

Mahalanobis uzaklığı tabanlı aykırı değer bulma ve ReliefF öznitelik seçimine dayalı bir makine öğrenmesi yaklaşımı ile akıllı telefon verileri üzerinden stres tespiti

Stress detection on smartphone data with a machine learning approach based on Mahalanobis distance-based outlier finding and ReliefF feature selection

Ensar Arif SAĞBAŞ^{1*}, Serdar KORUKOĞLU¹, Serkan BALLI²

¹Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Ege Üniversitesi, İzmir, Türkiye.
arifsagbas@mu.edu.tr, ensar.arif.sagbas@ege.edu.tr, serdar.korukoglu@ege.edu.tr

²Bilişim Sistemleri Mühendisliği Bölümü, Teknoloji Fakültesi, Muğla Sıtkı Koçman Üniversitesi, Muğla, Türkiye.
serkan@mu.edu.tr

Geliş Tarihi/Received: 07.06.2021
Kabul Tarihi/Accepted: 03.09.2021

Düzeltilme Tarihi/Revision: 03.09.2021

doi: 10.5505/pajes.2021.88724
Araştırma Makalesi/Research Article

Öz

Stres kişinin odaklanması, uyanık kalması ve tetikte olması durumlarında fayda sağlamaktadır. Fakat yüksek dozda strese maruz kalmak kişinin sağlığına zarar vermektedir. Bu nedenle stresin tespit edilip en kısa sürede rahatlama geçilmesi önemlidir. Bu çalışmada, akıllı telefondan elde edilen dokunmatik panel, yerçekimi, doğrusal ivme ve jiroskop verileri ile yazma davranışları incelenmiştir. Elde edilen sonuçlardan yazma davranışları ile kişilerin stres seviyeleri arasında bir bağlantı olduğu görülmüştür. Bu kapsamda genişletilmiş bir veri kümesi oluşturulmuştur. Stresin daha yüksek doğrulukta tespit edilebilmesi için Mahalanobis uzaklığı tabanlı bir aykırı veri tespiti yaklaşımı uygulanmıştır. Devamında, verimli özniteliklerin tespit edilerek sınıflandırma gerçekleştirilmesi için ReliefF öznitelik seçimi yöntemi ve makine öğrenmesi teknikleri kombine edilerek bir yapı oluşturulmuştur. Aykırı verilerin temizlenerek elde edilen sonuçlar, oluşturulan yapıların yüksek doğrulukta başarı yakaladığını göstermiştir. Ek olarak aykırı veri tespiti ve temizliği, sınıflandırma başarısını 1.77 puan artırmıştır.

Anahtar kelimeler: Stres tespiti, Mahalanobis uzaklığı, Öznitelik değerlendirme, Akıllı telefon verileri, Yazma davranışı.

Abstract

Stress is beneficial when a person is focused, awake and alert. However, exposure to high doses of stress harms a person's health. For this reason, it is important to detect stress and begin relief as soon as possible. In this study, soft keyboard typing behaviors with touchscreen panel, gravity, linear acceleration, and gyroscope data obtained from smartphones were examined. It was observed that there was a correlation between the results obtained and typing behaviors and the stress levels of individuals. In this context, an expanded data set was created. In order to detect stress with higher accuracy, a Mahalanobis distance-based outlier detection approach was applied. Subsequently, a structure was created by combining the ReliefF feature selection method and machine learning techniques to identify efficient features and perform classification. The results obtained by cleaning outlier data showed that the created structures achieved success with high accuracy. In addition, outlier detection and cleaning increased the classification success by 1.77 points.

Keywords: Stress detection, Mahalanobis distance, Feature evaluation, Smartphone data, Typing behavior.

1 Giriş

Stres günümüz toplumunda önemli bir problemdir. İnsanlar belli bir zaman kısıtlaması ile gerçekleştirmesi gereken işleri yerine getirirken stres altında olduğunun farkında olabilir. Bu durumlarda stres, kişiyi motive eden bir unsur olsa da fazla miktarda strese maruz kalmak kişiye zarar verecektir [1]. Bu nedenle stresin erken tespit edilmesi, gözetim altında tutulması ve rahatlama yoluna gidilmesi önemli bir adımdır. Bu kapsamda stresin tespit edilmesi bir sınıflandırma problemi olarak ele alınabilir. Araştırmacılar, stresi erken tespit edebilmek için çeşitli veri kaynaklarından faydalanmışlardır [2]. Akıllı telefonlar da sahip oldukları algılayıcılar ve sağladığı içerik bilgileri ile bu veri kaynaklarının arasında yer almaktadır. Akıllı telefonlardan elde edilen veriler uzun yıllardır stres tespiti de içinde olmak üzere aktivite tespiti [3], konu modelleme [4], duygu analizi [5] gibi çeşitli araştırma konularında makine öğrenmesi yöntemleri kullanılarak

sınıflandırılmaktadır. Bu aşamada araştırmacıların karşısına çeşitli veri madenciliği problemleri çıkmaktadır. Aykırı verilerin tespit edilmesi, verimli özniteliklere karar verilmesi ve veriye en uygun sınıflandırma yöntemine karar verilmesi bu problemler arasında gösterilebilir.

Bu çalışmada iki sınıflı stres tespiti için akıllı telefon yazılım klavyesi yazma davranışları incelenmiştir. Bu amaçla akıllı telefonun sahip olduğu ivmeölçer, jiroskop ve dokunmatik panelden elde edilen veriler kullanılmıştır. İvmeölçer algılayıcısı yerçekimi ve doğrusal ivme olarak ele alınmıştır. Buna bağlı olarak Sağbaş ve diğ. [6] çalışmasındaki veri kümesi genişletilerek kullanılmıştır. Literatürde stres tespiti ile ilgili çeşitli çalışmalar bulunuyor olsa da, bu çalışma yazma davranışlarını algılayıcı verileri üzerinden tespit eden yapısı ile diğer çalışmalardan farklılaşmaktadır. Çalışmanın konusunun yanında özgün bir yöntem de önerilmektedir. Makine öğrenmesinde sıkça karşılaşılan aykırı veri problemi Mahalanobis uzaklığı tabanlı bir yaklaşım ile ele alınmış olumlu

*Yazışılan yazar/Corresponding author

sonuçlar elde edilmiştir. Bir başka makine öğrenmesi problemi olan boyutsallık sorununun önüne ise ReliefF algoritması ile geçilmiştir. İnşa edilen bu melez yapılar ile çok yüksek sınıflandırma doğruluğuna ulaşılmıştır. Hem önerilen özgün yaklaşım ve inşa edilen makine öğrenmesi yapısı hem de makine öğrenmesi yöntemleri kullanılarak stres tespiti ile alakalı Türkçe kaynak bulunmaması bakımından bu çalışmanın bilime katkı sağlayacağı ve bu alanda çalışacak olan araştırmacılara ışık tutacağı düşünülmektedir. Çalışmanın ikinci kısmında akıllı telefonlar ile gerçekleştirilen stres tespiti çalışmalarına değinilmiştir. Verilerin toplanması, öznelite çıkartımı ve Mahalanobis uzaklığı tabanlı aykırı değer tespiti ve temizlenmesi üçüncü kısımda açıklanmıştır. Dördüncü kısımda kullanılan sınıflandırma yöntemleri kısaca açıklanmıştır. Elde edilen deneysel bulgular beşinci kısımda ele alınmış ve tartışılmıştır. Son olarak altıncı kısımda çalışma sonuçlandırılmıştır.

