandırıcıları beslemek için kullanılan öznitelik kümeleri de enfeksiyon tipine göre farklılık göstermektedir (Şekil 2.4.).



Şekil 2.4. Enfeksiyon türlerinde makine öğrenme özniteliklerinin dağılımı

Sağlık alanındaki birçok makine öğrenimi çalışması, kullanılan veri kümesinin boyutu ve içeriği ile ilgili sorunlarla karşılaşmıştır. Bu sorunlar iki şekilde ortaya çıkmaktadır. Birincisi, bu alanda büyük veri kümelerinin çok nadir görülmesidir. Bu problem, mevcut eğitim verileri ile test verilerinin arasındaki boşluğu göstermek için “küçük veri” olarak adlandırılmaktadır. Eğitim verileri tüm veriyi temsil etmek için yetersiz olduğunda, genel modeller geliştirmek daha zor hale gelmektedir. Bu sorun, geliştirilen modelin veriyi ezberlemesi, daha düşük doğruluk gibi başka sorunlara neden olabilir. Diğer bir temel problem, veri kümesindeki sınıfların dengesiz dağılımıdır. Tıp alanında genellikle normal / kontrol grubunda fazla örnek bulunması ve hastalık grubunun azınlıkta kalmasından dolayı bu problem oluşmaktadır. Bu probleme “dengesiz veri” adı verilir. Bu iki önemli problem, fizyolojik verilerden öznitelik çıkarırken enfeksiyon tahminini nasıl etkilediklerini görmek için çalışmalarda incelenmiştir.


Küçük veri problemi 30 çalışmada bahsedilmiştir detaylar Şekil 2.5. ile verilmiştir. Bu çalışmalardan altısı, sorunu tahmin sistemine herhangi bir etkisi olmayan genel bir sınırlama olarak adlandırmıştır. Çalışmalar incelendiğinde üç etki ortaya çıkmıştır: (1) düşük doğruluk, (2) sınırlı genelleme ve (3) haksız değerlendirme. Çalışmalardan 11 tanesi, eğitim verilerinin azlığından dolayı enfeksiyon tahmin doğruluğunun azaldığını göstermiş veya varsaymıştır. Diğer 11 çalışma, küçük bir veri kümesine sahip olunması nedeniyle modeli tüm popülasyona genellendirmenin kolay olmadığından bahsetmişlerdir. Çalışmalardan ikisi, küçük verilerin modelin haksız değerlendirilmesindeki etkisinden bahsetmiştir. Haksız değerlendirme, değerlendirilen makine öğrenme yöntemlerinin performansları arasında adil bir karşılaştırma yapmak için yeterli kaynak veya uygun ortamın bulunmaması anlamına gelmektedir.



Şekil 2.5. Küçük veri probleminin çalışmalardaki etkileri


Küçük veri problemine çözüm öneren çalışmaların istatistikleri Şekil 2.6. ile verilmiştir. Küçük veri probleminden bahseden makalelerin 15 tanesinde özel bir çözüm önerilmemiştir. Çalışmaların beşi, makine öğrenme modelinin parametrelerini ayarlayarak küçük eğitim verileri problemini çözmeye çalışmışlardır. Stanculescu ve diğerleri [180] sepsis veri kümesindeki örnek sayısının düşük olması nedeniyle tahminlerin çok kötü olmasını önlemek için otoregresif Hidden Markov Modellerinde optimize edilmiş

parametreler kullanmıştır. Wiens ve diğerleri [198] küçük veri kümeleri için daha uygun olacak yeni bir öznitelik çıkarma prosedürü önermiştir. Kam ve Kim [136] düşük boyutlu eğitim verileri için özelleştirilmiş detaylı bir mimariye sahip yeni bir derin öğrenme modeli geliştirmiştir. Diğer üç çalışma da eğitim verilerinin miktarını arttırmak için rastgele yeniden örnekleme kullanmıştır. Yedi çalışmada, yeni verilerin toplanmasının küçük verilerin olumsuz etkilerini yenmek için en iyi çözüm olacağını savunmuştur.




Şekil 2.6. Küçük veri problemi için önerilen çözümler

Dengesiz veri sorunu, çalışmaların 25 tanesinde açıkça belirtilmiştir (bkz. Şekil 2.7). Bu çalışmaların sekizi, sorunu genel bir sınırlama olarak tanımlamış ve tahmine herhangi bir etkisi olmadığından bahsetmiştir. Küçük veri probleminde olduğu gibi aynı etkiler ortaya çıkmıştır. Sonuçlara göre, çalışmaların sekiz tanesinde enfeksiyonu tahmin etmek için geliştirilen modellerin haksız değerlendirilmesi dengesiz verilerin en ciddi etkisi olarak bahsedilmiştir. En sık bahsedilen ikinci etki, düşük doğruluktur. Bu çalışmaların yazarları, genel doğruluk ölçütleri gibi geleneksel yöntemlerin modellerin yeteneğini ayırt etmek için yeterli olmadığını belirtmiştir. Son olarak bir kaç çalışmada yazarlar dengesiz verilerin oluşturulan modelin genelleştirilmesini sınırlayabileceğini bildirmiştir.




Şekil 2.7. Dengesiz veri probleminin çalışmalardaki etkileri

Dengesiz veri problemine çözüm öneren çalışmaların istatistikleri Şekil 2.8. ile verilmiştir. Dengesiz veri probleminden bahseden çalışmaların üçü bunun için özel bir çözüm sunmamaktadır. Çalışmaların beşi dengesiz verilerle başa çıkma yöntemi olarak model parametrelerini ayarlamıştır. Sen ve diğerleri [175] enfeksiyonu tahmin etmek için bir SVM modeli eğitirken, objektif fonksiyonunda azınlık sınıfına daha yüksek bir yanlış sınıflandırma maliyeti ataması yapmıştır. Monsalve ve diğerleri [159], her alt modelin dengeli bir alt kümeden eğitildiği bir lojistik regresyon modeli topluluğu oluşturmuştur. Wiens ve diğerleri [198] dengesiz enfeksiyon verisinden SVM'yi eğitmek için asimetric bir maliyet parametresi kullanmıştır. Çalışmaların 14 tanesinde, sınıfların dağılımını dengelemek için örnek azaltma veya arttırma stratejisi uygulanmıştır. Çalışmaların dördü belirli bir çözüm önermemiş ancak AUC (AUROC) eğrisi altındaki alana dayalı daha objektif bir performans değerlendirme şeması kullanılmıştır. Dengesiz veri probleminden açıkça bahsedilmemesine rağmen, çalışmaların 61 tanesi model performanslarını değerlendirmek ve kıyaslamak için AUROC tabanlı bir metodoloji kullanmıştır.



Şekil 2.8. Dengesiz veri problemi için önerilen çözümler

Son olarak, çalışmalar raporladıkları performans ölçütüne göre incelenmiştir. Bu inceleme sonucu Şekil 2.9. ile gösterilen istatistiksel grafik ortaya çıkmıştır. AUC metriği enfeksiyon tahmini çalışmalarında en çok kullanılan performans metriği olmuştur. İkinci en çok kullanılan duyarlılık ve özgüllük metrikleridir. Doğruluk metriği de en çok kullanılanlar arasında olmasına rağmen tek başına anlamlı olmadığı raporlanmıştır ve genellikle deneylerde destekleyici rol oynamıştır. F1 skoruyla birlikte PPV (Positive Predictive Value) ve NPV (Negative Predictive Value) metrikleri ise en az kullanılanlar arasındadır.



Şekil 2.9. Enfeksiyon tahmini ve izlenmesi çalışmalarında kullanılan performans ölçüm metrikleri

2.3. Sepsis Hastalığı İzleme

2.3.1. Giriş

Sepsis (kan zehirlenmesi) her yıl dünya çapında 18 milyon insanı etkilemektedir [205]. Sepsis, hastane yoğun bakım ünitelerinde özel tedavi gerektiren ve hayatı tehdit eden bir hastalıktır. Vücuttaki bir enfeksiyona cevap olarak oluşur ve vücudun organlara yeterli kan akışı sağlayamadığı bir aşamaya ilerleyebilir. Çok sık ve yanlış antibiyotik kullanımı ile bağışıklık sisteminin zayıf düşmesi bu hastalığın oluşmasına zemin hazırlamaktadır. Hastalığın sonraki evrelerinde çoklu organ yetmezliği ve ölüm görülme sıklığı çok fazladır [206]. Sepsis vakalarının yaklaşık yüzde 90'ına bakteri neden olur, ancak sepsise virüs veya mantar da sebep olabilir [205]. Her ne kadar gelişmiş ilaç sektörü ve son klinik uygulamalar sepsis ile ölüm riskini azaltmış olsa da, hastanelerde görülen vaka sayısındaki genel artış nedeniyle her yıl ölen kişi sayısı artmaya devam etmektedir [207]. Bu nedenle, sepsise sahip yüksek risk taşıyan hastaları belirlemek büyük bir zorluktur. Hızlı ilerleyen bir hastalık olduğu için hızlı ve doğru zamanda müdahale etmek hayatları kurtarabilmektedir. Ayrıca, doğru zamanda doğru ilaç verilerek ölüm oranı etkili bir şekilde azaltılabilir.

Sepsis hastalığının tespiti için biyobelirteçler, geleneksel yöntemler ve çeşitli skorlama sistemleri kullanılmaktadır [208]. Biyobelirteçler; kan, plazma veya vücut sıvısından alınarak klinik olarak sepsisi tespit etmekte önemli bir role sahiptir. Sepsis için biyobelirteçlerin belirlenmesi, etkileri ve klinik olarak sepsis üzerindeki önemleri hakkında kapsamlı araştırmalar yapılmıştır. Bununla birlikte, tıp literatüründe sepsis tanısı koymak için çok az sayıda biyobelirteç tespit edilmiştir. Sepsis tanısında en çok kullanılan biyobelirteçler C-reactive protein (CRP), Procalcitonin (PCT) ve beyaz kan hücreleridir (lökosit) [209].

CRP, makrofajlar tarafından oluşturulan faktörlere cevap olarak öncelikle karaciğerde sentezlenir. Enfeksiyon ve enflamasyondan durumlarında seviyesi artış gösteren akut bir faz proteinidir. Bu sebepten dolayı klinik olarak enfeksiyon ve enflamasyon tespitinde sıklıkla kullanılan bir biyobelirteçtir. CRP seviyesindeki artış hastalığın derecesi ve enfeksiyonun şiddeti ile uyum içindedir. CRP ‘nin kolay erişilebilirliği onu güçlü bir hastalık tespit ölçütü yapmaktadır [209]. PCT, insanda tiroit bezinin C hücreleri tarafından salgılanan bir hormon olan kalsitoninin öncüsüdür. Sepsise sahip hastaların plazma ve serumlarında PCT düzeylerinin yüksek seviyelerde olduğu kabul edilmiştir. Ayrıca, bu ölçüt enfeksiyonlu hastalarda sağ kalma oranını temsil eder.

Geleneksel yöntemlerden en çok kullanılanı kan kültürü alınmasıdır. Kan kültürü kan akışındaki patojenleri tespit eder ve Sepsis tanısında altın standart terim olarak adlandırılır. Pozitif kan kültürü sonuçlarına bakıldığında, hastanın savunma mekanizmasının enfeksiyona karşı aktive olduğu bilgisi çıkarılır. Fakat kan kültüründen sonuç alma süresi patojenlerin yavaş büyümesinden dolayı gecikebilir [209] [210].

Tespit için kullanılan bu yöntemler çok adımlı analizler gerektirmektedir. Bu yöntemleri uygulamak, zaman alan, maliyetli ve tıbbi olarak eğitilmiş personel gerektirmektedir. Ek olarak, bu yöntemler bir laboratuvar ortamı gerektirmektedir. Bu sebepten dolayı bu yöntemlerin dezavantajlarının üstesinden gelen teknolojiler kullanılmalı ve klinik olarak yoğun bakım ünitesi sistemine bütünleştirilmelidir [209]. Bu yüzden sepsis hastalığını yoğun bakım ünitesinde kolayca ölçülebilen hayati belirtileri (vital signs) kullanarak makine öğrenmesi yöntemleriyle tahmin edilmesi önem kazanmaktadır [152]. Giyilebilir sensörlerle alınabilen hayati belirti değerleri ve makine öğrenmesi kullanılarak geleneksel yöntemlerin zaman ve iş gücü problemi çözülebilir ve zamanında müdahale edilerek hastanın hayatı kurtulabilir.

Sepsis hastalığının tıp literatüründe farklı evreleri bulunmaktadır. Bu evreler: sepsis, ağır sepsis ve septik şok olarak adlandırılmaktadır. Bu evrelerin kolaylıkla tespiti için çeşitli kural tabanlı skorlama sistemleri üretilmiştir. Kural tabanlı sistemlerin seçilmesinin nedeni, sepsis tanısında bir standart belirlemek ve vakit kaybetmeden müdahale edebilmek içindir. Bu skorlama sistemlerinden ilk kullanılanı Systemic Inflammatory Response Syndrome (SIRS) kriteridir. 1992 yılında American College of Chest Physicians (ACCP) ve the Society of Critical Care Medicine (SCCM) kuruluşları bir konsensüs oluşturup sepsisin semptomlarını tanımlamış ve buna Sepsis-1 adı vermişlerdir. Daha sonra 2001 yılında bu tanımlama genişletilerek SIRS kriterleri oluşturulmuş ve bu tanıma da Sepsis-2 denilmiştir. SIRS kriterleri dört elemandan oluşmaktadır: (1) kalp ritminin dakikada 90 atımdan fazla olması, (2) vücut ısının 38 dereceden büyük veya 36 dereceden küçük olması, (3) nefes alma hızının dakikada 20 den fazla olması veya PaCO₂ oranının 32 mmHg den küçük olması ve (4) beyaz kan hücrelerinin sayısının 12x10⁹ cells/L değerinden fazla olmasıdır [152].

Sepsis-2 tanımına göre eğer SIRS kriterlerinden herhangi ikisi hastada görünüyorsa sepsis şüphesi var demektir. SIRS kriterlerinden herhangi ikisinin hastada bulunmasına ek olarak organ yetmezliği kriterlerinden bir tanesinin görülmesi hastalığın ağır sepsis vakası olarak değerlendirilmesi sonucunu vermektedir. Organ yetmezliği kriterleri; kandaki laktoz seviyesi, kreatin miktarı ve idrar miktarı gibi bir takım ölçümlerden oluşmaktadır [152]. Septik şok kriteri ise hastaya serumun bağlı olmasına rağmen hipotansiyon konumundan en az 30 dakika çıkamamasıdır [152].

Sepsis-2 tanımının yıllarca kullanılmasından sonra sağlık uzmanları sepsis semptomlarının tipik olmadığını, tanı ve tedavinin bu yüzden geciktiğini raporlamışlardır [206]. Sepsis-2 standardını oluşturan araştırmacılar daha açık ve kapsamlı bir standardın getirilmesi kararı almışlardır. Bu bağlamda 2016 yılında Sepsis-3 adı altında yeni bir tanım ortaya çıkmıştır. Bu tanıma göre sepsis “hayati tehlike arz eden bir hastalıktır ve enfeksiyon sonucu organların işlevlerini kaybetmesine sebep olmaktadır”. Bu tanım SIRS kriterini ve ağır sepsis evresini orijinal Sepsis-1 ve Sepsis-2 tanımından çıkarmıştır. Bu tanımla birlikte sepsis artık Sequential (Sepsis Related) Organ Failure Assessment (SOFA) skoru ile değerlendirilmektedir [206]. Günümüzde dünyadaki çoğu ülkede SOFA skorundaki değişime göre sepsis tanısı yapılmaktadır [211]. Bu skor değişimine göre sepsis hastalığı başlangıç saati (onset time) belirlenmektedir. SOFA skoru ne kadar yüksekse ölüm oranı riski de o kadar fazladır. Bu sebeple SOFA skorlarına bakılarak enfeksiyonun ölümcül olma oranı da tespit edilmektedir. Skor, organ sistemine göre anormallikleri tespit eder ve klinik müdahalelere olanak sağlamaktadır [211]. SOFA skoru, sepsis tespiti için kullanılmasının

yanı sıra organ yetmezliği tespitinde de kullanılmaktadır. Bu skor, organların çeşitli enfeksiyonlar sebebiyle ne kadar etkilendiğini belirten bir ölçüttür. Günümüzde medikal literatürde, SOFA skorunun ölüm oranı tahmininde, sepsis ve organ sistemlerinin durumunu izlemeye geçerliliği bir çok çalışma ile kanıtlanmıştır [212, 213, 214]. SOFA, altı farklı organ sistemini (kardiyovasküler, solunum, sinir, karaciğer, pıhtılaşma ve böbrek) temsil eden 6 değişkeni göz önünde bulundurur ve her bir bileşene sayısal puanlar atanır. Bu değişkenler; PaO₂ değeri, trombosit, bilirubin, kan basıncı veya dopamine/epinefrin seviyesi, Glasgow Coma Scale ve kreatindir [215]. Her organ sistemi için puanlama, normal işlev için 0, maksimum başarısızlık / işlev bozukluğu için 4 arasında değişmektedir. Bu değişkenlerin skorlarının toplamı SOFA skorunu vermektedir. Dolayısıyla bu skor maksimum 24 olabilir ki bu durum 6 organ sisteminin de çökmesi durumudur [216] [217]. SOFA skorunun 7 değerinden büyük olması durumunda ölüm riski başlamıştır demektir [206]. SOFA skoru bileşenleri Şekil 2.10. ile gösterilmektedir. Şekil 2.10. ile görüldüğü üzere her kategorideki ölçümler aralıklara bölünmüş ve aralık değerlerine skor ataması yapılmıştır. Bu ölçümlerin yapılabilmesi için hastalardan kan ve idrar numuneleri alınması ve bu numunelerin laboratuvarlarda incelenmesi gerekmektedir.

SOFA score	0	1	2	3	4
Respiration					
PaO ₂ /FIO ₂ (mmHg)	> 400	301-400	201-300	101-200	≤ 100
(kPa)	> 5.3	(4.1-5.3)	(2.8-4.0)	(1.4-2.7)	≤ 1.3
Coagulation					
Platelets (x10 ³ /mm ³)	> 150	101-150	51-100	21-50	≤ 20
Liver					
Bilirubin (mg/dl)	< 1.2	1.2-1.9	2.0-5.9	6.0-11.9	≥ 12.0
(μmol/l)	< 20	(20-32)	(33-101)	(102-204)	≥ 204
Cardiovascular					
Hypotension	No hypotension	MAP < 70 mmHg	Dopamine ≤ 5 or dobutamine (any dose)*	Dopamine > 5	Dopamine > 15
Central nervous system					
Glasgow coma score	15	13-14	10-12	6-9	< 6
Renal					
Creatinine (mg/dl)	< 1.2	1.2-1.9	2.0-3.4	3.5-4.9	> 5.0
(μmol/l)	< 110	(110-170)	(171-299)	(300-440)	> 440
or urine output				< 500 ml/day	< 200 ml/day

* adrenergic agents administered for at least 1 h (doses given are in μg/kg/min)

Şekil 2.10. SOFA skoru bileşenleri [218]

Tez çalışmasının bu bölümünde, sepsis semptomlarının ve organ sistemlerinin durumunu nicel olarak izlemek için hesaplamsal bir çözüm sunulmaktadır. Önerilen çözüm, hastalarda organ yetmezliğinin ciddiyetini ölçmek için kullanılabilecek SOFA skorunun tam değerini tahmin edebilme imkânı sağlamaktadır. Önerilen model, SOFA skorlarını tahmin

etmek için YBÜ (Yoğun Bakım Ünitesi) 'de yatak başucundan elde edilebilecek sadece yedi hayati belirtiyi kullanarak tahmin bazında bir analiz gerçekleştirmektedir. SOFA skor tahmini için çeşitli makine öğrenme ve derin öğrenme yaklaşımları ile deneyler yapılmıştır. Bu regresyona dayalı analizin gerçekleştirilmesiyle, SOFA puanını hesaplamak için laboratuvar sonuçlarını bekleme ve yorumlama ihtiyacı ortadan kalkmaktadır. Ayrıca normalde invazif yani iğne ile kan alımı ve kanın laboratuvarında incelenmesi ile ölçülen bu skor invazif olmayan giyilebilir sensörlerden alınan hayati belirtilerle doğru, hızlı ve kolay bir şekilde otomatik olarak hesaplanma imkânı sunmaktadır. Önerilen SOFA skoru tahmin çözümü, organ yetmezliği ve sepsis hastalıklarının hızlı teşhisini ve tedavisini sağlamayı amaçlamaktadır. SOFA puanının önceden tahmin edilmesi, sağlık çalışanlarının organ sistemlerinin durumunu izlemesinde yardımcı olacaktır. Bu çalışmada, çeşitli makine öğrenme ve derin öğrenme yaklaşımlarının Sepsis hastalarını tespit etme performansı da çeşitli deneylerle değerlendirilmiştir. Ayrıca, tez çalışmasında en iyi sonucu veren model, mevcut sepsis tahmin modelleri ile karşılaştırılarak çeşitli deneyler yapılmıştır. Deneyler sonucunda SOFA skoru ve sepsis hastalığı tahmininde bir derin öğrenme yapısı olan CNN mimarisinden çıkarılan özniteliklerle birlikte Rastgele Orman algoritmasının kullanıldığı model diğer modellere göre en iyi performansı göstermiştir.

2.3.2. İlgili çalışmalar

Makine öğrenmesi yöntemleri kullanılarak Sepsis tahmini üzerine son yıllarda literatürde birçok çalışma bulunmaktadır. Fakat bu çalışmalar Sepsis tahmini üzerine sadece ikili karar verme biçiminde çalışmışlardır. Hastalığın varlığını oluşmadan önce tahmin etmeye çalışmışlardır. Literatürde Sepsis üzerine çalışmalar bu bölümde incelenmiştir.

Desautels ve diğerleri [116] elektronik sağlık verileri ve makine öğrenmesi kullanarak yoğun bakım ünitesinde yatan hastaların sepsis olup olmama durumunu tahmin eden bir çalışma yapmışlardır. Çalışmada MIMIC III veri kümesinde bulunan hasta verilerini kullanmışlardır. Veri kümesindeki hastalardan kalp ritmi, GCS (Glasgow Coma Scale), oksijen satürasyonu, sıcaklık, kan basıncı gibi hayati belirti sinyallerine ek olarak yaş demografik bilgisini de çıkarmışlardır. Bu sinyalleri sepsis olmadan önceki sıfır ve dördüncü saatler için elde etmişlerdir. Bu saatler için elde edilen verileri sepsisi önceden tahmin etmek için kullanmışlardır. Geliştirdikleri sisteme Insight adını vermişlerdir. Insight sistemi içine kendi makine öğrenme yöntemlerini entegre ederek testler gerçekleştirmişlerdir. Yöntemlerini SOFA, SIRS gibi çeşitli sepsis tespit etme yöntemleriyle karşılaştırmışlardır.

Sınıflandırma performansını AUC, Doğruluk, F1 skoru metrikleriyle ölçmüşlerdir. Diğer yöntemlere göre başarılı sonuçlar elde ettiğini raporlamışlardır.

Calvert ve diğerleri [109] geliştirilen Insight sistemini, sepsis tahmininde güçlü bir araç olarak kullanılan kandaki laktik asit oranı ve Prokalsitonin (PCT) seviyesi yöntemleriyle erken sepsis teşhisi performansı üzerine karşılaştırmışlardır. Kullandıkları veri kümesi MIMIC II veri kümesidir. Bu veri kümesinden kalp atım hızı, sıcaklık, kanın PH değeri, beyaz kan hücreleri sayısı gibi birtakım öznitelikler çıkarmışlardır. Bu öznitelikleri sepsis olmadan önceki beş saatlik periyottan çıkarmışlardır ve dolayısıyla zaman serisi sinyalleri elde etmişlerdir. Kendi geliştirdikleri makine öğrenmesi yöntemiyle laktik asit oranı, Prokalsitonin (PCT) ve SIRS ölçütleriyle sepsis tahmin etme yöntemlerini karşılaştırmışlardır. AUC ölçütü bakımından Insight algoritmasının diğer ölçütlere göre üstün geldiğini raporlamışlardır.

Kam ve Kim [136] derin öğrenme yaklaşımıyla sepsis hastalığını önceden tahmin etme üzerine bir çalışma gerçekleştirmişlerdir. Çalışmada MIMIC II veri kümesini kullanmışlardır. Hastaların sepsis olmadan önceki beş saate ait ölçüm sinyallerini veri kümesinden çıkarmışlardır. Bu sinyaller sıcaklık, kan basıncı, solunum hızı, beyaz kan hücreleri sayısı ve yaş gibi özniteliklerden oluşmaktadır. Bu sinyallerden saatlik periyotlarla ortalama, minimum ve maksimum değer öznitelikleri çıkarmışlardır. Çıkarılan özniteliklerle, LSTM (Long short-term memory) derin öğrenme yapısını ve derin ileri beslemeli ağ yapısını (Deep Feed forward network) eğitip sınıflandırma gerçekleştirmişlerdir. Testlerinde farklı derin ileri besleme ağı ve LSTM mimarilerini karşılaştırmışlardır. Bu mimarilerle ayrıca da Insight modelini karşılaştırmış ve AUC ölçütü bazında LSTM yapısının daha başarılı olduğunu raporlamışlardır.

Moor ve diğerleri [219] DTW (Dynamic Time Warping) ve derin öğrenme yöntemleriyle sepsis hastalığını önceden tahmin etme üzerine bir çalışma yapmışlardır. MIMIC III veri kümesinden hastalık gerçekleşmeden önceki yedi saatlik dönem üzerinden kırk dört tane öznitelik çıkarmışlardır. Bu öznitelikler laboratuvar ve hayati belirti sinyallerini içermektedir. Modellerinde bu öznitelikleri birlikte kullanmışlardır. Gaussian Process (GP) adında bir yöntemle zaman serilerini modellemişlerdir. Bu yöntemi seçmelerinin sebebi farklı boyutlardaki sinyalleri aynı ölçüte getirmektir. Temporal Convolutional network derin öğrenme yöntemini GP yöntemiyle birleştirmişlerdir. Ayrıca bir zaman serisi yöntemi olan DTW yöntemini k en yakın komşuluk yöntemiyle birleştirip yeni bir yöntem ortaya çıkarmışlardır. Daha sonra önerdikleri bu yöntemlerin sınıflandırma performanslarını daha önceki çalışmayla ve sadece ham verinin kullanıldığı derin öğrenme

yapısıyla karşılaştırmış, sonuçları AUC ve AUPRC cinsinden vermişlerdir. Önerdikleri yöntemlerin önceki yönteme ve ham veri kullanan yöntemlere göre AUC ve AUPRC cinsinden daha başarılı olduğunu raporlamışlardır.

Nemati ve diğerleri [207] birçok farklı alandaki öznitelikleri kullanarak makine öğrenmesi yöntemiyle sepsis tahmin etme üzerine deneyler gerçekleştirmişlerdir. Kullandıkları veri kümesi iki kısımdan oluşmaktadır. Makine öğrenmesi yöntemini eğitmek için Emory Healthcare system veri kümesini kullanmışlardır. Test etmek için ise MIMIC III veri kümesindeki hasta kayıtlarını kullanmışlardır. Bu hastalardan dört grupta öznitelik çıkarmışlardır. İlki entropi ve standart sapma istatistiksel öznitelikleri, ikincisi kalp ritmi, solunum hızı gibi hayati belirti öznitelikleri, üçüncüsü kandaki hemoglobin sayısı, kreatin oranı, PH değeri gibi laboratuvar öznitelikleri ve son olarak da yaş, yara tipi ve son on iki saatteki ameliyat sayısı gibi demografik ve tarihsel özniteliklerdir. Bu verileri dörder, altışar, sekizer ve on ikişer saatlik dönemler için elde etmişlerdir. Kullandıkları makine öğrenmesi algoritması modified regularized Weibull-Cox analysis algoritmasıdır. Farklı sepsis tespit kriterlerine göre de karşılaştırmalar yapmışlardır. Performansı ölçmek için AUC ölçütü kullanılmıştır. SOFA sepsis kriterinin kendi algoritmalarıyla birleştirip kullanılmasında en yüksek başarıyı elde ettiklerini raporlamışlardır. Dört saatlik dönemler için daha yüksek başarımda sepsis tahmini gerçekleştirmişlerdir.

Mao ve diğerleri [152] MIMIC III üzerinde kullanılan Insight algoritmasının farklı veri kümelerindeki sepsis, ağır sepsis ve septik şok tahmin performansını incelemişlerdir. Kullandıkları veri kümeleri University of California San Francisco ((UCSF) Medical Center), Stanford Medical Center (Stanford, California, USA), Oroville Hospital (Oroville, California, USA), Bakersfield Heart Hospital (BHH; Bakersfield, California, USA) ve Cape Regional Medical Center (CRMC; Cape May Courthouse, New Jersey, USA) hastanelerinde acil bölümünde kalan hastaların üç saatlik hayati belirti sinyallerinden oluşmaktadır. Bu sinyaller Insight algoritmasının kullandığı kalp ritmi, GCS (Glasgow Coma Scale), oksijen saturasyonu, sıcaklık, tansiyon gibi hayati belirti sinyallerini içermektedir. Makine öğrenmesi algoritması olarak Gradient Tree Boosting algoritmasını tercih etmişlerdir. Makine öğrenmesi algoritmasını MIMIC III veri kümesiyle transfer öğrenme (transfer learning) yöntemiyle eğitip testler gerçekleştirmiştir. Testlerinde sepsis i tespit etmekte kullanılan farklı skrolama sistemleriyle geliştirdikleri algoritmanın performansını karşılaştırmışlardır. Yöntem diğerlerine göre AUC cinsinden daha iyi sonuçlar vermiştir. Ayrıca transfer öğrenmesiyle eğitilen algoritmanın kullanılan diğer veri kümeleriyle eğitilen algoritmadan AUC cinsinden daha başarılı olduğunu raporlamışlardır.

Mani ve diğerleri [150] çocuklarda sepsis hastalığını önceden tespit eden tıbbi bir karar destek sistemi geliştirmişlerdir. Kullandıkları veri kümesi Monroe Carell Jr. Children's Hospital at Vanderbilt adlı hastanede çocuk acilde kalan hastalardan oluşmaktadır. Bu hastalardan mikrobiyoloji, laboratuvar, hayati belirtiler ve demografik bilgilerden oluşan öznitelikler çıkarmışlardır. Toplam kullanılan öznitelik sayısı doksan ikidir. Bu öznitelikleri enfeksiyon şüphesiyle kan kültürü alınmadan kırk sekiz saat öncesi ve kan kültürü alındıktan on iki saat sonrası aralığı için çıkartmışlardır. Çıkarttıkları öznitelikleri çeşitli makine öğrenme algoritmalarına girdi olarak vermiş ve sonuçları AUC cinsinden vermişlerdir. Kullandıkları makine öğrenmesi algoritmaları Destek Vektör makineleri, Naive Bayes türleri, k en yakın komşuluk, rasgele orman ve lojistik regresyon' dur. Naive bayes ve rasgele orman algoritmalarının diğer algoritmalara göre iyi sonuçlar ürettiğini raporlamışlardır. Ayrıca yazarlar, çocuklarda Sepsis tespitinde en ayırt edici özniteliklerin mikrobiyoloji testlerinden elde edilen öznitelikler olduğunu kanıtlamışlardır.

Masino ve diğerleri [153] çocuklarda sepsis hastalığının önceden tespit edilmesi üzerine bir çalışma gerçekleştirmişlerdir. Kullandıkları veri kümesi Children's Hospital of Philadelphia hastanesinde çocuk acil bölümünde yatan hastalardan oluşmaktadır. Sepsis oluşmasından önceki kırk dört saati dikkate alarak veri kümesinden öznitelikler çıkartmışlardır. Bu öznitelikler laboratuvar, hayati belirtiler ve demografik bilgilerden oluşmaktadır. Çıkarttıkları öznitelikleri naive bayes, Destek vektör makineleri, Rasgele orman, Lojistik regresyon, Adaboost, Gradient boosting gibi makine öğrenme algoritmalarına girdi olarak vermişlerdir. Testlerinde farklı sepsis senaryoları denemişlerdir. Kan kültürü pozitif grup (enfeksiyon olan) ve klinik (sepsis kriterlerini sağlayan) olarak pozitif olan grupları ayrı ayrı ve birlikte performanslarını incelemişlerdir. AUC bakımından bu grupların birlikte değerlendirilmesi daha yüksek sonuçlar vermiştir. Gradient Boosting, Adaboost ve Lojistik regresyon algoritmaları diğer algoritmalara göre AUC bakımından daha iyi sonuçlar verdiğini raporlamışlardır.

