

Bası Yaralarının Oluşumunu Önlemek İçin Giyilebilir IMU Sensörler ve Makine Öğrenmesi Yaklaşımı ile Yatış Pozisyonu Tespit ve Takip Sistemi

Rabia Gizemnur EREN¹, Beyda TASAR²

¹ Bilgisayar Teknolojileri Bölümü, Bilişim Teknolojileri Meslek Yüksekokulu, 29 Mayıs Üniversitesi, İstanbul, Türkiye

² Mekatronik Mühendisliği Bölümü, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

✉: btasar@firat.edu.tr  [0000-0002-4689-8579](https://orcid.org/0000-0002-4689-8579)  [0000-0001-7501-486X](https://orcid.org/0000-0001-7501-486X)

Geliş (Received): 23.06.2025

Düzeltilme (Revision):
23.07.2025

Kabul (Accepted): 08.08.2025

ÖZ

Bası yaraları, özellikle mobilite kısıtlılığı yaşayan bireylerde sık karşılaşılan ve yaşam kalitesini olumsuz etkileyen ciddi bir sağlık sorunudur. Bu çalışmada, bası yaralarının önlenmesine katkı sağlamak amacıyla giyilebilir atalet ölçüm birimi (IMU) kullanılarak yatış pozisyonlarının tespit edilmesini sağlayan bir sistem geliştirilmiştir. Göğüs ve bacak bölgelerine yerleştirilen IMU sensörden elde edilen Euler açıları temel alınarak, beş farklı yatış pozisyonu makine öğrenmesi algoritmaları (k-En Yakın Komşu, Karar Ağacı ve Rastgele Orman) ile sınıflandırılmıştır. Çalışmaya, 18-65 yaş aralığında 100 gönüllü katılmıştır. Elde edilen sonuçlar, Rastgele Orman modelinin %99.8 doğruluk ve %99.9 özgünlük ile en yüksek başarıyı gösterdiğini ortaya koymuştur. Geliştirilen sistem, kablosuz veri aktarımı ve kullanıcı konforuna uygun hafif tasarımıyla, özellikle yoğun bakım ve evde bakım ortamlarında bası yarası riskinin azaltılması için etkili bir çözüm sunmaktadır. Ayrıca, sistemin ileri düzey algoritmalar ve sensör entegrasyonları ile geliştirilerek bireyselleştirilmiş hasta takibine yönelik uygulanabilirliği tartışılmıştır. Sonuçlar, sistemin klinik kullanıma uygun, taşınabilir ve güvenilir bir destek aracı olabileceğini göstermektedir.

Anahtar Kelimeler: Bası Yarası Önleme, Giyilebilir Teknolojiler, IMU Sensörler, Yatış Pozisyonu Takibi, Makine Öğrenmesi

A System for Detection and Monitoring of Sleeping Postures Using Wearable IMU Sensors and Machine Learning Approach to Prevent Pressure Ulcers

ABSTRACT

Pressure ulcers are a serious health issue frequently encountered in individuals with mobility limitations and negatively affect quality of life. In this study, a system was developed to detect lying positions using a wearable Inertial Measurement Unit (IMU) in order to contribute to the prevention of pressure ulcers. Based on the Euler angles obtained from IMU sensors placed on the chest and leg regions, five different lying positions were classified using machine learning algorithms (k-Nearest Neighbor, Decision Tree, and Random Forest). A total of 100 volunteers aged between 18 and 65 participated in the study. The results showed that the Random Forest model achieved the highest performance with 99.8% accuracy and 99.9% specificity. The developed system offers an effective solution for reducing the risk of pressure ulcers, especially in intensive care and home care environments, with its wireless data transmission and lightweight design suitable for user comfort. In addition, the applicability of the system for personalized patient monitoring through integration with advanced algorithms and additional sensors was discussed. The findings suggest that the system can serve as a portable, reliable, and clinically applicable support tool.

Keywords: Pressure Ulcers Prevention, Wearable Technologies, IMU Sensors, Bed Position Tracking, Machine Learning

GİRİŞ

Tıbbî bilimler ve teknoloji alanındaki hızlı ilerlemeler, küresel ölçekte insan yaşam süresinin belirgin şekilde uzamasına olanak sağlamış ve bu artış eğiliminin

önümüzdeki yıllarda da devam edeceği öngörülmektedir. Bununla birlikte, yaşam süresindeki uzama, özellikle ileri yaş popülasyonundaki artışla birlikte yeni sağlık sorunlarının ortaya çıkmasına zemin hazırlamıştır. Bu sorunlar arasında, uzun süreli immobilizasyon

sonucunda gelişen ve yönetimi oldukça güç olan bası yaraları önemli bir yer tutmaktadır [1]. Mobilite kısıtlılığı yaşayan bireylerde bası yaralarının insidansının yüksek olması, bu sağlık sorununun önlenmesine yönelik yenilikçi teknolojik çözümlere olan ihtiyacı daha da belirgin hale getirmektedir.

Bası yaraları, toplumda sıklıkla “yatak yarası” olarak bilinen ve cilt ile cilt altı dokuların uzun süreli basınca maruz kalması sonucunda gelişen lokal doku hasarlarıdır. Sürekli basınç etkisi, doku perfüzyonunun azalmasına ve oksijen yetersizliğine neden olmakta, bu durum da nekroz ile sonuçlanmaktadır [2]. Bu yaralar, özellikle felçli bireylerde, kronik hastalığı bulunanlarda, uzun süre yatakta veya tekerlekli sandalyede kalan hastalarda yaygın olarak gözlemlenmektedir. Risk grupları arasında yaşlı bireyler, diyabet hastaları, beslenme yetersizliği yaşayanlar ve cilt hijyeni sağlanamayan hastalar yer almaktadır. Bası yaralarının en sık lokalize olduğu anatomik bölgeler arasında kalça, sakrum, omurga, skapula ve ekstremitelerin arka yüzeyleri bulunmaktadır [3].

Bası yaralarının patogenezinde, cilt yüzeyinde basınç birikimi ile başlayan dolaşım bozukluğu temel rol oynamaktadır. Sürekli basınca maruz kalan dokular, yeterli oksijen ve besin maddesi alamadığından hücrel ölüm meydana gelmekte ve bu süreç açık yaraların oluşumuyla sonuçlanmaktadır. Avrupa Bası Yaraları Danışma Paneli (European Pressure Ulcer Advisory Panel, EPUAP) tarafından önerilen sınıflamaya göre bası yaraları dört evrede değerlendirilmektedir [4]. Evre 1: Cilt bütünlüğü bozulmamıştır; ancak eritem ve hassasiyet gözlemlenir. Erken müdahale ile ilerleyici doku hasarı önlenbilir. Evre 2: Epidermis ve/veya dermisin kısmi kaybı söz konusudur; yara genellikle pembe veya kırmızı renkte olup nemlidir. Evre 3: Hasar, cilt altı yağ dokusuna kadar ilerlemiş olup nekrotik doku izlenebilir. Evre 4: Lezyon, kas ve kemik dokusuna kadar

derinleşmiş olup, bu aşamada enfeksiyon riski belirgin şekilde artmaktadır [5].

Bası yaraları, uygun şekilde yönetilmediği takdirde enfeksiyon, osteomyelit ve sepsis gibi yaşamı tehdit edebilecek komplikasyonlara neden olabilir. Klinik gözlemler, bası yaralarının yoğun bakım ünitelerinde %10-18 arasında bir görülme sıklığına sahip olduğunu, evde bakım hizmetlerinde ise bu oranın %29'a kadar yükseldiğini ortaya koymaktadır [6]. Bası yaraları, bireysel yaşam kalitesinde ciddi düşüşlere yol açarken, sağlık sistemlerine de gerek zaman gerekse ekonomik açıdan ciddi bir yük getirmektedir.

