T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

DOKTORA TEZİ

Alt Ekstremite Biyomekanik Analiziyle Derin Öğrenme Tabanlı İnsan Yürüyüşü Tanıma

Hacer KUDUZ

DANIŞMAN
Prof. Dr. Fırat KAÇAR

Biyomedikal Mühendisliği Anabilim Dalı

Biyomedikal Mühendisliği, Doktora Programı

Aralık, 2023

Anneme ve babama ithaf ediyorum…

BÜTÇE DESTEKLERİ

Alt Ekstremite Biyomekanik Sinyal Analiziyle
Derin Öğrenme Tabanlı İnsan Yürüyüşü Tanıma

Bu tez çalışması için herhangi bir kurumdan bütçe desteği alınmamıştır.

TEŞEKKÜR

Tez sürecimin başından sonuna akademik ve manevi desteklerini her zaman hissettiğim değerli danışmanım Prof. Dr. Fırat KAÇAR başta olmak üzere ara rapor değerlendirmelerindeki geri bildirimleri ve önerileriyle tezime katkıda bulunan tez izleme komitesi hocalarım Doç. Dr. Abdurrahim AKGÜNDOĞDU ve Doç. Dr. Övünç POLAT'a kıymetli katkılarından dolayı çok teşekkür ederim.

Yüksek lisans tez danışmanım Prof. Dr. Emin SÜNBÜLOĞLU ve kıymetli hocam Öğr. Gör. Dr. Ergün BOZDAĞ'a akademik hayatıma biyomekanik alanındaki katkıları ve destekleri için teşekkür ederim. Ayrıca doktora tez sürecimde manevi destekleriyle yanımda olan Prof. Dr. Ahmet BOZKURT ve Doç. Dr. Kerim Kürşat ÇEVİK'e çok teşekkür ederim. Son olarak, sevgili arkadaşım Arş. Gör. Dilayda SOYLU PEKPOSTALCI, kuzenim Ayda Nur UYSAL, komşum Fatma Cefair ve İsmet KUŞAKCI'ya anlayışları ve bu süreçteki destekleri için teşekkür ederim.

Doktora eğitimim süresinde akademik ve manevi destekleriyle hayatıma olumlu katkıları olan İstanbul Üniversitesi-Cerrahpaşa Elektrik Elektronik Mühendisliği bölümündeki ve Akdeniz Üniversitesi Mühendislik Fakültesindeki iş yeri arkadaşlarıma ayrıca teşekkür ederim.

Tez çalışmasında kullandığım açık erişim veri setini paylaştığından dolayı Camargo ve arkadaşlarına sonsuz teşekkürlerimi sunarım.

Son fakat en önemlisi, bana kendimi gerçekleştirme yolunda cesaret veren ve tüm imkanlarını sunan sevgili annem ve babama minnettarım. Hayattaki şansım olduğuna inandığım biricik kardeşime, ne kadar uzakta olursak olalım her daim varlığını yanımda hissettirdiğinden dolayı en içten dileklerimle teşekkür ederim.

Aralık 2023 Hacer KUDUZ

Biyomedikal Yüksek Mühendisi

İÇİNDEKİLER

Sayfa No

TEZ KABUL VE ONAYI ii
BEYAN iii
BÜTÇE DESTEKLERİ v
TEŞEKKÜR vi
İÇİNDEKİLER vii
ŞEKİL LİSTESİ ix
TABLO LİSTESİ xii
SİMGE VE KISALTMA LİSTESİ xiii
ÖZET xvi
ABSTRACT xviii
1. GİRİŞ 1
2. GENEL KISIMLAR 4
2.1. İNSAN ETKİNLİĞİ TANIMA 4
2.2. YÜRÜYÜŞ TANIMA SİSTEMLERİ 6
2.2.1. Referans Geleneksel Teknolojiler 6
2.2.2. Giyilebilir Sensör Teknolojileri 7
2.3. DİJİTAL SİNYAL İŞLEME YÖNTEMLERİ 9
2.3.1. Savitzky-Golay Filtresi 9
2.3.2. Kayan Pencereler Yöntemi 11
2.3.3. Zaman-Frekans Analizi Yöntemleri 13
2.4. DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ 15
2.4.1. Makine Öğrenmesi 16
2.4.2. Derin Öğrenme 18
2.4.3. Sınıflandırma Performans Ölçütleri 19
2.5. LİTERATÜR ÖZETİ 21
3. YÖNTEM 31
3.1. ALT EKSTREMİTE GİYİLEBİLİR BİYOMEKANİK VERİSETİ 31
3.2. BİYOMEDİKAL SİNYAL İŞLEME 32

3.3. MAKİNE ÖĞRENMESİ ve DERİN ÖĞRENME YÜRÜYÜŞ TANIMA MODELLERİ 37
4. BULGULAR 43
4.1. MAKİNE ÖĞRENİMİ YAKLAŞIMIYLA BİYOMEKANİK SENSÖR VERİLERİNE DAYALI İNSAN ALT EKSTREMİTE HAREKETİNİN SINIFLANDIRILMASI 43
4.1.1. Kayan Pencere Uzunluğunun Sınıflandırma Performansına Etkisi 43
4.1.2. Tekli ve Çoklu Giyilebilir Sensör Modellerinin Sınıflandırma Performansına Etkisi 46
4.2. MAKİNE ÖĞRENMESİ YAKLAŞIMIYLA IMU BİYOMEKANİK SENSÖR VERİLERİNE DAYALI İNSAN YÜRÜYÜŞÜ TANIMA 48
4.2.1. Veri Normalizasyonu ve PCA'nın ML Sınıflandırma Performansına Etkisi 49
4.2.2. ML Sınıflandırma Performansının Sensör Bazında Değerlendirilmesi 50
4.3. DERİN ÖĞRENME TABANLI IMU SENSOR VERİSİNİN ZAMAN-FREKANS ANALİZİ GÖRÜNTÜLERİNDEN İNSAN YÜRÜYÜŞÜ TANIMA 53
4.3.1. Ham IMU CNN Modellerinin Sınıflandırma Performansları 53
4.3.2. IMU Bileşke Lineer İvmelenme CNN Modellerinin Sınıflandırma Performansları 55
4.4. CNN TABANLI GİYİLEBİLİR BİYOMEKANİK SENSÖR VERİSİNİN STFT GÖRÜNTÜLERİNDEN İNSAN YÜRÜYÜŞÜ TANIMA 59
4.4.1. Filtrelemenin IMU Sensör CNN Modeli Sınıflandırma Başarısına Etkisi 59
4.4.2. Segmentasyonun Giyilebilir Sensör CNN Modeli Sınıflandırma Başarısına Etkisi 65
4.4.3. İki Girişli Tek Çıkışlı Giyilebilir Sensör CNN Modelinin Sınıflandırma Başarısına Etkisi 69
5. TARTIŞMA 73
6. SONUÇ VE ÖNERİLER 86
KAYNAKLAR 89
EKLER 97
İNTİHAL RAPORU İLK SAYFASI 98
ETİK KURUL İZİN YAZISI 99
KURUM İZNİ YAZILARI 100
ÖZGEÇMİŞ 101

ŞEKİL LİSTESİ

Sayfa No

Şekil 1.1: Tez aşamalarını gösteren blok diyagram. 3

Şekil 2.1: HAR uygulama alanlarına bazı örnekler. 5

Şekil 2.2: Giyilebilir biyomekanik sensör örnekleri. 7

Şekil 2.3: Savitzky-Golay filtresi [29]. 11

Şekil 2.4: Kayan pencereler yöntemi uygulanması [32]. 12

Şekil 2.5: Derin CNN mimarisi katmanları. 19

Şekil 2.6: AUC-ROC eğrisi. 21

Şekil 3.1: Alt ekstremite giyilebilir biyomekanik veri seti sensör yerleşimleri. 31

Şekil 3.2: IMU sensör *(a)* Ham sinyali, *(b)* sinyaline Savitzky-Golay filtresi uygulanması, *(c)* sinyalinin 5 s süreyle kırpılması. 33

Şekil 3.3: Giyilebilir biyomekanik sensör zaman serisi sinyalleri. *(a)* Ayak IMU sensörü, *(b)* Bacak IMU sensörü, *(c)* Uyluk IMU sensörü, *(d)* Gövde IMU sensörü, *(e)* GON sensör açı sinyalleri, *(f)* Alt ekstremite kaslarına ait EMG sensör sinyalleri. 34

Şekil 3.4: Giyilebilir sensör sinyallerinden kayan pencereler yöntemiyle öznitelik çıkarımı. . 35

Şekil 3.5: IMU sensör sinyallerinden CNN giriş görüntü veri seti oluşturma. *(a)* Ham IMU sinyalleri, *(b)* IMU bileşke lineer ivmelenme sinyalleri. 36

Şekil 3.6: IMU *(a)* ham sinyal, *(b)* sinyaline Savitzky-Golay filtresi uygulanması. 37

Şekil 3.7: IMU sinyal işleme adımları ve STFT görüntülerinin oluşturulması. 37

Şekil 3.8: CNN giriş görüntü veri setlerine örnekler. 40

Şekil 3.9: Giyilebilir sensör STFT görüntüleri eğitim ve test kümelerinin seçimi. 41

Şekil 3.10: Giyilebilir sensör sinyalleriyle yürüyüş tanıma CNN model mimarisi. 42

Şekil 4.1: IMU ve GON sensörlerin ML performanslarının karşılaştırılması. *(a)* IMU sensör sınıflandırma doğruluğu, *(b)* IMU sensör AUC-ROC skoru, *(c)* GON sensör sınıflandırma doğruluğu, *(d)* GON sensör AUC-ROC skoru. 44

Şekil 4.2: IMU sensör modellerinin karışıklık matrisleri. 45

Şekil 4.3: GON sensör modellerinin karışıklık matrisleri. 46

Şekil 4.4: Çoklu giyilebilir sensör modellerinin ML sınıflandırma performansı. *(a)* Sınıflandırma doğruluğu, *(b)* AUC-ROC skoru. 47

Şekil 4.5: EMG ve diğer çoklu sensör modellerinin karışıklık matrisleri. 48

Şekil 4.6:Veri normalizasyonu ve PCA'nın ML sınıflandırma performansına etkisi. *(a)* Durum-I, *(b)* Durum-II, *(c)* Durum-III, *(d)* Durum-IV..... 50

Şekil 4.7: ML sınıflandırma doğruluklarının sensör bazında karşılaştırılması. 51

Şekil 4.8: ML sınıflandırıcıların sensör bazlı karışıklık matrisleri..... 52

Şekil 4.9: Ham IMU CNN modellerinin karışıklık matrisleri. Veri dağılımı her bir sınıfta farklı sayıda görüntü olan *(a)* Eğitim kümesi, *(b)* Test kümesi, Veri dağılımı her bir sınıfta aynı sayıda görüntü olan *(c)* Eğitim kümesi, *(d)* Test kümesi..... 54

Şekil 4.10: IMU bileşke lineer ivmelenme CNN modellerinin karışıklık matrisleri. Veri dağılımı her bir sınıfta farklı sayıda görüntü olan *(a)* Eğitim kümesi, *(b)* Test kümesi, Veri dağılımı her bir sınıfta aynı sayıda görüntü olan *(c)* Eğitim kümesi, *(d)* Test kümesi. 56

Şekil 4.11: IMU CNN modellerinin karşılaştırmalı test sınıflandırma performansları. 58

Şekil 4.12: Grup I test kümesi sınıflandırma performans ölçütleri. 60

Şekil 4.13: Grup I karışıklık matrisleri *(a)* Eğitim kümesi, *(b)* Test kümesi..... 61

Şekil 4.14: Grup II test kümesi sınıflandırma performans ölçütleri. 61

Şekil 4.15: Grup II karışıklık matrisleri *(a)* Eğitim kümesi, *(b)* Test kümesi. 63

Şekil 4.16: Grup III test kümesi sınıflandırma performans ölçütleri..... 63

Şekil 4.17: Grup III karışıklık matrisleri *(a)* Eğitim kümesi, *(b)* Test kümesi. 64

Şekil 4.18: Filtrelemenin CNN sınıflandırma performansına etkisi..... 65

Şekil 4.19: Grup IV test kümesi sınıflandırma performans ölçütleri. 66

Şekil 4.20: Grup IV karışıklık matrisleri *(a)* Eğitim kümesi, *(b)* Test kümesi..... 67

Şekil 4.21: Grup V test kümesi sınıflandırma performans ölçütleri..... 68

Şekil 4.22: Grup V karışıklık matrisleri *(a)* Eğitim kümesi, *(b)* Test kümesi. 69

Şekil 4.23: Grup VI test kümesi sınıflandırma performans ölçütleri. 70

Şekil 4.24: Grup VI karışıklık matrisleri *(a)* Eğitim kümesi, *(b)* Test kümesi..... 71

Şekil 5.1: Deneylerde kullanılan sensör model doğruluklarının karşılaştırılması. *(a)* IMU sensör ML ve CNN modelleri, *(b)* GON sensör ML ve CNN modelleri, *(c)* IMU-GON sensör

çoklu sensör ML ve CNN modelleri, *(d)* IMU sensör yerleşimlerine göre ML ve DL modelleri. 76

Şekil 5.2: Sensör yerleşimlerine göre 2D-CNN STFT modellerinin performans ölçütleri. 81

Şekil 5.3: Deneylerde en yüksek doğruluğa sahip 2D-CNN modellerinin performans ölçütleri. 82

TABLO LİSTESİ

Sayfa No

Tablo 2.1: Karışıklık matrisi ve sınıflandırma ölçütleri. 21

Tablo 3.1: ML modelleri için giyilebilir sensör sinyallerinin çıkarılan öznitelik matrisi. 38

Tablo 3.2: Makine öğrenmesi modeli eğitim hiperparametreleri. 39

Tablo 4.1: Ham IMU CNN modelleri test kümesi sınıflandırma performansları. 55

Tablo 4.2: IMU-BLİV CNN modelleri test kümesi sınıflandırma performansları. 57

Tablo 4.3: Grup I eğitim ve test kümesi sınıflandırma performans ölçütleri. 60

Tablo 4.4: Grup II eğitim ve test kümesi sınıflandırma performans ölçütleri. 62

Tablo 4.5: Grup III eğitim ve test kümesi sınıflandırma performans ölçütleri..... 64

Tablo 4.6: Grup IV eğitim ve test kümesi sınıflandırma performans ölçütleri. 66

Tablo 4.7: Grup V eğitim ve test kümesi sınıflandırma performans ölçütleri. 68

Tablo 4.8: Grup VI eğitim ve test kümesi sınıflandırma performans ölçütleri. 70

Tablo 5.1: Tekli ve çoklu sensör ML model doğruluklarının karşılaştırılması. 75

Tablo 5.2: Güncel insan yürüyüş tanıma çalışmaları ve önerilen yöntemin karşılaştırılması. . 84

SİMGE VE KISALTMA LİSTESİ

Simgeler	Açıklama
B	: Band genişliği
2B	: İki Boyutlu
3B	: Üç Boyutlu
f_s	: Örnekleme frekansı
g	: Yer çekimi ivmesi
Hz	: Hertz
mV	: miliVolt
N	: Newton
R	: Çözünürlük

Kısaltmalar	Açıklama
AI	: Artificial Intelligence
ANN	: Artificial Neural Network
AUC	: Area Under Curve
AUS	: Area Under Signal
BLİV	: Bileşke Lineer İvmelenme
CM	: Confusion Matrice
CMMR	: Common Mode Rejection Ratio
CNN	: Convolutional Neural Networks
CoP	: Center of Pressure
CWT	: Continious Wavelet Transform
DL	: Deep Learning
DSP	: Digital Signal Processing
DT	: Decision Tree
DWT	: Discrete Wavelet Transform
EBT	: Ensemble Bagged Trees
EEG	: Electroencephalography

EKG : Electrocardiography
EMG : Electromyography
ESKNN : Ensemble Subspace K-Nearest Neighbors
FFT : Fast Fourier Transform
FP : Force Plate
GAF : Gramian Angular Field
GON : Goniometer
GRF : Ground Reaction Force
HAR : Human Activity Recognition
IMU : Inertial Measurement Unit
IoT : Internet of Things
k-fold CV : k-fold Cross Validation
KNN : K-Nearest Neighbors
KPY : Kayan Pencereler Yöntemi
KSVM : Kernel Support Vector Machine
LC : Load Cell
LDA : Linear Discriminant Analysis
LR : Logistic Regression
LSTM : Long Short Term Memory
MEMS : Micro Electro Mechanical Systems
ML : Machine Learning
MLP : Multi Layer Perception
Mocap : Motion Capture
NB : Naive Bayes
QDA : Quadratic Discriminant Analysis
QSVM : Quadratic Support Vector Machine
PSD : Power Spectral Density
RBF : Radial Base Function
RNN : Recurrent Neural Network
ROC : Receiver Operating Characteristic
SG : Savitzky-Golay
STFT : Short Time Frequency Transform
SVM : Support Vector Machine
TFA : Time Frequency Analysis

WHO : World Health Organization

Wi-Fi : Wireless Fidelity

WNN : Wide Neural Networks

WS : Walking Speed

ÖZET

DOKTORA TEZİ

ALT EKSTREMİTE BİYOMEKANİK SİNYAL ANALİZİYLE DERİN ÖĞRENME TABANLI İNSAN YÜRÜYÜŞÜ TANIMA

Hacer KUDUZ

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

Biyomedikal Mühendisliği Programı

Danışman: Prof. Dr. Fırat KAÇAR

Son yıllarda insan aktivitesini tanıma amacıyla giyilebilir biyomekanik sensörler ve derin öğrenme yaklaşımları giderek yaygınlaşmaktadır. Bu tez çalışmasında, sağlıklı katılımcılara yerleştirilmiş IMU, gonyometre ve EMG sensöründen yer seviyesi yürüyüş sırasında farklı yürüme hızlarında kaydedilen açık erişimli bir veri seti kullanılmıştır. Çalışmamız, sağlıklı bireylerin fiziksel yürüyüşündeki zamansal yürüyüş örüntülerini doğru olarak sınıflandırmak üzere çeşitli makine öğrenmesi (ML) ve derin öğrenme (DL) algoritmalarını araştırmayı amaçlamaktadır. Yürüyüş sinyali öznitelikleri çıkarmada kayan pencereler yöntemi (KPY) kullanılırken farklı pencere uzunluklarının ve ML algoritmalarının sınıflandırma performansına etkileri karşılaştırılmıştır. Derin evrişimli sinir ağı (CNN) modeli girişi için IMU sensör ve bileşke lineer ivmelenme sinyalleri segmentlere ayrılmış, ardından Sürekli Dalgacık Dönüşümü (CWT) ve Kısa Süreli Fourier Dönüşümü (STFT) dönüşümleriyle zaman-frekans analizi (TFA) temsilleri oluşturulmuştur. Ayrıca ayak, bacak, uyluk ve gövdeye yerleştirilen IMU sensör ile ayak bileği, diz ve kalçaya yerleştirilen GON sensör yürüyüş spektrogramları, yürüyüş sinyallerine STFT uygulanarak elde edilmiş ve 2D-CNN sınıflandırıcısıyla eğitilmiştir.

IMU, GON ve EMG biyomekanik sinyallerinin, kayan pencereler yöntemi kullanılarak ML sınıflandırılmasında 1000 (5s) uzunluğundaki kayan pencere uzunluğu ve QSVM sınıflandırıcısı daha iyi performans sağlamıştır. Tekli sensör IMU, GON ve EMG modellerinin doğrulukları sırasıyla 0.95, 0.83 ve 0.74'tür. Çoklu sensör modellerinin doğrulukları ise IMU-GON (0.95), IMU-EMG (0.90), GON-EMG (0.78) ve IMU-GON-EMG (0.92)'dir. Bu sonuçlar insan yürüyüş tanımada IMU giyilebilir sensör kullanımının etkisini göstermektedir. Ayrıca ML yaklaşımıyla IMU sensör yerleşim yerinin ve farklı veri işleme yöntemlerinin insan yürüyüş tanımadaki etkisi değerlendirilmiş ve SVM tabanlı sınıflandırıcıların yüksek sınıflandırma doğruluğu sağladığına ulaşılmıştır. Tekli IMU sensör 'Ft', 'Sh', 'Th' ve 'Tr'modellerinin doğrulukları sırasıyla 0.693, 0.727, 0.748 ve 0.66'dır. Çoklu IMU sensör 'ShTh', 'ShThFt' ve 'All' modellerinin doğrulukları ise 0.75, 0.799 ve 0.839 olarak bulunmuştur. DL yaklaşımıyla IMU sinyali ve bileşke lineer ivmelenmeleri TFA görüntülerinin insan yürüyüş tanıma üzerindeki etkisi değerlendirilmiştir. Analizler 'STFT-tümü', 'CWT-tümü' ve 'CWT-BLİV' CNN modellerinin en yüksek test sınıflandırma performansına, sırasıyla 0.833, 0.809 ve 0.794 doğruluk ve 0.876, 0.857 ve 0.846 özgüllük değerleriyle ulaşılmıştır. DL analiz sonuçları, STFT ve CWT tabanlı TFA görüntüleri kullanılan CNN modelleri, tüm IMU kanalları birleştirildiğinde, en yüksek sınıflandırma doğruluğunu göstermiştir. Bu analizlerde biyomekanik sensör yerleşim yerine göre sinyal filtreleme ve segmentasyonu etkileri karşılaştırılarak tek ve iki girişli IMU ve GON sensör CNN modellerinin insan yürüyüş tanıma performansları incelenmiştir. 'IMU-5s', 'Multi-5s', ve 'Multi-tüm' modellerinin sınıflandırma performansı ortalamaları sırasıyla doğrulukları 0.910, 0.842 ve 0.828 özgüllükleri ise 0.932, 0.882 ve 0.871 olarak bulunmuştur. Uyluk ve bacak spektrogramları, yürüyüş hızı gruplarının tam olarak sınıflandırılmasına olanak sağlamıştır.

Sonuç olarak, makine öğrenmesi yaklaşımı sağlıklı bireyler için giyilebilir biyomekanik sensörlerden uygun geçici yürüyüş özelliklerinin belirlemesinde önemli bir değerlendirme aracıdır. Önerilen bu yaklaşım, sağlıklı bireylerin yürüyüş hızı sınıflandırmasında TFA yaklaşımı ve 2D-CNN kullanarak giyilebilir sensör sinyallerinde gözlemlenebilir farklılıklar olmadan yürüyüşün güvenilir çoklu sınıflandırmasını sağlayan yenilikçi bir çalışmadır.

Aralık 2023 , 121 sayfa.

Anahtar kelimeler: İnsan Yürüyüş Tanıma, Makine Öğrenmesi, Evrişimsel Sinir Ağı, Zaman-Frekans Analizi, Biyomekanik Veri, Giyilebilir Sensörler

ABSTRACT

Ph.D. THESIS

HUMAN GAIT RECOGNITION BASED ON DEEP LEARNING USING LOWER LIMB BIOMECHANICAL SIGNAL ANALYSIS

Hacer KUDUZ

İstanbul University-Cerrahpaşa

Institute of Graduate Studies

Department of Biomedical Engineering

Programme of Biomedical Engineering

Supervisor: Prof. Dr. Fırat KAÇAR

Recently, weareble biomechanical sensors and deep learning applications have been prevailing for human activity recognition. In this thesis study, an open-access dataset recorded at different walking speeds in level-ground gait from IMU, goniometer and, EMG sensors placed in healthy subjects was used. Our study aimed to investigate several machine learning and deep learning algorithms to classify the temporal gait characteristics of human physical walking performed by healthy subjects. The consequences of various window lengths and machine learning methods on classification performance has been assessed while extracting gait signal characteristics using the sliding windows approach. The input of the deep convolutional neural network (CNN) model was obtained by segmenting the IMU sensor and the resultant linear acceleration signals. Afterwards, time-frequency analysis (TFA) representations were obtained using the Continuous Wavelet Transform (CWT) and Short-Term Fourier Transform (STFT) transformations. Moreover, the gait spectrograms from the GON sensor, which is found on the ankle, knee, and hip, and the IMU sensor, which is placed on the foot, shank, thigh, and trunk, were obtained by applying STFT to the gait signals and then trained using a 2D-CNN classifier.

The sliding window length of 1000 (5s) and the QSVM classifier demonstrated higher accuracy in applying the sliding window method for ML classification of IMU, GON, and EMG biomechanical signals. The accuracies of the single sensor models IMU, GON and EMG are 0.95, 0.83 and 0.74, respectively. Multi-sensor models have the following accuracies: GON-EMG (0.78), IMU-GON-EMG (0.92), IMU-GON (0.95), and IMU-EMG (0.90). These results highlight whether IMU wearable sensors may be utilized to recognize human gaits. Furthermore, the ML approach was used to assess the effect of IMU sensor location and several methods of data processing on human gait recognition. The outcomes demonstrated that SVM-based classifiers provide superior classification accuracy. The accuracies of IMU single sensor models 'Ft', 'Sh', 'Th' and 'Tr' are 0.693, 0.727, 0.748 and 0.66, respectively. The accuracies of the multi-IMU sensor models 'ShTh', 'ShThFt' and 'All' have been found to be 0.75, 0.799 and 0.839, respectively. Human gait recognition has been evaluated applying the DL approach with regard to the IMU signal and the linear accelerations of the resultant TFA images. The 'STFT-all', 'CWT-all', and 'CWT-BLIV' CNN models had the best test classification performance, based on analyses, with 0.833, 0.809, and 0.794 accuracy and 0.876, 0.857, and 0.846 specificity values, respectively. CNN models using STFT and CWT-based TFA images exhibited the highest classification accuracy when all IMU channels were used together, according to the outcomes of the DL analysis. By comparing the signal filtering and segmentation effects based on the biomechanical sensor position, the human gait recognition performances of single- and dual-input IMU and GON sensor CNN models have been assessed in the aforementioned analyses. The 'IMU-5s,' 'Multi-5s,' and 'Multi-all' models have been shown to provide accuracy in classification averages of 0.910, 0.842, and 0.828, respectively, and specificities of 0.932, 0.882, and 0.871, respectively. Each group could be accurately recognized by applying thigh and shank spectrograms.

In conclusion, the machine learning method is an extremely useful tool for mapping out appropriate temporal gait characteristics for healthy individuals based on wearable biomechanical sensors. Applying the TFA method and 2D-CNN for the classification of gait speed in healthy individuals, this novel work offers reliable multiple classification of gait without discernible differences in wearable sensor outcomes.

December 2023, 121 pages.

Keywords: Human gait recognition, Machine Learning, Convolutional Neural Network, Time-Frequency Analysis, Biomechanical Data, Wearable Sensors

1. GİRİŞ

Gelişen teknoloji ve iyileşen yaşam koşullarıyla birlikte günümüzde ortalama ömür ve yaşlı nüfusu her geçen yıl artmaktadır. Yaşlıların günlük yaşam aktivitelerini kendi başlarına karşılayabilmeleri, giyilebilir sensörlerle etkinliklerinin takibi ve yapay zekâ yöntemleriyle etkinlik örüntülerinin değerlendirilmesi küresel sağlık harcamalarına ayrılan bütçeyi önemli ölçüde etkileyecektir. Özellikle yetişkin ve yaşlı kişilerde yürüyüş, denge, güç ve dayanıklılığı birleştiren çok bileşenli fiziksel egzersizleri aktif olarak sürdürmenin sağlık hizmetlerini iyileştirmenin en uygun yolu olduğu ve bu bireylerde düşmeye bağlı yaralanma olasılığını azaltabileceği düşünülmektedir.

Yaşlılarda yürüme anormallikleri genellikle düşme ve yaralanmalarda, hareketlilikte azalmada, günlük aktivitelerde kısıtlılıkta, sakatlık ve ölümdeki artışla ortaya çıkmaktadır. Azalan adım uzunluğu, kadans, hız ve ortalama hızlanma, anormal bir yürüyüşün belirtileri olabilir. Bireyin kendine has karakteristik yürüyüş hızı (WS), insanın işlevsel yeteneği ve refahı hakkında bilgi sağlamak için kullanılabilen, kolayca ölçülebilen ve güvenilir bir tarama tekniğidir. Yakın gelecekte yürüyüş hızının hekimler için nabız, solunum, kan basıncı, ağrı ve vücut sıcaklığı gibi düzenli olarak gözlemlenebilen beş fizyolojik parametrelerden sonra insanlar için yararlı, bilgilendirici ve işlevsel bir ‘altıncı yaşamsal belirti’ olarak kullanılabilmesi öngörülmektedir.

Bu tez çalışmasında, sağlıklı bireylerin fiziksel yürüyüşünü alt ekstremiteye yerleştirilen giyilebilir biyomekanik sensör verileri yardımıyla yürüyüş hızlarına göre çeşitli makine öğrenmesi ve derin öğrenme yöntemleriyle sınıflandırılması amaçlanmıştır. Bu kapsamda önce yürüyüş örüntüsü, kayan pencereler yöntemiyle zaman domeni sinyal özniteliklerinden makine öğrenmesi algoritmalarıyla tanınmıştır. Sensör yerleşiminin ve farklı pencere boyutlarının sınıflandırma performansına etkileri değerlendirilmiştir. Ardından veri setindeki ham IMU sinyali ve lineer ivmelenmelerinin bileşkesine ait zaman ve zaman-frekans domeni temsillerinin görüntüleri Evrişimsel Sinir Ağlarıyla (CNN) sınıflandırılmıştır. Son olarak sensör verilerine Kısa Zamanlı Fourier Dönüşümü (STFT) uygulanarak spektral güç yoğunluğu haritaları elde edilmiş CNN derin öğrenme yöntemiyle yürüyüş örüntüsü tanınmıştır. İnsan yürüyüş örüntüsü tanımada, farklı sensör yerleşimleri ve sinyal işleme yöntemleri karşılaştırılarak en iyi sensör

ve yöntem kombinasyonu belirlenmiş olup alt ekstremite hareket biyomekaniği açısından değerlendirilmiştir.

Tezin Amacı ve Literatüre Katkısı

Sağlıklı bireylere ait giyilebilir biyomekanik sensör fiziksel yürüyüş sinyallerinin farklı yürüyüş hızlarına göre sınıflandırılması amaçlanan bu tez kapsamında;

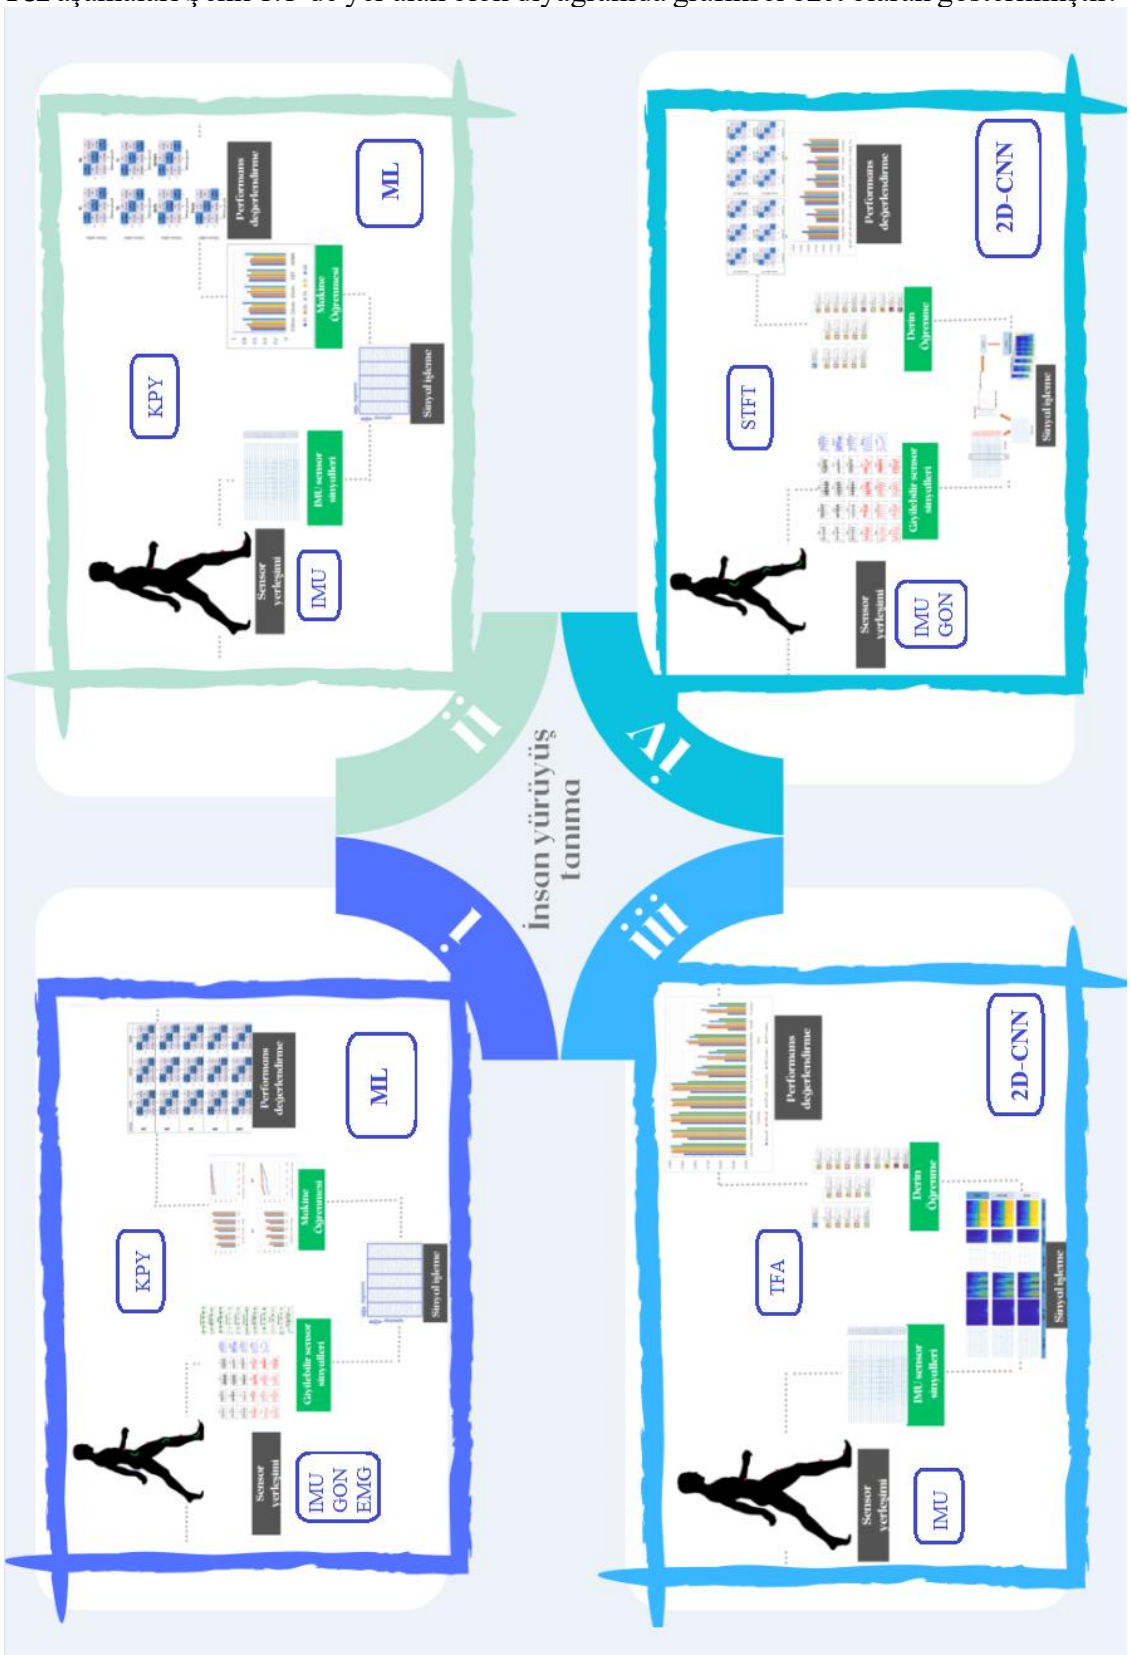
i) Giyilebilir IMU, gonyometre ve EMG sensör veri setleri üzerinde kayan pencereler yöntemindeki kayan pencere boyutu seçiminin insan yürüyüş tanıma performansı üzerine etkisi makine öğrenmesiyle karşılaştırılarak insan alt ekstremite hareket biyomekaniğini değerlendirme açısından incelenmiştir.

ii) Çoklu IMU kanalı içeren zaman serisi sensör verilerinden yürüyüş etkinliğini tanımada en etkili sensör yerleşiminin belirlenmesine yönelik PCA ve veri normalizasyonu gibi farklı yöntemlerin etkisi de incelenerek öznitelikler çıkarılmış ve yürüyüş hızına göre makine öğrenmesi algoritmalarıyla sınıflandırılmıştır.

iii) Giyilebilir çoklu IMU sensöründen elde edilen ham sinyal ve bileşke lineer ivmelenmelerinin, zaman alanı ve zaman-frekans alanı temsillerinin göreceli katkıları, segmentasyon ve spektral görüntü haritaları gibi bazı sinyal işleme yöntemleriyle analiz edilerek önerilen TFA tabanlı CNN derin öğrenme modelinin insan yürüyüşü tanıma performansına katkısı test edilmiştir.

iv) CNN derin öğrenme modeliyle IMU ve GON giyilebilir sensör sinyallerinin STFT görüntülerinden insan yürüyüşü tanıma hedeflenmiştir. Filtreleme ve segmentasyon gibi sinyal ön işleme adımlarının sensör bazlı sınıflandırma başarısı üzerine etkileri değerlendirilmiştir. Ayrıca IMU ve GON sensör verilerinin birlikte kullanıldığı iki girişli CNN modeliyle yürüyüş sınıflandırılmış, performans ölçütleriyle değerlendirilerek sensör konfigürasyonları ve sinyal işleme yöntemleri açısından karşılaştırılmıştır.

Tez aşamaları Şekil 1.1'de yer alan blok diyagramda grafiksel özet olarak gösterilmiştir.



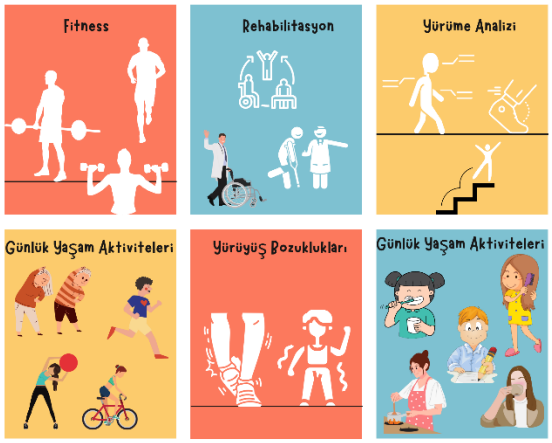
Şekil 1.1: Tez aşamalarını gösteren blok diyagram.

2. GENEL KISIMLAR

Günlük yaşam faaliyetlerini ölçen ve gözlemleyen mobil giyilebilir teknolojiler, sağlık durumunu izleme, insan-bilgisayar etkileşimi ve hareket örüntü tanıma dahil olmak üzere çok sayıda uygulamaya olanak sağlamıştır. Bu uygulamaların büyük çoğunluğu, insan etkinliği tanımayı (HAR) gerçekleştirmek için birçok mobil ve giyilebilir cihazda bulunan düşük güç tüketimli sensörlerin kapsamlı bir koleksiyonundan yararlanılarak gerçekleştirilmiştir. Son zamanlarda, derin öğrenme, mobil ve giyilebilir teknolojilerde HAR uygulamalarının önünü açmıştır. Bu bölümde, giyilebilir teknolojilere dayalı insan etkinliği tanıma için kullanılan giyilebilir biyomekanik sensörler, sinyal işleme yöntemleri, derin öğrenme ve makine öğrenmesi yöntemleri hakkında bilgi verilmiş olup HAR konusunda literatürdeki güncel çalışmalar sunulmuştur.

2.1. İNSAN ETKİNLİĞİ TANIMA

İnsan etkinliği tanıma, veri bilimi, insan davranışı analizi ve insan-bilgisayar etkileşiminde önemli bir araştırma alanıdır. Bu alandaki araştırmalarda, yürüme, oturma, su içme vb. gibi basit ve karmaşık etkinlikleri tanımada makine öğrenmesi ve derin öğrenme algoritmalar kullanılmaktadır. 5G mobil ağların, nesnelerin interneti (IoT) ve yapay zekanın (AI) hızla gelişmesiyle birlikte HAR teknolojisi insanların günlük yaşamında giderek daha fazla önem kazanmaktadır. Günlük etkinliklerin tanınması, sağlıklı yaşam tarzının sürdürülebilirliği, yaşlıların fiziksel aktivite takibi, harekete yardımcı ekipman tasarımı ve kontrolü açısından oldukça önemlidir. Şekil 2.1'de HAR çalışmalarının uygulandığı alanlara bazı örnekler sunulmuştur.



Şekil 2.1: HAR uygulama alanlarına bazı örnekler.

Temel olarak HAR günümüzde iki grupta incelenmektedir. Bunlardan ilki video tabanlı HAR, kameralarla toplanan video ve görüntü verini işleyerek ikincisi ise sensör tabanlı HAR, giyilebilir sensörlerle algılanan farklı modlu verileri kullanarak bireylerin hem duruş hem de gezgin haldeki aktivitelerini, vücut hareketlerini ve eylemlerini tespit etmeye imkân sağlamaktadır. Bu kısımda son yıllarda araştırma odağı haline gelen sensör tabanlı HAR teknolojileri ve uygulamalarıyla ilgili giriş niteliğinde bilgi sağlamak amaçlanmaktadır.

Dünya genelinde doğum oranlarında düşüş ve ortalama yaşama süresindeki artış, yaşlanan bir nüfus yapısına neden olmaktadır. Çoğu toplum, sağlık sistemlerinin demografik değişime uyum sağlamasıyla ilgili hazırlık aşamasında sorunlarla karşılaşmaktadır. Uzun süreli bakım sağlamak için tıbbi ve yardımcı teknolojilerle yeni sistemler geliştirmek veya yaşlıların kendi günlük yaşamsal faaliyetlerini sürdürebileceği ortamlar oluşturmak gibi bazı önlemler, yaşlıların yaşam kalitesini korumak ve iyileştirmek adına araştırılmaktadır. Bilişsel ve fiziksel gerilemeler gibi yaşlanmanın neden olduğu rahatsızlıklar, insanların yaşam kalitesini etkileyebilir, yaralanmalara, nörolojik bozukluklara ve fiziksel hareketlerde kısıtlamalara neden olabilir. Sensörler, kablosuz iletişim ve makine öğrenmesi tekniklerinin ilerlemesiyle insan etkinliği tanıma uygulamalarında, yaşlı insanların günlük yaşamını desteklemeye yardımcı teknolojiler başta olmak üzere insan hareket örüntüsündeki bozukluklarına neden olan patolojik hastalıkların tespit edilmesi, hastalık seviyesinin belirlenmesi ve sınıflandırılması gibi uygulamalarda büyük bir potansiyel sağlamıştır. Yaşlıların ve rehabilitasyon sürecindeki hastaların izlenmesini kolaylaştıran evde sağlık uygulamalarında akıllı telefonlardaki ivmeölçer ve jiroskoplardan yararlanabilir. Bu giyilebilir sensörler, bireyin fonksiyonel kabiliyeti ve yaşam tarzı hakkında bilgi sağlar.

Yürüme, çeşitli koşullar ve ortamlarda gerçekleştirilebilen en yaygın insan fiziksel aktivitelerinden biridir. İnsan yürüyüş örüntülerinin analizi, fiziksel ve nörolojik fonksiyonlarla ilgili önemli bilgiler sağlayabilir ve patolojik durumlarda insan motor bozuklarının teşhisinde katkıda bulunabilir.

2.2. YÜRÜYÜŞ TANIMA SİSTEMLERİ

Motor işlevleri yerine getirirken kas-iskelet biyomekaniği hakkında nicel bilgilerin elde edilmesi, insan hareket analizi ve yürüyüş tanımanın önemli bir aşamasıdır [1]. İnsan hareket örüntü tanıma çalışmalarında yaygın olarak kullanılan referans geleneksel teknolojiler (Mocap sistemleri ve kuvvet plakaları) ve giyilebilir sensör teknolojileri (IMU) olmak üzere iki grupta incelenebilir [2].

2.2.1. Referans Geleneksel Teknolojiler

Mocap olarak bilinen hareket yakalama sistemleri işaretçili ve işaretsiz sistemler olarak sınıflandırılmaktadır. İşaretleyicilerin yer değiştirmesini hesaplamaya yönelik video tabanlı bir optoelektronik sistem ve Newington modeli gibi çeşitli modeller ile birlikte yansıtıcı işaretleyiciler kullanılmaktadır. Yansıtıcı işaretleyiciler, özel kıyafet gibi ek donanım ve zaman alıcı kurulum hazırlığı gibi sınırlamalar, araştırmacıları geleneksel kameraların çeşitli üç boyutlu kameralarla birlikte yer aldığı daha kullanışlı işaretsiz sistemler geliştirmeye yöneltmiştir. Hareket analiz sistemleri, eklemler (örn. kalça, diz, ayak bileği) hareketi ve uzay-zamansal parametreler (örn. adım süresi ve hız) açısından kinematik verileri elde etmek için başarıyla kullanılmıştır [3] ancak iyi bilinen diğer referans standartlarıyla karşılaştırıldığında daha yüksek doğruluk oranlarına rağmen yüksek maliyetleri ve geniş alan gereksinimleri araştırmacılar ve klinisyenler tarafından kullanımlarını engellemektedir [4].