2 Geçmiş çalışmalar

Geçmiş çalışmalar incelendiğinde akıllı telefonlar ile gerçekleştirilen çeşitli stres tespiti çalışmalarına rastlamak mümkündür. Bu çalışmalarda akıllı telefonların dâhili algılayıcıları ve içerik bilgilerinden faydalanılmıştır. Lu ve diğ. [7] stresi tespit etmek için ses sinyallerinden faydalanmıştır. Wang ve diğ. [8] sosyallik, uyku ve aktivitelerinin kişinin stres seviyesi ile olan ilişkisini ivmeölçer, bluetooth, GPS, ışık ve ses algılayıcılarından elde ettikleri veriler ile incelemiştir. Garcia-Ceja ve diğ. [9] stresi algılamak için sadece ivmeölçer algılayıcısından faydalanmıştır. Vildjiounaite ve diğ. [10] yedi, Ferdous ve diğ. [11] ise beş farklı stres seviyesini tahminlemek için akıllı telefon uygulama kullanım bilgilerini incelemiştir. Sırası ile %70 ve %75 sınıflandırma başarısı yakalanmıştır. Stütz ve diğ. [12] akıllı telefon uygulama bilgilerinin yanında insan aktivitelerini takip ederek stres seviyesini belirlemeyi amaçlamıştır. Muaremi ve diğ. [13] 35 katılımcıdan topladığı GPS, ivmeölçer, ses ve sosyal etkileşim verileri ile stres tespitini 3 sınıflı olarak gerçekleştirmiştir. Bauer ve Lokowicz [14] 7 adet katılımcıdan topladıkları arama ve SMS kayıtları, GPS, WiFi ve Bluetooth verileri ile stres arasındaki ilişkiyi incelemişlerdir. Sysoev ve diğ. [15] yedi farklı stres seviyesini tespit etmek için akıllı telefonda elde ettikleri bağlamsal ve davranışsal verileri incelemiştir. Gjoreski ve diğ. [16] ivmeölçer, GPS, WiFi, ses, ışık ve arama kayıtlarını kullanarak 3 sınıflı stres tespiti gerçekleştirmiştir. İvmeölçer algılayıcı ile kullanıcının aktivite türü tespit edilmiştir. Bogomolov ve diğ. [17] iki sınıflı stres tespiti için arama, SMS kayıtları ve bluetooth algılayıcısından elde ettiği verilere ek olarak hava durumu bilgisinden faydalanmıştır. Ciman ve diğ. [18] kişinin stres durumunu akıllı telefon ekranında gerçekleştirdiği kaydırma ve metin girme hareketlerini inceleyerek değerlendirmiştir. Ghosh ve diğ. tarafından gerçekleştirilen çalışmalarda [19],[20] stresi de içinde bulunduran 4 farklı duyguyu tespit etmek için yazma karakteristiği incelenmiştir. Gao ve diğ. [21] 4 farklı duygu durumunun tespiti için akıllı telefon dokunmatik ekranından elde ettiği bilgileri kullanmıştır. Kim ve Choi [22] ivmeölçer ve jiroskop gibi hareket algılayıcılarının yanında dokunmatik ekrandan elde edilen bağlamsal bilgilerden faydalanmıştır. Ciman ve Wac [23] ekrana dokunma istatistiklerine ek olarak fiziksel aktivite takibi, uygulama kullanımı, ışık ve ekran açma kapama gibi verilerden faydalanmıştır. Sağbaş ve diğ. [6] iki sınıflı stres tespiti için kişilerin yazma karakteristiğini dokunmatik panel, ivmeölçer ve jiroskoptan elde ettikleri veriler ile incelemiştir. Lee ve diğ. [24] yedi farklı duyguyu tespit etmek için dokunmatik ekrandan elde edilen verilere

(yazma hızı, yanlış yazma, özel sembol kullanımı vs.) ek olarak hava durumu, konum ve ışık gibi algılayıcı ve içerik bilgilerinden de faydalanmıştır.

3 Veri kümesi

Çalışmada kullanılan veri kümesini oluşturan ham veriler Android işletim sistemine sahip akıllı telefonlar üzerinde çalışabilen bir mobil uygulama aracılığı ile toplanmıştır. Stresin yazma davranışları üzerinden tespit edilmesi amaçlanan bu çalışmada, katılımcıların kendi telefonlarını kullanmaları sağlanmıştır. Böylece yazma davranışlarında istekleri dışında bir farklılığın oluşmasının önüne geçilmiştir. Çalışma kapsamında katılımcılara ait bilgiler Tablo 1'de katılımcıların yaş dağılımları ise Şekil 1'de sunulmaktadır.

Tablo 1. Katılımcılara ait sayısal bilgiler.

Table 1. Numerical information of the participants.

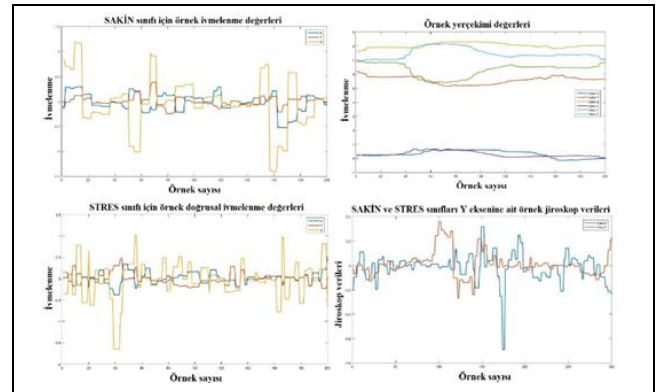
Katılımcı Sayısı	Erkek	Kadın	Yaş		Std. Sapma
			En küçük	En büyük	
110	87	23	16	39	22,48

Şekil 1. Katılımcıların yaş dağılımları.

Figure 1. Age distribution of the participants.

3.1 Verilerin toplanması

Çalışma kapsamında akıllı telefon kullanıcısının stresli olup olmadığının tespit edilebilmesi amacı ile akıllı telefonların sahip olduğu yerleşik ivmeölçer ve jiroskop algılayıcılarından veriler toplanmıştır. Bu algılayıcılar cihazın hareketi ve duruş şekli hakkında bilgiler sunmaktadır [25]. İvmeölçer algılayıcısı yerçekimi ve doğrusal ivme olarak ele alınmıştır. Bunlara ek olarak dokunmatik panele dokunma sayısı, silme tuşuna basma sayısı, kullanıcının yaşı ve cinsiyeti de kaydedilmiştir. Akıllı telefon saniyede 20 örnek veri toplayacak şekilde ayarlanmıştır. Ham hareket algılayıcısı verilerinin görselleştirilmesi Şekil 2'de gösterilmektedir.



Şekil 2. Ham verilerin görselleştirilmesi.

Figure 2. Visualization of raw data.