Futoma ve diğerleri [220] Multitask Gaussian Process algoritması ve RNN (Recurrent Neural Network) derin öğrenme yapısı yardımıyla sepsis tahminin gerçekleştirilmesi üzerine çalışmışlardır. Yazarlar özel bir veri kümesi olan Duke University hospital EHR veri kümesini kullanmışlardır. Burada acil bölümünde bulunan hastaları çalışmaya dâhil etmişlerdir. Bu hastalardan laboratuvar ve hayati belirtilerden oluşan otuz dört tane öznitelik çıkarmışlardır. Veri kümesinden değişen uzunlukta sinyaller çıkarmışlardır ve bu sinyaller bir kaç saatten yüz yirmi bir saate kadar uzamaktadır. Bu farklı uzunluktaki sinyalleri işleyebilmek için Multitask Gaussian Process (MGP) adında bir algoritma kullanmışlardır.

Bu algoritma farklı boyuttaki ve farklı zamanda alınmış sinyalleri sabit uzunluklu ortak bir modele çevirir. Testlerini bir derin öğrenme algoritması olan RNN yöntemiyle gerçekleştirmişlerdir. Sinyali ham olarak, Gaussian Process ile işleyip ve MGP ile işleyip RNN algoritmasına girdi olarak vermiş ve AUC ve AUPRC ölçütleri bakımından karşılaştırmalar yapmışlardır. Ayrıca önerdikleri yöntemi SIRS gibi sepsis tespit yöntemleriyle de karşılaştırmışlardır. MGP ile işlenen sinyalin RNN yapısına girdi olarak verildiğinde en yüksek AUC ve AUPRC değerlerine sahip olduğunu raporlamışlardır.

Van Wyk ve diğerleri [195] en az sayıda fizyolojik öznitelik kullanarak sepsisi önceden tahmin etmek üzerine çalışmıştır. Kullandıkları veri kümesi Methodist LeBonheur Healthcare (MLH) system adında yazarların kendi topladıkları bir veri kümesidir. Veri kümesi dört tane hastanenin acil bölümünde yatan hasta kayıtlarından oluşmaktadır. Hastalardan kalp ritmi, tansiyon, ortalama arter tansiyonu, sıcaklık, oksijen saturasyonu, acilde kalma suresi gibi birtakım öznitelikler çıkarmışlardır. Bu özniteliklere ek olarak bir laboratuvar özneliği olan beyaz kan hücreleri sayısını da öznitelik havuzuna eklemişlerdir. Hastalardan sepsis olmadan önceki üç ve altı saatlik dönemler için bahsedilen öznitelikleri çıkarmışlar ve zaman serisi sinyaline dönüştürmüşlerdir. Çıkarılan bu öznitelikleri Rasgele orman algoritmasına girdi olarak vererek sepsis olmadan önce tahmin etme üzerine deneyler yapmışlardır. Deneylerdeki ölçüm metrikleri AUC, F1 skoru, hassasiyet, özgüllüktür. Deneylerde altı saatlik ölçümlerin üç saate göre daha başarılı olduğunu raporlamışlardır. Ayrıca sadece fizyolojik özniteliklerin, fizyolojik öznitelikler ve beyaz kan hücreleri sayısı birleştirilmiş özniteliklerine göre sepsisi daha yüksek doğruluk oranında tahmin ettiğini de göstermişlerdir.

Horng ve diğerleri [131] hayati belirtilere ek olarak hemşirelerin yazılı notlarını da kullanarak sepsis tahmini gerçekleştirmişlerdir. Veri kümesini, elli beş bin acil hastası kaydına sahip bir eğitim araştırma hastanesinin acil bölümünden oluşturmuşlardır. Buradaki hastalardan kalp ritmi, kan basıncı gibi hayati belirtilerine ek olarak demografik öznitelikler, hemşirelerin yazılı notları ve hastanın yazılı şikâyetlerini de içeren öznitelikler çıkarmışlardır. Farklı öznitelik grupları oluşturarak yazılı notların enfeksiyon tahmini üzerine olan etkisini incelemişlerdir. Yazılı notlar için bag of words ve topic öznitelik çıkarma modellerini kullanmışlar ve öznitelik vektörleri oluşturmuşlardır. Daha sonra bu öznitelikleri Destek vektör makinesi, Lojistik regresyon, Naive bayes ve Rasgele orman algoritmalarına girdi olarak vermişlerdir. Testlerinde metin özniteliklerinin fizyolojik ve demografik özniteliklerle birlikte kullanıldığında AUC ölçütü bakımından diğer öznitelik

şemalarına göre daha yüksek sonuçlar elde edildiğini raporlamışlardır. Ayrıca Destek vektör makinesi algoritmasının diğer algoritmalara göre daha başarılı çalıştığını da kanıtlamışlardır.

Van Steenkiste ve diğerleri [221] kan kültür sonucunu derin öğrenme yöntemi olan LSTM yapısı ile tahmini üzerine çalışmalar gerçekleştirmiştir. Kan kültür sonucu tahminin önemi, sepsis tespitinde çok kullanılan bir adım olmasıdır ve sonuç pozitif ise kanda enfeksiyon olduğunun habercisidir. Çalışmada kullandıkları veri kümesi Ghent Üniversitesi hastanesinin acil bölümünde bulunan hastalardan oluşmaktadır. Sadece kan kültürü alınmış hastaları çalışmaya dâhil etmişlerdir. Hastalardan laboratuvar ve hayati belirti öznitelikleri çıkarmışlardır. Bunlar sıcaklık, kalp ritmi, lökosit ve trombosit oranı gibi özniteliklerden oluşmaktadır. Bu hastalardan kan kültürü alınmadan önceki yetmiş iki saatlik dönem için öznitelikler çıkarılmıştır. Çıkarılan bu öznitelikleri çift yönlü LSTM yapısına girdi olarak verip sonuçlarını raporlamışlardır. Performans ölçütü olarak AUC ve AUPRC kullanmışlardır. Veri alınma zaman döneminin performansını ölçmek için kırk sekiz saatlik dönem ve yetmiş iki saatlik dönemi karşılaştırmışlardır. Yetmiş iki saatlik dönemin kan kültürü tahmininde daha başarılı olduğunu raporlamışlardır. Ayrıca yöntemlerini K en yakın komşu, yapay sinir ağı, Lojistik regresyon ve DVM yöntemleriyle karşılaştırmışlardır. Derin öğrenme yapısının daha üstün performans gösterdiğini kanıtlamışlardır.

Scherph ve diğerleri [173], MIMIC III veri kümesini kullanarak sepsisi tahmin etmek için bir RNN mimarisi önermiştir. Hayati belirtiler ve beyaz kan hücresi sayımı gibi birçok özelliği veri kümesinden elde etmişlerdir. Sonuçlarını Insight algoritmasıyla karşılaştırmışlardır. AUC bazında yöntem, Insight yöntemine göre daha iyi sonuçlar vermiştir.

Schamoni ve diğerleri [222], sepsis tahmini üzerine olan katkılarını yeni bir veri kümesi oluşturarak sağlamışlardır. Sağlık personelleri, günlük olarak hastalarla ilgili elektronik anket doldurarak veri kümesine hastalarla ilgili etiket bilgilerini girmişlerdir. Böylelikle daha kapsamlı ve daha güncel bilgilere sahip bir veri kümesi oluşturmuşlardır. Nefes alma hızı ve CRP gibi birtakım öznitelikleri kullanmışlardır. Doğrusal ve doğrusal olmayan modellerle veri kümesini test etmişlerdir. Ek olarak veri kümesi üzerinde farklı özniteliklerin nasıl performans gösterdiğini incelemişlerdir. Çalışmanın başlıca katkısı veri kümesidir, çünkü sepsis tanımları için verilen talimatlarla doğrudan ilgili değildir; doktorların günlük gözlemlerine bakıp sepsis talimatlarına bakılmadığından sepsis araştırma alanının geçerliliğini arttırmaktadır.


Ripoll ve diğerleri [223] yoğun bakım ünitesi hastalarının sepsis ölüm oranını tahmin etme üzerine çalışmalar yapmıştır. Sepsis hastalarının ölüm durumlarını tahmin etmek için Qutoient Basis Kernel (QBK) adında yeni bir çekirdek yöntemi geliştirmişlerdir. Buna ek

olarak Fisher kernel yöntemini problem için basitleştirmişlerdir. MIMIC III veri kümesinden hastanede kalma süresi, vazotif ilaç gibi bir takım öznelilikler çıkarmışlardır. Geliştirdikleri çekirdek yöntemini diğer yöntemler ile karşılaştırmışlardır. Önerdikleri çekirdek yöntemleri klasik yöntemlerden daha başarılı olduğunu raporlamışlardır.

2.3.3. Hastalık izleme için genel yapı

Çalışmada çok sayıda farklı hastalık ve ölçümler içeren MIMIC III adında bir açık erişim veri kümesi kullanılmıştır. Bu veri kümesinden, sepsis hastaları ve sağlıklı bireylerin 12 saatlik hayati belirti ölçümleri çıkartılmıştır. Önerilen yapı birçok hayati belirti sinyallerini alır ve sepsis semptomlarını ve organ sistemlerinin durumunu izlemek için regresyona dayalı bir model kullanır. Bu regresyon problemi için iki aşamadan oluşan tipik bir model kullanılmaktadır: eğitim ve tahmin (Şekil 2.11.).

İlk olarak veri kümesinden etiketli hayati belirti sinyalleri çıkartılır. İkincisi, bu sinyaller eksik değerler içerebilir, bu nedenle eksik değerlerin belirlenmesi ve doldurulması işlemi veri ön işleme aşaması olarak gerçekleştirilir. Bu sinyaller bir regresör veya sınıflandırıcı ile eğitilir. Her bir örnek sinyal, tahminin amacına göre bir SOFA değeri ve hastalık etiketine sahiptir (Sepsis veya Sepsis değil). Eğitilen veri üzerinden bir makine öğrenmesi modeli oluşturulur. Üçüncüsü, regresöre veya sınıflandırıcıya bir test örneği verilir (ön işleme tabi tutulmuş) ve regresör, SOFA puanının tam değerini ve sınıf etiketini tahmin eder. Son olarak, regresyon ve sınıflandırma için metrikler kullanılarak performans raporlanır.




Şekil 2.11. SOFA skoru tahmini için önerilen genel yapı

3. TEZ ÇALIŞMASINDA KULLANILAN VERİ KÜMELERİ

3.1. Physionet Gait in Parkinsons Disease Veri Kümesi

Parkinson hastalığının izlenmesi için giyilebilir bir ayakkabı vasıtasıyla elde edilen yürüyüş sinyallerini içeren Physionet Gait in Parkinsons Disease veri kümesi seçilmiştir. Parkinson hastalığı izleme probleminde Physionet ve Laboratory for Gait & Neurodynamics, Movement Disorders Unit of the Tel Aviv Sourasky Medical Center tarafından toplanan veri kümesi kullanılmıştır [224]. Veri kümesi PH hastaları ve kontrol grubu yürüyüş sinyallerini içermektedir. PH deneklerin yaş ortalaması 66.3, PH hastalarının % 63'ü erkektir. Kontrol denekleri yaş ortalaması 66.3 ve % 55'i erkektir. Veri kümesindeki PH deneklerinin ve kontrol deneklerinin sayısı sırasıyla 93 ve 73'tür. Yürüyüş sinyalleri, iki dakika boyunca düz zeminde yürürken kaydedilmiştir. Yürüyüş sinyali kayıtları için ölçüm protokolleri, seri-7 çıkarma testi içeren olağan yürüyüş ve çift görevli yürüyüşten oluşur. Seri-7 çıkarma testinde, deneklerin yürürken ve her zamanki yürüyüşle aynı koşullar altındayken 3 basamaklı sayılardan (örn. 400, 393, 386) 7 çıkarılması istenmiştir. Bu testi yapmadan önce, deneklerden sorulara yüksek sesle duraksamadan cevap vermeleri ve normal hızda yürümeleri istenmiştir. Bu test global olarak bilişsel bir değerlendirme yapmak için kullanılmaktadır [225].

Rehabilitasyon tedavisinden önce ve sonra yürüme fazlarının incelenmesi etkin bir tedavi sürecini garantiler [226]. Yürüyüş fazları, her fazdaki ayak basıncı dağılımı örüntülerinin tekilliği ve tekrarlılığı nedeniyle ayak basıncı dağılımları ile belirlenebilir. Kuvvet ölçen bir sensör (Force sensitive sensor) genellikle ayak basınç dağılımını ölçmek için kullanılmaktadır. Fakat bu sensörlerin dezavantajı küçük bir sensör alanı ve sınırlı ölçme aralığına sahip olmasıdır. Bu yüzden gerçek ayak basıncını temsil edememektedir. Bu eksiklikten dolayı GRF (Ground Reaction Force) ölçen akıllı ayakkabıların kullanılması yaygınlaşmıştır [227]. GRF vücudun temas ettiği bölgeye uygulanan kuvvettir. Ayaklardaki bu reaksiyon kuvveti, kişisel yürüme alışkanlıklarına dayalı yürüme aktivitesi sırasında zamanla değiştiğinden, bireysel yürüyüş analizi için uygun bir kaynak olduğu düşünülmektedir [88]. Yürüyüş sırasında akıllı ayakkabı kullanılarak ölçülen GRF değerini gösteren grafik Şekil 3.1. ile verilmiştir. GRF ölçen örnek bir akıllı ayakkabı ise Şekil 3.2. ile verilmiştir. Genellikle GRF sensörleri bu akıllı ayakkabıların tabanına bir tabaka olarak eklenilmektedir.




Şekil 3.1. Bir adımda oluşan GRF değerleri



Şekil 3.2. GRF ölçen örnek bir akıllı ayakkabı [228]

Veri kümesinde yürüyüş sinyallerini ölçmek için kullanılan sistemde, her bir ayağın altında 8 GRF sensörü bulunmaktadır. Bu 16 sensörün çıktıları dijitalleştirilmiş ve kaydedilmiştir, örnekleme oranı 100 Hertzdir. Her bir sensör, kuvveti zamanın bir fonksiyonu olacak şekilde Newton olarak ölçer. Bu fonksiyonu kullanarak her bir ayaktaki merkez kuvvet değerinin zamanlama ölçütleri (örn: salınım süresi (swing time)) hesaplanabilir. Salınım süresi, bir ayağın yerden kaldırılıp tekrar dokunduğu süreye verilen isimdir. Şekil 3.3. ile kontrol grubu ve Parkinson hastalığına sahip kişilerin salınım süresi grafiği verilmiştir. Şekil 3.3. incelendiğinde hastaların salınım süresinin daha fazla olduğu görülmektedir.




Şekil 3.3. Kontrol ve Parkinson hastalığına sahip bireylerin salınım süresi-adım grafiği

Sensörlerin pozisyonu şu şekildedir: Bir kişinin birbirine paralel iki ayak ile ayakta durduğunu varsayarak, orijin noktası tam olarak bacakların ortasındadır ve kişi Y ekseninin pozitif tarafına doğru bakmaktadır. Her bir sensörün X ve Y koordinatları Tablo 3.1. ile verilmiştir. L, sol ayak ve R, sağ ayak anlamına gelmektedir. X ve Y değerleri, sensörlerin yerini belirlemek için kullanılabilecek yapay koordinatlardır. Bu yapay koordinat sistemi, her bir ayağın basınç merkezinin hesaplanmasını kolaylaştırmak için geliştirilmiştir. Her ayağın altındaki GRF sensör konumlarının görselleştirilmesi, Şekil 3.4. ile verilmiştir.

Tablo 3.1. Sensörlerin ayağın altındaki konumu

Sensör Adı	X koordinatı	Y koordinatı
L1	-500	-800
L2	-700	-400
L3	-300	-400
L4	-700	0
L5	-300	0
L6	-700	400
L7	-300	400
L8	-500	-800
R1	500	-800
R2	700	-400
R3	300	-400
R4	700	0
R5	300	0
R6	700	400
R7	300	400
R8	500	800



Şekil 3.4. Her bir GRF sensörünün ayaktaki konumu

Veri kümesi, deneklerin demografik bilgilerini (yaş, boy ve kilo) ve UPDRS ve H & Y ölçeğinde nicel semptom değerlerini içermektedir. PH'nın yürüyüş değişkenliğinin güvenilirliği üzerinde olumsuz bir etkisi olmadığı belirtilmiştir. Ek olarak, PH hastaları için değişkenlik kontrol grubundan daha güvenilirdir [229]. Yürüyüş değişkenliğinin güvenilirliği ve sınırlamaların üstesinden gelmek için aşağıdaki protokollere dikkat edilmesi önerilmiştir:

- 1) Aralıklı yürüyüşler yerine sürekli yürüyüş protokolü kullanın
- 2) Değişkenliği hesaplamak için 30'dan fazla adım gereklidir (en uygun 50)
- 3) Sol ve sağ adımlardan gelen bilgileri birleştirin.

Önerilen regresyon sistemi için kullanılan veri kümesi, kişinin yürüme değişkenliğini en aza indirmek için bu koşulları karşılar.

3.2. MIMIC III Veri Kümesi

Sepsis hastalığının izlenmesi için, giyilebilir sensörlerle elde edilebilen kalp ritmi, kan basıncı, oksijen satürasyonu gibi hayati belirti sinyallerini içeren MIMIC III (Medical Information Mart for Intensive Care III) veri kümesi seçilmiştir. MIMIC III veri kümesi 2010 yılında oluşturulan MIMIC II veri kümesinin genişletilmiş ve iyileştirilmiş halidir. Bu veri kümesinin tez çalışması için seçilmesinin üç tane nedeni vardır; ilki, alanındaki tek açık erişime sahip büyük çapta medikal veri içeren veri kümesidir. İkincisi, veri kümesindeki kayıtlar on yıldan daha fazla bir zamana yayılmaktadır ve son olarak ayrıca birçok türden elektronik sağlık verilerini içermektedir [230].


Veri kümesi Boston Massachusetts'te bulunan Beth Israel Deaconess Tıp Merkezi (BIDMC)'nde 2001 ve 2012 yılları arasında var olan 53423 yoğun bakım ünitesi kayıtlarından (16 yaş ve üzeri) oluşmaktadır. Ayrıca 2001 ve 2008 yılları arası 7870 yeni doğan acil kaydı bulunmaktadır. Bu veri kümesi Massachusetts Institute of Technology (MIT) üniversitesinin Hesaplamalı Fizyoloji Laboratuvarı araştırmacıları tarafından oluşturulmuştur. Erişkin hastaların ortalama yaşı 65.8, % 55.9'u erkek ve hastane içi ölüm oranı % 11.5'dir. Acil bölümünde ortalama kalış süresi 2.1 gündür ve hastanede kalış süresinin ortalama 6.9 gündür. Her bir acil kaydı için ortalama 4579 hayati belirti değeri ölçümü ve 380 laboratuvar ölçümü mevcuttur. Veri kümesinde bulunan verilerin kategorileri Tablo 3.2. ile verilmiştir.

Tablo 3.2. MIMIC III veri kategorileri

Kategori	Açıklama
Fatura	Öncelikli olarak faturalandırma ve idari amaçlar için kaydedilen kodlanmış veriler. Mevcut Prosedürel Terminoloji, Tanı İle İlgili Grup kodları ve Uluslararası Hastalık Sınıflaması kodları.
Hasta kayıt	Demografik, giriş-çıkış kayıtları ve ölüm tarihi verileri.
Sözlükler	Çeşitli hastalık etiketlerinin karşılıkları.
Müdahaleler	Diyaliz, Manyetik Rezonans, röntgen görüntüsü çekilmesi ile ilgili bilgiler.
Laboratuvar	Kan kimyası, hematoloji, idrar analizi ve mikrobiyoloji test sonuçları.
İlaç	İlaçların verilme saatleri ve ilaç türleri.
Notlar	Hastalık gelişimi ve taburcu durumu ile ilgili yazılı notlar
Fizyolojik	Hemşire onaylı hayati belirti değerleri, yaklaşık olarak saat başı (kalp ritmi, tansiyon, nefes alma hızı vb.)
Raporlar	ECG ve diğer görüntüleme araçlarının doktor raporları

Fizyolojik veriler Philips Healthcare ve iMDsoft MetaVision izleme sistemleri ile elde edilmiştir [231]. Bu hasta izleme sistemi her acil hastasının yatağının yanında

bulunmaktadır. Her izleyici sistem, çoklu parametrik fizyolojik verileri işleyip sayısallaştırmıştır. Bu sayısallaşan sinyaller, klinik ölçümlerin (kalp atım hızı, tansiyon, oksijen satürasyonu gibi) zaman serileri sinyaline dönüşmesini sağlamıştır ve ayrıca bu izleyici sistem alarm durumlarını da kaydetmiştir. EEG gibi fizyolojik dalga sinyalleri 125 Hz de örneklenmiştir ve trend verisi dakika başı güncellenmiştir. Veriler daha sonra, genellikle birkaç acil birimini destekleyen merkezi bir veritabanı sunucusunda geçici olarak depolanmıştır. Geliştirilen özelleştirilmiş bir arşivleme aracı, merkezi veritabanı sunucularında bulunan fizyolojik verilerin kalıcı kopyalarını oluşturmuştur [230]. MIMIC III veri kümesinin genel şeması Şekil 3.5. ile gösterilmiştir.



Şekil 3.5. MIMIC III veri kümesi genel şeması

Yakın zamanda, bu veri kümesinden “Sepsis-3 in MIMIC-III” [232] adında klinik olarak kabul edilen ve en son sepsis tanımına dayanan bir sepsis veri kümesi oluşturulmuştur. Bu alt veri kümesi için MIMIC-III veri tabanından 23620 acil kaydı analiz edilmiştir. Bir dizi eleme ölçütleri uygulandıktan sonra, 11791 hastaya ait veri kümesi ortaya

çıkıştır. Veri kümesini oluşturan yazarların çalışmasında [232], Sepsis-3 kriterinin sepsis hastalığı tespitinde diğer tespit yöntemlerine göre daha başarılı sonuçlar verdiğini ve ölüm oranını azalttığını raporlamışlardır. Veri kümesindeki her hasta için son antibiyotik verildiği ve bir kültür numunesi alındığı zaman için SOFA skoru hesaplanmıştır. Daha sonra, SOFA skorundaki değişime bağlı olarak bir sepsis başlangıç zamanı tahmin edilmektedir. En erken alınan kültürün ilk zamanını alarak veya enfeksiyon şüphesi olarak antibiyotik verilme zamanını alarak, bu süreden 48 saat önce ve bu noktadan 24 saat sonra bir pencere analiz edilmiştir. SOFA değerinin bu pencerenin başlangıcı ile bitişi arasındaki puanının iki den büyük olması durumunda, bu ilk saat sepsis başlangıç zamanı (onset time) olarak belirlenmiştir. Sepsis 3 kriterine göre SOFA skorunun iki değerinden büyük olması sepsis hastalığına işarettir [232]. Bu kritere göre sepsise sahip olan hastalar ve sepsis olmayanlar veri kümesinde etiketlenmiştir. Bu örneklerin SOFA skorları her bir acil kaydına göre sepsis başlangıç zamanı için hesaplanmış ve veri kümesinde etiketlenmiştir.


SOFA skoru değeri tahmin çalışması için, öngörülen sepsis başlangıç zamanından on iki saat önce yedi farklı hayati belirtinin ölçümleri toplanmıştır. Bunlar kalp ritmi, sistolik ve diastolik kan basıncı, solunum hızı, oksijen saturasyonu, Glasgow Koma Skalası göz açma ölçütü (GCS (Glasgow Coma Scale) – eye opening) ve sıcaklıktır. Yedi farklı hayati belirtinin açıklaması sırasıyla verilmiştir:

Kalp ritmi: İnsan kalbinin ana amacı, oksijene karışmış kan ve besin maddelerini vücuda pompalamak ve karbondioksit ve diğer atıkları kandan uzaklaştırmaktır. Kirli kanın akciğerlerden dönmesi ve temiz kanın aorttan vücuda pompalanması aşamasına kalp döngüsü (cardiac cycle) denir [233]. Kalp ritmi veya diğer bir adıyla kalp döngülerinin frekansı, dakika başına atım ile ifade edilir. Kalp ritmi, vücudun ihtiyacına göre değişir ve vücudun normal durumunda değişikliklere açıktır. Kişinin büyük fiziksel ve ruhsal durum değişikliklerinde kalp ritmi de buna bağlı olarak değişebilir. Bu sebeple kalp ritmi kişinin fiziksel ve ruhsal durumunu ölçmekte kullanılan önemli hayati belirtilerden biridir. Kalp ritmi yüksek doğrulukla birçok yöntemle ölçülebilir, elektriksel, optik ve gerginlik sensörleri ile ölçümler bu yöntemlere örnektir. En çok kullanılan yöntem elektriksel olarak ölçmektir. Bu ölçüm ECG adındaki aletlerin ucundaki elektrotlarla gerçekleştirilir (Şekil 3.6.). ECG sinyalleri periyodik olduğundan kalp ritmi bu periyodik sinyallerin aralıklarının ölçülmesiyle kolaylıkla modellenilebilir [234]. Günümüzde ECG sistemi akıllı saatlere de entegre edilmiştir (Şekil 3.6.). 10 yaşından büyük bir kişinin normal kalp ritmi, dinlenirken 60 ile 100 dakika başına atım olmalıdır.



Şekil 3.6. Kalp ritmi ölçmek için kullanılan bir ECG sensörü ve akıllı saat

Sistolik ve divastolik kan basıncı: Kan basıncı, arter damarların duvarlarına karşı yapılan basıncın veya kuvvetinin ölçümüdür. Vücutta kan basıncının çok artması (hipertansiyon) veya çok azalması (hipotansiyon) vücuttaki sorunların habercisi olarak gösterilir [233]. Kan basıncı ikiye ayrılmaktadır, sistolik ve divastolik kan basıncı. Sistolik kan basıncı, her kalp attığında arter damarlarına ne kadar basınç oluştuğunu belirtir. Divastolik kan basıncı ise kalbin atımlar arası dinlenme sırasında arter damarlarına ne kadar basınç yaptığını belirtmektedir. Yetişkin insanlarda normal değerler, sistolik için 120 mmHg ve divastolik için ise 80 mmHg değeri civarında olmalıdır. Günümüzde geleneksel olarak kan basıncı sfıgmomanometre adı verilen bir aletle ölçülür. Fakat giyilebilir sensörlerin gelişmesiyle birlikte kan basıncı ölçümlerinde yüksek doğrulukla ölçümü gerçekleştiren sensör sistemleri kullanılmaya başlanmıştır [234]. Bu sensör sistemleri genellikle kapasitif gerilime duyarlı sensörleri içermektedir. Şekil 3.7. ile kan basıncını ölçen örnek giyilebilir sensörler verilmiştir.




Şekil 3.7. Kan basıncını ölçen sensörler [235].

Solunum hızı: Solunum hızı önemli bir hayati belirtidir çünkü yeterli miktarda oksijen alımı ve karbon dioksit verimi yapılamazsa, kişi ölüm riskiyle ve sakat kalma riskiyle karşı karşıya kalabilir [233]. Solunum hızı dakika alınan nefes sayısı ile ölçülür. Yetişkin bir bireyin normal solunum hızı dinlenirken dakikada 12 ile 20 nefes olmalıdır. Solunum hızını ölçmek için sensörler nefes akışına veya nefes sırasında göğsün ve karnın genişlemesine ve büzülmesine bakarak ölçüm gerçekleştirirler. Bu sensörlere örnek Şekil 3.8. ile verilmiştir.



Şekil 3.8. Solunum hızı ölçen sensör [236].

Oksijen Satürasyonu: Oksijen satürasyonu veya oksijenasyonu, kandaki oksihemoglobin konsantrasyonunun kandaki oksijen ve deoksi-hemoglobin konsantrasyonunun toplamına bölünmesiyle hesaplanır [234]. Ölçme yerine ve yöntemine bağlı olarak oksijen satürasyonu: doku oksijenasyonu, venöz oksijenasyonu ve periferik oksijenasyon (SpO_2) olarak kategorize edilebilir. Bu oksijenasyon ölçümleri arasında, SpO_2 ölçümü invazif olmaması sebebiyle en çok kullanılanıdır. Satürasyonu ölçmek için genellikle optik tabanlı sensör sistemleri kullanılır. Bu sensörler satürasyonu, iki farklı dalga boyunda çalışan iki LED'in, kulak memesi, alın veya parmak üzerinde dönüşümlü olarak parladığı bir optik ölçüm yaklaşımıyla belirler. Belirli bir zamanda, kan hacmi ve kandaki oksi-hemoglobin konsantrasyonu, doku ve deriden iletilen veya yansıtılan ışığın yoğunluğunu ile belirlenir. Eğer sinyal arteriyel damarlardan ölçülüyorsa bu ölçüme nabız oksijenasyonu denir. Oksijen satürasyonu ölçümü yapan optik tabanlı sensör Şekil 3.9. ile verilmiştir.



Şekil 3.9. Oksijen Satürasyonu ölçen optik sensör [237].


Bireyin nabız değeri ve nabız oksijenasyonu, kişinin kardiyovasküler durumunu temsil etmektedir [234]. Sağlıklı bir yetişkinde oksijen satürasyonu en az %95 olmalıdır. %80 değerinden az olması organlara düzgün oksijen iletimi yapılmadığını göstermektedir.

Glasgow Coma Scale: 1974 yılında ilk olarak ortaya çıkan koma hastaların bilincini objektif olarak ölçebilen ilk skarlama sistemidir [238]. GCS içinde motor (best motor response), ses (verbal response) ve göz açma (eye opening) alt başlıkları bulunmaktadır. Bu alt başlıklara verilen yanıtlardan elde edilen skorlar hastanın bilincini karakterize etmektedir. Bu yanıtlar tarafından oluşturulan genel tablo, hem hastalar arasında hem de zaman içinde hastaların yönetimini önemli ölçüde yönlendiren değişikliklerin karşılaştırılmasını sağlar. Üç alt başlık ayrı ayrı puanlanabilir veya toplam puan olarak eklenebilir. Hem tek tek alt başlıklar hem de toplam puan yoğun bakım ünitesinde bilinç düzeyi düşük olan hastalarda kullanılmaktadır ve GCS skarlama sistemi birkaç yoğun bakım ünitesi sınıflandırma sistemine entegre edilerek günümüzde de kullanılmaktadır [238]. Azalan skorlarla ölüm oranı artması arasında doğrusal bir ilişki bulunmaktadır. Diğer bir deyişle düşük bir skor kapalı bir bilinç ve yüksek ölüm oranı anlamına gelmektedir [239]. Günümüzde bu skarlama sistemini giyilebilir sensörlerle otomatik olarak değerlendirebilecek sistemler için patentler alınmış ve geliştirme aşamasındadır. Şekil 3.10. ile GCS skarlama sisteminde alt başlıklardaki skorların nasıl belirlendiği açıklanmıştır. Sağlık personelleri hastaya fiziksel müdahaleler ve seslenerek hastanın bilinç durumunu verdiği cevaplara göre ölçmektedirler. GCS Eye Opening ölçütü, hastanın dış müdahaleler sonucunda göz açıp kapama yoluyla tepki vermesini ölçmektedir.

Eye opening (E)
1 None
2 To pressure
3 To speech
4 Spontaneous
Verbal response (V)
1 None
2 Sounds
3 Words
4 Confused
5 Orientated
Best motor response (M)
1 None
2 Extension
3 Abnormal flexion
4 Normal flexion (withdrawal)
5 Localising
6 Obeying commands

Şekil 3.10. GCS skoru ve alt başlıkların puan dağılımı [239].