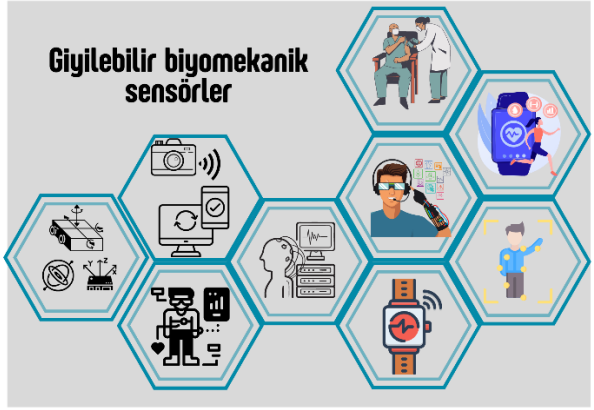
Kuvvet plakaları (FP) olarak da bilinen kuvvet ölçüm teknolojileri basınç sensörleri ve yük hücreleri (LC) aracılığıyla yer tepki kuvveti (GRF) ve bu uygulama noktası (CoP), momentlerini ölçmektedir. FP'ler, hareketin nasıl üretildiğini ve sürdürüldüğünü anlamak amacıyla yaygın olarak kullanılmaktadır [5], ancak küçük boyutları nedeniyle sadece ayak vuruşlarıyla sınırlıdır. Alternatif olarak, bir basınç sensörü dizisi kullanılan ekipmanlı koşu bantları veya basınçlı yürüme yollarıyla da tekrarlanan ayak vuruşlarını algılanabilmektedir. Kinematik yürüme özelliklerinin ölçümü için ekipmanlı koşu bantlarının performans

değerlendirmesi, video tabanlı sistemle yapılan bir karşılaştırmanın sonucu olarak incelendiğinde ekipmanlı yürüme yollarının zamansal parametreler açısından karşılaştırılabilir sonuçlar verdiğini fakat mekansal performansın doğruluğunu değerlendirmek için daha fazla araştırmaya ihtiyaç olduğunu göstermiştir. Ayrıca, ekipmanlı yürüme yolu sistemleri, altın standart olarak geniş çapta kabul görmelerine rağmen hatasız değildir [6, 7].

2.2.2. Giyilebilir Sensör Teknolojileri

Giyilebilir sensör sistemleri bir dizi algılama teknolojisini barındırmakla birlikte en tercih edileni 1970'lerden bu yana, insan hareketine ait olan hızlanma sinyallerini algılamakta kullanılan atalet ölçüm üniteleridir. Mikro-elektromekanik sistemlerdeki (MEMS) gelişmelerin ilerleyişi, atalete dayalı giyilebilir teknolojilerin (IMU), kolay erişilebilirlik, düşük maliyet, gezgin kullanım gibi birçok avantajının olması nedeniyle referans standartların yerini almasını sağlamıştır [8, 9].

Şekil 2.2'de gösterilen ivmeölçer, jiroskop ve magnetometrelerden oluşan ivme ölçer üniteleri giyilebilir sensörler teknolojilerinde önemli bir yere sahiptir. Son yıllarda, geleneksel yürüyüş laboratuvarındaki optik sistemler ve kuvvet ölçer platformunun hantal ve pahalı yönlerinin üstesinden düşük-güç tüketimli, ekonomik ve hassas giyilebilir sensörler gelmeye başlamıştır.



Şekil 2.2: Giyilebilir biyomekanik sensör örnekleri.

İvmeölçerler, 3B doğrusal ivmeleri ölçebilen, zamansal ve uzamsal sonuçları değerlendirmek üzere ayağın ilk-son temas olaylarını saptamaya yarayan en tercih edilen yürüyüş tanıma sensörüdür. 3B açısal hızları ölçebilen jiroskoplar ise, bireyin ya da cismin dönüşünün tespitine yardımcı olmaktadır. Manyetometreler, belirli bir konumdaki manyetik alanın değişimini ölçme kapasiteleri nedeniyle sensör birleştirme teknikleriyle ivmeölçerlerin ve jiroskopların algılama

yeteneklerini artırmak için sıklıkla kullanılmaktadır [9]. İvmeölçerler ve jiroskoplar yürüyüş değerlendirmesi için ayrı ayrı kullanılabildiği gibi bu sensörlerin manyetometreler ve diğer ekipmanlarla birlikte de uygulanabilmektedir. İnsan hareketi analizinde IMU'ların tercih edilmesi için çeşitli nedenler sıralanabilir [10, 11]. İlk olarak, ivmeölçerler ve jiroskoplar çalışma sırasında bağımsızdır, zamandan ve ortamdan bağımsız olarak niceliksel hareket verilerini toplayabilir. Ayrıca dünya üzerinde her yerde bulunan bir manyetik alanın varlığı manyetometrelerin yaygın olarak uygulanmasını mümkün kılmaktadır. İkinci olarak, ticari olarak temin edilebilen IMU'lar küçük, hafiftir ve ek donanımla (örn. Bluetooth, Wi-Fi, SD kart), kablosuz veri iletimi veya dahili bellek kaydı gibi uygulamalara entgere edilebilmektedir [12].

Newton'un ikinci yasasına göre, sabit kütleli (kg) bir nesne, uygulanan net kuvvetle (N) orantılı olarak ivmelenir (m/s^2). İvmeölçerler, piezoelektrik, termal ve kapasitif gibi farklı yaklaşımlardan faydalanılarak bu prensip temelli geliştirilmektedir. İvmeölçerler, bant genişliklerinin veya frekans yanıtlarının kuplaj filtre kapasitörleri aracılığıyla ayarlanabildiği yüksek düzeyde yapılandırılabilir cihazlardır. Bu, algılamanın doğruluğunu artıran önemli bir avantajdır, çünkü ölçüm harekete ait bant genişliği ilgili frekansı veya titreşimi içermelidir. Menzil ($g = 9.81\ m/s^2$) ve örnekleme frekansı (f_s, Hz), ölçülecek aktivite tipi dikkate alınarak seçilmesi gereken ilgili ek parametrelerdir [13]. Bir ivme ölçerin dinamik aralığı, veri toplama sırasında çıkış sinyalini bozmadan önce ölçülebilen ± maksimum genliktir. Postural denge gibi düşük yoğunluklu hareketler, daha düşük g değerleri ile daha hassas bir şekilde değerlendirilirken yürüyüş gibi yüksek genlikli (aralıklı) hareketi bozmadan veya kırpmadan yakalalabilmek amacıyla daha yüksek g değerleriyle doğru bir şekilde değerlendirilmektedir. İvmeölçer tabanlı giyilebilir cihazların çoğu seçilebilir aralıklara sahiptir; ancak optimum aralık hem hareketin türüne hem de hareketi yapan vücut kısmına bağlıdır [14, 15].

Açısal hızı (°/s) ölçen jiroskoplar, ivmeölçerlerden sonra en yaygın tercih edilen atalet sensörüdür. Yerleştirme sırasında, jiroskopun hassasiyetini gösteren ölçek faktörü kararlılığı dikkate alınmalıdır. Minimum ölçek faktörü kararlılığı, küçük sensör hatalarına yol açar ve rastgele yürüme açısı (ARW) = R /60sqrt(B) ile ifade edilebilirken burada R ve B, sırasıyla çözünürlüğü ve bant genişliğini temsil etmektedir [15, 16].

Manyetometreler, belirli bir konumdaki manyetik alanın (Gauss) yönünü, gücünü ve değişimini ölçmektedir. Spesifik olarak, manyetometreler Dünya'nın manyetik alanına duyarlıdır ve

kaymayı düzeltmek veya bilinen bir yöndeki dönüşlerin saptamak amacıyla yararlanılmaktadır. Manyetometreler olmadığında, hareketin 6 eksenli (üç eksenli ivmeölçer ve jiroskop) kaymaların dahil olduğu görece yön belirlenmektedir. Manyetometreler dahil edildiğinde ise, Dünya'nın manyetik alanının küresel bir referans noktası sağlanarak ölçümdeki kaymalar azaltılabilmektedir. Ancak manyetometreler, serbest uzay gibi kontrolsüz ortamlarda değişebilen bölgesel manyetik alanlardan etkilenebilmektedir [17, 18].

Diğer bir giyilebilir sensör türü olan EMG sensörleri ise, iğne veya yüzeyel elektrot gibi farklı türler kullanılarak kastaki miyoelektrik sinyalleri kaydetmektedir. İğne elektrotlar kas-sinir bozukluklarını saptama amacıyla kasa invaziv uygulanırken, yüzeyel elektrotlar ise cilt üzerine non-invaziv yerleştirilerek kastaki elektriksel aktiviteleri kaydetmeye yönelik kullanılmaktadır. İlki daha güvenilir sonuçlar sağlar ancak uygulama açısından sınırlayıcıdır [19, 20]. Miyoelektrik sinyalleri genellikle milivolt (mV) seviyesinde ve 10-1000 Hz frekans aralığındadır. Örneğin; bir kas kasılması, doku yer değiştirmesinin bir sonucu olarak 10 Hz civarında sinyaller üretebilirken, yürüme sırasındaki bir yer tepkisi 25-30 Hz sinyaller üretebilmektedir. EMG sinyali, düşük sinyal genliğine sahip olduğundan, çoğunlukla doku hareketinden ve komşu motorlardan kaynaklanan istenmeyen sinyallere yani gürültüye karşı daha hassastır. Bu gürültüler, sinyal alımı ve son işleme sırasında belirli seviyelerde algılanarak ortadan kaldırılmaktadır. Sinyal kaydı sırasında, bir çift yüzey elektrotu ve aynı yönde akan bir gürültü olan ortak mod sinyali dahil olmak üzere istenmeyen elektronik sinyaller, diferansiyel amplifikatörler veya enstrümantasyon yükselteci kullanılarak ortadan kaldırılabilir. Bu yükselteçler büyük ortak mod reddetme oranına (CMRR) sahiptir [21]. Sinyal kaydı sonrası gürültü filtreleme için, sEMG frekans spektrumu dikkate alınarak dijital alçak geçiren, yüksek geçiren veya bant geçiren filtreler kullanılmaktadır. sEMG'nin en büyük dezavantajı, ilgilenilen kas dışındaki komşu kasların aktivitelerini kaydetme olarak ifade edilebilecek bir olay olan çapraz konuşmadır. Genellikle 1 kHz örnekleme frekansına sahip bir sEMG kullanılırken gürültü etkisini azaltmak için 10 Hz düşük kesme ve 500 Hz yüksek kesme ile bant geçiren filtreler önerilmektedir [22, 23].

2.3. DİJİTAL SİNYAL İŞLEME YÖNTEMLERİ

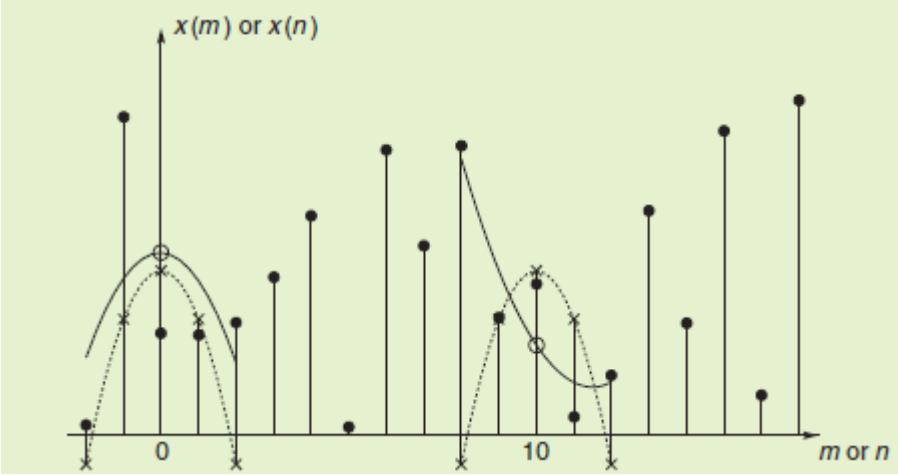
2.3.1. Savitzky-Golay Filtresi

Giyilebilir sensör sinyalleri aktivite sırasındaki sinyal bozucu etkiler, çoklu sensör ortamında sensörlerin birbiriyle girişimi gibi gürültülerle birlikte algılanmaktadır. Sinyalin bu

gürültülerden arındırılması için Kalman filtresi, hareketli ortalama filtre (moving average), ortanca filtre (median) ve Savitzky-Golay (SG) filtresi kullanılmaktadır [24, 25]. Ayrıca IMU sensörlerle yürüyüş analizi çalışmalarında 5 Hz kesim frekansına sahip Butterworth alçak geçiren filtreler yüksek firekanslı sinyalleri bastırmak amacıyla uygulanmaktadır. İvmeölçer ve jiroskoplarla algılanan üç eksenli yer değiştirme sinyalleri eklem fleksiyon/ekstansiyon açısı değerlendirmesinde öncelikle SG filtresi uygulanmaktadır.

SG filtresinin en önemli avantajı, hareketli ortalama filtresiyle genellikle mümkün olmayan sinyalin şeklini koruma kapasitesidir. Doğru çerçeve boyutu ve sırası seçilirse, SG filtresinin performansı geleneksel filtrelerden çok daha üstündür. Uyarlanabilir SG filtreleme, yinelemeli analiz ve sinyal korelasyonu kullanarak en uygun çerçeve boyutunu ve sırasını seçmeye yardımcı olur [26, 27]. Ayrıca işlem hızı önemli ölçüde artar. Belirli bir uygulama için filtre katsayılarının yalnızca bir kez değerlendirilmesi gerekir, bu da filtreleme işlemini basit, kolay ve hızlı hale getirir. Teknik, parametre değerlendirme dezavantajının üstesinden gelmenin yanı sıra, en iyi filtrelenmiş sinyali elde etmek için optimal değerlerin kullanılmasına izin verir [28].

İvmeölçer sensör sinyallerini filtrelemede yaygın olarak ivmenin zamana göre türevi, bir dizi veri noktasını farklı derecelerdeki polinomlara en iyi şekilde uyduran bir düzleştirme (smoothing) ve türev alıcı filtre olan SG filtresinden yararlanılmaktadır [29]. Bu filtre, en küçük kareler yöntemini kullanarak her bir veri noktasında bitişik veri noktalarına en iyi uyan k'ıncı dereceden bir polinom uydurur. Ardından bilgi içeren bir veri dizisi olduğunda geçerli veri değerini ayarlar. Dönüştürme kullanarak bir polinomun sonucunu doğru şekilde bulabilen bir işlem olan bu filtre, sensör verilerindeki tepe noktalarının genişliğini, maksimum ve minimum noktalarını korumaktadır. Bu filtre Şekil 2.3'te temsil edilmiştir. Yani x_n'nin yeni değeri, her iki tarafın yakınında $2M + 1$ nokta kullanarak polinomu döndüren ve x_n'i $p_n(x_n)$ ile değiştiren bir p_n formülü bulunur. Bu yaklaşımla, yakalanan ardışıklığın düzleştirilmiş hali elde edebilir.



Şekil 2.3: Savitzky-Golay filtresi [29].

Şekil 2.3'teki $n = 0$ merkezli $2M + 1$ örnek grubu dikkate alındığında, bir polinomun katsayılarını elde edilmektedir. Analiz, diğer $2M + 1$ girdi örnekleri grubu için aynıdır. $N = 2$ ve $M = 2$ olmak üzere soldaki kalın eğri -2 ile +2 arasında ince bir ızgara üzerinde değerlendirilen p(n) polinomudur ve değerlendirilerek düzleştirilmiş çıkış değeri elde edilir. p(0) merkez noktasında $n = 0$'daki çıktıdır. Yani çıktı değeri, sıfırıncı polinom katsayısına eşittir. Bir sonraki örnekteki çıktı ise, analiz aralığını bir örnek sağa kaydırarak, orijini $2M + 1$ örneklerinden oluşan yeni bloğun orta örneğinin konumu olacak şekilde yeniden tanımlayarak ve polinom uydurma ile değerlendirmeyi tekrarlayarak merkezi konumu elde edilir. Bu, girdinin her örneğinde tekrarlanabilir, her seferinde yeni bir polinom ve p_n çıktı dizisinin yeni bir değeri üretilir. Başka bir örnek Şekil 2.3'te sağda gösterilmektedir, burada aralığın merkezi $n = 10$ örneğine kaydırılmıştır. $8 \leq n \leq 12$ örneklerine uyan yeni polinom kalın eğri ve $n = 10$'daki çıktı ile tekrar gösterilmiştir ve bu değer, merkez konumda değerlendirilen yeni polinomun değeridir.

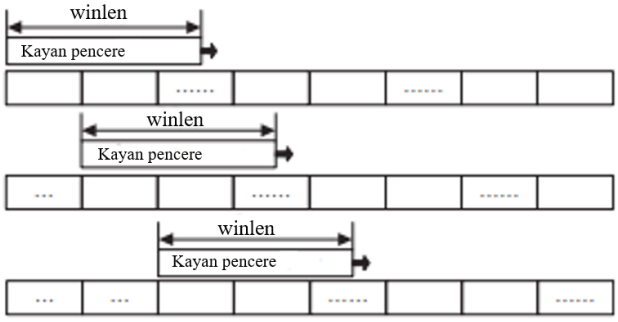
2.3.2. Kayan Pencereler Yöntemi

Sensör veri segmentasyonuyla ilgili önceki çalışmalar manuel segmentasyon (bölütleme), eşikleme yöntemleri, kayan pencere yöntemleri, hibrit yöntemler ve derin öğrenme olmak üzere beş grupta incelenmiştir [30]. Manuel segmentasyon, sensör verilerini, segmentasyon referansları gerektiren kullanışlı veri segmentlerine manuel olarak bölmeyi ifade eder. İki bitişik aktivite arasında birkaç saniye duraklama, manuel segmentasyonu kolaylaştırabilirken manuel segmentasyon, oldukça fazla zaman, insan gücü ve kaynak tüketir ve gerçek zamanlı sistemlerde çalışamaz. Eşikleme yöntemleri, gerçek zamanlı segmentasyonu gerçekleştirebilen sabit eşik ve değişken eşik yöntemlerinden oluşur fakat performansın hassasiyeti düşük ve hata

oranı yüksektir. Hibrit yöntemler ve derin öğrenme yöntemlerin kullanıldığı diğer segmentasyon yöntemleri giyilebilir cihazlar için uygun olmayan karmaşık, zaman alıcı ve hesaplama yükü gerektirir.

Gerçek zamanlı günlük yaşam aktivitelerini tanıyabilen sistemlerin doğruluğu, büyük ölçüde sinyal bölütleme için işleme adımına bağlıdır. Verileri bölümlere ayırmak için sıklıkla pencereleme yaklaşımları kullanılmıştır. Pencere boyutu ve örtüşme boyutunun segmentasyon performansını etkileyen iki temel etken olduğu kayan pencereler yöntemleri, insan etkinliği tanıma bağlamında oldukça popüler olup segmentasyon ön işleme adımını gerçekleştirmeyi amaçlamaktadır. Kayan zaman penceresinin boyutu, etkinlik tanıma sonuçlarını etkileyecektir. Zaman penceresi çok büyükse, birden çok faaliyetin bilgisini içerebilir ve tanıma sisteminin tepkiselliğini azaltarak hesaplama yükünü artıracaktır. Tam tersine, zaman penceresi çok küçükse, bazı etkinlikler ardışık birden çok pencereye bölünebilir, tanıma görevi çok sık tekrarlanır fakat yüksek tanıma sonuçları elde edilemeyecektir [30, 31].

Kayan pencere yönteminin uygulanma süreci Şekil 2.4'te gösterilmektedir, burada winlen, kayan pencerenin boyutudur. Kayan pencere taramasından sonra, her bir ham giyilebilir sensör verisi zaman ekseni boyunca segmentlere ayrılmakta, bu da sinyalin tamamının ayrıntılı olarak taranmasını sağlamakta ve bu segmentlerden çıkarılan öznitelikler makine öğrenmesi giriş matrisini oluşturmaktadır.



Şekil 2.4: Kayan pencereler yöntemi uygulanması [32].

Hem kısa hem de uzun süreli etkinlikler dikkate alındığında, pencere boyutu seçiminin elde edilen etkinlik tanıma doğruluğu üzerindeki etkisinin araştırılması konusunda literatür belirsizdir. İnsan etkinlik tanıma çalışamalarında belirli uygulama senaryolarına ve gereksinimlerine bağlı olarak, kayan zaman penceresinin boyutu 0.08 saniye - 2 saniye ve hatta 30 saniyeye kadar seçilebilmektedir [32]. Pencere uzunluğunun tanıma performansını doğrudan

etkilediği göz önüne alındığında, yöntemleri karmaşık olmasına rağmen Wang ve ark. [33] farklı pencere boyutlarını karşılaştırarak 2.5s - 3.5s'nin hareket tanıma için ve 0.5s'nin duruş örüntü tanıma için en uygun sonucu sağlayabileceğini bulmuşlardır. Literatürdeki çalışmalar incelendiğinde ardışık kayan pencereler örtüşmeyebileceği gibi, bazı çalışmalar ise %25 - %50 örtüşmeyi önermektedir [34]. Pencere boyutu uygun şekilde ayarlanırsa, bu basit yaklaşım, izlenen etkinlikler benzer sürelere sahip olduğunda yüksek doğrulukta sonuçlar sağlamaktadır. Ayrıca birkaç çalışmada uyarlanabilir kayan pencereye odaklanılmıştır. Noor ve ark. [35], tek bir üç eksenli ivmeölçer kullanarak fiziksel aktiviteyi tespit etmek için zaman penceresini genişleten uyarlanabilir bir pencere yöntemi önerirken, Ni ve ark. [31], etkinlik örneklerinin bilgisini elde etmek için pencere başlangıç noktası ve bitiş noktasını dinamik olarak tanımlamak için değişiklik noktası tabanlı bir bölütleme yöntemi önermiştir. Farklı aktiviteler arasındaki geçişlerin de dikkate alındığı günlük yaşam aktivitelerinin tanınmasında pencere boyutunun etkisini sunan başka bir uyarlanabilir kayan pencere çalışmasında ise 1.5s pencere boyutunun %90'ın üzerinde bir doğrulukla etkinlikleri sınıflandırdığına ulaşılmıştır [30].

2.3.3. Zaman-Frekans Analizi Yöntemleri

Zaman-frekans analizi (TFA), sinyalleri aynı anda hem zaman hem de frekans alanında analiz etmeyi amaçlayan bir sinyal işleme dalıdır. TFA'nın genel fikri, salınım davranışını her bir zaman noktasında yerel olarak incelemektir. Tek boyutlu bir fonksiyon olan belirli bir sinyalin zaman-frekans dönüşümü sonucunda iki boyutlu bir fonksiyon temsili elde edilmektedir. Bu temsille salınım bilgisinin çıkarılması, sinyalin ayrıştırılması ve filtrelenmesi gibi çeşitli görevleri gerçekleştirebilmektedir [36, 37]. Doğrusal TFA yöntemleri arasında Kısa Zamanlı Fourier Dönüşümü (STFT) ve Sürekli Dalgacık Dönüşümü (CWT) bulunmaktadır.

Ayrık Fourier dönüşümü $X(k)$, bir dijital sinyali $x(n)$ temel fonksiyonların (harmonikler) toplamı olarak temsil etmek için kullanılır. Bu Denklem 2.1'deki genel form ile yazılabilir [38]:

$$X(k) = \sum_{n=1}^{N} x(n) e^{-j\omega_k n} \tag{2.1}$$

Burada $k, n = 1,2.... N$ için açısal frekans $\omega_k = \frac{2\pi k}{N}$

Seri açılımı Denklem 2.2'deki şekilde yazılınca

$$x(n) = \frac{1}{2} a_0 + \frac{1}{N} \sum_{k}^{N-1} a_k \cos\frac{2\pi nk}{N} + b_k j \sin\frac{2\pi nk}{N} \tag{2.2}$$

Burada a_0, DC eğilimidir (sıfır frekans), a_k ve b_k, $k = 1,2 \ldots . N$ harmonikleri için Fourier katsayılarıdır ve $x(n)$ sinyaliyle aynı birimlere sahiptir. Fourier dönüşümleri bu nedenle, sinyal frekans içeriği hakkında bilgi sağlamak için güçlü bir sinyal işleme tekniğidir. Fourier katsayıları benzersiz olduğundan, bir sinyali karakterize etmek için kullanılabilirler. Bir sinyaldeki k-ncı harmoniğin gücü, Denklem 2.3'te gösterildiği şekilde tanımlanan güç büyüklüğüyle ölçülebilir:

$$P_k = a_k^2 + b_k^2 \tag{2.3}$$

$x(n)$ sinyalinin güç spektrumu, $x(n)$'deki tüm harmonikler üzerindeki güç büyüklüklerini gösteren bir grafiktir ve insan yürüyüş aktivitelerinde sinyal frekanslarını belirlemek için kullanılabilir [39].

Durağan olmayan zamanla değişen sinyallerin analizinde geleneksel bir zaman-frekans analizi yöntemi olan Kısa Zamanlı Fourier Dönüşümü (STFT) yaygın olarak uygulanmaktadır çünkü bu sinyallerin Fourier Dönüşümüyle analizi sınırlıdır. Bu soruna çözüm olan STFT yönteminde sinyalin üzerinde bir kayan pencere uygulanarak sinyal segmentleri elde edilir ve her bir segmentin ayrı ayrı Fourier Dönüşümü hesaplanarak sinyalin zamanla değişen spektral karakteristiği elde edilir. Sinyalin spektrogramı, STFT dönüşümünden sonra sinyalin karesinden STFT'si hesaplanabilir. $x(t)$ sinyali, $\omega(t)$ pencere fonksiyonu ve f frekansı verildiğinde, spektrogram Denklem 2.4 ve Denklem 2.5'teki gibi hesaplanır [37].

$$spektrogram\big(x(t), \omega(t)\big) = |STFT_x(t,f)|^2 \tag{2.4}$$

$$STFT_x(t,f) = \int_{-\infty}^{+\infty} [x(u)\omega(u-t)]\, e^{-j2\pi f u} du \tag{2.5}$$

Sürekli Dalgacık Dönüşümü (CWT), STFT'ye benzer bir zaman-frekans analizi yöntemidir fakat bu yöntem STFT'deki pencerenin frekansla değişmeyen eksikliklerin üstesinden gelmektedir. CWT, pencerenin genişliğini ayarlayarak sinyaldeki frekans değişikliğine uyum sağlayabilir. Sinyalin yüksek frekans bileşenlerini barındıran kısmında CWT yöntemi zaman penceresini daraltarak sinyal çözünürlüğünü artırır. Ayrıca etkili bir sinyal analiz aracı olan CWT, bir sinyaldeki değişimleri genlik ve frekans spektrumunda karakterize etme yeteneğine sahiptir [37].

$$X(a,b) = \frac{1}{\sqrt{b}} \int_{-\infty}^{+\infty} x(t) \varphi \left(\frac{t-a}{b}\right) dt \tag{2.6}$$

$$\int_{-\infty}^{+\infty} \frac{|\varphi(\omega)|^2}{\omega} d\omega < \infty \quad (2.7)$$

Denklem 2.6 ve Denklem 2.7'de CWT yöntemine ait denklemlere yer verilmiştir, Denklem 2.6'daki $\varphi(\omega)$, $\omega(t)$'nin Fourier Dönüşümüdür. Ana dalgacık fonksiyonu olarak tanımlanan $\omega(t)$ sınırlı süreli, değişken frekanslı ve sıfır ortalamalı bir sinyal olma koşullarını sağlamalıdır. Ölçeklendirme faktörü olan b, dalgacık fonksiyonunun ölçeklendirilmesini kontrol ederken ötelenme miktarı a ise dalgacık fonksiyonunun ötelenmesini kontrol eder. Sinyale Sürekli Dalgacık Dönüşümü uygulanmasından sonra, ölçek olarak görüntüye benzer olan ve aynı zamanda zamanlama sekansı verilerinin frekans alanı bilgisini içeren skalogram spektrumu elde edilmektedir.

2.4. DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ

Biyomedikal uygulamalar başta olmak üzere bilimin birçok alanında sınıflandırmadan yararlanılmaktadır. Makine öğrenmesi ve derin öğrenmede sınıflandırma problemleri, veri setindeki örneklerin, sınıflandırıcı bir model yardımıyla gerçek gözlemlerin eğitilerek bilinmeyen yeni gözlemlerin tahmin edilmesi ya da bu gözlemlerin sınıflandırması olarak ele alınmaktadır. İnsan yürüyüş tanımada mevcut bir klinik zorluk, sağlıklı bir yürüyüş paternini patolojik olandan ayırt etmek ve hareket sırasında yürüme bozukluklarının ilerlemesini değerlendirmektir. Bu nedenle, istatistiksel analiz, matematiksel dönüşümler ve makine öğrenimi yaklaşımlarına dayalı yürüyen sınıflandırma yöntemleri uygulanmaktadır [40]. İstatistiksel analiz yaklaşımları, niceliksel analizin zorluklarını karşılamada yetersiz kalmıştır ve sıklıkla, girdi verileri için normal bir dağılım varsaymaktadır [41]. Ek olarak, matematiksel dönüşümler, tek değişkenli sinyallerin uygulamaları ve dalgacıklara dayalı kılavuz seçimi ile sınırlıdır [42]. Buna karşılık, çalışmalar, makine öğrenimi algoritmalarının yürüyüş verilerinde hem kalıpları yakalamada hem de karmaşık doğrusal olmayan ilişkileri modellemede daha büyük bir performans gösterdiğini ortaya koymaktadır [43, 44]. Ek olarak, bu algoritmalar çok boyutlu verilerle uygun şekilde çalışmakta ve tahmin başarısını iyileştirmeye yönelik yeni mevcut verileri kolayca birleştirmektedir [45]. İnsan yürüyüş verileri gibi doğrusal olmayan ve çok boyutlu verileri ele alma yeteneği ve yeni mevcut verileri uygun şekilde işleme yeteneği, makine öğrenimi yaklaşımlarını insan yürüyüş modelini tanıma için uygun yöntemler haline getirmektedir.

HAR uygulamalarında yararlanılan makine öğrenmesi örüntü tanıma yaklaşımında öncelikle, sensörlerden ham sinyaller elde edilmektedir. İkinci olarak uzman bilgisine dayalı klasik ML yaklaşımlarındaki ortalama, varyans ve genlik gibi manuel olarak öznitelikler çıkarılmaktadır. Son olarak, bu öznitelikler HAR uygulamasında bir örüntü tanıma modelinin eğitiminde giriş verisi olarak kullanılmaktadır. Geleneksel ML yaklaşımları HAR uygulamalarında iyi sonuçlar vermesine rağmen birkaç dezavantaja sahiptir. Bunların başında, özniteliklerin kullanıcı deneyimi ve alan bilgisine bağlı olarak manuel çıkarılması gelmektedir. Uzmanlık bilgisi belirli alana özgü kısımda sınıflandırma performansını artıcı etki gösterirken genele uygulandığında başarım düşebilmekte veya işlem süresi uzayabilmektedir. Bir diğer dezavantaj, uzmanlık alanındaki kullanıcıların genellikle ortalama, varyans ve frekans gibi yüzeysel istatistiksel bilgilere eğilim göstermesidir. Bu bilgilerden yürüme, zıplama gibi bağlama dayalı etkinliklerin tanınmasında faydalanılabilirken saç taramak gibi karmaşık bir hareketin tanınmasında etkin bir şekilde yararlanılamamaktadır. En önemli diğer bir dezavantaj ise HAR veri setlerindeki etkinlik verilerinin çoğunluğu etiketlenmemiş verilerdir ve denetimsiz ML uygulamalarında sınıflandırma performansını olumsuz etkilemektedir. Derin öğrenme ağlarında model eğitiminin etiketlenmemiş verilerle de gerçekleştirilebilirliği bu olumsuzluğun giderilmesi için önemlidir.

Derin öğrenme uygulamalarında öznitelikler, ham sensör verilerinden herhangi bir öznitelik çıkarma işlemene gerek duymaksızın otomatik olarak öğrenilebilir. Derin sinir ağları, derin katmanlarda giriş verilerini temsilini çıkararak karmaşık etkinlik tanımada üstünlük sağlayabilmektedir. Ayrıca büyük miktarda etiketlenmemiş verilerin olması durumunda derin öğrenme model eğitiminde etiketlenmemiş bu veriler doğrudan kullanılabilir.

2.4.1. Makine Öğrenmesi

İnsan yürüyüş tanıma çalışmalarına sıklıkla kullanılan makine öğrenmesi algoritmaları şunlardır:

Yapay Sinir Ağları (ANN), biyolojik sinir sistemlerinin yapısından ve işlevsel yönlerinden esinlenilen matematiksel bir modeldir. ANN genel yapısı itibariyle, birimler arasındaki bağlantıların yalnızca gizli katmanlar aracılığıyla giriş katmanından çıkış katmanına ilerlediği, birbirine bağlı bir dizi nörondan oluşan çok katmanlı bir ileri beslemeli sinir ağıdır. Girişler, bir giriş katmanı aracılığıyla düğümlere eşlenir ve çıkışlar, her düğüm içindeki bir transfer

fonksiyonu tarafından kontrol edilir ve hata fonksiyonunu azaltmak için düğümler arasındaki bağlantıların ağırlıklarını ayarlamak gerekmektedir [46-49].

Destek vektör makinesi (SVM), insan yürüyüş verileri, esas olarak patolojik veriler gibi doğrusal olmayan verileri daha yüksek boyutlu bir özellik uzayına eşlemek amacıyla doğrusal, polinom ve Gauss RBF gibi farklı çekirdek yöntemlerini kullanan denetimli bir sınıflandırıcıdır. Bu öznitelik uzayında sınıflandırma, analiz edilen sınıflar arasında optimal bir ayırıcı hiperdüzlem bulunarak gerçekleştirilmektedir. Bu optimizasyon probleminde, maksimum marj genişliği ile minimum sınıflandırma hatası arasındaki dengeye karşılık gelen C parametresi hesaplanmaktadır [48-53].

Naïve Bayes (NB), Bayes teoremine göre tüm özelliklerin birbirinden bağımsız olduğunu varsaymaktadır. İlk olarak, NB sınıflandırıcısı, bir girdi örneğinin belirli bir sınıfa ait olma olasılığını tahmin eden olasılıksal bir model oluşturmaktadır. Biyomekanik yürüyüş verileri için, olasılıksal model yaygın olarak normal dağılım yoluyla uygulanmakta ardından, verileri en olası sınıfla eşleştirmek için bir karar kuralı uygulanmaktadır [52, 54].

Lojistik regresyon (LR), çıktıyı bir mantık değişkenine dönüştürdükten sonra maksimum olasılık tahminini uygulayan, sınıflandırma için ayrımcı bir modeldir. Bu şekilde LR, girdi özelliklerinin belirli bir sınıfa ait olup olmama olasılığını tahmin etmektedir. Diskriminant analizi, girdi verilerini en küçük kareler algısına göre iki veya daha fazla sınıfa ayırarak, lineer (LDA) veya kuadratik (QDA) kombinasyonunu bulmayı amaçlar [52, 54]. Her giriş özelliğinin kendi atanmış ağırlığı vardır, bu da bu özelliğin sınıflar arasında ayrım yapmadaki önemini göstermektedir.

Karar ağaçları (DT), sıklıkla sınıflandırma problemlerinde kullanılabilen denetimli bir öğrenme tekniğidir. Bir veri kümesinin özellikleri iç düğümlerle temsil edilirken, karar kuralları ise dallarla temsil edildiği ağaç yapılı bir sınıflandırıcı türüdür. Bir karar ağacında, karar düğümü ve yaprak düğümü olmak üzere iki düğüm vardır. Karar düğümleri herhangi bir karar vermek için kullanılır ve birden fazla dala sahiptir, yaprak düğümleri ise bu kararların çıktısıdır ve başka dallar bulundurmaz. Verilen veri setinin özelliklerine göre kararlar ya da test işlemi gerçekleştirilir. Belirli koşullara dayalı olarak bir soruna veya karara tüm olası çözümlerin elde edilmesi için grafiksel bir gösterimdir [31, 49, 53, 54].

Ayrıca, K-En Yakın Komşular (KNN), girdi verilerinin özelliklerini komşularıyla olası benzerliğe dayalı olarak tanımlayan hiyerarşik olmayan bir kümeleme yöntemidir. Komşuluk, k nokta içerecek şekilde tanımlanır ve bir sorgulama noktasının en yakın komşularını belirlemek için bir mesafe metriği (örn., Öklid mesafesi) kullanılmaktadır. Bu nedenle, yeni örneği en yaygın k örnek sınıfıyla sınıflandırmak için k (burada k ≥1) en yakın eğitim örneği kullanılmaktadır [31, 49, 53].

2.4.2. Derin Öğrenme

İnsan hareketi tanımada makine öğrenmesi yaklaşımlarının yanı sıra son zamanlarda oldukça popüler hale gelen derin öğrenme (DL) yöntemlerinden faydalanılmaktadır. DL ağları, makine öğrenimesinde kullanılan yapay sinir ağının çok katmanlı (en az üç), derin ve daha karmaşık varyantları olarak tanımlanabilmektedir. DL uygulamalarında kullanıcıların öznitelikleri manuel olarak çıkarması ve seçmesine gerek kalmaksızın ilgili öznitelikler, giriş verilerinden otomatik olarak çıkarılmaktadır [55, 56]. Derin ağ mimarileri, bir sınıflandırma işlemini gerçekleştirme amacıyla bir veya çok boyutlu girdi verileri tarafından eğitilmek üzere tasarlanmıştır. İki boyutlu (2B) girdi kullanan DL yaklaşımlarında, giriş verileri bir görüntü olarak temsil edilebilmektedir [57]. 2B görüntüleri kullanan DL mimarilerinin, tek boyutlu (1B) girdilere kıyasla görüntülerdeki uzamsal bilgilerin işlenmesindeki avantajla birlikte daha yüksek bir sınıflandırma performansı gösterebilmektedir [58, 59].

Çok Katmanlı Algılayıcılar (MLP), Evrişimsel Sinir Ağları (CNN), Tekrarlayan Sinir Ağı (RNN) ve Uzun Kısa Süreli Bellek (LSTM) yaygın olarak uygulanan derin öğrenme ağlarındadır. Ağırlıklı olarak konuşma tanıma, doğal dil işleme ve video işleme gibi zaman serisi modelleme problemlerine uygulanan RNN ve LSTM ağları bilginin kalıcı olmasını tekrarlayan döngüler ve bellek kapasitesiyle sağlayan sinir ağlarıdır. LSTM ağları, karmaşık çok değişkenli zaman serisi verilerinden uzun süreli korelasyonları öğrenebilme ve parelel giriş dizilerini ayrı ayrı modelleyebilme kabiliyetleri ile ön plana çıkmaktadır [58]. Ayrıca VGG, AlexNet, Inception gibi modelleri bulunan transfer öğrenme yöntemleri de çok sayıda veri setleri içeren insan aktivitesi tanımada son yıllarda yaygınlaşmaktadır [55]. Transfer öğrenme, bir DL modelini rastgele ağırlıklarla başlatmak yerine önceden eğitilmiş bir DL modelini başlangıç noktası olarak kullanmaktadır. Az sayıda veri bulunduran yeni bir veri kümesi girildiğinde bu ağırlıklar uyarlanarak modelin eğitimi hızlanmaktadır.

Evrişimsel Sinir Ağı (CNN), Şekil 2.5'te gösterildiği gibi birden fazla katmandan oluşmaktadır. Piksel değerlerinden oluşan giriş (input) katmanındaki görüntülerin, evrişim (convolution) katmanındaki bir dizi ağırlıktan oluşan filtre matrisleri ile işlenmesiyle bir özellik haritası oluşturulmaktadır. Toplu normalizasyon (batch normalization) katmanı, daha yapılandırılmış bir nöron modeli oluşturur ve eğitim sırasında performansı artırır; ReLU katmanı ise derin sinir ağının aktivasyon fonksiyonunu belirlemektedir. Maksimum havuzlama (max pooling) katmanı, derin CNN mimarisindeki ağırlıkları azaltmakta ve bunların uygulanabilirliğini analiz etmektedir. Eğitim sırasında aşırı öğrenmeyi önlemek için aşırı nöronları ortadan kaldırmak amacıyla bir bırakma (dropout) katmanı uygulanmaktadır. Ayrıca geleneksel bir sinir ağındaki girişlere benzeyen bir giriş matrisi oluşturmak amacıyla tamamen bağlı (fully connected) bir katman uygulanmaktadır. Son olarak ise bir sınıflandırma (classification) katmanı olan çıktı katmanı ve kategorik sınıflandırma için aktivasyon fonksiyonuna sahip olan softmax katmanı yaygın olarak kullanılan son iki katmandır.



Şekil 2.5: Derin CNN mimarisi katmanları.

2.4.3. Sınıflandırma Performans Ölçütleri

İnsan etkinliği tanımada, makine öğrenmesi ve derin öğrenme algoritmalarının performans değerlendirmesi önemli bir yere sahiptir. Derin öğrenme sınıflandırıcılarının eğitim ve test setlerinin performansını belirlemek için karışıklık matrisi (CM) ve bu karşıklık matrisinden hesaplanan doğruluk, kesinlik vb. gibi performans ölçütleri kullanılmaktadır [2, 57, 60]. Gerçek Negatif (TN), doğru şekilde negatif (N) olarak sınıflandırılan bir örneği ifade ederken, Gerçek

Pozitif (TP), doğru şekilde pozitif (P) olarak sınıflandırılan bir örneği ifade etmektedir. Yanlış negatif (FN) numuneler, doğru şekilde pozitif olarak sınıflandırılan ancak aslında negatif sınıfta olan yanlış pozitif (FP) örneklerin aksine, doğru şekilde pozitif olarak sınıflandırılan ancak aslında negatif sınıfta olan örneklerdir. İkili sınıf karışıklık matrisi Tablo 2.1(a)'da sunulmaktadır ve aşağıdaki nicel performans ölçümleri türetilebilir [61]:

- Doğruluk: Test setindeki tüm numuneler arasında doğru şekilde sınıflandırılan numunelerin yüzdesi.
- Kesinlik (pozitif sınıf için): Modelin o gruba dahil olan pozitif sınıfta olacağını tahmin ettiği örnek sayısı.
- Özgüllük: Negatif sınıfın tüm örnekleri içerecek şekilde doğru bir şekilde tahmin edildiği veri kümesindeki örnek sayısı.
- Duyarlılık (pozitif sınıf için): Gerçekte pozitif sınıfa ait olan örnek sayısının bir ölçüsü doğru bir şekilde tahmin edilmiştir.
- F1-skoru (pozitif sınıf için): Pozitif sınıf için duyarlılık ve kesinlik puanlarının harmonik ortalaması.
- G-skoru (pozitif sınıf için): Pozitif sınıf için duyarlılık ve kesinlik puanlarının geometrik ortalaması.

Çoklu sınıflandırma performans metrikleri hesaplanırken ise Tablo 2.1(b)'de belirtildiği gibi bir dönüşüm uygulanmaktadır. Sınıf bazlı değerlendirme için TP, TN, FP ve FN değerleri hesaplanmakta ve Tablo 2.1(a)'da listelenen performans ölçütleri kullanılarak çoklu sınıflandırmalar uygulanmaktadır [62].

Tablo 2.1: Karışıklık matrisi ve sınıflandırma ölçütleri.

	Gerçek bilinen	
Tahmin	P	N
P	**TP**	**FP**
N	**FN**	**TN**

Doğruluk	$\frac{TP+TN}{TP+FP+TN+FN}$
Kesinlik	$\frac{TP}{TP+FP}$
Özgüllük	$\frac{TN}{TN+FP}$
Duyarlılık	$\frac{TP}{TP+FN}$
F1-skoru	$\frac{2\,.\,Kesinlik.Duyarlılık}{Kesinlik\,+\,Duyarlılık}$
G-skoru	$\sqrt{Kesinlik\,.\,Duyarlılık}$

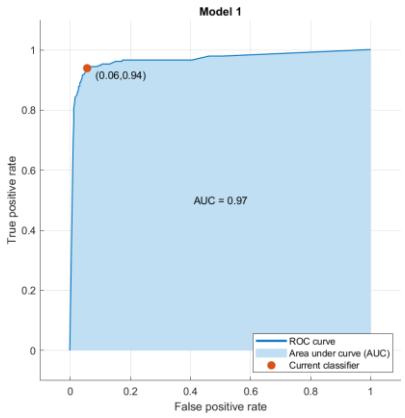
(a)

	Gerçek bilinen		
Tahmin	A	B	C
A	**a**	**b**	**c**
B	**d**	**e**	**f**
C	**g**	**h**	**j**

Class	TP	TN	FP	FN
A	a	e+f +h+j	b+c	d+g
B	e	a+c+g+j	d+f	b+h
C	j	a+b+d+e	g+h	c+f

(b)

Makine öğrenmesi sınıflandırıcılarının performansını değerlendirilmesinde doğruluk ölçütünün yanı sıra önerilen başka bir kriter ise AUC-ROC eğrisi'dir [2, 48, 52]. Doğruluktan daha yüksek yakınsama sunmakta ve tüm olası özgüllükler genelinde ortalama duyarlılığı temsil etmektedir. Şekil 2.5'te gösterilen AUC, TP oranı ile FP oranı arasındaki değişimi görselleştiren bir grafik olan Alıcı Çalışma Karakteristiklerine dayalı yamuk yöntemiyle entegrasyon yoluyla belirlenmektedir.