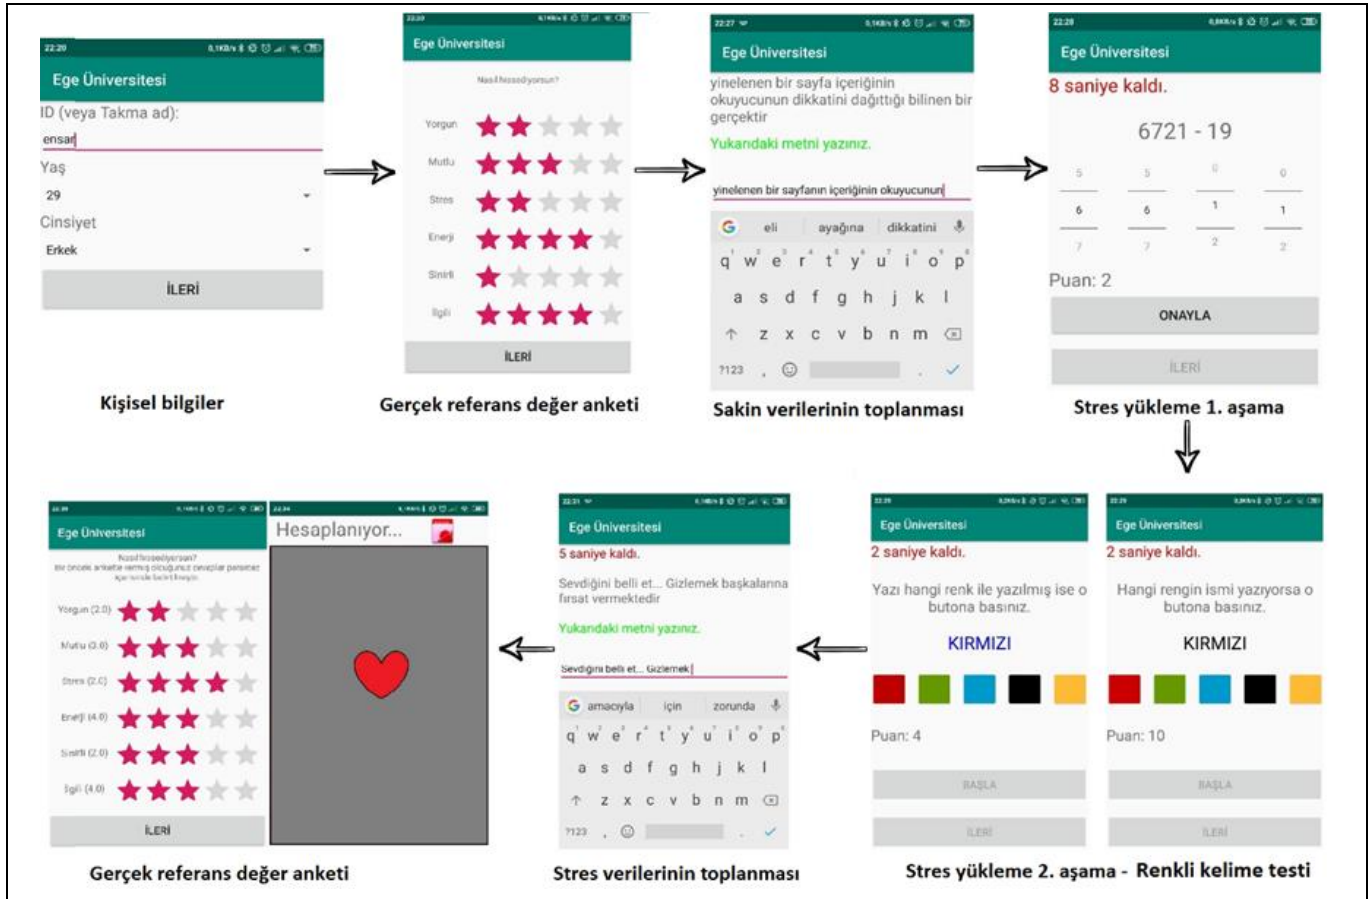
Veri toplama aşaması 5 ana basamaktan oluşmaktadır. Bunlar şu şekilde listelenebilir:

1. Kişisel bilgilerin girilmesi,
2. Gerçek referans değer anketinin ve nabız bilgilerinin elde edilmesi,
3. Sakin verilerinin toplanması,
4. Stres yüklemeye aşaması,
5. Stres verilerinin toplanması.

Gerçek referans değer anketi ve nabız bilgileri hem uygulamanın başında hem de sonunda katılımcılardan istenmektedir. Veri toplama aşamasının akış şeması Şekil 3'te sunulmaktadır.

Veri toplama uygulaması öncelikli olarak katılımcıdan bir kullanıcı adı, yaş ve cinsiyet bilgilerini girmesini istemektedir. Kullanıcı adı katılımcı tarafından belirlenen takma isimdir. Sonrasında katılımcının nasıl hissettiğine dair sorular içeren 6 adet duygusal durum anketi ekrana gelmektedir. Bu 6 duygusal durumun 3'ü olumlu, 3'ü ise olumsuz duygular ifade etmektedir. Bu anketi 5 yıldız üzerinden puanladıktan sonra akıllı telefonun flaşını ve kamerasını kullanarak nabız ölçümü

gerçekleştirilmektedir. Bu aşamadan sonra ekranda çeşitli metinler belirlemekte ve katılımcılardan okudukları metinleri metin kutusuna yazmaları istenmektedir. Bu aşamada katılımcılar kendi telefonlarını kullandıkları için yazma davranışlarına müdahale edilmemektedir. Herhangi bir zaman baskısı olmadan katılımcılar uygulamanın sunduğu miktarda metni girdikten sonra stres yüklemeye aşamasına geçilmektedir. Bu aşamada zihinsel stresi tetikleyen oyunlar tasarlanmıştır. Katılımcıların zaman baskısı altında aritmetik işlemler yapması ve Stroop renkli kelime testini [26] gerçekleştirmesi istenmektedir. Stres yüklemeye aşamasından sonra stres verilerinin toplanması aşamasına geçilmektedir. Bu aşamada sakın verilerinin toplanması aşamasına ek olarak her metin için farklı uzunluklarda zaman kısıtlamaları eklenmiştir. Ek olarak metni giriş için son 5 saniye kaldığında bunu belirten geri sayım müziği eşlik etmektedir. Son olarak gerçek referans değer anketi ve nabız bilgileri tekrar toplanarak veri toplama işlemi sonlandırılmaktadır. Gerçek referans değer anketleri sonrasında elde edilen verilerin ortalama ve standart hata değerleri Tablo 2'de, güven aralığı grafiği ise Şekil 4'te sunulmaktadır. Anket puanlarında analiz edilen nokta stres yüklemeye aşamasının amacına ulaşmış ulaşmadığıdır.



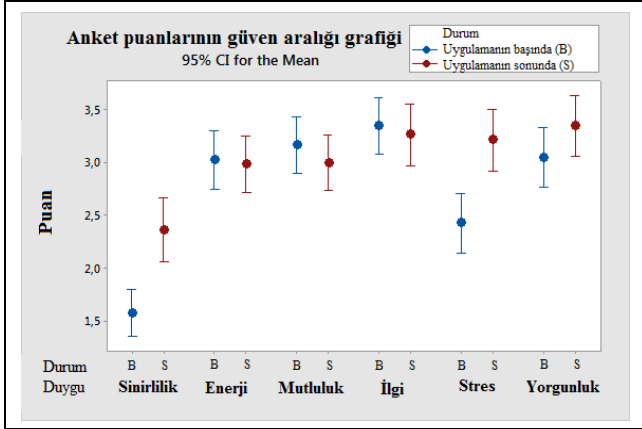
Şekil 3. Veri toplama akış şeması.

Figure 3. Flowchart of the data collection.

Tablo 2. Gerçek referans değer anketlerinin ortalama ve standart hata değerleri.

Table 2. Average and standard error values of the ground truth surveys.

	Nabız	Sinirlilik	Enerji	Mutluluk	İlgi	Stres	Yorgunluk
Uygulama başında	78.64±2.47	1.58±0.11	3.03±0.14	3.16±0.13	3.35±0.13	2.43±0.14	3.05±0.14
Uygulama sonunda	88.04±3.96	2.36±0.15	2.99±0.13	3.01±0.13	3.26±0.15	3.21±0.15	3.35±0.14



Şekil 4. Anket puanlarının güven aralığı grafiği.

Figure 4. Confidence interval graph of survey scores.

Tablo 2 incelendiğinde olumlu tutumların ortalamasının uygulama sonunda azalırken, olumsuz tutumların ortalama puanlarının arttığı görülmektedir. Ek olarak ortalama nabızın da arttığı gözle çarpılmaktadır. Şekil 4 incelendiğinde ise uygulama

öncesi stres verisinin güven aralığı üst noktası ile uygulama sonrası stres verisinin güven aralığı alt noktasının birbiri ile kesişmediği görülmektedir. Bu bilgiler dâhilinde stres yüklenme aşamasının amacına ulaştığı söylenebilir.