Sıcaklık: Vücut sıcaklığı, bireyin fizyolojik durumu hakkında birçok işaret sağlayabilir. Yüksek vücut sıcaklığı genellikle bir enfeksiyonun varlığını belirtmektedir. Öte yandan düşük vücut sıcaklığı, düşük kan akışı nedeniyle dolaşım şoku durumunun varlığının kanıtıdır. Bu sebeplerden dolayı vücut sıcaklığı hastalık şüphelerinde bakılan ilk hayati belirti değeridir. Vücut sıcaklığı termistör adı verilen sensörlerle ölçülmektedir. Termistör üzerindeki dirençler ısıya duyarlı değişmektedir ve bu sayede sıcaklık ölçülmektedir. Bu sensörün seçilmesinin nedeni invazif olmayan ve giyilebilir sensörlerle uyumlu olmasıdır [234]. Vücut sıcaklığının normal değeri 37° Celcius olarak kabul görmektedir. Örnek bir giyilebilir sıcaklık sensörü Şekil 3.11 ile gösterilmektedir.




Şekil 3.11. Bilekten sıcaklık ölçen termistör tabanlı örnek sensör [240].

Tez çalışması için veri kümesi hazırlanırken, herhangi bir saatlik periyot için birden fazla ölçüm varsa, değerlerin ortalaması alınmıştır. Yani on iki zaman noktasına sahip zaman serisi sinyalleri elde edilmiştir. Sepsis tahmini ve SOFA değer tahmini için veri kümesinin hazırlanmasında üç ek dâhil etme ölçütü uygulanmıştır: (1) bir sepsis başlangıç zamanı tahmin edilebilir olmalı ve (2) öngörülen sepsis başlangıç zamanından 12 saat önce yaşamsal belirtilerin her biri için en az bir ölçüm mevcut olmalı (3) sepsis bulunmayan (negatif) yani acil bölümüne kaldırılmış fakat hiç sepsis şüphesi olmayan kişileri veri kümesine dâhil

etmek için yapay bir sepsis başlangıç zamanı belirlenmiştir. Bu zaman, hastanın yoğun bakıma girdiği saatten 24 saat sonrası olarak belirlenmiştir. Bu ölçütün uygulanmasının sebebi negatif örnek sayısını arttırmak ve aynı şartlarda pozitif örneklerle karşılaştırabilmektir. Böylelikle makine öğrenmesi algoritmalarına örnekleri daha sağlıklı ayırabilme imkânı sağlanmaktadır.

Bu dâhil etme ölçütleri sonucunda 5154 acil kaydı örneği elde edilmiştir. Her birinin yedi fizyolojik ölçümü, sepsis etiketi (1404 pozitif, 3750 negatif) ve SOFA skor değeri etiketi bulunmaktadır. Bu dâhil etme ölçütleri Şekil 3.12. ile verilmiştir.



Şekil 3.12. Veri kümesine uygulanan dâhil etme ölçütleri

Veri kümesindeki her örnek için ölçümler zaman serisi haline getirildiğinde, her hasta için her bir ölçüm aynı sıklıkta alınmadığı için eksik veri sorunu ortaya çıkmaktadır. Örneğin bir hastanın durumu ağır olduğu için kan basıncı her saat ölçülmüş olabilir fakat başka bir hastanın ise dört saatte bir ölçülmüş olabilir. Bu sorun sağlık uygulamalarında sıkça karşılaşılan bir sorundur [241, 242, 243]. Ölçüm olmayan saatlerin nasıl doldurulması ile ilgili bir kaç çözüm mevcuttur. Bunlar, basit, kolay uygulanan yöntemler ve matris

faktörizasyonuna dayalı yöntemlerdir [231]. Basit yöntemlere örnek olarak var olan ölçümlerin ortalamasını almak ve medyan değerini almak verilebilir. Matris faktörizasyonuna dayalı yöntemlere örnek, eksik verileri tahmin etmek için k-eigen değerinin lineer kombinasyonunu kullanan SVDImpute [244] yöntemi ve PCA (Principal Component Analysis) algoritmasını olasılıksal bir yaklaşımla ve Expectation-Minimization yaklaşımıyla birleştirip o şekilde eksik verileri tahmin eden Probabilistic Principal Component Analysis (PPCA) yöntemi verilebilir [245]. Bu çalışmada PPCA yöntemi eksik verileri doldurmak için kullanılmıştır.

PPCA yönteminin eksik veri tahmini için seçilmesinin sebepleri, diğer yöntemlere göre hızlı ve büyük veri kümelerinde başarılı olmasından dolayıdır [246]. Ayrıca sağlık enformatiği alanında başarılı sonuçlar elde edildiği de raporlanmıştır [241, 242, 243].

PCA yöntemi, boyut azaltma, faktör analizi, öznitelik çıkarma ve kayıplı veri sıkıştırma alanlarında sıkça kullanılan bir yöntemdir. PCA, yansıtılan verinin varyansı en üst düzeye çıkacak şekilde asıl alt uzay adında alt boyutlu bir doğrusal uzay üzerine verinin belirli bir dikey yansımasıdır. PPCA, özellikle veri kümesindeki eksik değerlerle başa çıkma yeteneği olmak üzere çeşitli avantajlar sağlayan PCA 'nın maksimum olasılık ile yeniden oluşturulması olarak düşünülebilir [245].

Maksimum olasılıkla eksik veri doldurma fikri, geniş çapta kabul görmüş bir ilkeye dayanır: Bir olasılıksal fonksiyondan çıkarımlar yapılabilir ve gözlenen verilerin uç dağılımı örnekleme yoluyla tahmin edilebilir. Böylelikle eksik veriler hiç örnekleme yapılmamış rasgele değişkenler olarak kabul edilir. Eğer olasılık fonksiyonu örneklenmiş verilerden doğru bir şekilde tahmin edilebilirse, eksik veriler elde edilen olasılık fonksiyonuna göre tahmin edilebilir [247]. Başka bir deyişle, gözlemlenen veri olasılık fonksiyonu, eksik veri mekanizmasını görmezden gelir.

4. YÖNTEMLER

4.1. Yeni Öznitelik Çıkartma Yöntemleri

4.1.1. Zaman ve frekans öznitelikleri

Tez çalışmasının PH bölümünde birkaç sebepten dolayı regresyon modelini doğrudan GRF sinyalleri ile beslemek uygun değildir. İlk olarak birçok regresyon modeli girdinin uzunluğunun eşit olmasını gerektirir ki bu durum GRF sinyalleri için söz konusu değildir. İkincisi, sinyaller aynı uzunlukta olsalar bile aynı zaman ölçeğinde bulunmamaktadır. Bu yüzden yürüyüş örüntülerinde her zaman yerel benzerlikleri yakalamak mümkün değildir. Üçüncüsü, zamansal gözlemler, regresyon modelinin tahmin etmesini istendiği PH semptom değerleri açısından GRF'nin davranışını yansıtmayabilir. Bu nedenle, bu tür zaman serisi sinyallerinin analizinde yaygın yapılan bir uygulama: ham sinyalden sabit sayıda temsili öznitelik elde etmek ve giriş sinyalini, ham ölçümler yerine bu öznitelik değerlerini içeren bir vektörle temsil etmektir. Sepsis hastalığı tahmininde hayati belirti sinyallerinden de zaman serisi öznitelikleri çıkarılmıştır.

Tez çalışmasında Parkinson hastalığı izleme regresyon modelinde yürüme sinyallerini temsil etmek için iki tip öznitelik kümesi kullanıldı: zaman ve frekans uzayı öznitelikleri [248]. On altı zaman uzayı özniteliği çıkarıldı: ortalama, medyan, minimum değer ve endeksi, maksimum değer ve endeksi, aralık, kök ortalama karesi (Root Mean Square (RMS)), çeyrek arası aralık (Inter Quartile Range (IQR)), ortalama mutlak sapma (Mean Absolute Deviation(MAD)), çarpıklık (Skewness), basıklık (kurtosis), entropi, enerji, güç ve harmonik ortalama. Frekans uzayındaki öznitelikleri çıkarmak için sinyale Fast Fourier Dönüşümü (FFT) uygulanmıştır. Daha sonra, yedi frekans uzayı öznitelikleri çıkarıldı: ortalama, maksimum değer, minimum değer, normalleştirilmiş değer, enerji, faz ve güç.

Aynı şekilde Sepsis ve SOFA değeri tahmini için zaman serisi hayati belirti sinyallerinden zaman uzayı öznitelikleri çıkarılmıştır. Bunlar; ortalama, medyan, varyans, entropi, kök ortalama karesi, çeyrek arası aralık, ortalama mutlak sapma ve eşit aralıklı beş birikimli olasılık için aralıklardır (quantiles for five evenly spaced cumulative probabilities) [249].

$\bar{X}$ olarak gösterilen ortalama ölçütü düşük bir maliyetle hesaplanabilir ve minimum bellek kapasitesi gerektirir. Ortalama, aşağıdaki denklemde (4.1) gösterildiği gibi değerlerin

toplamının değerlerin sayısına bölünmesiyle bulunur. Birçok çalışmada ortalama ölçütü; sinyallerden anlamlı bilgi çıkarmak için doğrudan ya da dolaylı olarak kullanılmıştır [250].

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n x_i \quad (4.1)$$

x_i inci örneği ve n toplam örnek sayısını göstermektedir.

Medyan, veri örneklerinin üst ve alt yarısını ayıran sayıdır. Sadeliğine rağmen, aktivite ve insan/yürüyüş takibi gibi alanlarda kullanılmıştır [29]. Medyan özneliği, aşağıdaki formülde (4.2) görülebilen sıralı bir indeksin medyan ögesi olarak da adlandırılabilir:

$$i = \frac{(n+1)}{2} \quad (4.2)$$

Burada i medyan değer indeksini göstermektedir.

Minimum ve maksimum değerler bir sinyal segmentinin en küçüğü ve en büyük değeri olarak ifade edilebilir.

Minimum değer ve maksimum değer endeksleri, sinyal bileşeninin minimum / maksimum değerde olduğu yerlerdir. Sınıfa bağlı olarak, sinyalin minimum / maksimum değerine eriştiği nokta tekrarlanabilir. Bu nedenle her sinyale tekillik katar.

Aralık, bir sinyal bölgesinin en düşük ve en yüksek değerleri arasındaki farktır. Bu fark, sinyal tanınması problemlerinde tercih edilir, çünkü sinyalin dalgalanması ile ilgili bizi bilgilendirir. Metriği açıklayan ifade Eşitlik 4.3 ile verilmiştir:

$$Aralık(X) = \max(X) - \min(X) \quad (4.3)$$

Aralık, zaman içindeki ortalama değişimi göstermek için sıkça kullanılır. Bu öznelik literatürde tek bir bölümdeki veya tüm sinyaldeki değişiklikleri yakalamak için kullanılmıştır [251].

N ayrık değerler dizisini temsil eden bir sinyal olmak üzere x_j 'nin kök ortalama karesi (RMS) aşağıdaki denklem kullanılarak elde edilir ve önemli bilgilerinin çıkarılması için yararlı olabilir [248, 252]. Kök ortalama karesi eşitliği Eşitlik 4.4 ile gösterilmiştir.

$$RMS(x) = \sqrt{\frac{\sum_{j=1}^n x_j^2}{N}} \quad (4.4)$$

Aykırı değerler, bir veri kümesinde varolduğunda, genellikle çeyrekler arası aralık (IQR) olarak adlandırılan değişkenlik, birinci ve üçüncü çeyrekler arasındaki fark olarak tanımlanır [251]. IQR, aşağıdaki denklemde gösterildiği gibi, üçüncü çeyreğin (Q1 olarak

gösterilen) medyanının birinci çeyreğin medyanından (Q3 olarak gösterilir) çıkarılarak hesaplanır (4.5):

$$IQR = median(Q3) - median(Q1) \quad (4.5)$$

Bir veri kümesinin ortalama mutlak sapması (MAD), her veri noktası ile ortalama değer arasındaki ortalama uzaklıktır. Ortalama mutlak sapma, veri kümesindeki değerlerin, bir veri kümesinde nasıl dağıldığını anlamlandırılmasında yardımcı olan varyasyonları tanımlamanın bir yoludur [253]. Eşitlik 4.6 ile gösterildiği gibi hesaplanabilir.

$$MAD(x) = \frac{\sum_{i=1}^n |x_i - \bar{X}|}{n} \quad (4.6)$$

Çarpıklık ve basıklık, verilerin normal dağılım gösterip göstermediğini belirtir. Çarpıklık, yatay eksenle simetrik eksiklik olarak tanımlanabilir [254]. Denklem aşağıda (4.7) gösterilmiştir.

$$\text{Çarpıklık}(x) = \frac{1}{\sigma^3} \left[\frac{1}{N} \sum_{j=1}^N (x_i - \bar{X})^3 \right] \quad (4.7)$$

Basıklık normal dağılım eğrisinin ne kadar dik veya düz olduğunu gösterir [254]. Denklem aşağıda gösterildiği gibi hesaplanır (4.8):

$$\text{Basıklık}(x) = \frac{1}{\sigma^4} \left[\frac{1}{N} \sum_{j=1}^N (x_i - \bar{X})^4 \right] \quad (4.8)$$

N, veri sayısını temsil eder, $\bar{X}$, sinyalin ortalamasını temsil eder ve σ standart sapmadır.

Entropi, benzer enerji değerlerine sahip olan, ancak farklı modellere karşılık gelen sinyalleri ayırt etmeyi sağlayabilecek bir özneliktir [255]. Entropi hesaplaması aşağıdaki denklemde gösterilmiştir (4.9). Burada n, sinyal örneklerinin sayısını temsil eder ve x, sinyali temsil eder.

$$\text{Entropi}(x) = \sum_{i=1}^n \frac{x}{\sqrt{\sum_{i=1}^n x^2}} \ln \left(\frac{x}{\sum_{i=1}^n x^2} \right) \quad (4.9)$$

Sinyalin enerjisi, aşağıdaki denklemde gösterildiği gibi sinyalin uzunluğu ile normalize edilen spektral katsayıların kare toplamı olarak hesaplanabilir. Enerji literatürde tekrarlanan veriler üzerinde daha etkili olduğu için sıkça kullanılır [256]. Denklem 4.10 ile verilmiştir.

$$Enerji(x) = \int_{-\infty}^{\infty} |x^2| dt \quad (4.10)$$

Güç, birim zamanda tüketilen enerji miktarını temsil eder [250]. N, toplam örnek sayısını gösterir ve t zamanı temsil eder. Denklem 4.11 eşitliğinde ifade edilmiştir.

$$Güç(x) = \lim_{n \rightarrow \infty} \left(\frac{1}{2n} \right) \int_{-n}^n |x(t)|^2 dt \quad (4.11)$$

Harmonik ortalama, diğerlerine göre çok yüksek değerlere sahip olan bir sinyaldeki unsurların ortalama üzerindeki etkisini azaltmak için kullanılır. Bu değerler sıklıkla özel bir durumda ortaya çıktıklarından, etkilerinin azaltılması sinyalin normal seyrinin görülmesine yardımcı olur [257]. Aşağıda verilen denklemde (4.12) N toplam sinyal sayısını gösterir, d_j her sinyal değerini temsil eder.

$$Harmonik\ Ortalama = \frac{N}{\sum_{j=1}^N \frac{1}{d_j}} \quad (4.12)$$

Faz, bir sinyalin iç organizasyonu hakkında bilgi içerir [252]. Bu bilgi, sinyalin belirli bir eşiğin üstünde veya altında olup olmadığı ve hangi frekansın mevcut olduğu zaman detaylarını içerir [258].

4.1.2. Yerel ikili öznitelikler (Local Binary Patterns)

Bu yöntem ilk olarak imgelerde yer alan desenlerin temsil edilmesi ve özniteliklerinin çıkarılmasında kullanılmıştır [259]. Desen ve imgelerin temsilinde başarılı sonuçlar ürettiği için yöntem daha sonraki yıllarda birçok uygulama alanında kullanılmaya başlanmıştır [260] [261]. Yerel ikili öznitelikler (Local Binary Patterns(LBP)) yönteminin yaygın olarak kullanılmasının nedenleri; gri seviyeli değişimlere karşı dirençli olması ve hesaplama bakımından verimli bir şekilde çalışmasıdır [259].

Yöntem, imge üzerinde bir maske gezdirerek maskenin ortasında bulunan merkez pikselin komşuluğundaki piksellerin değerlerine bakılarak merkez piksele yeni bir değer atamasını gerçekleştirir. Merkezdeki piksel eşik değeri seçilerek ve komşuluktaki bütün değerlere bakılarak bir ikili kod oluşturulur. Komşuluk değeri eşik değerden büyük veya eşit olanlar için 1, küçük olanlar için 0 şeklinde ikili kod oluşturulmuş olur. Daha sonra bu ikili kod onluk tabana çevrilerek merkez pikselin yeni değeri imgeye yazılır. i nci piksel için t_i değeri, P_c merkez ve P_i komşu pikseller arasındaki fark olarak temsil edilmektedir [262] (4.13).

$$t_i = P_i - P_c \quad (4.13)$$


Eşik değeri hesaplanması aşağıdaki fonksiyon ile ifade edilir (4.14):

$$f_i(t_i) = \begin{cases} 1, & t_i \geq 0 \\ 0, & t_i < 0 \end{cases} \quad (4.14)$$

Son olarak merkez noktanın LBP değerinin bulunması 4.15 numaralı eşitlikle gösterilmektedir:

$$LBP(j) = \sum_{i=1}^{j-1} f_i(t_i) * 2^i \quad (4.15)$$

Şekil 4.1. ile ikili kod üretilmesi süreci gösterilmektedir. 3x3 boyutundaki maske için eşik değeri olan merkez piksel 54 olarak seçilmiştir. İkili kod üretimi saat yönünde veya saatin tersi yönünde olabilir. Komşuluğun büyüklüğüne göre ikili kod büyüklüğü değişebilir.



Şekil 4.1. İkili kod üretilme süreci [14]


Maske bütün imgeyi dolaşarak piksellerin değerlerini güncelledikten sonra imgenin histogramı hesaplanır. Bu histogramda her bir piksel değeri için bin ataması yapılır. LBP yönteminde bir imge artık bu histogram değerleri tarafından temsil edilmektedir. Histogram yapısının kullanılmasının amacı desen yapısı bulunurken yapısal yaklaşımın yanında istatistiksel yaklaşımın da kullanılmak istenilmesidir [259].

Histogram bir sayılar dizisinden oluşur ve bir verinin içerdiği değerlerin frekans aralığını temsil eder. Bu dizideki her bir eleman (bin), veride aynı değere sahip olan elemanların sayısını göstermektedir. Histogram ile verinin iki önemli bilgisini ortaya çıkarabiliriz. İlki verinin dağılımının nasıl bir dağılım olduğu bilgisi, ikincisi ise bu dağılımın istatistiksel bilgileri [14]. Histogram yöntemi imge işlemede imgeyi iyileştirmek için kullanılmasının dışında ayrıca istatistiksel olarak bilgi verdiği için bölütleme, sınıflandırma gibi birçok alanda da kullanılmaktadır.

$[0, L-1]$ gri seviye aralığına sahip bir imgenin histogramı ayırık bir fonksiyondur ve fonksiyon Eşitlik 4.16 ifade edildiği gibi gösterilir.

$$h(r_k) = n_k \quad (4.16)$$

Burada r_k k'ncı gri seviye değeri, n_k ise r_k gri seviyesine sahip piksellerin sayısını gösterir. Örnek bir imgenin histogramının hesaplanması Şekil 4.2. ile gösterilmiştir. Burada histogramın x eksenini piksellerin gri seviye değerlerini göstermektedir, y eksenini ise piksellerin sayısını temsil etmektedir.



Şekil 4.2. Örnek bir imgenin histogramının hesaplanması

Tez çalışmasında sinyal verisinden öznelik çıkarmak için LBP yönteminin bir çeşidi olan 1 boyutlu (1-D) LBP yöntemi kullanılmıştır [14][263]. 1 boyutlu LBP yönteminde sinyalde 1 boyut üzerinde bir komşuluk maskesi belirlenir daha sonra merkez nokta değeri LBP yöntemindeki gibi ikili bir kod şeklinde hesaplanır. Burada ikili kod oluştururken imge alanında kullanılan LBP yönteminden farkı; merkez noktanın önündeki ve arkasındaki noktaların komşu noktalar olarak varsayılmasıdır. 1-D LBP yönteminin işleyişinin formülasyonu Eşitlik 4.17 ile verilmiştir [264]. i nci sinyal noktası için t_i değeri, P_c merkez ve P_i noktalarının arasındaki fark olarak temsil edilmektedir. N sayısı, komşuluğa dâhil edilecek tüm noktaların sayısını göstermektedir.

$$t_i = P_i - P_c \quad (4.17)$$


Eşik değer hesaplanması aşağıdaki fonksiyon ile ifade edilir (4.18):

$$f_i(t_i) = \begin{cases} 1, & t_i \geq 0 \\ 0, & t_i < 0 \end{cases} \quad (4.18)$$

Son olarak merkez noktanın LBP değerin bulunması Eşitlik 4.19 ile gösterilmektedir:

$$LBP(j) = \sum_{i=1}^{\left(\frac{[N+1]}{2}-1\right)} f_i(t_i) * 2^i + \sum_{i=\left(\frac{[N+1]}{2}+1\right)}^N f_i(t_i) * 2^{i-1} \quad (4.19)$$

1-boyutlu LBP yönteminde ikili kod oluşturma Şekil 4.3. ile anlatılmaktadır. Merkezdeki değerden 4 öncesi ve 4 sonrası komşuluk için seçilmiştir. Bu şekilde merkez değer 25 seçilerek ikili kod oluşturulmuştur. Oluşturulan ikili kod ondalık değere çevrilerek merkez değere yazılır. Bu işlem bütün sinyal boyunca bir boyutta devam etmektedir. Daha sonra LBP yönteminde bahsedildiği gibi histogram hesaplanır. Hesaplanan histogram sayesinde sinyal artık LBP değerleriyle temsil edilmiş olur.



Şekil 4.3. 1 boyutta LBP yönteminin uygulanması [14]

4.2. Yerel Ağırlıklandırılmalı Rasgele Orman (LWRF)

Global öğrenme algoritmalarında olduğu gibi, RF regresyon algoritmasının bilinen bir dezavantajı, parametrelerin, her bir veri örneğini öğrenme aşamasında eşit olarak dikkate alarak, tüm eğitim verilerini göz önüne alarak ayarlanmasıdır. Bu, tüm durumlar için yeterli doğru tahminini sağlayamayan zayıf parametrelere neden olabilir. Bu durum, özellikle çıkış değerlerini temsil etmede yardımcı olan faktörlerin dışındaki bazı faktörlerde yüksek değişkenlik gösterdiğinde, özellikle sorun oluşturabilir. Bu değişkenlerin etkilerini en aza indirmek için bir çözüm, tüm örnekler için bir küresel model uydurmak yerine, sorgu örneklerinin komşu verilerine dayanarak yerel modellerini oluşturmaktır. Bu, sorgu örneğine yanıt olarak eğitim verilerindeki her bir numunenin ağırlıklandırılmasını ve tahmin için yerel bir modelin öğrenilmesini gerektirir. Giyilebilir sensörlerle hastalık izleme probleminde bu ağırlıklandırma şeması, semptomları tahmin ederken söz konusu hastaya benzer bireylere daha fazla önem verilmesini ifade etmektedir. Daha az benzer kişilere daha düşük ağırlıklar atamak, bu örneklerin etkisini indirmeye, dolayısıyla da hasta değişkenliğinin etkilerini azaltmaya yardımcı olacaktır. Bahsedilen problemler için, bu yerel öğrenme şeması RF regresyonuna adapte edilmiş ve bu melez model Yerel Ağırlıklandırılmalı Rasgele Ormanı (Locally weighting Random Forest (LWRF)) olarak adlandırılmıştır.

Global yöntemlerin önemli bir dezavantajı iyi bir çözüm elde etmek için iyi bir parametre ayarının yapılması gerektiğidir. Ek olarak, bazen hesaplama maliyetleri belirli problemler için çok yüksek olabilir, örneğin, tahmin görevi az miktarda zaman içinde birçok tahmin gerektiriyorsa, model kademeli olarak büyüyecektir. Global yöntemlere bir alternatif Yerel ağırlıklandırılmalı öğrenme (Locally weighted learning (Lwl)) 'dir. Lwl parametrik olmayan bir yöntemdir [265]. Yalnızca veri kümesinin alt kümelerini kullanan yerel fonksiyonları kullanır. Tüm fonksiyonel alan için global bir model oluşturmak yerine, temel fikir, sorgu noktasına en yakın olana dayalı yerel bir model oluşturmaktır. Her örnek noktanın bir ağırlık faktörü vardır ve bu ağırlıklar hedef değerin tahminini etkiler. Genel olarak, sorgu noktasının yakınındaki numune noktaları uzak noktalara göre daha büyük ağırlık değerlerine sahiptir [266].

LWRF yönteminde, her numune RF yönteminin her iki fazında, yani her bir karar ağacında bootstrap örnekleme ve bölmelerin hesaplanmasında ağırlıklandırılır. Yerel ağırlıklı öğrenme için Eşitlik 4.20 ile belirtilen bir maliyet fonksiyonu tanımlanmıştır:

$$J = \sum_{i=1}^N w_i(X_q)(y_i - f(X_q, \theta_q)) \quad (4.20)$$


X_q , sorgu örneğidir, y_i , semptomun tam değeridir, N , eğitim verilerindeki örnek sayısıdır, $f(.)$ regresyon fonksiyonudur, θ_q sorguya özgü regresyon parametresidir ve w_i , mevcut tahmin için eğitim verilerindeki her bir örneğe verilen ağırlıktır. Ağırlıklar, sorgu ile eğitim örnekleri arasındaki Öklid mesafesi olarak tanımlanır. RF için θ_q , belirli bir sorgu için bootstrap örneklerinden oluşturulduğunda mevcut ağırlıkları dikkate alan her bir karar ağacını ifade eder.

4.3. Derin Öğrenme Hibrit Yapıları

4.3.1. Sinyal girdisi dönüştürme işlemi


Tez çalışması için oluşturulan derin öğrenme hibrit yapılarında girdi olarak verilen sinyalleri CNN derin öğrenmesi yapısıyla işleyip öznitelik çıkarmak için verilere 2 boyuta (2-D) dönüştürme işlemi uygulanmaktadır. Bu işlemin amacı kullanılan CNN mimarisinin 2 boyutlu girdi kabul etmesi ve 2 boyuta dönüştürülerek sensörler veya hayati belirti kategorileri arasındaki ilişkiyi ortaya çalışmaktır. Sepsis hastalığı ve SOFA skor tahmini için 1 boyutlu hayati belirti sinyalleri dönüştürme işlemine girdi olarak verilmiştir. Parkinson Hastalığı tahmininde ise 1 boyutlu GRF sinyalleri dönüştürme işleminde girdi olarak kullanılmıştır.

MIMIC III veri kümesinden çıkartıldıktan sonra her bir hayati belirti sinyali 1 boyuta sahiptir. Veri kümesinde her bir örneğin uzunluğu 84'tür (12 zaman noktası x 7 hayati belirti kategorisi). Önerilen hibrit modellerde, her örnek, 1 boyutu, 2 boyuta dönüştüren bir ön işlem aşamasından geçmektedir. Bu örnekler 12 saatlik veriyi temsil eden 12 genişliğine ve hayati işaret kategorisi sayısını temsil eden 7 yüksekliğe sahiptir. Dönüştürme işlemi Şekil 4.4. ile gösterilmektedir.



Şekil 4.4. Hayati belirti sinyallerinin 2 boyuta çevrilmesi.

Physionet veri kümesinden çıkartılan GRF sinyalleri makine ve derin öğrenme algoritmalarından işlenebilmesi için her bir GRF sensöründen zaman ve frekans öznitelikleri çıkartılmıştır. Bu öznitelikler 1 boyuta sahiptir. Veri kümesinde her bir örneğin uzunluğu 368'tür (16 zaman noktası x 23 zaman ve frekans öznitelikleri). Önerilen hibrit modellerde, her örnek, 1 boyutu, 2 boyuta dönüştüren bir ön işlem aşamasından geçmektedir. Bu örnekler öznitelik sayısı olan 23 genişliğe ve sensör sayısını temsil eden 16 yüksekliğe sahiptir. Dönüştürme işlemi Şekil 4.5. ile gösterilmektedir.



Şekil 4.5. GRF sensörlerinden çıkartılan özniteliklerin 2 boyuta çevrilmesi.


Sepsis hastalığı için zaman öznitelikleri de aynı işleme tabii tutulmuştur. Ayrıca, Hem GRF hem de hayati belirti sinyallerinden LBP öznitelikleri çıkarılmıştır. Çıkarılan LBP öznitelikleri de aynı dönüştürme işlemi uygulanmıştır. Parkinson hastalığı için 2 boyutta genişlik ve yükseklik sırasıyla, LBP öznitelik uzunluğu ve sensör sayısıdır. Sepsis hastalığı için 2 boyutta genişlik ve yükseklik sırasıyla, LBP öznitelik uzunluğu ve hayati belirti sayısıdır.

4.3.2. CNN ve Bi-LSTM derin öğrenme hibrit yapısı

Bu Hibrit yapıdaki modelde, veriler arasındaki ilişkileri ortaya çıkarmak için CNN ve Bi-LSTM mimarileri birleştirilerek kullanılmıştır. Amaç, CNN katmanlarıyla yerel öznitelikleri yakalamak ve zamansal ilişkileri haritalandırmak için onları Bi-LSTM 'ye beslemektir.

2 boyuta dönüştürme süreçlerinden sonra, tüm örnekler bu hibrit mimariye girdi olarak verilmeye hazır hale gelmektedir.

Önerilen mimari, bir giriş katmanı, dört evrişim katmanı ve bu katmanlardan sonra bir Bi-LSTM katmanı, tam bağlaşımlı katman ve bir regresyon katmanından oluşmaktadır. Önerilen derin öğrenme mimarisi Şekil 4.6. ile gösterilmektedir. Evrişim katmanları 1x6 ve 7x1 boyutlarında 40 filtreye sahiptir. Farklı filtre boyutlarının temel nedeni hem yatayda hem de dikeyde yerel öznitelikleri yakalamaktır. Dikey öznitelikler, hayati belirtiler ve sensörler arasındaki ilişkiyi ve yatay öznitelikler ise sepsis için zaman noktaları, Parkinson için ise zaman ve frekans öznitelikleri arasındaki ilişkiyi temsil eder. Bu yüzden, bu yerel özniteliklerin birleştirilmesi, sinyallerinin daha iyi temsil edilmesine ve anlamlandırılmasına olanak sağlayacaktır. Her evrişimsel katmandan sonra normalizasyon katmanını ReLU ve maksimum havuzlama katmanı izler. Seyreltme katmanı, tahmin hatasını azaltmak için kullanılır. 128 gizli üniteye sahip Bi-LSTM katmanı CNN yapısından çıkan yerel özniteliklerle beslenmektedir. Tam bağlaşımlı katman, SOFA skorlarını hayati belirtilerden ve UPDRS/H&Y değerlerini zaman-frekans özniteliklerden tahmin etmek için öğrenilen öznitelikleri bir araya getirir. Regresyon katmanı ise SOFA skoru ve UPDRS/H&Y değer tahmini için yarı-ortalama-kare-hata kaybını (half-mean-squared-error) hesaplar.




Şekil 4.6. Önerilen CNN ve Bi-LSTM derin öğrenme modelin genel mimarisi

4.3.3. CNN ve RF / LWRF derin öğrenme hibrit yapısı

Bu hibrit mimari yapısında CNN derin öğrenme mimarisi ile çıkartılan öznitelikler RF veya LWRF makine öğrenmesi yöntemlerine girdi olarak verilmiştir. Bu hibrit yapının oluşturulmasının amacı, CNN kullanarak hayati işaretler hakkında değerli öznitelikler ortaya çıkartılıp, verileri temsil eden bu değerli özniteliklerle karar ağaçları oluşturularak rastgele ağaç koleksiyonlarıyla bu özniteliklerin işlenmesidir. 2 boyuta dönüştürme süreçlerinden sonra, tüm örnekler bu hibrit mimariye girdi olarak vermeye hazır hale gelmektedir.