Şekil 2.6: AUC-ROC eğrisi.

2.5. LİTERATÜR ÖZETİ

Günümüzde insan etkinliği tanıma sistemleri ve giyilebilir sensörler, tıbbi izleme, rehabilitasyona yardımcı eğitim ve ekipman, akıllı giyilebilir protezler, dış iskelet robot geliştirilmesi gibi birçok alana uygulanmaktadır. Son yıllarda makine öğrenmesi ve derin öğrenme alanlarındaki gelişmelerle birlikte, insan alt ekstremite hareket örüntü tanıma

çalışmasında büyük ilerlemeler kaydedilmiştir. Bu tez çalışmasında, makine öğrenmesi uygulamalarında, kayan pencereler yöntemiyle zaman domeni ve frekans alanı öznitelikleri kullanılırken derin öğrenme uygulamalarında ise zaman-frekans alanı analiziyle STFT ve CWT yöntemlerinden elde edilen renkli güç spektral haritalarından yararlanılmıştır. Bu bölümde, güncel literatürde yer alan bazı çalışmalar değerlendirilmiştir.

2020 Dünya Sağlık Örgütü (WHO) yönergeleri, artan fiziksel aktivitenin sağlık hizmetlerini iyileştirmenin en uygun yol olduğu fikrini yeniden doğrulamış ve aktif olmayan yaşamı en az düzeye indirmek için yeni öneriler sunmuştur [63]. Buna göre rapordaki bulgular, yürüyüş, denge, güç ve dayanıklılığı birleştiren çok bileşenli fiziksel egzersizin, özellikle yetişkinlerde veya yaşlı kişilerde düşmeye bağlı yaralanma olasılığını azaltabileceğini göstermektedir. Yaşlılarda yürüme anormallikleri genellikle düşme ve yaralanmalarda, hareketlilikte azalmada, günlük aktivitelerde kısıtlılık, sakatlık ve ölümde artışla ortaya çıkmaktadır [64, 65]. Azalan adım uzunluğu, kadans, hız ve ortalama ivmelenme, anormal bir yürüyüşün belirtileri olabilmektedir. Bireylerin kendilerine has olan karakteristik yürüme hızı (WS) olarak da bilinen yürüyüş hızı, insanın işlevsel yeteneği ve iyi olma hali hakkında bilgi sağlamada kullanılabilen, kolayca ölçülebilen ve güvenilir bir gözlem tekniğidir [66]. Klinisyenler yakın gelecekte nabız, solunum, kan basıncı, ağrı ve vücut sıcaklığı gibi düzenli olarak gözlemlenebilen fizyolojik parametrelere benzer bir şekilde, WS'in analiz edilerek insanlar için yararlı, bilgilendirici ve işlevsel bir altıncı ‘yaşamsal belirti’ olarak kullanılabilmesini öngörmektedir [67].

Erişkin ve geriatrik yürüme bozuklukları son yıllarda dünya çapında önemli bir problem olarak ortaya çıkmıştır. 2015 ile 2050 arasında, WHO ve Birleşmiş Milletler, 60 yaş üstü küresel nüfus oranının yaklaşık olarak %12'den %22'ye çıkacağını tahmin etmektedir [68]. Son yıllarda, giyilebilir biyomekanik sensörlerden gelen verileri aracılığıyla günlük insan aktivitelerini tanıyan yeni yöntemler ve teknolojiler geliştirme kavramı, artan yaşlı nüfus nedeniyle popülerlik kazanmıştır [69]. Bu yaklaşım, spor bilimi, fizik tedavi, rehabilitasyon ve yardımcı robotik cihaz tasarımı dahil olmak üzere çeşitli alanlarda bu tür yöntemlerin potansiyel uygulamalarından dolayı ortaya çıkmıştır [70-72]. İnsan yürüyüşünü tanıma amacıyla iki ana biyomekanik kaynaktan yürüyüş hızı verileri toplanmaktadır. Bazı araştırmacılar, giyilebilir atalet ölçüm birimi (IMU) sensörlerinden [52, 73] yararlanırken, diğerleri ise görüş tabanlı sistemlerden (kameralar, videolar ve görüntüler) [74, 75] faydalanmaktadır. Ahmadian ve ark., sporcu sağlığını değerlendirme ölçütü olan sıçrama testinde (hop test) kameralı hareket algılama sistemiyle üç boyutlu eklem açısı ölçmüş, 3 IMU sensörden oluşan giyilebilir sistemle

karşılaştırılarak sensör sisteminin yaralanma sonrası sporcu sağlığı izlemede yeterli güvenilirlikte olduğu istatistiksel olarak anlamlı bulmuştur [76].

Genel olarak yürüyüş verileri, kuvvet plakaları ve İnsan Aktivitesi Tanıma sistemleriyle elde edilmektedir. Görüntü tabanlı (kameralar, filmler vb.) ve sensör tabanlı sistemler HAR sistemler (giyilebilir, nesne etiketli ve cihazsız) bu verilerin temel iki ana kategorisidir [65, 77, 78]. Akıllı telefonlar ve akıllı saatler gibi IMU tabanlı cihazlar, insan hareketini analiz etmede kolayca entegre edilip vücuda takılabilmesine rağmen, görüş tabanlı sistemler, çok büyük miktarda bilgi depolama gereksinimi ve kamera yapılandırmasındaki zorluklar gibi önemli sınırlamalara sahiptir [71, 73]. Hassan ve ark., akıllı telefonlardaki ivmeölçer sensörler yardımıyla insan aktivite tanımada klasik makine öğrenmesi yöntemleri ve DBN derin öğrenme yöntemiyle karşılaştırmıştır. Önerilen DBN yönteminin, ortalama %89.61 tanıma oranı ve %95.85 doğrulukla, SVM makine öğrenmesi yöntemine göre belirgin üstünlük sağladığına ulaşmıştır [79]. Sabatini ve ark., uzay-zamansal yürüyüş parametrelerinin tahminine yönelik ayağa yerleştirilen IMU sensörle algılamasının sonraki yürüyüş döngülerinin güvenilir bir şekilde tanımlanması, yürüyüş hızı ve eğiminin doğru değerlendirilmesi için umut verici bir araç olduğu sonucuna varmıştır [80].

Küçük boyutları, düşük enerji tüketimi ve hafiflikleri nedeniyle, 3D ivmeölçerler ve jiroskoplar içeren IMU sensörleri, HAR uygulamalarında biyomekanik veri toplama araçları olarak popülaritesini artırmaktadır [1, 73, 81]. Günlük olarak farklılık gösteren yürüyüş şekilleri ve çevresel faktörler yürüme hızını etkilemektedir. Hem açısal hem de doğrusal hareketleri izleyerek daha kapsamlı bir hareket görünümü sağlayabilen atalet ölçüm birimi IMU'lar, uzun vadeli yürüyüş analizi çalışmalarındaki uygulamaları yaygınlaşmaktadır. Düşük güç tüketimli tek bir ivmeölçer eş zamanlı bağlamsal bilgileri azaltabilse de uyumluluğu artırabilmektedir. Ayrıca, vücuda giyilebilen birden fazla IMU sensörünün bileşke lineer ivmelenmesinde, insan etkinliği tanıma çalışmalarında yararlanılmıştır [50, 61, 82].

Son zamanlarda, spor bilimi, rehabilitasyon, yaşlı bakımı, biyometri ve günlük yaşamdaki insan aktivitelerini otomatik olarak tanımak için harekete yardımcı ekipmanların tasarımı gibi çeşitli uygulamalarda giyilebilir sensör sinyalleri kullanılmıştır [58, 61, 82, 83]. İvmeölçerler, jiroskoplar, manyetometreler, IMU'lar, elektromiyografi (EMG) ve IoT tabanlı giyilebilir cihazlar, karmaşık hareket görevlerini algılamak için insan etkinliği tanıma (HAR) uygulamalarındaki kullanılımı giderek artmaktadır [21, 35, 53]. Günlük olarak farklılık

gösteren yürüyüş şekilleri ve çevresel faktörler yürüme hızını etkilemektedir. Ek olarak, vücuda takılan birden fazla IMU sensörünün sonuçta ortaya çıkan ivmesi, insan etkinliği tanıma çalışmaları açısından oldukça önemlidir [84, 85]. Huynh ve Tran, insan düşme tespiti üzerine yaptıkları çalışmada, IMU doğrusal ivme verilerinin bileşkeleri için TFA yöntemlerinden biri olan güç spektral yoğunluk (PSD) yaklaşımını uygulamayı önermişlerdir. Günlük aktivite verilerini kullanarak, güç spektral yoğunluğu (PSD) tabanlı metodolojinin %98.4'lük yüksek hassasiyetle düşüşü tespit edebildiğini ortaya çıkarmışlardır [84]. Rodriguez-Martin ve ark., belin ön ve sol yan kısmı arasına yerleştirilen üç eksenli tek bir IMU ile Parkinson hastalarında gözlenen oturarak ayağa kalkma ve ayaktayken oturma gibi duruş geçişlerinin tanınması üzerine yaptıkları çalışmada SVM tabanlı makine öğrenmesi algoritmasıyla % 98.75 doğruluk elde etmiştir [86].

Giyilebilir biyomekanik sensörler, uzaysal-zamansal parametreler [1, 73] gibi önemli hareket ölçümlerini tahmin etmenin yanı sıra yürüme hızı dahil olmak üzere çoklu hareket modellerini sınıflandırmak veya sağlıklı ve patolojik yürüyüş arasındaki yürüyüş değişkenliğini karşılaştırmaya yönelik kullanılabilmektedir [87]. Bu sensörlerin ortak bir kombinasyonu hem açısal hem de doğrusal hareketleri izleyerek daha kapsamlı bir hareket görünümü sağlayabilen atalet ölçüm birimidir [52, 61, 88]. Alt ekstremite aktivitesi sırasında hareketin ve kas aktivasyonunun etkinliği, kişinin duruşunu nasıl koruduğuna bağlıdır. Kinematik veriler ayrıca, eklem açılarını ve mesafeyi ölçen hareket yakalama kameraları ve dijital gonyometreler aracılığıyla toplanmaktadır [89, 90]. Chen ve ark., farklı hareket modlarında güçlendirilmiş femur protezlerini kontrol etmek amacıyla geliştirdikleri yürüyüş fazını kestirim modelinde uyluk eklem açısının hareket modlarına uyumlu değiştiğini gonyometre verileriyle göstermiştir [70]. Lipperts ve ark., ortopedi alanında hastaların tanı, tedavi ve iyileşme sürecindeki etkinliklerinin takibi veya değerlendirilmesinde üç boyutlu ivmeölçerlerin kliniklerde kullanımının geçerliliği değerlendirmiştir. Dinlenme/oturma, yürüme, merdiven inme/çıkma gibi günlük yaşam aktivitelerinin sinyal işleme yöntemleri ve istatistiksel analiz değerlendirilmesi sonucunda düşük hata oranıyla hasta ve sağlıklı bireyleri ayırt edebildiği gözlenmiştir [91].

Çoklu hareket örüntüleri ve yürüme fazları açısından, bir biyomekanik çalışma [92], insan kaslarının ve eklemlerinin nasıl çalıştığına dair önemli biyomekanik farklılıklar göstermiştir. Bu bağlamda, giyilebilir bir sistemin insan vücudunu algılaması, verilen görevi [93] yerine getirmek için en temel yeteneğidir. Bu özellik, insan hareket tanıma sistemlerini kapsamlı ve

entegre sistemler haline getirmektedir. Uygulanan sinyal işleme yöntemleri ve sensör kombinasyonları, insan hareketini net bir şekilde tanımak için uyumlu olmalıdır. Nagaraj ve ark., sporcuların egzersiz sırasında alt ekstremite eklem açısının tahmini için EMG sinyalini ve hareket kameralarından açısal ivmeyi ANN modeline girdi olarak uygulamış ve dijital gonyometre ile ölçülen deneysel sonuçlarla karşılaştırmıştır [90]. Lencioni ve ark., kuvvet plakası, hareket yakalama kamerası ve EMG verilerinden hesaplanan biyomekanik parametrelerle farklı hızlarda düz yürüme ve merdiven çıkma sırasındaki insan hareketini istatistiksel olarak analiz etmiş ve sonuçları karşılaştırmıştır [92]. Hedel ve ark., değişen vücut ağırlığı ve yürüyüş hızlarına bağlı olarak EMG aktivitesi ile eklem kinematiğindeki farklılıkları belirlemek amacıyla koşu bandında 0.14 m/s-1.69 m/s farklı hızlarda ölçümler almıştır [20]. Çalışmanın sonuçları, EMG aktivitesi ve eklem açısı yörüngelerine ilişkin standartların 0.69 m/s'den daha yüksek yürüyüş hızında ve vücut ağırlığının %50'sinden az yük boşaltma durumu koşullarında karşılaştırılmasını göstermektedir. Kang ve ark., robotik dış iskelet kontrolcü tasarımında biyomekanik sensör verileri ve yapay sinir ağları modeliyle 0.08 m/s-1.3 m/s RMSE hatasına ulaşmış, EMG'nin yalnızca mekanik sensörlerin kullanıldığı modele kıyasla hata oranını %15 civarında azaltarak performansı artırabildiğini göstermiştir [94].

Alt ekstremite biyomekaniği alanında, bir IMU sensörü kullanarak insan yürüyüşünün tanınmasına yönelik çalışmalar, doğru ve kesin çıktılar sağlamak için uygulamalarda hızla uygulanabildikleri için umut vericidir. Ancak, veri setlerinin yüksek karmaşıklığı ve büyük boyutu nedeniyle geleneksel makine öğrenimi tekniklerini kullanarak IMU'lardan gelen verileri analiz etmek zordur, bu nedenle öznitelik çıkarma ve seçme prosedürleri tercih edilmektedir [95]. Bu tür yöntemlerin geliştirilmesindeki ana zorluklardan biri, farklı alt ekstremite hareketlerini doğru bir şekilde temsil edebilen sensör verilerinden uygun özniteliklerin seçilmesidir. Makine öğrenimi mühendisleri tarafından çıkarılan uygun özniteliklerden kolayca öğrenebilen ve etkinlikleri bunlara göre sınıflandırabilen makine öğrenimi algoritmaları, bu zorluğun üstesinden kolaylıkla gelebilmektedir. Huynh ve Tran, insan düşme tespiti üzerine yaptıkları çalışmada, IMU sensör verilerinin FFT'sini (Hızlı Fourier Dönüşümü) kullanarak frekans alanı özniteliklerini uygulamayı önermiştir [84]. Shawen ve ark., Parkinson hastalığının tespitine yönelik makine öğrenimi sınıflandırma çalışmasında, IMU sensör verilerinin zaman alanı ve frekans alanı ortalaması, standart sapma, çarpıklık, basıklık özniteliklerini uygulamıştır [96]. Robotik diz ve ayak bileği protezi için sürekli zamanlı yürüme hızı belirleme algoritmaları ve sensörlerinin değerlendirildiği bir başka çalışmada Bhakta ve ark., her bir yürüyüş aşamasına

ait minimum, maksimum, ortalama, standart sapma, başlangıç değeri, bitiş değeri, sinyal büyüklüğü olmak üzere sekiz zaman serisi özelliği alan ve sinyal enerjisi tercih etmiştir [97].

Öne çıkan bir zaman serisi analiz yöntemi olan ML öznitelik çıkarmada kullanılan kayan pencere yöntemi insan alt ekstremite aktivitesini tanımada yaygın olarak tercih edilmektedir. Seçilen pencerenin uzunluğu, bu yöntemin insan hareketini ne kadar iyi tanıdığını etkilemektedir. Daha geniş bir pencere uzunluğu kullanıldığında işlem süresi artarken, hareket modelinde daha dar pencere uzunlukları tercih edildiğindeyse aktivite yeterince tanınmadığından tanıma başarısı düşmektedir. Literatürdeki hareket tanıma çalışmalarında kayan pencerenin uzunluğu 0.08 saniye ile 2.5 saniye ve hatta 30 saniye arasında olacak şekilde seçilmiştir [32]. Noor ve ark., IMU sensörlerini [35] kullanarak etkinlik tanıma için zamansal çerçeve uzunluğunu seçmeye yönelik uyarlanabilir bir yöntem önermiştir. Wang ve ark., insan hareket paternlerini tanımaya yönelik farklı pencere uzunluklarını değerlendirmiş ve patern tanımanın 0.5 s ve 2.5 s –3.5 s uzunluklarda kabul edilebilir olduğunu gözlemlemiştir [33]. Fida ve ark., kısa (oturma, ayakta durma ve aktiviteler arası geçişler) ve uzun (yürüme, merdiven inme ve merdiven çıkma) süreli aktiviteler ve arasındaki geçişlerin de dikkate alındığı günlük yaşam aktivitelerinin tanınmasında pencere boyutunun etkisini insan beline üç eksenli ivmeölçerlerden yararlanmıştır. Beş farklı ML sınıflandırıcısı test edilmiştir ve farklı pencere boyutları arasında, 1.5 s pencere boyutu, %90'ın çok üzerinde doğruluk sağlamıştır [30]. Ayrıca, yürüyüş örüntüsü tanıma çalışmalarında Temel Bileşen Analiziyle (PCA) öznitelik matrisinin boyutu azaltılabilmekte ve veri dönüşümü için normalizasyon uygulanarak veri setindeki uç değerlerin sınıflandırma performansını olumsuz etkilemesinin önlemektedir [6, 98].

İnsan aktivite tanımada gerekli olan çeşitli insan aktivitelerinin zamanla değişen frekans özellikleri, zaman-frekans alanı spektrogramı ve skalogramla da iyi bir şekilde temsil edilebilmektedir. Uygulama kolaylığı nedeniyle, STFT, EMG ve giyilebilir sensörlerden gelen verilere göre spektrogram hesaplanması üzerine literatür incelendğinde [55, 99, 100] bunun yaygın olarak kullanıldığı görülmektedir. Ek olarak, Dalgacık Dönüşümü [101, 102], insanın fiziksel aktivitelerinden bir güç spektral yoğunluk haritası oluşturmak için etkili bir yöntemdir. Too ve ark., el hareketi tanımada Dalgacık Dönüşümü uygulayarak EMG sinyallerinin özniteliklerini çıkarmış ve ardından bunları SVM ve KNN [101] gibi makine öğrenimi algoritmalarıyla sınıflandırmıştır. İlgili başka bir çalışmada Özdemir ve ark., EMG verilerine zaman-frekans analizi (TFA) uygulayarak elde ettikleri spektral görüntüleri sınıflandırmaya yönelik CNN ve transfer öğrenme yaklaşımlarını kullanmıştır [18].

Derin öğrenme ve makine öğrenimi algoritmaları gibi veri hesaplama teknikleri, özellikle daha yüksek işlem yapan makinelere erişim arttıkça, insan hareketindeki verilerden karmaşık kalıpları yönetmek için IMU tarafından üretilen yürüyüş verilerine uygulandığında umut vaat ettiğini göstermiştir [18, 61, 103]. CNN derin öğrenme algoritmaları, insan yürüyüşünün tanınmasında sıklıkla kullanılmaktadır. IMU sensörlerinin ham sinyalleri ve zaman-frekans spektrum görüntüleri CNN girdileri olarak yaygın olarak kullanılmaktadır [56, 57, 60, 104]. Jung ve arkadaşlarının metodolojisi, derin evrişimsel sinir ağlarıyla IMU verilerinden yararlanarak güvenilir çoklu ve ayırt edilebilir fark olmayan patolojik yürüyüş fazlarını sınıflandırma için spektrografik yaklaşım sağlayan çalışmaya dayanmaktadır [57]. Başka bir çalışmada, Jung ve ark., ham ivme ve açısal hız verilerinin zaman-frekans alanı analizinden elde edilen yürüyüş spektrogramları ile eğitilmiş 2D-CNN tabanlı giyilebilir IMU sensörleri kullanan üç farklı grubun yürüyüş tanıması için etkili bir yaklaşım önermiştir. Bu sınıflandırıcı sporcu, normal ayak ve deforme ayak gruplarının sınıflandırılmasında %93.02 doğruluk göstermiştir [60]. Martinez-Hernandez ve ark., alt ekstremiteye yerleştirilen üç giyilebilir IMU sensör ve CNN kullanarak yürüme aktivitesinin tanınması ve yürüme süresinin tahminine yönelik yeni bir öğrenme mimarisi sunmuştur. Bu çalışmanın doğrulaması, düz zeminde yürüme, rampa çıkış ve rampa inişinin tanınması ve yürüyüş sürelerinin tahmini ile gerçekleştirilmiştir. CNN modeli tek başına kullanıldığında, yürüme aktivitesi ve yürüyüş periyodunun tanınması sırasıyla %100 ve %98.63'tür. Önerdikleri metadoloji ve uyarlanabilir kombinasyonla birlikte uygulandığında yürüyüş süresinin tanınmasında %99.9 doğruluk sağlamaktadır [59].

Son yıllardaki giyilebilir biyomekanik sensör verileriyle insan aktivitesi sınıflandırma çalışmaları derin öğrenme algoritmalarının yanı sıra, çıkarılan özniteliklerle birlikte makine öğrenmesi algoritmaları da kullanılmaktadır. Makine öğrenmesine dayalı insan etkinliği tanımada genellikle, rehabilitasyon ve yardımcı robotik [70, 95], yürüme anormallikleri [44, 64, 93] ve yaşlı bakımı [18, 65] alanlarında SVM, KNN, LDA, ANN ve RF başta olmak üzere çeşitli sınıflandırıcılardan yararlanılmaktadır [34, 48, 97]. Bir çalışma, IMU ve EMG sensörlerinden toplanan bilgilere dayalı olarak SVM algoritması kullanarak günlük yaşam aktivitelerini %94.29'luk doğrulukla sınıflandırmıştır [105]. Başka bir çalışma ise, IMU, GON ve EMG gibi birkaç giyilebilir sensör tipinin ve konumunun sınıflandırma performansına etkisini değerlendirmiştir. Camargo ve ark., gonyometrelerin merdiven/rampa hız tahmini için büyük oranda doğruluk sağladığını ve düz zeminde hız tahmini içinse tek bir IMU sensörün

bile, tüm ek sensör türleri ve konumlarına olan ihtiyacı önemli ölçüde azalttığına ulaşmışlardır [95]. Ayrıca Dong ve ark., çoklu kaynağa dayalı insan hareket yürüyüş fazlarının ve modellerinin tanınması amacıyla çok kanallı EMG ve IMU sensör verileriyle makine öğrenimi algoritmalarını kullanarak yürüyüş fazlarını yüksek doğrulukla sınıflandırmıştır [106]. Ni ve ark., akıllı ev üzerine bir çalışmada yaşlıların evde gerçekleştirilebilecekleri tüm farklı etkinlik türleri, yani statik, dinamik ve geçiş etkinliklerini kişinin bileğine yerleştirilen giyilebilir bir ivmeölçerle topladıkları bir veri seti üzerinden tanımayı önermiş SVM, DT ve KNN sınıflandırıcıları ve önerdikleri 10 kat çapraz doğrulama yaklaşımıyla yaklaşık %96.87 bir genel sınıflandırma doğruluğu elde etmiştir [31].

Uzun yıllardan günümüze kadar zaman-frekans analizi (TFA) yöntemlerinden olan STFT ve CWT, durağan olmayan biyolojik sinyallerin zamanla değişen spektral karakteristiklerini çıkarmada kullanılmaktadır. Son yıllarda derin öğrenme mimarileri ve bilişim teknolojilerindeki gelişmeler, TFA görüntülerinin biyomedikal alanındaki çalışmalarda uygulanmasını beraberinde getirmiştir. TFA görüntüleri yardımıyla sınıflandırma yapan, insanların hareket ve fizyolojik sağlık durumlarını ilişkilendiren ve sınıflandırma başarım ölçütlerinin iyileştirilmesini hedefleyen literatür çalışmalarının bazıları şunlardır:

Kalp ritmindeki düzensizliklerden kaynaklanan kardiyak hastalıkların (aritmi) derin öğrenme modelleriyle sınıflandırılması üzerine elektrokardiyografi (EKG) sinyalleri kullanılan çalışmalar mevcuttur. Bu çalışmalardan Mohanta ve ark., beş farklı kalp aritmisinin kısa segmentasyon süresiyle 2D CNN sınıflandırıcı ve CWT yönteminden elde edilen skalogram görüntüleri üzerinden % 98.87 doğrulukla tespit ederken [107], Rahhal ve ark., dört farklı kalp aritmisinin uzmanlar tarafından etiketlenmiş verisetlerindeki sinyallerin skalogram görüntülerinden ventriküler aritmileri yüksek doğrulukta tahmin etmekte [108], Nahak ve ark., aritmi ve kalp yetmezliğini otomatik transfer öğrenme ve TFA yöntemleriyle sınıflandırmanın manuel olarak çıkarılan zaman domeni öznitelikleri ve makine öğrenmesiyle sınıflandırmaya göre daha başarılı olduğunu ve geliştirdikleri bu yöntemin % 99.06 doğrulukla performans sergilediğini göstermektedir [109]. Huang ve ark., beş farklı kalp aritmisini sınıflandırmada STFT ve 2D-CNN kullanılan yöntemin % 99.00 ortalama doğruluk sağladığı [62], Çınar ve Tuncer, hibrit Alexnet-SVM derin öğrenme mimarisiyle normal sinüs ritim, aritmi ve kalp yetmezliğini sınıflandırmada sinyallerin spektogram görüntülerinin kullandıldığı modelde en yüksek doğruluk olan % 96.77'ye ulaşmıştır [110]. Liu ve ark., spektogram görüntülerini beş farklı aritmiyi sınıflandırmada 2D-CNN ve tranfer öğrenme yöntemleriyle farklı sinyal

uzunluklarının etkisini gözlemleniş, on kalp atış uzunluğundaki ECG ve EfficientNet transfer öğrenme mimarisinin kullanıldığı modelin ortalama doğruluğunun % 97.0 ± 0.4 olduğu sonucuna varmışlardır [111]. Kardiyak anomalinin tahmininde Azam ve ark., harici gürültülü barındıran kalp sesi sinyaline spektogram ve ResNet CNN yöntemlerini uygulayarak % 84.09 F1-skoru ile diğer yöntemlere kıyasla üstün performans sağlarlarken [112], Yıldırım ve ark., otomatik diyabet hastalığı tespitinde kalp atım sinyallerinin spektogram görüntülerini ve transfer öğrenme DenseNet mimarisi kullanarak % 97.62 ortalama doğrulukla diyabet hastalarını sınıflandırmıştır [113]. İnme sonrası rehabilitasyon sürecinin değerlendirilmesinde, giyilebilir sensörlerden elde edilen zaman serisi sinyallerinin sınıflandırılmasında CNN net sonuçlar vermektedir. Boukhennoufa ve ark., Gramian açısal alan (GAF) algoritmasıyla inme sonrası aktivite tanımada bir zaman penceresine ait tüm sensör kanallarının iki boyutlu görüntülerini kullanan bir model geliştirmiştir. 1D CNN sınıflandırıcı ve geleneksel segmentasyon yaklaşımıyla %94 test başarısı sağlarken, GAF ile birlikte 2D CNN sınıflandırıcısı %97.06 ve VGG-16 transfer öğrenme sınıflandırıcı %98.53 test başarına ulaşmıştır [114].

Shi ve ark., Parkinson hastalarının alt ekstremite IMU yürüyüş sinyallerine CWT uygulayarak derin CNN yaklaşımıyla hastaların yürüyüşündeki donuklukların tespiti üzerine yaptıkları çalışmalarında önerdikleri kişi-bağımsız CNN modelinde %90.7 G-skoru ve %91.5 F1-skoru ile başarılı bir sınıflandırma sonucu elde etmiştir [115]. Chakraborty ve Nandy, giyilebilir ivmeölçer sensörle serebral palsi ve normal çocuk yürüyüş örüntülerinin algılanmasında çoklu kanal 1D-CNN modeli ve Ayrık Dalgacık Dönüşümü (DWT) kullanarak önerdikleri segment tabanlı modelde %96.4 doğruluğa ulaşmıştır [116]. Giyilebilir IMU sensörlerle yürüyüş tanıma üzerine bir başka çalışmada ise Yan ve ark., farklı açık alan yürüme koşullarında alınan yürüyüş sinyalleri ve DWT uygulanarak elde edilen alt bantlarından öznitelik çıkarmış ve bu öznitelikleri gri skala görüntü matrisine dönüştürerek önerdikleri AlexNet tabanlı CNN modeliyle %88.4 doğrulukla sınıflandırmıştır [117]. Vidya ve Sasikumar makine öğrenmesi yaklaşımıyla insan aktivite sınıflandırma üzerine yaptıkları bir çalışmada, IMU sensör sinyallerini EMD ve DWT ile alt bileşenlerine ayrıştırarak öznitelikleri çıkarmışlar ve DT algoritmasını kullandıkları modelde %99.63 ile en yüksek sınıflandırma doğruluğunu bulmuştur [118]. Middya ve ark., akıllı telefon ivmeölçer sensörü verilerine dayalı olarak biyometrik kişi tanımlama için CNN tabanlı bir yöntem önermişlerdir. Bu yaklaşım, ivmeölçer sinyalinin STFT'sini kişisel tanımlama amacıyla CNN modelini eğitmek için 2 boyutlu zaman-

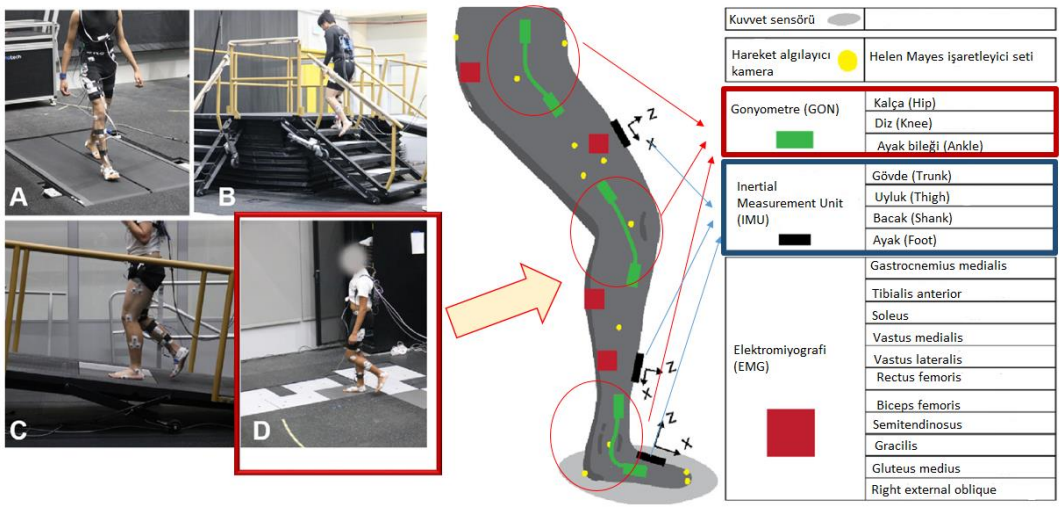
frekans görüntü temsiline dönüştürmektedir. Geleneksel makine öğrenmesi ve transfer öğrenme modelleriyle de deneylerin gerçekleştirildiği bu çalışmada önerilen 2D-CNN modeli %98 doğruluk ve %96 F1-skoru ile en yüksek sınıflandırma performansını göstermiştir [119]. Biyometrik tanımlama üzerine benzer yaklaşımı kullanan Jung ve ark., üç eksenli ivmelenme ve açısal hız sinyallerini, yürüme esnasında ayak, bacak, uyluk ve posterior pelvise takılan IMU sensörleriyle ölçmüştür. Ardından bir adımda ölçülen alt vücut hareketi sinyallerine STFT uygulayarak yürüyüş spektrogramları elde etmişlerdir. Çalışmanın bulguları ayak, gövde, uyluk ve pelvik spektrogramlar kullanılarak %99.69'luk bir doğruluğa ve yalnızca ayak spektrogramları kullanılarak %96.89 doğruluğa ulaşıldığını göstermiştir [120].

3. YÖNTEM

Bu bölümde çalışmada kullanılan giyilebilir sensör veri seti, uygulanan sinyal işleme yöntemleri ile hareket sınıflandırmaya yönelik uygulanan makine öğrenmesi ve derin öğrenme yöntemleri değerlendirilmiştir.

3.1. ALT EKSTREMİTE GİYİLEBİLİR BİYOMEKANİK VERİSETİ

Bu çalışmada, zemin seviyesinde/koşu bandında yürüme, merdevin inme/çıkma ve rampa inme/çıkma gibi çoklu hareket modu ve arazi koşulları için 22 sağlıklı yetişkinden alınan üç boyutlu giyilebilir sensör verilerini içeren açık erişimli Camargo ve ark., biyomekanik veri setindeki zemin seviyesinde farklı hızlardaki yürüme verileri kullanılmıştır [121]. Şekil 3.1'de sensör yerleşimlerini gösterilen veri seti, hareket tanıma, robotik yardımcı ekipman ve arazi koşullarına daha iyi uyum sağlayan biyomimetrik kontrolcülerin geliştirilmesi alanındaki yeni çalışmalara yol göstermeye yönelik alt ekstremiye ait kapsamlı hareket bilgisi sunmaktadır.



Şekil 3.1: Alt ekstremite giyilebilir biyomekanik veri seti sensör yerleşimleri.

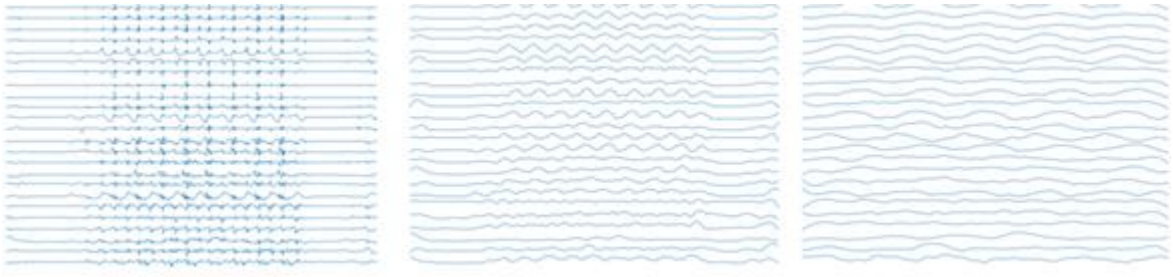
Veri setinin çalışma grubunu 3'ü kadın ve 19'u erkek 22 sağlıklı yetişkin (yaş 21 ± 3.4 yıl, boy 1.70 ± 0.07 m, kütle 68.3 ± 10.83 kg) oluşturmaktadır. Her katılımcının kendi tercih ettiği hıza göre düz zeminde hızlı (F), normal (N) ve yavaş (S) üç yürüyüş hızının her birinde toplam otuz tekrarlı yürüyüş gerçekleştirilmiştir. Her katılımcının gerçek yürüyüş hızını tahmin etmek amacıyla katılımcının ortalama kararlı durum yürüyüş hareketinde pelvis lineer hızı

kullanılmıştır. Tüm deneylerin ortalama pelvis hızlarına göre hızlı, normal ve yavaş yürüyüş hızları 1.45 ± 0.27 m/s, 1.17 ± 0.21 m/s ve 0.88 ± 0.19 m/s olarak verilmiştir.

Giyilebilir sensör verileri, kuvvet sensörleri, EMG, hareket algılayıcı kamera ve işaretleyicileri, IMU (Yost, Ohio, ABD) ve gonyometre (Biometrics. Ltd. Newport, Birleşik Krallık) sensörleri gibi birçok çoklu sensör verisi veri setini oluşturmaktadır. Tez çalışması kapsamında yürüyüş hareketi sınıflandırmada IMU ve gonyometre sensör verilerinden yararlanılmıştır. Hazır veri setinde IMU verileri, 200 Hz'lik bir örnekleme frekansıyla gövde, uyluk, bacak ve ayak segmentlerinin ön yüzeyinden toplandıktan sonra bir alçak geçiren filtre (kesme frekansı 100 Hz, 6. dereceden Butterworth) ile dijital olarak işlenmiştir. Uyluk, bacak ve ayak için, IMU sensörleri sağ alt ekstremitenin her bir segmentinin ¾'ü kadar aşağıya (distal olarak) yerleştirilirken gövde IMU sensörü, sternum ve göbek arasına merkezi olarak yerleştirilmiştir. GON verileri, 1000 Hz örnekleme frekansıyla sağ taraftaki kalça, diz ve ayak bileği eklemlerinden toplanarak ardından ve bir alçak geçiren filtre (kesme frekansı 20 Hz, 4. dereceden Butterworth) ile dijital olarak filtrelenmiştir. Kalça ve ayak bileği için hem sagittal hem de frontal (frt) açı verileri kaydedilirken, diz için sadece sagital (sgt) açı verileri kaydedilmiştir. Ayrıca, Gastrocnemius, Tibialis anterior, Soleus, Vastus medialis, Vastus lateralis, Rectus femoris, Biceps femoris, Semitendious, Gracilis, Gluteus medius ve Sağ eksternal oblik alt ekstremite kaslarından 1000 Hz örnekleme frekansı ile EMG verileri kaydedilmiştir.

3.2. BİYOMEDİKAL SİNYAL İŞLEME

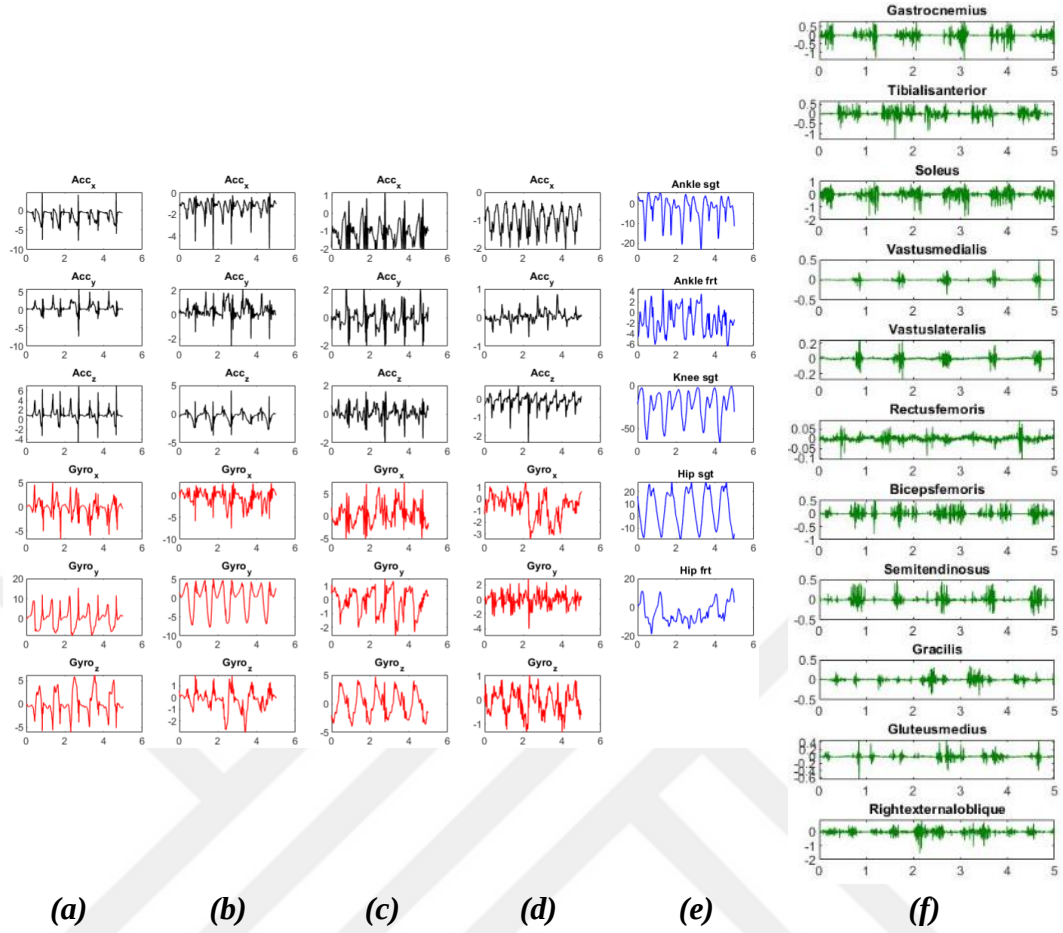
Giyilebilir sensör sinyallerine MATLAB (The MathWorks, 2021b) yazılımıyla filtreleme, veri normalizasyonu, segmentasyon, zaman serisi analizi ve zaman-frekans analizi gibi sinyal işleme adımları uygulanmıştır. Çalışmanın makine öğrenmesi kısmında kayan pencereler yöntemi, derin öğrenme kısmında ise zaman-frekans analizi yöntemleri kullanılmıştır. Kayan pencereler yöntemi öncesi sinyal işleme adımları, IMU sensör zaman serisi sinyalleri üzerinde Şekil 3.2'de gösterilmiştir. Her bir tekrardaki yürüyüş süresinin birbirinden farklı olması ve giyilebilir sensör sinyallerinin başı ile sonunda yer alan herhangi bir bilgi taşımayan kısımlar barındırması gibi nedenlerden dolayı Şekil 3.3'te gösterildiği gibi, farklı katılımcılar ve tekrarlar arasındaki yürüyüş hareketinden toplanan sinyal uzunluklarını standartlaştırma amacıyla ham giyilebilir sensör sinyalleri 5 saniyelik bir süre ile kırpılmıştır. Ardından Savitzky-Golay filtresi uygulanarak gürültü bileşenleri bastırılmıştır.



(a) ***(b)*** ***(c)***

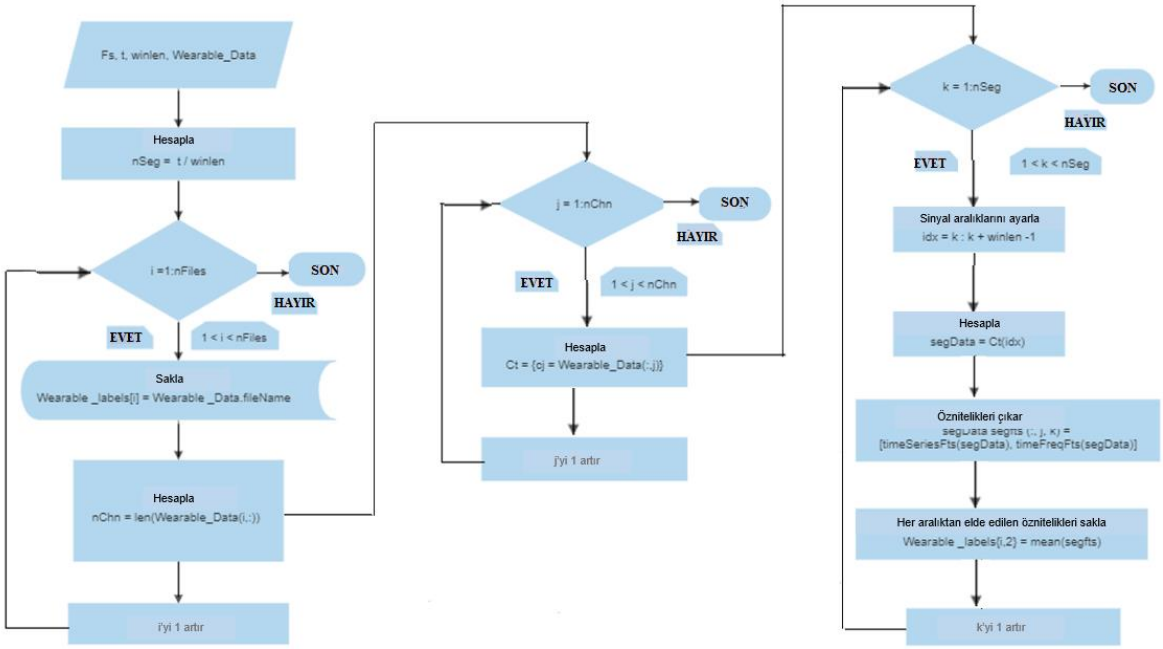
Şekil 3.2: IMU sensör ***(a)*** Ham sinyali, ***(b)*** sinyaline Savitzky-Golay filtresi uygulanması, ***(c)*** sinyalinin 5 s süreyle kırpılması.