3.2 Öznitelik çıkarımı

Akıllı cihaz algılayıcı verileri ile insan hareketlerinin sınıflandırıldığı çeşitli çalışmalar bulunmaktadır [27, 28]. Bu çalışmalarda algılayıcı verileri, ele alınan konuya göre farklı uzunlukta pencere aralıklarında bölünmektedir. Bu çalışmada ise elde edilen ham veriler 5, 10 ve 15 saniyelik pencerelere bölünmüştür. Gerçekleştirilen ön çalışmada en başarılı sonuçlar 15 saniyelik pencere aralığı ile elde edilen veri kümesinden sağlanmıştır [6]. Buna bağlı olarak, bu çalışmada veri kümesi 15 saniye pencere aralığı ile oluşturulmuştur. Bu işlem sonrasında öznitelik çıkarımı için 1989 sakın, 2370 stres olmak üzere toplamda 4359 desen elde edilmiştir. Veri toplama aşamasında yerçekimi, doğrusal ivme ve jiroskop algılayıcılarından sinyal verilerine ek olarak ekrana dokunma sayısı, silme tuşuna basma sayısı, kullanıcının yaşı ve cinsiyeti bilgileri de toplanmıştır. Hareket algılayıcısı sinyallerine Tablo 3'te sunulan 15 adet formül (Denk. 1-Denk. 15) uygulanmıştır.

Tablo 3. Hareket algılayıcısı sinyallerine uygulanan formüller.

Table 3. Formulas applied to motion sensor signals.

Öznitelik İsmi	Formül	
En küçük değer (EKD)	$EKD = \min[x_i] \quad i = 1, \dots, n$	(1)
En büyük değer (EBD)	$EBD = \max[x_i] \quad i = 1, \dots, n$	(2)
Standart sapma (S)	$S = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{X})^2}{n-1}}$	(3)
Aritmetik ortalama (\bar{X})	$\bar{X} = \frac{1}{n} \sum_{i=1}^n x_i$	(4)
Toplam (T)	$Toplam = x_1 + x_2 + \dots + x_n$	(5)
Q1	$Q_1 = x_{(i)}[0.25(n+1)]$	(6)
Medyan (Q2)	$Q_2 = x_{(i)}[0.5(n+1)]$	(7)
Q3	$Q_3 = x_{(i)}[0.75(n+1)]$	(8)
Varyans (S^2)	$S^2 = \frac{\sum_{i=1}^n (x_i - \bar{X})^2}{n-1}$	(9)
Çarpıklık (α_3)	$\alpha_3 = \frac{\sum_{i=1}^n (x_i - \bar{X})^3}{(n-1) * S^3}$	(10)
Basıklık (α_4)	$\alpha_4 = \frac{\sum_{i=1}^n (x_i - \bar{X})^4}{(n-1) * S^4}$	(11)
Sıfır geçiş sayısı (SGS)	$x_{i-1} < 0 \text{ ve } x_i > 0 \text{ VEYA } x_{i-1} > 0 \text{ ve } x_i < 0 \text{ VEYA } x_{i-1} \neq 0 \text{ ve } x_i = 0$	(12)
Ortalama enerji (OE)	$OE = \frac{1}{n} \sum_{i=1}^n x_i^2$	(13)
Ortalama eğri uzunluğu (OEU)	$OEU = \frac{1}{n} \sum_{i=2}^n x_i - x_{i-1} $	(14)
Ortalama teager enerji (OTE)	$OTE = \frac{1}{n} \sum_{i=3}^n (x_{i-1}^2 - x_i x_{i-2})$	(15)

Üç eksenle elde edilen doğrusal ivme ve jiroskop algılayıcıları sinyallerine bu üç eksenin toplamını ifade eden bir magnitude (Denk. 16) eksenini eklenmiştir.

$$\text{magnitude} = \sqrt{x^2 + y^2 + z^2} \quad (16)$$


Doğrusal ivme için 60 adet (4 eksen x 15), jiroskop için 60 adet (4 eksen x 15) ve yerçekimi için 45 adet (3 eksen x 15) öznelik çıkarılmıştır. Bunlara ek olarak yaş, cinsiyet, ekrana basma sayısı, silme sayısı, ekrana basma süreleri arasındaki varyans, silme tuşuna basma süreleri arasındaki varyans değerleri ve ekrana basma sayısı ile silme tuşuna basma sayısının oranı veri kümesine öznelik olarak eklenmiştir. Toplamda 172 adet öznelik stresin tespiti amacıyla çıkarılmıştır. Weka veri madenciliği aracının [29] gereksiz öznelikleri kaldıran filtresi kullanılarak yerçekimi algılayıcısının Y, Z ve magnitude eksenlerinden ve jiroskop algılayıcısının magnitude ekseninden elde edilen sıfır geçiş sayısı öznelikleri kaldırılarak öznelik sayısı 168'e indirilmiştir.

3.3 Mahalanobis uzaklığı tabanlı aykırı veri tespiti ve temizliği

Geometrik açıdan, iki nokta arasındaki Öklid uzaklığı, aralarında mümkün olan en kısa uzaklıktır. Öklid uzaklık ölçüsü ile ilgili bir problem, yüksek düzeyde ilişkili değişkenler arasındaki korelasyonu hesaba katmamasıdır. Bu durumda Öklid uzaklığı bu tür değişkenlere eşit ağırlık verir ve bu değişkenler esasen aynı özelliği ölçtüğü için bu tek özellik ek ağırlık alır. Gerçekte, ilişkili değişkenler Öklid uzaklığına göre fazla ağırlık alır. Alternatif bir yaklaşım, her bir değişkenin değişkenliğine göre bireysel değişkenlerin uzaklık değerine katkısını ölçektir. Bu yaklaşım, Hintli bir istatistikçi olan PC Mahalanobis tarafından istatistiksel bir ölçüm olarak geliştirilen Mahalanobis uzaklığı (Denk. 17) tarafından değerlendirilir [30]. Ölçekle değişmez bir metriktir ve belirli bir p değişkenli olasılıksal dağılıma sahip $f(x)$ ile sağlanan bir $x \in R^p$ noktası ile dağılımın ortalaması $\mu = E(X)$ arasındaki mesafenin bir ölçümünü sağlamaktadır. $f(x)$ 'in ikinci dereceden momentlere sahip olduğu ve $\Sigma = E(X - \mu)'nin kovaryans matrisi olarak gösterildiği varsayılınsın.$

$$D(X, \mu) = \sqrt{(X - \mu)^T \Sigma^{-1} (X - \mu)} \quad (17)$$

Mahalanobis uzaklığı, çok değişkenli istatistikler alanında geniş uygulamalar bulmaktadır. Öklid uzaklığından, değişkenler arasındaki korelasyonları hesaba katması bakımından bu şekilde farklılık gösterir. Şekil 5'te gözlenen fark, Mahalanobis uzaklığının aynı zamanda verilerin korelasyon yapısını da açıkladığı gerçeğinden kaynaklanmaktadır.



Şekil 5. Bir veri kümesi için hesaplanan Mahalanobis (elips) ve Öklid (daire) uzaklıklarının şematik karşılaştırması.

Figure 5. Schematic comparison of Mahalanobis (ellipse) and Euclidean (circle) distances calculated for the dataset [30].

Şekil 5'te mavi renk ile gösterilen daireler ve kırmızı renk ile gösterilen elipsler, verilerin merkezinden bir ve iki birimlik Öklid ve Mahalanobis mesafelerine karşılık gelmektedir. Çalışmada her sınıftaki veriler için Mahalanobis uzaklıkları hesaplanmıştır. Sonrasında öznelik sayısına bağlı olarak her bir desen için olasılık değeri (1-ChiSquare) bulunmuştur. Bulunan olasılık değerleri 0.001 eşik değerinin altında olanlar aykırı değer olarak işaretlenmiş ve veri kümesinden temizlenmiştir. Aykırı veri temizliğinden sonra veri kümesi 1713 adet sakin ve 2072 adet stres olmak üzere 3785 adet desen içermektedir.

4 Sınıflandırma yöntemleri

İlgili çalışmalar incelendiğinde, stres tespitinin çeşitli makine öğrenmesi yöntemleriyle ele alındığı görülmektedir. Bu çalışmada literatürde yaygın olarak görülen k En yakın komşu (kNN), C4.5 karar ağacı ve Bayes ağları (BA) yöntemleri uygulanmıştır.