Bası yaralarının önlenmesine yönelik geleneksel yaklaşımlar; hastaların düzenli aralıklarla pozisyonlarının değiştirilmesi ve birebir hasta takibinin sağlık profesyonelleri tarafından gerçekleştirilmesi esasına dayanmaktadır. Ancak, sağlık kuruluşlarındaki artan hasta yoğunluğu ve sınırlı personel kaynağı bu yöntemlerin sürdürülebilirliğini olumsuz etkilemektedir [7,8,9]. Üstelik manuel takip yöntemleri hem zaman alıcıdır hem de insan hatasına açık bir yapı sergilemektedir [10,11]. Bu zorluklar, sağlık hizmetlerinde teknoloji destekli yenilikçi çözümlerin kaçınılmaz olduğunu göstermektedir.

LİTERATÜR ÖZETİ

Son yıllarda geliştirilen giyilebilir sensör teknolojileri, sağlık alanında önemli bir paradigma değişimi yaratmış ve bireylerin anatomik ve fizyolojik parametrelerinin yanı sıra çevresel faktörlerin de gerçek zamanlı olarak izlenmesine imkân tanımıştır.

Bu çalışmada literatürde farklı sensör ve yöntemlerle yatış pozisyonu tespiti üzerine yapılan çalışmalara ilişkin karşılaştırmalı bir analiz Tablo 1'de sunulmuştur. Tablo, çalışmalardaki katılımcı sayısı, kapsanan yatış pozisyonu sayısı, kullanılan sensör türü, uygulanan algoritma ya da model ve elde edilen başarı yüzdesi gibi temel yapısal bilgileri içermektedir.

Tablo 1. Yatış Pozisyon tespiti çalışmalarına ilişkin literatür analizi

Yazar (Yıl)	Katılımcı Sayısı	Uyku Pozisyonları	Sensörler	Algoritma/Model	Sonuç (%)
Liu ve diğ. (2017) [12]	16	4	Veri Toplama Modülü	OVO-SVM, YSA, LDA	99.67
Fallmann ve diğ. (2017) [13]	6	10	3 Shimmer3 IMU sensörü	GMLVQ	83.62
Zhang, Wang & Guo (2018) [14]	10	10	PIR sensör	En yakın komşu tanımlama	83.55
Liu & Ye (2018) [15]	12	4	BCG, Piezoelektrik film sensörü	Bayes Sınıflandırma	97
Mohammadi ve diğ. (2018) [16]	12	12	Kinect derinlik kamerası	CNN	91
Li & Lei (2018) [17]	22	10	Kinect, RGB Kamera	Çok akışlı CNN'ler	90.9
Eyobu ve diğ. (2018) [18]	Belirtilmemiş	4	IMU sensör	LSTM-RNN	99.09
Kido ve diğ. (2019) [19]	12	3	cECG cihazı	CNN modelleri: qua_model, pos_model	99
Liu ve diğ. (2019) [20]	300	6	Esnek piezorezistif sensör	CNN	97.2
Jeon ve diğ. (2019) [21]	11	4	3 IMU sensörü	DST-SVM, DST-RF	99


Akbarian ve diğ. (2019) [22]	50	2	Kızılötesi kamera	ResNet50, MobileNet, Darknet19	87
Mondragon ve diğ. (2020) [23]	1	3	Kinect kamera	CNN	84
Cao ve diğ. (2020) [24]	8	6	CSI Wi-Fi verisi	Ind-RNN	93.5
Yue ve diğ. (2020) [25]	26	4	BodyCompass RF sinyali	YSA	94
Diao ve diğ. (2021) [26]	16	2	FSR sensörlü mat	ResNet	95.08
Chen & Wang (2021) [27]	12	9	Termopil dizi sensörü	HOG+PCA, SVM, DT, RF, Gradyan Artırma, MLP	99.8
Hu ve diğ. (2021) [28]	5	6	Basınca duyarlı sensör matrisi	CNN	91.24
Tam ve diğ. (2021) [29]	66	7	RGB + IR derinlik görüntü	CNN	88.9
Zhou ve diğ. (2021) [30]	3	8	FMCW mmw radar sistemi	Inception-Residual CNN	98.8
Piriyajitakonkij ve diğ. (2021) [31]	38	4	UWB radar	SleepPoseNet (SPN)	-
Tang ve diğ. (2021) [32]	Belirtilmemiş	4	Basınç, FSR, piezorezistif sensörler	Transfer öğrenmeli CNN	90
Islam & Lubecke (2022) [33]	20	3	Doppler radar	KNN, SVM, DT	98.4
Li ve diğ. (2021) [34]	4	3	RGB Kamera	FrCNN Net	91.7
Xing, Gao & Chuai (2022) [35]	Belirtilmemiş	4	Piezoelektrik seramik	Kayan pencere işleme	89.53
Mohammadi ve diğ. (2021) [36]	11	5	Aktif IR kamera	De novo CNN, Transfer öğrenme	95.1
Lai ve diğ. (2023) [37]	18	4	2 radar	LR, SVM, XGBoost, RF, ResNet, DenseNet, Transformer	93.8
Jesmen ve diğ. (2023) [38]	6	3	Kamera	CNN	99.59
Intongkum ve diğ. (2023) [39]	1	5	Vücuda takılı ivmeölçer	KNN	93
Kau ve diğ. (2023) [40]	2	5	Basınca duyarlı mat	CNN	99.98
Stern ve diğ. (2023) [41]	13	3	Basınç matı	2D DNN	99.97
He ve diğ. (2024) [42]	15	4	IMU ve basınç sinyalleri	BCG, CNN	94.44
Khan ve diğ. (2024) [43]	10	6	RGB ve termal kamera	SVM	99
Khan ve diğ. (2024) [44]	9	5	RGB ve termal görüntüleme	KNN	99.2
Xu ve diğ. (2024) [45]	41	4	Basınç sensörlü hava yastığı mat	Stacking	94.48
Liu ve diğ. (2024) [46]	10	6	mmWave radar	DNN	98
Lai ve diğ. (2024) [47]	30	4	IR-UWB radarlar	Vision Transformer ve Swin Transformer	80.8
Hu ve diğ. (2024) [48]	22	3	Piezoelektrik seramik sensör dizileri	S3CNN	93.02
Lai ve diğ. (2024) [49]	70	7	Xethru X4M03 Radar	MWCNN + DenseNet121	80.9

KATKILAR VE ÖZGÜNLÜK

Bu çalışma kapsamındaki katkılar özetlenecek olursa;

- Bası yaralarının önlenmesine yönelik giyilebilir atalet ölçüm birimi (IMU) tabanlı bir sistem tasarlayarak literatüre özgün

katkılar sağlamaktadır. Literatürde genellikle basınç matları, radar sistemleri ve kamera tabanlı çözümler kullanılırken, bu çalışmada düşük maliyetli, hafif ve kullanımı kolay bir giyilebilir sistem geliştirilmiş; klinik kullanım potansiyeline sahip bir prototip sunulmuştur.