Yürüyüş hareketindeki doğrusal ivmelenmeyi ve dönmeyi ölçmek amacıyla IMU sensörünün üç eksenli bir ivmeölçer ve üç eksenli jiroskop kullanılmıştır. Şekil 3.3(a-d)'de üç eksenli ivmeölçer (Acc_x, Acc_y ve Acc_z) ve 3 eksenli jiroskop ($Gyro_x$, $Gyro_y$ ve $Gyro_z$) ile birlikte IMU sensörlerinden toplanan sinyallere, Şekil 3.3(e)'de ise farklı düzlemlerdeki gonyometre açı sinyallerine yer verilmiştir. Şekil 3.3(f)'de alt ekstremite kaslarına ait EMG sinyalleri gösterilmiştir. Sinyal ön işlemede, GON ve EMG sinyallerinin örnekleme frekansı ile IMU'nun örnekleme frekansının dengelenmesi amacıyla aşağı örnekleme yöntemi uygulanmış ve çalışmada kullanılan tüm giyilebilir sinyallerin örnekleme frekansı 200 Hz olarak elde edilmiştir.



Şekil 3.3: Giyilebilir biyomekanik sensör zaman serisi sinyalleri. ***(a)*** Ayak IMU sensörü, ***(b)*** Bacak IMU sensörü, ***(c)*** Uyluk IMU sensörü, ***(d)*** Gövde IMU sensörü, ***(e)*** GON sensör açı sinyalleri, ***(f)*** Alt ekstremite kaslarına ait EMG sensör sinyalleri.

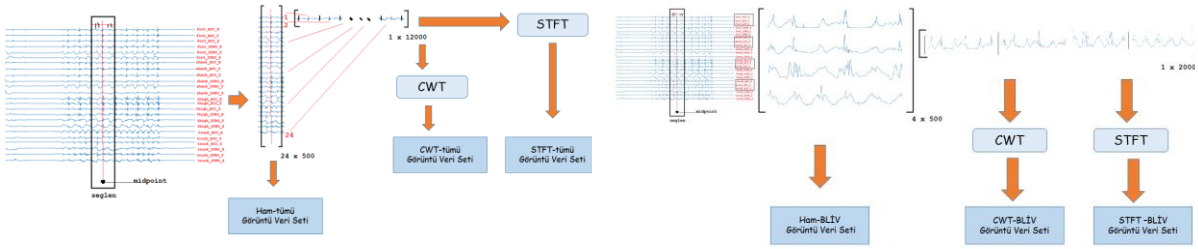
Zaman penceresi boyutunun segmentasyon performansını etkileyen en önemli faktör olduğu kayan pencereler yöntemi, insan etkinliği tanıma bağlamında oldukça popülerdir ve sensör veri segmentasyonu ön işleme adımını gerçekleştirmeyi amaçlamaktadır. Kayan zaman penceresinin uzunluğu, hareket tanıma sonuçlarını etkilemektedir. Zaman penceresi çok büyükse, tanıma sisteminin yanıt verebilirliğini azaltıcı ve hesaplama yükünü artırıcı birden çok etkinliğe dair bilgi içerebilmektedir. Tam tersine, eğer zaman penceresi çok küçükse, bazı faaliyetler birden çok ardışık pencereye bölünebilmekte, tanıma görevi çok sık tekrarlanmakta ancak yüksek tanıma performansı sağlanamamaktadır. Şekil 3.4'te gösterildiği gibi, kayan pencere algoritmasıyla, önce sinyal zaman uzunluğu (t) pencere uzunluğuna (winlen) bölünerek segment sayısı (nSeg) elde edilmiştir. Daha sonra her bir kanal için, her segmentin zaman serileri ve zaman-frekans alanı özellikleri hesaplanmıştır. Bu ardışık görevler Ek-1'deki sözde-kodda gösterildiği gibi bir kanaldaki tüm segmentler için işlenmiş ve ardından segmentlerin ortalaması belirlenmiştir.



Şekil 3.4: Giyilebilir sensör sinyallerinden kayan pencereler yöntemiyle öznitelik çıkarımı.

Makine öğrenmesi yaklaşımıyla IMU, GON ve EMG giyilebilir biyomekanik sinyallerinin yürüyüş örüntüsü tanıma başarısında kayan pencere uzunluğunun ve tekli ve çoklu sensör öznitelikleri seçiminin etkisi değerlendirilmiştir. Ayrıca [0-1] veri normalizyonu ve özniteliklerin azaltılması amacıyla uygulanan PCA'nın etkisi IMU sensör yerleşim yerine göre insan yürüme biyomekaniği açısından incelenmiştir.

Çalışmanın derin öğrenmeyle insan yürüyüşü tanıma üzerine olan ilk aşamasında önce IMU sensör sinyalinin tüm kanalları ile bileşke lineer ivmelenme sinyali kanallarının zaman serisi ve zaman-frekans analizi gerçekleştirilmiştir. Ardından buradan elde edilen görüntü veri setleri önerilen 2D-CNN modeline giriş olarak verilmiş, sınıflandırma performansına etkileri incelenmiştir. Veri setinde IMU sinyallerinin dikdörtgen düz zemindeki bir yürüyüş yolunda kaydedildiği belirtilmiştir. Bu sinyallerin, dönüş noktalarındaki kesintileri ve süreksizlikleri önlemek için her bir sinyalin orta noktası, başlangıç noktası ve bitiş noktasından eşit uzaklıkta olacak şekilde otomatik olarak kırpılarak kaydedilmiştir. Şekil 3.5(a)'da gösterildiği gibi ham IMU verilerinden çıkarılan bu 24x500 sinyaller yeni bir veri setine dönüştürülmüştür. Ardından, her bir kanal sırayla uç uca eklenerek 1x12000 vektörü oluşturulmuş ve frekans-zaman alanında sinyal güç spektrumunu elde etmek için CWT ve STFT dönüşümleri uygulanmıştır.

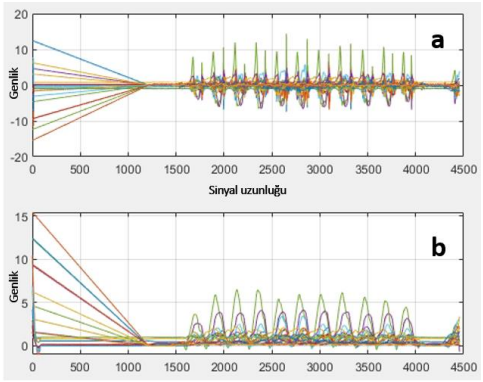


(a) ***(b)***

Şekil 3.5: IMU sensör sinyallerinden CNN giriş görüntü veri seti oluşturma. ***(a)*** Ham IMU sinyalleri, ***(b)*** IMU bileşke lineer ivmelenme sinyalleri.

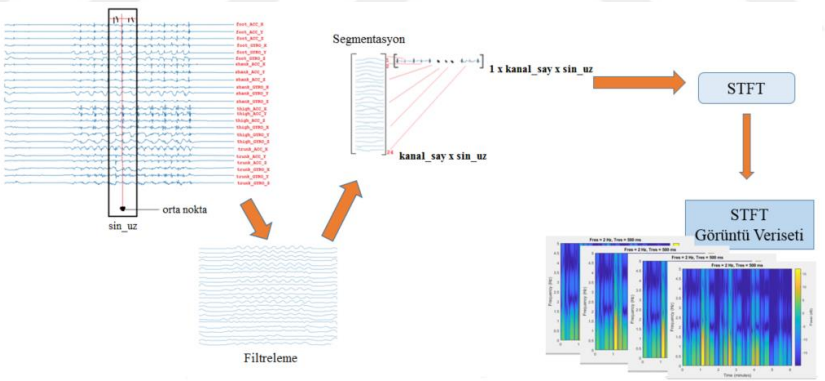
Üç eksenli doğrusal ivmelenme ve açısal hız parametrelerine ek olarak, x, y ve z eksenlerindeki doğrusal ivmelerin kareleri toplamının karekökü alınarak bileşke lineer ivmelenme (Ham-BLİV) de hesaplanmıştır. Şekil 3.5(b)'de gösterildiği gibi, ayak, bacak, uyluk ve gövde IMU bileşke lineer ivmelenmeleri elde edilerek 4×500 matrislerden bir görüntü veri seti oluşturulmuştur. Ayrıca her kanaldaki sinyaller uç uca eklenerek 1×2000 vektörü oluşturulmuştur. Zaman-frekans alanı bileşke lineer ivmelenmelerin güç spektrumlarını oluşturmak amacıyla CWT ve STFT dönüşümleriyle iki yeni veri seti daha üretilmiştir.

Derin öğrenme çalışmasının ikinci aşamasında ise yer seviyesindeki yürüme hareketine ait gonyometre (GON) ve ivmeölçer (IMU) sensör sinyalleri filtrelenerek ve farklı zamansal uzunluklarda segmente edilerek yürüyüş hızlarına (YH) göre yavaş (S), normal (N) ve hızlı (F) olmak üzere CNN derin öğrenme modelleriyle otomatik olarak sınıflandırılmıştır. Segmente edilen IMU ve GON sinyalleri, zaman-frekans domenindeki güç spektrumunu gösteren Kısa Zamanlı Fourier Dönüşümü (STFT) kullanılarak CNN girişine görüntü veri setleri hazırlanmıştır. Ayrı ayrı IMU ve GON sensörleri tek girişli CNN derin öğrenme modeline uygulanmasının yanında her iki sensör parametrelerinin insan yürüyüş tanımadaki başarımını değerlendirmek amacıyla ayrıca iki girişli CNN modeli de geliştirilmiştir. Şekil 3.6'da giyilebilir sensör veri setindeki bir örneğe ait giyilebilir IMU sensör sinyali ve Savitzky-Golay filtresi uygulanmış sinyal gösterilmiştir. Filtrelemeyle gereksiz frekans bileşenleri elimine edilmiş ve sinyal içeriğine ait bilgiler daha baskın hale gelmiştir.



Şekil 3.6: IMU ***(a)*** ham sinyal, ***(b)*** sinyaline Savitzky-Golay filtresi uygulanması.

Şekil 3.7'de görüldüğü gibi ham IMU sinyallerine Savitzky-Golay filtresi uygulanmış ardından sinyalin bilgi barındırmayan kısımlarını çıkarnak amacıyla her bir kanalın orta noktasından başlangıç noktası ve bitiş noktasına eşit uzaklıkta olacak şekilde sinyal, otomatik olarak segmente edilmiştir. Farklı uzunluklarda segmente edilen bu sinyallerden bir veri seti oluşturulmuştur. Ayrıca her bir kanalın peş peşe eklenmesiyle bir vektör oluşturulmuş ve sinyalin frekans-zaman domenindeki güç spektrumunu elde etmek için STFT dönüşümü uygulanarak güç spektrum görüntülerinden oluşan STFT veri seti oluşturulmuştur.



Şekil 3.7: IMU sinyal işleme adımları ve STFT görüntülerinin oluşturulması.

3.3. MAKİNE ÖĞRENMESİ ve DERİN ÖĞRENME YÜRÜYÜŞ TANIMA MODELLERİ

İnsan aktivite tanıma uygulamalarında makine öğrenmesi ve derin öğrenme model eğitiminde yaygın olarak iki tür yaklaşım kullanılmaktadır: k-kat çapraz doğrulama (k-fold CV) ve rastgele eğitim-test ayırma. k-fold CV, bilinmeyen veriler üzerinde modelin performansını tahmin etmekte kullanılan bir yöntemdir. Yöntemin uygulama adımları sırasıyla:

- Mevcut veri kümesini rastgele karıştırmak,

- Veri kümesini yaklaşık olarak eşit büyüklükte k kata ayırmak,
- Her bir benzersiz kat için, veri kümesinden bir parça test kümesi, kalan k-1 parça eğitim kümesi seçilip model eğitilerek sınıflandırıcının başarımını hesaplamak,
- Bu işlem her bir kat için uygulanarak sınıflandırıcı başarımlarının ortalaması alınır.

Diğer bir yöntemde ise modelin aşırı öğrenmesini önlemek ve veri setindeki bilinmeyen veri kümesini (test kümesi) rasgele seçebilmek amacıyla giriş veri seti yaygın olarak %80-%20 ya da %70-%30 eğitim- test olacak şekilde ayrılmaktadır.

Makine öğrenmesi modelinin girişine her bir katılımcıya bir satır karşılık gelecek şekilde çıkarılan özniteliklerin sütunları oluşturduğu ve son sütuna da sınıf etiketlerinin eklendiği bir öznitelik matrisi uygulanmıştır. Aşırı öğrenmeyi yani modelin verileri ezberlemesini önlemek için 10 kat çapraz doğrulama (ÇD) işlemi uygulanmıştır. Hızlı(F), Normal(N) ve Yavaş(S) olarak üç sınıftan oluşan giyilebilir sensör sinyallerinden çıkarılan öznitelikler sırasıyla 225, 221 ve 229 olmak üzere toplamda 675 etiketlik sinyalden oluşan bir veri setidir. Sinyal zaman serisi öznitelikleri olarak ortalama, maksimum (maks), standart sapma (std), minimum (min), ortanca mutlak sapma (mad), çeyrekler arası aralık (iqr) ve sinyal altında kalan alan (AUS) kullanılırken, zaman-frekans alanı öznitelikleri, sinyalin Hızlı Fourier Dönüşümünden (FFT) maksimum, çarpıklık, basıklık ve AUS değerleri hesaplanmıştır. Tekli ve çoklu giyilebilir sensörlerin serbestlik dereceleri ve çıkarılan öznitelik sayısı Tablo 3.1'de verilmiştir.

Tablo 3.1: ML modelleri için giyilebilir sensör sinyallerinin çıkarılan öznitelik matrisi.

Sensör	Sensör sayısı	Sensor serbestlik derecesi	Öznitelik sayısı
Ft-IMU	1	6	6*11 = 66
Sh-IMU	1	6	6*11 = 66
Th-IMU	1	6	6*11 = 66
Tr-IMU	1	6	6*11 = 66
ShTh-IMU	2	12	12*11 = 132
ShThFt-IMU	3	18	18*11 = 198
IMU (All-IMU)	4	24	24*11 = 264
GON	3	5	5*11 = 55
EMG	11	11	11*11 = 121
IMU-GON	9	29	24*11 + 5*11 = 319
IMU-EMG	15	35	24*11 + 11*11 = 385
GON-EMG	9	16	5*11 + 11*11 = 176
IMU-GON-EMG	20	40	24*11 + 5*11 + 11*11 = 440

İlk olarak, çıkarılan öznitelik matrisleri, insan vücuduna yerleştirilen IMU sensörlerinin ayak (Ft-IMU), bacak (Sh-IMU), uyluk (Th-IMU), gövde (Tr-IMU) ve bunların 'ShTh-IMU',

'ShThFt-IMU' ve 'All-IMU' gibi kombinasyonları dahil olmak üzere oluşturulmuştur. MATLAB Classification Learner Toolbox kullanılarak dört farklı durum için ML sınıflandırma performansları incelenmiştir. Sınıflandırma işlemi, HAR problemlerinde sıklıkla kullanılan beş farklı ML algoritması kullanılarak gerçekleştirilmiştir: Grup Altuzay K-en yakın komşular (ESKNN), Karesel Karar Destek Makinesi (QSVM), Çekirdek Karar Destek Makinesi (KSVM), Grup Yığın Ağaçlar (EBT) ve Geniş Sinir Ağları (WNN). Çalışmanın ikinci kısmında ise kayan pencere uzunluklarının insan yürüyüşü tanıma başarısı üzerine etkisi ESKNN, QSVM ve WNN makine öğrenmesi algoritmalarıyla giyilebilir sensör sinyalleri kullanılarak incelenmiştir. Makine öğrenmesi algoritmalarının eğitim parametrelerine Tablo 3.2'de yer verilmiştir.

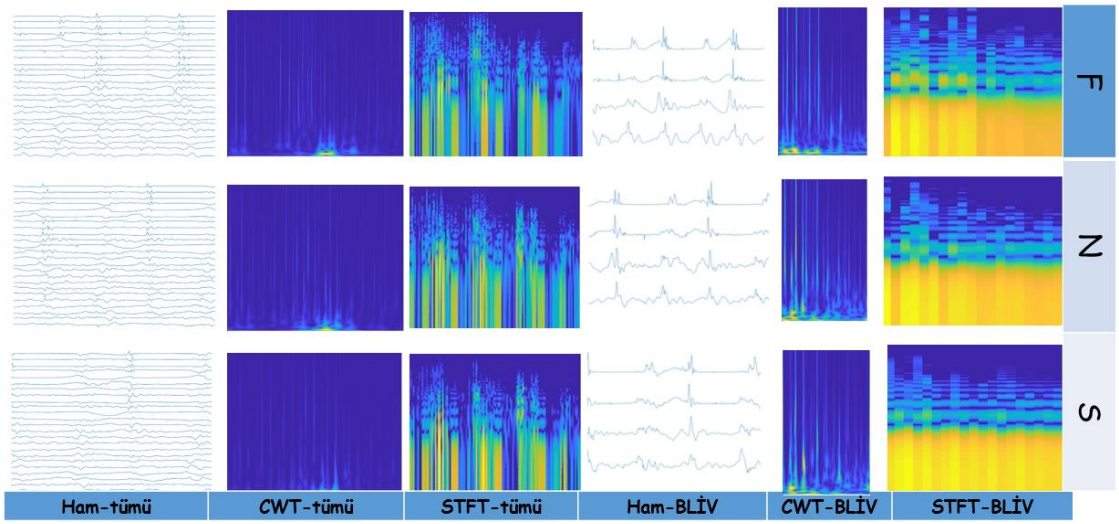
Tablo 3.2: Makine öğrenmesi modeli eğitim hiperparametreleri.

ESKNN	Ensemble method: Subspace Learner type: Nearest neighbors Number of learners: 30 Subspace dimension: 132
QSVM	Kernel function: Quadratic Kernel scale: Automatic Box constraint level: 1 Multiclass method: One-vs-One Standardize data: true
KSVM	Number of expansion dimensions: Auto Regularization strength (Lambda): Auto Kernel scale: Auto Multiclass method: One-vs-One Iteration limit: 1000
EBT	Learner type: Decision tree Maximum number of splits: 674 Number of learners: 30
WNN	Number of fully connected layers: 1 First layer size: 100 Activation: ReLU Iteration limit: 1000

Analiz edilen ML sınıflandırıcılarının eğitim, test ve doğrulama setinde ne kadar iyi performans gösterdiğini belirlemek için doğruluk, alma çalışma eğrisi-eğri altındaki alan (AUC-ROC) ve karışıklık matrisi gibi performans ölçütlerinden yararlanılmıştır. Bir model pozitif ve negatif sınıfları doğru bir şekilde sınıflandırdığında, çıktılar sırasıyla True Positive (TP) ve True Negative (TN) olur. Benzer şekilde, Yanlış Pozitif (FP) ve Yanlış Negatif (FN), sırasıyla pozitif ve negatif sınıflar yanlış sınıflandırıldığında modelin sonuçlarıdır. Sınıflandırma doğruluğu, TP ve TN toplamının toplam örneklere bölünmesiyle hesaplanmıştır.

Derin öğrenme yöntemlerinden biri olan CNN, giyilebilir sensör sinyalleri zaman-frekans analizi görüntülerine uygulanarak insan yürüyüşü tanımadaki performansı değerlendirilmiştir.

CNN tabanlı sınıflandırmanın ilk aşamasında giriş veri seti görüntü matrisi olarak, IMU sensör ham ve bileşke lineer ivmelenme sinyal kanalları doğrudan uygulanmıştır. Bu sinyallere, sıklıkla tercih edilen TFA yöntemlerinden olan CWT ve STFT yöntemleri uygulanarak Şekil 3.8'de gösterilen CNN giriş veri setleri elde edilmiştir. Eğitim ve test giriş veri seti rastgele olacak şekilde %80-%20 şeklinde ayrılmıştır. Eşit dağılmayan (unbalanced) giyilebilir sensör veri setindeki sınıflandırma performansına etkisi incelemek amacıyla en az sayıda veri barındıran sınıftaki kadar görüntünün kullanıldığı aşağı örnekleme (down-sampling) işlemi uygulanarak bu kısımdaki deneyler yinelenmiştir. Bu deneylerde her bir yürüme hızı sınıfına ait 220'şer görüntü bulunmaktadır.



Şekil 3.8: CNN giriş görüntü veri setlerine örnekler.

CNN tabanlı sınıflandırmanın ikinci aşamasında ise IMU ve GON sensör sinyallerinin STFT görüntüleri giriş veri seti olarak uygulanmıştır. Giyilebilir sensör veri setinde, hızlı, normal ve yavaş yürüme hızı sınıfları için sırasıyla 230, 221 ve 229 görüntü bulunmaktadır. Bu deneylerde, giyilebilir sensör veri setindeki her bir yürüyüş hızına ait görüntüler otomatik olarak 5 kümeye ayrılmıştır. Şekil 3.9'da gösterildiği üzere CNN modeli, her bir tekrarda daha önce seçilen test kümesi haricindeki diğer dört veri kümesi eğitim kümesi olarak belirlenerek %80-%20 olarak eğitilmiştir. Derin öğrenme modeli sınıflandırma performansı değerlendirme ölçütleri her bir tekrar için ayrı ayrı hesaplanarak beş tekrarın ortalaması alınmıştır. Ortalamaya en yakın doğruluğa ait tekrardaki karışıklık matrislerine bulgularda yer verilmiştir.

Test					1. tekrar
	Test				2. tekrar
		Test			3. tekrar
			Test		4. tekrar
				Test	5. tekrar

Şekil 3.9: Giyilebilir sensör STFT görüntüleri eğitim ve test kümelerinin seçimi.

CNN modelinin eğitim aşaması için temel model parametreleri, eğitim ve test doğruluğu üzerinde en büyük etkiye sahiptir. MATLAB R2021b Deep Network Designer Toolbox'ı kullanılarak oluşturulan CNN modelinde, eğitim işlemi, optimize edici (optimizer) 'adam', ilk öğrenme hızı (learning rate) 0.0001, maksimum devir (epoch) 10 ve mini yığın boyutu (batch size) 64 parametreleriyle gerçekleştirilmiştir. Şekil 3.10'daki CNN modeli, bu parametrelerle en yüksek test doğruluğuna ulaşacak şekilde çeşitli parametre kombinasyonları denenerek elde edilmiştir.

Layers	**Type**	**Subtype**	**Configuration**	**Activations**	**Learnables**
1	Input layer	Image input	64 x 64 x 3 images with 'zerocenter' normalization	64 x 64 x 3	0
2	Feature extraction layer-1	Convolution	16 3 x 3 convolutions with stride [1 1] and padding 'same'	64 x 64 x 16	3 x 3 x 3 x 16
3		ReLU	ReLU	64 x 64 x 16	0
4		Convolution	16 3 x 3 convolutions with stride [1 1] and padding [1 1 1 1]	64 x 64 x 16	3 x 3 x 16 x 16
5		ReLU	ReLU	64 x 64 x 16	0
6		Batch Normalization	Batch normalization with 16 channels	64 x 64 x 16	0
7	Feature extraction layer - 2	Convolution	32 3 x 3 convolutions with stride [1 1] and padding 'same'	64 x 64 x 32	3 x 3 x 16 x 32
8		ReLU	ReLU	64 x 64 x 32	0
9		Convolution	32 3 x 3 convolutions with stride [1 1] and padding [1 1 1 1]	64 x 64 x 32	3 x 3 x 32 x 32
10		ReLU	ReLU	64 x 64 x 32	0
11		Batch Normalization	Batch normalization with 32 channels	64 x 64 x 32	0
12	Feature extraction layer - 3	Convolution	32 3 x 3 convolutions with stride [1 1] and padding 'same'	64 x 64 x 32	3 x 3 x 32 x 32
13		ReLU	ReLU	64 x 64 x 32	0
14		Convolution	32 3 x 3 convolutions with stride [1 1] and padding [1 1 1 1]	64 x 64 x 32	3 x 3 x 32 x 32
15		ReLU	ReLU	64 x 64 x 32	0

16		Batch Normalization	Batch normalization with 32 channels	64 x 64 x 32	0
17		Maximum pooling	2 x 2 max pooling with stride [1 1] padding ‘same’	64 x 64 x 32	0
18	Classification layer	Dropout	50% dropout	64 x 64 x 32	0
19		Fully connected	3 fully connected layer	1 x 1 x 3	3 x 1648928
20		Softmax	softmax	1 x 1 x 3	0
21	Output layer	Classification	‘fast’, ‘normal’ and ‘slow’	1 x 1 x 3	0

Şekil 3.10: Giyilebilir sensör sinyalleriyle yürüyüş tanıma CNN model mimarisi.

Çalışma kapsamında IMU ve GON sensör sinyallerinin STFT görüntü veri setleri ayrı ayrı Şekil 3.10‘daki CNN modeline uygulanmıştır. Ayrıca GON sensörü STFT görüntü veri seti IMU sensör STFT görüntü veri setleriyle birlikte çok girişli tek çıkışlı CNN modeline uygulanmıştır. Buradaki amaç, çoklu sensör verilerinin CNN modeliyle insan yürüyüşü tanımadaki başarısını değerlendirmektir. Şekil 3.10’daki modelden farklı olarak bu modele, giriş katmanından önce IMU ve GON görüntü veri setlerinin birleştirildiği bir katman daha eklenmiştir.

Analiz edilen derin CNN sınıflandırıcılarının eğitim ve test setleri üzerindeki sınıflandırma performansının değerlendirilmesinde karışıklık matrisi, doğruluk (Acc), duyarlılık (Sens), özgüllük (Spec), kesinlik (Prec), F1-skoru (F1-sc) ve G-skoru (G-sc) parametrelerinden yararlanılmıştır. Doğruluk yerine F1-skoru değerinden yararlanılmasının en önemli sebebi eşit dağılım göstermeyen veri kümelerinde hatalı bir model seçimi yapmayı önlemektedir. Ayrıca sadece FN ya da FP yerine tüm karışıklık matrisi parametrelerini barındıran bir ölçüm metriği ihtiyacını karşıladığından dolayı F1-skoru önemlidir. Kesinlik ve duyarlılığın uygulanmasında karmaşık etkinin dikkate alınması gerekmektedir. Bu nedenle burada sınıflandırıcının performansını değerlendirmede kullanılan kesinlik ve duyarlılık metriklerini birleştirebilen F1-skoru ve G-skoru iki önemli göstergeden yararlanılmıştır.

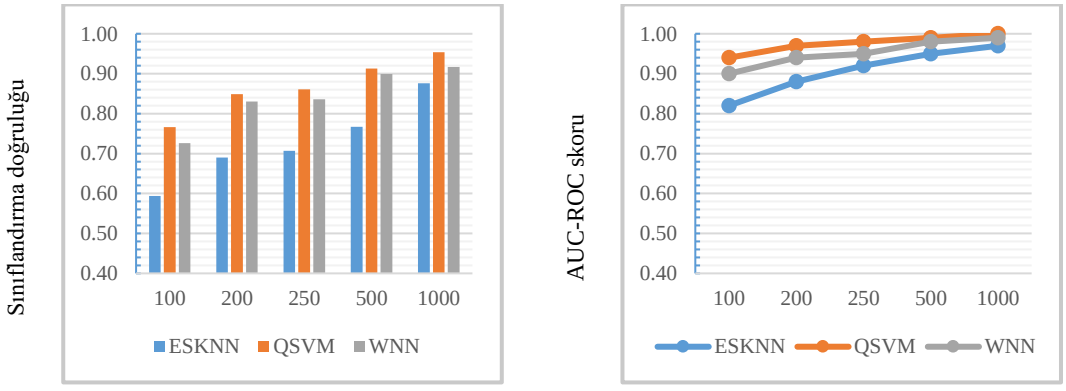
4. BULGULAR

4.1. MAKİNE ÖĞRENİMİ YAKLAŞIMIYLA BİYOMEKANİK SENSÖR VERİLERİNE DAYALI İNSAN ALT EKSTREMİTE HAREKETİNİN SINIFLANDIRILMASI

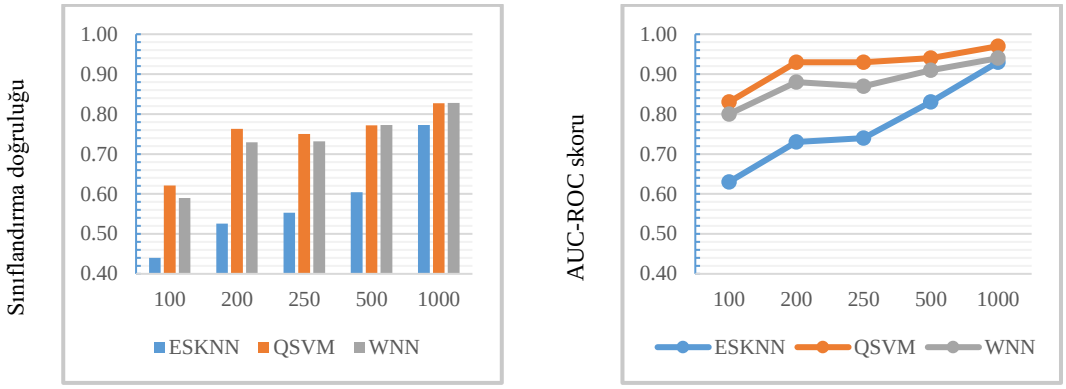
Bu kısımda IMU, GON ve EMG giyilebilir sensörleriyle sağlıklı bireylerden elde edilen sinyaller insan yürüyüşü tanıma amacıyla makine öğrenmesi yaklaşmıyla sınıflandırılmıştır. Sınıflandırma performansları değişen kayan pencere uzunlukları ve biyomekanik sensörlerin tekli veya çoklu kullanımına göre değerlendirilmiştir.

4.1.1. Kayan Pencere Uzunluğunun Sınıflandırma Performansına Etkisi

Yürüyüş tanımada IMU ve GON sensörü sinyalleri üzerinde farklı kayan pencere uzunluklarına karşılık gelen ML sınıflandırma doğrulukları sırasıyla Şekil 4.1(a) ve Şekil 4.1(c)'de gösterilmektedir. Benzer şekilde, IMU ve GON sensör modellerinin AUC-ROC skorları Şekil 4.1(b) ve Şekil 4.1(d)'de gösterilmektedir. IMU ve GON sensörünün ML sınıflandırma doğrulukları, kayan pencere uzunluklarının artmasıyla birlikte artmaktadır. En yüksek doğruluklar, 1000 pencere uzunluğu (winlen) ve QSVM sınıflandırıcıyla IMU sensörü için 0.954 ve gonyometre sensörü için 0.828 olmuştur. Benzer şekilde, IMU ve GON sensörlerin AUC-ROC puanı, artan kayan pencere uzunluklarıyla birlikte kademeli olarak artmaktadır. QSVM ve pencere uzunluklarının 1000 olması durumunda IMU sensörün AUC-ROC puanı 0.99'a ulaşırken, GON sensörün AUC-ROC puanı 0.97'ye ulaşmıştır.



(a) *(b)*



(c) ***(d)***

Şekil 4.1: IMU ve GON sensörlerin ML performanslarının karşılaştırılması. ***(a)*** IMU sensör sınıflandırma doğruluğu, ***(b)*** IMU sensör AUC-ROC skoru, ***(c)*** GON sensör sınıflandırma doğruluğu, ***(d)*** GON sensör AUC-ROC skoru.

Şekil 4.1'deki grafikler, sınıflandırıcıların IMU ve GON sensör modelleri için değişen kayan pencere uzunluğuna göre farklı sınıflandırma doğruluğu ve AUC-ROC skoruna sahip olduğunu göstermektedir. QSVM, diğer sınıflandırıcılara kıyasla yürüyüş hızı tanımada daha yüksek doğruluğa sahiptir. Özellikle IMU sensörü ve QSVM sınıflandırıcısıyla 1000 kayan pencere uzunluğundaki deneyde doğruluk en yüksektir. IMU sensöründe doğruluğun GON sensörüne göre daha yüksek olduğu görülmüştür. IMU sensörü ve QSVM sınıflandırıcıyla yürüyüş tanımada winlen-1000 (0.954), winlen-500 (0.913) ve winlen-250 (0.861) modelleri en yüksek doğruluğu gösteren modeller olarak görülmektedir. Benzer şekilde AUC-ROC puanları da modellerin doğruluğuna göre sıralanmıştır. IMU ve GON giyilebilir sensör verileriyle ML sınıflandırma performansı değerlendirildiğinde, genel (tüm ML sınıflandırıcılar, sensör türleri ve pencere uzunlukları) doğruluklar ve AUC-ROC puanları IMU sensörü için sırasıyla 0.954 ve 0.99 ve gonyometre sensörü için 0.828 ve 0.97'dir.

ML modelleri tarafından tahmin edilen her bir yürüme hızı için örnek sayısı, Şekil 4.2 ve Şekil 4.3'teki karışıklık matrislerinde gösterilmiştir. Örnekler için gerçek yürüyüş hızı etiketleri ise sütunlarda gösterilmiştir. Tablonun alt satırındaki parantez içindeki sayılar TP yüzdesini gösterirken, tablonun üst satırındaki mavi hücreler her WS sınıfı için TP değerini göstermektedir. Belirli bir WS sınıfı için FN değeri, mavi hücre dışında sıradaki tüm hücrelerdeki değerlerin toplamıdır.

winlen		ESKNN			QSVM			WNN		
		Gerçek bilinen								
		S	N	F	S	N	F	S	N	F
100 (0.5s)	Tahmin edilen S	**162 (0.707)**	49 (0.214)	18 (0.079)	**193 (0.843)**	34 (0.148)	2 (0.009)	**182 (0.795)**	42 (0.183)	5 (0.022)
	Tahmin edilen N	64 (0.29)	**103 (0.466)**	54 (0.244)	41 (0.186)	**154 (0.697)**	26 (0.118)	41 (0.186)	**139 (0.629)**	41 (0.186)
	Tahmin edilen F	26 (0.116)	63 (0.28)	**136 (0.604)**	3 (0.013)	52 (0.231)	**170 (0.756)**	2 (0.009)	54 (0.24)	**169 (0.751)**
200 (1s)	Tahmin edilen S	**170 (0.747)**	55 (0.24)	4 (0.017)	**195 (0.852)**	33 (0.144)	1 (0.04)	**198 (0.865)**	29 (0.127)	2 (0.09)
	Tahmin edilen N	53 (0.24)	**121 (0.548)**	47 (0.213)	21 (0.095)	**181 (0.819)**	19 (0.086)	29 (0.131)	**169 (0.765)**	23 (0.104)
	Tahmin edilen F	4 (0.018)	46 (0.204)	**175 (0.778)**	1 (0.04)	27 (0.12)	**197 (0.876)**	1 (0.04)	31 (0.138)	**193 (0.858)**
250 (1.25s)	Tahmin edilen S	**185 (0.808)**	38 (0.166)	6 (0.026)	**207 (0.904)**	21 (0.092)	1 (0.04)	**201 (0.878)**	28 (0.122)	0 (0)
	Tahmin edilen N	46 (0.208)	**132 (0.597)**	43 (0.195)	18 (0.081)	**184 (0.833)**	19 (0.086)	22 (0.1)	**168 (0.76)**	31 (0.14)
	Tahmin edilen F	13 (0.058)	52 (0.231)	**160 (0.711)**	2 (0.09)	33 (0.147)	**190 (0.844)**	2 (0.09)	28 (0.124)	**195 (0.867)**
500 (2.5s)	Tahmin edilen S	**198 (0.865)**	26 (0.114)	5 (0.022)	**212 (0.926)**	17 (0.074)	0 (0)	**214 (0.934)**	15 (0.066)	0 (0)
	Tahmin edilen N	35 (0.158)	**152 (0.688)**	34 (0.154)	12 (0.054)	**197 (0.891)**	12 (0.054)	17 (0.077)	**186 (0.842)**	18 (0.081)
	Tahmin edilen F	8 (0.036)	49 (0.218)	**168 (0.747)**	1 (0.004)	17 (0.076)	**207 (0.92)**	0 (0)	18 (0.08)	**207 (0.92)**
1000 (5s)	Tahmin edilen S	**201 (0.878)**	25 (0.109)	3 (0.013)	**218 (0.952)**	11 (0.048)	0 (0)	**220 (0.961)**	9 (0.039)	0 (0)
	Tahmin edilen N	24 (0.109)	**184 (0.833)**	13 (0.059)	3 (0.014)	**215 (0.973)**	3 (0.014)	20 (0.009)	**185 (0.837)**	16 (0.072)
	Tahmin edilen F	4 (0.018)	15 (0.067)	**206 (0.916)**	1 (0.004)	13 (0.058)	**211 (0.938)**	1 (0.004)	10 (0.044)	**214 (0.951)**

Şekil 4.2: IMU sensör modellerinin karışıklık matrisleri.

Yürüyüş tanımada çeşitli kayan pencere uzunluklarına sahip giyilebilir IMU ve GON sensör modellerini kullanan üç sınıflandırıcının karışıklık matrisi sırasıyla Şekil 4.2 ve Şekil 4.3'te gösterilmektedir. Bu tablolarda, üç sınıflandırıcının her üç yürüme hızı sınıfı için farklı tanıma doğruluklarına sahip olduğu görülmektedir. QSVM, diğer sınıflandırıcılarla karşılaştırıldığında yürüme hızı tanıma açısından daha yüksek TP'ye sahiptir. Özellikle kayan pencere uzunluğu 1000 olan IMU sensörünü temel alan QSVM sınıflandırıcısının kullanıldığı deneyde TP değeri ve yüzdesi en yüksek çıkmıştır. GON sensörünün aksine, sınıflandırma doğruluğundaki karşılaştırmaya benzer şekilde daha düşük bir TP değeri ve yüzdesine sahiptir. Yapılan deneylerde üç sınıflandırıcının en düşük TP değeri ve yüzdesi 'N' hız sınıfındadır. Ayrıca, IMU modeli ve QSVM sınıflandırıcısı kullanıldığında, her bir yürüme hızı sınıfı için en yüksek TP

değerleri sırasıyla S (218), N (215) ve F (211) olmuştur. GON modeli ve QSVM sınıflandırıcısı kullanıldığında, her bir yürüme hızı sınıfı için en yüksek TP değerleri sırasıyla S (186), N (176) ve F (196) olmuştur.

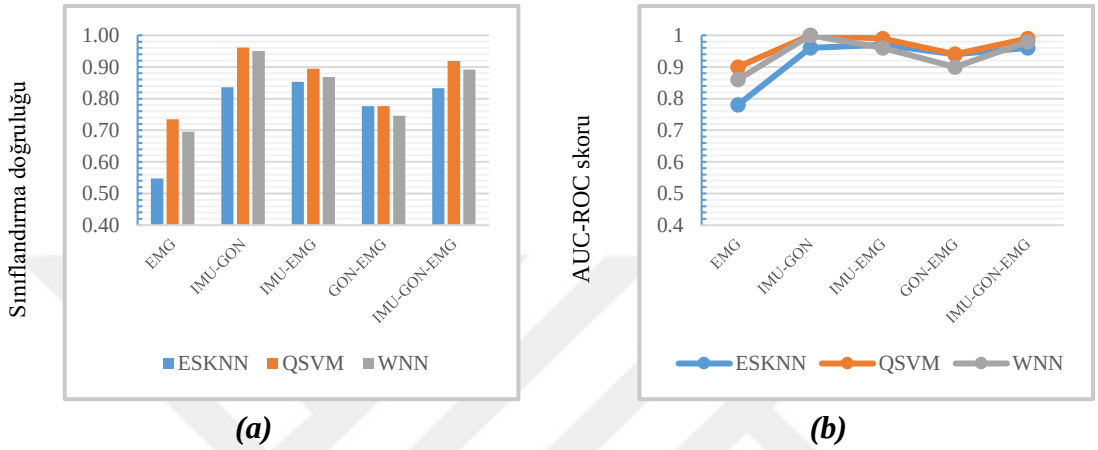
winlen		ESKNN			QSVM			WNN		
		Gerçek bilinen								
		S	N	F	S	N	F	S	N	F
100 (0.5s)	Tahmin edilen S	**117 (0.511)**	72 (0.314)	40 (0.175)	**145 (0.633)**	68 0.297)	16 (0.007)	**152 (0.664)**	55 0.24)	22 (0.096)
	Tahmin edilen N	78 (0.353)	**81 (0.367)**	62 (0.281)	43 (0.195)	**126 (0.57)**	52 (0.235)	56 (0.253)	**98 (0.443)**	67 (0.303)
	Tahmin edilen F	51 (0.227)	75 (0.333)	**99 (0.44)**	16 (0.071)	61 (0.271)	**148 (0.658)**	18 (0.008)	59 (0.262)	**148 (0.658)**
		S	N	F	S	N	F	S	N	F
200 (1s)	Tahmin edilen S	**113 (0.493)**	75 (0.328)	41 (0.179)	**172 (0.751)**	55 (0.24)	2 (0.009)	**179 (0.782)**	43 (0.188)	7 (0.031)
	Tahmin edilen N	54 (0.244)	**99 (0.448)**	68 (0.308)	29 (0.131)	**161 (0.729)**	31 (0.14)	41 (0.186)	**143 (0.647)**	37 (0.167)
	Tahmin edilen F	33 (0.147)	49 (0.218)	**143 (0.636)**	5 (0.022)	38 (0.169)	**182 0.809)**	6 (0.027)	49 (0.218)	**170 (0.756)**
		S	N	F	S	N	F	S	N	F
250 (1.25s)	Tahmin edilen S	**133 (0.581)**	65 (0.284)	31 (0.135)	**177 (0.773**	44 (0.192)	8 (0.035)	**169 (0.738)**	49 (0.214)	11 (0.048)
	Tahmin edilen N	57 (0.258)	**114 (0.516)**	50 (0.226)	33 (0.149)	**155 (0.701**	33 (0.149)	41 (0.186)	**146 (0.661)**	34 (0.154)
	Tahmin edilen F	40 (0.178)	59 (0.262)	**126 (0.56)**	2 (0.009)	49 (0.218)	**174 (0.773)**	7 (0.031)	39 (0.173)	**179 (0.796)**
		S	N	F	S	N	F	S	N	F
500 (2.5s)	Tahmin edilen S	**150 (0.655)**	54 (0.236)	25 (0.109)	**181 (0.738)**	41 (0.179)	7 (0.031)	**184 (0.803)**	42 (0.183)	3 (0.013)
	Tahmin edilen N	45 (0.204)	**130 (0.588)**	46 (0.208)	30 (0.136)	**163 (0.738)**	28 (0.127)	29 (0.131)	**153 (0.692)**	39 (0.176)
	Tahmin edilen F	27 (0.012)	70 (0.311)	**128 (0.569)**	4 (0.018)	44 (0.196)	**177 (0.787)**	6 (0.027)	34 (0.151)	**185 (0.822)**
		S	N	F	S	N	F	S	N	F
1000 (5s)	Tahmin edilen S	**186 (0.812)**	38 (0.166)	5 (0.022)	**186 (0.812)**	43 (0.188)	0 (0)	**198 (0.865)**	29 (0.127)	2 (0.009)
	Tahmin edilen N	30 (0.136)	**151 (0.683)**	40 (0.181)	22 (0.1)	**176 (0.796)**	23 (0.104)	27 (0.122)	**167 (0.756)**	27 (0.122)
	Tahmin edilen F	6 (0.027)	34 (0.151)	**185 (0.822)**	3 (0.013)	26 (0.116)	**196 (0.871)**	2 (0.009)	29 (0.129)	**194 (0.862)**

Şekil 4.3: GON sensör modellerinin karışıklık matrisleri.

4.1.2. Tekli ve Çoklu Giyilebilir Sensör Modellerinin Sınıflandırma Performansına Etkisi

İnsan yürüyüşünü tanımaya yönelik EMG ve diğer çoklu giyilebilir sensör modellerinin 1000 kayan pencere uzunluğundaki sınıflandırma doğrulukları Şekil 4.4(a)'da ve AUC-ROC skorları Şekil 4.4(b)'de gösterilmektedir. Bu grafiklerden, sınıflandırıcıların beş sensör modeli için farklı sınıflandırma doğruluğuna ve AUC-ROC skoruna sahip olduğu görülmektedir. QSVM, diğer sınıflandırıcılarla karşılaştırıldığında yürüyüş tanıma konusunda daha yüksek doğruluğa sahiptir. Özellikle IMU sensörünün ve QSVM sınıflandırıcısının kullanıldığı deneydeki doğruluk, diğer sensör modelleri ve sınıflandırıcılar arasında en yüksek olanıdır. IMU

sensörünün dahil edildiği modellerin doğruluğu EMG sensörü modellerininkine göre daha yüksek olduğu görülmüştür. QSVM sınıflandırıcısıyla yürüyüş tanımada IMU-GON (0.961), IMU-GON-EMG (0.919) ve IMU-EMG (0.895) modelleri en yüksek doğruluğu gösteren modeller olarak görülmektedir. Benzer şekilde AUC-ROC puanları da modellerin doğruluğuna göre sıralanmıştır.