4.1 k En yakın komşu

k En yakın komşu (kNN), sınıflandırma sürecinde kullanılan denetimli bir sınıflandırma algoritmasıdır. Bu algoritma, yeni bir örneğin hangi sınıfa ait olduğuna, kullanıcı tarafından tanımlandığı kadar bir komşuya bakarak karar verme mantığıyla çalışmaktadır [31]. Bu çalışmada uzaklık değeri ölçülürken sıklıkla kullanılan Öklid uzaklık kriteri seçilmiştir.

Ayrıca problem farklı k komşuluk değerleri ile test edilmiş ve en uygun k değeri 1 olarak bulunmuştur. Aykırı değer verileri temizlenmiş veri kümesi için hareket algılayıcısı verilerinden elde edilmiş en yüksek üç sıraya sahip özneliklerin görselleştirilmesi Şekil 6'da verilmiştir. Şekil 6 sadece üç boyutta bile sınıfların belli bir dereceye kadar ayrıştığını göstermektedir.

4.2 C4.5 Karar ağacı


Karar ağaçlarının yapılandırılması ve anlaşılmasının diğer algoritmalarından çok daha kolay olması nedeniyle sınıflandırma problemlerinin yaygın olarak kullanılan çözümlerinden biridir. Üstelik ağacın oluşturulmasında kullanılan kurallar anlaşılır ve basittir. Karar ağaçları, sınıflandırma sürecinin gerçekleştirilmesi için çok aşamalı veya sıralı bir yaklaşım kullanır. Ağaç, sınıflandırmanın ilk adımında oluşturulur. İkinci adımda ise ağaç üzerine verinin tek tek uygulanarak veri sınıflandırması yapılmaktadır. Karar ağaçlarına dayalı birçok gelişmiş algoritma vardır. Literatürde en çok bilinen algoritmalar ID3, C4.5 ve C5'tir. Bu çalışmada entropi değerine dayalı C4.5 algoritması tercih edilmiştir. Özelliklerin bilgi kazancı ve bilgi kazanma oranı alt kümede bulunur ve C4.5 ile birlikte hesaplanır. En yüksek bilgi kazanım oranının özelliği bir düğüm olarak seçilir. Karar ağacının her bir dalı bir sınıfa karşılık gelene kadar işlemler devam eder. Daha sonra karar ağacı kural setine dönüştürülür [32].

4.3 Bayes ağları

Bayes ağları düğümlerinin değişkenleri, belirsizlik altında karar vermek için kullanılan grafik modellerdir. Bir Bayes ağında, düğümler ortamdan elde edilen rastgele değişkenleri temsil eder ve birbirlerine yön oklarıyla bağlanır. Bu oklar, düğümler arasındaki bağımlılığı temsil eder. İki ayrı düğüm arasındaki bağlantının gücü, bu iki düğüm arasındaki koşullu olasılıkla ölçülür. Öncelikle değişkenler arasındaki ilgi belirlenir.

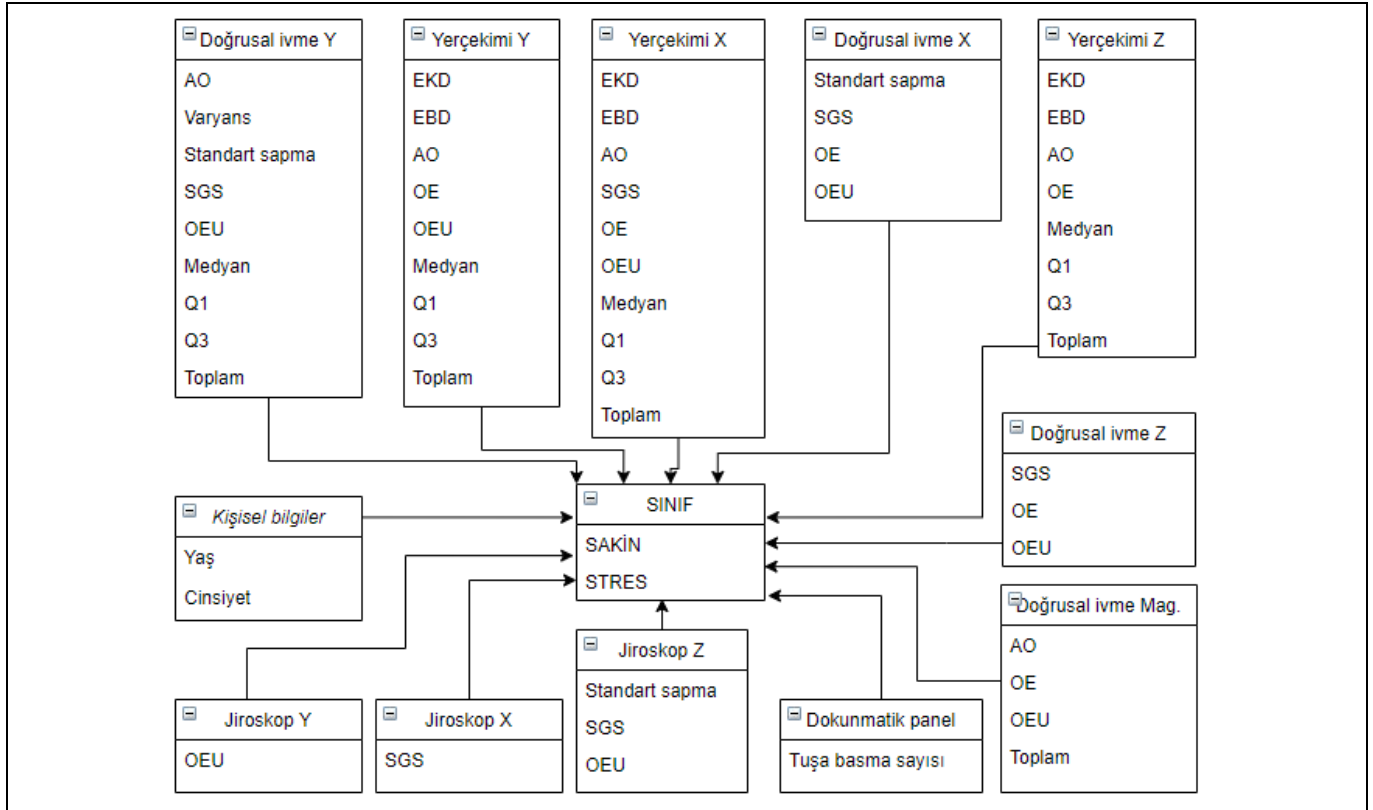
Bu, düğümlerin neyi temsil ettiğini ve hangi değerleri aldıklarını belirler. Ağın topolojisi veya yapısı, değişkenler arasındaki nitel ilişkiyle ilgilidir. Özellikle, iki düğüm birbirini etkiliyorsa veya birinin oluşmasına neden oluyorsa, bu iki düğüm doğrudan bağlantılı olarak gösterilir [33]. Bayes kuralının en kullanışlı uygulamalarından biri Naive Bayes

sınıflandırıcıdır. Naive Bayes modeli, öznitelikler ve sınıf değişkeni arasındaki koşullu bağımsızlığı kodlayan bir Bayes ağı olarak temsil edilebilir. Bu çalışmada, Şekil 7'de görüldüğü gibi bağımsız özniteliklere sahip bir Bayes ağ yapısı oluşturulmuştur.



Şekil 6. Aykırı verileri temizlenmiş veri kümesi için en yüksek dereceye sahip üç öznitelğin görselleştirilmesi.

Figure 6. Visualization of the features that have the highest three ranks for the dataset with outlier cleaned.



Şekil 7. Bayes ağları yapısı.

Figure 7. Structure of Bayesian networks.