Şekil 1. Yöntemin şematik gösterimi

- Geliştirilen sistemde, IMU sensörlerinden elde edilen Euler açıları kullanılarak beş farklı yatış pozisyonu sınıflandırılmıştır. 100 gönüllüden toplanan geniş kapsamlı veri seti, mevcut çalışmaların sınırlı veri yapısına kıyasla daha güvenilir bir analiz imkânı sağlamıştır. Çalışmada, K-En Yakın Komşu, Karar Ağacı ve Rastgele Orman gibi farklı makine öğrenmesi algoritmaları karşılaştırılmış; en yüksek başarı oranı %99 doğruluk ile Rastgele Orman modeli tarafından elde edilmiştir.
- Bu çalışma ayrıca, IMU sensörlerine dayalı kablosuz veri toplama ve gerçek zamanlı analiz özellikleri ile klinik pratikte uygulanabilir, ergonomik ve kullanıcı konforunu ön planda tutan bir çözüm önermektedir. Elde edilen yüksek sınıflandırma başarımı, sistemin yoğun bakım üniteleri ve evde bakım uygulamaları için etkili bir destek aracı olabileceğini göstermektedir.

Sonuç olarak, geliştirilen prototip, mevcut izleme sistemlerine göre daha taşınabilir ve erişilebilir bir alternatif sunmakta; sağlık hizmetlerinde baskı yaralarının önlenmesi için önemli bir teknoloji temelli çözüm olarak literatüre özgün bir katkı getirmektedir.

MATERYAL ve YÖNTEM


Şekil 1, çalışmada geliştirilen yatış pozisyonu tespit sisteminin genel işleyiş sürecini şematik olarak özetlemektedir. Sistem, giyilebilir IMU sensörlerinden elde edilen hareket verilerinin mobil cihazlar aracılığıyla kablosuz olarak toplanmasını ve kaydedilmesini temel almaktadır. Toplanan bu ham veriler, Euler açılarına

(yunuslama, yuvarlanma ve sapma) dönüştürülerek bir özellik kümesi

oluşturulmakta ve sınıflandırma algoritmalarına giriş verisi olarak kullanılmaktadır. Elde edilen veriler üzerinde makine öğrenmesi tabanlı sınıflandırma algoritmaları (K-En Yakın Komşu, Karar Ağacı, Rastgele Orman) uygulanarak bireyin yatış pozisyonu yüksek doğrulukla tespit edilmektedir. Bu yapı, baskı yaralarının önlenmesi için gerekli olan yatış pozisyonu değişimlerini gerçek zamanlı izlemeye olanak tanıyarak sistemin hem klinik hem de evde bakım uygulamaları için etkin bir şekilde kullanılabilmesini sağlamaktadır.

A. Giyilebilir kablosuz sensörler ile hasta yatış takip sistemi için İMU sensörlerden veri toplanması

Çalışmada geliştirilen yatış pozisyonu takip kıyafetine ait ön tasarım Şekil 2’de yer almaktadır. Bu tasarımda, göğüs ve bacak bölgelerine yerleştirilecek olan IMU sensörleri, yumuşak ve esnek özellikte, cilt yüzeyinde baskı veya tahrişe neden olmayacak özel bir tekstil malzemesine sabitlenmiştir. IMU sensörleri, Movella DOT sensör uygulaması aracılığıyla mobil cihazlarla kablosuz iletişim kurmakta ve veri transferi gerçekleştirmektedir. Giyilebilir sensör kıyafette kullanılan sensörler tamamen girişimsel olmayandır; cilde veya cilt altı dokulara herhangi bir zarar vermemekte, kullanıcıda ağrı veya rahatsızlık oluşturmamaktadır. Veri toplama işlemi sırasında herhangi bir tıbbi müdahale, örneğin anestezi uygulaması veya yaşamsal bulgu ölçümü yapılmamıştır. Kıyafetin toplam ağırlığı yaklaşık 200 gram olup, kullanıcı konforunu olumsuz etkilemeyecek şekilde hafif tasarlanmıştır.



Şekil 2. Tasarıma ilişkin çizim ve veri toplama anında çekilen örnek fotoğraflar

Şekil 2’de kıyafetin tasarım aşamasına ilişkin çizimler ve veri toplama sürecinde çekilen örnek fotoğraflar sunulmaktadır. Çalışma kapsamında, etik kurallar çerçevesinde bilgilendirilmiş onam formu imzalayan 100 gönüllüden veri toplanmıştır. Katılımcı seçiminde, okuryazar olmak, herhangi bir nörolojik, ortopedik ya da sistemik hastalığa sahip olmamak, kol ve bacak uzuvlarının sağlam olması ve sözlü komutlara yanıt verebilecek şekilde işitme ve konuşma yetilerinin bulunması kriterleri aranmıştır. Katılımcıların yaş aralığı 18-65 arasında değişmekte olup, 16’sı erkek ve 84’ü kadındır. Gönüllülerin 90’ı sağlıklı bireylerden, 10’u ise Fırat Üniversitesi Araştırma Hastanesi’nde tedavi görmekte olan hastalar arasından seçilmiştir. Hazırlık ve veri kayıt işlemleri toplamda 20 dakika içerisinde tamamlanmıştır. Her bir yatış pozisyonu için bir dakikalık veri kaydı alınmış ve toplamda beş dakikalık veri setleri oluşturulmuştur. Çalışmada kullanılan beş yatış pozisyonu sırasıyla: sırtüstü yatış, sağa dönük bacaklar düz pozisyonunda yatış, sağa dönük bacaklar diz kapağından bükülerek gövdeye çekilmiş yatış, sola dönük bacaklar düz pozisyonunda yatış ve sola dönük bacaklar diz kapağından bükülerek gövdeye çekilmiş yatış olarak belirlenmiştir.

B. Hareket sınıflandırma algoritmalarının geliştirilmesi ve yatış pozisyon tipi tespiti

Yatış pozisyonlarının sınıflandırılması için öncelikle her bir IMU sensörden okunan euler (yunuslama, yuvarlanma ve sapma) açıları (her bir IMU için) birleştirilerek özellik kümesi olarak sınıflandırma algoritmasına girdi olarak verilmiştir. Yatış

pozisyonunun tespiti için temel makine öğrenme algoritmaları (En yakın komşu, karar ağacı, rastgele orman algoritması) geliştirilecektir. Çalışma kapsamında kullanılan sınıflandırma algoritmaları kısaca özetlenmiştir.

Karar ağacı, veri setlerini belirli özelliklere göre dallara ayırarak sınıflandırma yapan denetimli bir öğrenme yöntemidir. Basit yapısı ve yorumlanabilirliği sayesinde yaygın olarak kullanılmaktadır. Ağaç yapısı, veri setini en iyi şekilde ayıran özellik seçilerek oluşturulur ve dallanmalar sonlandırma kriterlerine bağlı olarak devam eder.

K-En Yakın Komşu algoritması, eğitim aşaması gerektirmeyen, örnek tabanlı bir sınıflandırma yöntemidir. Bir veri noktasının sınıfı, kendisine en yakın k komşusunun sınıflarına göre belirlenir. Bu çalışmada, veri noktaları arasındaki benzerlik ölçümü için Öklid mesafesi kullanılmıştır. K değeri, çapraz doğrulama ile optimize edilmiştir.

Rastgele Orman algoritması, birden fazla karar ağacından oluşan topluluk (ensemble) yöntemidir. Her ağaç, veri setinin farklı alt kümesi ve özellikleri ile eğitilir; sonuçlar çoğunluk oylaması ile birleştirilir. Bu yapı, aşırı uyum riskini azaltır ve modelin genelleme yeteneğini artırır. Parametre ayarlamaları, ağaç sayısı ve maksimum derinlik gibi kriterlerle yapılır.