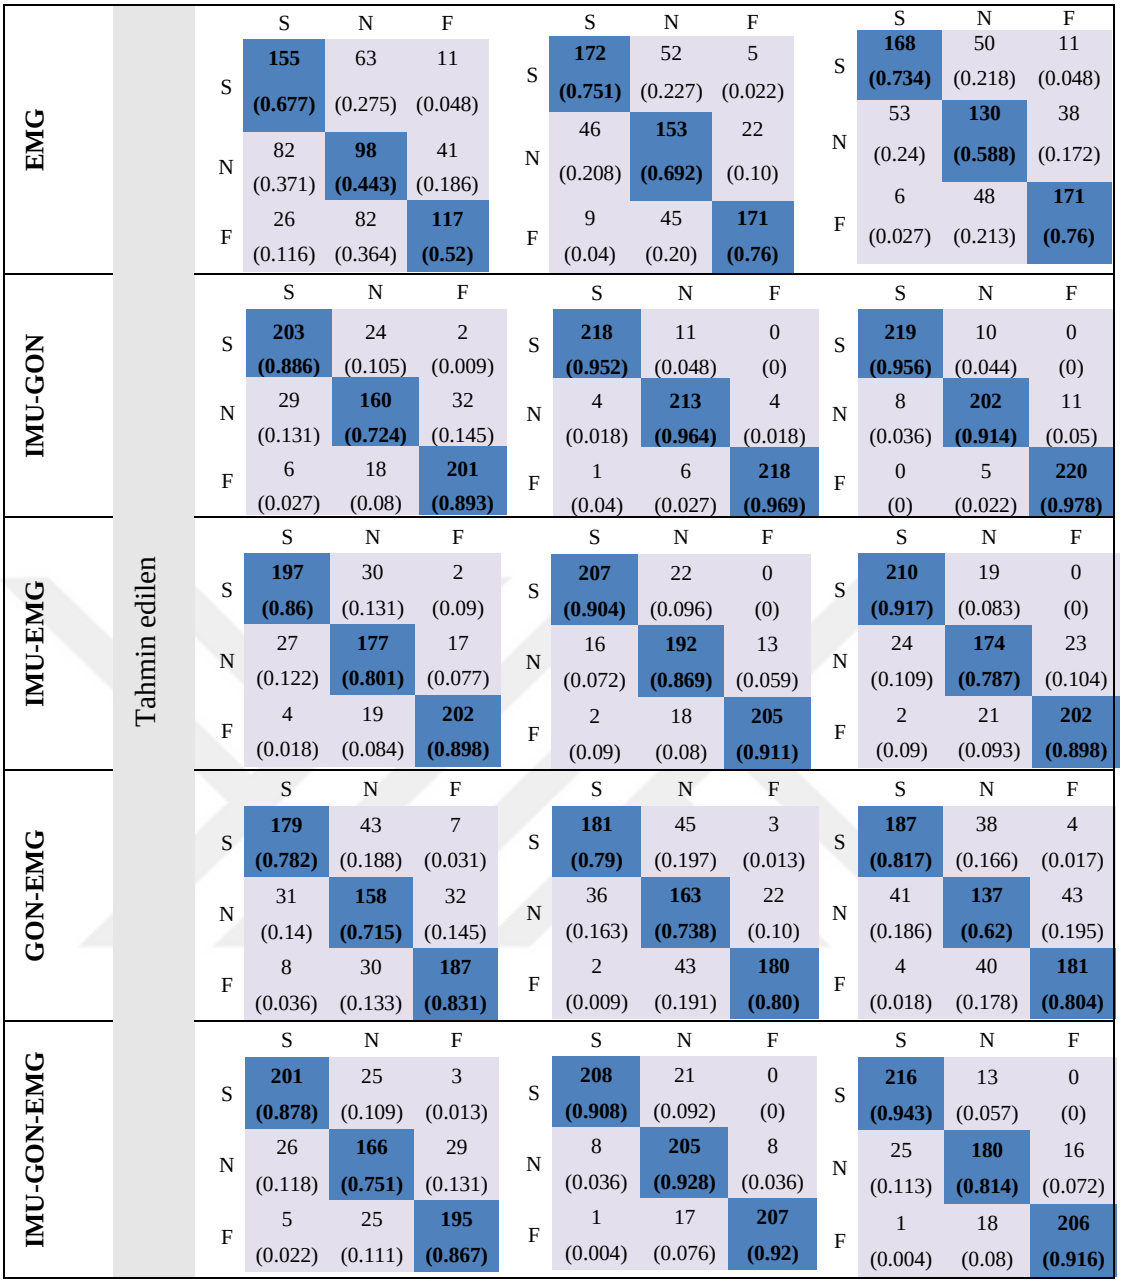


(a) ***(b)***

Şekil 4.4: Çoklu giyilebilir sensör modellerinin ML sınıflandırma performansı. ***(a)*** Sınıflandırma doğruluğu, ***(b)*** AUC-ROC skoru.

İnsan yürüyüş örüntüsü tanımada, 1000 kayan pencere uzunluğundaki EMG ve diğer çoklu giyilebilir sensörleri sinyalleriyle üç makine öğrenimi sınıflandırıcısının karışıklık matrisi Şekil 4.5'te gösterilmektedir. 1000 kayan pencere uzunluğundaki IMU ve GON sensör sinyalleriyle üç sınıflandırıcıya ait karışıklık matrislerine Şekil 4.2 ve Şekil 4.3'te yer verilmiştir. Bu bulgulardan, üç sınıflandırıcının üç yürüme hızı için farklı TP değerlerine sahip olduğu görülmektedir. QSVM, diğer sınıflandırıcılarla karşılaştırıldığında yürüme hızı tanıma açısından daha yüksek TP'ye sahiptir. Özellikle IMU sensör ve QSVM sınıflandırıcının kullanıldığı deneydeki TP değeri, diğer sensör kombinasyonları ve ML sınıflandırıcıları arasında en yüksek değerdir. Yapılan deneylerde üç sınıflandırıcının en düşük TP değeri 'N' hız sınıfındadır. Sağlıklı bireylerin yürüyüş sinyali olduğundan 'S' hız sınıfı 'N' hız sınıfı ile, 'F' hız sınıfı ise 'N' hız sınıfı ile karıştırılmaktadır, bu da 'N' hız sınıfının TP değerinin düşük olmasının temel sebebidir. Ayrıca, IMU-GON modeli ve QSVM sınıflandırıcısıyla, her bir yürüme hızı sınıfı için en yüksek TP değerleri sırasıyla S (218), N (213) ve F (218) olmuştur.

sensör	ESKNN	QSVM	WNN
	Gerçek bilinen		



Şekil 4.5: EMG ve diğer çoklu sensör modellerinin karışıklık matrisleri.

4.2. MAKİNE ÖĞRENMESİ YAKLAŞIMIYLA IMU BİYOMEKANİK SENSÖR VERİLERİNE DAYALI İNSAN YÜRÜYÜŞÜ TANIMA

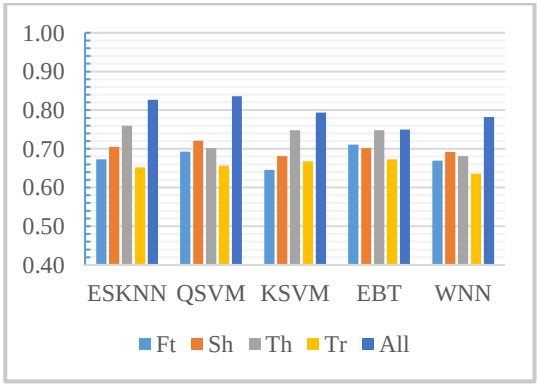
Bu kısımda insan alt ekstremitesi üzerine yerleştirilen dört IMU sensör yardımıyla yürüyüş örüntüsü tanımada biyomekanik sensör seçiminin ve farklı veri işleme yöntemlerinin etkinliği makine öğrenmesi algoritmalarıyla incelenmiştir. Bir önceki kısımdaki deneylerde 200 (1s) uzunluğundaki IMU sinyali kullanıldığında insan yürüyüş hızı tanımada kayda değer doğruluğa ulaşıldığı görülmüştür. Bu nedenle en yüksek tanıma doğruluğuna yakın ve işlem süresini kısaltan en uygun uzunluktaki sinyalle deneyler gerçekleştirilmiştir. Çalışmada analiz edilen

dört durum, Durum-I: özniteliklerin doğrudan kullanıldığı, Durum-II: özniteliklere sadece [0-1] veri normalizasyonu, Durum-III: özniteliklere sadece PCA uygulanması, Durum-IV: özniteliklere PCA ve [0-1] veri normalizasyonu uygulanmasıdır.

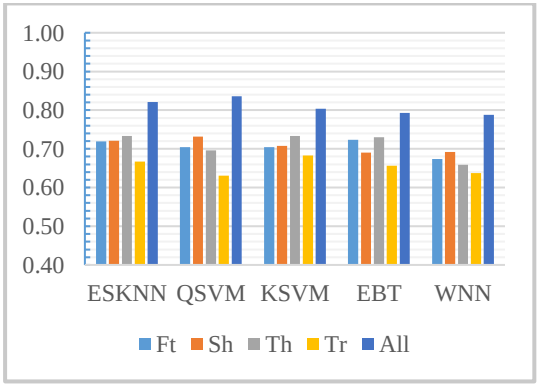
4.2.1. Veri Normalizasyonu ve PCA'nın ML Sınıflandırma Performansına Etkisi

Her bir durum için beş farklı makine öğrenmesi sınıflandırıcısının tekli giyilebilir sensör bazında sınıflandırma doğruluğu Şekil 4.6'da gösterilmiştir. Şekil 4.6(a)-(b) veri normalizasyonun, Şekil 4.6(a)-(c) PCA'nın ve Şekil 4.6(a)-(d) PCA ile veri normalizasyonun birlikte uygulamanın makine öğrenmesi sınıflandırması üzerine etkisini göstermektedir.

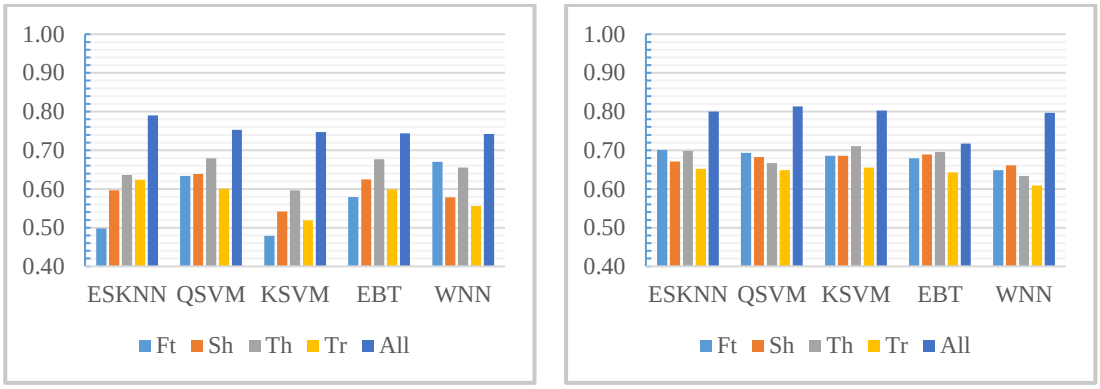
Şekil 4.6(a)'da gösterildiği gibi Durum-I için en yüksek sınıflandırma doğruluğuna, tüm giyilebilir sensör verilerinin birlikte kullanıldığı QSVM modeli (0.836) ve ardından ESKNN modeliyle (0.827) ulaşılırken, en düşük sınıflandırma doğruluğu ise gövde sensör verilerinin kullanıldığı WNN modeliyle (0.636) elde edilmiştir. Şekil 4.6(b)'de görüldüğü üzere normalizasyon işleminin uygulandığı Durum-II ML sınıflandırıcı çıktıları, QSVM ve ESKNN'nin tüm sensör öznitelikleri birlikte kullanılarak en yüksek doğruluk 0.836'ya ulaştığını, OSVM ve WNN'nin gövde sensörü öznitelikleri kullanılarak en düşük doğruluk 0.631'e ulaştığını göstermektedir. Veri normalizasyonunun ML sınıflandırıcıları üzerine etkileri karşılaştırıldığında ayak ve bacak sensör özniteliklerinin sınıflandırma doğruluğunu artırırken gövde sensör özniteliklerinin sınıflandırma doğruluğunu azalttığı bulunmuştur.



(a)



(b)



(c) ***(d)***

Şekil 4.6: Veri normalizasyonu ve PCA'nın ML sınıflandırma performansına etkisi. ***(a)*** Durum-I, ***(b)*** Durum-II, ***(c)*** Durum-III, ***(d)*** Durum-IV.

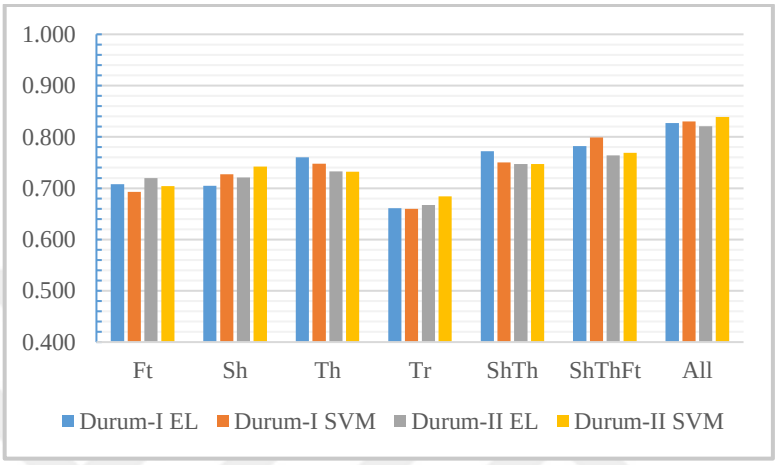
Öznitelik sayısını azaltmayı sağlayan PCA uygulandığında ise, Şekil 4.6(c)'deki sınıflandırıcı çıktılarının, ESKNN'nin tüm özniteliklerle birlikte kullanılarak 0.79 ile en yüksek doğruluğa ulaştığı, ayak sensör öznitelikleriyle birlikte KSVM'nin 0.498 ile en düşük doğruluğa sahip olduğu gösterilmiştir. Durum-IV için Şekil 4.6(d)'deki sınıflandırıcı çıktıları, EBT hariç tüm sensör özniteliklerinin birlikte kullanılmasıyla elde edilen ortalama doğruluğun 0.80 olduğunu, gövde sensörü öznitelikleri ve WNN'nin 0.609 ile en düşük doğruluğa ulaştığını göstermiştir.

Sonraki analizler, ML sınıflandırma doğruluğu üzerine ihmal edilebilir etkisi sebebiyle PCA uygulanmadan gerçekleştirilmiştir. Ek olarak, WNN sınıflandırıcısı, daha düşük bir sınıflandırma doğruluğuna sahip olduğu için sonraki analizlerde kullanılmamıştır. Ayrıca sonraki kısımda QSVM ve KSVM'den sınıflandırma doğruluğu en yüksek olanı SVM olarak, ESKNN ve EBT'den sınıflandırma doğruluğu en yüksek olanı EL olarak ifade edilmiştir.

4.2.2. ML Sınıflandırma Performansının Sensör Bazında Değerlendirilmesi

ML algoritmalarının sınıflandırma doğruluğu değerlendirildiğinde, insan yürüyüş tanımada SVM sınıflandırıcısıyla tüm sensör özniteliklerine veri normalizasyonu uygulamanın bunu tekli IMU sensör öznitelikleriyle uygulamaya kıyasla daha iyi sonuçlar verdiği Şekil 4.7'de gösterilmiştir. SVM tabanlı sınıflandırıcıların, EL tabanlı sınıflandırıcılarla karşılaştırıldığında yürüyüş tanıma konusunda nispeten daha yüksek doğruluğa sahip olduğu sonucuna ulaşılmaktadır. Özellikle IMU sensör kanallarının tümünün dahil edildiği özniteliklerle [0-1] veri normalizasyonu ve SVM sınıflandırıcısının kullanıldığı deneydeki doğruluk (0.839), diğer sensör modelleri ve sınıflandırıcıları arasında en yüksek olanıdır. Özniteliklerin doğrudan uygulandığı tekli IMU sensör modelleri değerlendirildiğinde EL tabanlı modellerin doğrulukları sırasıyla 'Th' (0.76), 'Sh' (0.705), 'Ft' (0.708) ve 'Tr' (0.661) ve SVM tabanlı

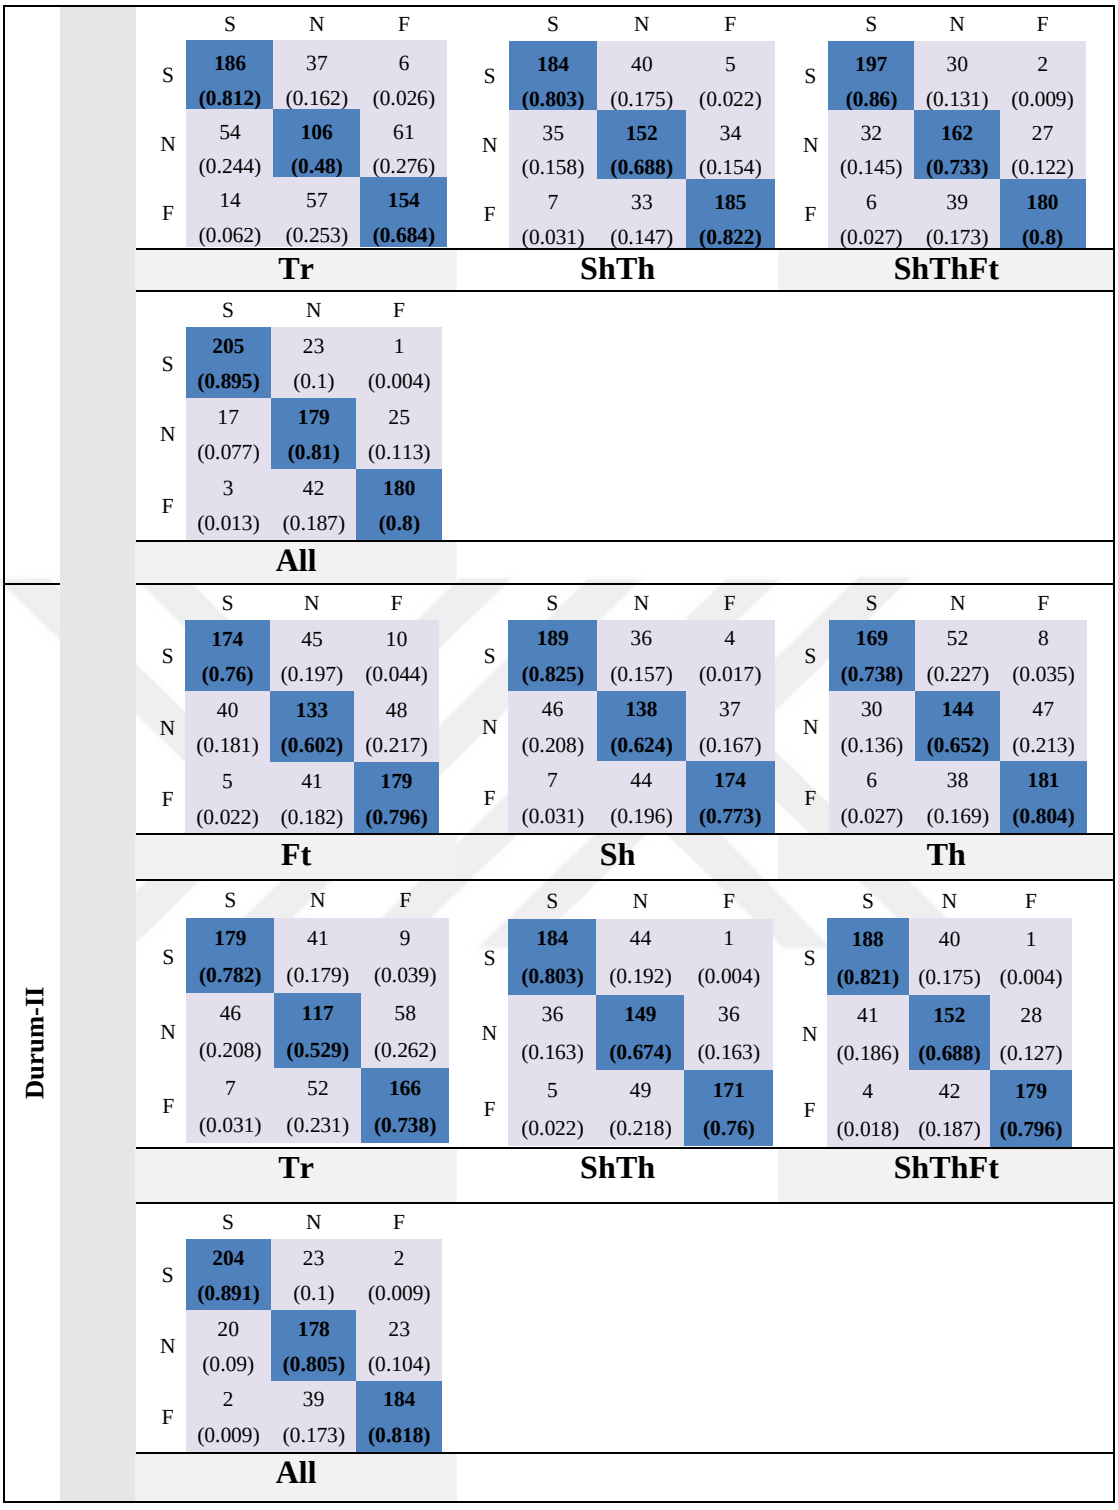
modellerin doğrulukları sırasıyla ‘Th’ (0.748), ‘Sh’ (0.727), ‘Ft’ (0.693) ve ‘Tr’ (0.66) olarak görülmektedir. Özniteliklerin doğrudan uygulandığı çoklu IMU sensör modelleri değerlendirildiğinde ise EL tabanlı modellerin doğrulukları sırasıyla ‘ShTh’ (0.772), ‘ShThFt’ (0.782) ve SVM tabanlı modellerin doğrulukları sırasıyla ‘ShTh’ (0.75), ‘ShThFt’ (0.799) olarak görülmektedir.



Şekil 4.7: ML sınıflandırma doğruluklarının sensör bazında karşılaştırılması.

Şekil 4.8’deki Durum-I ve Durum-II karışıklık matrisleri, makine öğrenmesi modelleriyle tahmin edilen her bir yürüyüş hızı (WS) için örnek sayısını göstermektedir. Benzer şekilde sütunlar, örneklerin gerçek yürüyüş hızı etiketlerini ifade etmektedir. Tablonun üst satırındaki mavi hücreler, her bir WS sınıfı için TP değerini, alt satırdaki parantez içindeki değer ise TP yüzdesini göstermektedir. Mavi hücre dışında her bir satırdaki tüm hücrelerdeki değerlerin toplamı, belirli bir WS sınıfı için FN değerine karşılık gelmektedir.

		Gerçek bilinen											
Durum-I	Tahmin edilen	S	N	F	S	N	F	S	N	F	S	N	F
	S	**180** (0.786)	40 (0.175)	9 (0.039)	**179** **(0.782)**	47 (0.205)	3 (0.013)	**175** **(0.764)**	49 (0.214)	5 (0.022)
	N	50 (0.226)	**122** **(0.552)**	49 (0.222)	49 (0.222)	**138** **(0.624)**	34 (0.154)	40 (0.181)	**141** **(0.638)**	40 (0.181)
	F	6 (0.027)	43 (0.181)	**176** **(0.782)**	7 (0.031)	44 (0.196)	**174** **(0.773)**	5 (0.022)	31 (0.138)	**189** **(0.84)**
		Ft			**Sh**			**Th**		



Şekil 4.8: ML sınıflandırıcıların sensör bazlı karışıklık matrisleri.

Durum-I için sensör bazında sınıflandırma karışıklık matrislerinde görüldüğü gibi, her bir yürüyüş hızı etiketinde en düşük TP değerini 'Tr' modelinde ve en yüksek TP değerini ise 'Tümü' modelinde almıştır. Durum-II karışıklık matrislerinde de benzer şekilde TP değerleri ve sensör modelleri uyumlanmıştır. 'ShTh', 'ShThFt' ve 'All' gibi çoklu sensörler, her yürüyüş

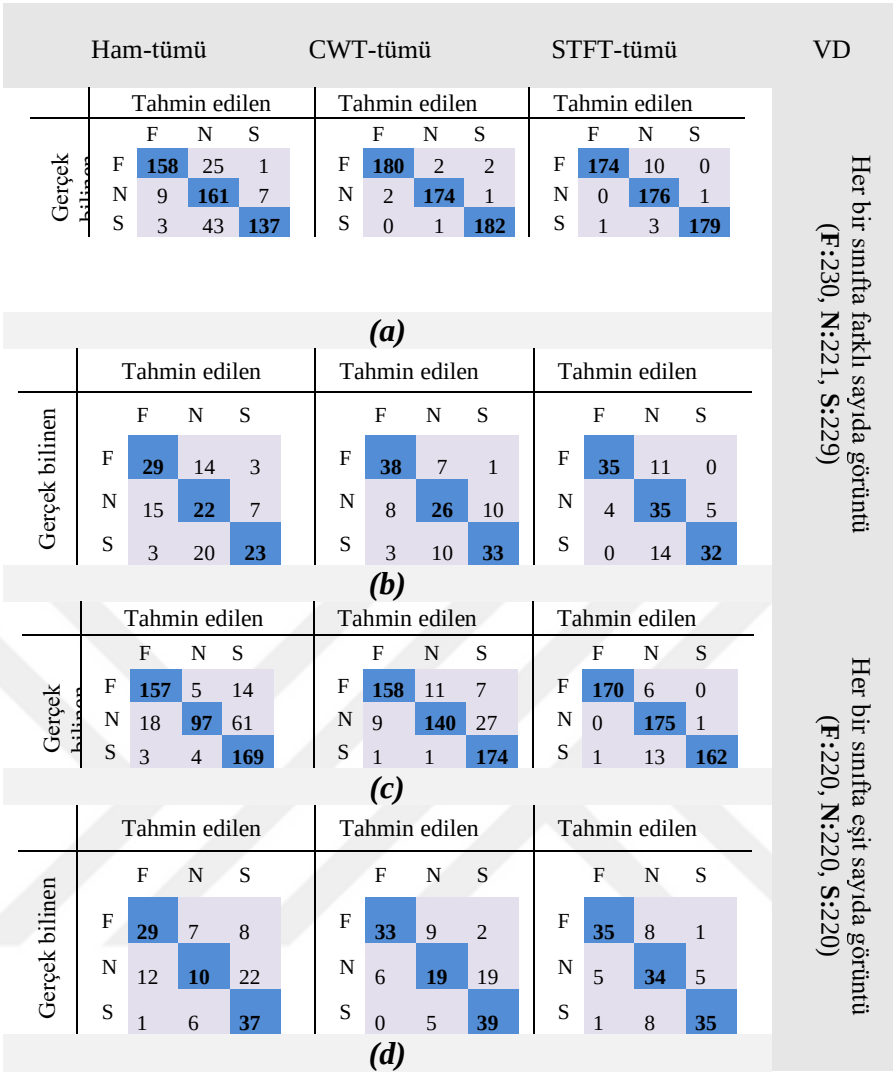
hızı sınıfında ‘Ft’, ‘Sh’, ‘Th’ ve ‘Tr’ gibi tekli sensörlerden daha yüksek doğruluk göstermiştir. En düşük TP ise ‘Tr’ sensör veri setinin ‘normal’ sınıfında görülmüştür. Bu durumun sebebi ise sağlıklı bireylerin alt ekstremite giyilebilir biyomekanik sensör sinyalleri incelendiğinden S ve F hız etiketleriyle N hız etkiketlerinin net olarak ayırt edilememesidir.

4.3. DERİN ÖĞRENME TABANLI IMU SENSOR VERİSİNİN ZAMAN-FREKANS ANALİZİ GÖRÜNTÜLERİNDEN İNSAN YÜRÜYÜŞÜ TANIMA

Çalışmanın bu kısmında, derin CNN modeli kullanılarak biyomedikal sinyal işleme yöntemlerinden elde edilen farklı zaman-frekans alanı görüntülerinin, yürüyüş hızı tanımadaki performansı sınıflandırma metrikleri yardımıyla karşılaştırılmıştır. Ham verilerin yanı sıra biyomekanik sensör lineer ivmelenmelerin bileşkesine de TFA analizi uygulanarak derin CNN yöntemiyle sınıflandırılmıştır. Ayrıca veri setindeki eşit olmayan dağılımın etkisini değerlendirmek amacıyla her bir yürüyüş hızı sınıfındaki veriler eşit olarak alınarak analiz tekrarlanmıştır. Giyilebilir IMU sensörlerinin tüm kanalları için eğitim ve test karışıklık matrisleri ve buradan elde edilen sınıflandırma performans ölçütleri değerlendirilerek insan yürüyüş örüntüsü tanımada dijital sinyal işleme yöntemlerinin etkinliği derin öğrenme modellerinden yararlanılarak karşılaştırılmıştır.

4.3.1. Ham IMU CNN Modellerinin Sınıflandırma Performansları

Ham IMU sensör zaman-frekans analizi görüntülerinin veri dağılımına (VD) göre çoklu sınıflandırma CNN modeline ait eğitim ve test karışıklık matrisleri Şekil 4.9'da gösterilmiştir. Dijital sinyal işleme yöntemleri açısından karşılaştırıldığında sinyal kanallarının doğrudan görüntüsünün alındığı ‘Ham-tümü’ görüntü veri setinin, zaman-frekans alanı öznitelikleri olan ‘CWT-tümü’ ve ‘STFT-tümü’ TFA görüntü veri setlerine göre hem eğitim hem test kümesi karışıklık matrislerinde daha düşük TP değerine sahip olduğu gözlenmiştir.



Şekil 4.9: Ham IMU CNN modellerinin karışıklık matrisleri. Veri dağılımı her bir sınıfta farklı sayıda görüntü olan ***(a)*** Eğitim kümesi, ***(b)*** Test kümesi, Veri dağılımı her bir sınıfta aynı sayıda görüntü olan ***(c)*** Eğitim kümesi, ***(d)*** Test kümesi.

Veri dağılımına göre Şekil 4.9 (a-b)'de her bir sınıfta farklı sayıda görüntü bulunan ve Şekil 4.9 (c-d)'de her bir sınıfta aynı sayıda görüntü bulunan IMU sensör CNN modellerine ait karışıklık matrislerine yer verilmiştir. Bu bulgulardan, üç CNN modelinin üç yürüme hızı sınıfı için farklı TP değerlerine sahip olduğu görülmektedir. 'STFT-tümü' modeli, diğer modellerle karşılaştırıldığında yürüme hızı tanıma açısından her üç yürüme hızı sınıfında da en yüksek TP'ye sahiptir. Veri dağılımına göre test kümesi sınıflandırma performansı değerlendirildiğinde her bir sınıfta aynı sayıda görüntü bulunan deneylerde farklı sayıda görüntü bulunan deneylere kıyasla 'STFT-tümü' modeli hariç daha düşük TP değerine ulaşılmıştır. Yürüme hızı sınıfları karşılaştırıldığında ise özellikle en düşük TP değeri 'N' hız sınıfındadır. Eğitim ve test kümesi TP değerleri yürüyüş hızı etiketi yönünden karşılaştırıldığında ise benzer şekilde, zaman-frekans analizi öznitelikleri olan 'CWT-tümü' ve 'STFT-tümü' TFA görüntü veri setlerinin

‘hızlı’ ve ‘yavaş’ hız etiketi TP değeri, ‘Ham-tümü’ görüntü veri seti ‘normal’ hız etiketine göre daha yüksektir.

Ham IMU CNN modelinin test kümesi sınıflandırma performansları Tablo 4.1’de gösterilmiştir. Veri dağılımına göre her bir sınıfta aynı ve farklı sayıda görüntü veri setinin kullanıldığı ‘CWT-tümü’ ve ‘STFT-tümü’ modellerinde doğruluk 0.800 civarı ve üzerinde olduğu gözlenmiştir. Benzer şekilde ‘CWT-tümü’ ve ‘STFT-tümü’ modelleri sırasıyla VD’ye göre her bir sınıfta farklı sayıda görüntü veri setiyle özgüllükte 0.857 ve 0.876, VD’ye göre her bir sınıfta farklı sayıda görüntü veri setiyle duyarlılıkta 0.845 ve 0.894 değerleriyle insan yürüyüş hareketi en iyi sınıflandırma performansını göstermiştir. ‘Ham-IMU’ modeli ise VD’ye göre her bir sınıfta farklı sayıda görüntü veri setiyle F-skoru (0.549) ve kesinlik (0.543) ile en düşük sınıflandırma performansı göstermiştir.

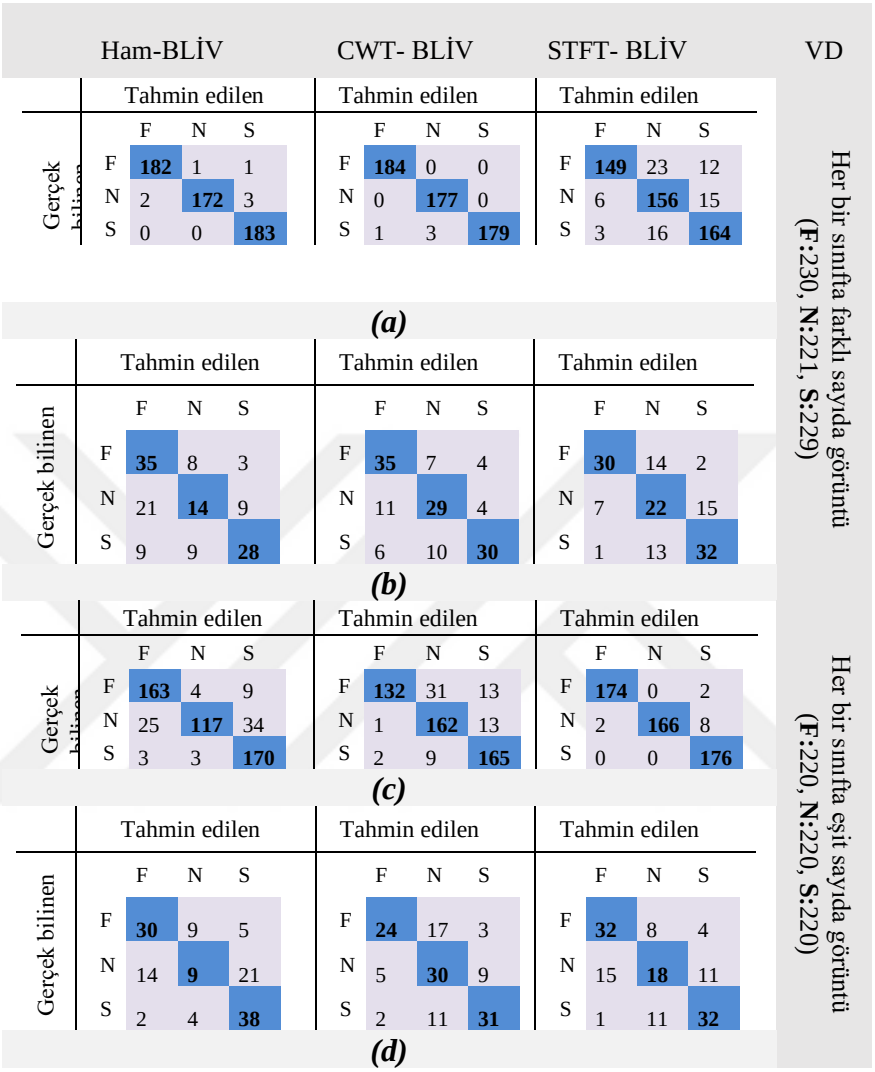
Tablo 4.1: Ham IMU CNN modelleri test kümesi sınıflandırma performansları.

VD		Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F-skoru	Görüntü
Her bir sınıfta farklı sayıda görüntü	F	0.743	0.617	0.800	0.630	0.624	Ham-tümü
	N	0.588	0.393	0.630	0.500	0.440	
	S	0.757	0.697	0.889	0.500	0.582	
	ORT	0.696	0.569	0.773	0.543	0.549	
	F	0.860	0.776	0.878	0.826	0.800	CWT-tümü
	N	0.743	0.605	0.815	0.591	0.598	
	S	0.824	0.750	0.878	0.717	0.733	
	ORT	**0.809**	**0.710**	**0.857**	**0.711**	**0.710**	
	F	0.890	0.897	0.956	0.761	0.824	STFT-tümü
	N	0.750	0.583	0.728	0.795	0.673	
	S	0.860	0.865	0.944	0.696	0.771	
	ORT	**0.833**	**0.782**	**0.876**	**0.751**	**0.756**	
Her bir sınıfta aynı sayıda görüntü	F	0.788	0.852	0.690	0.659	0.674	Ham-tümü
	N	0.644	0.852	0.435	0.227	0.299	
	S	0.720	0.659	0.552	0.841	0.667	
	ORT	0.717	0.788	0.559	0.576	0.547	
	F	0.871	0.932	0.846	0.750	0.795	CWT-tümü
	N	0.705	0.841	0.576	0.432	0.494	
	S	0.803	0.761	0.650	0.886	0.750	
	ORT	**0.793**	**0.845**	**0.691**	**0.689**	**0.680**	
	F	0.886	0.932	0.854	0.795	0.824	STFT-tümü
	N	0.803	0.818	0.680	0.773	0.723	
	S	0.886	0.932	0.854	0.795	0.824	
	ORT	**0.859**	**0.894**	**0.796**	**0.788**	**0.790**	

4.3.2. IMU Bileşke Lineer İvmelenme CNN Modellerinin Sınıflandırma Performansları

İnsan yürüyüş sınıflandırmada dijital sinyal işleme yöntemlerinin etkinliğini belirlemek amacıyla ham IMU sensör zaman-frekans analizi görüntülerine ek olarak IMU bileşke ivmelenme CNN modeli kullanılarak karşılaştırılmıştır. Her bir sınıftaki görüntü sayısının dağılımına göre ‘CWT-BLİV’ modelinin, doğrudan IMU bileşke lineer ivmelenme sinyallerinin görüntüsünün alındığı ‘Ham-BLİV’ modeli ve ‘STFT-BLİV’ modeline göre daha

yüksek TP değerine sahip olduğu Şekil 4.10'daki eğitim ve test kümesi karışıklık matrislerinde gözlenmiştir.



Şekil 4.10: IMU bileşke lineer ivmelenme CNN modellerinin karışıklık matrisleri. Veri dağılımı her bir sınıfta farklı sayıda görüntü olan ***(a)*** Eğitim kümesi, ***(b)*** Test kümesi, Veri dağılımı her bir sınıfta aynı sayıda görüntü olan ***(c)*** Eğitim kümesi, ***(d)*** Test kümesi.

Veri dağılımına göre Şekil 4.10 (a-b)'de her bir sınıfta farklı sayıda görüntü bulunan ve Şekil 4.10 (c-d)'de her bir sınıfta aynı sayıda görüntü bulunan IMU sensör bileşke lineer ivmelenme CNN modellerine ait karışıklık matrislerine yer verilmiştir. Bu bulgulardan, üç CNN modelinin üç yürüme hızı sınıfı için farklı TP değerlerine sahip olduğu görülmektedir. 'CWT-BLİV' modeli, diğer modellerle karşılaştırıldığında yürüme hızı tanıma açısından her üç yürüme hızı sınıfında da en yüksek TP'ye sahiptir. Veri dağılımına göre test kümesi sınıflandırma performansı değerlendirildiğinde her bir sınıfta aynı sayıda görüntü bulunan deneylerde farklı sayıda görüntü bulunan deneylere kıyasla 'CWT-BLİV' modeli hariç daha düşük TP değerine

ulaşılmıştır. Eğitim ve test kümesi TP değerleri yürüyüş hızı etiketi bakımından karşılaştırıldığında ise TFA öznitelikleri olan ‘CWT-BLİV’ ve ‘STFT-BLİV’ görüntü veri setlerinin ‘hızlı’ ve ‘yavaş’ hız etiketi TP değeri, ‘Ham-BLİV’ görüntü veri seti ‘normal’ hız etiketi TP değerine göre daha yüksektir.

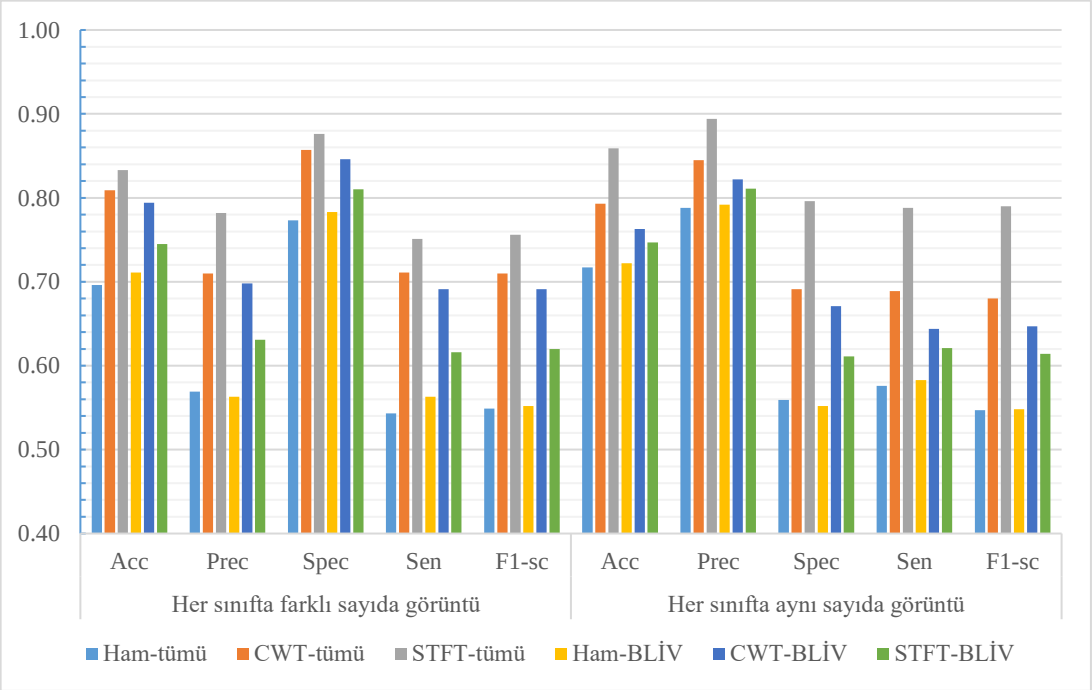
IMU bileşke lineer ivmelenme CNN modelinin test kümesi sınıflandırma performansları Tablo 4.2’de gösterilmiştir. Veri dağılımına göre her bir sınıfta aynı ve farklı sayıda görüntü veri setinin kullanıldığı ‘CWT-BLİV’ modelinde doğrulukların sırasıyla 0.763 ve 0.794 olduğu gözlenmiştir. Benzer şekilde ‘CWT-BLİV’ ve ‘STFT-BLİV’ modelleri sırasıyla VD’ye göre her bir sınıfta farklı sayıda görüntü veri setiyle özgüllükte 0.846 ve 0.810, VD’ye göre her bir sınıfta aynı sayıda görüntü veri setiyle duyarlılıkta 0.822 ve 0.811 değerleriyle insan yürüyüş hareketi en iyi sınıflandırma performansını göstermiştir. ‘Ham-IMU’ modeli ise VD’ye göre her bir sınıfta aynı sayıda görüntü veri setiyle F-skoru (0.548) ve kesinlik (0.583) ile en düşük sınıflandırma performansı göstermiştir.

Tablo 4.2: IMU-BLİV CNN modelleri test kümesi sınıflandırma performansları.