Önerilen mimari, bir giriş katmanı, dört evrişim katmanı ve bu katmanlardan çıkarılan derin özniteliklerin girdi olarak verildiği RF veya LWRF yönteminden oluşmaktadır. Önerilen derin öğrenme mimarisi Şekil 4.7. 'de görülmektedir. Şekil 4.7. ile RF algoritması için mimari gösterilmiştir. CNN ve LWRF hibrit yapısında ise tek fark son algoritmanın LWRF olmasıdır. Evrişim katmanları 1x6 ve 7x1 boyutlarında 40 filtreye sahiptir. Farklı filtre boyutlarının temel nedeni hem yatayda hem de dikeyde yerel öznitelikleri yakalamaktır. Dikey öznitelikler, hayati belirtiler ve sensörler arasındaki ilişkiyi ve yatay öznitelikler ise sepsis için zaman noktaları, Parkinson için ise zaman ve frekans öznitelikleri arasındaki ilişkiyi temsil eder. Bu yüzden, bu yerel özniteliklerin birleştirilmesi, sinyallerinin daha iyi temsil edilmesine ve anlamlandırılmasına olanak sağlayacaktır. Her evrişim katmanından sonra normalizasyon katmanını ReLU ve maksimum havuzlama katmanı izler. Son evrişim bloğundan sonra öğrenilen öznitelikler rasgele ağaçlar oluşturmak için RF ve LWRF algoritmalarına girdi olarak verilir.



Şekil 4.7. Önerilen CNN ve RF/LWRF derin öğrenme modelin genel mimarisi

5. SONUÇLAR

5.1. Değerlendirme Ölçütleri

Tüm regresyon ve sınıflandırma yöntemlerini değerlendirmek için on kat çapraz doğrulama kurulumu kullanılmıştır. Çapraz doğrulama için, veri kümesi on eşit parçaya bölünür. Bu parçaların her biri, regresyon veya sınıflandırma yöntemiyle test için ayrılmıştır ve kalan dokuz bölüm, aynı regresyon veya sınıflandırma yöntemiyle eğitim için kullanılmaktadır. Süreç her bir bölüm test olarak kullanılabileceği kadar devam eder.

H&Y, UPDRS ve SOFA skoru tahmin performanslarını değerlendirmek için üç farklı metrik kullanılmıştır: korelasyon katsayısı (Correlation Coefficient (CC)), ortalama mutlak hata (Mean Absolute Error (MAE)) ve kök ortalama karesi hatası (Root Mean Square (RMSE)). Sonuç olarak düşük hata oranları (MAE ve RMSE) tercih edilirken, tahmin edilen değer ve gerçek değerleri arasında yüksek korelasyon (CC) olması beklenmektedir. n örnek sayısını gösterdiği varsayılırsa, p_i ve a_i tahmin edilen ve gerçek değerlerdir, $\bar{p}$ ve $\bar{a}$ bu değerlerin aritmetik ortalamasıdır. CC tahmin edilen ve gerçek değerler arasındaki korelasyonu ölçer. -1 ile 1 aralığında değerler alabilir. 1 mükemmel pozitif korelasyon, -1 mükemmel negatif korelasyon ve 0 ise korelasyon yok anlamına gelmektedir. CC formülü Eşitlik 5.1 ile gösterilmektedir:

$$CC = \frac{S_{PA}}{\sqrt{S_P S_A}} \quad (5.1)$$

$$S_{PA} = \frac{\sum_i (p_i - \bar{p})(a_i - \bar{a})}{n-1}, S_P = \frac{\sum_i (p_i - \bar{p})^2}{n-1}, \text{ ve } S_A = \frac{\sum_i (a_i - \bar{a})^2}{n-1}.$$

MAE, tekil hataların büyüklüğünü onların işaretini dikkate almadan hesaplar (5.2).

$$MAE = \frac{|p_1 - a_1| + \dots + |p_n - a_n|}{n} \quad (5.2)$$

RMSE, regresyon analizi için başlıca ve en yaygın kullanılan değerlendirme ölçütüdür. Karekök, tahmin edilen değerlerin kendisiyle aynı boyutları vermek için alınır. RMSE aşağıdaki forma sahiptir (5.3):

$$RMSE = \sqrt{\frac{(|p_1 - a_1|)^2 + \dots + (|p_n - a_n|)^2}{n}} \quad (5.3)$$

Bu çalışmada, yöntemlerin hastalığa sahip ve sağlıklı bireyleri tahmin etme (sınıflandırma) performansını ölçmek için (Area Under Curve (AUC)) , Doğruluk, Duyarlılık ve Özgüllük metrikleri kullanılmıştır. GP, GN, YP ve YN kısaltmaları sırasıyla gerçek pozitif, gerçek negatif, yanlış pozitif ve yanlış negatif ifadelerinin kısaltmasıdır. AUC hesaplaması için, Gerçek pozitif oran, (True Positive Rate (TPR)), (aynı zamanda duyarlılık (Sensitivity) olarak da bilinir) ve yanlış pozitif oran (False Positive Rate (FPR)) (1-özgüllük (Specificity)) eğrisi çizilir. Daha sonra, eğri altındaki alan (Area Under Curve (AUC)) hesaplanarak, iki tanı grubu (hasta / sağlıklı) arasında ayırım yapılabilir.

Bütün ifadeler aşağıda açıklanmıştır.

GP: Doğru bir şekilde hasta olarak tanımlanan hasta örnek sayısı.

GN: hasta olmayıp sağlıklı olarak doğru tanımlanan örnek sayısı.

YP: hasta olmayıp hasta olarak teşhis edilen örnek sayısı.

YN: hasta olup sağlıklı olarak teşhis edilen örnek sayısı

Doğruluk, Duyarlılık ve Özgüllük ölçütlerinin formülleri Eşitlik 5.4 ile verilmiştir:

$$Duyarlılık = \frac{TP}{TP+FN}, \text{ Özgüllük} = \frac{TN}{TN+FP}, \text{ Doğruluk} = \frac{GP+GN}{P+N} \quad (5.4)$$

Maksimum AUC skoru 1'dir, yani sınıflandırıcı örnekleri mükemmel şekilde ayırmıştır. Bu nedenle, daha büyük AUC skoru daha iyi sınıflandırıcı performansını demektir.

Derin öğrenme modelinin hiper-parametre tahmini, deneme yanılma yaklaşımı ile yapıldı. Derin öğrenme parametreleri, tahmin hatası değerine göre optimize edildi. Başlangıçta bir kaba değer aralığıyla başlanıp, tahmin performansı ölçüldü ve ardından tüm ölçütlerde en iyi performansı elde etmek için parametreler ayarlanarak devam edildi. Bu yaklaşımda evrişim katmanında 1x2 ve 1x3 gibi küçük boyutlu filtreler denenmiş fakat dikey ve yatay düzlemde bilgileri tam olarak yakalanamadığı görülmüştür. Bu sebeple filtre boyutu 1x6 ve 7x1 seçilmiştir. Havuzlama katmanında ise ortalama ve maksimum havuzlama katmanları denenmiş ve maksimum havuzlama katmanının daha iyi performans gösterdiği gözlemlenmiştir. Bu sürece dayanarak, derin öğrenme eğitimi sırasında epoch sayısı 50'ye ayarlanmış ve Adam (adaptive moment estimation) optimizasyon algoritması kullanılmıştır.

Normalizasyon katmanı için kanal bazında yerel cevap normalizasyon (Channel-wise local response normalization) katmanı seçilmiştir. Bi-LSTM katmanında ağırlıklara ilk değeri vermek için he optimizasyon algoritması kullanılmıştır. Aktivasyon fonksiyonu softsign fonksiyonu olarak seçildi. Sınıflandırma için ise modeldeki regresyon katmanı, softmax katmanı ile değiştirildi.

5.2. DeneySEL SonuÇlar

5.2.1. Parkinson hastalığı

Bu bölümde Parkinson hastalığı şiddet seviyesi değerinin GRF sensörleriyle tahmini üzerine deneyler gerçekleştirmiştir. UPDRS ve H&Y olmak üzere iki farklı şiddet seviyesi için deneyler yapılmıştır. Deneyler sırasında 16 GRF sensörü üzerinden 1 boyutlu LBP, zaman ve frekans öznitelikleri çıkartılmış ve bu farklı öznitelik çıkarma şemaları karşılaştırılmıştır. Değer tahmini için regresyon modelleri kullanılmıştır. Bu modeller tezin 1.3. bölümünde anlatılan k-NN, Rastgele Orman (RF), Ayırıklaştırma ile Regresyon (RBD), Yerel Ağırlıklandırılmış Rastgele Orman (LWRF), Destek Vektör Regresyon (SVR), J48 Karar Ağacı (J48), Lineer Regresyon (LIR), Evrişimsel Sinir Ağı (CNN), Çift Yönlü Uzun Kısa Süreli Hafıza (Bi-LSTM), CNN ve Bi-LSTM hibrit model (CNN + Bi-LSTM), CNN ve RF hibrit model yapısı (CNN + RF) ve son olarak CNN ve LWRF hibrit model yapısıdır (CNN + LWRF).

Regresyon ve sınıflandırma problemleri için farklı öznitelik şemaları kullanılmıştır. Öznitelik çıkarmak için kullanılan LBP yönteminin tek bir parametresi vardır o da ikili kod üretilirken bakılan komşu sinyal noktalarının sayısıdır. Deneylerde bu parametreye pencere boyutu adı verilmiştir. Örneğin pencere boyutunun 4 olması demek, ikili kod üretilirken temel alınan noktanın 2 öncesi ve 2 sonrasındaki noktalara bakılması anlamına gelmektedir. Farklı makine öğrenmesi yöntemleri ve LBP yönteminin farklı pencere boyutu parametrelerine göre Parkinson şiddet tahmini için CC / MAE / RMSE cinsinden ölçülen performanslar Tablo 5.1. ve Tablo 5.2. ile verilmiştir. Bu tablolardan da görüldüğü üzere en yüksek CC ve en düşük MAE / RMSE değeri pencere boyutu 2 seçildiğinde elde edilmiştir. Diğer öznitelik şemasıyla karşılaştırmalar yapılırken UPDRS ve H&Y tahmini için LBP yönteminin parametresi olarak pencere boyutu 2 seçilmiştir.

Tablo 5.1. LBP yönteminde pencere boyutuna göre UPDRS değeri regresyon sonuçları

Regresyon Modeli	Pencere Boyutu 2			Pencere Boyutu 4			Pencere Boyutu 6		
	CC	MAE	RMSE	CC	MAE	RMSE	CC	MAE	RMSE
RF	0.674	5.862	7.709	0.651	6.264	8.001	0.674	6.525	8.09
LWRF	0.705	4.91	7.218	0.694	5.269	7.402	0.671	5.621	7.66
k-NN (k=1)	0.681	3.556	8.018	0.527	4.753	9.774	0.538	4.812	9.673
RBD	0.667	6.033	7.826	0.656	6.465	8.075	0.652	6.779	8.329
SVR	-0.04	8.572	10.12	-0.04	8.572	10.12	-0.04	8.572	10.12
J48	0.339	7.741	9.93	0.323	7.942	9.966	0.244	8.103	10.14
LIR	0.59	6.511	8.266	0.412	10.68	14.136	-0.123	8.575	10.13

Tablo 5.2. LBP yönteminde pencere boyutuna göre H&Y değeri regresyon sonuçları

Regresyon Modeli	Pencere Boyutu 2			Pencere Boyutu 4			Pencere Boyutu 6		
	CC	MAE	RMSE	CC	MAE	RMSE	CC	MAE	RMSE
RF	0.728	0.624	0.786	0.694	0.684	0.833	0.668	0.742	0.873
LWRF	0.753	0.509	0.723	0.726	0.577	0.762	0.708	0.611	0.788
k-NN (k=1)	0.717	0.345	0.826	0.614	0.456	0.968	0.612	0.464	0.971
RBD	0.723	0.632	0.792	0.708	0.684	0.826	0.697	0.733	0.861
SVR	0.02	0.913	1.106	0.02	0.913	1.106	0.02	0.913	1.106
J48	0.391	0.801	1.038	0.421	0.756	1.018	0.421	0.777	0.999
LIR	0.627	0.705	0.866	0.438	1.166	1.548	-0.133	0.969	1.095

Tablo 5.3. ile regresyon modellerinin UPDRS değer tahmini performansı verilmiştir. 4.4.3 bölümünde anlatılan 2 boyutlu dönüştürme şeması LBP yönteminde veri genişliği önerilen mimariye göre küçük kaldığı için uygulanamamıştır. Bu sebepten dolayı deneyler sırasında önerilen mimari modelini bozulmaması ve aynı ortamda test edilmesi adına CNN ve hibrit öğrenme modellerinde kullanılamamıştır. Kullanılamayan yerlerde MD (Mevcut

Değil) işaretiyle tabloda işaretlenmiştir. CNN özniteliklerinin LWRF yöntemiyle birlikte kullanıldığı hibrit model 0.897 CC değeri, 3.009 MAE değeri ve 4.556 RMSE değeri ile en iyi performansı göstermiştir. Yöntem, zaman ve frekans özniteliklerini girdi olarak kullandığında en yüksek CC değerine ve en düşük MAE/RMSE değerine sahiptir. Zaman ve frekans öznitelikleri ile ikinci en iyi performansı gösteren yöntem CC bakımından 0.895 ile LWRF, MAE/RMSE bakımından ise 3.267 MAE ve 4.689 RMSE ile CNN yöntemidir. En kötü performansı ise Lineer regresyon ve Bi-LSTM yöntemleri elde etmiştir. Tablo 5.3. incelendiğinde UPDRS değeri tahmininde zaman ve frekans özniteliklerinin LBP özniteliklerine göre daha anlamlı olduğu sonucu çıkarılabilir. Ayrıca LWRF yönteminin UPDRS değeri tahmininde etkili bir yöntem olduğu ve CNN öznitelikleriyle birlikte kullanıldığında derin özniteliklerin zaman ve frekans özniteliklerine göre daha anlamlı olduğu ortaya çıkmaktadır. CNN yöntemiyle alınan iyi sonuçlar da derin yerel özniteliklerin veriyi temsil etmede daha iyi olduğu durumunu desteklemektedir. UPDRS değer tahmininin düşük hata ile tahmin edilebilmesinin ayrıca bir önemi vardır, bu değer aralığı günümüzde klinik olarak H& Y ölçeğine göre daha sık ve güncel kullanılan Parkinson Hastalığı ölçütüdür.

Tablo 5.4. ile regresyon modellerinin H&Y değer tahmini performansı verilmiştir. UPDRS bölümündeki aynı durum burada da geçerli olduğu için önerilen mimari modelini bozmamak adına 1 boyutlu LBP yöntemi CNN ve hibrit öğrenme modellerinde kullanılamamıştır. Kullanılamayan yerlerde MD (Mevcut Değil) işaretiyle tabloda işaretlenmiştir. Zaman ve frekans özniteliklerinin LWRF yöntemine girdi olarak verildiği model 0.960 CC değeri, 0.168 MAE değeri ve 0.306 RMSE değeri ile en iyi performansı göstermiştir. Zaman ve frekans öznitelikleri ile ikinci en iyi performansı gösteren yöntem 0.176 MAE ve 0.352 RMSE ile k-NN yöntemidir. En kötü performansı ise CNN, Bi-LSTM, LR ve CNN+RF yöntemleri elde etmiştir. Tablo 5.4. incelendiğinde H&Y değer tahmininde CNN yapısından çıkartılan derin yerel özniteliklerin zaman ve frekans özniteliklerine göre daha az anlamlı olduğu söylenebilir. UPDRS yönteminin tersine derin öğrenme yapıları yerine LWRF, k-NN gibi makine öğrenmesi yapıları daha başarılı sonuçlar elde etmiştir. Tablo 5.4. incelendiğinde H&Y değeri tahmininde zaman ve frekans özniteliklerinin LBP özniteliklerine göre daha anlamlı olduğu sonucu çıkarılabilir.

Tablo 5.3. UPDRS değeri regresyon sonuçları


Regresyon Modeli	Zaman ve Frekans Öznitelikeri			LBP		
	CC	MAE	RMSE	CC	MAE	RMSE
k-NN (k=1)	0.873	4.703	8.113	0.681	3.556	8.018
RF	0.876	5.678	8.124	0.674	5.862	7.709
RBD	0.878	5.763	8.072	0.667	6.033	7.826
LWRF	0.895	4.462	7.382	0.705	4.91	7.218
SVR	0.867	5.308	8.298	-0.05	8.736	10.371
J48	0.754	6.609	11.439	0.561	6.484	8.422
LIR	0.679	11.649	15.194	0.59	6.511	8.266
CNN	0.884	3.267	4.689	MD	MD	MD
Bi-LSTM	0.624	10.371	13.303	0.07	10.044	7.218
CNN + Bi-LSTM	0.073	8.72	10.31	MD	MD	MD
CNN + RF	0.874	4.577	5.758	MD	MD	MD
CNN + LWRF	0.897	3.009	4.556	MD	MD	MD

Ayrıca Tablo 5.3. ve 5.4. incelendiğinde LWRF yönteminin hem UPDRS hem de H&Y değer tahmininde yüksek performans göstermesi, bu yöntemin GRF sensörlerinden gelen sinyallerden çıkarılan öznitelikleri doğru biçimde anlamlandırdığını kanıtlamaktadır. CNN derin yerel öznitelikleri ve zaman-frekans özniteliklerini LWRF yapısı rasgele ağaçlarla modelleyip, daha sonra Yerel Ağırlıklandırılmalı yaparak diğer yöntemlere göre daha başarılı tahminler gerçekleştirmiştir. Ayrıca H&Y değer tahmininde UPDRS değer tahminine göre daha yüksek CC ve daha düşük MAE/RMSE değeri elde edilmesinin sebebi H&Y değer aralığının 0-5, UPDRS değer aralığının ise 0-199 olmasından kaynaklanmaktadır.


Tablo 5.4. H&Y değeri regresyon sonuçları

Regresyon Modeli	Zaman ve Frekans Öznitelikleri			LBP		
	CC	MAE	RMSE	CC	MAE	RMSE
k-NN (k=1)	0.947	0.176	0.352	0.717	0.345	0.826
RF	0.947	0.254	0.366	0.728	0.624	0.786
RBD	0.947	0.255	0.366	0.722	0.632	0.792
LWRF	0.96	0.168	0.306	0.753	0.509	0.723
SVR	0.93	0.258	0.404	0.02	1.057	1.117
J48	0.882	0.232	0.531	0.552	0.694	0.928
LIR	0.811	0.543	0.72	0.627	0.705	0.866
CNN	0.864	0.429	0.553	MD	MD	MD
Bi-LSTM	0.879	0.427	0.541	0.353	0.918	1.049
CNN + Bi-LSTM	0.923	0.275	0.382	MD	MD	MD
CNN + RF	0.878	0.516	0.648	MD	MD	MD
CNN + LWRF	0.947	0.215	0.356	MD	MD	MD

LWRF yönteminde ayarlanacak tek parametre, Yerel Ağırlıklandırmada dikkate alınacak en yakın komşu sayısı olan k değeridir. Yukarıda verilen sonuçlarda deneylerde kullanılmak üzere UPDRS için $k=27$ ve H&Y ölçeği için ise $k=11$ seçilmiştir. Şekil 5.1., seçilen k değerinin tahmin performansında CC 'ye olan etkisini göstermektedir. Görüldüğü üzere, k değerinin 5 ten büyük olduğu durumlarda k değiştiğinde CC değeri çok fazla değişim göstermemektedir. Ayrıca çalışmada kullanılan k-NN algoritması için de aynı deneyler yapılmıştır (Şekil 5.2.) ve $k=1$ olduğunda en yüksek CC değerine sahip olduğu tespit edilmiştir. Deneylerde kullanılmak üzere UPDRS ve H&Y ölçeği için ise $k=1$ seçilmiştir.



Şekil 5.1. LWRF yönteminde kullanılan k parametresinin UPDRS ve H&Y değeri tahmininde etkisi



Şekil 5.2. k-NN yönteminde kullanılan k parametresinin UPDRS ve H&Y değeri tahmininde etkisi

Mevcut regresyon modeli ile aynı hedefe yönelik önceki çalışmalar yoktur. Bununla birlikte, bir sınıflandırma deney kurulumu gerçekleştirilip önceki PH saptama çalışmalarıyla, LWRF yöntemi ve derin öğrenme mimarileri karşılaştırılmıştır. Bu amaçla, yöntemler ikili PH kategorisini tahmin edebilecek şekilde çalıştırılmıştır. Tablo 5.5. bu karşılaştırmayı göstermektedir. Elde edilen sonuçlara göre, CNN özniteliklerinin LWRF yöntemine girdi olarak verildiği CNN + LWRF yöntemi önceki yöntemlere ve tez çalışmasında kullanılan diğer yöntemlere göre %99.5 doğruluk değeri ile en iyi performansı göstermektedir. LWRF yöntemi ise %99.5 ile en yüksek özgüllük değerine sahiptir. (RE: Rapor edilmemiş sonuçları göstermektedir.)

Tablo 5.5. Parkinson hastalığı için sınıflandırma sonuçları

	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)
Lee ve Lim [87]	74.3	81.6	73.8
Daliri [88]	89.9	91.7	91.2
Jane ve diğerleri [89]	91.5	RE	RE
Ertugrul ve diğerleri [90]	88.8	88.9	82.2
Acici ve diğerleri [29]	98	99.1	95.7
LWRF	99	97.8	99.5
LWRF (LBP öznitelikleri)	93	80.52	99
CNN + Bi-LSTM	97.7	96.6	98.2
CNN	98.7	98.9	98.7
Bi-LSTM	97.4	92.1	99.6
CNN + RF	99.1	97.5	94.2
CNN + LWRF	99.5	98.7	99.1

5.2.2. Sepsis hastalığı

Bu bölümde Sepsis hastalığı takibinde kullanılan SOFA skor değerinin hayati belirti sinyalleriyle tahmini üzerine deneyler gerçekleştirilmiştir. Deneyler sırasında 7 hayati belirti sinyali üzerinden 1 boyutlu LBP, zaman ve ham veri öznitelikleri çıkartılmış ve bu farklı öznitelik çıkarma şemaları karşılaştırılmıştır. Değer tahmini için regresyon modelleri kullanılmıştır. Bu modeller tezin 1.3. bölümünde anlatılan k-NN, Rastgele Orman (RF), Ayırıklaştırma ile Regresyon (RBD), Yerel Ağırlıklandırılmalı Rastgele Orman (LWRF), Destek Vektör Regresyon (SVR), J48 Karar Ağacı (J48), Lineer Regresyon (LIR), Evrişimsel Sinir Ağı (CNN), Çift Yönlü Uzun Kısa Süreli Hafıza (Bi-LSTM), CNN ve Bi-LSTM hibrit model (CNN + Bi-LSTM), CNN ve RF hibrit model yapısı (CNN + RF) ve son olarak CNN ve LWRF hibrit model yapısıdır (CNN + LWRF).

Regresyon ve sınıflandırma problemleri için farklı öznitelik şemaları kullanılmıştır. Farklı makine öğrenmesi yöntemleri ve LBP yönteminin farklı pencere boyutu parametrelerine göre SOFA skor tahmini için CC / MAE / RMSE cinsinden ölçülen performanslar Tablo 5.6. ile verilmiştir. Bu tablolardan da görüldüğü üzere en yüksek CC ve en düşük MAE / RMSE değeri pencere boyutu 4 seçildiğinde elde edilmiştir. Diğer öznitelik çıkarma şemalarıyla karşılaştırmalar yapılırken SOFA skor tahmini için LBP yönteminin parametresi olarak pencere boyutu 4 seçilmiştir.

Tablo 5.6. LBP yönteminde pencere boyutuna göre SOFA skoru regresyon sonuçları

Regresyon Modeli	Pencere Boyutu 2			Pencere Boyutu 4			Pencere Boyutu 6		
	CC	MAE	RMSE	CC	MAE	RMSE	CC	MAE	RMSE
k-NN (k=19)	0.58	1.024	1.973	0.597	1.042	1.945	0.550	1.379	2.085
RF	0.611	1.047	1.921	0.623	1.027	1.899	0.599	1.075	1.949
RBD	0.61	1.045	1.923	0.62	1.034	1.907	0.595	1.079	1.958
LWRF	0.562	1.017	2.018	0.608	0.998	1.927	0.576	1.218	2.005
SVR	0.585	0.991	2.03	0.596	0.965	2.008	0.261	1.32	2.482
J48	0.561	1.05	2.01	0.533	1.068	2.059	0.476	1.171	2.139
LIR	0.535	1.241	2.049	0.591	1.22	1.957	0.57	1.259	2

Tablo 5.7. ile regresyon modellerinin SOFA skor değeri tahmini performansı verilmiştir. Tablo 5.7. incelendiğinde, ham veri olarak hayati belirtilerin girdi olarak kullanıldığı CNN + RF hibrit yapısı 0.863 CC, 0.659 MAE ve 1.23 RMSE değeri ile hastalık başlangıç saatinde (onset time) en iyi performansı gösteren regresyon modeli olmuştur. İkinci en iyi performansı ham veri öznitelik şeması ile CNN + LWRF (0.835 CC, 0.709 MAE ve 1.349 RMSE) yöntemi elde etmiştir. En kötü performanslara bakacak olursak bütün öznitelik şemalarında genel olarak SVR ve Bi-LSTM yapılarının regresyon analizinde başarılı olmadığı söylenebilir. Öznitelik başarımı perspektifiyle Tablo 5.7. incelendiğinde SOFA skoru değeri tahmininde ham veri özniteliklerinin LBP ve zaman özniteliklerine göre daha anlamlı olduğu söylenebilir. Buna ek olarak, SOFA skor değeri tahmininde zaman özniteliklerinin ise LBP özniteliklerine göre daha anlamlı olduğu sonucu çıkarılabilir. Ayrıca RF yönteminin regresyonda etkili bir yöntem olduğu ve CNN derin özniteliklerin girdi olarak kullanılması, ham veri ve diğer özniteliklerin algoritmalara girdi olarak verilmesinden daha anlamlı ve başarılı olduğu sonucu çıkarılabilir. CNN derin yerel özniteliklerini kullanan algoritmalarla alınan iyi sonuçlar da derin yerel özniteliklerin hayati belirti sinyallerini temsil etmede daha iyi olduğu durumunu desteklemektedir.


Tablo 5.7. SOFA Skoru için regresyon sonuçları (hastalık başlangıç zamanı).

Regresyon Modeli	Zaman öznitelikleri			LBP			Ham veri		
	CC	MAE	RMSE	CC	MAE	RMSE	CC	MAE	RMSE
k-NN (k=19)	0.655	0.982	1.838	0.597	1.042	1.945	0.552	1.496	2.147
RF	0.688	0.984	1.762	0.623	1.027	1.899	0.707	0.991	1.723
RBD	0.68	0.979	1.783	0.62	1.034	1.907	0.706	0.995	1.735
LWRF	0.653	0.955	1.845	0.608	0.998	1.927	0.565	1.412	2.101
SVR	0.225	1.325	2.488	0.596	0.965	2.008	0.203	1.338	2.501
J48	0.581	1.011	1.986	0.533	1.068	2.059	0.556	1.078	2.031
LIR	0.534	1.213	2.155	0.591	1.22	1.957	0.508	1.357	2.09
CNN	0.639	1.099	1.926	0.52	1.302	2.247	0.701	0.902	1.732
Bi-LSTM	0.622	1.073	1.902	0.548	1.344	2.11	0.297	1.518	2.336
CNN + Bi-LSTM	0.632	1.006	1.895	0.549	1.206	2.19	0.713	0.797	1.586
CNN + RF	0.777	0.845	1.526	0.684	0.952	1.754	0.863	0.659	1.23
CNN + LWRF	0.753	0.849	1.604	0.667	1.015	1.889	0.835	0.709	1.349

Sepsis hastalığını ve enfeksiyon durumunu inceleyen literatürdeki çalışmalarda hastalık anında hastalığı tahmin etmekten ziyade hastalık olmadan önce tahmin üzerine deneyler yapılmaktadır. Tez çalışmasında da bu yaklaşım uygulanmıştır. Ham veri öznitelik şemasıyla oluşturulan CNN + RF modelinin performansını daha detaylı değerlendirmek için hastalık başlamadan altı saat önceki pencereye bakarak deneyler genişletildi. Model; aynı öznitelik şemasıyla RF, CNN, CNN + Bi-LSTM ve CNN + LWRF modelleriyle karşılaştırıldı. Tablo 5.8. ile görülebileceği gibi, önerilen yaklaşım CC ölçütü açısından diğer regresör modellerinden daha iyi performans göstermektedir. CNN+RF modeli, sepsisin başlamasından 6 saat önce 0.842 CC 'ye ulaşırken, CNN + LWRF 0.824, CNN + Bi-LSTM 0.729, CNN 0. 714 ve RF 0.551'e ulaşabilmiştir. (CC değeri / hastalık başlangıç zamanından önceki saatler) grafiği, modelin performansını göstermek için Şekil 5.3. verilmiştir.

Tablo 5.8. Regresör modellerinin başlangıç saatine kadar olan saatlerde CC performans karşılaştırması

Başlangıç zamanından önceki saatler	Regresyon Modeli				
	CNN + RF	CNN + LWRF	CNN + Bi-LSTM	CNN	RF
0	0.863	0.835	0.713	0.701	0.707
1	0.859	0.828	0.725	0.711	0.542
2	0.855	0.824	0.731	0.705	0.546
3	0.853	0.826	0.731	0.708	0.557
4	0.853	0.826	0.729	0.704	0.565
5	0.847	0.827	0.728	0.707	0.547
6	0.842	0.824	0.729	0.714	0.551




Şekil 5.3. Sepsis başlamadan önceki altı saat için regresör modellerinin CC performansı

Aynı altı saatlik pencere, modelin MAE performansını değerlendirmek için analiz edildi. Tablo 5.9. incelendiğinde, CNN + RF modelinin MAE ölçütü açısından diğer regresör modellerinden daha iyi performans gösterdiği görülmektedir. Önerilen modelin sepsis başlamadan 6 saat önceki MAE değeri 0.697 iken, CNN + LWRF 0.723, CNN + Bi-LSTM 0.868, CNN 0.919 ve RF 0.917 ‘dir. (MAE değeri / hastalık başlangıç zamanından önceki saatler) grafiği, modelin performansını göstermek için Şekil 5.4. verilmiştir.

Tablo 5.9. Regresör modellerinin başlangıç saatine kadar olan saatlerde MAE performans karşılaştırması

Başlangıç zamanından önceki saatler	Regresyon Modeli				
	CNN + RF	CNN + LWRF	CNN + Bi-LSTM	CNN	RF
0	0.659	0.709	0.797	0.902	0.991
1	0.658	0.724	0.869	0.955	0.917
2	0.674	0.733	0.859	0.983	0.912
3	0.684	0.731	0.857	0.946	0.906
4	0.666	0.712	0.873	0.968	0.896
5	0.686	0.714	0.886	0.915	0.906
6	0.697	0.723	0.868	0.919	0.917




Şekil 5.4. Sepsis başlamadan önceki altı saat için regresör modellerinin MAE performansı

Son olarak, altı saatlik pencerede regresör modellerinin RMSE performansı Tablo 5.10 ile gösterilmektedir. CNN+RF modeli RMSE ölçütü bakımından diğer regresör modellerden daha iyi performans göstermektedir. CNN+RF modeli sepsis başlamadan altı saat önce 1.308 RMSE değerine sahipken CNN + LWRF 1.376, CNN + Bi-LSTM 1.673, CNN'de 1.686 ve RF 2.072 'dir. (RMSE değeri / hastalık başlangıç zamanından önceki saatler) grafiği, modelin performansını göstermek için Şekil 5.5. verilmiştir.