Çalışmada kullanılan üç sınıflandırma algoritmasına ait parametre yapılandırmaları Tablo 2’de detaylı olarak sunulmuştur. Bu yapılandırmalar, her algoritmanın performansını optimize etmek amacıyla literatürde önerilen değerler doğrultusunda belirlenmiş ve çapraz doğrulama ile test edilmiştir.

Tablo 2. Bu çalışmada kullanılan sınıflandırma yöntemlerine ilişkin parametreler

Algoritma	Parametre	Değer	Parametre	Değer
En Yakın Komşu Algoritması	Komşu Sayısı	5	Mesafe Ölçüm Derecesi (p=1 Manhattan, p=2 Euclidean)	2 (Euclidean mesafe)
	Ağırlıklandırma Yöntemi	'uniform'	Mesafe Ölçütü (KNN için)	'minkowski'
	Komşu Arama Algoritması	'auto'	Mesafe Ölçütü Parametreleri	None
	Yaprak Boyutu (KNN için)	30	Paralel İşlem Sayısı	None
Karar Ağacı	Bölme Ölçütü (Safsızlık Ölçütü)	'gini'	Maksimum Özellik Sayısı	None
	Bölme Stratejisi	'best'	Rastgelelik Tohumu (Random Seed)	None
	Maksimum Ağaç Derinliği	None	Maksimum Yaprak Düğüm Sayısı	None
	Düğüm Bölmek İçin Gerekli Minimum Örnek Sayısı	2	Minimum Safsızlık (Impurity) Azalması	0.0
Rastgele Orman	Yaprak Düzümdeki Minimum Örnek Sayısı	1	Sınıf Ağırlıkları	None
	Yaprak Düzümdeki Minimum Ağırlık Oranı	0.0	Karmaşıklık Düzeltme Pruning (Budama) Parametresi	0.0
	Ağaç Sayısı (Rastgele Orman için)	100	Bootstrap Örnekleme Kullanımı	True
	Bölmede Kullanılacak Maksimum Özellik Sayısı	'gini'	Çanta Dışı (Out-of-Bag) Skoru	False
Rastgele Orman	Maksimum Yaprak Düzüm Sayısı	None	Detaylı Çıktı Seviyesi (Çalışma Bilgisi Baskısı)	None
	Minimum Safsızlık Azalması	2	Modelin Önceki Sonuçlarla Devam Etmesi	None
	Komşu Sayısı	1	Bootstrap İçin Maksimum Örnek Sayısı	0
	Ağırlıklandırma Yöntemi	0.0	Mesafe Ölçüm Derecesi (p=1 Manhattan, p=2 Euclidean)	False
Rastgele Orman	Komşu Arama Algoritması	'sqrt'	Mesafe Ölçütü (KNN için)	None
	Yaprak Boyutu (KNN için)	None	Mesafe Ölçütü Parametreleri	0.0
	Bölme Ölçütü (Safsızlık Ölçütü)	0.0	Paralel İşlem Sayısı	None

C. Sınıflandırma Algoritmalarının Performans Kriterleri

Sınıflandırma algoritmalarının etkinliğini değerlendirmek amacıyla farklı performans ölçütleri kullanılmaktadır. Bu ölçütler, modelin doğruluk kapasitesini ve sınıflandırmadaki başarımını anlamak için önemli bilgiler sunar. Kullanılacak metrikler, veri kümesinin dengesi ve problemin gereksinimleri doğrultusunda belirlenir. Çalışmada en sık kullanılan doğruluk, seçicilik, duyarlılık ve F1 skoru gibi temel


ölçütler esas alınmıştır [50]. Bu çalışmada kullanılan performans metrikleri Tablo 3'de özetlenmiştir.

BULGULAR Ve TARTIŞMA

Yöntem kısmında detayları sunulan sınıflandırma algoritmalarına ilişkin kodlamalar Python dilinde Kaggle platformunda geliştirilmiştir. Kaggle platformu üzerinde yazılım GPU desteği ile koşturulmuş ve başarı metrikleri hesaplanmıştır. Bir kişiden beş yatış pozisyonu için IMU sensörden toplanan örnek Euler açıları değişim grafiği Şekil 3'de görselleştirilmiştir

Tablo 3. Performans metrikleri

Metrik	Tanım	Formül
Doğruluk	Modelin doğru sınıflandırdığı örneklerin, toplam örnekler içindeki oranıdır.	$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN}$
Seçicilik	Pozitif olarak tahmin edilen örnekler içindeki doğru sınıfların oranıdır.	$\text{Seçicilik} = \frac{DP}{DP + YP}$
Duyarlılık	Gerçek pozitif örneklerin ne kadarının doğru tahmin edildiğini gösterir.	$\text{Duyarlılık} = \frac{DP}{DP + YN}$
F1 Skoru	Seçicilik ve duyarlılık arasında denge kuran harmonik ortalamadır. Veri dengesizliğinde kullanımı uygundur.	$\text{F1 Skor} = 2x \frac{\text{Seçicilik} \times \text{Hassasiyet}}{\text{Seçicilik} + \text{Hassasiyet}}$



Şekil 3. Bir gönüllüden alınan örnek sağ, sol bacak ve gövde euler açıları grafiği

Şekil 3'te, bir gönüllüye ait sağ bacak (IMU1), sol bacak (IMU2) ve göğüs (IMU3) bölgelerine yerleştirilen IMU sensörlerinden elde edilen Euler açıları (x: yunuslama, y: yuvarlanma, z: sapma) zaman eksenine göre görselleştirilmiştir. Grafiklerde her pozisyon için yaklaşık 60 saniyelik veri yer almaktadır.

Göğüs sensörü (IMU3) açısından bakıldığında, sırtüstü pozisyonda sapma (Euler_z) açısı belirgin şekilde sıfıra yakınken, yan pozisyonlarda $\pm 30^\circ$ ile $\pm 90^\circ$ arasında değiştiği gözlenmiştir. Bacak sensörleri (IMU1 ve IMU2) için özellikle yunuslama (Euler_x) değerlerinde, bacakların düz ya da katlanmış olmasına bağlı olarak dalgalanma eğilimleri tespit edilmiştir. Bacakların gövdeye doğru çekildiğinde Euler_x ve y değerlerinin mutlak değeri artmakta, düz pozisyonlarda ise stabil seyretmektedir.

Tüm sensörlerde görülen açı değişimleri, beş farklı yatış pozisyonunun hem uzuv hareketi hem de gövde oryantasyonu açısından ayırt edici nitelikte olduğunu doğrulamaktadır. Bu açısal farklılıklar, sınıflandırma algoritmalarının yatış pozisyonlarını başarıyla ayırt edebilmesinin temelini oluşturmuş ve sistemin yüksek doğrulukla çalışmasını sağlamıştır.

Tablo 4'te, yüz katılımcıdan elde edilen IMU sensör verilerine ilişkin özet istatistikler sunulmaktadır. IMU1, IMU2 ve IMU3 sensörleri sırasıyla sağ bacak, sol bacak ve göğüs bölgelerine yerleştirilmiştir. Euler açıları, x, y ve z eksenleri etrafındaki yatay, dikey ve uzunlamasına

rotasyonel hareketleri temsil etmektedir. Her eksen için 100 bireyden toplamda 1.800.000 ölçüm kaydı alınmıştır. Ortalama değerler bireylerin genel hareket eğilimlerini yansıtırken, minimum, maksimum ve çeyrek değerler veri dağılımını ve varyasyonunu ortaya koymaktadır. Özellikle göğüs bölgesine yerleştirilen sensör (IMU1) ile bacaklara yerleştirilen sensörler (IMU2 ve IMU3) arasında gözlenen belirgin dağılım farkları, yatış pozisyonlarında vücut segmentlerinin farklı açısal konumlar sergilediğini göstermektedir. Verilerin geniş dağılım aralıkları, yatış pozisyonlarındaki çeşitliliği yansıtırken, yüksek standart sapma ve çeyrek aralık değerleri, bu çeşitliliğin istatistiksel olarak anlamlı düzeyde olduğunu desteklemektedir. Elde edilen bu veriler, bireylerin hareket örüntülerinin detaylı bir şekilde analiz edilmesine ve yatış pozisyonlarının sınıflandırılmasına temel oluşturmuştur.