VD		Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F-skoru	Görüntü
Her bir sınıfta farklı sayıda görüntü	F	0.699	0.538	0.667	0.761	0.631	Ham-BLİV
	N	0.654	0.452	0.815	0.318	0.373	
	S	0.779	0.700	0.867	0.609	0.651	
	ORT	0.711	0.563	0.783	0.563	0.552	
	F	0.794	0.673	0.811	0.761	0.714	CWT-BLİV
	N	0.765	0.630	0.815	0.659	0.644	
	S	0.824	0.789	0.911	0.652	0.714	
	ORT	**0.794**	**0.698**	**0.846**	**0.691**	**0.691**	
	F	0.824	0.789	0.911	0.652	0.714	STFT-BLİV
	N	0.640	0.449	0.707	0.500	0.473	
	S	0.772	0.653	0.811	0.696	0.674	
	ORT	0.745	0.631	0.810	0.616	0.620	
Her bir sınıfta aynı sayıda görüntü	F	0.773	0.818	0.652	0.682	0.667	Ham-BLİV
	N	0.636	0.852	0.409	0.205	0.273	
	S	0.758	0.705	0.594	0.864	0.704	
	ORT	0.722	0.792	0.552	0.583	0.548	
	F	0.795	0.920	0.774	0.545	0.640	CWT-BLİV
	N	0.682	0.682	0.517	0.682	0.588	
	S	0.811	0.864	0.721	0.705	0.713	
	ORT	**0.763**	**0.822**	**0.671**	**0.644**	**0.647**	
	F	0.788	0.818	0.667	0.727	0.696	STFT-BLİV
	N	0.659	0.784	0.486	0.409	0.444	
	S	0.795	0.830	0.681	0.727	0.703	
	ORT	0.747	0.811	0.611	0.621	0.614	

Her bir sınıftaki veri dağılımının ve dijital sinyal işleme yöntemlerinin giyilebilir IMU sensör CNN modelleriyle insan yürüyüş tanımadaki performanslarını etkisini karşılaştırma amacıyla her bir CNN modelinin sınıflandırma performans ölçütleri Şekil 4.11’de görüldüğü gibi birbirinden bağımsız olarak ele alınmıştır. Bu performans ölçütleriyle ile ilgili olarak, ‘STFT-tümü’ ve ‘CWT-tümü’ modellerinin ‘Ham-tümü’ göre sınıflandırma başarısının daha yüksek

olduğu görülmüştür. En iyi sınıflandırma doğruluğuna sahip ‘STFT-tümü’ modelinin her bir sınıfta farklı sayıda ve aynı sayıda görüntü bulunmasına göre test doğrulukları sırasıyla 0.833 ve 0.859 olarak bulunmuştur. Her bir sınıfta farklı sayıda görüntü bulunan veri setiyle yüksek test sınıflandırma doğruluğuna sahip diğer iki model olan ‘CWT-tümü’ ve ‘CWT-BLİV’ modellerinin doğrulukları ise sırasıyla 0.809 ve 0.794’dir. Benzer şekilde her bir sınıfta farklı sayıda görüntü bulunan veri setinin kullanıldığı deneyin test kümesi özgüllükleri ise ‘STFT-tümü’, ‘CWT-tümü’ ve ‘CWT-BLİV’ modeli için sırasıyla 0.876, 0.857 ve 0.846 olup bu modeller özgüllüğü en yüksek üç CNN modeli olarak bulunmuştur.



Şekil 4.11: IMU CNN modellerinin karşılaştırmalı test sınıflandırma performansları.

Dijital sinyal işleme yöntemlerinin giyilebilir IMU sensör sinyallerini kullanarak insan yürüyüş tanımadaki performanslarını karşılaştırmak için her bir CNN modelinin sınıflandırma performans ölçütleri Şekil 4.11’de görüldüğü gibi birbirinden bağımsız olarak ele alınmıştır. Bu performans ölçütleriyle ile ilgili olarak, ‘STFT-tümü’ ve ‘CWT-tümü’ modellerinin ‘Ham-tümü’ göre sınıflandırma başarısının daha yüksek olduğu görülmüştür. En iyi sınıflandırma test doğruluğuna sahip model ‘STFT-tümü’ modeli (0.833) olarak bulunmuştur. Yüksek test sınıflandırma doğruluğuna sahip diğer iki model olan ‘CWT-tümü’ ve ‘CWT-BLİV’ için doğruluklar, sırasıyla 0.809 ve 0.794’dir. Test kümesi özgüllük açısından değerlendirildiğinde ise en yüksek üç CNN modelinin özgüllüğü ‘STFT-tümü’, ‘CWT-tümü’ ve ‘CWT-BLİV’ modeli için sırasıyla 0.876, 0.857 ve 0.846 olarak bulunmuştur.

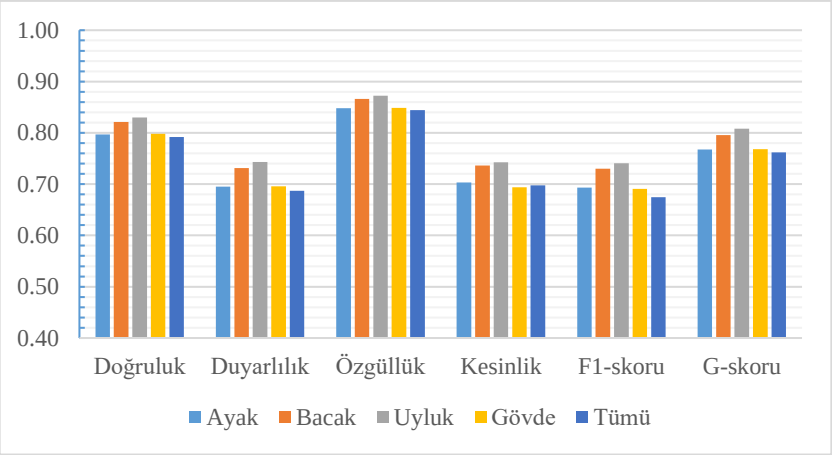
4.4. CNN TABANLI GİYİLEBİLİR BİYOMEKANİK SENSÖR VERİSİNİN STFT GÖRÜNTÜLERİNDEN İNSAN YÜRÜYÜŞÜ TANIMA

Bir önceki bölümde IMU kanallarının tamamının dahil edildiği STFT görüntü veri setleri ve CNN modeliyle insan yürüyüşü sınıflandırma performansının daha yüksek olduğu sonucuna varılmıştır. Bu bölümde ise yer seviyesindeki yürüme hareketine ait gonyometre (GON) ve ivmeölçer (IMU) sensör sinyalleri filtrelenmiş ve farklı zamansal uzunluklarda segmente edilerek yürüyüş hızlarına (WS) göre yavaş (S), normal (N) ve hızlı (F) olmak üzere CNN derin öğrenme modelleriyle otomatik olarak sınıflandırılmıştır. Farklı sinyal segmentasyon uzunlukları ve sensör kombinasyonlarının insan yürüyüşü tanımadaki CNN sınıflandırma performansı üzerine etkileri kapsamlı olarak incelenmiştir. Segmente edilen IMU ve GON sinyalleri, zaman-frekans analiziyle güç spektrumunu gösteren Kısa Zamanlı Fourier Dönüşümü (STFT) kullanılarak CNN girişine toplamda 670 görüntüden oluşan (F:223, N:220 ve S:227) görüntü veri setleri hazırlanmıştır. Ayrı ayrı IMU ve GON sensörleri tek girişli CNN derin öğrenme modeline uygulanmasının yanında her iki sensör parametrelerinin insan yürüyüş tanımadaki başarımını değerlendirmek amacıyla ayrıca iki girişli CNN modeli de geliştirilmiştir. Bu kısımda biyomekanik sinyallere uygulanan sinyal işleme yöntemlerinin ve geliştirilen CNN modelinin sınıflandırma performans ölçütleri karşılaştırılmalı olarak sunulmuştur.

4.4.1. Filtrelemenin IMU Sensör CNN Modeli Sınıflandırma Başarısına Etkisi

IMU sensör sinyal filtrelemenin CNN modeliyle insan yürüyüş hareketini sınıflandırma başarısına etkisi sensör bazında üç grup altında incelenmiştir, bunlar;

- Grup I: Segmente edilmemiş (sinyalin tamamının dahil edildiği)-filtrelenmemiş sinyal STFT görüntü veri setinin kullanıldığı CNN modeli,
- Grup II: Segmente edilmemiş (sinyalin tamamının dahil edildiği)-filtrelenmiş sinyal STFT görüntü veri setinin kullanıldığı CNN modeli,
- Grup III: 7 s uzunluğunda segmente edilmiş-filtrelenmiş sinyal STFT görüntü veri setinin kullanıldığı CNN modelidir.



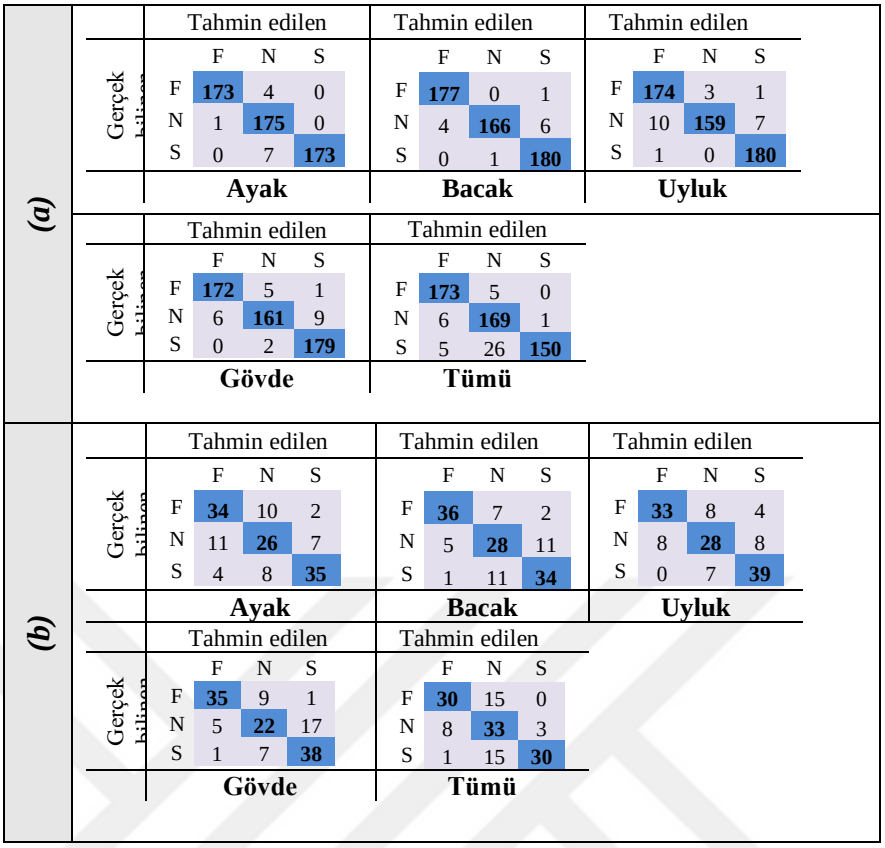
Şekil 4.12: Grup I test kümesi sınıflandırma performans ölçütleri.

Grup I CNN modelinin test kümesi sınıflandırma performansları Şekil 4.12'de gösterilmiştir. Özgüllük ve doğruluk ölçütlerinin her bir sensör türünde 0.80 civarı ve üzerinde olduğu gözlenmiştir. Benzer şekilde Tablo 4.3'te özgüllük (0.872±0.016) ve doğruluk (0.83±0.021) ile uyluk IMU sensörü, ardından özgüllük (0.866±0.01) ve doğruluk (0.821±0.013) ile bacak IMU sensörü insan yürüyüş hareketi en iyi sınıflandırma performansını göstermiştir. IMU sensör kanallarının tümünün dahil edildiği model ise özgüllük (0.844±0.02) ve doğruluk (0.844±0.02) ile en düşük sınıflandırma performansı göstermiştir.

Tablo 4.3: Grup I eğitim ve test kümesi sınıflandırma performans ölçütleri.

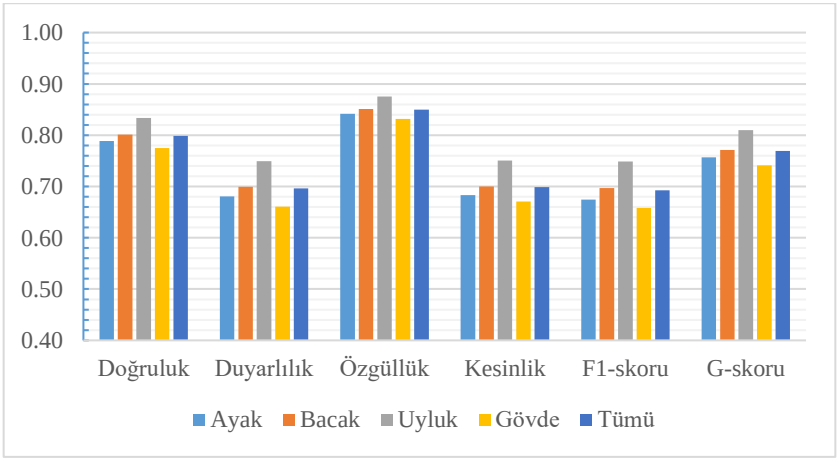
	(Ort±Std)	Ayak	Bacak	Uyluk	Gövde	Tümü
Eğitim	Acc	0.979±0.016	0.984±0.015	0.988±0.01	0.985±0.012	0.975±0.019
	Sens	0.968±0.023	0.976±0.022	0.982±0.015	0.977±0.019	0.962±0.028
	Spec	0.984±0.012	0.988±0.011	0.991±0.008	0.989±0.009	0.981±0.014
	Prec	0.969±0.022	0.977±0.022	0.982±0.015	0.978±0.019	0.965±0.025
	F1-sc	0.968±0.023	0.976±0.022	0.982±0.016	0.977±0.019	0.962±0.028
	G-sc	0.976±0.018	0.982±0.017	0.986±0.012	0.983±0.014	0.972±0.021
Test	Acc	0.797±0.015	0.821±0.013	**0.83±0.021**	0.798±0.038	0.792±0.026
	Sens	0.695±0.022	0.731±0.02	0.743±0.031	0.696±0.057	0.687±0.039
	Spec	0.848±0.011	0.866±0.01	**0.872±0.016**	0.849±0.029	0.844±0.02
	Prec	0.703±0.024	0.736±0.022	0.743±0.034	0.694±0.062	0.698±0.038
	F1-sc	0.693±0.023	0.73±0.02	0.741±0.032	0.691±0.06	0.674±0.056
	G-sc	0.768±0.017	0.796±0.016	0.808±0.024	0.768±0.044	0.762±0.031

Segmente edilmemiş ve filtrelenmemiş ham IMU sensör STFT görüntülerinin CNN modeline ait sınıflandırma eğitim ve test karışıklık matrisleri Şekil 4.13'te gösterilmiştir. IMU sensör türü açısından karşılaştırıldığında 'hızlı've 'yavaş' hız etiketleri için 'Tümü' STFT görüntü veri setinin, 'Uyluk' ve 'Bacak' STFT görüntü veri setlerine göre hem eğitim hem test kümesi karışıklık matrislerinde daha düşük TP değerine sahip olduğu gözlenmiştir.



Şekil 4.13: Grup I karışıklık matrisleri ***(a)*** Eğitim kümesi, ***(b)*** Test kümesi.

Şekil 4.14'te Grup II test sınıflandırma performans ölçütlerine yer verilmiştir. Test performans ölçütlerinden özgüllük ve doğruluk başta olmak üzere diğer tüm ölçütlerde bacak ve uyluk sensörlerinin başarımları ayak ve gövde sensörlerine kıyasla daha yüksek olduğu görülmüştür.



Şekil 4.14: Grup II test kümesi sınıflandırma performans ölçütleri.

Tablo 4.4'te Grup II eğitim kümesi performans ölçütleri, ayak sensörü hariç diğer sensörlerde birbirine oldukça yakın gözlemlenmiştir. Test kümesi sınıflandırma ölçütlerinden özgüllükte

'Uyluk', 'Bacak' ve 'Tümü' sırasıyla 0.875±0.018, 0.851±0.025 ve 0.849±0.022 değerlerini, doğrulukta ise 0.834±0.024, 0.801±0.033 ve 0.799±0.029 değerlerini alarak en yüksek sınıflandırma performansı gösteren üç sensör olmuştur.

Tablo 4.4: Grup II eğitim ve test kümesi sınıflandırma performans ölçütleri.

	(Ort±Std)	Ayak	Bacak	Uyluk	Gövde	Tümü
Eğitim	Acc	0.985±0.013	0.959±0.041	0.961±0.028	0.953±0.042	0.951±0.044
	Sens	0.977±0.021	0.938±0.062	0.94±0.043	0.93±0.063	0.927±0.066
	Spec	0.989±0.01	0.969±0.031	0.97±0.021	0.965±0.031	0.964±0.033
	Prec	0.978±0.018	0.939±0.063	0.945±0.035	0.938±0.049	0.929±0.064
	F1-sc	0.977±0.021	0.938±0.062	0.94±0.043	0.929±0.063	0.927±0.066
	G-sc	0.983±0.015	0.953±0.047	0.955±0.032	0.947±0.048	0.945±0.05
Test	Acc	0.788±0.02	0.801±0.033	**0.834±0.024**	0.775±0.049	0.799±0.029
	Sens	0.681±0.029	0.7±0.049	0.749±0.036	0.661±0.074	0.697±0.044
	Spec	0.842±0.015	0.851±0.025	**0.875±0.018**	0.831±0.037	0.849±0.022
	Prec	0.683±0.032	0.7±0.046	0.751±0.034	0.671±0.065	0.698±0.051
	F1-sc	0.675±0.038	0.697±0.048	0.749±0.035	0.658±0.074	0.692±0.044
	G-sc	0.757±0.023	0.771±0.038	0.81±0.027	0.741±0.058	0.769±0.034

Segmente edilmiş ve filtrelenmemiş ham IMU sensör STFT görüntülerinin CNN modeline ait sınıflandırma eğitim ve test karışıklık matrisleri Şekil 4.15'te gösterilmiştir. IMU sensör bazında karşılaştırıldığında 'hızlı've 'yavaş' hız etiketleri için 'Uyluk' ve 'Tümü' STFT görüntü veri setlerinin 'Ayak' ve 'Gövde' STFT görüntü veri setlerine göre test kümesi karışıklık matrislerinde daha yüksek TP değerine sahip olduğu gözlenmiştir.

(a)

Ayak — Tahmin edilen / Gerçek bilinen

	F	N	S
F	**184**	1	0
N	3	**174**	1
S	0	0	**184**

Bacak — Tahmin edilen / Gerçek bilinen

	F	N	S
F	**182**	2	0
N	0	**175**	2
S	0	5	**178**

Uyluk — Tahmin edilen / Gerçek bilinen

	F	N	S
F	**181**	2	0
N	0	**176**	0
S	0	1	**176**

Gövde — Tahmin edilen / Gerçek bilinen

	F	N	S
F	**180**	3	0
N	2	**174**	0
S	1	2	**180**

Tümü — Tahmin edilen / Gerçek bilinen

	F	N	S
F	**180**	2	2
N	7	**158**	11
S	0	0	**183**

(b)

Gerçek bilgisi \ Tahmin edilen	F	N	S
F	**31**	13	1
N	8	**29**	6
S	4	11	**30**

Ayak

Gerçek bilgisi \ Tahmin edilen	F	N	S
F	**33**	9	4
N	10	**28**	6
S	1	11	**34**

Bacak

Gerçek bilgisi \ Tahmin edilen	F	N	S
F	**37**	6	4
N	8	**29**	8
S	4	5	**37**

Uyluk

Gerçek bilgisi \ Tahmin edilen	F	N	S
F	**31**	14	2
N	10	**30**	5
S	4	9	**33**

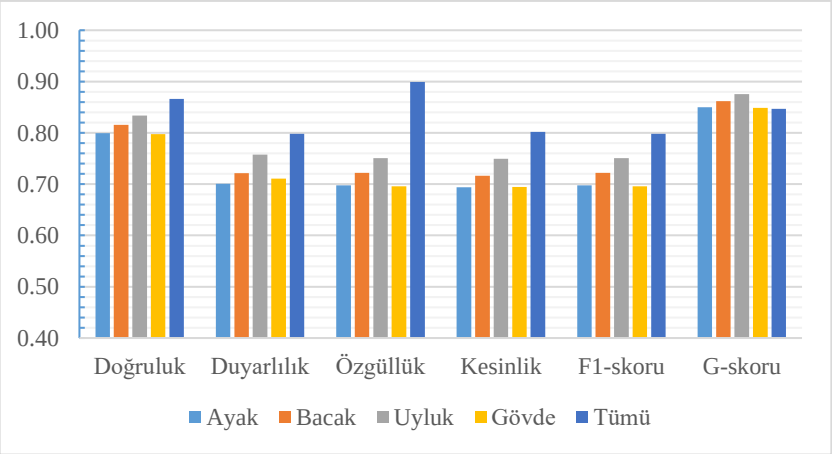
Gövde

Gerçek bilgisi \ Tahmin edilen	F	N	S
F	**33**	12	1
N	13	**22**	10
S	2	3	**41**

Tümü

Şekil 4.15: Grup II karışıklık matrisleri ***(a)*** Eğitim kümesi, ***(b)*** Test kümesi.

Şekil 4.16'da Grup III CNN modelinin test kümesi sınıflandırma performansları gösterilmiştir. Doğruluk ve G-skoru ölçütlerinin her bir sensör türünde 0.80 civarı ve üzerinde olduğu gözlenmiştir. Ayrıca test performans ölçütlerinden özgüllük ve doğruluk başta olmak üzere diğer tüm ölçütlerde 'Tümü' ve ''Uyluk' sensörlerinin başarımları 'Ayak' ve 'Gövde' sensörlerine kıyasla daha yüksek sınıflandırma performansı sağlamıştır.



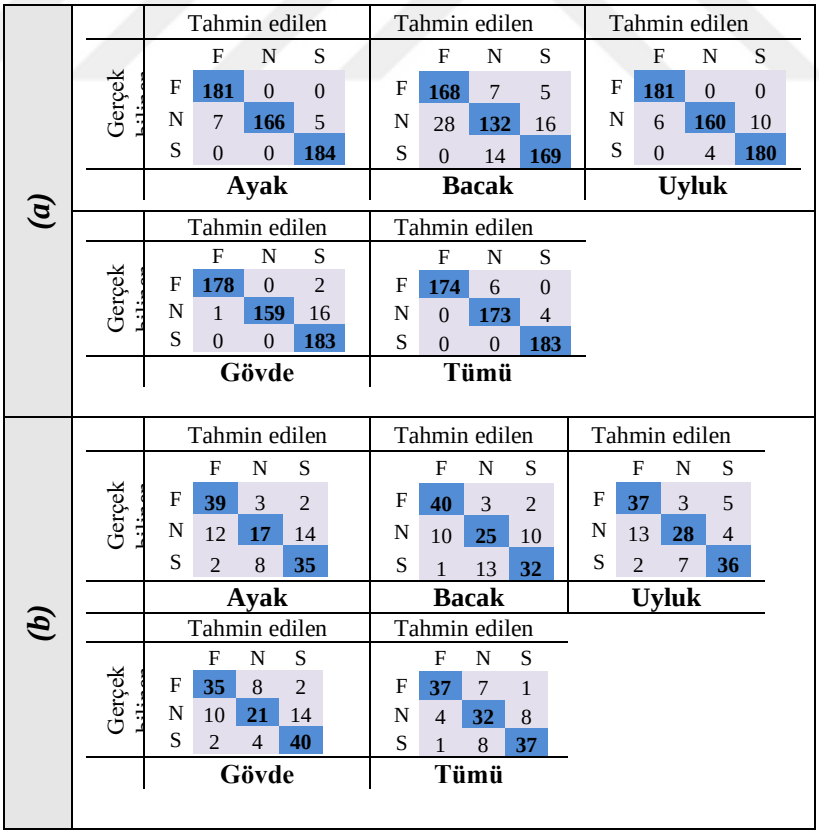
Şekil 4.16: Grup III test kümesi sınıflandırma performans ölçütleri.

Tablo 4.5'te listelenen her bir tekrardan elde edilen CNN sınıflandırma performans ölçütlerinin ortalaması ve standart sapmasına göre 'Uyluk' ve 'Tümü' sensörü insan yürüyüş hareketini tanımada daha yüksek hassasiyet gösterirken 'Ayak' ve 'Gövde' sensörü daha düşük hassasiyet göstermiştir. Yürüyüş hızı sınıf etiketleri bazında ortalama test doğrulukları karşılaştırıldığında 'Tümü' sensörü doğruluk (0.866±0.017) ve G-skoruyla (0.847±0.02) en yüksek 'Gövde' sensörü doğruluk (0.798±0.031) ve G-skoruyla (0.768±0.036) en düşük sınıflandırma performasına ulaşılmıştır.

Tablo 4.5: Grup III eğitim ve test kümesi sınıflandırma performans ölçütleri.

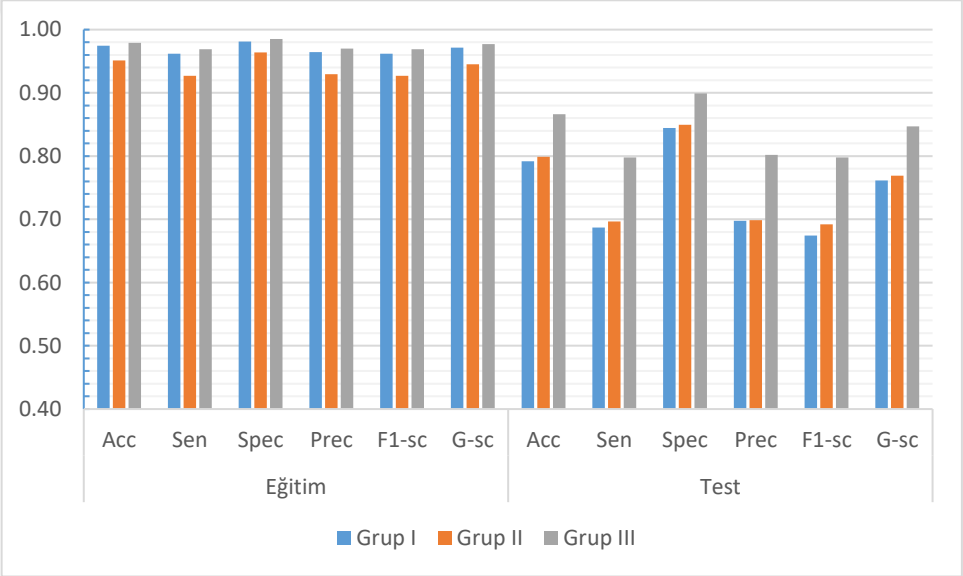
	(Ort±Std)	Ayak	Bacak	Uyluk	Gövde	Tümü
Eğitim	Acc	0.985±0.004	0.946±0.036	0.989±0.011	0.957±0.041	0.979±0.019
	Sens	0.978±0.005	0.918±0.054	0.984±0.016	0.936±0.061	0.969±0.029
	Spec	0.989±0.003	0.959±0.027	0.992±0.008	0.968±0.03	0.985±0.014
	Prec	0.979±0.005	0.922±0.051	0.984±0.016	0.941±0.055	0.97±0.029
	F1-sc	0.978±0.005	0.918±0.054	0.984±0.016	0.936±0.061	0.969±0.029
	G-sc	0.984±0.004	0.939±0.041	0.988±0.012	0.952±0.046	0.977±0.022
Test	Acc	0.799±0.023	0.816±0.02	0.834±0.007	0.798±0.031	0.866±0.017
	Sens	0.698±0.034	0.722±0.031	0.75±0.011	0.696±0.046	0.798±0.026
	Spec	0.85±0.017	0.862±0.015	0.876±0.006	0.848±0.023	0.899±0.013
	Prec	0.701±0.033	0.721±0.038	0.758±0.025	0.711±0.042	0.802±0.026
	F1-sc	0.694±0.031	0.716±0.035	0.75±0.013	0.695±0.043	0.798±0.024
	G-sc	0.77±0.027	0.789±0.024	0.811±0.009	0.768±0.036	0.847±0.02

7 s uzunluğunda segmente edilmiş ve filtrelenmiş IMU sensör STFT görüntülerinin CNN modeline ait sınıflandırma eğitim ve test karışıklık matrisleri Şekil 4.17'de gösterilmiştir. IMU sensör bazında karşılaştırıldığında 'hızlı', 'normal' ve 'yavaş' hız etiketlerinin her üçü için 'Tümü' STFT görüntü veri setlerinin diğer veri setlerine göre test kümesi karışıklık matrislerinde daha yüksek TP değerine sahip olduğu gözlenmiştir.



Şekil 4.17: Grup III karışıklık matrisleri ***(a)*** Eğitim kümesi, ***(b)*** Test kümesi.

Şekil 4.18'de IMU sensör kanallarının tamamının dahil edildiği STFT görüntü veri setlerine ait her bir grubun 'Tümü' CNN modeli sınıflandırma performansları gösterilmiştir. Grup I ve Grup II eğitim setinde 0.30 civarı bir fark olmasına rağmen test setinde anlamlı bir fark gözlemlenmemiştir. Sinyalin tamamının işleme dahil edildiği bu gruplarda filtrelemenin anlamlı bir etkisi görülmemiştir. Veri setindeki tüm verileri kapsayan en küçük aralık olan 7 s zaman aralığında segmente edildiği durumu belirten Grup III ile tüm durumlar birlikte değerlendirildiğinde segmentasyonun test seti sınıflandırma performansını önemli ölçüde artırdığı gözlemlenmiştir. Son olarak filtrelemenin ve IMU sensör seçiminin CNN sınıflandırma performansına etkisi değerlendirildiğinde tüm sensör kanallarının dahil edildiği konfigürasyonun ve sinyali filtrelemenin sınıflandırma performansı iyileştirdiği sonucuna varılmıştır.



Şekil 4.18: Filtrelemenin CNN sınıflandırma performansına etkisi.

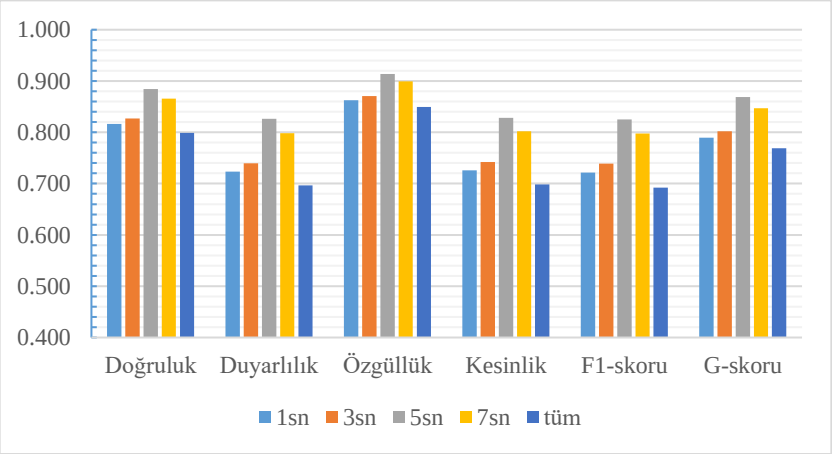
4.4.2. Segmentasyonun Giyilebilir Sensör CNN Modeli Sınıflandırma Başarısına Etkisi

Bu bölümde sinyal segmentasyonun sınıflandırma performansına etkisini gözlemlemek amacıyla farklı segmentasyon sürelerindeki giyilebilir IMU ve GON sensör sinyalleri tek ve çok girişli CNN modellerinde test edilmiştir. Sinyal segmentasyonun insan yürüyüş hareketini tanıma başarısına etkisi sensör bazında üç grup altında incelenmiştir, bunlar;

- Grup IV: IMU sensör sinyali STFT görüntü veri setinin kullanıldığı tek girişli CNN modeli,

- Grup V: GON sensör sinyali STFT görüntü veri setinin kullanıldığı tek girişli CNN modeli,

- Grup VI: IMU sensör ve GON sinyali STFT görüntü veri setinin kullanıldığı iki girişli tek çıkışlı CNN modelidir.



Şekil 4.19: Grup IV test kümesi sınıflandırma performans ölçütleri.

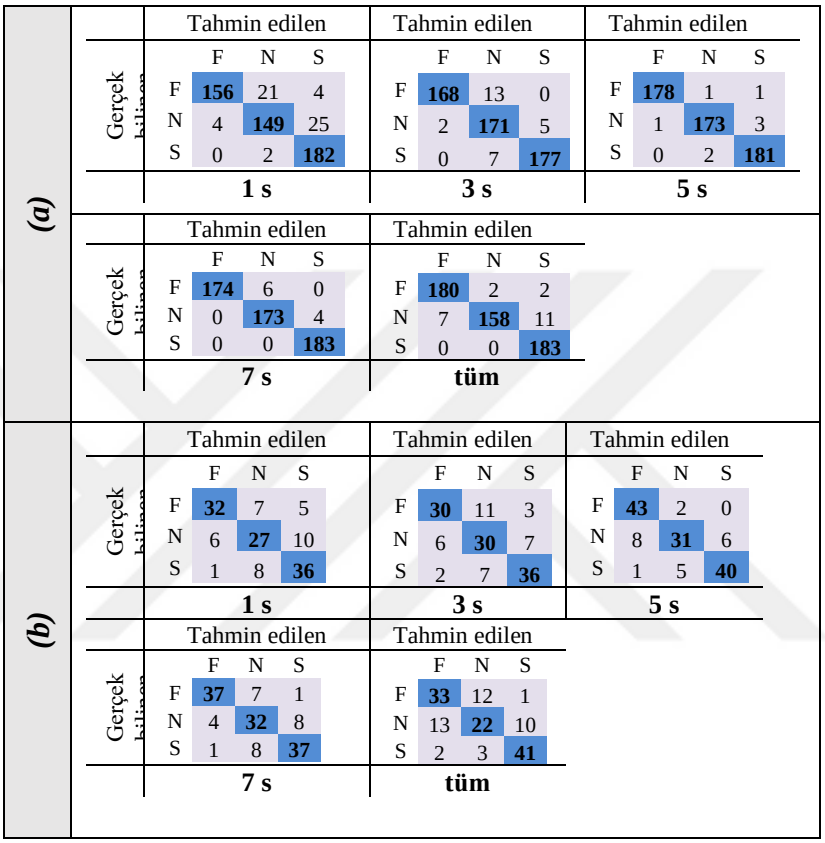
Şekil 4.19'da Grup IV test kümesi sınıflandırma performans ölçütlerine yer verilmiştir. Buna göre, özgüllük ve doğruluk başta olmak üzere tüm performans ölçütlerinde, '5 s' segmentasyon süresinde diğer segmentasyon sürelerine kıyasla daha yüksek olduğu görülmüştür. Bununla birlikte test kümesinde en düşük sınıflandırma performansına, 'tüm' yani herhangi bir sinyal segmentasyon işleminin uygulanmadığı durumda ulaşılmıştır.

Tablo 4.6: Grup IV eğitim ve test kümesi sınıflandırma performans ölçütleri.

	(Ort±Std)	1 s	3 s	5 s	7 s	tüm
Eğitim	Acc	0.963±0.021	0.963±0.03	0.985±0.008	0.979±0.021	0.951±0.044
	Sens	0.944±0.031	0.944±0.045	0.978±0.012	0.969±0.032	0.927±0.066
	Spec	0.972±0.016	0.972±0.022	0.989±0.006	0.985±0.016	0.964±0.033
	Prec	0.947±0.029	0.946±0.044	0.979±0.011	0.97±0.032	0.929±0.064
	F1-sc	0.944±0.031	0.944±0.045	0.978±0.012	0.969±0.032	0.927±0.066
	G-sc	0.958±0.024	0.958±0.034	0.984±0.009	0.977±0.024	0.945±0.05
Test	Acc	0.816±0.008	0.827±0.015	0.885±0.025	0.866±0.019	0.799±0.029
	Sens	0.723±0.014	0.739±0.022	0.826±0.038	0.798±0.029	0.697±0.044
	Spec	0.862±0.006	0.871±0.011	0.913±0.019	0.899±0.014	0.849±0.022
	Prec	0.726±0.02	0.742±0.02	0.828±0.037	0.802±0.029	0.698±0.051
	F1-sc	0.722±0.017	0.739±0.021	0.825±0.038	0.798±0.027	0.692±0.044
	G-sc	0.79±0.01	0.802±0.017	0.869±0.029	0.847±0.022	0.769±0.034

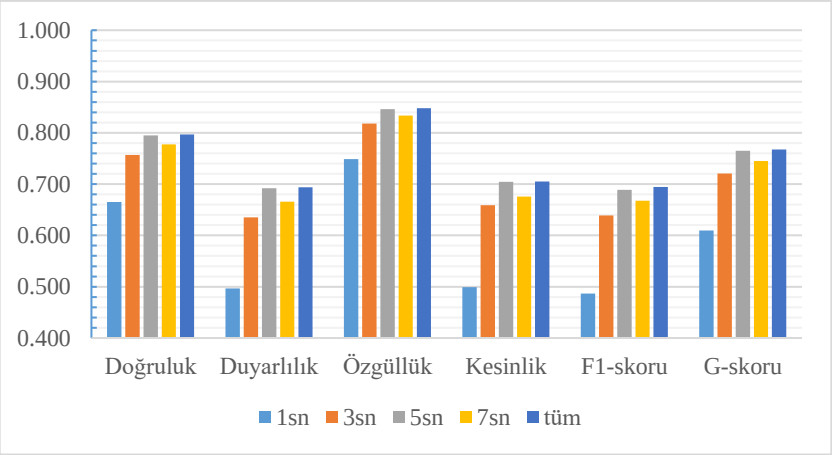
Grup IV CNN modelinin eğitim ve test kümesi sınıflandırma performans ölçütlerinin ortalaması ve standart sapması Tablo 4.6'da sunulmuştur. Buna göre test sınıflandırma performansları

karşılaştırıldığında ‘5 s’ segmentasyon süresi, insan yürüyüş hareketini tanımada 0.913±0.019 ile daha yüksek özgüllük gösterirken ‘tüm’ yani segmantasyon uygulanmaması durumu için özgüllük 0.849±0.022 ile en düşüktür. Sınıf bazında test kümesi F1-skoru makro ortalamaları karşılaştırıldığında bu değerlerden en yükseği 0.825±0.038 ile ‘5 s’ CNN modeli iken en düşüğü 0.692±0.044 ile ‘tüm’ CNN modelidir.



Şekil 4.20: Grup IV karışıklık matrisleri ***(a)*** Eğitim kümesi, ***(b)*** Test kümesi.

Şekil 4.20’deki Grup IV test kümesi karışıklık matrisleri incelendiğinde sınıf etiketleri bazında ‘5 s’ ve ‘7 s’ segmentasyon süreleri en yüksek doğru tahmin edilen değere sahipken, ‘1 s’ ve ‘tüm’ segmentasyon süreleri en düşük doğru tahmin edilen değere sahiptir.



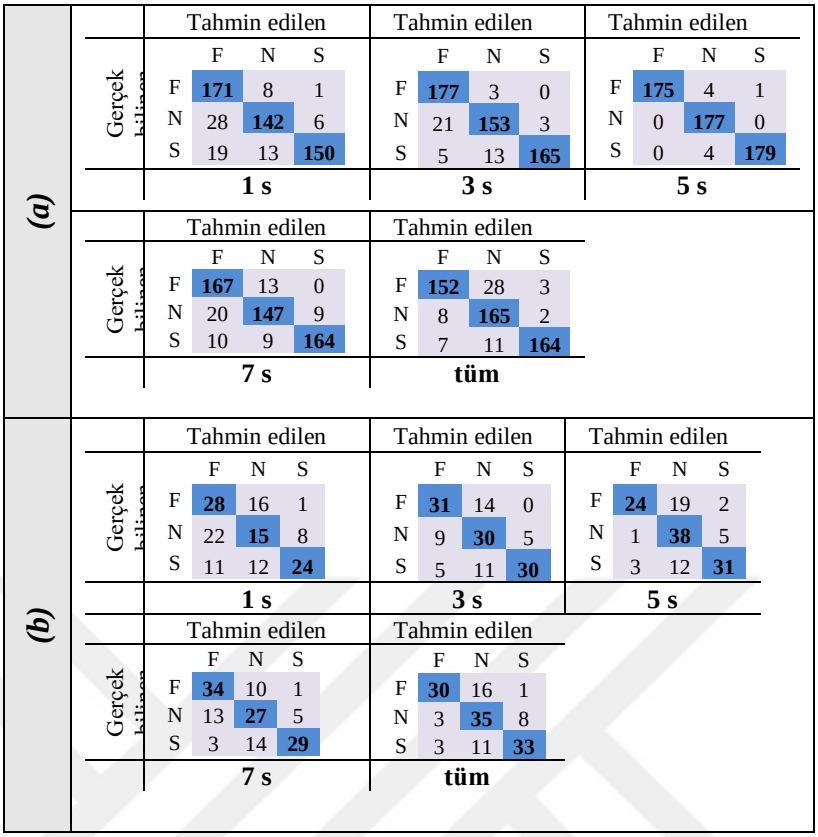
Şekil 4.21: Grup V test kümesi sınıflandırma performans ölçütleri.

Grup V eğitim ve test kümesi sınıflandırma performans ölçütlerine Şekil 4.21'de yer verilmiştir. Eğitim kümesi performans ölçütleri, '5 s' ve 'tüm' segmentasyon sürelerinde birbirine oldukça yakın ve en yüksek değer olarak gözlemlenmiştir. Benzer şekilde test kümesi performans ölçütlerinin de '5 s' ve 'tüm' segmentasyon sürelerinde en yüksek olduğu, '1 s' segmentasyon süresinde ise en düşük olduğu görülmüştür. Eğitim ve test kümelerinin her ikisinde de en düşük sınıflandırma performansı, '1 s' segmentasyon süresinde gözlemlenmiştir.

Tablo 4.7: Grup V eğitim ve test kümesi sınıflandırma performans ölçütleri.

	(Ort±Std)	1 s	3 s	5 s	7 s	tüm
Eğitim	Acc	0.855±0.061	0.954±0.034	0.971±0.025	0.95±0.045	0.959±0.034
	Sens	0.782±0.092	0.931±0.05	0.957±0.038	0.925±0.067	0.939±0.05
	Spec	0.891±0.046	0.965±0.025	0.978±0.019	0.963±0.033	0.97±0.025
	Prec	0.795±0.085	0.936±0.044	0.958±0.036	0.928±0.061	0.943±0.046
	F1-sc	0.779±0.095	0.93±0.051	0.956±0.037	0.925±0.067	0.939±0.05
	G-sc	0.834±0.07	0.948±0.038	0.967±0.028	0.943±0.051	0.954±0.038
Test	Acc	0.665±0.022	0.757±0.048	0.795±0.018	0.778±0.018	0.797±0.017
	Sens	0.496±0.032	0.635±0.072	0.692±0.027	0.666±0.027	0.694±0.027
	Spec	0.749±0.016	0.818±0.036	0.846±0.014	0.834±0.013	0.848±0.013
	Prec	0.499±0.034	0.659±0.061	0.704±0.037	0.676±0.027	0.705±0.03
	F1-sc	0.486±0.036	0.639±0.072	0.689±0.031	0.668±0.025	0.695±0.029
	G-sc	0.61±0.026	0.72±0.057	0.765±0.021	0.745±0.021	0.767±0.021

Tablo 4.7'de listelenen her bir tekrardan elde edilen CNN sınıflandırma performans ölçütlerinin ortalaması ve standart sapmasına göre, Grup V CNN eğitim ve test kümesi sınıflandırma performansları karşılaştırıldığında 'tüm' segmentasyon süresinin insan yürüyüş hareketini tanımada daha yüksek özgüllük (0.848±0.013) ve doğruluk (0.795±0.017) gösterdiği, '1 s' segmentasyon süresininse daha düşük özgüllük (0.749±0.016) ve doğruluk (0.665±0.022) gösterdiği gözlemlenmiştir.

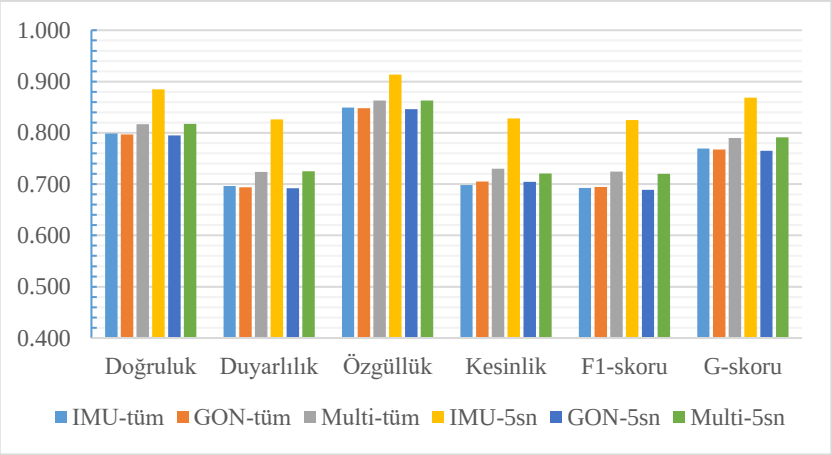


Şekil 4.22: Grup V karışıklık matrisleri ***(a)*** Eğitim kümesi, ***(b)*** Test kümesi.

Şekil 4.22'de Grup V eğitim ve test kümesi karışıklık matrisleri sınıf etiketleri bazında incelendiğinde '5 s' ve 'tüm' segmentasyon süreleri en yüksek doğru tahmin edilen değere, '1 s' segmentasyon süresi ise en düşük doğru tahmin edilen değere ulaşmıştır.

4.4.3. İki Girişli Tek Çıkışlı Giyilebilir Sensör CNN Modelinin Sınıflandırma Başarısına Etkisi

Grup VI seti, giyilebilir IMU ve GON sensörlerinin 'tüm' ve '5 s' segmentasyon sürelerinde tek girişli ve iki girişli (multi) CNN modeline uygulanmasıyla elde edilmiştir. Şekil 4.23'te test kümesi sınıflandırma performans ölçütlerine yer verilmiştir. Test kümesi sınıflandırma performans ölçütlerinin tamamında 'IMU-5s' CNN modeli en yüksek değere ulaşırken, 'IMU-tüm', 'GON-tüm' ve 'GON-5s' CNN modelleri düşük sınıflandırma performansı göstermiştir.