Tablo 5.10. Regresör modellerinin başlangıç saatine kadar olan saatlerde RMSE performans karşılaştırması

Başlangıç zamanından önceki saatler	Regresyon Modeli				
	CNN + RF	CNN + LWRF	CNN + Bi-LSTM	CNN	RF
0	1.230	1.349	1.586	1.732	1.723
1	1.242	1.382	1.679	1.753	2.090
2	1.258	1.386	1.664	1.805	2.076
3	1.265	1.373	1.660	1.737	2.055
4	1.267	1.374	1.696	1.776	2.044
5	1.290	1.367	1.682	1.737	2.069
6	1.308	1.376	1.673	1.686	2.072




Şekil 5.5. Sepsis başlamadan önceki altı saat için regresör modellerinin RMSE performansı

LWRF yönteminde ayarlanacak tek parametre, Yerel Ağırlıklandırmada dikkate alınacak en yakın komşu sayısı olan k değeridir. Verilen sonuçlarda deneylerde kullanılmak üzere SOFA skoru için $k=39$ seçilmiştir. Şekil 5.6. seçilen k değerinin tahmin performansında CC 'ye olan etkisini göstermektedir. Ayrıca çalışmada kullanılan k -NN algoritması için de aynı deneyler yapılmıştır (Şekil 5.7.) ve $k=19$ olduğunda en yüksek CC değerine sahip olduğu tespit edilmiştir. Deneylerde kullanılmak üzere UPDRS ve H&Y ölçeği için ise $k=1$ seçilmiştir.




Şekil 5.6. LWRF yönteminde kullanılan k parametresinin SOFA skoru tahmininde etkisi




Şekil 5.7. k -NN yönteminde kullanılan k parametresinin SOFA skoru tahmininde etkisi


Hayati belirtilerin SOFA skoru düşük ve yüksek örneklerde nasıl görüldüğünü incelemek için çalışmalar genişletilmiştir. Bu bağlamda SOFA skoru 0 ve 18 olan örneklerin hastalık başlamadan 12 saat önceki yedi hayati belirti sinyal ölçüm grafikleri Şekil 5.8.- 5.14. ile verilmiştir. Bu grafiklerde dikey sütun hayati belirti değerlerini ve yatay sütun ise hastalık başlangıç zamanından (0. saat) önceki saatleri göstermektedir. Grafikler incelendiğinde GCS göz açma ölçütü, Divastolik ve Sistolik kan basıncı, kalp ritmi hayati belirti değerlerinde örnekler arasında bariz bir fark görülmektedir. Grafiklere bakılarak bu hayati belirti değerlerinin SOFA skoru tahmininde hastalar arası bariz bir fark oluşturduğu söylenebilir. Sıcaklık, nefes alma hızı, oksijen satürasyonu hayati belirti değerlerinde ise değerlerin birbirine yakın olduğu tespit edilmiştir. Bu yakınlığın sebebi genel bir enfeksiyonunda aynı seyirde olabileceğinden kaynaklanmaktadır. Sofa skoru yüksek olan ve kritik durumda olan hastalarda GCS göz açma ölçütü, divastolik ve sistolik kan basıncı ve oksijen satürasyon değerleri düşük seviyede, sıcaklık, kalp ritmi, nefes alma hızı yüksek seviyede seyretmektedir.




Şekil 5.8. Farklı SOFA skorlarına göre GCS değerleri




Şekil 5.9. Farklı SOFA skorlarına göre divastolik kan basıncı değerleri




Şekil 5.10. Farklı SOFA skorlarına göre sistolik kan basıncı değerleri




Şekil 5.11. Farklı SOFA skorlarına göre vücut sıcaklığı değerleri



Şekil 5.12. Farklı SOFA skorlarına göre kalp ritmi değerleri



Şekil 5.13. Farklı SOFA skorlarına göre oksijen satürasyonu değerleri



Şekil 5.14. Farklı SOFA skorlarına göre nefes alma hızı değerleri

Çalışmanın odak noktası SOFA skorlarını tahmin etmek olmasına rağmen, önerilen modelin sepsis tahmin performansını ölçmek için çeşitli deneyler yapıldı. Modellerin ve öznitelik çıkarma yöntemlerinin Sepsis tahmini performanslarını karşılaştırmak için deneyler genişletildi. Tezin 2.2.2. bölümünde de bahsedildiği gibi sepsis hastalığı gibi enfeksiyonel hastalıkların tahmininde en çok kullanılan performans ölçütü olan AUC deneylerde sınıflandırıcıların performansını ölçmek için kullanılmıştır. Deneyler sırasında 7 hayati belirti sinyali üzerinden LBP, zaman ve ham veri öznitelikleri çıkartılmış ve bu farklı öznitelik çıkarma şemaları karşılaştırılmıştır. Deneylerde kullanılan modeller k en yakın komşu (k-NN), Lojistik Regresyon (LR), Naive Bayes (NB), Destek Vektör Makinesi (SVM), Rastgele Orman (RF), Yerel Ağırlıklandırılmalı Rastgele Orman (LWRF), Evrişimsel Sinir Ağı (CNN), Çift Yönlü Kısa Süreli Hafıza (Bi-LSTM), CNN ve Bi-LSTM hibrit model (CNN + Bi-LSTM), CNN ve RF hibrit model yapısı (CNN + RF) ve son olarak CNN ve LWRF hibrit model yapısıdır (CNN + LWRF).

Hastalık başlangıç zamanında Sepsisi tahmin etmek için on katlı çapraz doğrulamanın sınıflandırma deneyleri Tablo 5.11. ile görülmektedir. Tablo 5.11. incelendiğinde SOFA skor tahmininde başarılı sonuçlar elde eden ham verinin girdi olarak kullanıldığı CNN + RF yönteminin 0.982 AUC değeriyle en iyi tahmin performansına sahip olduğu görülmektedir. Ham veri özniteliklerinin kullanıldığı CNN + LWRF yöntemi, 0.972 ile ikinci en yüksek AUC değerini elde etmiştir. SVM, NB ve k-NN modelleri ise bütün öznitelik çıkarma şemaları içinde en düşük AUC değerine sahiptir. Genel olarak öznitelik çıkarma yöntemleri incelendiğinde LBP yönteminin geleneksel makine öğrenme yöntemlerinde ham veri ve zaman özniteliklerinden daha iyi performans gösterdiği söylenebilir. Derin öğrenme tabanlı sınıflandırıcı yöntemlerde ise ham veriyi girdi olarak alan yöntemler diğer öznitelik çıkarma yöntemlerine göre daha yüksek AUC değerine erişmiştir.


Tablo 5.11. Sepsis hastalığı için tahmin sonuçları (hastalık başlangıç zamanı) (AUC).

Sınıflandırma Modeli	Zaman öznitelikleri	LBP	Ham veri
k-NN (k=19)	0.926	0.934	0.921
RF	0.947	0.945	0.964
LR	0.941	0.944	0.866
NB	0.896	0.903	0.788
SVM	0.52	0.888	0.502
LWRF	0.932	0.94	0.939
CNN	0.935	0.933	0.964
Bi-LSTM	0.926	0.95	0.843
CNN + Bi-LSTM	0.935	0.94	0.966
CNN + RF	0.878	0.904	0.982
CNN + LWRF	0.871	0.891	0.972

Ham verinin girdi olarak kullanıldığı CNN+RF modelinin AUC performansını ölçmek için SOFA skor tahmininde kullanılan aynı altı saatlik aralık analiz edilmiştir. Karşılaştırılan diğer sınıflandırıcılar aynı öznitelik şemasındaki CNN + LWRF, CNN + Bi-LSTM, CNN ve RF olarak tekrar seçilmiştir. Tablo 5.12. incelendiğinde CNN + RF modelinin AUC değeri açısından diğer sınıflandırıcı modellerden daha iyi performans gösterdiği gözlemlenmektedir. Model, sepsisin başlamasından 6 saat önce 0.972 AUC'ye sahipken, CNN + LWRF 0.96, CNN + Bi-LSTM 0.965, CNN 0.960 ve RF 0.963'e sahiptir. (AUC değeri / hastalık başlangıç zamanından önceki saatler) grafiği, modelin performansını göstermek için Şekil 5.15 verilmiştir.

Tablo 5.12. Sınıflandırma modellerinin başlangıç saatine kadar olan saatlerde AUC performans karşılaştırması

Başlangıç zamanından önceki saatler	Sınıflandırma Modeli				
	CNN + RF	CNN + LWRF	CNN + Bi-LSTM	CNN	RF
0	0.982	0.972	0.966	0.964	0.964
1	0.979	0.969	0.963	0.956	0.96
2	0.972	0.959	0.966	0.959	0.961
3	0.972	0.96	0.964	0.958	0.961
4	0.982	0.972	0.965	0.962	0.96
5	0.972	0.962	0.964	0.963	0.959
6	0.972	0.96	0.965	0.96	0.963



Şekil 5.15. Sepsis başlamadan önceki altı saat için sınıflandırıcı modellerinin AUC performansı.

Sepsis tahmininde ve SOFA skoru tahmininde, hangi hayati belirtinin veriyi daha iyi temsil ettiğini belirlemek için bu hayati belirtiler tek tek rastgele orman algoritmasına girdi olarak verilmiştir. Bu deney, en iyi sonucu veren CNN + RF yöntemiyle gerçekleştirilememiştir çünkü kurulan derin öğrenme mimarisi, yedi hayati belirti kanalının hepsini işleyecek şekilde çalışmaktadır. Dolayısıyla CNN yapısı bir boyutlu verileri işleyemeyeceği için Rastgele orman algoritması deneylerde seçilmiştir. Tablo 5.13. ile alınan sonuçlara bakılarak en yüksek AUC değerine sahip nefes alma hızının sepsis tahmininde en tanımlayıcı hayati belirti olduğu söylenebilir. Bu sonuç, sepsis hastalığının ilerlemesinde vücutta en fazla etkilenen sistemin solunum sistemi olduğu gerçeğiyle örtüşmektedir [221]. Tablo 5.13. incelendiğinde bakıldığında ayrıca sıcaklık hayati belirtisinin, sepsis tahmininde en az etkiye sahip olduğu söylenebilir.

Tablo 5.13. Hayati belirtilerin Sepsis tahmin performansına olan etkisi

Hayati Belirtiler	AUC
Sistolik Kan Basıncı	0.923
Divastolik Kan Basıncı	0.919
GCS Göz Açma Ölçütü	0.944
Oksijen Satürasyonu	0.946
Kalp Atış Hızı	0.944
Nefes Alma Hızı	0.95
Sıcaklık	0.893

Aynı şekilde Tablo 5.14. sonuçlar incelendiğinde GCS göz açma ölçütünün SOFA skoru tahmininde en tanımlayıcı hayati belirti olduğu söylenebilir. Diğer hayati belirtilere göre CC bazında en yüksek değere sahiptir ve en düşük MAE-RMSE değerine sahiptir. Bu durum GCS göz açma ölçütünün SOFA skoru hesaplanmasında kullanılan GCS ölçütünün bir parçası olmasından kaynaklanmaktadır. Tablo 5.14 incelendiğinde ayrıca sıcaklık ve kan basıncı hayati belirtilerinin, SOFA skor tahmininde en az etkiye sahip olduğu söylenebilir.

Tablo 5.14. Hayati belirtilerin SOFA skoru tahmin performansına olan etkisi

Hayati Belirtiler	CC	MAE	RMSE
Sistolik Kan Basıncı	0.53	1.207	2.069
Divastolik Kan Basıncı	0.537	1.197	2.063
GCS Göz Açma Ölçütü	0.636	1.025	1.873
Oksijen Satürasyonu	0.62	1.064	1.907
Kalp Atış Hızı	0.578	1.151	1.989
Nefes Alma Hızı	0.623	1.063	1.902
Sıcaklık	0.539	1.201	2.068

Literatürde aynı amaçla daha önce yapılmış herhangi bir çalışma yoktur. Ancak sınıflandırma yani sepsis tahmini üzerine literatürde çeşitli çalışmalar mevcuttur. Bu bağlamda, sınıflandırma için sepsis tahmini konusundaki MIMIC veri kümesini kullanan önceki güncel çalışmalarla karşılaştırmalar yapıldı. Tablo 5.15. bu karşılaştırmayı göstermektedir. Sonuçlardan da görüleceği gibi, CNN + RF modeli AUC açısından diğer çalışmalardan daha iyi performans göstermiştir.

Tablo 5.15. CNN + RF modelinin Sepsis tahmininde diğer çalışmalarla olan karşılaştırılması.

Yazarlar	Veri kümesinin adı	Tahmin Zamanı (saat)	AUC
Calvert ve diğerleri [109]	MIMIC II	3	0.92
Kam ve Kim [136]	MIMIC II	3	0.93
Desautels ve diğerleri [116]	MIMIC III	4	0.74
Nemati ve diğerleri [207]	MIMIC III	4	0.85
Scherph ve diğerleri [173]	MIMIC III	6	0.80
Moor ve diğerleri [219]	MIMIC III	7	0.87
CNN + RF modeli	MIMIC III	6	0.97

6. TARTIŞMA VE SONUÇ

Bu çalışmada önerilen yöntemler ve sonuçlar bakımından tezin literatüre birçok yönden katkı yaptığı düşünülmektedir. Tez çalışmasında giyilebilir sensörlerle sağlık izleme amacıyla farklı türdeki hastalıkların giyilebilir sensörler kullanılarak nasıl izlenebileceği üzerine çalışmalar ve deneyler gerçekleştirilmiştir. Tez çalışmasının asıl amacı giyilebilir sensörlerle sağlık izlemesini etkin ve gürbüz yöntemlerle gerçekleştirmektir. Çalışmada kullanılan hastalıklar, şu anda kesin bir tedavisi bulunmayan ve sadece hastanın semptomlarını azaltan prosedürlerin olduğu Parkinson Hastalığı ve günümüzde çok ölümcül bir enfeksiyon tipi olan ve çok kısa sürede vücuda yayılabilen Sepsis hastalığıdır. İki hastalık için de günümüzde invazif olmayan ve giyilebilir sensörlerle hasta durumunu takip etmek literatürde çok önemli bir yer tutmaktadır. Tez çalışmasında ele alınan giyilebilir sensörlü bu yaklaşımlar sağlık çalışanlarının efor ve zaman kaybetmeden hasta takibi yapabilmesine ve hastaların ise belki bir sağlık kuruluşuna gitmeye gerek kalmadan evinde izlenip tedavi olabilmemesinin önünü açmaktadır.

Parkinson hastalarının uzaktan izlenmesi, tatmin edici bir klinik yardım ve ev bakımı sağlamak için çok önemli bir role sahiptir. Bu hastalar temel motor becerileri kaybetmek zorunda kaldığından, yürüyüş ölçümleri PH semptomlarının şiddetini tahmin etmede önemli bir rol oynar. Sensör teknolojisindeki son gelişmeler, giyilebilir sensörleri etkin ve kolay bir şekilde kullanmamızı sağlar. Bu sebepten dolayı GRF sensörleri teşhis ve prognoz için kolaylıkla kullanılabilir. Elde edilen sonuçlar, hastalığın ilerlemesinin, gelişmiş altyapılara ihtiyaç duymadan sürekli izlenebilir olabileceğini göstermektedir. PH prognoz amacı için iki tür ölçüt kullanılmaktadır. Birincisi, çıkarımsaldır, öznel, bir klinisyen veya hasta öz-değerlendirmesi ile görüşme ve muayeneye dayanır. Bu değerlendirmeler, UPDRS veya H & Y gibi bazı evrensel derecelendirme ölçeklerinden oluşur ve genellikle bir ordinal ölçekte olan skorlarla semptomların tahminlerini sağlar. İkinci ölçüm türü, genellikle hastalığın temeldeki fiziksel özelliklerini yakalayan giyilebilir sensörlere dayanan objektif bir ölçüm türüdür. Bu çalışmada, ikinci ölçüm türünde PH hastalarının durum değerlendirilmesi için bir hesaplama çözümü sunulmaktadır. Çözüm, ayağa giyilen GRF sensörleri tarafından elde edilen yürüme sinyallerinin analizine dayanmaktadır. UPDRS veya H & Y ölçeklerindeki PH semptomlarını tahmin etmek için regresyon tabanlı bir model oluşturulmuştur. PH hastaları yürüme sırasında büyük zorluklar yaşadığından, yürüyüş ölçümleri hastaların otomatik olarak izlenmesi için ayırt edici özelliktedir. Önerilen

yaklaşım motor bozukluk şiddetini tanımlayan sadece kategorik bir sonucu bildirmekten ziyade, PH semptom seviyesinin kesin bir değerinin tahminini mümkün kılmaktadır. Önerilen çözüm Parkinson hastalığı semptom takibinde bir ilk olmaktadır. Bu çözüm sağlık çalışanlarına ikili (hasta veya değil) bir teşhis kararı yardımı vermek yerine hastalığın durumu için yardım sağlamaktadır.

Sepsis hastalığı izleme, SOFA skoru tahmini yardımıyla yoğun bakım hastalarının sepsis hastalığının ve organ sistemlerinin durumunu takip edilmesini amaçlamaktadır. Sepsis-3 tanımında SOFA skoru, hastalık başlangıç zamanı tanımlanırken ve organ yetmezliğinin ciddiyetini belirlerken önemli bir rol oynamaktadır. Bu nedenle, bu skoru önceden tahmin ederek zamanında müdahale etmek hasta ölümlerini önleme imkânı sağlayabildiği için çok önemlidir. Tez çalışmasında önerilen regresyon modeli giyilebilir sensörlerle kolaylıkla elde edilebilen elektronik sağlık verilerini kullanarak 6 saat önceden hastalık başlangıç anındaki SOFA skorunu tahmin edebilmektedir. Önerilen regresyon modeli, sepsis vakalarında SOFA skor tahmini için bir ilk olmaktadır. Bu çalışmanın katkısı iki yönlüdür. İlk olarak, SOFA skorlarını kullanarak, derin öğrenme regresyon modeli sepsis ve enfekte olmuş organ sistemlerinin durumunu izlemeyi amaçlamaktadır. Önceki çalışmalar sadece sepsis başlangıcında ve hastalık başlamadan önce sepsisin varlığını öngörmeye odaklanırken, önerilen model Sepsis'te prognoz çözümü sağlamak için SOFA skorlarını tahmin etmeye odaklanmıştır. İkincisi, yoğun bakım ünitesinde hastaların SOFA skoru hesaplama işlemi büyük çoğunlukla laboratuvar ölçümlerine bağımlıdır. Bu bağımlılık, hastaların tedavisinde gecikmelere neden olmakta ve bu nedenle komplikasyonlar oluşmasına yol açmaktadır. Önerilen yapı, yoğun bakım ünitesinde rutin olarak toplanan kolay erişilebilir, invazif olmayan ve giyilebilir sensörlerle rahatlıkla ölçülebilen hayati belirtileri kullanarak, bu gecikmenin üstesinden gelebilir.

Hastalıkları izleyebilmek için tez çalışmasında çeşitli makine öğrenme yöntemleri ve öznitelik çıkarma şemaları kullanılmıştır. Kullanılan öznitelikler, sinyal verilerinin işlenmesinde sıklıkla kullanılan zaman, frekans öznitelikleri ve 1 boyutta sinyalde yerel olarak doku özniteliklerini ortaya çıkaran 1 boyutlu LBP öznitelikleridir. Makine öğrenmesi yöntemleri ise geleneksel yöntemler ve derin öğrenme mimarilerini içermektedir. Tez çalışmasında bir geleneksel makine öğrenme yöntemi olan Rastgele Orman algoritmasının gelişmiş bir versiyonu olan Yerel Ağırlıklandırılmış Rastgele Orman (LWRF) algoritması geliştirilmiştir. Bu algoritma başarılı bir RF regresyon modeli üretirken örneklere Yerel Ağırlıklandırılmış uygulanmasına dayalıdır. Bu algoritmaya ek olarak CNN derin öğrenme yapısı ile Bi-LSTM, Rastgele Orman ve LWRF algoritmalarının birleştirildiği hibrit

modeller de tez çalışması kapsamında oluşturulmuştur. Bu hibrit modellerde CNN derin öğrenme mimarisi, derin özniteliklerin çıkartılmasında kullanılmıştır. Hem Parkinson hastalığında hem de Sepsis hastalığında giyilebilir sensörlerle alınan sinyallerin hibrit ve derin öğrenme şemalarında kullanılabilmesi için sinyaller 2 boyutlu bir dönüşüm aşamasından geçmektedirler. Böylelikle sinyaller iki boyutlu bir yapıya dönüşüp CNN yardımıyla hem zamansal hem de sinyal kanalları bakımından iki yönlü biçimde işlenebilmektedir. İki boyutlu dönüşüm, Parkinson hastalığında sensörler arası bağlantıları ortaya çıkarırken, Sepsis hastalığında ise hayati belirti değerlerini birlikte değerlendirme imkânı sağlamaktadır. Bu dönüşüm sayesinde sinyal kanalları üzerinden anlamlı derin özniteliklerin çıkarılması sağlamaktadır.

Tez çalışmasında deneyler sonucunda genel olarak derin öğrenme tabanlı yöntemlerin hastalık durum değeri tahmininde etkili olduğu görülmektedir. Parkinson hastalığı UPDRS ölçütü değeri tahmininde, GRF sensörlerinden çıkartılan zaman ve frekans özniteliklerinin hibrit derin öğrenme modeli olan CNN + LWRF algoritmasının birleştirildiği yöntem en iyi performansı göstermiştir. H&Y ölçütü değeri tahmininde ise zaman ve frekans özniteliklerinin kullanıldığı LWRF algoritması üstün gelmiştir. Öznitelikler bakımından giyilebilir GRF sensörlerinin işleminde zaman ve frekans özniteliklerinin LBP özniteliklerine göre daha anlamlı olduğu görülmektedir. Ayrıca hastalık tahmini üzerine yapılan diğer çalışmalarla karşılaştırıldığında CNN + LWRF derin öğrenme hibrit modeli en yüksek doğruluk değerine ulaşmıştır.

Tez çalışmasının Sepsis hastalığı SOFA skor değeri tahmini bölümünde, hayati belirti değerlerinin girdi olarak kullanıldığı CNN + RF hibrit derin öğrenme modeli en iyi performansı gösterdiği kanıtlanmıştır. Öznitelikler bakımından deneysel sonuçlar incelendiğinde, hayati belirtilerin işleminde ham veri özniteliklerinin LBP ve zaman özniteliklerine göre daha anlamlı olduğu bilgisi çıkarılmaktadır. LBP özniteliklerinde pencere boyutu parametresi iki hastalık için de farklı seçilmiştir. Parkinson hastalığında pencere boyutunun küçük seçilmesi frekansı yüksek olan sinyal üzerinden daha küçük farklılıkları tespit etmek için, Sepsis hastalığı için ise frekansı düşük olan zaman serisi sinyalde daha geniş bir çerçeveye bakarak daha anlamlı öznitelikler çıkarmak içindir. Tez çalışmasında, SOFA skoru tahmininde hastalık başlangıç saatinden 6 saat öncesine kadar tahmin aralığı genişletilmiştir. Bu aralık için CNN + RF hibrit derin öğrenme yapısı diğer modellere göre üstünlüğünü korumuştur. Ayrıca hastalık tahmini üzerine yapılan diğer çalışmalarla karşılaştırıldığında CNN + RF derin öğrenme hibrit modeli en yüksek AUC değerine ulaşmıştır. Ek olarak yapılan deneyler sonucunda nefes alma hızı hayati belirti

değerinin diğerlerine göre daha SOFA skoru tahmininde daha etkili olduğu görülmüştür. Hastalık tahmininde ise GCS hayati belirti değeri belirleyici olmuştur.

Genel anlamda tez çalışması sonuçlarına bakarak, CNN yapısının sinyallerden anlamlı yerel derin öznitelikler çıkardığı sonucuna ulaşılabilir. Sinyallerin CNN yapısına girdi olarak verilmesine olanak sağlayan sinyali 2 boyuta dönüştürme işlemi, hem Parkinson hem de Sepsis semptomlarının takibinde başarılı sonuçlara ulaşılmasında rol almaktadır. CNN katmanlarının GRF sensörleri ve hayati belirtiler arasındaki ilişkiden istifade ettiği ve RF / LWRF yöntemleri bu ilişkileri öğrenilmiş CNN özniteliklerinden haritalayabildiği söylenebilir.

Tez çalışmasında bazı sınırlamalar bulunmaktadır. Bu sınırlamalar veri kümesi kaynaklı sorunlardır. Parkinson hastalığı takibinde kullanılan Physionet veri kümesinde hasta sayısı, sağlıklı bireylere göre azınlıktadır. Aynı şekilde MIMIC III veri kümesinde de birçok örnek bulunmasına rağmen, önerilen derin öğrenme modelin performansını hızlandırmak için kriterlere uyan sepsise sahip hasta sayısı yeterli değildir. Bu problem, hasta ve hasta olmayan örneklerde sınıf orantısızlığı yaratmaktadır. Bu sorunu çözmek için, mevcut verileri yeniden örnekleme algoritmaları kullanılabilir. Yeniden örnekleme yapılarak, derin öğrenme modelinin performansını arttırabilir çünkü derin öğrenme mimarileri büyük verilerle daha fazla başarıya ulaşır. MIMIC III veri kümesinde ek olarak bir diğer sınırlama ise hayati belirti ölçümlerinin ulaşılabilirliğidir. Veri kümesinde hayati belirti ölçümlerinin zaman aralıkları eşit değildir, bu yüzden eşit olmaları için eksik değerler doldurularak ya da ortalamaları alınarak çalışmada kullanılmıştır. Bu durum, modelleme algoritmasının veri popülasyonunu tamamen genelleştirememesine neden olabilir. Bu problem, MIMIC III veri kümesinde hayati belirti ölçümlerinin yoğun bakımda alınma sıklığının arttırılmasıyla aşılabılır.

Tez çalışmasında önerilen regresyon şeması gelecekte giyilebilir sensör tabanlı bir tıp karar destek sistemine entegre edilebilir. Böylelikle hasta durumunu izlemek için harcanan efor ve müdahale zamanı en kısaya indirgenerek klinik ortamında hem sağlık çalışanlarına hem de hastalara kolay ve hızlı bir şekilde hastalık takibi imkanı sağlanabilir. Bu sistem bir erken uyarı sistemi gibi de çalışabilir. Parkinson hastalarının semptomları ağırlaştığında doktora veya sağlık kuruluşuna bilgi verilip hastanın ilaç dozu ona göre ayarlanabilir. Aynı şekilde sepsis hastalarında hastanın durumu ağırlaşmadan ve septik şoka girmeden saatler öncesinde durumdan haberdar edilip hastaya doğru zamanda müdahale ve ilaç tedavisi başlanabilir.

KAYNAKLAR

- [1] N. Ravi, N. Dandekar, P. Mysore and M. L. Littman, "Activity recognition from accelerometer data," *In Proceedings of the 17th Conference on Innovative Applications of Artificial Intelligence*, 2005.
- [2] S. J. Preece, J. Y. Goulermas, L. P. J. Kenney and D. Howard, "A comparison of feature extraction methods for the classification of dynamic activities from accelerometer data," *IEEE Trans. Biomed. Eng.*, vol.56, no.3, pp.871–879, 2009.
- [3] P. Casale, O. Pujol and P. Radeva, "Activity Recognition from Accelerometer Data Using Wearable Device," *Personal and Ubiquitous Computing*, vol.6669, pp.289-296, 2011.
- [4] Y. Liao, C. Thompson, S. Peterson, J. Mandrola and M. S. Beg, "The Future of Wearable Technologies and Remote Monitoring," *Health Care*, vol 39, pp.115-121, 2019.
- [5] M. M. Rodgers, G. Alon, V. M. Pai and R. S. Conroy, "Wearable Technologies for Active Living and Rehabilitation: Current Research Challenges and Future Opportunities," *Journal of Rehabilitation and Assistive Technologies Engineering*, vol.6, 2019.
- [6] C. Munroe, Y. Meng, H. Yanco and M. Begum, "Augmented reality eyeglasses for promoting home-based rehabilitation for children with cerebral palsy," *In: The eleventh ACM/ IEEE international conference on human robot interaction*, Christchurch, NZ, pp.565–565, 7–10 March 2016.
- [7] D. McEwen, A. Taillon-Hobson, M. Bilodeau, H. Sveistrup and H. Finestone, "Virtual reality exercise improves mobility after stroke: an inpatient randomized controlled trial," *Stroke*, vol. 45, pp.1853–1855, 2014.
- [8] S. Malwade, S. S. Abdul, M. Uddin, A. A. Nursetyo, L. Fernandez-Luque, X. Zhu, L. Cilliers, C. Wong, P. Bamidis and Y. Li, "Mobile and wearable technologies in

healthcare for the ageing population,” *Computer Methods and Programs in Biomedicine*, vol.161, pp.233–237, 2018.

- [9] A. Godfrey, V. Hetherington, H. Shuma, P. Bonato, N. H. Lovell and S. Stuart, “From A to Z: Wearable technology explained,” *Maturitas*, vol.113, pp.40–47, 2018.
- [10] M. M. Baig, H. Gholamhosseini, A. A. Moqeem, F. Mirza and M. Lindén, “A Systematic Review of Wearable Patient Monitoring Systems - Current Challenges and Opportunities for Clinical Adoption,” *Journal of Medical Systems*, vol. 41, no.115, 2017.
- [11] Y. Athavale and S. Krishnan, “Biosignal monitoring using wearables: Observations and opportunities,” *Biomedical Signal Processing and Control*, vol. 38, pp.22-33, 2017.
- [12] O. Faust, Y. Hagiwara, T. J. Hong, O. S. Lih and U. R. Acharya, “Deep learning for healthcare applications based on physiological signals: A review,” *Computer Methods and Programs in Biomedicine*, vol.161, pp.1-13, 2018.
- [13] Y. Ren Y, L. Zhang and P. N. Suganthan, “Ensemble Classification and Regression—Recent Developments, Applications and Future Directions,” *IEEE Computational Intelligence Magazine*, vol. 11, no. 1, pp.41-53, 2016.
- [14] T. Asuroglu, K. Acici, C. B. Erdas and H. Ogul, “Texture of Activities: Exploiting Local Binary Patterns for Accelerometer Data Analysis,” *In: SITIS’16 12th International Conference on Signal-Image Technology and Internet-Based Systems IEEE*, 2016.
- [15] Jiawei Han, Micheline Kamber and Jian Pei, *Data Mining: Concepts and Techniques*. 3rd ed. The Morgan Kaufmann Series in Data Management Systems Morgan Kaufmann Publishers, July 2011.

- [16] F. Altunbey Ozbay and B. Alatas, "Fake news detection within online social media using supervised artificial intelligence algorithms," *Physica A: Statistical Mechanics and its Applications*, vol. 540, 2020.
- [17] T. D. Acharya, D. H. Lee, I. T. Yang and J. K. Lee, "Identification of Water Bodies in a Landsat 8 OLI Image Using a J48 Decision Tree," *Sensors*, vol. 16, no.7, 2016.
- [18] X. Meng, P. Zhang, Y. Xu and H. Xie, "Construction of decision tree based on C4.5 algorithm for online voltage stability assessment," *International Journal of Electrical Power & Energy Systems*, vol. 118, 2020.
- [19] R. Salman and V. Kecman, "Regression as classification," *In: Southeastcon Proceedings of IEEE*, 2012.
- [20] E. Frank and R. R. Bouckaert, "Conditional Density Estimation with Class Probability Estimators," *Advances in Machine Learning Lecture Notes in Computer Science*, vol. 5828, 2009.
- [21] C. J. C. Burges, "A tutorial on support vector machines for pattern recognition," *Data Min. Knowl. Disc.*, vol. 2, no. 2, pp.121–167, 1998.
- [22] E. Tuba and Z. Stanimirovic, "Elephant herding optimization algorithm for support vector machine parameters tuning," in: *9th International Conference on Electronics, Computers and Artificial Intelligence (ECAI)*, 2017.
- [23] S. K. Shevade, S. S. Keerthi, C. Bhattacharyya and K. R. K. Murthy, "Improvements to the SMO Algorithm for SVM Regression," *IEEE Transactions on Neural Networks*, vol. 11, no. 5, pp.1188-1193, 2000.
- [24] A. Danandeh Mehr, V. Nourani, V. Karimi Khosrowshahi, et al., "A hybrid support vector regression–firefly model for monthly rainfall forecasting," *Int. J. Environ. Sci. Technol.*, vol. 16, pp.335–346, 2019.