Oluşturulan veri seti için sınıf etiketleri Sınıf 1: sırtüstü yatış, Sınıf 2: sağa dönük bacaklar düz pozisyonda yatış, Sınıf 3: sağa dönük bacaklar diz kapağından katlı gövdeye çekilmiş yatış, Sınıf 4: sola dönük bacaklar düz pozisyonda yatış, Sınıf 5: sola dönük bacaklar diz kapağından katlı gövdeye çekilmiş yatış olarak tanımlanmıştır. Sınıflandırma aşamasına geçilmeden veri seti 70:30 – 80:20 ve 90:10 oranında rastgele olarak eğitim ve test kümesi olarak ayrılmıştır. Yöntemlerin başarı oranları test kümesi sonuçlarına göre hesaplanmış

ve karşılaştırılmıştır. Ayrıca veri setinin bölüntüleme oranının başarıya olan etkisi de kıyaslanmıştır.

Tablo 4. IMU Veri Setine ait özellikler

Özellikler	IMU1 Euler_x Yunuslama	IMU1 Euler_y Yuvarlanma	IMU1 Euler_z Sapma	IMU2 Euler_x Yunuslama	IMU2 Euler_y Yuvarlanma	IMU2 Euler_z Sapma	IMU3 Euler_x Yunuslama	IMU3 Euler_y Yuvarlanma	IMU3 Euler_z Sapma
Örnek Sayısı	1,800,000	1,800,000	1,800,000	1,800,000	1,800,000	1,800,000	1,800,000	1,800,000	1,800,000
Ortalama	-20.83	-1.57	-42.10	-37.43	-0.99	-24.08	-40.19	2.42	-22.67
Standart Sapma	54.47	64.21	72.57	91.94	62.00	101.80	95.20	61.64	87.56
Minimum	-180.00	-89.94	-179.99	-180.00	-89.86	-180.00	-180.00	-89.76	-180.00
25%	-36.23	-72.89	-98.32	-113.78	-66.89	-107.62	-132.75	-64.65	-84.36
Orta değer (50%)	-11.55	-0.92	-60.18	-25.35	-7.50	-51.29	-20.72	6.56	-37.12
75%	3.91	66.49	5.62	-2.04	65.88	63.12	-0.48	67.05	44.75
Maximum	180.00	89.95	180.00	180.00	89.74	180.00	180.00	89.90	180.00

Tablo 5’deki sonuçlar, En Yakın Komşu (k-NN), Karar Ağacı ve Rastgele Orman sınıflandırıcılarının farklı eğitim-test veri oranlarında yatış pozisyonlarını sınıflandırmadaki performansını göstermektedir. Tüm modeller yüksek doğruluk, seçicilik, özgünlük ve F1 skor değerleri sergilemiştir. Özellikle Rastgele Orman modeli, tüm veri ayırma oranlarında (70:30, 80:20 ve 90:10) en yüksek başarıyı göstermiştir. Bu model, %99.9 doğruluk ve %99.4 F1 skoru ile diğer algoritmaların önüne geçmiştir. k-NN modeli de benzer şekilde oldukça yüksek doğruluk değerleri üretmiş (%99.6-%99.7), ancak özellikle sınıf bazlı detaylarda Rastgele Orman’a kıyasla hafif geride kalmıştır. Karar Ağacı modeli ise diğer iki yöntemle karşılaştırıldığında daha düşük, ancak yine de oldukça yüksek bir performans (%99.1-%99.2 doğruluk) sergilemiştir.


Sınıflar bazında incelendiğinde, tüm modellerde sınıflar arasında performans farkları minimal olup, sınıflar arası

dengeşizliğin başarı oranlarına belirgin bir etkisi gözlenmemiştir. Seçicilik ve özgünlük oranlarının da tüm modellerde %99 üzeri olduğu dikkat çekmektedir, bu da yanlış pozitif ve yanlış negatif sınıflandırmaların çok düşük olduğunu göstermektedir. Çalışmada oluşturulan konfüzyon matrisleri (Şekil 4), tüm sınıflandırıcıların yüksek doğrulukla çalıştığını göstermektedir. k-En Yakın Komşu ve Rastgele Orman modelleri, neredeyse tüm yatış pozisyonlarını hatasız sınıflandırırken, Karar Ağacı modelinde düşük seviyede de olsa bazı sınıflar arasında karışmalar gözlenmiştir. Özellikle Rastgele Orman modeli, minimum hata oranı ile en yüksek sınıflandırma başarısını sağlamıştır. Diyagonal dışı değerlerin yok denecek kadar az olması, sistemin yatış pozisyonlarını yüksek hassasiyet ve özgünlükle ayırt edebildiğini ortaya koymaktadır. Sonuçlar, önerilen yöntemin klinik uygulamalarda güvenilir şekilde kullanılabileceğini desteklemektedir.

Tablo 5. Sınıflandırma yöntemlerinin performansı

	Sınıflandırıcı Modeli	Metrikler	Sınıf 1	Sınıf 2	Sınıf 3	Sınıf 4	Sınıf 5	Toplam
%70 eğitim %30 test veri oranı için	En Yakın Komşu	Doğruluk	0,9998	0,9996	0,9995	0,9993	0,9995	0,9996
		Seçicilik	0,9997	0,999	0,999	0,9982	0,9986	0,9989
		Özgünlük	0,9999	0,9998	0,9997	0,9995	0,9998	0,9997
		F1	0,9996	0,999	0,9988	0,9982	0,9988	0,9989
	Karar Ağacı	Doğruluk	0,9997	0,9988	0,9989	0,9987	0,9993	0,9991
		Seçicilik	0,9993	0,997	0,9974	0,9966	0,9983	0,9977
		Özgünlük	0,9998	0,9992	0,9993	0,9992	0,9996	0,9994
		F1	0,9991	0,997	0,9973	0,9967	0,9984	0,9977
	Rastgele Orman	Doğruluk	0,9999	0,9997	0,9997	0,9995	0,9997	0,9997
		Seçicilik	0,9997	0,9995	0,9991	0,9989	0,9987	0,9992
		Özgünlük	0,9999	0,9997	0,9998	0,9996	0,9999	0,9998
		F1	0,9997	0,9992	0,9992	0,9988	0,9992	0,9992
%80 eğitim %20 test veri oranı için	En Yakın Komşu	Doğruluk	0,9999	0,9997	0,9996	0,9994	0,9996	0,9996
		Seçicilik	0,9997	0,999	0,9993	0,9984	0,9987	0,9990
		Özgünlük	0,9999	0,9998	0,9997	0,9996	0,9998	0,9998
		F1	0,9997	0,9992	0,999	0,9984	0,9989	0,9990
	Karar Ağacı	Doğruluk	0,9996	0,9989	0,999	0,9987	0,9993	0,9991
		Seçicilik	0,9991	0,9971	0,9977	0,9964	0,9984	0,9977