Şekil 4.23: Grup VI test kümesi sınıflandırma performans ölçütleri.

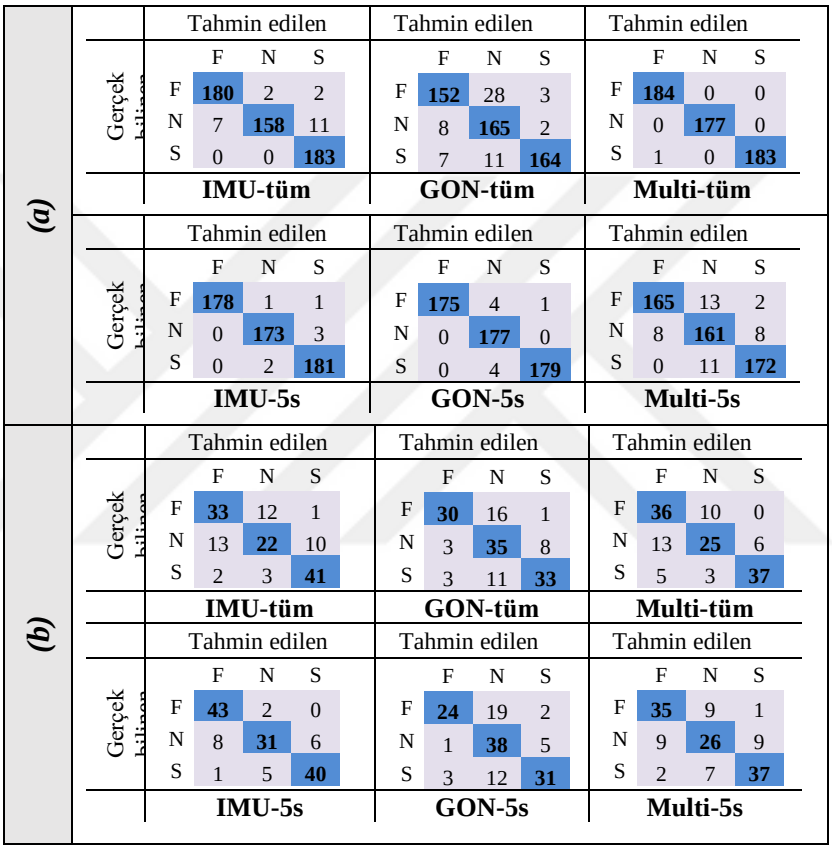
Her bir tekrardan elde edilen Grup VI CNN sınıflandırma performans ölçütlerinin ortalaması ve standart sapması Tablo 4.8'de sunulmuştur. Buna göre eğitim kümesi sınıflandırma ölçütlerinden özgüllük (0.989±0.006) ve doğruluk (0.985±0.008) ile 'IMU-5s' modeli en yüksek, özgüllük (0.964±0.033) ve doğruluk (0.951±0.044) ile 'IMU-tüm' modeli en düşük yürüyüş hareketi sınıflandırma performansını göstermiştir. Test kümesi sınıflandırma performansları karşılaştırıldığında ise 'IMU-5s' modeli özgüllük (0.913±0.019) ve doğruluk (0.885±0.025) ile en yüksek, 'GON-tüm' modeli özgüllük (0.848±0.013) ve doğruluk (0.797±0.017) ile en düşük yürüyüş örüntüsü sınıflandırma performansına sahip olduğuna ulaşılmıştır. İki girişli CNN modellerinden 'Multi-tüm' ve 'Multi-5s' modellerinin eğitim ve test kümesi sınıflandırma performansları birbirine yakın olup test kümesi özgüllük değerleri sırasıyla 0.863±0.008 ve 0.863±0.019'dir.

Tablo 4.8: Grup VI eğitim ve test kümesi sınıflandırma performans ölçütleri.

	(Ort±Std)	IMU-tüm	GON-tüm	Multi-tüm	IMU-5s	GON-5s	Multi-5s
Eğitim	Acc	0.951±0.044	0.959±0.034	0.986±0.02	0.985±0.008	0.971±0.025	0.968±0.02
	Sens	0.927±0.066	0.939±0.05	0.978±0.031	0.978±0.012	0.957±0.038	0.952±0.03
	Spec	0.964±0.033	0.97±0.025	0.989±0.015	0.989±0.006	0.978±0.019	0.976±0.015
	Prec	0.929±0.064	0.943±0.046	0.978±0.031	0.979±0.011	0.958±0.036	0.954±0.029
	F1-sc	0.927±0.066	0.939±0.05	0.978±0.031	0.978±0.012	0.956±0.037	0.952±0.03
	G-sc	0.945±0.05	0.954±0.038	0.984±0.023	0.984±0.009	0.967±0.028	0.964±0.022
Test	Acc	0.799±0.029	0.797±0.017	**0.817±0.011**	**0.885±0.025**	0.795±0.018	**0.817±0.025**
	Sens	0.697±0.044	0.694±0.027	0.724±0.017	0.826±0.038	0.692±0.027	0.725±0.037
	Spec	0.849±0.022	0.848±0.013	**0.863±0.008**	**0.913±0.019**	0.846±0.014	**0.863±0.019**
	Prec	0.698±0.051	0.705±0.03	0.73±0.016	0.828±0.037	0.704±0.037	0.721±0.039
	F1-sc	0.692±0.044	0.695±0.029	0.725±0.017	0.825±0.038	0.689±0.031	0.72±0.039
	G-sc	0.769±0.034	0.767±0.021	0.79±0.013	0.869±0.029	0.765±0.021	0.791±0.029

Şekil 4.24'deki Grup VI eğitim ve test kümesi karışıklık matrisleri incelendiğinde hem eğitim hem de test kümesinde 'Multi-tüm', 'IMU-5s' ve 'GON-5s' modellerinin en yüksek doğru

tahmin edilen değere, ‘IMU-tüm’ ve ‘GON-tüm’ modellerinin ise en düşük doğru tahmin edilen değere sahip olduğu gözlenmiştir.



Şekil 4.24: Grup VI karışıklık matrisleri ***(a)*** Eğitim kümesi, ***(b)*** Test kümesi.

İnsan alt ekstremite biyomekanik giyilebilir IMU ve gonyometre sensör sinyallerinden STFT görüntüleri elde edilerek CNN derin öğrenme modeli girişine uygulandığı bu çalışmada sensör konfigürasyonunun, filtreleme ve segmentasyon gibi sinyal ön işleme adımlarının sınıflandırma performansına etkisi değerlendirilmiştir. Filtrelemenin CNN sınıflandırma performansına etkisi IMU sensör ‘Uyluk’ ve ‘tümü’ sensör modellerinde belirgin olarak gözlenmiştir. İkinci olarak tüm sensör kanalları dahil edilmiş, IMU ve GON sensörlerinin farklı segmentasyon sürelerinde sınıflandırma performansına etkisi ‘IMU-5s’ tek girişli CNN modelinde en yüksek olarak bulunmuştur. Son olarak IMU ve GON sensör STFT görüntülerinin birlikte giriş olarak

kullanıldığı iki girişli CNN modellerinin sınıflandırma performansının ‘IMU-5s’ sınıflandırma performansına yakın olduğuna ulaşılmıştır.

5. TARTIŞMA

Bu çalışma, insan yer seviyesi yürüyüş hareketini tanıma hakkında bilgi sağlamak amacıyla giyilebilir biyomekanik sensör verilerinden yararlanılarak makine öğrenmesi ve derin öğrenme modellerinin geliştirilmesini kapsamaktadır. Sensör yerleşimleri, öznitelik çıkarma, sinyal işleme ve model oluşturma adımlarını içeren önerilen yöntem, insan yürüme hızı tahmini probleminde daha önceki çalışmalara göre benzer sınıflandırma performansı göstermiştir. Bu önerilen sistem, yürüme biyomekaniğinde sensör yerleşimiyle seçiminin önemini ve farklılıklarını daha sonraki araştırmacılara göstermeye yönelik önemli bilgiler sağlamaktadır.

Makine öğrenmesi yaklaşımıyla insan yürüyüş tanıma performansını değerlendirmek amacıyla birden fazla giyilebilir biyomekanik sensörün dahil edildiği modeller tek sensörlü modellerle kıyaslanmış, bu modellerin karışıklık matrisleri ve AUC-ROC puanları üç farklı sınıflandırıcıdan faydalanılarak karşılaştırılmıştır. Farklı kayan pencere uzunluklarının sınıflandırma performansı üzerindeki etkisinin gözlemlenmesinde başlangıçta IMU ve GON sensör modellerinin 0.5s, 1s, 1.25s, 2.5s ve 5s zaman aralıklarında deneyler yapılmıştır. 5s zaman aralığındaki kayan pencere uzunluğunun insan hareket tanımada yüksek performans gösterdiği bu deneysel sonuçların sınıflandırma doğrulukları ve AUC-ROC puanları Şekil 4.1'te, karışıklık matrisleri Şekil 4.2 ve Şekil 4.3'te gösterilmektedir. Daha sonra 5s zaman aralığında kayan pencere uzunluğu EMG sensör modeline uygulanarak çalışmaya dahil edilmiş ve böylece giyilebilir sensör modellerinin tekli ve çoklu sınıflandırma performansları üç farklı sınıflandırıcıyla analiz edilmiştir. EMG ve çoklu giyilebilir sensör modellerinin sınıflandırma doğrulukları ve AUC-ROC puanları Şekil 4.4'te, karışıklık matrisleri ise Şekil 4.5'te verilmiştir.

1000 (5s) pencere uzunluğuna sahip IMU tabanlı sensör modeli, önerilen yönteme dayalı olarak farklı yürüme hızlarında insan yürüyüşünü sınıflandırmada, en yüksek 0.954 sınıflandırma doğruluğuna sahiptir. Şekil 4.1(a) ve Şekil 4.1(c)'de gösterildiği gibi, farklı kayan pencere uzunlukları kullanan makine öğrenmesi modelleri arasında, tüm giyilebilir sensörler için 1000 (5s) kayan pencere uzunluğuna sahip IMU tabanlı sensör modeli en yüksek sınıflandırma doğruluğuna sahipken, 100 (0.5s) pencere uzunluğuna sahip GON tabanlı sensör modeli en düşük sınıflandırma doğruluğuna sahiptir. Pencere uzunluğu 1000 (5s) olan GON tabanlı sensör modelleriyle IMU tabanlı sensörün pencere uzunluğu 200 (1s) olan modelleri

karşılaştırıldığında, bu modellerin sınıflandırma doğruluğunun birbirine yakın olduğu görülmüştür. IMU sensörleri, kısa pencere uzunluklarında bile GON sensörlerine kıyasla hassas sınıflandırma performansı göstermiştir. Bu nedenle, daha sonraki insan alt ekstremite hareket örüntü tanıma çalışmalarında IMU sensörleri rahatlıkla tercih edilebilir.

Kayan zaman penceresi yöntemi, insan etkinliği tanımada yaygın olarak uygulanmaktadır. Ma ve ark., tekerlekli sandalye kullanıcılarının günlük aktivitelerini tanımada sabit ya da uyarlanabilir kayan zaman penceresi yaklaşımlarıyla 10 kat çapraz doğrulama kullanarak DT ve KNN sınıflandırıcılarını uygulamıştır. Sabit duruş aktiviteleri sadece sabit bir zaman penceresi ile iyi sonuçlar üretebilirken sabit duruş ve geçiş aktivitelerinin uyarlanabilir bir kayan pencere uygulandığında daha etkili bir şekilde tanındığı ortaya çıkmıştır. Hem uyarlanabilir hem de sabit pencere yaklaşımlarının, düz zeminde postüral aktiviteleri tanımada 0.90 doğruluk oranına sahip olduğu gösterilmiştir [32]. Noor ve ark., tek bir ivmeölçer kullanmaya dayalı olarak insan etkinliği tanıma için yeni bir ayarlanabilir kayan pencere yaklaşımı geliştirmiştir. Bu yaklaşımda pencere boyutu, aktivite sinyali analizine dayalı olarak sürekli olarak değerlendirilmektedir. Önerdikleri ayarlanabilir kayan pencere yaklaşımı, sabit pencere kullanan mevcut yaklaşımlarla karşılaştırıldığında, ayarlanabilir kayan pencere yaklaşımının testlerde 0.954 doğruluk oranına ulaştığını ortaya koymuştur [35].

İnsan yürüyüşü tanımada 5 s kayan pencere uzunluğundaki tekli ve çoklu giyilebilir sensör modellerinin makine öğrenmesi sınıflandırma doğrulukları karşılaştırmalı olarak Tablo 5.1'de gösterilmektedir. Bu tablodan yedi sensör modeli için sınıflandırıcıların farklı sınıflandırma doğruluğuna sahip olduğu görülmektedir. QSVM, yürüyüş tanımada WNN ve ESKNN sınıflandırıcılarına kıyasla daha yüksek doğruluğa sahiptir. Özellikle, çoklu IMU ve GON sensör modeli ve QSVM sınıflandırıcısıyla yapılan deneydeki doğruluk (0.961), diğer sensör modelleri ve sınıflandırıcıları arasında en yüksek olanıdır. Tekli sensör modelleri ve QSVM sınıflandırıcısıyla yürüyüş tanıma performansları karşılaştırıldığında, doğruluklar sırasıyla IMU (0.954), GON (0.827) ve EMG (0.735) sensör modelleri olarak bulunmuştur. Daha sonra ikili sensör modellerinde en yüksek doğruluk sırasıyla IMU-GON (0.961), IMU-EMG (0.895) ve GON-EMG (0.776) sensör modellerinde elde edilmiştir. Son olarak üç sensörün de yer aldığı IMU-GON-EMG modelinin doğruluğu 0.919'dur. Bu çalışmanın bulguları, IMU sensör modellerinin düz yer seviyesi yürüyüş örüntüsü tanımadaki performansını iyileştirdiğini ve GON sensör modelleriyle birlikte kullanılmasının bu performansa olumlu katkı sağladığını

göstermiştir. EMG sensör modellerinin, IMU sensör modellerine göre daha düşük sınıflandırma performansı gösterdiği tespit edilmiştir.

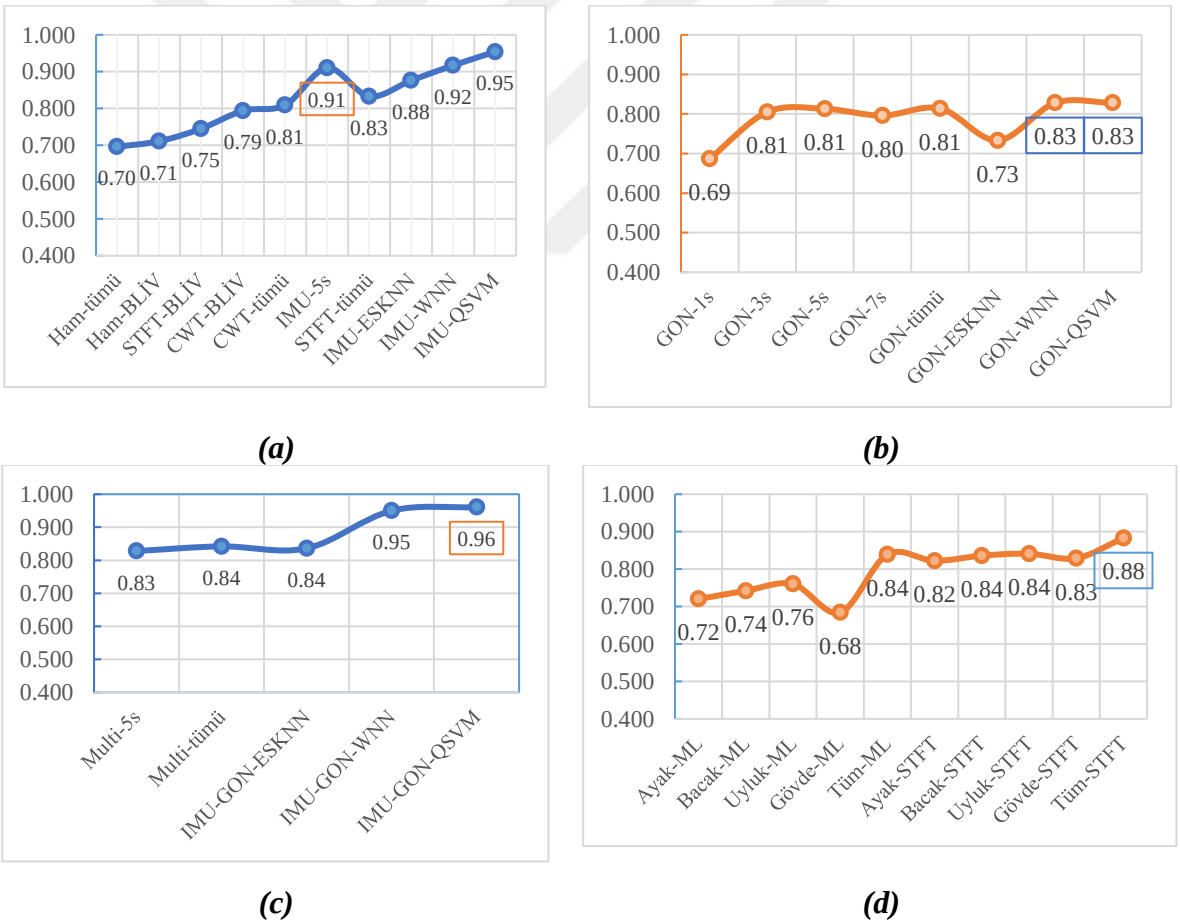
Tablo 5.1: Tekli ve çoklu sensör ML model doğruluklarının karşılaştırılması.

Sensör modeli	Makine Öğrenmesi Modeli		
	ESKNN	QSVM	WNN
IMU	0.876	0.954	0.917
GON	0.773	0.827	0.828
EMG	0.548	0.735	0.695
IMU-GON	0.836	0.961	0.95
IMU-EMG	0.853	0.895	0.868
GON-EMG	0.776	0.776	0.746
IMU-GON-EMG	0.833	0.919	0.892

Önerilen yöntemin ikinci bölümde bahsedilen insan yürüyüş örüntüsü tanıma çalışmalarıyla kabaca karşılaştırılabilir sonuçlar verdiği, çoklu giyilebilir sensör modelleri ve sadece IMU sensöründen faydanılan modelle karşılaştırıldığında görülmektedir. Dong ve ark., yürüyüş fazı ve örüntüsü tanımada SVM, ANN, AlexNet ve LeNet5 olarak dört algoritmanın performansını değerlendirmiştir. Deneysel sonuçlarında, EMG ve IMU sinyalini birlikte kullanan modelle, dört algoritmanın yürüyüş fazları için 0.977'lik bir tanıma doğruluğu ve yürüyüş örüntüleri için 0.992'nin üzerinde bir ortalama tanıma doğruluğu elde edebildiğini göstermiştir. SVM algoritmasıyla sadece IMU sensörü kullandıkları modelde yürüyüş fazları ve yürüyüş örüntüsü için sırasıyla 0.941 ve 0.987 doğruluğa ulaşılmıştır [106]. Çalışmada kullandığımız aynı veri seti ile Camargo ve ark., EMG, GON ve IMU verilerini içeren veri setini kullanarak yer seviyesi yürüyüşünde hız tahmini gerçekleştirmiştir. Tek bir IMU ile bile, yürüyüş hız tahmininde bir EMG veya GON sensörü yerine yalnızca bir IMU sensörü kullanmanın model hatasını azalttığı gösterilmiştir. Yürüyüş hızı tahmininde ise makine öğrenmesi sınıflandırıcılarından SVM modellerinin en düşük sınıflandırma hata oranına sahip olduğunu ortaya çıkarmıştır. Ek olarak, çalışmalarında çeşitli yürüme alanı koşulları için hangi sensör tipinin önemli olduğunu vurgulamış, IMU ve GON gibi biyomekanik sensörlerin, düz zeminde yürüme hızını tahmin etmede EMG sensörlerine göre sınıflandırma için daha önemli olduğunu fakat EMG'nin kaldırılması durumunun sınıflandırma hatasında artışa neden olduğunu göstermiştir [95].

Bu sonuçlar, yürüme hızının, önerilen kayan zaman penceresi yöntemi ve farklı makine öğrenimi sınıflandırıcılarıyla birlikte genişletilebilen biyomekanik gösterge olarak olası kullanımına işaret etmektedir. Bu çalışmadaki yürüyüş tanıma yaklaşımları, biyomekanik

sensör modellerinin tekli kullanımının yanı sıra farklı sensör modellerinin çoklu kullanımını içermektedir. Şekil 5.1 (a) ve Şekil 5.1 (c)'de, insan yürüyüş tanımada QSVM sınıflandırıcıyla tekli IMU sensör modeli ve IMU-GON sensör modeli en yüksek sınıflandırma doğruluğunun sırasıyla 0.954 ve 0.961 olduğunu göstermektedir. Sadece GON sensörlerinin kullanıldığı derin öğrenme ve makine öğrenmesi modellerinin doğruluklarına Şekil 5.1 (b)'de yer verilmiş olup 0.83 olan en yüksek doğruluğa WNN ve QSVM sınıflandırıcılarıyla ulaşılmıştır. Ayrıca yürüyüş örüntüsü tanımada, ESKNN sınıflandırıcısıyla EMG sensör modeli ve EMG-GON sensör çoklu modelinin en düşük doğrulukları sırasıyla 0.548 ve 0.776 olarak bulunmuştur. Bu sonuç, önerilen kayan pencereler yöntemi ve makine öğrenme yaklaşımının, IMU sensör modelinin zamansal yürüyüş parametrelerini doğru adreslemedeki etkinliğine ve EMG sensör modellerinin yürüyüş tanımada IMU ile GON giyilebilir sensör modellerinin gerisinde kalmasına bağlanabilir.



Şekil 5.1: Deneylerde kullanılan sensör model doğruluklarının karşılaştırılması. ***(a)*** IMU sensör ML ve CNN modelleri, ***(b)*** GON sensör ML ve CNN modelleri, ***(c)*** IMU-GON sensör çoklu sensör ML ve CNN modelleri, ***(d)*** IMU sensör yerleşimlerine göre ML ve DL modelleri.

İnsan yürüyüş örüntüsü tanımada, uygun giyilebilir IMU sensör yerleşimi ve seçimine yönelik makine öğrenmesi yaklaşımının kullanıldığı önerilen sistem, %84 civarında doğrulukla performans göstermiştir. Şekil 4.2'de gösterildiği gibi, tekli sensör öznitelikleri arasında, uyluk ve gövde sensörleri sırasıyla %76 ve %74 ile en yüksek sınıflandırma doğruluğuna sahipken, gövde sensörü en düşük sınıflandırma doğruluğuna sahiptir. Gövde ve bacak sensörü öznitelikleri birlikte kullanıldığında, sınıflandırıcıların sınıflandırma doğruluğu %77'ye yükselmiştir. Ayak sensörü özniteliklerinin bu sensörlere eklenmesi, sınıflandırma doğruluğunu %79'a çıkarmıştır. Sensör özniteliklerinin tümünün birlikte kullanıldığı model, önerilen yönteme dayalı olarak farklı yürüme hızlarında insan yürüyüşünü tanımada %84 ile en yüksek sınıflandırma doğruluğuna ulaşılmıştır. Şekil 5.1 (d)'de farklı sensör modellerinin sınıflandırma doğrulukları incelendiğinde, insan yürüyüş tanımada giyilebilir IMU sensör yerleştirmek için bacaklar, gövdeden daha iyi bir konum olduğu görülmektedir. Tek bir sensörle bile en iyi tanıma doğruluğu sağlayan sensör yerleşimleri uyluk veya bacakta olabilir. Camargo ve ark., önceki bir çalışmalarında [95] yürüme hızını sadece IMU sensörlerden yararlanarak tahmin etmiş ve bacağın en kritik IMU konumu olarak işlev gördüğünü göstermiştir. Diğer bir çalışmada ise Nasrabadi ve ark., sol bilek ile sağ uyluk veya bel ile sağ uyluk, iki sensör için en uygun seçenek olurken, tekli sensör için üstün seçenek, uylukta konumlandırılan alt ekstremite sensörü olarak bulmuştur [61].

EL ve SVM tabanlı makine öğrenmesi sınıflandırıcıları kullanılarak, tüm sensör kanalları dahil edildiğinde sınıflandırma doğruluğunun kabaca %80 olduğu Şekil 4.7'de gösterilmektedir. EL tabanlı sınıflandırıcının normalizasyondan önce daha iyi performans gösterdiği sonucuna ulaşılmıştır. [0-1] veri normalizasyonuyla, SVM tabanlı sınıflandırıcılarla %83.9 sınıflandırma doğruluğu elde edilirken, EL tabanlı sınıflandırıcılarla %82.1 sınıflandırma doğruluğuna ulaşılmıştır. Nasrabadi ve ark., Parkinson hastalarının yürüyüş ve oturma hareketlerini tanıma üzerine on IMU sensör kullanarak gerçekleştirdikleri bu çalışmalarında [61] sol uyluk ve sol ön kola yerleştirilmiş iki IMU sensörle KNN sınıflandırıcıyla hasta grupta %88.1 genel performans sağlarken, sağlıklı bireylerin olduğu grupta %93 duyarlılık performansı sağlamıştır. Ayrıca sol uylukta ve solda bulunan iki IMU kullanılarak NM sınıflandırıcısıyla %85.2'lik bir duyarlılık performansına ulaşılırken sol uyluk ve omurgaya yerleştirilmiş iki IMU ve KNN sınıflandırıcısıyla % 95.2'lik bir duyarlılık performansı elde etmiştir. Sağ ve sol uyluk sensör yerleşimlerinin insan aktivitesi tanımada diğer sensör yerleşimlerine göre daha yüksek performans gösterdiğine ulaşmıştır. Yedi farklı aktivite tanımaya yönelik altı IMU sensör ve

makine öğrenmesi sınıflandırıcısının kullanıldığı sağlıklı bireylerle gerçekleştirdikleri bir çalışmalarında Cleland ve ark., bel ve kalça gibi proksimal kısımlara yerleştirilen sensörler ve SVM tabanlı sınıflandırıcıyla %97.81 F-skoruyla yürüyüş tanımada uyluğun en optimum sensör konum olduğunu bulmuştur [81].

Aynı biyomekanik veri setinin kullanıldığı çoklu çevresel parametre koşullarında yürüyüş mod sınıflandırmasını amaçlayan bir çalışmada Camargo ve ark., önerdikleri sistemin ortalama %98'in üzerinde doğrulukla performans gösterdiğini ortaya koymuştur [95]. Hız tahminindeki performası daha önceki çalışmalarla karşılaştırabilmek amacıyla ortalama karekök hatası (RMSE) hesaplanmıştır. Önerdikleri sistemin RMSE hatası 0.07 m/s ile Sabatini ve ark., elde ettiği 0.05 m/s RMSE hatasından yüksektir fakat onların yöntemi zamansal parametrelere bağımlılık ve işlem yoğunluğunun fazla olması nedenleriyle kullanışlı değildir [80]. Benzer sensör veri setinden yararlanan Kang ve ark., önerdikleri yapay sinir ağı modelinin performansını 0.08 m/s RMSE hatasıyla diğer çalışmalarla tutarlı olarak bulmuştur [94]. Veri setini kullandığımız çalışmadaki bulgular, diğer çalışmaların 0.83 m/s-1.79 m/s hız aralığına kıyasla, 0.5 m/s-1.85 m/s hız aralığıyla daha geniş bir hız aralığını da tahmin edebilmiştir. Aralığın düşük tarafındaki analiz edilen bu hızlar, klinik çalışmalardaki popülasyonun daha yavaş yürüme eğiliminde olması açısından hareket tanımada önemlidir. Bu, eklem hareketlerinin örüntüsü 0.69 m/s'den [20] daha yavaş hız durumları için değiştiği tespit edildiğinden, yürüyüş tanıma probleminin daha zor olmasını beraberinde getirmektedir. Benzer şekilde tez çalışmasındaki sınıf bazında sınıflandırma performans ölçütleri ve karışıklık matrisleri incelendiğinde yavaş hızlardaki sınıflandırma performansı diğer yürüyüş hız gruplarına göre daha düşük olarak elde edilmiştir.

Bu çalışma, ayrıca sağlıklı bireylerin yer seviyesi yürüyüş hareketini üç farklı yürüme hızına göre çoklu sınıflandırabilen derin öğrenme tabanlı yeni bir zaman-frekans analizi yaklaşımı önermektedir. Uzamsal ve zamansal yürüyüş parametreleri gibi geleneksel kinematik yürüyüş değerlendirme ölçümleri olmadan, 5 saniyelik bir yürüyüş sinyalinin hem ham hem de bunun bileşke lineer ivmelenmelerinin spektral görüntüleri, sınıflandırma algoritmalarına giriş veri seti olarak uygulanmıştır. Güncel çalışmalarda zaman-frekans analizleri yaygın olarak EKG'ye [107], radar sinyallerine [99] uygulanmış ve zaman-frekans alanında temsil edilen kalp sesi sinyalleri [111-112] 2D-CNN ile eğitilerek özellikle konuşma tanıma alanında önemli sonuçlar ortaya konulmuştur. Ancak yürüyüş sınıflandırmasındaki uygulamaları oldukça sınırlıdır. Jung ve ark., 6-DOF IMU ile yürüyüşün biyomekanik değerlendirmesinde spektral analiz yöntemini

uyguladığı çalışmaları bu konudaki ilk çalışma olup gözlemlenebilir bir fark olmaksızın patolojik yürüyüşün güvenilir şekilde sınıflandırılmadaki faydasını doğrulamıştır [57]. IMU sinyallerinin spektrogramları kullanılarak eğitilen önerilen 2D-CNN modelinin, çok fazla sinyal işleme, zaman alıcı ve kaynak yoğun süreçler ve özel bilgi gerektirmeden %100 doğrulukta sınıflandırma sağlaması dikkat çekicidir. Ek olarak, önerdikleri 2D-CNN modeli, mevcut diğer derin öğrenme modellerinden daha basit olduğu için eğitim ve test süresini azaltmıştır.

Zaman-frekans analiz tekniklerini karşılaştırmak amacıyla her bir modelin sınıflandırma performans ölçütleri bağımsız olarak ele alınmıştır. İlk olarak, tüm IMU sensör kanallarını içeren sinyallerin zaman-genlik görüntüleri kullanılarak bir veri seti oluşturulmuştur. Ardından bu sinyaller üzerinde STFT ve CWT kullanılarak spektral görüntülerden veri setleri oluşturulmuştur. Ayrıca elde edilen bileşke lineer ivmelenmelerin oluşturduğu zaman-genlik sinyallerine aynı zaman-frekans analizi dönüşümü işlemi uygulanarak bileşke lineer ivmelenmelerin spektral görüntülerinden oluşan veri setleri üretilmiştir.

Ham IMU ve bileşke IMU modellerine ait test kümesi sınıflandırma performansı sırasıyla Tablo 4.1 ve Tablo 4.2'de gösterilmiştir. Bu performans metrikleri göz önüne alındığında, tüm IMU kanallarını içeren ve STFT uygulanan CNN modelleri ile IMU lineer bileşke ivmelenme sinyallerine CWT uygulanan CNN modellerinin daha iyi bir yürüyüş tanıma performansı gösterdiğine ulaşılabilmektedir. 2D-CNN modellerinin performans metrikleri makro ortalama değerler bazında değerlendirildiğinde, en iyi sınıflandırma doğruluğuna sahip STFT-tümü modeli için test kümesi doğruluğu 0.859 iken diğer yüksek sınıflandırma doğruluğuna sahip diğer iki model olan CWT-tümü ve CWT-BLİV için test kümesi doğrulukları sırasıyla 0.809 ve 0.794'dir. Yürüyüş hız etiketlerine göre örneğin 'hızlı' sınıfında olmadığı bilinen bir örneğin tahmin edilen değerde o sınıfta olmaması yüzdesi olan özgüllük yani yanlış pozitif oranı bir diğer önemli performans metriğidir. Özgüllük değerlerine göre 2D-CNN modelleri değerlendirildiğinde ise doğruluk metriğine benzer şekilde 'STFT-tümü', 'CWT-tümü' ve 'CWT-BLİV' modellerinin sırasıyla 0.876, 0.857 ve 0.846 özgüllükle en yüksek üç model olduğuna ulaşılmıştır. Zaman-frekans analizi uygulanan 2D-CNN modellerinin sınıflandırma performansı, ayrıca Şekil 4.9 ve Şekil 4.10'da listelehnen karışıklık matrisleriyle de değerlendirilmiştir. STFT-tümü modeli, Şekil 4.9'da gösterildiği gibi hem eğitim hem de test veri kümeleri için daha az yanlış pozitif ve yanlış negatif oranı sağlamıştır.

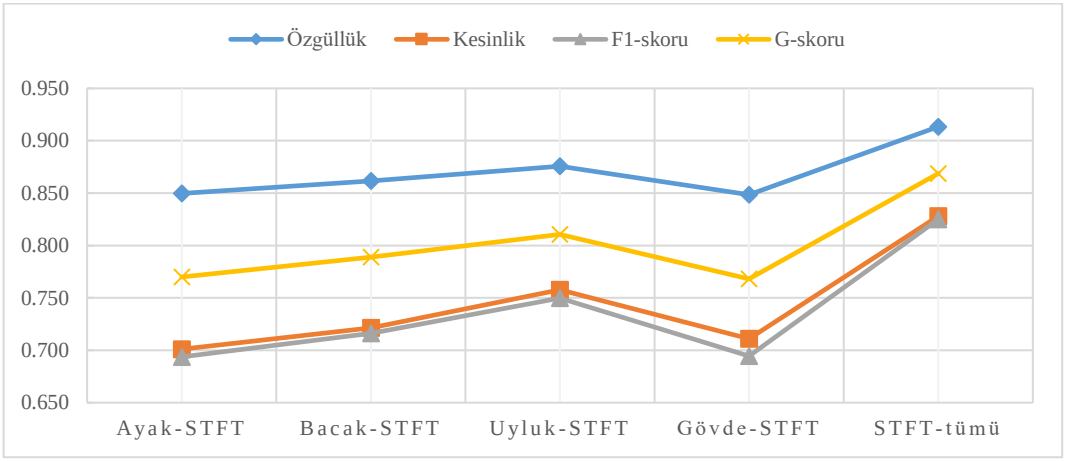
Üç farklı yürüme hızında sağlıklı yetişkinlerin geçici yürüyüş örüntüsü tanımayı amaçladığımız çalışmada kullandığımız aynı veri setiyle Camargo ve ark., klasik makine öğrenme algoritmalarını kullanarak insan yürüyüşünü yürüme hızına göre sınıflandırılmıştır. Yürüme hızı tahmininde hızlı, yavaş ve normal grup sınıflandırmasında en düşük RMSE hata oranını ML tabanlı SVM modellerinde 0.04 ± 0.01 m/s olarak bulmuştur. Ayrıca çalışmalarında farklı yürüme alanı koşulları için hangi sensör tipinin ve yerleşiminin önemli olduğunu, IMU ve GON gibi mekanik sensörlerin sınıflandırma için EMG sensörlerinden daha belirleyici olduğunu ve bacağa yerleştirilen IMU sensörlerinin yürüme hızını tahmin etmede daha yüksek doğruluğa sahip olduğunu göstermiştir [95]. Bu çalışmadaki yürüyüş parametrelerine benzer şekilde, Bhakta ve ark., robotik bir protez üzerinde yürüme hızını gerçek zamanlı olarak belirlemeyi amaçlayan çalışmalarında, transfemoral amputasyonlu deneklerin yürüme hızını belirlemede çoklu makine öğrenme algoritmalarının etkinliğini değerlendirmiştir. Özellikle dinamik durumlar için yürüme hızını belirlemede 0.014±0.001 m/s RMSE ile düşük hata performansını doğrulamıştır [97]. Bu çalışmadaki sonuçlar, yürüyüş hızının biyomekanik tanımlayıcı olarak olası kullanabilirliğini göstermesinin yanı sıra insan yürüyüş tanıma yaklaşımı olarak spektogram ve skalogram gibi zaman-frekans analizi yöntemlerinin uygulanabilirliğini ortaya koymaktadır. Yürüyüş sinyali spektral görüntüsünün insan yürüyüş karakteristiğiyle ilgili zamansal ve uzamsal parametreleri doğru bir şekilde yansıtabilmedeki etkinliği, STFT tabanlı 2D-CNN yaklaşımıyla yüksek doğrulukla insan hareketi sınıflandırmayı yaygınlaştırabilir.

Önerilen STFT tabanlı 2D-CNN yaklaşımının insan yürüyüşü tanıma performansını iyileştirmek amacıyla IMU sinyallerine filtreleme ve segmentasyon sinyal ön işlemleri uygulanarak değerlendirilmiştir. Aynı zamanda giyilebilir biyomekanik sensör yerleşimi ve seçiminin insan yürüyüş tanımadaki önerilen derin öğrenme yaklaşımıyla analiz edilmiştir. Ardından farklı segmentasyon sürelerindeki GON sinyalleri aynı modelle eğitilerek deneyler gerçekleştirilmiştir. Ayrıca IMU ve GON spektogram görüntülerinin giriş olarak uygulandığı iki girişli ve tek çıkışlı önerilen 2D-CNN modeliyle deneyler tekrarlanmış, STFT tabanlı derin öğrenme model sonuçları karşılaştırılmalı olarak sunulmuştur.

IMU giyilebilir sensör verilerinden yararlanılarak filtreleme sinyal ön işleme adımının ve sensör yerleşiminin insan yürüyüş hızı sınıflandırma performansına etkisi değerlendirilmiş, Tablo 4.3, Tablo 4.4 ve Tablo 4.5'te eğitim ve test sınıflandırma ölçütlerinin makro ortalaması gösterilmiş ayrıca her bir yürüyüş hızına ait karışıklık matrislerine Şekil 4.13, Şekil 4.15 ve Şekil 4.17'de yer verilmiştir. Şekil 4.18'de ise IMU sensör kanallarının tamamının dahil

edildiği STFT görüntü veri setlerine ait her bir grubun ‘Tümü’ CNN modeli sınıflandırma performansları karşılaştırmalı olarak gösterilmiştir. Sinyalin tamamının işleme dahil edildiği filtre uygulanmayan ve filtre uygulanan test kümesi sınıflandırma performansları arasında anlamlı bir fark gözlemlenmemiştir. Tüm deneyler birlikte değerlendirildiğinde veri setindeki tüm verileri kapsayan en küçük aralık olan 7 s zaman aralığında segmente edildiği deneylerde ise segmentasyonun, test kümsesi sınıflandırma performansını önemli ölçüde artırdığına ulaşılmıştır. Son olarak tüm sensör kanallarının dahil edildiği ve filtrelemenin uygulandığı 2D-CNN modellerinin sınıflandırma performansını iyileştirdiği sonucuna ulaşılmıştır.

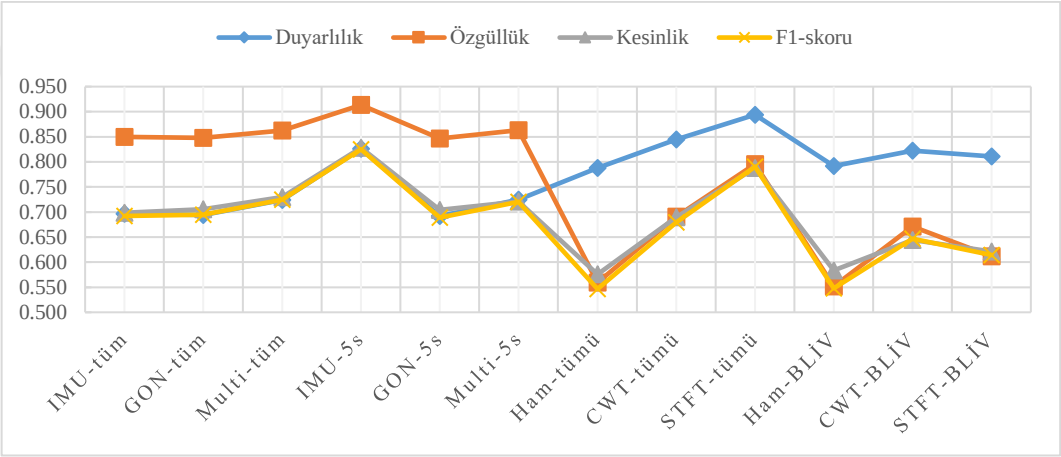
Giyilebilir IMU sensör yerleşimlerine göre değerlendirildiğinde STFT tabanlı 2D-CNN modellerinin sınıflandırma performansı ölçütleri, en yüksekten en düşüğe ‘STFT-tümü’, ‘Uyluk-STFT’, ‘Bacak-STFT’, ‘Ayak-STFT’ ve ‘Gövde-STFT’ olarak Şekil 5.2’deki gibi sıralanmıştır. ‘STFT-tümü’, ‘Uyluk-STFT’ ve ‘Bacak-STFT’ modellerinin özgüllükleri sırasıyla 0.913, 0.876 ve 0.862 iken G-skorları sırasıyla 0.869, 0.811 ve 0.789 olarak bulunmuştur. En düşük sınıflandırma ölçütlerine sahip iki sensör modeli olan ‘Ayak-STFT’ ve ‘Gövde-STFT’ modellerinin sınıflandırma performansı birbirine oldukça yakındır. Ayrıca bu modellerin F1-skoru sırasıyla 0.694 ve 0.695 iken kesinlikleri sırasıyla 0.701 ve 0.711 olarak bulunmuştur.



Şekil 5.2: Sensör yerleşimlerine göre 2D-CNN STFT modellerinin performans ölçütleri.

STFT tabanlı derin 2D-CNN yaklaşımıyla IMU ve GON giyilebilir sensör verilerinden yararlanılarak farklı segmentasyon sürelerindeki insan yürüyüş tanıma performansları analiz edilerek, Tablo 4.6, Tablo 4.7 ve Tablo 4.8’de eğitim ve test sınıflandırma ölçütlerinin makro ortalaması listelenmiş ayrıca her bir yürüyüş hızına ait karışıklık matrisleri Şekil 4.20, Şekil

4.22 ve Şekil 4.24'te gösterilmiştir. Bir önceki deneylerde en yüksek doğruluğa tüm sensör kanalları dahil edildiğinde ulaşıldığından bu kısımdaki deneylerde sensör türüne ait tüm kanallar dahil edilerek deneyler gerçekleştirilmiş, segmentasyon sürelerine göre 5s uzunluğu ve sinyalin tamamının analiz edildiği modellerin sınıflandırma doğruluklarının daha yüksek olduğu sonucuna ulaşılmıştır. Şekil 4.23'te tek girişli IMU sensör ve iki girişli IMU-GON sensör CNN modellerinin tek girişli GON sensör CNN modeline göre daha üstün bir yürüyüş tanıma performansı gösterdiği sonucuna varılmıştır. 2D-CNN modellerinden 'IMU-5s', 'Multi-5s' ve 'Multi-tüm' modellerinin özgüllükleri sırasıyla 0.913, 0.863 ve 0.863 iken 'GON-5s' modelinin özgüllüğü ise 0.846 olarak bulunmuştur.



Şekil 5.3: Deneylerde en yüksek doğruluğa sahip 2D-CNN modellerinin performans ölçütleri.

Zaman-frekans analizi tabanlı giyilebilir IMU ve GON sensör modellerinin insan yürüyüş tanıma performansları karşılaştırmalı olarak Şekil 5.3'te gösterilmiştir. STFT tabanlı modellerin CWT tabanlı ve ham sensör sinyallerinin görüntülerinin kullanıldığı modellere göre daha iyi tanıma performansı gösterdiğine ulaşılmıştır. 'IMU-5s', 'Multi-5s' ve 'Multi-tüm' modellerinin özgüllükleri sırasıyla 0.913, 0.863 ve 0.863 iken F1-skorları sırasıyla 0.825, 0.720 ve 0.725 olarak bulunmuştur. IMU bileşke lineer ivmelerin STFT görüntülerinin alındığı 'CWT-BLİV' ve 'STFT-BLİV' modellerinin sınıflandırma performansı birbirine yakın olmakla birlikte STFT tabanlı modellere göre daha düşük olarak bulunmuştur. Ayrıca bu modellerin F1-skorunun sırasıyla 0.647 ve 0.614 iken kesinliklerinin ise sırasıyla 0.644 ve 0.621 olduğu sonucuna ulaşılmıştır.