- [25] A. Gascón, P. Schoppmann, B. Balle, M. Raykova, J. Doerner, S. Zahur and D. Evans, "Privacy-Preserving Distributed Linear Regression on High-Dimensional Data, Proceedings on Privacy Enhancing Technologies," vol. 4, pp.345-364, 2017.
- [26] M. Srividya, S. Mohanavalli and N. Bhalaji, "Behavioral Modeling for Mental Health using Machine Learning Algorithms," *N. J Med Syst*, vol. 42, no. 88, 2018.
- [27] G. Manogaran and D. Lopez, "Health data analytics using scalable logistic regression with stochastic gradient descent," *Int. J. Advanced Intelligence Paradigms*, vol. 10, Nos. 1/2, 2018.
- [28] C. Bonte and F. Vercauteren, "Privacy-preserving logistic regression training," *BMC Med Genomics*, vol. 11, no. 86, 2018.
- [29] K. Acici, C. B. Erdas, T. Asuroglu, M. K. Toprak, H. Erdem and H. Ogul, "A Random Forest method to detect Parkinson's Disease via gait analysis," *Communications in Computer and Information Science*, vol. 744, pp.609-619, 2017.
- [30] P. Casale, O. Pujol and P. Radeva, "Personalization and user verification in wearable systems using biometric walking patterns," *Personal and Ubiquitous Computing*, vol. 16, no. 5, pp.563-580, 2012.
- [31] O. Yurur, C. H. Liu and W. Moreno, "Unsupervised posture detection by smartphone accelerometer," *Electronics Letters*, vol. 49, no. 8, pp.562-564, 2013.
- [32] L. Breiman, "Random forests," *Machine Learning*, vol.45, no.1, pp.5–32, 2001.
- [33] A. Verikas, A. Gelzinis and M. Bacauskiene "Mining data with random forests: A survey and results of new tests," *Pattern Recognition*, vol. 44, pp.330–349, 2011.
- [34] J. Fagerström, M. Bång, D. Wilhelms and M. S. Chew, "LiSep LSTM: A Machine Learning Algorithm for Early Detection of Septic Shock," *Scientific Reports*, vol. 9, no. 15132, 2019.

- [35] Ü. Budak , Z. Cömert, Z. N. Rashid, A. Şengür and M. Çıbuk, “Computer-aided diagnosis system combining FCN and Bi-LSTM model for efficient breast cancer detection from histopathological images,” *Applied Soft Computing Journal*, vol. 85, 2019.
- [36] Q. Sun, M. V. Jankovic, L. Bally and S. G. Mougiakakou, “Predicting Blood Glucose with an LSTM and Bi-LSTM Based Deep Neural Network,” *in: 14th Symposium on Neural Networks and Applications (NEUREL)*, 2018.
- [37] O. Yildirim, “A novel wavelet sequence based on deep bidirectional LSTM network model for ECG signal classification,” *Computers in Biology and Medicine*, vol. 96, pp.189–202, 2018.
- [38] S. Aleshin-Guendel, “Examining the Structure of Convolutional Neural Networks,” M.Sc. Thesis, Boston College, Boston, USA, 2017.
- [39] B. Shickel, P. J. Tighe, A. Bihorac and P. Rashidi, “Deep EHR: A Survey of Recent Advances in Deep Learning Techniques for Electronic Health Record (EHR) Analysis,” *IEEE J Biomed Health Inform.*, vol. 22, no. 5, pp.1589-1604, 2018.
- [40] J. Gu, Z. Wang, J. Kuen, L. Ma, A. Shahroudy, B. Shuai, T. Liu, X. Wang, G. Wang, J. Cai and T. Chen, “Recent advances in convolutional neural networks,” *Pattern Recognition*, vol.77, pp.354-377, 2018.
- [41] K. Açııcı, T. Aşuroğlu, Ç. B. Erdaş and H. Oğul, “T4SS Effector Protein Prediction with Deep Learning,” *Data: Open Access Journal of Data in Science*, vol. 4, no.1, 2019.
- [42] C. Münker, Using Convolutional Neural Networks to distinguish vehicle pose and vehicle class, M.Sc. Thesis, Technische Universität Darmstadt, Darmstadt, Germany, 2016.
- [43] E. R. Dorsey, R. Constantinescu, J. P. Thompson, K. M. Biglan , R. G. Holloway, K. Kiebertz, F. J. Marshall, B. M. Ravina, G. Schifitto, A. Siderowf and C. M. Tanner,

“Projected number of people with Parkinson disease in the most populous nations, 2005 through 2030,” *Neurology*, vol.68, no. 5, pp.384-386, 2007.

- [44] M. C. de Rijk, L. J. Launer, K. Berger, M. M. Breteler, J. F. Dartigues, M. Baldereschi, L. Fratiglioni, A. Lobo, J. Martinez-Lage, C. Trenkwalder and A. Hofman, “Prevalence of Parkinson's disease in Europe: A collaborative study of population-based cohorts Neurologic Diseases in the Elderly Research Group,” *Neurology*, vol. 54, pp.21-23, 2000.
- [45] J. Jankovic, “Progression of Parkinson disease: Are we making progress in charting the course?,” *Arch. Neurol.*, vol. 62, pp.351–352, 2005.
- [46] C. G. Goetz, W. Poewe, O. Rascol and C. Sampaio, “Evidence-based medical review update: pharmacological and surgical treatments of Parkinson's disease: 2001 to 2004,” *Mov. Disord.*, vol. 20, no. 5, pp.523-539, 2005.
- [47] A. L. Silva de Lima, T. Hahn, N. M. de Vries, E. Cohen, L. Bataille, M. A. Little, H. Baldus, B. R. Bloem and M. J. Faber, “Large-Scale Wearable Sensor Deployment in Parkinson's Patients: The Parkinson@Home Study Protocol,” *JMIR Res. Protoc.*, vol. 5, no. 3, 2016.
- [48] R. Bhidayasiri and P. Martinez-Martin, “Clinical Assessments in Parkinson's Disease: Scales and Monitoring,” *International Review of Neurobiology*, vol. 132, pp.129-182, 2017.
- [49] B. Kostek, K. Kaszuba, P. Zwan, P. Robowski and J. Slawek, “Automatic assessment of the motor state of the Parkinson's disease patient--a case study,” *Diagnostic Pathology*, vol. 7, no. 18, 2012.
- [50] A. Nicoletti, G. Mostile, G. Portar, A. Luca, F. Patti and M. Zappia, “Computer-assisted cognitive rehabilitation on freezing of gait in Parkinson’s disease: A pilot study,” *Neuroscience Letters*, vol. 654, pp.38-41, 2017.

- [51] S. Patel, K. Lorincz, R. Hughes, N. Huggins, J. Growdon, D. Standaert, M. Akay, J. Dy, M. Welsh and P. Bonato, "Monitoring motor fluctuations in patients with Parkinson's disease using wearable sensors," *IEEE Transactions on Information Technology in Biomedicine*, vol. 13, no. 6, pp.864-873, 2009.
- [52] B. Post, M. P. Merkus, R. M. A. de Bie, R. J. de Haan, J. D. Speelman, "Unified Parkinson's Disease Rating Scale Motor Examination: Are Ratings of Nurses, Residents in Neurology, and Movement Disorders Specialists Interchangeable?," *Movement Disorders*, vol. 20, no. 12, pp.1577–1584, 2005.
- [53] M. C. Akbostancı, "Rating Scales Used in the Evaluation of Parkinson's Disease and the New UPDRS," *Türkiye Klinikleri J Neurol-Special Topics*, vol. 1, no. 4, pp.115-117, 2008.
- [54] A. T. Tzallas, M. G. Tsipouras, G. Rigas, D. G. Tsalikakis, E. C. Karvounis, M. Chondrogiorgi, F. Psomadellis, J. Cancela, M. Pastorino, M. T. Waldmeyer, S. Konitsiotis and D. I. Fotiadis, "PERFORM: a system for monitoring, assessment and management of patients with Parkinson's disease," *Sensors*, vol. 14, no.11, pp.21329-21357, 2014.
- [55] K. Aminian, C. Trevisan, B. Najafi, H. Dejnabadi, C. Frigo, E. Pavan, A. Telonio, F. Cerati, E. C. Marinoni, P. Robert and P. F. Leyvraz, "Evaluation of an ambulatory system for gait analysis in hip osteoarthritis and after total hip replacement," *Gait Posture*, vol. 20, no. 1, pp.102-107, 2004.
- [56] P. Burkhard, H. Shale, J. Langston and J. Tetrud, "Quantification of Dyskinesia in Parkinson's Disease: Validation of a Novel Instrumental Method," *Movement Disorders*, vol. 14, pp.754–763, 1999.
- [57] T. O. Mera, D. A. Heldman, A. J. Espay, M. Payne and J. P. Giuffrida, "Feasibility of home-based automated Parkinson's disease motor assessment". *Journal of Neuroscience Methods* vol. 203, pp.152–156, 2011.

- [58] R. Spain, R. S. George, A. Salarian, M. Mancini, J. M. Wagner, F.B. Horak and D. Bourdette, “Body-worn motion sensors detect balance and gait deficits in people with multiple sclerosis who have normal walking speed,” *Gait Posture*, vol. 35, pp.573–578, 2012.
- [59] Lift Labs. <https://www.liftware.com/> (Accessed: Jun. 14, 2020)
- [60] Rescue Project. <http://hces-online.net/websites/rescue/> (Accessed: Jun. 14, 2020)
- [61] Parreha.
<http://www.istworld.org/ProjectDetails.aspx?ProjectId=25c35370be294afab742a8783686e513> (Accessed: Jun. 14, 2020)
- [62] Parkaid. <http://www.parkaid.net/> (Accessed: Jun. 14, 2020)
- [63] Daphne. <http://clinicaltrials.gov/ct2/show/NCT00141518>. (Accessed: Jun. 14, 2020)
- [64] Help. <http://www.aal-europe.eu/projects/help/> (Accessed: Jun. 14, 2020)
- [65] S. Mazilu, U. Blanke, M. Hardegger, G. Troster, E. Gazit, M. Dorfman and J. M. Hausdorff, “Gait Assist: A wearable assistant for gait training and rehabilitation in Parkinson's disease,” *In: Proceedings of the 2014 IEEE International Conference on Pervasive Computing and Communications Workshops (PERCOM Workshops)*, 2014.
- [66] J. Cabestany, C. Perez Lopez, A. Sama, J. M. Moreno, A. Bayes and A. Rodriguez-Molinero, “REMPARK: When AI and technology meet Parkinson Disease assessment,” *In: Proceedings of the 20th International Conference Mixed Design of Integrated Circuits and Systems (MIXDES)*, 2013.
- [67] R. Bhidayasiri and D. Tarsy, *Parkinson's Disease: Hoehn and Yahr Scale*. Movement Disorders: A Video Atlas, Humana Press Springer Science+Business Media: New York; 2012.

- [68] UPDRS Form: <https://www.parkinsons.va.gov/resources/UPDRS.asp> (Accessed: Jun. 14, 2020)
- [69] K. Aminian and B. Najafi, "Capturing human motion using body-fixed sensors: outdoor measurement and clinical applications," *Computer Animation & Virtual Worlds*, vol. 15, no. 2, pp.79–94, 2004.
- [70] C. B. Erdas, I. Atasoy, K. Acici and H. Ogul, "Integrating features for accelerometer-based activity recognition," *Procedia Computer Science*, vol. 98, pp.522-557, 2016.
- [71] Y. Zhao, T. Heida, E. E. van Wegen, B. R. Bloem and R. J. van Wezel, "E-health Support in People with Parkinson's Disease with Smart Glasses: A Survey of User Requirements and Expectations in the Netherlands," *Journal of Parkinson's Disease*, vol. 5, no. 2, pp.369-378, 2015.
- [72] B. Bilney, M. Morris and K. Webster, "Concurrent related validity of the GAITRite walkway system for quantification of the spatial and temporal parameters of gait," *Gait Posture*, vol. 17, no.1, pp.68-74, 2003.
- [73] P. H. Chen, R. L. Wang, D. J. Liou and J. S. Shaw, "Gait Disorders in Parkinson's Disease: Assessment and Management," *International Journal of Gerontology*, vol. 7, no. 4, pp.189-193, 2013.
- [74] S. J. M. Bamberg, A. Y. Benbasat, D. M. Scarborough, D. E. Krebs and J. A. Paradiso, "Gait analysis using a shoe-integrated wireless sensor system," *IEEE Trans. Inf. Technol. Biomed.*, vol. 12, pp.413–423, 2008.
- [75] A. Salarian, P. R. Burkhard, F. J. Vingerhoets, B. M. Jolles and K. Aminian, "A novel approach to reducing number of sensing units for wearable gait analysis systems," *IEEE Trans. Biomed. Eng.*, vol. 60, pp.72–77, 2013.
- [76] G. Li, T. Liu, L. Gu, Y. Inoue, H. Ning and M. Han, "Wearable gait analysis system for ambulatory measurement of kinematics and kinetics," *In: Proceedings of the IEEE Sensors*, 2014.

- [77] Y. Chen, W. Hu, Y. Yang, J. Hou and Z. Wang, "A method to calibrate installation orientation errors of inertial sensors for gait analysis," *In: Proceedings of the 2014 IEEE International Conference on Information and Automation (ICIA)*, 2014.
- [78] R. Takeda, G. Lisco, T. Fujisawa, L. Gastaldi, H. Tohyama and S. Tadano, "Drift removal for improving the accuracy of gait parameters using wearable sensor systems," *Sensors*, vol. 14, pp.23230–23247, 2014.
- [79] S. R. Hundza, W. R. Hook, C. R. Harris, S. V. Mahajan, P. A. Leslie, C. A. Spani, L. G. Spalteholz, B. J. Birch, D. T. Commandeur and N. J. Livingston, "Accurate and reliable gait cycle detection in Parkinson's disease," *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 22, pp.127–137, 2014.
- [80] M. L. Ferster, S. Mazilu and G. Tröster, "Gait Parameters Change Prior to Freezing in Parkinson's Disease: A Data-driven Study with Wearable Inertial Units," *In: Proceedings of the 10th EAI International Conference on Body Area Networks (BodyNets '15)*, 2015.
- [81] Z. Wang and R. Ji, "Estimate spatial-temporal parameters of human gait using inertial sensors," *In: Proceedings of the 2015 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER)*, 2015.
- [82] I. González, J. Fontecha, R. Hervás and J. Bravo, "An ambulatory system for gait monitoring based on wireless sensorized insoles," *Sensors*, vol. 15, pp.16589–16613, 2015.
- [83] M. Demonceau, A. F. Donneau, J. L. Croisier, E. Skawiniak, M. Boutaayamou, D. Maquet and G. Garraux, "Contribution of a Trunk Accelerometer System to the Characterization of Gait in Patients with Mild-to-Moderate Parkinson's Disease," *IEEE J. Biomed. Health Inform.*, vol. 19, pp.1803–1808, 2015.
- [84] S. Del Din, A. Godfrey and L. Rochester, "Validation of an accelerometer to quantify a comprehensive battery of gait characteristics in healthy older adults and Parkinson's

disease: toward clinical and at home use,” *IEEE J. Biomed. Health Inform.*, vol. 20, pp.838–847, 2016.

- [85] A. Ferrari, P. Ginis, M. Hardegger, F. Casamassima, L. Rocchi and L. Chiari, “A Mobile Kalman-Filter Based Solution for the Real-Time Estimation of Spatio-Temporal Gait Parameters,” *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 24, pp.764–773, 2016.
- [86] C. Tunca, N. Pehlivan, N. Ak, B. Arnrich, G. Salur and C. Ersoy, “Inertial Sensor-Based Robust Gait Analysis in Non-Hospital Settings for Neurological Disorders,” *Sensors* vol. 17, no. 4, 2017.
- [87] S. H. Lee and J. S. Lim, “Parkinson’s disease classification using gait characteristics and wavelet-based feature extraction,” *Expert Systems with Applications*, vol. 39, no. 8, pp.7338–7344, 2010.
- [88] M. R. Daliri, “Chi-square distance kernel of the gaits for the diagnosis of Parkinson’s disease,” *Biomedical Signal Processing and Control*, vol. 8, no. 1, pp.66–70, 2013.
- [89] Y. N. Jane, H. K. Nehemiah and K. Arputharaj, “A Q-backpropagated time delay neural network for diagnosing severity of gait disturbances in Parkinson’s disease,” *Journal of Biomedical Informatic*, vol. 60, pp.169–176, 2016.
- [90] O. F. Ertugrul, Y. Kaya, R. Tekin and M. N. Almali, “Detection of Parkinson’s disease by Shifted One Dimensional Local Binary Patterns from gait,” *Expert Systems with Applications*, vol. 56, pp.156-163, 2016.
- [91] W. Zeng, F. Liu, Q. Wang, Y. Wang, L. Mab and Y. Zhang, “Parkinson’s disease classification using gait analysis via deterministic learning,” *Neuroscience Letters*, vol. 633, pp.268–278, 2016.
- [92] S. V. Perumal and R. Sankar, “Gait and Tremor Assessment for Patients with Parkinson’s Disease Using Wearable Sensors,” *Information and Communications Technology (ICT) Express*, vol. 2, no. 4, pp.168-174, 2016.

- [93] F. J. Martínez-Murcia, J. M. Górriz, J. Ramírez, I. A. Illán and A. Ortiz, “Automatic detection of Parkinsonism using significance measures and component analysis in DaTSCAN imaging,” *Neurocomputing*, vol. 126, pp.58–70, 2014.
- [94] Y. Tang, L. Meng, C. Wan, Z. Liu, W. Liao, X. Yan, X. Wang, B. Tang and J. Guo, “Identifying the presence of Parkinson’s disease using low-frequency fluctuations in BOLD signals,” *Neuroscience Letters*, vol. 645, pp.1–6, 2017.
- [95] J. Naren, P. Ramalingam, U. Raja Rajeswari, P. Vijayalakshmi and G. Vithya, “An Intelligent System on Computer-Aided Diagnosis for Parkinson’s Disease with MRI Using Machine Learning,” *Learning and Analytics in Intelligent Systems*, vol. 10, pp.159-165, 2020.
- [96] S. Shinde, S. Prasad, Y. Saboo, R. Kaushick, J. Saini, P. K. Pal and M. Ingalthalikar, “Predictive markers for Parkinson's disease using deep neural nets on neuromelanin sensitive MRI,” *NeuroImage: Clinical*, vol. 22, 2019.
- [97] E. Adeli, F. Shi, L. An, C. Y. Wee, G. Wu, T. Wang and D. Shen, “Joint feature-sample selection and robust diagnosis of Parkinson's disease from MRI data,” *NeuroImage*, vol. 141, pp.206–219, 2016.
- [98] A. Pompili et al., “Automatic Detection of Parkinson’s Disease: An Experimental Analysis of Common Speech Production Tasks Used for Diagnosis,” *Lecture Notes in Computer Science*, vol. 10415, pp.411-419, 2017.
- [99] D. Hemmerling, J. R. Orozco-Arroyave, A. Skalski, J. Gajda and E. Nöth, “Automatic Detection of Parkinson's Disease Based on Modulated Vowels,” *INTERSPEECH*, 2016.
- [100] A. K. Patra, R. Ray, A. A. Abdullah and S. R. Dash, “Prediction of Parkinson's disease using Ensemble Machine Learning classification from acoustic analysis,” *Journal of Physics: Conference Series*, vol. 1372, 2019.

- [101] C. R. Pereira, S. A. T. Weber, C. Hook, G. H. Rosa and J. P. Papa, "Deep Learning-Aided Parkinson's Disease Diagnosis from Handwritten Dynamics," 2016 29th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI), pp. 340-346, 2016.
- [102] E. Yassir, K. Ghizlane, M. Mostafa and C. Driss, "Towards an automatic and early detection of Parkinson's disease: Modeling of a polar coordinates system based on spiral tests," AIP Conference Proceedings, vol. 2074, pp.1-9 2019.
- [103] R. Senatore, A. Della Cioppa and A. Marcelli, "Automatic Diagnosis of Parkinson Disease through Handwriting Analysis: A Cartesian Genetic Programming Approach," 2019 IEEE 32nd International Symposium on Computer-Based Medical Systems (CBMS), pp. 312-317, 2019.
- [104] R. C. Amland and K. E. Hahn-Cover, "Clinical decision support for early recognition of sepsis," *Amer. J. Med. Qual.*, vol. 31, no. 2, pp. 103–110, Mar. 2016.
- [105] R. C. Amland, J. J. Lyons, T. L. Greene and J. M. Haley, "A two-stage clinical decision support system for early recognition and stratification of patients with sepsis: An observational cohort study," *JRSM Open*, vol. 6, no. 10, 2015.
- [106] E. Bloch, T. Rotem, J. Cohen, P. Singer and Y. Aperstein, "Machine learning models for analysis of vital signs dynamics: A case for sepsis onset prediction," *J. Healthcare Eng.*, vol. 2019, 2019.
- [107] W. Branch-Elliman, J. Strymish, V. Kudesia, A. K. Rosen and K. Gupta, "Natural language processing for real-time catheter-associated urinary tract infection surveillance: Results of a pilot implementation trial," *Infection Control Hospital Epidemiol.*, vol. 36, no. 9, pp.1004–1010, 2015.
- [108] J. Calvert, N. Saber, J. Hoffman and R. Das, "Machine-learning-based laboratory developed test for the diagnosis of sepsis in high-risk patients," *Diagnostics*, vol. 9, no. 1, 2019.

- [109] J. S. Calvert, D. A. Price, U. K. Chettipally, C. W. Barton, M. D. Feldman, J. L. Hoffman, M. Jay and R. Das, “A computational approach to early sepsis detection,” *Comput. Biol. Med.*, vol. 74, pp.69–73, 2016.
- [110] Y.-J. Chang, M.-L. Yeh, Y.-C. Li, C.-Y. Hsu, C.-C. Lin, M.-S. Hsu and W.-T. Chiu, “Predicting hospital-acquired infections by scoring system with simple parameters,” *PLoS ONE*, vol. 6, no. 8, 2011.
- [111] K. L. Colborn, M. Bronsert, E. Amioka, K. Hammermeister, W. G. Henderson and R. Meguid, “Identification of surgical site infections using electronic health record data,” *Amer. J. Infection Control*, vol. 46, no. 11, pp.1230–1235, 2018.
- [112] O. K. Danner, S. Hendren, E. Santiago, B. Nye and P. Abraham, “Physiologically-based, predictive analytics using the heart-rate-to- Systolic-Ratio significantly improves the timeliness and accuracy of sepsis prediction compared to SIRS,” *Amer. J. Surg.*, vol. 213, no. 4, pp. 617–621, 2017.
- [113] J. S. De Bruin, K.-P. Adlassnig, A. Blacky, H. Mandl, K. Fehre and W. Koller, “Effectiveness of an automated surveillance system for intensive care unit-acquired infections,” *J. Amer. Med. Inf. Assoc.*, vol. 20, no. 2, pp. 369–372, 2013.
- [114] J. S. De Bruin, K.-P. Adlassnig, A. Blacky and W. Koller, “Detecting borderline infection in an automated monitoring system for healthcare-associated infection using fuzzy logic,” *Artif. Intell. Med.*, vol. 69, pp. 33–41, May 2016.
- [115] R. J. Delahanty, J. Alvarez, L. M. Flynn, R. L. Sherwin and S. S. Jones, “Development and evaluation of a machine learning model for the early identification of patients at risk for sepsis,” *Ann. Emergency Med.*, vol. 73, no. 4, pp. 334–344, 2019.
- [116] T. Desautels, J. Calvert, J. Hoffman, M. Jay, Y. Kerem, L. Shieh, D. Shimabukuro, U. Chettipally, M. D. Feldman and C. Barton, “Prediction of sepsis in the intensive care unit with minimal electronic health record data: A machine learning approach,” *JMIR Med. Informat.*, vol. 4, no. 3, 2016.

- [117] T. Desautels, J. Hoffman, C. Barton, Q. Mao, M. Jay, J. Calvert, and R. Das, “Detecting pathogen exposure during the non-symptomatic incubation period using physiological data,” *bioRxiv*, 2017.
- [118] E. R. Dubberke, Y. Yan, K. A. Reske, A. M. Butler, J. Doherty, V. Pham and V. J. Fraser, “Development and validation of a clostridium difficile infection risk prediction model,” *Infection Control Hospital Epidemiol.*, vol. 32, no. 4, pp.360–366, 2011.
- [119] G. J. Escobar, J. M. Baker, P. Kipnis, J. D. Greene, T. C. Mast, S. B. Gupta, N. Cossrow, V. Mehta, V. Liu and E. R. Dubberke, “Pre- diction of recurrent clostridium difficile infection using comprehensive electronic medical records in an integrated healthcare delivery system,” *Infection Control Hospital Epidemiol.*, vol. 38, no. 10, pp. 1196–1203, 2017.
- [120] S. Ghosh, J. Li, L. Cao, and K. Ramamohanarao, “Septic shock prediction for ICU patients via coupled HMM walking on sequential contrast patterns,” *J. Biomed. Inform.*, vol. 66, pp. 19–31, 2017.
- [121] K. K. Giuliano, “Physiological monitoring for critically ill patients: Test- ing a predictive model for the early detection of sepsis,” *Amer. J. Critical Care*, vol. 16, no. 2, pp.122–130, 2007.
- [122] J. Guillén, J. Liu, M. Furr, T. Wang, S. Strong, C. C. Moore, A. Flower and L. E. Barnes, “Predictive models for severe sepsis in adult ICU patients,” in *Proc. Syst. Inf. Eng. Design Symp.*, pp.182–187, 2015.
- [123] E. Gultepe, H. Nguyen, T. Albertson and I. Tagkopoulos, “A Bayesian network for early diagnosis of sepsis patients: A basis for a clinical decision support system,” in *Proc. IEEE 2nd Int. Conf. Comput. Adv. Bio Med. Sci.*, pp.1–5, 2012.
- [124] E. Gultepe, J. P. Green, H. Nguyen, J. Adams, T. Albertson and I. Tagkopoulos, “From vital signs to clinical outcomes for patients with sepsis: A machine learning basis for a clinical decision support system,” *J. Amer. Med Inf. Assoc.*, vol. 21, no. 2, pp. 315–325, 2014.

- [125] A. V. Gundlapalli, H. Tang, C. Tonnierre, G. Stoddard, R. T. Rolfs, R. S. Evans and M. H. Samore, “Validity of electronic medical record- based rules for the early detection of meningitis and encephalitis,” in *Proc. AMIA Annu. Symp.*, vol. 2007, p. 299, 2007.
- [126] A. V. Gundlapalli, G. Divita, A. Redd, M. E. Carter, D. Ko, M. Rubin, M. Samore, J. Strymish, S. Krein, K. Gupta, A. Sales and B. W. Trautner, “Detecting the presence of an indwelling urinary catheter and urinary symptoms in hospitalized patients using natural language processing,” *J. Biomed. Informat.*, vol. 71, pp. S39–S45, 2017.
- [127] K. Gunnarsdottir, V. Sadashivaiah, M. Kerr, S. Santaniello and S. V. Sarma, “Using demographic and time series physiological features to classify sepsis in the intensive care unit,” in *Proc. IEEE 38th Annu. Int. Conf. Eng. Med. Biol. Soc.*, pp.778–782, 2016.
- [128] A. Gupta, T. Liu and S. Shepherd, “Clinical decision support system to assess the risk of sepsis using tree augmented Bayesian networks and electronic medical record data,” *Health Informat. J.*, 2019.
- [129] T. Hartvigsen, C. Sen, S. Brownell, E. Teeple, X. Kong and E. A. Rundensteiner, “Early prediction of MRSA infections using electronic health records,” in *Proc. 11th Int. Joint Conf. Biomed. Eng. Syst. Technol.*, vol. 5, pp. 156–167, 2018.
- [130] C. Hebert, H. Du, L. R. Peterson and A. Robicsek, “Electronic health record–based detection of risk factors for clostridium difficile infection relapse,” *Infection Control Hospital Epidemiol.*, vol. 340, no. 4, pp. 407–414, 2013.
- [131] S. Horng, D. A. Sontag, Y. Halpern, Y. Jernite, N. I. Shapiro and L. A. Nathanson, “Creating an automated trigger for sepsis clinical deci- sion support at emergency department triage using machine learning,” *PLoS ONE*, vol. 12, no. 4, 2017.
- [132] Y. Hu, V. C. Lee and K. Tan, “An application of convolutional neural networks for the early detection of late-onset neonatal sepsis,” in *Proc. Int. Joint Conf. Neural Netw. (IJCNN)*, 2019.

- [133] Z. Hu, G. J. Simon, E. G. Arsoniadis, Y. Wang, M. R. Kwaan and G. B. Melton, “Automated detection of postoperative surgical site infections using supervised methods with electronic health record data,” *Stud. Health Technol. Informat.*, vol. 216, p. 706, 2015.
- [134] Z. Hu, G. B. Melton, E. G. Arsoniadis, Y. Wang, M. R. Kwaan, and G. J. Simon, “Strategies for handling missing clinical data for automated surgical site infection detection from the electronic health record,” *J. Biomed. Inform.*, vol. 68, pp.112–120, 2017.
- [135] R. Jouffroy, A. Saade, S. Ellouze, A. Carpentier, M. Michaloux, P. Carli and B. Vivien, “Prehospital triage of septic patients at the SAMU regulation: Comparison of qSOFA, MRST, MEWS and PRESEP scores,” *Amer. J. Emergency Med.*, vol. 36, no. 5, pp.820–824, 2018.
- [136] H. J. Kam and H. Y. Kim, “Learning representations for the early detection of sepsis with deep neural networks,” *Comput. Biol. Med.*, vol. 89, pp.248–255, 2017.
- [137] R. Kamaleswaran, O. Akbilgic, M. A. Hallman, A. West, R. L. Davis and S. H. Shah, “Applying artificial intelligence to identify physiomarkers predicting severe sepsis in the PICU,” *Pediatric Clin. Care Med.*, vol. 19, no. 10, pp.e495–e503, 2018.
- [138] C. Ke, Y. Jin, H. Evans, B. Lober, X. Qian, J. Liu, and S. Huang, “Prognostics of surgical site infections using dynamic health data,” *J. Biomed. Informat.*, vol. 65, pp.22–33, 2017.
- [139] F. Khoshnevisan, J. Ivy, M. Capan, R. Arnold, J. Huddleston and M. Chi, “Recent temporal pattern mining for septic shock early prediction,” in *Proc. IEEE Int. Conf. Healthcare Informat.*, pp.229–240, 2018.
- [140] J. Kim, J. Blum, and C. Scott, “Temporal features and kernel methods for predicting sepsis in postoperative patients,” Univ. Michigan Tech. Rep., 2010.

- [141] P. Kocbek, N. Fijacko, C. Soguero-Ruiz, K. Ø. Mikalsen, U. Maver, P. P. Brzan, A. Stozer, R. Jenssen, S. O. Skrøvseth and G. Stiglic, “Maximizing interpretability and cost-effectiveness of surgical site infection (SSI) predictive models using feature-specific regularized logistic regression on preoperative temporal data,” *Comput. Math. Methods Med.*, vol. 2019, pp.1–13, 2019.
- [142] F. Lamping, T. Jack, N. Rübsamen, M. Sasse, P. Beerbaum, R. T. Mikolajczyk, M. Boehne and A. Karch, “Development and validation of a diagnostic model for early differentiation of sepsis and non-infectious SIRS in critically ill children—A data-driven approach using machine-learning algorithms,” *BMC Pediatrics*, vol. 180, no. 1, 2018.
- [143] S. Le, J. Hoffman, C. Barton, J. C. Fitzgerald, A. Allen, E. Pellegrini, J. Calvert and R. Das, “Pediatric severe sepsis prediction using machine learning,” *Frontiers Pediatrics*, vol. 7, 2019.
- [144] C. Lin, Y. Zhang, J. Ivy, M. Capan, R. Arnold, J. M. Huddleston and M. Chi, “Early diagnosis and prediction of sepsis shock by combining static and dynamic information using convolutional-LSTM,” in *Proc. IEEE Int. Conf. Healthcare Informat.*, pp.219–228, 2018.
- [145] G. Liu, Y. Xu, X. Wang, X. Zhuang, H. Liang, Y. Xi, F. Lin, L. Pan, T. Zeng and H. Li, “Developing a machine learning system for identification of severe hand, foot, and mouth disease from electronic medical record data,” *Sci. Rep.*, vol. 7, no. 1, 2017.
- [146] Y.-S. Lo, W.-S. Lee and C.-T. Liu, “Utilization of electronic medical records to build a detection model for surveillance of healthcare- associated urinary tract infections,” *J. Med. Syst.*, vol. 37, no. 2, 2013.
- [147] F. López-Martínez, E. R. Núñez-Valdez, J. L. Gomez and V. García-Díaz, “A neural network approach to predict early neonatal sepsis,” *Comput. Electr. Eng.*, vol. 76, pp.379–388, 2019.