5 Deneysel bulgular ve tartışma

Çalışmada akıllı telefonda elde edilen veriler ile stresin tespiti için makine öğrenmesi tabanlı bir yaklaşım önerilmiştir. Hesaplamalarda Weka veri madenciliği aracı [29] ve Java programlama dili kullanılmıştır. Testler 10 katlı çapraz doğrulama kullanılarak Intel Core i5 7400 3.0 Ghz işlemcili bilgisayar üzerinde gerçekleştirilmiştir. Modellerin çıktıları karşılaştırılırken çeşitli performans değerlendirme ölçütleri hesaplanmıştır. Bunlar, precision, recall, f-score ve sınıflandırma doğruluğu (SD)'dir. Bu ölçümlere ait formüller sırası ile Denk. 18 – Denk. 21'de verilmiştir.

$$precision = \frac{true\ positive}{true\ positive + false\ positive} \quad (18)$$

$$recall = \frac{true\ positive}{true\ positive + false\ negative} \quad (19)$$

$$f - score = \frac{2 * precision * recall}{precision + recall} \quad (20)$$

$$SD = \frac{100 * doğruTahmin}{toplamlar\ örnek\ sayısı} \quad (21)$$

5.1 ReliefF öznelik değerlendirme

ReliefF algoritması [34] (Şekil 8) iki sınıflı problemlerle sınırlı değildir. Gürültülü ve eksik verilerle başa çıkabilir. Relief'e benzer şekilde, ReliefF rastgele bir R_i örneğini seçer, ancak daha sonra aynı sınıftan en yakın isabetler H_j olarak adlandırılan k adet en yakın komşusunu arar. Ayrıca her bir diğer sınıftan da k adet en yakın hatalar $M_j(C)$ olarak en yakın komşuları hesaplar. R_i , H_j ve $M_j(C)$ değerlerine bağlı olarak tüm A öznelikleri tahmin değerlerini $W[A]$ günceller. Tüm isabetler ve hataların katkılarının ortalamasının alınması dışında güncelleme formülü Relief'in formülüne benzemektedir. Her bir hata sınıfının katkısı, sınıfın önceki olasılığı $P(C)$ ile ağırlıklandırılır. Her adımdaki isabetlerin ve hataların katkılarının $[0, 1]$ aralığında ve aynı zamanda simetrik olması istendiğinden, hataların olasılık ağırlıklarının toplamının 1 olmasını sağlanmalıdır. Toplamda isabet sınıfı az olduğu için her olasılık ağırlığı $1-P(\text{sınıf}(R_i))$ ögesine bölünmelidir. İşlem m kere tekrarlanır [35].

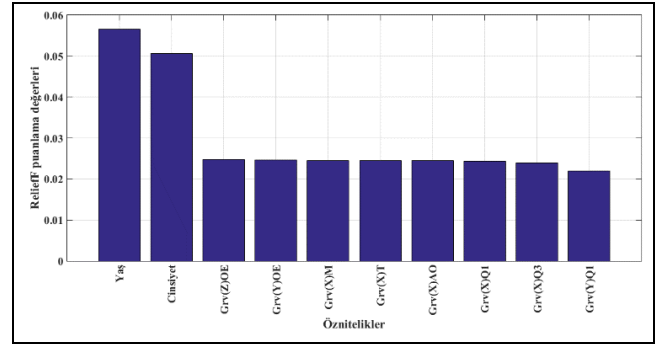
Girdi: Her eğitim örneği için öznelik değerleri ve sınıf değeri içeren bir vektör
Çıktı: Özneliklerin değerlerini tahminlerinin içeren bir W vektör

1. Bütün ağırlıkları ayarla. $W[A] := 0.0$;
2. **for** $i:=0$ **to** m **do begin**
3. Rastgele bir R_i örneği seç;
4. En yakın k adet isabetleri H_j bul;
5. **for** her sınıf $C \neq \text{sınıf}(R_i)$ **do**
6. En yakın k adet hata $M_j(C)$ değerini her sınıftan bul;
7. **for** $A := 1$ **to** a **do**
8. $W[A] := W[A] - \sum_{j=1}^k \frac{diff(A, R_i, H_j)}{m.k} + \sum_{C \in \text{sınıf}(R_i)} \frac{P(C)}{1 - P(\text{sınıf}(R_i))} \sum_{j=1}^k \frac{diff(A, R_i, M_j(C))}{m.k}$;
10. **end**;

Şekil 8. ReliefF algoritmasının sözde kodu.

Figure 8. Pseudo code of the ReliefF algorithm.

Bu çalışmada, sınıflandırma aşamasına geçmeden önce elde edilen veri kümelerinin öznelikleri ReliefF algoritması kullanılarak derecelendirilmiştir. Sonrasında en büyük değere sahip öznelikler kullanılarak en iyi N elemanlı alt kümeler elde edilerek sınıflandırmalar tekrarlanmıştır. ReliefF yönteminden elde edilen puanlar büyükten küçüğe Ö21, Ö40, Ö55, Ö5, ..., Ö110 olarak elde edilmiş olsun. En iyi N elemanlı alt küme yaklaşımı ile öncelikle Ö21 sınıflandırılır. Devamında Ö21 ve Ö40 özneliklerinin beraber oluşturdukları veri kümesi test edilir. Sonrasında Ö21, Ö40 ve Ö55 ile sınıflandırma tekrarlanır. Bu işlem veri kümesindeki bütün öznelikler dahil oluncaya kadar devam eder. Aykırı verilerin temizlenmesi öncesi ve sonrasında ReliefF yönteminden elde edilen öznelik puanlarının sıralaması değişiklik göstermektedir. Şekil 9'da aykırı veriler temizlendikten sonra elde edilen veri kümesinin en yüksek puanlı 10 adet özneliğinin puanlama değerleri sunulmuştur.



Şekil 9. İlk 10 özneliğinin ReliefF puanlaması.

Figure 9. ReliefF scores of the first 10 features.

Şekil 9'daki grafikte yerçekimi Grv ile ifade edilmiştir. Parantez içindeki ifade ise elde edildiği eksen belirtmektedir. Grafikten görüldüğü üzere en yüksek puana sahip öznelikler kişisel bilgiler olan cinsiyet ve yaş öznelikleridir. Sonrasında gelen öznelikler ise yerçekimi algılayıcısının X ve Y eksenlerinden elde edilen verilerden çıkartılan özneliklerdir. İlk 10 özneliğinin 8 tanesi yerçekimi algılayıcısından sağlanan verilerden elde edilmiştir. Bu da kişinin telefonu tutuş pozisyonunun önemini göstermektedir.


5.2 Bulgular

Çalışmanın ilk basamağında ivmeölçer, jiroskop gibi hareket algılayıcıları ve dokunmatik ekrandan elde edilen veriler kaydedilerek bir veri kümesi oluşturulmuştur. Sonrasında elde edilen ham verilerden çeşitli istatistiksel formüller kullanılarak öznelikler çıkartılmıştır. Devamında veri kümesindeki aykırı veriler geliştirilen Mahalanobis uzaklığı tabanlı bir yaklaşım ile tespit edilmiş ve veri kümesinden temizlenmiştir. Böylece aykırı verilerin temizlendiği ve temizlenmediği iki ayrı veri kümesi elde edilmiştir. Her iki veri kümesinde de çıkartılan özneliklerden daha verimli sonuçlar elde etmek için ReliefF öznelik değerlendirme yöntemi kullanılmıştır. ReliefF tarafından derecelendirilen öznelikler akıllı telefon kullanıcılarının stresli olup olmadığının yüksek hassasiyetle saptanması amacı ile üç farklı makine öğrenmesi yöntemi (Bayes ağları, kNN ve C4.5 karar ağacı) ile test edilmiştir.

Deneylerin ve performans değerlendirmesinin akış şeması Şekil 10'da, aykırı verileri temizlenmemiş veri kümesi ile gerçekleştirilen deneyler sonucu elde edilen doğruluk oranlarındaki değişim ise Şekil 11'de gösterilmektedir.