%90 eğitim %10 test veri oranı için	Rastgele Orman	Özgünlük	0,9997	0,9993	0,9993	0,9992	0,9996	0,9994
		F1	0,999	0,9972	0,9975	0,9966	0,9983	0,9977
		Doğruluk	0,9999	0,9998	0,9998	0,9996	0,9997	0,9997
		Seçicilik	0,9998	0,9995	0,9995	0,9992	0,9988	0,9994
		Özgünlük	0,9999	0,9998	0,9998	0,9997	1	0,9998
	En Yakın Komşu	F1	0,9997	0,9994	0,9994	0,9989	0,9993	0,9994
		Doğruluk	0,9999	0,9997	0,9997	0,9995	0,9996	0,9997
		Seçicilik	0,9997	0,9991	0,9996	0,9988	0,9988	0,9992
		Özgünlük	0,9999	0,9999	0,9998	0,9997	0,9998	0,9998
		F1	0,9997	0,9993	0,9993	0,9987	0,999	0,9992
	Karar Ağacı	Doğruluk	0,9997	0,999	0,9992	0,9988	0,9993	0,9992
		Seçicilik	0,9993	0,9976	0,9981	0,9968	0,9985	0,998
		Özgünlük	0,9998	0,9994	0,9995	0,9993	0,9996	0,9995
		F1	0,9992	0,9976	0,998	0,9969	0,9983	0,998
	Rastgele Orman	Doğruluk	0,9999	0,9998	0,9998	0,9997	0,9998	0,9998
		Seçicilik	0,9997	0,9995	0,9996	0,9994	0,9989	0,9994
		Özgünlük	0,9999	0,9998	0,9998	0,9997	1	0,9999
		F1	0,9998	0,9994	0,9995	0,9991	0,9994	0,9994



Şekil 4. Sınıflandırmanın karışıklık matrisleri

Tablo 6. Üç farklı eğitim –test bölüntüleme oranı için sınıflandırma yöntemlerinin ortalama performansı

Sınıflandırıcı Modeli	Eğitim-Test Oranı	Doğruluk	Seçicilik	Özgünlük	F1	Eğitim Süresi (s)
En Yakın Komşu	%70-%30	0,9996	0,9989	0,9997	0,9989	3.12
	%80-%20	0,9996	0,9990	0,9998	0,9990	26.78
	%90-%10	0,9997	0,9992	0,9998	0,9992	120.45
Karar Ağacı	%70-%30	0,9991	0,9977	0,9994	0,9977	3.65
	%80-%20	0,9991	0,9977	0,9994	0,9977	30.12
	%90-%10	0,9992	0,998	0,9995	0,998	138.89
Rastgele Orman	%70-%30	0,9997	0,9992	0,9998	0,9992	4.13
	%80-%20	0,9997	0,9994	0,9998	0,9994	34.28
	%90-%10	0,9998	0,9994	0,9999	0,9994	155.06

Tablo 6'da farklı eğitim-test bölüntüleme oranlarına göre sınıflandırıcıların ortalama performans sonuçları sunulmuştur. Tüm modeller genel olarak yüksek doğruluk, seçicilik, özgünlük ve F1 skoru değerleri sergilemiştir. Rastgele Orman modeli, %99.8 doğruluk ve %99.9 özgünlük oranlarına ulaşarak en yüksek başarıyı göstermiştir. k-En Yakın Komşu modeli de %99.6-%99.7 doğruluk aralığında istikrarlı bir performans sergilemiştir. Karar Ağacı modeli diğer yöntemlere kıyasla biraz daha düşük başarı göstermiş olmakla birlikte %99'un üzerinde doğruluk ve diğer metriklerde yüksek skorlar sağlamıştır. Eğitim veri oranı arttıkça tüm modellerde başarı metriklerinin hafif şekilde iyileştiği gözlemlenmiştir. Sonuçlar, özellikle Rastgele Orman algoritmasının yatış pozisyonu sınıflandırmada en güvenilir yöntem olduğunu göstermektedir.

SONUÇ

Bası yaraları yatan hastaların çoğunda görülebilse de erken teşhis edildiğinde önlenebilirler olduğu bilinmektedir. Önerilen bu giyilebilir sensör teknolojisi ile yatış pozisyon tespit sisteminin doğruluk oranının %88-%99 arasında olduğu gösterilmiştir. Bu başarı sistemin uzman kontrolünde hastanelerde yoğun bakım hastalarının yatış pozisyon takibi için kullanılabilir seviyede güvenilir olduğunu göstermektedir. Koruyucu bakım kapsamında alınan tüm önlemlere rağmen yine de basınç yaralanmaları gelişebilmektedir. Yoğun bakım ünitelerindeki hastalarda bası yaralarının oluşma oranı %10 ile %18'i arasında, evde bakım hastalarında ise %0-%29'u oranında olduğu bilindiğinden önerilen sistemin kullanımı ile bu oranların önemli ölçüde azaltacağı aşikardır. Böylece hastanın hastane bakım giderleri (sağlık giderlerini) düşürülebilir ve hastanedeki personellerin iş yükünün azaltılması sağlanabilir. Geliştirilen prototipin sağlık alanındaki önemli bir probleme çözüm oluşturma potansiyelinin mevcut olduğu gösterilmiştir.

Bu çalışmada geliştirilen sistem, bası yaralarının önlenmesine yönelik önemli bir adım olmakla birlikte, sensör teknolojisi, yazılım teknolojisi ve ticari ürün oluşturma potansiyeli açısından geliştirmeye açıktır.

Sensör teknolojisi açısından sistemin daha hafif ve enerji verimli hale getirilmesi sistemin taşınabilirliğini ve kullanım konforunu artırabilir. Bu bağlamda, daha ergonomik tasarımlar ve uzun süreli kullanım için optimize edilmiş batarya sistemleri üzerinde çalışılması önerilmektedir. Mevcut IMU sensörlere ek olarak, basınç sensörleri veya deri altı oksijen seviyesi ölçebilen sensörlerinin entegrasyonu sağlanabilir. Böylece, sistem daha kapsamlı veriler toplayarak bası yarası riskini önceden tespit etme konusunda daha hassas hale gelebilir. Ayrıca hastaların bireysel sağlık verileri (örneğin, yaş, cilt yapısı, dolaşım özellikleri ve diyabet durumu) doğrultusunda özelleştirilmiş pozisyon önerileri sunulması sistemin hastaya özel kişiselleştirmesini, hastanın ihtiyaçlarına uygun bir bakım sürecinin oluşturulmasını destekleyecektir. Yazılım teknolojisi olarak sistemde kullanılan derin öğrenme algoritmalarının performansının artırılması için transfer öğrenme veya hibrit modeller gibi ileri düzey yapay zeka yöntemleri araştırılabilir. Bu tür algoritmalar, büyük veri setlerinin daha hızlı ve etkili bir şekilde işlenmesini sağlayarak sistemin doğruluğunu ve güvenilirliğini artıracaktır. Bunun yanı sıra, evde bakım gereksinimi olan hastalar için sistemin bulut tabanlı bir izleme platformu ile entegre edilmesi faydalı olabilir. Bu sayede sağlık çalışanları, hastaların durumlarını uzaktan takip edebilir ve gerekli müdahaleleri zamanında gerçekleştirebilir. Böyle bir entegrasyon, evde bakım hizmetlerinin kalitesini artırmakla birlikte, sağlık çalışanlarının iş yükünü de hafifletecektir.

TEŞEKKÜR

Veri Erişilebilirlik Beyanı: Bu çalışma sırasında üretilen ve analiz edilen veri setleri, makul bir talep üzerine sorumlu yazardan temin edilebilir.