- [148] H.-M. Lu, C.-P. Wei and F.-Y. Hsiao, “Modeling healthcare data using multiple-channel latent Dirichlet allocation,” *J. Biomed. Informat.*, vol. 60, pp.210–223, 2016.
- [149] R. A. Lukaszewski, A. M. Yates, M. C. Jackson, K. Swinger, J. M. Scherer, A. J. Simpson, P. Sadler, P. Mcquillan, R. W. Titball, T. J. G. Brooks and M. J. Pearce, “Presymptomatic prediction of sepsis in intensive care unit patients,” *Clin. Vaccine Immunol.*, vol. 15, no. 7, pp.1089–1094, 2008.
- [150] S. Mani, A. Ozdas, C. Aliferis, H. A. Varol, Q. Chen, R. Carnevale, Y. Chen, J. Romano-Keeler, H. Nian and J.-H. Weitkamp, “Medical decision support using machine learning for early detection of late-onset neonatal sepsis,” *J. Amer. Med. Inf. Assoc.*, vol. 21, no. 2, pp.326–336, 2014.
- [151] G. Mansingh, K.-M. Osei-Bryson and H. Reichgelt, “Using ontologies to facilitate post-processing of association rules by domain experts,” *Inf. Sci.*, vol. 181, no. 3, pp.419–434, Feb. 2011.
- [152] Q. Mao, M. Jay, J. L. Hoffman, J. Calvert, C. Barton, D. Shimabukuro, L. Shieh, U. Chettipally, G. Fletcher, Y. Kerem, Y. Zhou and R. Das, “Multicentre validation of a sepsis prediction algorithm using only vital sign data in the emergency department, general ward and ICU,” *BMJ Open*, vol. 8, no. 1, 2018.
- [153] A. J. Masino, M. C. Harris, D. Forsyth, S. Ostapenko, L. Srinivasan, C. P. Bonafide, F. Balamuth, M. Schmatz and R. W. Grundmeier, “Machine learning models for early sepsis recognition in the neonatal intensive care unit using readily available electronic health record data,” *PLoS ONE*, vol. 14, no. 2, 2019.
- [154] T. Matsui, Y. Hakozaki, S. Suzuki, T. Usui, T. Kato, K. Hasegawa, Y. Sugiyama, M. Sugamata and S. Abe, “A novel screening method for influenza patients using a newly developed non-contact screening system,” *J. Infection*, vol. 60, no. 4, pp.271–277, 2010.
- [155] W. J. Meurer, B. L. Smith, E. D. Losman, D. Sherman, J. D. Yaksich Rn, J. D. Jared, P. N. Malani and J. G. Younger, “Real-time identification of serious infection in

geriatric patients using clinical information system surveillance,” *J. Amer. Geriatrics Soc.*, vol. 57, no. 1, pp.40–45, 2009.

- [156] K. Øyvind Mikalsen, C. Soguero-Ruiz, F. Maria Bianchi, A. Revhaug and R. Jenssen, “An unsupervised multivariate time series kernel approach for identifying patients with surgical site infection from blood samples,” *arXiv:1803.07879*, 2018.
- [157] L. Milechin, S. Davis, T. Patel, M. Hernandez, G. Ciccarelli, S. Schwartz, S. Samsi, L. Hensley, A. Goff and J. Trefry, “Detecting pathogen exposure during the non-symptomatic incubation period using physiological data,” *bioRxiv*, 2017.
- [158] S. Mitchell, K. Schinkel, Y. Song, Y. Wang, J. Ainsworth, T. Halbert, S. Strong, J. Zhang, C. C. Moore and L. E. Barnes, “Optimization of sepsis risk assessment for ward patients,” in *Proc. IEEE Syst. Inf. Eng. Design Symp.*, pp.107–112, 2016.
- [159] M. Monsalve, S. Pemmaraju, S. Johnson and P. M. Polgreen, “Improving risk prediction of *Clostridium difficile* infection using temporal event-pairs,” in *Proc. Int. Conf. Healthcare Inform.*, pp. 140–149, 2015.
- [160] T. Mulder, M. F. Kluytmans-van den Bergh, M. S. Van Mourik, J. Romme, R. M. Crolla, M. J. Bonten and J. A. Kluytmans, “A diagnostic algorithm for the surveillance of deep surgical site infections after colorectal surgery,” *Infection Control Hospital Epidemiol.*, vol. 40, no. 5, pp.574–578, 2019.
- [161] X. Na, A. J. Martin, S. Sethi, L. Kyne, K. W. Garey, S. W. Flores, M. Hu, D. N. Shah, K. Shields, D. A. Leffler and C. P. Kelly, “A multi-center prospective derivation and validation of a clinical prediction tool for severe *clostridium difficile* infection,” *PLoS ONE*, vol. 10, no. 4, Apr. 2015.
- [162] S. K. Nachimuthu and P. J. Haug, “Early detection of sepsis in the emergency department using dynamic Bayesian networks,” in *Proc. AMIA Annu. Symp.*, 2012.
- [163] V. Q. Nguyen, S. Abe, G. Sun, A. Matsuoka, H. Nishimura, M. Ishihara and T. Matsui, “Rapid screening for influenza using a multivariable logistic regression model to save

labor at a clinic in Iwaki, Fukushima, Japan,” *Amer. J. Infection Control*, vol. 42, no. 5, pp.551–553, 2014.

- [164] J. Oh, M. Makar, C. Fusco, R. McCaffrey, K. Rao, E. E. Ryan, L. Washer, L. R. West, V. B. Young and J. Guttag, “A generalizable, data-driven approach to predict daily risk of clostridium difficile infection at two large academic health centers,” *Infection Control Hospital Epidemiology*, vol. 390, no. 4, pp.425–433, 2018.
- [165] J. D. Parente, K. Möller, G. M. Shaw and J. G. Chase, “Hidden Markov models for sepsis classification,” *IFAC-Papers OnLine*, vol. 510, no. 27, pp.110–115, 2018.
- [166] J. P. Parreco, A. E. Hidalgo, A. D. Badilla, O. Ilyas and R. Rattan, “Predicting central line-associated bloodstream infections and mortality using supervised machine learning,” *J. Critical Care*, vol. 45, pp.156–162, 2018.
- [167] C. Paxton, A. Niculescu-Mizil and S. Saria, “Developing predictive models using electronic medical records: Challenges and pitfalls,” in *Proc. AMIA Annu. Symp.*, 2013.
- [168] V. Prasad, J. C. Lynch, C. L. Pasakarnis, J. E. Thorsen, M. R. Filbin, A. T. Reisner and T. Heldt, “Classification models to predict vaso- pressor administration for septic shock in the emergency department,” in *Proc. 39th Annu. Int. Conf. IEEE Eng. Med. Biol. Soc.*, pp.2650–2653, 2017.
- [169] S. Rabhi, J. Jakubowicz and M.-H. Metzger, “Deep learning versus conventional machine learning for detection of healthcare-associated infections in french clinical narratives,” *Methods Inf. Med.*, vol. 58, no. 1, pp.31–41, 2019.
- [170] P. C. Sanger, M. Granich, R. Olsen-Scribner, R. J. W. B. Lober, A. Stapleton and P. S. Pottinger, “Electronic surveillance for catheter-associated urinary tract infection using natural language processing,” in *Proc. AMIA Annu. Symp.*, pp.1507–1516, 2018.

- [171] P. C. Sanger, G. H. Van Ramshorst, E. Mercan, S. Huang, A. L. Hart- zler, C. A. Armstrong, R. J. Lordon, W. B. Lober and H. L. Evans, “A prognostic model of surgical site infection using daily clinical wound assessment,” *J. Amer. College Surgeons*, vol. 223, no. 2, pp. 259–270, 2016.
- [172] L. Saunders, M. Perennec-Olivier, P. Jarno, F. L’Hériteau, A.-G. Venier, L. Simon, M. Giard, J.-M. Thiolet and J.-F. Viel, “Improving prediction of surgical site infection risk with multilevel modeling,” *PLoS ONE*, vol. 9, no. 5, 2014.
- [173] M. Scherpf, F. Gräßer, H. Malberg and S. Zaunseder, “Predicting sepsis with a recurrent neural network using the MIMIC III database,” *Comput. Biol. Med.*, vol. 113, 2019.
- [174] C. A. M. Schurink, S. Visscher, P. J. F. Lucas, H. J. Van Leeuwen, E. Buskens, R. G. Hoff, A. I. M. Hoepelman and M. J. M. Bonten, “A Bayesian decision-support system for diagnosing ventilator-associated pneumonia,” *Intensive Care Med.*, vol. 33, no. 8, pp.1379–1386, 2007.
- [175] C. Sen, T. Hartvigsen, E. Rundensteiner and K. Claypool, “CREST— Risk prediction for Clostridium difficile infection using multimodal data mining,” in *Proc. Joint Eur. Conf. Mach. Learn. Knowl. Discovery Databases. Cham, Switzerland: Springer*, pp. 52–63, 2017.
- [176] P. R. Shankar, A. Kesari, P. Shalini, N. Kamalashree, C. Bharadwaj, N. Raj, S. Srinivas, M. Shivakumar, A. R. Ulle and N. N. Tagadur, “Predictive modeling of surgical site infections using sparse laboratory data,” *Int. J. Big Data Anal. Healthcare*, vol. 3, no. 1, pp.13–26, 2018.
- [177] S. P. Shashikumar, M. D. Stanley, I. Sadiq, Q. Li, A. Holder, G. D. Clifford and S. Nemati, “Early sepsis detection in critical care patients using multiscale blood pressure and heart rate dynamics,” *J. Electrocardiol.*, vol. 50, no. 6, pp.739–743, 2017.

- [178] D. W. Shimabukuro, C. W. Barton, M. D. Feldman, S. J. Mataraso and R. Das, “Effect of a machine learning-based severe sepsis prediction algorithm on patient survival and hospital length of stay: A randomised clinical trial,” *BMJ Open Respiratory Res.*, vol. 4, no. 1, 2017.
- [179] C. Soguero-Ruiz, W. M. Fei, R. Jenssen, K. M. Augestad, J.-L. R. Álvarez, I. M. Jiménez, R.-O. Lindsetmo and S. O. Skrøvseth, “Data-driven temporal prediction of surgical site infection,” in *Proc. AMIA Annu. Symp.*, 2015.
- [180] I. Stanculescu, C. K. I. Williams and Y. Freer, “Autoregressive hidden Markov models for the early detection of neonatal sepsis,” *IEEE J. Biomed. Health Inform.*, vol. 18, no. 5, pp.1560–1570, 2014.
- [181] I. Stanculescu, C. K. Williams and Y. Freer, “A hierarchical switching linear dynamical system applied to the detection of sepsis in neonatal condition monitoring,” in *Proc. 30th Conf. Uncertainty Artif. Intell.*, pp. 752–761, 2014.
- [182] A. S. Strauman, F. M. Bianchi, K. Ø. Mikalsen, M. Kampffmeyer, C. Soguero-Ruiz and R. Jenssen “Classification of postoperative surgical site infections from blood measurements with missing data using recurrent neural networks,” *arXiv:1711.06516* 2017.
- [183] G. Sun, N. Abe, Y. Sugiyama, Q. V. Nguyen, K. Nozaki, Y. Nakayama, O. Takei, Y. Hakozaiki, S. Abe and T. Matsui, “Development of an infection screening system for entry inspection at airport quarantine stations using ear temperature, heart and respiration rates,” in *Proc. 35th Annu. Int. Conf. IEEE Eng. Med. Biol. Soc.*, pp.6716–6719, 2013.
- [184] G. Sun, Y. Yao, R. Yoshinaka, M. Ikegami, S. Kim, M. Schiek and T. Matsui, “A pediatric infection screening system with a radar respiration monitor for rapid detection of seasonal influenza among outpatient children,” *J. Infectious Diseases Therapy*, 2014.

- [185] G. Sun, T. Matsui, Y. Hakozaiki and S. Abe, “An infectious disease/fever screening radar system which stratifies higher-risk patients within ten seconds using a neural network and the fuzzy grouping method,” *J. Infection*, vol. 70, no. 3, pp.230–236, 2015.
- [186] G. Sun, K. Miyata, A. Matsuoka, Z. Zhao, S. Iwakami, S. Kim and T. Matsui, “A compact and hand-held infection-screening system for use in rapid medical inspection at airport quarantine stations: System design and preliminary validation,” *J. Med. Eng. Technol.*, vol. 39, no. 3, pp.185–190, 2015.
- [187] A. Swiston, Jr., L. E. Milechin, S. Davis, T. Patel, M. Hernandez, G. Ciccarelli, S. Schwartz, L. Hensley, A. Goff, and J. Trefry, “Detecting virus exposure during the pre-symptomatic incubation period using physiological data,” *MIT Lincoln Lab., Lexington, MA, USA, Tech. Rep.*, 2016.
- [188] I. Taneja, B. Reddy, G. Damhorst, S. D. Zhao, U. Hassan, Z. Price, T. Jensen, T. Ghonge, M. Patel and S. Wachspress, “Combining biomarkers with EMR data to identify patients in different phases of sepsis,” *Sci. Rep.*, vol. 70, no. 1, 2017.
- [189] J. Tanner, D. Khan, D. Anthony and J. Paton, “Waterlow score to predict patients at risk of developing *Clostridium difficile*-associated disease,” *J. Hospital Infection*, vol. 71, no. 3, pp.239–244, 2009.
- [190] H. Tou, L. Yao, Z. Wei, X. Zhuang and B. Zhang, “Automatic infection detection based on electronic medical records,” *BMC Bioinf.*, vol. 19, no. 5, 2018.
- [191] W. E. Trick, B. M. Zagorski, J. I. Tokars, M. O. Vernon, S. F. Welbel, M.F. Wisniewski, C. Richards and R. A. Weinstein, “Computer algorithms to detect bloodstream infections,” *Emerg. Infect. Diseases*, vol. 10, no. 9, pp.1612–1620, 2012.
- [192] N. Tvardik, I. Kergourlay, A. Bittar, F. Segond, S. Darmoni and M.-H. Metzger, “Accuracy of using natural language processing methods for identifying healthcare-associated infections,” *Int. J. Med. Informat.*, vol. 117, pp.96–102, 2018.

- [193] C. A. Umscheid, J. Betesh, C. Vanzandbergen, A. Hanish, G. Tait, M. E. Mikkelsen, B. French and B. D. Fuchs, “Development, implementation, and impact of an automated early warning and response system for sepsis,” *J. Hospital Med.*, vol. 10, no. 1, pp. 26–31, 2015.
- [194] F.-M.-E. Uzoka, J. Osuji and O. Obot, “Clinical decision support system (DSS) in the diagnosis of malaria: A case comparison of two soft computing methodologies,” *Expert Syst. Appl.*, vol. 38, no. 3, pp.1537–1553, 2011.
- [195] F. van Wyk, A. Khojandi, R. L. Davis and R. Kamaleswaran, “Physiomarkers in real-time physiological data streams predict adult sepsis onset earlier than clinical practice,” *bioRxiv*, 2018.
- [196] F. van Wyk, A. Khojandi, R. Kamaleswaran, O. Akbilgic, S. Nemati and R. L. Davis, “How much data should we collect? A case study in sepsis detection using deep learning,” in *Proc. IEEE Healthcare Innov. Point Care Technol.*, pp.109–112, 2017.
- [197] L. Ward, M. Paul and S. Andreassen, “Automatic learning of mortality in a CPN model of the systemic inflammatory response syndrome,” *Math. Biosci.*, vol. 284, pp.12–20, 2017.
- [198] J. Wiens, E. Horvitz and J. V. Guttag, “Patient risk stratification for hospital-associated C. diff as a time-series classification task,” in *Proc. Adv. Neural Inf. Process. Syst.*, vol. 25, pp.467–475, 2012.
- [199] J. Wiens, W. N. Campbell, E. S. Franklin, J. V. Guttag and E. Horvitz, “Learning data-driven patient risk stratification models for Clostridium difficile,” *Open Forum Infectious Diseases*, vol. 1, no. 2, 2014.
- [200] Y. Yao, G. Sun, T. Matsui, Y. Hakoziaki, S. Van Waasen and M. Schiek, “Multiple vital-sign-based infection screening outperforms thermography independent of the classification algorithm,” *IEEE Trans. Biomed. Eng.*, vol. 63, no. 5, pp.1025–1033, 2016.

- [201] C. R. Yee, N. R. Narain, V. R. Akmaev and V. Vemulapalli, “A data- driven approach to predicting septic shock in the intensive care unit,” *Biomed Inf. Insights*, vol. 11, 2019.
- [202] N. Binti Mohd Zainee and K. Chellappan, “A preliminary dengue fever prediction model based on vital signs and blood profile,” in *Proc. IEEE EMBS Conf. Biomed. Eng. Sci.*, pp. 652–656, 2016.
- [203] B. Zhang, X. Wan, F.-S. Ouyang, Y.-H. Dong, D.-H. Luo, J. Liu, L. Liang, W.-B. Chen, X.-N. Luo, X.-K. Mo, L. Zhang, W.-H. Huang, S.-F. Pei, B.-L. Guo, C.-H. Liang, Z.-Y. Lian and S.-X. Zhang, “Machine learning algorithms for risk prediction of severe hand-foot-mouth disease in children,” *Sci. Rep.*, vol. 70, no. 1, 2017.
- [204] Y. Zhang, C. Lin, M. Chi, J. Ivy, M. Capan, and J. M. Huddleston, “LSTM for septic shock: Adding unreliable labels to reliable predictions,” in *Proc. IEEE Int. Conf. Big Data*, Dec. 2017, pp. 1233–1242.
- [205] W. Robson and J. Newell, “Assessing, treating and managing patients with sepsis,” *Nursing Standard*, vol. 19, no. 50, pp.56-64, 2005.
- [206] X. Fang, Z. Wang, J. Yang, H. Cai, Z. Yao, K. Li and Q. Fang, “Clinical Evaluation of Sepsis-1 and Sepsis-3 in the Intensive Care Unit,” *Chest*, vol. 153, no. 5, pp.1169-1176, 2018.
- [207] S. Nemati, A. Holder, F. Razmi, M. D. Stanley, G. D. Clifford and T. G. Buchman, “An interpretable machine learning model for accurate prediction of sepsis in the ICU,” *Crit Care Med.*, vol. 46, no. 4, pp.547–53, 2018.
- [208] J. Arwyn-Jones et al., “Sepsis, Surgery,” *Oxford International Edition*, Vol.37, no. 1, pp.1 – 8, 2019.
- [209] S. Kumar, S. Tripathy, A. Jyoti and S. G. Singh, “Recent advances in biosensors for diagnosis and detection of sepsis: a comprehensive review,” *Biosens Bioelectron*, vol. 124, pp.205-215, 2019.

- [210] H. R. Hassan, J. R. Gohil, R. Desai, R. R. Mehta, V. P. Chaudhary, "Correlation of blood culture results with the sepsis score and sepsis screen in the diagnosis of early-onset neonatal septicemia," *J Clin Neonatol*, vol. 5, pp.193-198, 2016.
- [211] M. Singer, C. S. Deutschman, C. W. Seymour, et al., "The Third International Consensus Definitions for Sepsis and Septic Shock (Sepsis-3)," *JAMA*, vol. 315, no. 8, pp.801–810, 2016.
- [212] I. Toshiaki, M. Arakawa, K. Mochizuki, O. Nishida, H. Wada and Jerrold H. Levy, "Usefulness of Measuring Changes in SOFA Score for the Prediction of 28-Day Mortality in Patients with Sepsis-Associated Disseminated Intravascular Coagulation," *Clinical and Applied Thrombosis/Hemostasis*, 2019.
- [213] Z. Liu, Z. Meng, Y. Li, et al., "Prognostic accuracy of the serum lactate level, the SOFA score and the qSOFA score for mortality among adults with Sepsis," *Scand. J. Trauma Resusc. Emerg. Med.*, vol. 27, no.51, 2019.
- [214] B. Khwannimit, R. Bhurayanontachai and V. Vattanavanit, "Comparison of the performance of SOFA, qSOFA and SIRS for predicting mortality and organ failure among sepsis patients admitted to the intensive care unit in a middle-income country," *Journal of Critical Care*, vol. 44, pp.156-160, 2018.
- [215] J. L. Vincent, A. de Mendonça, F. Cantraine, et al., "Use of the SOFA score to assess the incidence of organ dysfunction/failure in intensive care units: results of a multicenter, prospective study. Working group on "sepsis-related problems" of the European Society of Intensive Care Medicine," *Crit Care Med.*, vol. 26, no. 11, pp.1793-800, 1998.
- [216] B. Shickel, T. J. Loftus, L. Adhikari, T. Ozrazgat-Baslanti, A. Bihorac and P. Rashidi, "DeepSOFA: A Continuous Acuity Score for Critically Ill Patients using Clinically Interpretable Deep Learning," *Sci Rep.*, vol. 9, no.1879, 2019.

- [217] V. J. R. Ripoll, A. Vellido, E. Romero and J. C. Ruiz-Rodríguez, “Sepsis mortality prediction with the Quotient Basis Kernel,” *Artificial Intelligence in Medicine*, vol.61, pp.45–52, 2014.
- [218] A. de Mendonça, J. Vincent, P. Suter, et al. “Acute renal failure in the ICU: risk factors and outcome evaluated by the SOFA score,”. *Intensive Care Med*, vol. 26, pp.915–921 2000.
- [219] M. Moor, M. Horn, B. Rieck, D. Roqueiro and K. Borgwardt, “Temporal Convolutional Networks and Dynamic Time Warping can Drastically Improve the Early Prediction of Sepsis,” *Proceedings of Machine Learning Research*, 2019.
- [220] J. Futoma, S. Hariharan and K. Heller, “Learning to Detect Sepsis with a Multitask Gaussian Process RNN Classifier,” in: *Proceedings of the 34 th International Conference on Machine Learning*, 2017.
- [221] T. Van Steenkiste, J. Ruyssinck, L. De Baets, J. Decruyenaere, F. De Turck, F. Ongenaes and T. Dhaene, “Accurate prediction of blood culture outcome in the intensive care unit using long short-term memory neural networks,” *Artificial Intelligence in Medicine*, vol. 97, pp. 38-43, 2019.
- [222] S. Schamonia, H. A. Lindner, V. Schneider-Lindner, M. Thiel and S. Riezlera, “Leveraging implicit expert knowledge for non-circular machine learning in sepsis prediction,” *Artificial Intelligence in Medicine*, vol. 100, 2019.
- [223] V. J. R Ripoll, A. Vellido, E. Romero and J. C. Ruiz-Rodríguez, “Sepsis mortality prediction with the Quotient Basis Kernel”, *Artificial Intelligence in Medicine*, vol. 61, no. 1, pp.45-52, 2014.
- [224] Gait in Parkinson's Disease. <https://physionet.org/pn3/gaitpdb/> (Accessed: Jun. 14, 2020)

- [225] J. M. Hausdorff, J. Balash and N. Giladi, "Effects of Cognitive Challenge on Gait Variability in Patients with Parkinson's Disease," *Journal of Geriatric Psychiatry and Neurology*, vol. 16, no. 1, pp.53 – 58, 2003.
- [226] J. Bae and M. Tomizuka, "Gait phase analysis based on a Hidden Markov Model," *Mechatronic*, vol. 21, 961–970, 2011.
- [227] J. Bae and M. Tomizuka, "A tele-monitoring system for gait rehabilitation with an inertial measurement unit and a shoe-type ground reaction force sensor," *Mechatronics*, vol. 23, pp.646–651, 2013.
- [228] B. Chen, X. Wang, Y. Huang, K. Wei, Q. Wang, X. Wang, et al. "A foot-wearable interface for locomotion mode recognition based on discrete contact force distribution," *Mechatronics*, vol. 32, pp.12-21, 2015.
- [229] B. Galna, S. Lord and L. Rochester, "Is gait variability reliable in older adults and Parkinson's disease? Towards an optimal testing protocol," *Gait Posture*, vol. 37, no. 4, pp.580-585, 2013.
- [230] A. E. Johnson, T. J. Pollard, L. Shen, et al., "MIMIC-III, a freely accessible critical care database", *Sci Data*, vol. 3, no.160035, 2016.
- [231] M. Saeed, M. Villarroel, A. T. Reisner, G. Clifford, L. Lehman, G. B. Moody, T. Heldt, T. H. Kyaw, B. E. Moody and R. G. Mark, "Multiparameter intelligent monitoring in intensive care II (MIMIC-II): A public-access ICU database," *Critical Care Medicine*, vol. 39, no. 5, pp.952-960, 2011.
- [232] E. W. Johnson, J. Aboab, J. D. Raffa et al., "A Comparative Analysis of Sepsis Identification Methods in an Electronic Database". *Crit Care Med.*, vol. 46, no. 4, pp.494-499, 2018.
- [233] Yasser Khan, A. E. Ostfeld, C. M. Lochner, A. Pierre and A. C. Arias, "Monitoring of Vital Signs with Flexible and Wearable Medical Devices," *Advanced Materials*, vol. 28, no. 22, pp.4373-4395, 2016.

- [234] Z. Wang, Z. Yang and T. Dong, "A Review of Wearable Technologies for Elderly Care that Can Accurately Track Indoor Position, Recognize Physical Activities and Monitor Vital Signs in Real Time," *Sensors*, vol. 17, no. 341, 2017.
- [235] D. Xiaorong, et al., "Continuous Blood Pressure Measurement From Invasive to Unobtrusive: Celebration of 200th Birth Anniversary of Carl Ludwig," *IEEE Journal of Biomedical and Health Informatics*, vol. 20, no. 6, pp.1455-1465, 2016.
- [236] P. Vasandani, et al. "Triboelectric Nanogenerator Using Microdome-Patterned PDMS as a Wearable Respiratory Energy Harvester," *Advanced Materials Technologies*, vol. 2, no. 6, 2017.
- [237] W. Natthapol, T. Lomas, A. Wisitsoraat and Adisorn Tuantranont, "Wireless wearable pulse oximeter for health monitoring using ZigBee wireless sensor network," in *ECTI-CON2010: The 2010 ECTI International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology*, pp.575-579, 2010.
- [238] F. C. M. Reith, R. Van den Brande, A. Synnot, R. Gruen and A. I. R. Maas, "The reliability of the Glasgow Coma Scale: a systematic review," *Intensive Care Med*, vol. 42, pp.3–15, 2016.
- [239] G. Teasdale, A. Maas, F. Lecky, G. Manley, N. Stocchetti and G. Murray, "The Glasgow Coma Scale at 40 years: standing the test of time," *Lancet Neurol.*, vol. 13, no. 8, pp.844-54, 2014.
- [240] S. Y. Sim, M. J. Koh, K. M. Joo, S. Noh, S. Park, Y. H. Kim and K. S. Park, "Estimation of Thermal Sensation Based on Wrist Skin Temperatures," *Sensors* vol. 16, no. 420, 2016.
- [241] H. Zhen, G. B. Melton, E. G. Arsoniadis, Y. Wang, M. R. Kwaan and G. J. Simon, "Strategies for handling missing clinical data for automated surgical site infection

detection from the electronic health record,” *J Biomed Inform.*, vol. 68, pp. 112–120, 2017.

- [242] J. C. Ho, C. H. Lee and J. Ghosh, “Imputation-enhanced prediction of septic shock in ICU patients,” in: *Proc. of the ACM SIGKDD Workshop on Health Informatics (HI-KDD12)*, 2012.
- [243] J. C. Ho, C. H. Lee and J. Ghosh, “Septic shock prediction for patients with missing data,” *ACM Transactions on Management Information Systems (TMIS)*, vol. 5, no.1, 2014.
- [244] O. G. Troyanskaya, M. Cantor, G. Sherlock, P. O. Brown, T. Hastie, R. Tibshirani, D. Botstein and R. B. Altman, “Missing value estimation methods for DNA microarrays,” *Bioinformatics*, vol. 17, no. 6, pp.520-525, 2001.
- [245] M. E. Tipping and C. M. Bishop, “Probabilistic principal component analysis,” *J. R. Stat. Soc., Ser. B*, vol. 21, no. 3, pp.611–622, 1999.
- [246] P. Loukopoulos et al., "Dealing with missing data for prognostic purposes," in: *2016 Prognostics and System Health Management Conference (PHM-Chengdu)*, pp. 1-5, 2016.
- [247] L. Qu, L. Li, Y. Zhang and J. Hu, "PPCA-Based Missing Data Imputation for Traffic Flow Volume: A Systematical Approach," *IEEE Transactions on Intelligent Transportation Systems*, vol. 10, no. 3, pp.512-522, 2009.
- [248] D. Figo, P. C. Diniz, D. R. Ferreira and J. M. P. Cardoso, “Preprocessing techniques for context recognition from accelerometer data,” *Personal and Ubiquitous Computing*, vol. 14, no.7, pp.645-662, 2010.
- [249] H. Oğul, A. Baldominos, T. Aşuroğlu and R. Colomo-Palacios, "On Computer-Aided Prognosis of Septic Shock from Vital Signs," in: *IEEE 32nd International Symposium on Computer-Based Medical Systems (CBMS)*, pp. 87-92, 2019.

- [250] S. Krishnan and Y. Athavale, "Trends in biomedical signal feature extraction," *Biomedical Signal Processing and Control*, vol. 43, pp.41-63, 2018.
- [251] X. Wan, X. Wang, J. Liu and T. Tong, "Estimating the sample mean and standard deviation from the sample size, median, range and/or interquartile range," *BMC Medical Research Methodology*, vol. 14, no. 135, 2014.
- [252] S. J. Preece, J. Y. Goulermas, L. P. J. Kenney and D. Howard, "A Comparison of Feature Extraction Methods for the Classification of Dynamic Activities From Accelerometer Data," *IEEE Transactions On Biomedical Engineering* vol. 56, no. 3, pp.871-879, 2009.
- [253] E. A. E. Habib, "Correlation coefficients based on mean absolute deviation about median," *International Journal of Statistics and Systems*, vol. 6, no. 4, pp.413–428, 2011.
- [254] A. Celikoglu and U. Tirnakli, "Skewness and kurtosis analysis for non-Gaussian distributions," *Physica A*, vol. 499, pp.325–334, 2018.
- [255] L. L. Scharf, "Statistical Signal Processing Detection, Estimation, and Time Series Analysis" 1st ed. Pearson; 1991.
- [256] A. Rihaczek, "Signal energy distribution in time and frequency," *IEEE Transactions on Information Theory*, vol. 14, no. 3, pp.369-374, 1968.
- [257] F. A. S. Borges, R. A. S. Fernandes, I. N. Silva and C. B. S. Silva, "Feature Extraction and Power Quality Disturbances Classification Using Smart Meters Signals," *IEEE Transactions On Industrial Informatics*, vol. 12, no. 2, pp.824-833, 2016.
- [258] B. Boashash, "Digital Control and Signal Processing Systems and Techniques," Academic Press, 1996.

- [259] T. Ojala, M. Pietikainen and T. Maenpaa, "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, no. 7, pp. 971-987, 2002.
- [260] T. Ahonen, A. Hadid and M. Pietikainen, "Face Description with Local Binary Patterns: Application to Face Recognition," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 28, no. 12, pp. 2037-2041, 2006.
- [261] N. Chatlani N and J. J. Soraghan, "Local binary patterns for 1-D signal processing," *in: 18th European Signal Processing Conference (EUSIPCO-2010)*, 2010.
- [262] L. Liu, P. Fieguth, G. Zhao, M. Pietikäinen and D. Hu, "Extended local binary patterns for face recognition," *Information Sciences*, vol. 358–359, pp. 56-72, 2016.
- [263] K. Açııcı, T. Aşuroğlu and H. Oğul, "Information retrieval in metal music sub-genres," *25th Signal Processing and Communications Applications Conference (SIU)*, 2017.
- [264] P. P. M Shanir, K. A. Khan, Y. U Khan, O. Farooq and H. Adeli, "Automatic Seizure Detection Based on Morphological Features Using One-Dimensional Local Binary Pattern on Long-Term EEG," *Clinical EEG and Neuroscience*, vol. 49, no. 5, pp. 351–362, 2018.
- [265] C. G. Atkeson, A. W. Moore and S. Schaal, "Locally weighted learning," *Artificial Intelligence Review*, vol. 11, no. 1, pp. 11-73, 1997.
- [266] P. Englert and T. Darmstadt "Locally Weighted Learning," *in: Seminar Class on Autonomous Learning Systems*, 2012.