Şekil 11 incelendiğinde en iyi sonucun kNN yöntemi ile sağlandığı görülmektedir. Bu yöntemi C4.5 takip etmiştir. Bayes ağları yönteminin başarı oranı ise diğer yöntemlerden çok düşük kalmıştır. Ek olarak, kNN ve C4.5 yöntemlerinde ilk 10 öznelik ile başarı oranının ciddi miktarda arttığı gözle

çarpılmaktadır. Sonrasında kNN doğruluk oranını artırmaya devam ederken C4.5 ise düşüşe geçmiştir. Bayes ağları ise yaklaşık 50 öznelikten sonra çok fazla bir değişim göstermemiştir. Şekil 11’de sunulan sınıflandırma sonuçlarına ait hesaplama sürelerindeki değişim Şekil 12’de gösterilmiştir.




Şekil 10. Deneilerin akış şeması.

Figure 10. Flowchart of the experiments.



Şekil 11. Aykırı verilerin temizlenmediği veri kümesindeki doğruluk oranlarındaki değişim.

Figure 11. Variation in classification accuracies of the dataset where outlier data is not cleaned.



Şekil 12. Aykırı verilerin temizlenmediği veri kümesindeki hesaplama sürelerindeki değişim.

Figure 12. Variation in run times of the dataset where outlier data is not cleaned.

Hesaplama süreleri üç sınıflandırma yöntemi için de doğrusal bir artış göstermiştir. En hızlı yöntem Bayes ağları olurken en yavaş yöntem C4.5 olmuştur. 168 adet öznitelige sahip alt kümenin sınıflandırılması C4.5 için 9 saniyenin üzerinde sürerken kNN için yaklaşık 3 saniye, Bayes ağları için ise 2 saniyeden az sürmüştür. Elde edilen en başarılı sınıflandırmalara ait performans metrikleri Tablo 4'te sunulmaktadır.

Tablo 4. Aykırı verilerin temizlenmediği veri kümesindeki ortalama sınıflandırma sonuçları.

Table 4. Average classification results of the dataset where outlier data is not cleaned.

Yöntem	SD	Precision	Recall	F-score	#öznitelik	Süre (s)
Öznitelik seçimi sonucu elde edilen en iyi sonuçlar						
BA	66.758	0.678	0.741	0.708	59	0.584
kNN	89.722	0.905	0.905	0.905	45	0.989
C4.5	77.564	0.792	0.797	0.794	9	0.597
Öznitelik seçimi uygulanmadan elde edilen sonuçlar						
BA	64.396	0.660	0.711	0.685	168	1.625
kNN	82.473	0.832	0.849	0.841	168	2.872
C4.5	68.777	0.708	0.725	0.716	168	9.492

Tablo 4'te görüldüğü üzere en yüksek doğruluk oranı 89.722 ile kNN yöntemden sağlanmıştır. Bu sınıflandırma için 45 adet öznitelikten oluşan bir öznitelik vektörü kullanılmıştır. Veri kümesinin dengeli yapısından kaynaklı olarak f-score değerleri sınıflandırma doğruluklarına benzerlik göstermiştir. Birbirine yakın sonuçlar veren precision ve recall değerleri ise sınıfların kendi içerisindeki hatalı sınıflandırma oranlarının benzer olduğunu göstermektedir. Hesaplama süreleri ise C4.5 için 0.597 saniye, Bayes ağları için 0.584 saniye ve kNN için ise 0.989 olarak bulunmuştur.

Öznitelik seçimi uygulanmadığında ise bütün yöntemlerde sınıflandırma başarısında düşüş, hesaplama sürelerinde ise

artış gözlemlenmiştir. Tablo 4'te sunulan en iyi sonuçlara ait karmaşıklık matrisleri Tablo 5'te sunulmaktadır.

Tablo 5. Karmaşıklık matrisleri.

Table 5. Confusion matrices.

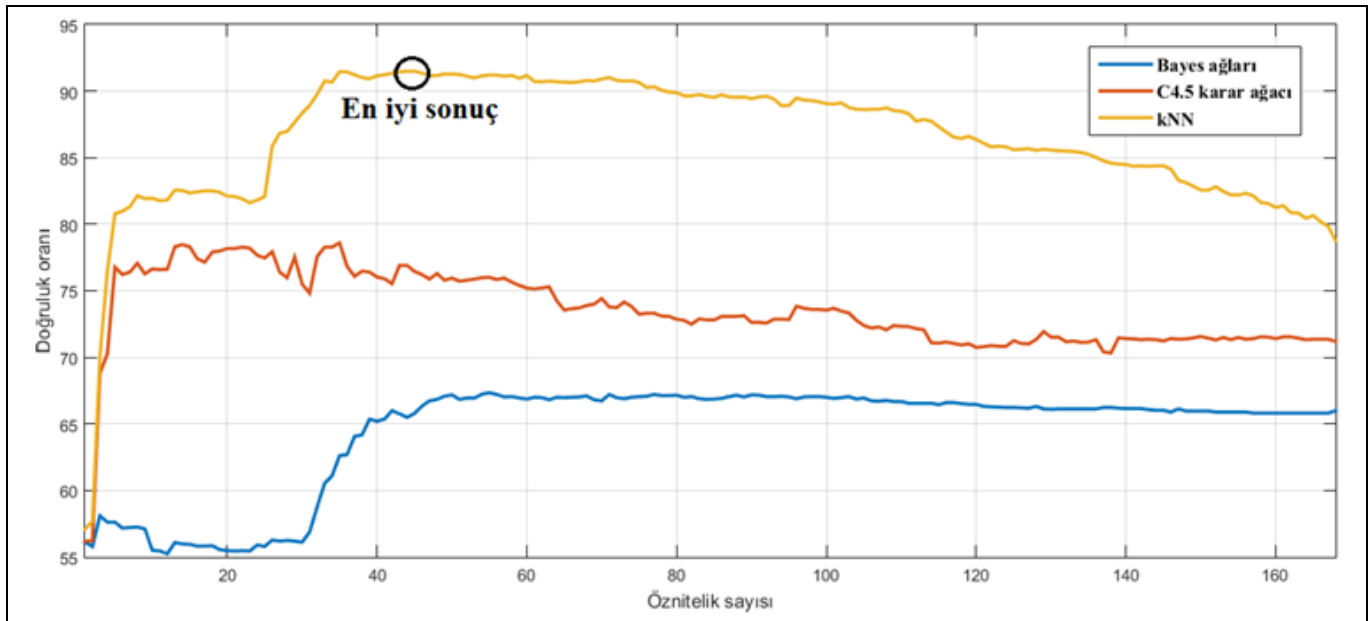
	BA	Sakin	Stres
BA			
Sakin		1153	836
Stres		613	1757

	kNN	Sakin	Stres
kNN			
Sakin		1765	224
Stres		224	2146

	C4.5	Sakin	Stres
C4.5			
Sakin		1493	496
Stres		482	1888


Karmaşıklık matrisleri incelendiğinde stresin daha başarılı sınıflandırıldığı görülmektedir. Bu da, recall değerinin precision değerinden bir miktar daha yüksek hesaplanmasına neden olmaktadır. Aykırı veriler temizlendikten sonra elde edilen veri kümesi ile gerçekleştirilen deneyler sonucu elde edilen doğruluk oranlarındaki değişim Şekil 13'te sunulmaktadır. Aykırı veriler temizlendikten sonra elde edilen grafik incelendiğinde ise kNN ve C4.5 yöntemlerinin doğruluk oranının ilk 5 öznitelik ile ciddi bir artış sergilediği görülmektedir. En iyi sonuç bu deneyde de kNN ile elde edilmiştir. Şekil 13'te sunulan sınıflandırma sonuçlarına ait hesaplama sürelerindeki değişim Şekil 14'te gösterilmiştir.

Hesaplama süreleri aykırı veriler temizlendikten sonra da doğrusal artış göstermiştir. Yöntem bazında sıralama değişmemiştir. En hızlı yöntem Bayes ağları, olurken en yüksek hesaplama süresine sahip yöntem C4.5 olmuştur. En başarılı sonuçlara ait performans metrikleri Tablo 6'da sunulmaktadır.