Veri setindeki dağılımın dengesiz olmasını hesaba katıldığı performans ölçütlerinden olan F-skoru ve G-skorunu kullanmak model performansını değerlendirmede etkilidir. Çoğu patolojik

yürüyüş veri setinde patolojiye ait sınıfta az veri olması, veri setinin dengesiz dağılımına neden olmaktadır. Parkinson hastalarının alt ekstremite IMU yürüyüş sinyallerine CWT uygulayarak derin CNN yaklaşımıyla hastaların yürüyüşündeki donuklukların tespiti üzerine Shi ve ark., önerdikleri kişi-bağımsız yürüyüş tanımada önerdikleri CNN modeliyle %90.7 G-skoru elde etmiştir [115]. Middya ve ark., akıllı telefon ivmeölçer sensörü verilerine dayalı olarak biyometrik kişi tanımlama için ivmeölçer sinyalinin STFT'sini kişisel tanımlama amacıyla CNN modelini eğitmek amacıyla 2 boyutlu zaman-frekans görüntü temsiline dönüştürmektedir. Geleneksel makine öğrenmesi ve transfer öğrenme modellerinin karşılaştırıldığı çalışmalarında önerilen 2D-CNN modeli %98 doğruluk ve %96 F1-skoru ile en yüksek sınıflandırma performansını göstermiştir [119]. Benzer şekilde çalışmamızda önerilen IMU-5s modelinde G-skoru 0.869±0.029 olarak %89.8 bulunmuştur.

Jung ve ark., yürüyüş sinyalinin bir adımından her bir alt vücut bölümünün üç lineer ötelenmesi (Acc) ve üç açısal hızı (Gyro) üzerindeki DCNN tabanlı spektrografik analizle, yürüyüşe ait kinematik özelliklerini etkili bir şekilde temsil etmiştir [120]. Biyometrik kişi tanıma amacıyla ResNet50 derin öğrenme modeliyle eğitilen ayak, bacak, uyluk ve pelvik spektrogramlar, yürüyüş hızından bağımsız olarak %99.69 doğrulukla etkili bir sınıflandırma performansına ulaşmışlardır. Çalışmamız bu çalışmaya benzer şekilde, güvenilir yürüyüş hızına göre insan yürüyüş tanıma amacıyla alt ekstremiteye yerleştirilen IMU sensör yürüyüş spektrogramlarını ve 2D-CNN yaklaşımını önermiştir. Ayrıca çalışmamızda yenilik olarak GON sensör spektogramlarıyla IMU ve GON sensör spektrogramlarının birlikte uygulandığı iki girişli 2D-CNN modeli kullanılmıştır.

Yukarıda belirtilen çalışmalarla karşılaştırıldığında önerilen bu STFT tabanlı 2D-CNN yaklaşımı, öznitelik mühendisliği gerektirmeden insan yürüyüşünün doğru tanınmasını sağlamıştır. Başka bir deyişle, IMU ve GON sensör kinematik yürüyüş verilerinin spektrogramlar olarak temsil edilmesi, birçok manuel uğraşın, zaman alıcı ve uzun işlemlerin azaltılmasına ve yürüyüş tanımaya yönelik daha az uzmanlık bilgisiyle öznitelik çıkarılmasına yardımcı olmuştur. Ayrıca bu yaklaşımla 5 saniye gibi kısa bir yürüyüş sinyalinin spektogramından yararlanılarak yüksek doğrulukla yürüyüş sınıflandırabilmektedir. Şekil 5.2'de gösterildği gibi, insan yürüyüşü tanımada uyluk spektrogramlarından yararlanmak, bacak, ayak veya gövde spektrogramlarına göre daha etkili olarak bulunmuştur. Bu sonuç alt ekstremitenin anatomik yapısıyla ilgili olabilir. Farklı alt vücut bölümlerinin senkronize

hareketlerini içeren yürüyüşe ait ayak, bacak, uyluk ve gövde spektrogramların birlikte kullanılması, insan yürüyüş tanımada en iyi sınıflandırma performansı sağlayabilir.

Tablo 5.2: Güncel insan yürüyüş tanıma çalışmaları ve önerilen yöntemin karşılaştırılması.

Referans	Sensör türü	Sinyal işleme yöntemi	Sınıflandırıcı	Sınıflandırma performansı
[95]	IMU GON EMG	Pencere tabanlı öznitelik çıkarımı	LDA ve ANN	Hareket modu sınıflandırması için, önerilen sistem ortalama %98'in üzerinde doğrulukla (%0.7 kararlı durum hatası, %3.55 geçiş hatası) performans göstermiştir.
[116]	IMU	DWT	1D-CNN	%96.4 doğruluk
[117]	IMU	DWT	AlexNet-CNN	%88.4 doğruluk
[118]	IMU	EMD ve DWT	DT	%99.63 doğruluk
[120]	IMU	STFT	ResNet50-CNN	%99.69 doğruluk
Önerilen CNN yöntemi	IMU GON	STFT	2D-CNN	(IMU-tüm) 0.817±0.025 doğruluk (IMU-5s) 0.885±0.025 doğruluk
Önerilen ML yöntemi	IMU GON EMG	Kayan pencereler yöntemi	SVM KNN ANN	(SVM- 0.954) doğruluk (SVM- 0.827) doğruluk

Önerilen STFT tabanlı 2D-CNN yaklaşımın performansının değerlendirilmesi amacıyla modeller, IMU sensör spektogram temsillerinin yanı sıra GON sensör spektrogram görüntüleriyle de eğitilerek literatürde benzer veri setlerinde kullanılan mevcut bazı çalışmalarla Tablo 5.2'de karşılaştırılmıştır. IMU sensörlerden yararlanılan güncel insan yürüyüşü tanıma çalışmalarında önerilen derin STFT tabanlı 2D-CNN yaklaşımın yanı sıra DWT tabanlı 1D-CNN ve makine öğrenmesi yaklaşımlarının uygulandığı görülmüştür. Chakraborty ve Nandy, giyilebilir ivmeölçer sensörle serebral palsi ve normal çocuk yürüyüş örüntülerinin algılanmasında çoklu kanal 1D-CNN modeli ve DWT kullanarak önerdikleri segment tabanlı modelde %96.4 doğruluğa ulaşmıştır [116]. Bir başka yürüyüş tanıma çalışmasında ise Yan ve ark., farklı açık alan yürüme koşullarındaki deneylerde yürüyüş sinyallerine DWT uygulamış, elde edilen alt bantlarından öznitelik çıkarmış ve bu öznitelikleri gri skala görüntü matrisine dönüştürerek önerdikleri AlexNet tabanlı CNN modeliyle %88.4 doğrulukla sınıflandırmıştır [117]. Vidya ve Sasikumar makine öğrenmesi yaklaşımıyla insan

aktivite sınıflandırma üzerine yaptıkları bir çalışmada, IMU sensör sinyallerini EMD ve DWT ile alt bileşenlerine ayrıştırarak öznitelikleri çıkarmışlar ve DT algoritmasını kullandıkları modelde %99.63 ile en yüksek sınıflandırma doğruluğunu bulmuştur [118].

Bu çalışmanın sadece yürüyüş hızına göre değil aynı zamanda diğer insan günlük yaşam davranışlarını tanımaya yönelik biyometrik kimlik tanıma teknolojilerine de ilham vermesi beklenmektedir. Bu çalışma, genellenebilirlik yönünden bir takım sınırlılıklara sahiptir. Önerilen yaklaşımın farklı patolojik ve antropometrik özelliklere sahip daha çok sayıda bireylere uygulanmasının, IMU sensör bulunduran akıllı telefon gibi mobil cihazlar kullanılarak alt vücut hareketi sinyal kaydı sırasıyla eş zamanlı gerçekleşmesi gerekmektedir.

6. SONUÇ VE ÖNERİLER

Bu çalışmada giyilebilir sensör sinyalleri üzerinde önerilen makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak sağlıklı yetişkinlerin üç farklı geçici yürüme hızının sınıflandırılması kapsamlı olarak ele alınmıştır. Çalışmada açık kaynak erişimli alt ekstremite biyomekanik veri setinden yararlanılmıştır. Veri setindeki bu sinyallere dijital sinyal ön işleme adımları olan filtreleme ve segmentasyon uygulanmıştır. Çalışmada zaman serisi sinyalleriyle makine öğrenmesi ve zaman-frekans analizi görüntüleriyle derin öğrenme olmak üzere iki farklı yöntem test edilmiştir. Birinci yöntemde kayan pencerler yöntemiyle giyilebilir sensör zaman serisi sinyallerinden çıkarılan öznitelikler 10-kat çapraz doğrulama ile farklı makine öğrenmesi yöntemlerine uygulanarak sonuçlar karşılaştırılmıştır. Ayrıca sensör türü, sensör kanalı, pencere boyutu, PCA ve veri normalizasyonun makine öğrenmesiyle insan yürüyüşü sınıflandırmadaki etkisi incelenmiştir. İkinci yöntem olan Evrişimsel Sinir Ağları (CNN) derin öğrenme modeliyle giyilebilir sensör sinyali iki boyutlu zaman serisi ve zaman-frekans analizi görüntüleriyle eğitilerek insan yürüyüş tanımadaki performansları kıyaslanmıştır. Bu yöntemin avantajı, ilk yöntemdeki öznitelik çıkarma aşamasının daha hassas olması ve görüntü üzerinden doğrudan öznitelik çıkarılarak sınıflandırma işlemini otomatik ve hızlı bir şekilde gerçekleştirilebilmesidir.

Bu tez çalışmasında veri setinin kullanıldığı literatürdeki diğer çalışmalardan farklı olarak katılımcı bazında değil yürüyüş örüntüsü bazında sınıflandırma yapılmıştır. Yürüyüş örüntüsü tanımada önerilen makine öğrenmesi ve derin öğrenme modellerinin sınıflandırma performansları karşılaştırılmıştır. Makine öğrenmesi kullanılarak IMU giyilebilir sensörlerin biyomekanik parametreleriyle gerçekleştirilen insan yürüyüşü tanıma amacıyla kayan pencere özellik çıkarma yöntemi önerilmiştir. Çalışmanın ilk kısmında IMU, GON ve EMG giyilebilir biyomekanik sinyallerinin kayan pencereler yöntemi kullanılarak makine öğrenmesiyle sınıflandırılmasında 1000 (5 s) uzunluğundaki kayan pencere uzunluğu ve QSVM sınıflandırıcısı daha iyi performans sağlamıştır. Tekli sensör IMU, GON ve EMG modellerinin doğrulukları sırasıyla 0.95, 0.83 ve 0.74'tür. Çoklu sensör modellerinin doğrulukları ise IMU-GON (0.95), IMU-EMG (0.90), GON-EMG (0.78) ve IMU-GON-EMG (0.92)'dir. Bu sonuçlar insan yürüyüş tanımada IMU giyilebilir sensör kullanımının etkisini göstermektedir. Makine

öğrenmesi yaklaşımının ikinci kısmında IMU sensör yerleşim yerinin ve farklı veri işleme yöntemlerinin insan yürüyüş tanımadaki etkisi değerlendirilmiştir. Beş farklı makine öğrenmesi sınıflandırıcısından SVM tabanlı sınıflandırıcıların yüksek sınıflandırma doğruluğu sağladığına ulaşılmıştır. Tekli IMU sensör 'Ft', 'Sh', 'Th' ve 'Tr'modellerinin doğrulukları sırasıyla 0.693, 0.727, 0.748 ve 0.66'dır. Çoklu IMU sensör 'ShTh', 'ShThFt' ve 'All' modellerinin doğrulukları ise 0.75, 0.799 ve 0.839 olarak bulunmuştur. Birden fazla sensör kanalının dahil edildiği öznitelikler, tekli sensör kanalı özniteliklerine göre yüksek doğrulukla sınıflandırma performansı göstermiştir. Ayrıca alt ekstremite bacak ve uyluk sensörlerinin insan yürüyüşü tanımadaki performası gövde sensörüne göre daha yüksek olduğu sonucuna ulaşılabilir.

Derin öğrenme yaklaşımıyla IMU sinyali ve bileşke lineer ivmelenmeleri zaman-frekans analizi (TFA) görüntülerinin insan yürüyüş tanıma üzerindeki etkisi değerledirilmiştir. Analizler 'STFT-tümü', 'CWT-tümü' ve 'CWT-BLİV' CNN modellerinin en yüksek test sınıflandırma performansına, sırasıyla 0.833, 0.809 ve 0.794 doğruluk ve 0.876, 0.857 ve 0.846 özgüllük değerleriyle ulaşılmıştır. DL analiz sonuçları, STFT ve CWT tabanlı TFA görüntüleri kullanılan CNN modellerinin, tüm IMU giyilebilir sensör kanalları birleştirildiğinde, en yüksek sınıflandırma doğruluğuyla oldukça hassas ve uygulaması kolay bir sınıflandırma problemi sunduğunu göstermiştir. Derin öğrenme yaklaşımının ikinci kısmında giyilebilir IMU ve GON biyomekanik sensör veri setine STFT uygulanarak CNN modelerine giriş görüntü verileri elde edilmiştir. Bu analizlerde biyomekanik sensör yerleşim yerine göre sinyal filtreleme ve segmentasyonu etkileri karşılaştırılarak tek ve iki girişli IMU ve GON sensör CNN modellerinin insan yürüyüş tanıma performansları incelenmiştir. 'IMU-5s', 'Multi-5s', ve 'Multi-tüm' modellerinin sınıflandırma performansı ortalamaları sırasıyla doğrulukları 0.885±0.025, 0.817±0.025 ve 0.817±0.011 özgüllükleri ise 0.913±0.019, 0.863±0.019 ve 0.863±0.008 olarak bulunmuştur. Son olarak IMU ve gonyometre sensör STFT görüntülerinin birlikte giriş olarak kullanıldığı iki girişli CNN modellerinin sınıflandırma performansının, 5 s uzunluğunda IMU sensör modeli sınıflandırma performansına yakın olduğu sonucuna varılmıştır. Önerilen bu yaklaşımla, giyilebilir biyomekanik sinyallerin zaman serisi temsillerinde gözlemlenebilir bir fark olmaksızın sensör yerleşimi ve türüne göre insan yürüyüşü çoklu sınıflandırılabilmektedir. Uyluk ve bacak spektrogramları, özellik mühendisliği için karmaşık bir süreç gerektirmeden bile üç grubun tam olarak sınıflandırılmasına olanak sağlamıştır.

Sonuç olarak, makine öğrenmesi yaklaşımı sağlıklı bireyler için giyilebilir biyomekanik sensörlerden uygun geçici yürüyüş özelliklerinin belirlemesinde önemli bir değerlendirme aracıdır. Bu çalışmada kullanılan kayan pencere yöntemi, giyilebilir yardımcı cihaz tasarımları ile rehabilite edici yürüyüş egzersiz programları için adım uzunluğunun ve biyometrik tanımlama için yürüyüş hızının bireysel olarak izlenmesini de mümkün kılabilmektedir. Derin öğrenme yaklaşımıyla insan yürüyüşünün otomatik olarak sınıflandırılmasına yönelik mevcut çalışmalar, hasta ve sağlıklı yürüyüşün ikili sınıflandırmasıyla sınırlı olup çoklu sınıflandırmada doğruluğun düşük olduğu görülmektedir. Önerilen bu yaklaşım, sağlıklı bireylerin yürüyüş hızı sınıflandırmasında zaman-frekans analizi yaklaşımı ve 2D-CNN kullanarak giyilebilir sensör sinyallerinde gözlemlenebilir farklılıklar olmadan yürüyüşün güvenilir çoklu sınıflandırmasını sağlayan yenilikçi bir çalışmadır. Bu çalışmanın bulguları, derin öğrenme yöntemlerini bilimsel alandan biyotıp alanına uygulayarak yürüme bozukluklarının ilerleyişini tahmin etmeye de katkıda bulunabilir. Ayrıca, yürüyüş anormalliklerinin tanısı ile aşama değerlendirmesine ve rehabilite edici giyilebilir cihazlarda yürüyüş örüntülerinin saptanmasına olanak sağlayabilmektedir. Daha sonraki araştırmalarda, aynı alt ekstremite biyomekanik veri seti, rampa ve merdiven hareketi dahil olmak üzere insan aktivitesini tanımak amacıyla LSTM ve transfer öğrenme gibi derin öğrenme modelleri geliştirmek hedeflenmektedir.

KAYNAKLAR

[1]. Celik Y., Stuart S., Woo W.L., Godfrey A., 2021, Gait analysis in neurological populations: Progression in the use of wearables, Medical Engineering & Physics, 87, 9-29.

[2]. Wang Y., Cang S., Yu H., 2019, A survey on wearable sensor modality centred human activity recognition in health care, Expert Systems with Applications, 137, 167-90.

[3]. Rucco R., Agosti V., Jacini F., Sorrentino P., Varriale P., De Stefano M., et al., 2017, Spatio-temporal and kinematic gait analysis in patients with Frontotemporal dementia and Alzheimer's disease through 3D motion capture, Gait & posture, 52, 312-7.

[4]. Colyer S.L., Evans M., Cosker D.P., Salo A.I., 2018, A review of the evolution of vision-based motion analysis and the integration of advanced computer vision methods towards developing a markerless system, Sports medicine-open, 4(1), 1-15.

[5]. Hazra S., Pratap A.A., Tripathy D., Nandy A., 2021, Novel data fusion strategy for human gait analysis using multiple kinect sensors, Biomedical Signal Processing and Control, 67, 102512.

[6]. Slijepcevic D., Zeppelzauer M., Schwab C., Raberger A.-M., Breiteneder C., Horsak B., 2020, Input representations and classification strategies for automated human gait analysis, Gait & posture, 76, 198-203.

[7]. Garza-Ulloa J., Yu H., Sarkodie-Gyan T., 2012, A mathematical model for the validation of the ground reaction force sensor in human gait analysis, Measurement, 45(4), 755-62.

[8]. Chen S., Lach J., Lo B., Yang G.-Z., 2016, Toward pervasive gait analysis with wearable sensors: A systematic review, IEEE journal of biomedical and health informatics, 20(6), 1521-37.

[9]. González I., López-Nava I.H., Fontecha J., Muñoz-Meléndez A., Pérez-SanPablo A.I., Quiñones-Urióstegui I., 2016, Comparison between passive vision-based system and a wearable inertial-based system for estimating temporal gait parameters related to the GAITRite electronic walkway, Journal of biomedical informatics, 62, 210-23.

[10]. Picerno P., Iosa M., D'Souza C., Benedetti M.G., Paolucci S., Morone G., 2021, Wearable inertial sensors for human movement analysis: A five-year update, Expert review of medical devices, 18(sup1), 79-94.

[11]. Rajkumar A., Vulpi F., Bethi S.R., Wazir H.K., Raghavan P., Kapila V., 2019, Wearable inertial sensors for range of motion assessment, IEEE sensors journal, 20(7), 3777-87.

[12]. Zhang P., Li Y., Zhuang Y., Kuang J., Niu X., Chen R., 2023, Multi-level information fusion with motion constraints: Key to achieve high-precision gait analysis using low-cost inertial sensors, Information Fusion, 89, 603-18.

[13]. Kurban O.C., Yıldırım T., 2019, Daily motion recognition system by a triaxial accelerometer usable in different positions, IEEE Sensors Journal, 19(17), 7543-52.

[14]. Minarno A.E., Kusuma W.A., Wibowo H., Akbi D.R., Jawas N., editors. Single triaxial accelerometer-gyroscope classification for human activity recognition. 2020 8th international conference on information and communication technology (ICoICT); 2020: IEEE.

[15]. Jalal A., Quaid M.A.K., Tahir S.B.u.d., Kim K., 2020, A study of accelerometer and gyroscope measurements in physical life-log activities detection systems, Sensors, 20(22), 6670.
[16]. Webber M., Rojas R.F., 2021, Human activity recognition with accelerometer and gyroscope: A data fusion approach, IEEE Sensors Journal, 21(15), 16979-89.
[17]. Lin C.-L., Chiu W.-C., Chu T.-C., Ho Y.-H., Chen F.-H., Hsu C.-C., et al., 2020, Innovative head-mounted system based on inertial sensors and magnetometer for detecting falling movements, Sensors, 20(20), 5774.
[18]. Kavuncuoğlu E., Uzunhisarcıklı E., Barshan B., Özdemir A.T., 2022, Investigating the Performance of Wearable Motion Sensors on recognizing falls and daily activities via machine learning, Digital Signal Processing, 126, 103365.
[19]. Papagiannis G.I., Triantafyllou A.I., Roumpelakis I.M., Zampeli F., Garyfallia Eleni P., Koulouvaris P., et al., 2019, Methodology of surface electromyography in gait analysis: review of the literature, Journal of medical engineering & technology, 43(1), 59-65.
[20]. van Hedel H.J., Tomatis L., Müller R., 2006, Modulation of leg muscle activity and gait kinematics by walking speed and bodyweight unloading, Gait & posture, 24(1), 35-45.
[21]. Fricke C., Alizadeh J., Zakhary N., Woost T.B., Bogdan M., Classen J., 2021, Evaluation of three machine learning algorithms for the automatic classification of EMG patterns in gait disorders, Frontiers in neurology, 12, 666458.
[22]. Mazzetta I., Zampogna A., Suppa A., Gumiero A., Pessione M., Irrera F., 2019, Wearable sensors system for an improved analysis of freezing of gait in Parkinson's disease using electromyography and inertial signals, Sensors, 19(4), 948.
[23]. Schlink B.R., Nordin A.D., Ferris D.P., 2020, Comparison of signal processing methods for reducing motion artifacts in high-density electromyography during human locomotion, IEEE open journal of engineering in medicine and biology, 1, 156-65.
[24]. Celik Y., Stuart S., Woo W.L., Sejdic E., Godfrey A., 2022, Multi-modal gait: A wearable, algorithm and data fusion approach for clinical and free-living assessment, Information Fusion, 78, 57-70.
[25]. Prigent G., Aminian K., Cereatti A., Salis F., Bonci T., Scott K., et al., 2023, A robust walking detection algorithm using a single foot-worn inertial sensor: validation in real-life settings, Medical & Biological Engineering & Computing, 1-12.
[26]. Acharya D., Rani A., Agarwal S., Singh V., 2016, Application of adaptive Savitzky–Golay filter for EEG signal processing, Perspectives in science, 8, 677-9.
[27]. Rajan T.J., Kumar K.S., Hariharan K., 2021, Displacement Estimation by Savitzky Golay filtering technique through inertial sensor, New Frontiers in Communication and Intelligent Systems, Soft Computing Research Society, 377-82.
[28]. Agarwal S., Rani A., Singh V., Mittal A.P., 2016, Performance evaluation and implementation of FPGA based SGSF in smart diagnostic applications, Journal of medical systems, 40, 1-15.
[29]. Schafer R.W., 2011, What is a Savitzky-Golay filter?[lecture notes], IEEE Signal processing magazine, 28(4), 111-7.
[30]. Fida B., Bernabucci I., Bibbo D., Conforto S., Schmid M., 2015, Varying behavior of different window sizes on the classification of static and dynamic physical activities from a single accelerometer, Medical engineering & physics, 37(7), 705-11.
[31]. Ni Q., Zhang L., Li L., 2018, A heterogeneous ensemble approach for activity recognition with integration of change point-based data segmentation, Applied Sciences, 8(9), 1695.
[32]. Ma C., Li W., Cao J., Du J., Li Q., Gravina R., 2020, Adaptive sliding window based activity recognition for assisted livings, Information Fusion, 53, 55-65.

[33]. Wang G., Li Q., Wang L., Wang W., Wu M., Liu T., 2018, Impact of sliding window length in indoor human motion modes and pose pattern recognition based on smartphone sensors, Sensors, 18(6), 1965.
[34]. Chen Z., Zhu Q., Soh Y.C., Zhang L., 2017, Robust human activity recognition using smartphone sensors via CT-PCA and online SVM, IEEE transactions on industrial informatics, 13(6), 3070-80.
[35]. Noor M.H.M., Salcic Z., Kevin I., Wang K., 2017, Adaptive sliding window segmentation for physical activity recognition using a single tri-axial accelerometer, Pervasive and Mobile Computing, 38, 41-59.
[36]. Wu H.-T., 2020, Current state of nonlinear-type time–frequency analysis and applications to high-frequency biomedical signals, Current Opinion in Systems Biology, 23, 8-21.
[37]. Cohen L. Time-frequency analysis: Prentice hall New Jersey; 1995.
[38]. Proakis J.G., 1996, Manolakis, Dimitris G, Digital Signal Processing: Principles, algotithms and applications.
[39]. Lai D.T., Begg R., Charry E., Palaniswami M., editors. Frequency analysis of inertial sensor data for measuring toe clearance. 2008 International Conference on Intelligent Sensors, Sensor Networks and Information Processing; 2008: IEEE.
[40]. Alaqtash M., Yu H., Brower R., Abdelgawad A., Sarkodie-Gyan T., 2011, Application of wearable sensors for human gait analysis using fuzzy computational algorithm, Engineering Applications of Artificial Intelligence, 24(6), 1018-25.
[41]. Gupta A., Semwal V.B., 2020, Multiple task human gait analysis and identification: ensemble learning approach, Emotion and Information Processing: A Practical Approach, 185-97.
[42]. Shi B., Yen S.C., Tay A., Tan D.M., Chia N.S., Au W.L., editors. Convolutional neural network for freezing of gait detection leveraging the continuous wavelet transform on lower extremities wearable sensors data. 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC); 2020: IEEE.
[43]. Zhang M., Liu D., Wang Q., Zhao B., Bai O., Sun J., 2022, Gait pattern recognition based on plantar pressure signals and acceleration signals, IEEE Transactions on Instrumentation and Measurement, 71, 1-15.
[44]. Jun K., Lee D.-W., Lee K., Lee S., Kim M.S., 2020, Feature extraction using an RNN autoencoder for skeleton-based abnormal gait recognition, IEEE Access, 8, 19196-207.
[45]. Jain R., Semwal V.B., Kaushik P., 2022, Deep ensemble learning approach for lower extremity activities recognition using wearable sensors, Expert Systems, 39(6), e12743.
[46]. Semwal V.B., Gaud N., Lalwani P., Bijalwan V., Alok A.K., 2022, Pattern identification of different human joints for different human walking styles using inertial measurement unit (IMU) sensor, Artificial Intelligence Review, 55(2), 1149-69.
[47]. Arshad H., Khan M.A., Sharif M.I., Yasmin M., Tavares J.M.R., Zhang Y.D., et al., 2022, A multilevel paradigm for deep convolutional neural network features selection with an application to human gait recognition, Expert Systems, 39(7), e12541.
[48]. Chong J., Tjurin P., Niemelä M., Jämsä T., Farrahi V., 2021, Machine-learning models for activity class prediction: A comparative study of feature selection and classification algorithms, Gait & Posture, 89, 45-53.
[49]. Hutabarat Y., Owaki D., Hayashibe M., 2021, Recent advances in quantitative gait analysis using wearable sensors: a review, IEEE Sensors Journal, 21(23), 26470-87.
[50]. Wang L., Sun Y., Li Q., Liu T., Yi J., 2020, Two shank-mounted IMUs-based gait analysis and classification for neurological disease patients, IEEE Robotics and Automation Letters, 5(2), 1970-6.

[51]. Mohr M., von Tscharner V., Emery C.A., Nigg B.M., 2019, Classification of gait muscle activation patterns according to knee injury history using a support vector machine approach, Human movement science, 66, 335-46.
[52]. Ferreira M.I.A., Barbieri F.A., Moreno V.C., Penedo T., Tavares J.M.R., 2022, Machine learning models for Parkinson's disease detection and stage classification based on spatial-temporal gait parameters, Gait & Posture, 98, 49-55.
[53]. Galasso S., Baptista R., Molinara M., Pizzocaro S., Calabrò R.S., De Nunzio A.M., 2023, Predicting physical activity levels from kinematic gait data using machine learning techniques, Engineering Applications of Artificial Intelligence, 123, 106487.
[54]. Hussain A.N., Abboud S.A., baki Jumaa B.A., Abdullah M.N., 2023, Impact of feature reduction techniques on classification accuracy of machine learning techniques in leg rehabilitation, Measurement: Sensors, 25, 100544.
[55]. Ozdemir M.A., Kisa D.H., Guren O., Akan A., 2022, Hand gesture classification using time–frequency images and transfer learning based on CNN, Biomedical Signal Processing and Control, 77, 103787.
[56]. Benegui C., Ionescu R.T., 2020, Convolutional neural networks for user identification based on motion sensors represented as images, IEEE Access, 8, 61255-66.
[57]. Jung D., Nguyen M.D., Park M., Kim J., Mun K.-R., 2020, Multiple classification of gait using time-frequency representations and deep convolutional neural networks, IEEE Transactions on Neural Systems and Rehabilitation Engineering, 28(4), 997-1005.
[58]. Martindale C.F., Christlein V., Klumpp P., Eskofier B.M., 2021, Wearables-based multi-task gait and activity segmentation using recurrent neural networks, Neurocomputing, 432, 250-61.
[59]. Martinez-Hernandez U., Awad M.I., Dehghani-Sanij A.A., 2022, Learning architecture for the recognition of walking and prediction of gait period using wearable sensors, Neurocomputing, 470, 1-10.
[60]. Jung D., Nguyen M.D., Han J., Park M., Lee K., Yoo S., et al., editors. Deep neural network-based gait classification using wearable inertial sensor data. 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC); 2019: IEEE.
[61]. Nasrabadi A.M., Eslaminia A.R., Bakhshayesh P.R., Ejtehadi M., Alibiglou L., Behzadipour S., 2022, A new scheme for the development of IMU-based activity recognition systems for telerehabilitation, Medical Engineering & Physics, 108, 103876.
[62]. Huang J., Chen B., Yao B., He W., 2019, ECG arrhythmia classification using STFT-based spectrogram and convolutional neural network, IEEE access, 7, 92871-80.
[63]. Bull F.C., Al-Ansari S.S., Biddle S., Borodulin K., Buman M.P., Cardon G., et al., 2020, World Health Organization 2020 guidelines on physical activity and sedentary behaviour, British journal of sports medicine, 54(24), 1451-62.
[64]. Tang Y.-m., Wang Y.-H., Feng X.-Y., Zou Q.-S., Wang Q., Ding J., et al., 2022, Diagnostic value of a vision-based intelligent gait analyzer in screening for gait abnormalities, Gait & Posture, 91, 205-11.
[65]. De Vos M., Prince J., Buchanan T., FitzGerald J.J., Antoniades C.A., 2020, Discriminating progressive supranuclear palsy from Parkinson's disease using wearable technology and machine learning, Gait & Posture, 77, 257-63.
[66]. Hagoort I., Vuillerme N., Hortobágyi T., Lamoth C.J., 2022, Outcome-dependent effects of walking speed and age on quantitative and qualitative gait measures, Gait & Posture, 93, 39-46.

[67]. Fritz S., Lusardi M., 2009, White paper:“walking speed: the sixth vital sign”, Journal of geriatric physical therapy, 32(2), 2-5.
[68]. Amuthavalli Thiyagarajan J., Mikton C., Harwood R.H., Gichu M., Gaigbe-Togbe V., Jhamba T., et al., 2022, The UN Decade of healthy ageing: Strengthening measurement for monitoring health and wellbeing of older people, Age and ageing, 51(7), afac147.
[69]. Scone T., Saadat M., Barton H., Rastegarpanah A., 2023, Effects of Variations in Hemiparetic Gait Patterns on Improvements in Walking Speed, IRBM, 44(1), 100733.
[70]. Chen X., Chen C., Wang Y., Yang B., Ma T., Leng Y., et al., 2022, A piecewise monotonic gait phase estimation model for controlling a powered transfemoral prosthesis in various locomotion modes, IEEE Robotics and Automation Letters, 7(4), 9549-56.
[71]. Boukhennoufa I., Zhai X., Utti V., Jackson J., McDonald-Maier K.D., 2022, Wearable sensors and machine learning in post-stroke rehabilitation assessment: A systematic review, Biomedical Signal Processing and Control, 71, 103197.
[72]. Lempke A.F.D., Hart J.M., Hryvniak D.J., Rodu J.S., Hertel J., 2021, Use of wearable sensors to identify biomechanical alterations in runners with exercise-related lower leg pain, Journal of Biomechanics, 126, 110646.
[73]. Teufl W., Lorenz M., Miezal M., Taetz B., Fröhlich M., Bleser G., 2018, Towards inertial sensor based mobile gait analysis: Event-detection and spatio-temporal parameters, Sensors, 19(1), 38.
[74]. Favorskaya M.N., Buryachenko V.V., 2022, Monocular depth-based visual tracker for gait recognition, Procedia Computer Science, 207, 205-14.
[75]. Gul S., Malik M.I., Khan G.M., Shafait F., 2021, Multi-view gait recognition system using spatio-temporal features and deep learning, Expert Systems with Applications, 179, 115057.
[76]. Ahmadian N., Nazarahari M., Whittaker J.L., Rouhani H., 2020, Instrumented triple single-leg hop test: A validated method for ambulatory measurement of ankle and knee angles using inertial sensors, Clinical Biomechanics, 80, 105134.
[77]. Reznick E., Embry K.R., Neuman R., Bolívar-Nieto E., Fey N.P., Gregg R.D., 2021, Lower-limb kinematics and kinetics during continuously varying human locomotion, Scientific Data, 8(1), 282.
[78]. Nweke H.F., Teh Y.W., Al-Garadi M.A., Alo U.R., 2018, Deep learning algorithms for human activity recognition using mobile and wearable sensor networks: State of the art and research challenges, Expert Systems with Applications, 105, 233-61.
[79]. Hassan M.M., Uddin M.Z., Mohamed A., Almogren A., 2018, A robust human activity recognition system using smartphone sensors and deep learning, Future Generation Computer Systems, 81, 307-13.
[80]. Sabatini A.M., Martelloni C., Scapellato S., Cavallo F., 2005, Assessment of walking features from foot inertial sensing, IEEE Transactions on biomedical engineering, 52(3), 486-94.
[81]. Cleland I., Kikhia B., Nugent C., Boytsov A., Hallberg J., Synnes K., et al., 2013, Optimal placement of accelerometers for the detection of everyday activities, Sensors, 13(7), 9183-200.
[82]. Soangra R., 2020, Multi-day longitudinal assessment of physical activity and sleep behavior among healthy young and older adults using wearable sensors, Irbm, 41(2), 80-7.
[83]. Hu B., Li S., Chen Y., Kavi R., Coppola S., 2021, Applying deep neural networks and inertial measurement unit in recognizing irregular walking differences in the real world, Applied Ergonomics, 96, 103414.

[84]. Huynh Q.T., Tran B.Q., 2021, Time-Frequency Analysis of Daily Activities for Fall Detection, Signals, 2(1), 1-12.
[85]. Ruder M.C., Hunt M.A., Charlton J.M., Calvin T., Kobsar D., 2022, Validity and reliability of gait metrics derived from researcher-placed and self-placed wearable inertial sensors, Journal of Biomechanics, 142, 111263.
[86]. Rodriguez-Martin D., Samà A., Pérez-López C., Cabestany J., Català A., Rodríguez-Molinero A., 2015, Posture transition identification on PD patients through a SVM-based technique and a single waist-worn accelerometer, Neurocomputing, 164, 144-53.
[87]. Khan M.H., Farid M.S., Grzegorzek M., 2019, Spatiotemporal features of human motion for gait recognition, Signal, Image and Video Processing, 13, 369-77.
[88]. Ma C., Li D., Pan L., Li X., Yin C., Li A., et al., 2022, Quantitative assessment of essential tremor based on machine learning methods using wearable device, Biomedical Signal Processing and Control, 71, 103244.
[89]. Aliman N., Ramli R., Haris S.M., Amiri M.S., Van M., 2022, A robust adaptive-fuzzy-proportional-derivative controller for a rehabilitation lower limb exoskeleton, Engineering Science and Technology, an International Journal, 35, 101097.
[90]. Nagaraj G., Mir B.A., Gomathy B., Leelavathy S., Sengupta A., Ahmad S.S., editors. Artificial Neural Network to Predict Swinging of Lower Limb in Jumping Jack Exercise. 2023 International Conference on Intelligent Data Communication Technologies and Internet of Things (IDCIoT); 2023: IEEE.
[91]. Lipperts M., van Laarhoven S., Senden R., Heyligers I., Grimm B., 2017, Clinical validation of a body-fixed 3D accelerometer and algorithm for activity monitoring in orthopaedic patients, Journal of Orthopaedic Translation, 11, 19-29.
[92]. Lencioni T., Carpinella I., Rabuffetti M., Marzegan A., Ferrarin M., 2019, Human kinematic, kinetic and EMG data during different walking and stair ascending and descending tasks, Scientific data, 6(1), 309.
[93]. Dhiman C., Vishwakarma D.K., 2019, A review of state-of-the-art techniques for abnormal human activity recognition, Engineering Applications of Artificial Intelligence, 77, 21-45.
[94]. Kang I., Kunapuli P., Hsu H., Young A.J., editors. Electromyography (EMG) signal contributions in speed and slope estimation using robotic exoskeletons. 2019 IEEE 16th International Conference on Rehabilitation Robotics (ICORR); 2019: IEEE.
[95]. Camargo J., Flanagan W., Csomay-Shanklin N., Kanwar B., Young A., 2021, A machine learning strategy for locomotion classification and parameter estimation using fusion of wearable sensors, IEEE Transactions on Biomedical Engineering, 68(5), 1569-78.
[96]. Shawen N., O'Brien M.K., Venkatesan S., Lonini L., Simuni T., Hamilton J.L., et al., 2020, Role of data measurement characteristics in the accurate detection of Parkinson's disease symptoms using wearable sensors, Journal of neuroengineering and rehabilitation, 17, 1-14.
[97]. Bhakta K., Camargo J., Compton W., Herrin K., Young A., 2021, Evaluation of continuous walking speed determination algorithms and embedded sensors for a powered knee & ankle prosthesis, IEEE Robotics and Automation Letters, 6(3), 4820-6.
[98]. Kececi A., Yildirak A., Ozyazici K., Ayluctarhan G., Agbulut O., Zincir I., 2020, Implementation of machine learning algorithms for gait recognition, Engineering Science and Technology, an International Journal, 23(4), 931-7.

[99]. Jia Y., Guo Y., Wang G., Song R., Cui G., Zhong X., 2021, Multi-frequency and multi-domain human activity recognition based on SFCW radar using deep learning, Neurocomputing, 444, 274-87.
[100]. Tam S., Boukadoum M., Campeau-Lecours A., Gosselin B., 2019, A fully embedded adaptive real-time hand gesture classifier leveraging HD-sEMG and deep learning, IEEE transactions on biomedical circuits and systems, 14(2), 232-43.
[101]. Too J., Abdullah A.R., Saad N.M., 2019, Classification of hand movements based on discrete wavelet transform and enhanced feature extraction, International Journal of Advanced Computer Science and Applications, 10(6).
[102]. Nahid N., Rahman A., Ahad M.A., editors. Deep learning based surface EMG hand gesture classification for low-cost myoelectric prosthetic hand. 2020 Joint 9th International Conference on Informatics, Electronics & Vision (ICIEV) and 2020 4th International Conference on Imaging, Vision & Pattern Recognition (icIVPR); 2020: IEEE.
[103]. Ahamed N.U., Krajewski K.T., Johnson C.C., Sterczala A.J., Greeves J.P., Wardle S.L., et al., 2021, Using machine learning and wearable inertial sensor data for the classification of fractal gait patterns in women and men during load carriage, Procedia Computer Science, 185, 282-91.
[104]. Yen C.-T., Liao J.-X., Huang Y.-K., 2020, Human daily activity recognition performed using wearable inertial sensors combined with deep learning algorithms, Ieee Access, 8, 174105-14.
[105]. Zhou B., Wang H., Hu F., Feng N., Xi H., Zhang Z., et al., 2020, Accurate recognition of lower limb ambulation mode based on surface electromyography and motion data using machine learning, Computer Methods and Programs in Biomedicine, 193, 105486.
[106]. Dong D., Ma C., Wang M., Vu H.T., Vanderborght B., Sun Y., 2023, A low-cost framework for the recognition of human motion gait phases and patterns based on multi-source perception fusion, Engineering Applications of Artificial Intelligence, 120, 105886.
[107]. Mohonta S.C., Motin M.A., Kumar D.K., 2022, Electrocardiogram based arrhythmia classification using wavelet transform with deep learning model, Sensing and Bio-Sensing Research, 37, 100502.
[108]. Al Rahhal M.M., Bazi Y., Al Zuair M., Othman E., BenJdira B., 2018, Convolutional neural networks for electrocardiogram classification, Journal of Medical and Biological Engineering, 38, 1014-25.
[109]. Nahak S., Pathak A., Saha G., 2023, Evaluation of handcrafted features and learned representations for the classification of arrhythmia and congestive heart failure in ECG, Biomedical Signal Processing and Control, 79, 104230.
[110]. Çınar A., Tuncer S.A., 2021, Classification of normal sinus rhythm, abnormal arrhythmia and congestive heart failure ECG signals using LSTM and hybrid CNN-SVM deep neural networks, Computer methods in biomechanics and biomedical engineering, 24(2), 203-14.
[111]. Liu T., Yang Y., Fan W., Wu C., 2021, Few-shot learning for cardiac arrhythmia detection based on electrocardiogram data from wearable devices, Digital Signal Processing, 116, 103094.
[112]. Azam F.B., Ansari M.I., Nuhash S.I.S.K., McLane I., Hasan T., 2022, Cardiac anomaly detection considering an additive noise and convolutional distortion model of heart sound recordings, Artificial Intelligence in Medicine, 133, 102417.

[113]. Yildirim O., Talo M., Ay B., Baloglu U.B., Aydin G., Acharya U.R., 2019, Automated detection of diabetic subject using pre-trained 2D-CNN models with frequency spectrum images extracted from heart rate signals, Computers in biology and medicine, 113, 103387.
[114]. Boukhennoufa I., Zhai X., McDonald-Maier K.D., Utti V., Jackson J., editors. Improving the activity recognition using GMAF and transfer learning in post-stroke rehabilitation assessment. 2021 ieee 19th world symposium on applied machine intelligence and informatics (SAMI); 2021: IEEE.
[115]. Shi B., Tay A., Au W.L., Tan D.M., Chia N.S., Yen S.-C., 2022, Detection of freezing of gait using convolutional neural networks and data from lower limb motion sensors, IEEE Transactions on Biomedical Engineering, 69(7), 2256-67.
[116]. Chakraborty J., Nandy A., 2020, Discrete wavelet transform based data representation in deep neural network for gait abnormality detection, Biomedical Signal Processing and Control, 62, 102076.
[117]. Yan M., Guo M., Sun J., Qiu J., Chen X., 2023, Gait Recognition in Different Terrains with IMUs Based on Attention Mechanism Feature Fusion Method, Neural Processing Letters, 1-20.
[118]. Vidya B., Sasikumar P., 2022, Wearable multi-sensor data fusion approach for human activity recognition using machine learning algorithms, Sensors and Actuators A: Physical, 341, 113557.
[119]. Middya A.I., Roy S., Mandal S., 2022, User recognition in participatory sensing systems using deep learning based on spectro-temporal representation of accelerometer signals, Knowledge-Based Systems, 258, 110046.
[120]. Jung D., Nguyen M.D., Arshad M.Z., Kim J., Mun K.-R., editors. Personal Identification Using Gait Spectrograms and Deep Convolutional Neural Networks. 2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC); 2021: IEEE.
[121]. Camargo J., Ramanathan A., Flanagan W., Young A., 2021, A comprehensive, open-source dataset of lower limb biomechanics in multiple conditions of stairs, ramps, and level-ground ambulation and transitions, Journal of Biomechanics, 119, 110320.

EKLER

Ek-1: Makine öğrenmesinde kayan pencereler yönteminin uygulandığı sözde-kod.

Algorithm Sliding window feature extraction for IMU time series data.

Input: Fs, t, winlen, Wearable_Data

Output: Wearable _labels

```
Calculate nSeg = t / winlen
for i from 1 to nFiles
    Read Wearable _Data
    Store Wearable _ labels[i]= Wearable _Data.fileName for classfication labels
    Compute nChn = length(Wearable_Data(i,:))
    for j from 1 to nChn
      Compute  Ct ={cj = Wearable_Data(:,j)}
        for k from 1 to nSeg
            Set segment ranges idx = k : k + winlen -1
            Compute segData = Ct(idx)
            Extract features of segData segfts (:, j, k) = [timeSeriesFts(segData), timeFreqFts(segData)]
            Store average of all segments based on features Wearable _labels{i,2} = mean(segfts)
        end
    end
end
```

İNTİHAL RAPORU İLK SAYFASI

Hacer_Kuduz

ORİJİNALLİK RAPORU

%5	%5	%2	%2
BENZERLİK ENDEKSİ	İNTERNET KAYNAKLARI	YAYINLAR	ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1	Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK) Öğrenci Ödevi	%2
2	acikbilim.yok.gov.tr İnternet Kaynağı	%1
3	aves.akdeniz.edu.tr İnternet Kaynağı	%1
4	real-j.mtak.hu İnternet Kaynağı	<%1
5	dergipark.org.tr İnternet Kaynağı	<%1
6	avesis.akdeniz.edu.tr İnternet Kaynağı	<%1
7	gredos.usal.es İnternet Kaynağı	<%1
8	sporbilimleri.akdeniz.edu.tr İnternet Kaynağı	<%1
9	F.O. Ozkok, M. Celik. "Convolutional Neural Network Analysis of Recurrence Plots for	<%1

Gönderim Tarihi: 04-Ara-2023 06:14PM (UTC+0300)
Gönderim Numarası: 1847014022
Dosya adı: IUC-BME-DoktoraTezi-2602170223-HacerKuduz.pdf (3.39M)
Kelime sayısı: 34342
Karakter sayısı: 207908