Finansman Beyanı: Bu çalışma, Rabia Gizemnur EREN tarafından yüksek lisans tezi kapsamında gerçekleştirilmiş olup, Fırat Üniversitesi Mühendislik Fakültesi Mekatronik Mühendisliği Bölümü'nde Doç. Dr. Beyda TAŞAR danışmanlığında yürütülmüştür. Çalışma, 2022 Acil11 projesi kapsamında TÜSEB tarafından 31070 protokol numarası ile desteklenmiştir.

Çıkar Çatışması Beyanı: Yazarlar, çıkar çatışması bulunmadığını beyan etmektedirler.

Etik Onay Beyanı: Çalışmalar, 01/09/2022 tarihli ve 2022/10-41 numaralı karar ile Fırat Üniversitesi Girişimsel Olmayan Araştırmalar Etik Kurulu onayı alınarak yürütülmüştür.

Hasta Onamı Beyanı: Çalışmaya katılan tüm bireylerden bilgilendirilmiş onam alınmıştır.

Diğer Kaynaklardan Materyal Kullanım İzni: Bu çalışmada başka kaynaklardan materyal kullanılmamıştır.

KAYNAKÇA

- [1] D. C. Klonoff, "The increasing incidence of diabetes in the 21st century," 2009, SAGE Publications Sage CA: Los Angeles, CA.
- [2] B. Pieper, "Pressure ulcers: impact, etiology, and classification," *Acute and Chronic Wounds-E-Book*, p. 124, 2015.
- [3] S. D. Horn et al., "The National Pressure Ulcer Long-Term Care Study: pressure ulcer development in long-term care residents," *J Am Geriatr Soc*, vol. 52, no. 3, pp. 359-367, 2004.
- [4] L. E. Edsberg, J. M. Black, M. Goldberg, L. McNichol, L. Moore, and M. Sieggreen, "Revised National Pressure Ulcer Advisory Panel pressure injury staging system: revised pressure injury staging system," *Journal of Wound, Ostomy, and Continence Nursing*, vol. 43, no. 6, p. 585, 2016.
- [5] J. Cuddigan, "Clinical Aspects of Deep Tissue Pressure Injury," 2016.
- [6] D. Berlowitz, C. Vandeusen Lukas, V. Parker, and Others, "Preventing pressure ulcers in hospitals| agency for healthcare research & quality," 2018.
- [7] S. A. JJ, T. I. B. JE, J. Posnett, L. San Miguel, and Others, "The Burden of Pressure Ulcers in Spain," *Wounds*, vol. 19, no. 7, pp. 201-206, 2007.
- [8] A. Tubaishat, P. Papanikolaou, D. Anthony, and L. Habiballah, "Pressure Ulcers Prevalence in the Acute Care Setting: A Systematic Review, 2000-2015," *Clin Nurs Res*, vol. 27, no. 6, pp. 643-659, 2018, doi: 10.1177/1054773817705541.
- [9] S. Zahia, M. B. Garcia Zapirain, X. Sevillano, A. González, P. J. Kim, and A. Elmaghraby, "Pressure injury image analysis with machine learning techniques: A systematic review on previous and possible future methods," *Artif Intell Med*, vol. 102, no. November 2018, p. 101742, 2020, doi: 10.1016/j.artmed.2019.101742.
- [10] Q. Jiang et al., "The incidence, risk factors and characteristics of pressure ulcers in hospitalized patients in China," *Int J Clin Exp Pathol*, vol. 7, no. 5, p. 2587, 2014.
- [11] G. Brown, "Long-term outcomes of full-thickness pressure ulcers: healing and mortality," *Ostomy Wound Manage*, vol. 49, no. 10, pp. 42-50, 2003.
- [12] G. Liu, K. Li, L. Zheng, W. H. Chen, G. Zhou, and Q. Jiang, "A Respiration-Derived Posture Method Based on Dual-Channel Respiration Impedance Signals," *IEEE Access*, vol. 5, pp. 17514-17524, Aug. 2017, doi: 10.1109/ACCESS.2017.2737461.
- [13] R. van V. L. C. D. W. F. C. and C. P. Sarah Fallmann, "Wearable Accelerometer Based Extended Sleep Position Recognition," Oct. 2017.
- [14] Z. Li, Y. Zhou, and G. Zhou, "A dual fusion recognition model for sleep posture based on air mattress pressure detection," *Sci Rep*, vol. 14, no. 1, Dec. 2024, doi: 10.1038/s41598-024-61267-0.
- [15] J. Liu, Y. Chen, Y. Wang, X. Chen, J. Cheng, and J. Yang, "Monitoring Vital Signs and Postures during Sleep Using WiFi Signals," *IEEE Internet Things J*, vol. 5, no. 3, pp. 2071-2084, Jun. 2018, doi: 10.1109/JIOT.2018.2822818.
- [16] S. M. Mohammadi, M. Alnowami, S. Khan, D.-J. Dijk, A. Hilton, and K. Wells, *Sleep Posture Classification using a Convolutional Neural Network*. 2018. doi: 10.0/Linux-x86_64.
- [17] Y.-J. L. L. L. C. C. Y.-P. H. Yan-Ying Li, *Sleep Posture Classification with Multi-Stream CNN Using Vertical Distance Map*. IEEE 2018 International Workshop on Advanced Image Technology, 2018.
- [18] Y. W. K. K. D. C. D. C. D. S. S. H. H. O.S. Eyobu, *A real-time sleeping position recognition system using IMU sensor motion data*. IEEE 2018 IEEE International Conference on Consumer Electronics (ICCE), 2018.
- [19] K. Kido et al., "A novel CNN-based framework for classification of signal quality and sleep position from a capacitive ECG measurement," *Sensors (Switzerland)*, vol. 19, no. 7, Apr. 2019, doi: 10.3390/s19071731.
- [20] X. W. M. S. and K. L. Zhong Liu, "A Method to Recognize Sleeping Position Using an CNN Model Based on Human Body Pressure Image," 2019 IEEE International Conference on Power, Intelligent Computing and Systems (ICPICS), 2019.
- [21] S. Jeon, T. Park, A. Paul, Y. S. Lee, and S. H. Son, "A wearable sleep position tracking system based on dynamic state transition framework," *IEEE Access*, vol. 7, pp. 135742-135756, 2019, doi: 10.1109/ACCESS.2019.2942608.
- [22] S. Akbarian, G. Delfi, K. Zhu, A. Yadollahi, and B. Taati, "Automated Non-Contact Detection of Head and Body Positions during Sleep," *IEEE Access*, vol.