EKLER



EK 1: ENFEKSİYONLARI BİLGİSAYAR YÖNTEMLERİYLE İNCELEYEN ÇALIŞMALAR



Kaynak	Kaynak No.	Enfeksiyon Türü	Amaç	Deneysel Kurulum	Veri kümesi	Yöntem	Öznitelikler	Performans
Amland ve Hahn-Cover, 2016	[104]	Sepsis	Erken uyarı	Hastane	Erişime açık veri kümesi (BIDMC Dataset)	SIRS kriteri	Sıcaklık, Solunum hızı, Kalp atış hızı, Tansiyon	Duyarlılık., Özgüllük., PPV, NPV 0.83, 0.92, 0.46, 0.99
Amland vd. 2015	[105]	Sepsis	Enfeksiyon tahmini	Hastane	Özel veri kümesi (University Hospital of North Norway (UNN) / Norway)	SIRS kriteri	Sıcaklık, Solunum hızı, Kalp atış hızı, Tansiyon	Duyarlılık, PPV 0.72, 0.73 (alarm öncesi); 0.81, 0.94 (alarm sonrası)
Bloch vd. 2019	[106]	Sepsis	Enfeksiyon tespiti	Hastane	Özel veri kümesi (general intensive care unit (ICU) of the tertiary-level, university-affiliated Rabin Medical Center (RMC), Petah Tikva, Israel)	LR, SVM, ANN	Sıcaklık, kalp atış hızı, Solunum hızı, Kan basıncı	AUC: 0.8838, AUCPR: 0.9358
Branch-Elliman vd. 2015	[107]	CAUTI	Erken uyarı	Hastane	Erişime açık veri kümesi (MIMIC III database)	NLP	EHR, Sıcaklık	Duyarlılık %90.9 / Doğruluk %60

Calvert vd. 2019	[108]	Sepsis	Erken uyarı	Hastane	Erişime açık veri kümesi (MIMIC III database)	GB	Laktoz ve (PCT) biyobelirteçleri	AUC: 0.917, Duyarlılık: 0.799, Özgüllük: 0.86, Doğruluk: 0.848
Calvert vd. 2016	[109]	Sepsis	Erken uyarı	Hastane	Erişime açık veri kümesi (MIMIC II database)	Kural tabanlı (Özel)	Sıcaklık, Solunum hızı, Kalp atış hızı, Oksijen satürasyonu, Tansiyon	AUC 0.92
Chang vd. 2011	[110]	Hastanede kapılan enfeksiyon	Uzaktan izleme	Hastane	Özel veri kümesi (Christiana Care Health System / USA)	LR, LDA	Demografikler, Klinik veri	AUC 0.969/Doğruluk %95.04/Duyarlı lık %97.06 /Özgüllük 96.52/PPV 90.6 /NPV 99.0
Colborn vd. 2018..	[111]	Cerrahi bölge enfeksiyonu	Enfeksiyon tespiti	Hastane	Özel veri kümesi (University of Colorado Hospital NSQIP database)	GLM	Lab testleri	Özgüllük: %90 Duyarlılık: %80 , AUC: 0.89
Danner vd. 2017	[112]	Sepsis	Tarama	Toplum sağlığı acil durumları	Özel veri kümesi (Takasaka Clinic / Japan)	LR	Sıcaklık, Solunum hızı, Kalp atış hızı, Oksijen satürasyonu, Lab testleri	Chi-Square <0.0001 / Duyarlılık %73.98

de Bruin vd. 2013	[113]	Sağlıkla ilişkili enfeksiyonlar	Erken uyarı	Hastane	Özel veri kümesi (Mayo Clinic / USA)	Kural tabanlı (özel)	Lab testleri	Duyarlılık, Özgüllük, PPV, NPV 0.87, 0.99, 0.96, 0.95
de Bruin vd. 2016	[114]	Genel Enfeksiyon	Erken uyarı	Hastane	Özel veri kümesi (Barnes-Jewish Hospital / USA)	Bulanık kurallar	Sıcaklık, Kalp atış hızı, Tansiyon, Lab testleri	p değeri<0.001
Delahanty vd. 2019	[115]	Sepsis	Uzaktan izleme	Hastane	Özel veri kümesi (49 urban community hospitals operated by Tenet Healthcare, USA)	GB	Lab testleri	AUC: 0.97
Desautels vd. 2016	[116]	Sepsis	Erken uyarı	Hastane	Erişime açık veri kümesi (MIMIC III database)	EL	Sıcaklık, Solunum hızı, Kalp atış hızı, Oksijen satürasyonu, Lab testleri	AUC 0.88/ Duyarlılık 0.8/ Özgüllük 0.80/ Doğruluk 0.80
Desautels vd. 2017	[117]	Sepsis	Erken uyarı	Hastane	Özel veri kümesi (UCSF Medical Center, USA)	RF	Demografik, Sıcaklık, Solunum hızı, Kalp atış hızı, Oksijen satürasyonu, Kan Basıncı	AUC 0.912

Dubberke vd. 2011	[118]	CDI	Uzaktan izleme	Hastane	Özel veri kümesi (University of California San Francisco Medical Center / USA)	LR	Demografikler, Lab testleri, Klinik veri, Lojistik veri	AUC 0.88
Escobar vd. 2017	[119]	CDI	Erken uyarı	Hastane	Erişime açık veri kümesi (MIMIC II database)	LR	Demografikler, Sıcaklık, Solunum hızı, Kalp atış hızı, Oksijen saturasyonu, Lab testleri, Klinik veri	C istatistiği 0.605/ R2 -0.1033 / Duyarlılık %79.17 / Özgüllük %32.04
Ghosh vd. 2017	[120]	Sepsis	Uzaktan izleme	Hastane ve tarama yapan kurumlar	Özel veri kümesi (Hospitals in Nigeria)	SVM, HMM	Solunum hızı, Kalp atış hızı, Tansiyon	p değeri 0.0014
Giuliano, 2007	[121]	Sepsis	Erken uyarı	Hastane	Özel veri kümesi (Academic teaching hospital / Netherlands)	LR	Sıcaklık, Solunum hızı, Kalp atış hızı, Tansiyon	Doğruluk %78.9
Guillén vd. 2015	[122]	Sepsis	Erken uyarı	Hastane	Özel veri kümesi (Centricity, General Electric Healthcare / USA)	LR, SVM, EL	Sıcaklık, Solunum hızı, Kalp atış hızı, Lab testleri	Duyarlılık 0.642 / Özgüllük 0.936 / PPV 0.651/ NPV 0.933 / AUC 0.871

Gultepe vd. 2012	[123]	Sepsis	Erken uyarı	Hastane	Özel veri kümesi (University of California Davis Medical Center / USA)	BN	Sıcaklık, Solunum hızı, Tansiyon, Lab testleri,Lojistik veri	Kayıp fonksiyonu 15.413
Gultepe vd. 2014	[124]	Sepsis	Erken uyarı	Hastane	Özel veri kümesi (Monroe Carell Jr. Children's Hospital at Vanderbilt University / USA)	NB, HMM, GP	Sıcaklık, Solunum hızı, Kalp atış hızı, Tansiyon, Lab testleri	GMM: AUC=0.759, ACC=0.837, F=0.906, SN=0.943, SP=0.312 NB: AUC=0.732, ACC=0.806, F=0.885, SN=0.920, SP=0.333 HMM: AUC=0.965, ACC=0.891, F=0.931, SN=0.871, SP=1.0
Gundlapalli vd. 2007	[125]	Menenjit ve Ensefalit	Karar destek	Hastane	Belirtilmemiş	Kural tabanlı (özel)	Biyomedikal sinyaller	Duyarlılık %91 / AUC 0.95
Gundlapalli vd. 2017	[126]	CAUTI	Tarama	Havaalanı Tarama	Özel veri kümesi (Self-defense Forces Hospital /Japan)	NLP	EHR	Duyarlılık %100, Keskinlik %96.5

Gunnarsdottir vd. 2016	[127]	Sepsis	Erken uyarı	Hastane	Özel veri kümesi (The University of Pennsylvania Health System (UPHS) / USA)	LiR	Solunum hızı, Kalp atış hızı, Oksijen saturasyonu, Lab testleri	Doğruluk 0.75/ Duyarlılık 1/ Özgüllük 0.5
Gupta vd. 2019	[128]	Sepsis	Uzaktan izleme	Hastane	Özel veri kümesi (Cerner Corporations HIPAA-compliant Health Facts, USA)	BN	Klinik veriler	AUC: 0.84
Hartvigsen vd. 2018	[129]	MRSA	Erken uyarı	Hastane	Özel veri kümesi (University of Iowa Hospitals and Clinics (UIHC) / USA)	LR, SVM, RF	Demografikler, Lojistik veri	AUC: 0.94
Hebert vd. 2013	[130]	CDI	Uzaktan izleme	Hastane	Özel veri kümesi (Teaching hospital in China)	LR	Demografikler, Sıcaklık, Kalp atış hızı, Tansiyon, Lab testleri, Klinik veri	AUC 0.70

Horng vd. 2017	[131]	Sepsis	Uzaktan izleme	Hastane	Özel veri kümesi (US Army Medical Research Institute of Infectious Diseases / USA)	SVM	EHR, Demografikler, Sıcaklık, Solunum hızı, Kalp atış hızı, Oksijen satürasyonu, Lab testleri	AUC 0.85
Hu vd. 2019	[132]	Sepsis	Uzaktan izleme	Hastane	Özel veri kümesi (Monash Children Hospital)	CNN, LR, SVM, RF, NN, Karar Ağacı	kalp atış hızı, Solunum hızı, Oksijen satürasyonu ve kan basıncı	Sensitivtiy: 0.7, Özgüllük: 0.61, AUC: 0.79, Keskinlik: 0.76
Hu vd. 2015	[133]	Cerrahi bölge enfeksiyonu	ölümcül olma oranını tahmin etme	Hastane	Özel veri kümesi (Beilinson Hospital/ Israel)	LR	EHR	Özgüllük 0.788-0.988, AUC 0.898
Hu vd. 2017	[134]	Cerrahi bölge enfeksiyonu	Uzaktan izleme	Hastane	Özel veri kümesi (Cook County Hospital, Provident Hospital / USA)	LR	Sıcaklık, Solunum hızı, Kalp atış hızı, Oksijen satürasyonu, Tansiyon, Lab testleri	AUC 0.935

Jouffroy vd. 2018	[135]	Sepsis	Erken uyarı	Hastane	Erişime açık veri kümesi (MIMIC II database)	Kural tabanlı (özel)	Demografikler, Sıcaklık, Solunum hızı, Kalp atış hızı, Oksijen satürasyonu, Tansiyon	Duyarlılık 0.92 / Özgüllük 0.29 / PPV 0.41/ NPV 0.88
Kam ve Kim, 2017	[136]	Sepsis	Erken uyarı	Hastane	Erişime açık veri kümesi (MIMIC II database)	LSTM	Sıcaklık, Solunum hızı, Kalp atış hızı, Oksijen satürasyonu, Lab testleri	AUC: 0.929
Kamaleswaran vd. 2018.	[137]	Sepsis	Erken uyarı	Hastane	Özel veri kümesi (Le Bonheur Children's Hospital, Memphis, TN, USA)	CNN, LR, RF	kalp atış hızı, Oksijen satürasyonu, kan basıncı	8-24saat aralığı için Özgüllük: %81 Duyarlılık: %76 .
Ke vd. 2017	[138]	Cerrahi bölge enfeksiyonu	Erken uyarı	Hastane	Özel veri kümesi (University Hospitals of Leicester / UK)	SVM	Sıcaklık, Solunum hızı, Kalp atış hızı, Oksijen satürasyonu, Tansiyon, Lab testleri	MAE 2.7

Khoshnevisan vd. 2018	[139]	Sepsis	Erken uyarı	Hastane	Özel veri kümesi (Millennium: Cerner Corporation / USA)	LR, SVM, RF, NB, ANN, CNN	Sıcaklık, Solunum hızı, Kalp atış hızı, Oksijen satürasyonu, Tansiyon, Lab testleri	Doğruluk 0.875/ Keskinlik 0.915/ Duyarlılık 0.826/ F ölçütü 0.868/ AUC 0.943
Kim vd. 2010	[140]	Sepsis	Uzaktan izleme	Hastane	Özel veri kümesi (Medical University of Vienna (MUV) / Austria)	SVM	Sıcaklık, Solunum hızı, Kalp atış hızı, Oksijen satürasyonu, Lab testleri	AUC 0.95
Kocbek vd. 2019.	[141]	Cerrahi bölge enfeksiyonu	Enfeksiyon tespiti	Hastane	Özel veri kümesi (University Hospital of North Norway)	LR, GB	Lab testleri	AUC: 0.967
Lamping vd. 2018	[142]	Sepsis	Erken uyarı	Hastane	Özel veri kümesi (NorthShore / USA)	LDA	Sıcaklık, Solunum hızı, Kalp atış hızı, Oksijen satürasyonu, Lab testleri, Klinik veri	AUC: 0.78
Le vd. 2019	[143]	Sepsis	Uzaktan izleme	Hastane	Özel veri kümesi (University of California San Francisco (UCSF) Medical Center)	Karar Ağacı	kalp atış hızı, Solunum hızı, Oksijen satürasyonu, Sıcaklık, kan basıncı	AUC: 0.916

Lin vd. 2018	[144]	Sepsis	Uzaktan izleme	Hastane	Özel veri kümesi (Christiana Care Health System (CCHS), Newark, DE, USA)	CNN, LSTM	Demografik veri ve Lab testleri	AUC: 94.08, F1 skoru: 85.79
Liu vd. 2017	[145]	El, ayak ve ağız hastalığı	Erken uyarı	Hastane	Erişime açık veri kümesi (MIMIC-III critical care database)	RF	Demografikler, Sıcaklık, Solunum hızı, Lab testleri	AUC: 0.916, Duyarlılık: 0.824, Özgüllük: 0.931, Doğruluk: 0.916
Lo vd. 2013	[146]	İdrar Yolu Enfeksiyonu	Uzaktan izleme	Hastane	Özel veri kümesi (Taipei Medical University)	LDA	Lab Testleri	Doğruluk %94.65, Duyarlılık: %100, Özgüllük: %94.61
López-Martínez vd. 2019	[147]	Sepsis	Enfeksiyon tespiti	Hastane	Özel veri kümesi (a private institution in Colombia)	MLP	Demografik veri ve klinik hasta verisi	Doğruluk: 0.867, Keskinlik: 0.83, Duyarlılık: 0.803
Lu vd. 2016	[148]	Üst solunum yolları enfeksiyonu	Uzaktan izleme	Hastane	Özel veri kümesi (Taipei Medical University Wan Fang Hospital / Taiwan)	TM	Klinik veri	Keskinlik: 0.375, Doğruluk: 0.325

Lukaszewski vd. 2008	[149]	Sepsis	Uzaktan izleme	Hastane	Özel veri kümesi (Taipei Medical University Wan Fang Hospital (TMUWFH))	KNN	Mikrobiyolojik veri	Doğruluk %94.55/ Duyarlılık %91.43
Mani vd. 2014	[150]	Sepsis	Uzaktan izleme	Hastane	Erişime açık veri kümesi (MIMIC III database)	LR, SVM, RF, NB, BN	EHR	AUC 0.78
Mansingh vd. 2011	[151]	Genel Enfeksiyon	Uzaktan izleme	Hastane	Özel veri kümesi (Vienna General Hospital / Austria)	Kural tabanlı (özel)	Demografikler, Lab testleri, Klinik veri	Güven 100% / Güvenirlilik 46.39% / Destek 94.66% / Lift 1.04
Mao vd. 2018	[152]	Sepsis	Uzaktan izleme	Hastane	Erişime açık veri kümesi (MIMIC III database), Özel veri kümesi (UCSF) Medical Center (San Francisco, California, USA))	GB	Oksijen Satürasyonu, Glasgow Koma Skoru, kan basıncı, Lab testleri	4 saat öncesi: AUC: 0.96
Masino vd. 2019	[153]	Sepsis	Uzaktan izleme	Hastane	Özel veri kümesi (Children's Hospital of Philadelphia, USA)	AdaBoost, LR, NB, SVM, RF, k-NN, GB	Elektronik sağlık verileri	AUC: 0.87

Matsui vd. 2010	[154]	Influenza	Tarama	Hastane	Özel veri kümesi (Nishi-kokubunji Clinic, Ritsu Pediatric Dental Clinic / Japan)	LDA	Sıcaklık, Solunum hızı, Kalp atış hızı	PPV, Duyarlılık 0.93, 0.88
Meurer vd. 2009	[155]	Genel Enfeksiyon	Uzaktan izleme	Hastane	Özel veri kümesi (Millennium: Cerner Corporation / USA)	CT	EHR	Duyarlılık 14% / Özgüllük 98%
Mikalsen vd. 2018	[156]	Cerrahi bölge enfeksiyonu	Teşhis için karar destek	Hastane	Özel veri kümesi(Zhongs han Hospital / China)	SVM	Lab testleri	F1-skoru 0.80
Milechin vd. 2017	[157]	Patojene maruz kalma	Erken uyarı	Hastane	Özel veri kümesi (Hannover Medical School / Germany)	RF	Solunum hızı, Kalp atış hızı, Tansiyon, Biyomedikal sinyaller	AUC: 0.95 51 saat önce tespit için
Mitchell vd. 2016	[158]	Sepsis	Erken uyarı	Hastane	Erişime açık veri kümesi (MIMIC II database)	LR	Lab testleri	AUC %73.9 / Duyarlılık %57.6 / Özgüllük %77.3
Monsalve vd. 2015	[159]	CDI	Uzaktan izleme	Hastane	Özel veri kümesi (The Boston Veterans Affairs Healthcare/US)	EL	EHR, Demografikler, Klinik veri,Lojistik veri	AUC: 0.866, Duyarlılık: 0.822, Özgüllük: 0.748

Mulder vd. 2019	[160]	Cerrahi bölge enfeksiyonu	Teşhis için karar destek	Hastane	Özel veri kümesi (Amphia Hospital (Breda, The Netherlands))	LR	Demografik veri ve klinik hasta verisi	Özgüllük: %68.7, Duyarlılık: %98.5, AUC: 0.950
Na vd. 2015	[161]	CDI	Tarama	Havaalanı Tarama	Özel veri kümesi (Japan Self-defense Forces Central Hospital / Japan)	LR	Demografikler, Lab testleri	Doğruluk 0.725
Nachimuthu and Haug, 2012	[162]	Sepsis	Uzaktan izleme	Hastane	Özel veri kümesi (RAISIN French Institute for Erişime açık veri kümesi Health Surveillance / France)	BN	Sıcaklık, Solunum hızı, Kalp atış hızı, Oksijen satürasyonu, Lab testleri	AUC 0.949
Nguyen vd. 2014	[163]	Influenza	Erken uyarı	Hastane	Erişime açık veri kümesi (MIMIC II database)	SVM, LiR	Sıcaklık, Solunum hızı, Kalp atış hızı	Duyarlılık %93 / PPV %91 / Özgüllük %91 / NPV 93%
Oh vd. 2018	[164]	CDI	Erken uyarı	Hastane	Özel veri kümesi (Royal Infirmary of Edinburgh / Scotland)	LR	EHR	AUC 0.82

Parente vd. 2018	[165]	Sepsis	Erken uyarı	Hastane	Özel veri kümesi (Christchurch Hospital ICU, New Zealand)	HMM	Sıcaklık,kalp atış hızı, Solunum hızı, kan basıncı ve SIRS skoru	AUC: 0.99, Duyarlılık: 0.95, Özgüllük: 0.96
Parreco vd. 2018	[166]	Kan akışı enfeksiyonu	Uzaktan izleme	Hastane	Özel veri kümesi (Geriatrics Center and Division of Geriatric & Palliative Medicine University of Michigan / USA)	LR, GBT, CNN	EHR	AUC 0.722 /Doğruluk %98.6/ Özgüllük %77.3
Paxton vd. 2013	[167]	Sepsis	Erken uyarı	Hastane	Özel veri kümesi (Emory affiliated hospital / USA)	SVM	EHR, Demografikler, Sıcaklık, Solunum hızı, Kalp atış hızı,Oksijen satürasyonu, Lab testleri, Klinik veri,Lojistik veri	AUC: 0.7

Prasad vd. 2017	[168]	Sepsis	Erken uyarı	Hastane	Erişime açık veri kümesi (BIDMC Dataset)	LR, RF, QDA	Demografikler, Sıcaklık, Solunum hızı, Kalp atış hızı, Oksijen saturasyonu, Lab testleri	AUC 0.815
Rabhi vd. 2019	[169]	Genel Enfeksiyon	Enfeksiyon tespiti	Hastane	Özel veri kümesi (Lyon, Nice, Rouen hospitals, France)	CNN, NB, k-NN, LR, RF, Karar Ağaçları, SVM, GB	Klinik notlar	F1 skoru: 97.7%, AUC: %99.8
Sanger vd. 2018	[170]	CAUTI	Uzaktan izleme	Hastane	Özel veri kümesi (The University of Washington Medical Center, USA)	NLP	Mikrobiyoloji/elektronik sağlık verisi, Fatura verisi	Duyarlılık: %97.1, Özgüllük: %94.5, PPV: %66.7, NPV %99.6
Sanger vd. 2016	[171]	Cerrahi bölge enfeksiyonu	Tarama	Havaalanı karantina istasyonu	Özel veri kümesi (Japan Self-defense Forces Central Hospital / Japan)	NB	Kalp atış hızı, Tansiyon	AUC 0.76
Saunders vd. 2014	[172]	Cerrahi bölge enfeksiyonu	Tarama	Toplanma yerleri and Havaalanı karantinaları	Özel veri kümesi (Japan Self-defense Forces Central Hospital / Japan)	LR	Demografikler, Klinik veri, Lojistik veri	AUC 0.84

Scherpf vd. 2019	[173]	Sepsis	Erken uyarı	Hastane	Erişime açık veri kümesi (MIMIC III database)	RNN	Yaş, Klinik veri	sepsisten 3 saat önce: AUC: 0.81
Schurink vd. 2007	[174]	Zatürre	Teşhis için karar destek	Hastane	Özel veri kümesi (The University Medical Center Utrecht (UMCU)) / Netherlands)	BN	Sıcaklık, Lab testleri, Biyomedikal sinyaller	AUC 0.846
Sen vd. 2017	[175]	CDI	Teşhis	Hastane	Özel veri kümesi (Guangzhou Women's and Children's Medical Center / China)	LR, SVM, RF	EHR, Demografikler, Sıcaklık, Solunum hızı, Kalp atış hızı, Oksijen satürasyonu, Klinik veri	AUC 0.838
Shankar vd. 2018.	[176]	Surgical Site Infection	Uzaktan izleme	Hastane	Özel veri kümesi(Department of Gastrointestinal Surgery at University Hospital of North Norway)	RF, SVM, LR	Lab testleri	Doğruluk: 0.86, Duyarlılık: 0.68, Özgüllük: 0.91

Shashikumar vd. 2017	[177]	Sepsis	Erken uyarı	Hastane	Özel veri kümesi (MedStar Health Research Institute / USA)	EL	Demografikler, Sıcaklık, Solunum hızı, Kalp atış hızı,Oksijen satürasyonu, Tansiyon, Lab testleri, Klinik veri,Lojistik veri, Risk faktörleri	AUC 0.78, Özgüllük 0.55, Doğruluk 0.61 (Duyarlılık 0.85)
Shimabukuro vd. 2017	[178]	Sepsis	Erken uyarı	Hastane	Erişime açık veri kümesi (MIMIC II database)	EL	Demografikler, Sıcaklık, Solunum hızı, Kalp atış hızı,Oksijen satürasyonu, Lab testleri,Lojistik veri	AUC: 0.952, Duyarlılık: 0.900, Özgüllük: 0.900
Soguero-Ruiz vd. 2015	[179]	Cerrahi bölge enfeksiyonu	Uzaktan izleme	Hastane	Erişime açık veri kümesi (MIMIC-II Klinik veriset)	GP	Lab testleri	Doğruluk 0.83
Stanculescu vd. 2014	[180]	Sepsis	Erken uyarı	Hastane	Özel veri kümesi (Carle Foundation Hospital / USA)	HMM	Sıcaklık, Kalp atış hızı,Oksijen satürasyonu	AUC 0.77

Stanculescu vd. 2014	[181]	Sepsis	Erken uyarı	Hastane	Özel veri kümesi (University of Houston College of Pharmacy, Beth Israel Deaconess Medical Center, Mater Misericordiae University Hospital / Ireland-USA)	LDS	Sıcaklık, Kalp atış hızı,Oksijen satürasyonu	AUC 0.85
Strauman vd. 2018.	[182]	Cerrahi bölge enfeksiyonu	Enfeksiyon tespiti	Hastane	Özel veri kümesi (University Hospital of North Norway)	RNN	Kan testleri	AUC: 0.91, F1 skoru: 0.71
Sun vd. 2013	[183]	Influenza	Tarama	Havaalanı Tarama	Özel veri kümesi (Japan Self-defense Forces Central Hospital)	LDA, QDA, SVM, kNN, LR, NB, SOM	Kalp atış hızı, Solunum hızı, Sıcaklık	Hata oranı %9.7, Duyarlılık: %98, Özgüllük: %77

Sun vd. 2014	[184]	Influenza	Şiddet tahmini	Hastane	Özel veri kümesi (Pusat Perubatan Universiti Kebangsaan Hospital Canselor Tuanku Muhriz (HCTM) / Malaysia)	SVM	Sıcaklık, Solunum hızı, Kalp atış hızı	Duyarlılık, Özgüllük, PPV, NPV 0.815, 0.907, 0.846, 0.886
Sun vd. 2015	[185]	Genel Enfeksiyon	Tarama	Havaalanı Tarama	Özel veri kümesi (Tokyo University / Japan)	LDA	Sıcaklık, Solunum hızı, Kalp atış hızı	Hata oranı 0.05
Sun vd. 2015	[186]	Influenza	Enfeksiyon tespit	Hastane	Özel veri kümesi (The University of Minnesota Academic Health Center / USA)	ANN	Sıcaklık, Solunum hızı, Kalp atış hızı	Duyarlılık, Özgüllük, PPV, NPV 0.971, 0.813, 0.791, 0.975
Swiston Jr ve Milechin, 2016	[187]	Ebola ve Marburg virüsleri	Erken uyarı	Hastane	Özel veri kümesi (LDS Hospital (LDSH) and Intermountain Medical Center (IMC) / USA)	RF	Biyomedikal sinyaller	AUC: 0.9 for 52+-14 saat önce tespit

Taneja vd. 2017	[188]	Sepsis	Uzaktan izleme	Hastane	Özel veri kümesi (US Army Medical Research Institute of Infectious Diseases / USA)	LR, SVM, RF, NB, GP	Sıcaklık, Solunum hızı, Kalp atış hızı, Lab testleri, Mikrobiyolojik veri	Doğruluk 0.81
Tanner vd. 2009	[189]	CDI	Uzaktan izleme	Hastane	Özel veri kümesi (University Health Care Edinburgh / Scotland)	LR	EHR, Demografikler, Klinik veri, Lojistik veri	AUC 0.847 / standard hata 0.040 / p değeri <0.001
Tou vd. 2018	[190]	Genel Enfeksiyon	Erken uyarı	Hastane	Özel veri kümesi (Royal Infirmary of Edinburgh / Scotland)	LR, RF, NB, GBT	Demografikler, Sıcaklık, Solunum hızı, Kalp atış hızı, Oksijen saturasyonu, Lab testleri, Biyomedikal sinyaller	AUC 0.88
Trick vd. 2004	[191]	CVC	Enfeksiyon tespiti	Hastane	Özel veri kümesi (Veteran affair hospital / USA)	Kural tabanlı (özel)	Mikrobiyolojik veri	Duyarlılık, Özgüllük, PPV, NPV 0.81, 0.72, 0.62, 0.87

Tvardik vd. 2018	[192]	Genel Enfeksiyon	Teşhis için karar destek	Hastane	Özel veri kümesi (French university hospitals(Lyon, Nice and Rouen))	ES	Tıbbi raporlar	Doğruluk: %84 Duyarlılık: %83.9, Özgüllük: %84.2
Umscheid vd. 2015	[193]	Sepsis	Uzaktan izleme	Hastane	Özel veri kümesi (MLH) / USA)	Kural tabanlı (özel)	Sıcaklık, Solunum hızı, Kalp atış hızı,Oksijen satürasyonu, Tansiyon	Duyarlılık, Özgüllük, PPV, NPV 0.16, 0.97, 0.26, 0.94
Uzoka vd. 2011	[194]	Malaria	Erken uyarı	Hastane	Özel veri kümesi (The University Hospital of North Norway / Norway)	Bulanık kurallar	Klinik veri	Doğruluk 0.80, 0.67 (fuzzy, AHP)
van WYK vd. 2018.	[195]	Sepsis	Erken uyarı	Hastane	Özel veri kümesi (Methodist LeBonheur Healthcare (MLH) System, Memphis USA)	RF, SVM, LR, NLP	Klinik veri	Sepsisten 1 saat öncesi: F1 skoru: 67%, Sensitivity: 80%
van Wyk v.d. 2017	[196]	Sepsis	Uzaktan izleme	Hastane	Erişime açık veri kümesi (National Health Insurance Dataset)	ANN, CNN	Sıcaklık, Solunum hızı, Kalp atış hızı,Oksijen satürasyonu, Tansiyon, Lab testleri	Doğruluk: 0.861

Ward vd. 2017	[197]	Sepsis	Erken uyarı	Hastane	Özel veri kümesi (Massachusetts General Hospital (MGH) / USA)	BN	Sıcaklık, Solunum hızı, Kalp atış hızı, Oksijen saturasyonu, Lab testleri	AUC 0.79
Wiens vd. 2012	[198]	CDI	Erken uyarı	Hastane	Özel veri kümesi (Queen Alexandra Hospital / USA)	SVM, HMM	Risk faktörleri	AUC 0.79/ F-skoru 0.37
Wiens vd. 2014	[199]	CDI	Erken uyarı	Hastane	Erişime açık veri kümesi (MIMIC II database)	LR	EHR, Risk faktörleri	AUC 0.814
Yao vd. 2016	[200]	Genel Enfeksiyon	Uzaktan izleme	Hastane	Özel veri kümesi (Kaiser Foundation Hospitals / USA)	LR, SVM, NB, LDA, QDA, KNN	Sıcaklık, Solunum hızı, Kalp atış hızı	Doğruluk: 0.902, Duyarlılık: 0.93, Özgüllük: 0.857, AUC: 0.95
Yee vd. 2019.	[201]	Sepsis	Erken uyarı	Hastane	Erişime açık veri kümesi (MIMIC III database)	BN	Demografik veri ve Lab testleri	AUC: 0.81, NPV: 0.87, PPV: 0.65

Zainee ve Chellappan, 2016	[202]	Dang Ateşi	Erken uyarı	Hastane	Özel veri kümesi (VU University Medical Center/Netherlands)	LDA	Sıcaklık, Solunum hızı, Kalp atış hızı, Oksijen satürasyonu, Tansiyon, Lab testleri	Doğruluk 83.3
Zhang vd. 2017	[203]	El, ayak ve ağız hastalığı	Erken uyarı	Hastane	Özel veri kümesi (Grady Memorial Hospital / USA)	GBT	Demografikler, Sıcaklık, Solunum hızı, Kalp atış hızı, Oksijen satürasyonu, Lab testleri, Biyomedikal sinyaller	AUC 0.985
Zhang vd. 2017	[204]	Sepsis	Erken uyarı	Hastane	Özel veri kümesi (The Project IMPACT data set)	LSTM	Sıcaklık, Solunum hızı, Kalp atış hızı, Oksijen satürasyonu, Tansiyon, Lab testleri	AUC: 0.990, Duyarlılık: 0.999, Özgüllük: 0.967, Keskinlik: 0.926, NPV: 0.999, F1: 0.961