- 7, pp. 72826-72834, 2019, doi: 10.1109/ACCESS.2019.2920025.
- [23] L. A. Zavala-Mondragon, B. Lamichhane, L. Zhang, and G. de Haan, "CNN-SkelPose: a CNN-based skeleton estimation algorithm for clinical applications," *J Ambient Intell Humaniz Comput*, vol. 11, no. 6, pp. 2369-2380, Jun. 2020, doi: 10.1007/s12652-019-01259-5.
- [24] Y. Cao et al., "Contactless Body Movement Recognition during Sleep via WiFi Signals," *IEEE Internet Things J*, vol. 7, no. 3, pp. 2028-2037, Mar. 2020, doi: 10.1109/JIOT.2019.2960823.
- [25] S. Yue, Y. Yang, H. Wang, H. Rahul, and Di. Katabi, "BodyCompass: Monitoring Sleep Posture with Wireless Signals," *Proc ACM Interact Mob Wearable Ubiquitous Technol*, vol. 4, no. 2, Jun. 2020, doi: 10.1145/3397311.
- [26] H. Diao et al., "Deep Residual Networks for Sleep Posture Recognition with Unobtrusive Miniature Scale Smart Mat System," *IEEE Trans Biomed Circuits Syst*, vol. 15, no. 1, pp. 111-121, Feb. 2021, doi: 10.1109/TBCAS.2021.3053602.
- [27] Z. Chen and Y. Wang, "Remote Recognition of In-Bed Postures Using a Thermopile Array Sensor with Machine Learning," *IEEE Sens J*, vol. 21, no. 9, pp. 10428-10436, May 2021, doi: 10.1109/JSEN.2021.3059681.
- [28] Q. Hu, X. Tang, and W. Tang, "A Real-Time Patient-Specific Sleeping Posture Recognition System Using Pressure Sensitive Conductive Sheet and Transfer Learning," *IEEE Sens J*, vol. 21, no. 5, pp. 6869-6879, Mar. 2021, doi: 10.1109/JSEN.2020.3043416.
- [29] A. Y. C. Tam, B. P. H. So, T. T. C. Chan, A. K. Y. Cheung, D. W. C. Wong, and J. C. W. Cheung, "A blanket accommodative sleep posture classification system using an infrared depth camera: A deep learning approach with synthetic augmentation of blanket conditions," *Sensors*, vol. 21, no. 16, Aug. 2021, doi: 10.3390/s21165553.
- [30] T. Zhou, Z. Xia, X. Wang, and F. Xu, "Human Sleep Posture Recognition Based on Millimeter-Wave Radar," in *2021 Signal Processing Symposium, SPSympo 2021*, Institute of Electrical and Electronics Engineers Inc., 2021, pp. 316-321. doi: 10.1109/SPSympo51155.2020.9593799.
- [31] M. Piriyaajakonkij et al., "SleepPoseNet: Multi-View Learning for Sleep Postural Transition Recognition Using UWB," *IEEE J Biomed Health Inform*, vol. 25, no. 4, pp. 1305-1314, Apr. 2021, doi: 10.1109/JBHI.2020.3025900.
- [32] K. Tang, A. Kumar, M. Nadeem, and I. Maaz, "CNN-Based Smart Sleep Posture Recognition System," *Internet of Things*, vol. 2, no. 1, pp. 119-139, Mar. 2021, doi: 10.3390/iot2010007.
- [33] Y. Y. Li, S. J. Wang, and Y. P. Hung, "A Vision-Based System for In-Sleep Upper-Body and Head Pose Classification," *Sensors*, vol. 22, no. 5, Mar. 2022, doi: 10.3390/s22052014.
- [34] S. M. M. Islam and V. M. Lubecke, "Sleep Posture Recognition with a Dual-Frequency Microwave Doppler Radar and Machine Learning Classifiers," *IEEE Sens Lett*, vol. 6, no. 3, Mar. 2022, doi: 10.1109/LSSENS.2022.3148378.
- [35] Z. Xing, W. Gao, and G. Chuai, "Research on sleeping position recognition algorithm based on human body vibration signal," in *2022 IEEE 2nd International Conference on Power, Electronics and Computer Applications, ICPECA 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 403-406. doi: 10.1109/ICPECA53709.2022.9719095.
- [36] S. M. Mohammadi, S. Enshaeifar, A. Hilton, D. J. Dijk, and K. Wells, "Transfer Learning for Clinical Sleep Pose Detection Using a Single 2D IR Camera," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 29, pp. 290-299, 2021, doi: 10.1109/TNSRE.2020.3048121.
- [37] D. K. H. Lai et al., "Dual ultra-wideband (UWB) radar-based sleep posture recognition system: Towards ubiquitous sleep monitoring," *Engineered Regeneration*, vol. 4, no. 1, pp. 36-43, Mar. 2023, doi: 10.1016/j.engreg.2022.11.003.
- [38] M. Z. H. Jesmeen, T. Bhuvaneswari, A. H. Mazbah, Y. B. Chin, L. H. Siong, and N. H. A. Aziz, "SleepCon: Sleeping Posture Recognition Model using Convolutional Neural Network," *Emerging Science Journal*, vol. 7, no. 1, pp. 50-59, Feb. 2023, doi: 10.28991/ESJ-2023-07-01-04.
- [39] C. Intongkum, Y. Sasiwat, K. Sengchuai, A. Booranawong, and P. Phukpattaranont, "Monitoring and Classification of Human Sleep Postures, Seizures, and Falls From Bed Using Three-Axis Acceleration Signals and Machine Learning," *SN Comput Sci*, vol. 5, no. 1, Jan. 2024, doi: 10.1007/s42979-023-02426-4.
- [40] L. J. Kau, M. Y. Wang, and H. Zhou, "Pressure-Sensor-Based Sleep Status and Quality Evaluation System," *IEEE Sens J*, vol. 23, no. 9, pp. 9739-9754, May 2023, doi: 10.1109/JSEN.2023.3262747.
- [41] L. Stern and A. Roshan Fekr, "In-Bed Posture Classification Using Deep Neural Network,"

- Sensors, vol. 23, no. 5, Mar. 2023, doi: 10.3390/s23052430.
- [42] C. He et al., "A Novel Detection Method for Heart Rate Variability and Sleep Posture Based on a Flexible Sleep Monitoring Belt," IEEE Sens J, 2024, doi: 10.1109/JSEN.2024.3518082.
- [43] A. Khan, C. Kim, J. Y. Kim, A. Aziz, and Y. Nam, "Sleep Posture Classification Using RGB and Thermal Cameras Based on Deep Learning Model," CMES - Computer Modeling in Engineering and Sciences, vol. 140, no. 2, pp. 1729-1755, 2024, doi: 10.32604/cmes.2024.049618.
- [44] A. Khan et al., "Ensemble Deep Learning for Classifying Sleeping Posture of Humans Covered in Blankets Using RGB and Thermal Imaging," IEEE Access, 2024, doi: 10.1109/ACCESS.2024.3498049.
- [45] X. Xu, Q. Mo, Z. Wang, Y. Zhao, and C. Li, "Classification of Sleeping Position Using Enhanced Stacking Ensemble Learning," Entropy, vol. 26, no. 10, Oct. 2024, doi: 10.3390/e26100817.
- [46] X. Liu et al., "PosMonitor: Fine-Grained Sleep Posture Recognition with mmWave Radar," IEEE Internet Things J, vol. 11, no. 7, pp. 11175-11189, Apr. 2024, doi: 10.1109/JIOT.2023.3328866.
- [47] D. K. H. Lai et al., "Vision Transformers (ViT) for Blanket-Penetrating Sleep Posture Recognition Using a Triple Ultra-Wideband (UWB) Radar System," Sensors, vol. 23, no. 5, Mar. 2023, doi: 10.3390/s23052475.
- [48] D. Hu, W. Gao, K. K. Ang, M. Hu, G. Chuai, and R. Huang, "Smart Sleep Monitoring: Sparse Sensor-Based Spatiotemporal CNN for Sleep Posture Detection," Sensors, vol. 24, no. 15, Aug. 2024, doi: 10.3390/s24154833.
- [49] D. K. H. Lai et al., "Deciphering Optimal Radar Ensemble for Advancing Sleep Posture Prediction through Multiview Convolutional Neural Network (MVCNN) Approach Using Spatial Radio Echo Map (SREM)," Sensors, vol. 24, no. 15, Aug. 2024, doi: 10.3390/s24155016.
- [50] B. Tasar; G. Karaduman. VirLesDetNet: Pre-Trained Hybrid Deep Learning Approaches for Virus-Based Skin Lesion Detection. Traitement du Signal, 2024, 41.5.