Şekil 13. Aykırı verilerin temizlendiği veri kümesindeki doğruluk oranlarındaki değişim.

Figure 13. Variation in classification accuracies of the dataset where outlier data is cleaned.



Şekil 14. Aykırı verilerin temizlendiği veri kümesindeki hesaplama sürelerindeki değişim.

Figure 14. Variation in run times of the dataset where outlier data is cleaned.

Tablo 6. Aykırı verilerin temizlendiği veri kümesindeki ortalama sınıflandırma sonuçları.

Table 6. Average classification results of the dataset where outlier data is cleaned.

Yöntem	SD	Precision	Recall	F-score	#Öznitelik	Süre (s)
Öznitelik seçimi sonucu elde edilen en iyi sonuçlar						
BA	67.345	0.700	0.705	0.703	55	0.456
kNN	91.492	0.927	0.917	0.922	44	0.778
C4.5	78.600	0.791	0.828	0.809	35	1.660
Öznitelik seçimi uygulanmadan elde edilen sonuçlar						
BA	65.997	0.685	0.702	0.693	168	1.381
kNN	78.758	0.806	0.806	0.806	168	3.990
C4.5	71.202	0.731	0.750	0.740	168	8.528

En yüksek sınıflandırma doğruluğu 44 adet öznitelik kullanılarak %91.492 ile kNN yönteminden elde edilmiştir. Bu sınıflandırma için precision değeri 0.927, recall değeri 0.917 ve f-score değeri 0.922 olarak hesaplanmıştır. C4.5 karar ağaçlarından 35 adet öznitelik ile %78.6, Bayes ağlarından ise 55 adet öznitelik ile %67.345 sınıflandırma başarısı yakalanmıştır. Ek olarak, kNN ve Bayes ağları yöntemlerinin hesaplama süreleri azalırken, artan öznitelik sayısı ile C4.5 yönteminin hesaplama süresi artmıştır. Öznitelik seçimi gerçekleştirilmeden elde edilen sonuçlar incelendiğinde ise aykırı verilerin temizlenmediği veri kümesinden sağlanan sonuçlara benzer olarak sınıflandırma başarısının azaldığı, hesaplama süresinin ise arttığı gözlemlenmiştir. En iyi sınıflandırmalara ait karmaşıklık matrisleri Tablo 7'de sunulmaktadır.

Karmaşıklık matrisleri incelendiğinde ise sınıflar arasında dengeli bir dağılım olduğu görülmektedir. En iyi sonucun elde edildiği kNN yönteminde sakin örneklerinin %8.7'si stres, stres örneklerinin ise %8.35'i sakin olarak sınıflandırılmıştır. Ortalamada %91'in üzerinde sınıflandırma başarısı yakalanmıştır.

5.3 Tartışma

Çalışma kapsamında Mahalanobis uzaklığı tabanlı aykırı verilerin tespit edilip temizlendiği ve temizlenmediği iki ayrı

veri kümesi test edilmiştir. İki veri kümesine ait karşılaştırmalı sonuçlar Tablo 8'de sunulmaktadır.

Aykırı verilerin temizlenmesinin sınıflandırma performansına etkisi Tablo 8'de özetlenmiştir. Tablo 8 incelendiğinde sınıflandırma doğruluğunun üç yöntem için de artış gösterdiği görülmektedir. Bayes ağları için 0.587, kNN için 1.77 ve C4.5 yöntemi için 1.038 puanlık bir artış gerçekleşmiştir. Aynı zamanda bu daha yüksek sınıflandırma başarısını sağlamak için Bayes ağları yönteminde 4, kNN yönteminde ise 1 adet daha az öznitelik ihtiyacı duyulmuştur. C4.5 yönteminde ise sınıflandırma doğruluğu artarken öznitelik sayısında artış gözlemlenmiştir. Her iki veri kümesi arasında en başarılı sonuç kNN ile (%91.492) elde edilmiştir. Ek olarak hesaplama süreleri Bayes ağları için 0.128 saniye, kNN için ise 0.211 saniye kısalmıştır. Artan öznitelik sayısı ile C4.5 yönteminin hesaplama süresi %178 artarak 1.660 saniye olmuştur.

Bu çalışmanın literatürde bulunan diğer çalışmalar ile birebir karşılaştırılması mümkün değildir. Çalışmalar farklı veri türleri, farklı yaklaşımlar ve farklı veri kümeleri ile değerlendirilmiştir. Bu nedenle karşılaştırma için bu çalışmada olduğu gibi sadece akıllı telefon verilerinden faydalanılan çalışmalar ele alınmıştır.

Tablo 7. Karmaşıklık matrisleri.

Table 7. Confusion matrices.

	BA	Sakin	Stres
Sakin		1088	625
Stres		611	1461

	kNN	Sakin	Stres
Sakin		1564	149
Stres		173	1899

	C4.5	Sakin	Stres
Sakin		1260	453
Stres		357	1715

Tablo 8. Aykırı veri temizliği karşılaştırması.

Table 8. Comparison of the outlier data cleaning.

Yöntem	Aykırı veriler temizlenmemiş veri kümesi			Aykırı veriler temizlenmiş veri kümesi			Fark		
	SD	#öznitelik	Süre	SD	#öznitelik	Süre	SD	#öznitelik	Süre
BA	66.758	59	0.584	67.345	55	0.456	0.587	-4	-0.128
kNN	89.722	45	0.989	91.492	44	0.778	1.77	-1	-0.211
C4.5	77.564	9	0.597	78.600	35	1.660	1.038	+26	1.063

Bu çalışmada yerçekimi, doğrusal ivme, jiroskop ve dokunmatik panel kullanılarak %91.492 doğruluk oranı yakalanmıştır. Bu çalışmaya en yakın çalışma olan [6]'da ivmeölçer, jiroskop ve dokunmatik panelden faydalanılmış ve %87.56 sınıflandırma doğruluğu elde edilmiştir. Lee ve diğ. [24] yedi farklı duyguyu tespit etmek için yazma karakteristiğinden faydalanmıştır. Ciman ve Wac [23], Kim ve Choi [22] ekrana dokunma ve algılayıcı verilerini birlikte kullanmıştır. Ciman ve diğ. [18], Ghosh ve diğ. [19], [20], Gao ve diğ. [21] sadece ekrana dokunma özellikleri kullanarak stresi tespit etmişlerdir. Stütz ve diğ. [12], Muaremi ve diğ. [13], Bauer ve Lokowicz [14], Sysoev ve diğ. [15], Gjoreski ve diğ. [16] ve Bogomolov ve diğ. [17] algılayıcı verileri ve içerik bilgilerini birlikte kullanmışlardır. Vildjiounaite ve diğ. [10] ve Ferdous ve diğ. [11] stresi de içeren duygu durumlarını tespit etmek için sadece içerik bilgilerinden faydalanmışlardır. Lu ve diğ. [7] ses, Garcia-Ceja ve diğ. [9] sadece ivmeölçer ve Wang ve diğ. [8] çeşitli yerleşik algılayıcılar ile stresi tespit etmeyi amaçlamışlardır. Akıllı telefon ile gerçekleştirilen stres tespiti çalışmalarının karşılaştırılması Tablo 9'da sunulmaktadır.

6 Sonuçlar

Bu çalışma akıllı telefon yazma karakteristiği üzerinden stresin tespiti için etkili bir aykırı veri temizleme ve öznitelik seçimi yaklaşımı sunmaktadır. Mahalanobis uzaklığı tabanlı aykırı veri tespiti ve temizliği sonrasında veri kümesinin boyutu yaklaşık %13 kadar küçülmüştür. Sunulan yaklaşım ile stresin tespitinde 1.77 puanlık bir başarı artışı gözlemlenmiştir. ReliefF öznitelik değerlendirme yaklaşımı ile verimsiz özniteliklerin kullanımının önüne geçerek hem bellek hem de zamandan tasarruf sağlanmıştır. Çıkarılan özniteliklerin sadece %26'sı kullanılarak en yüksek sınıflandırma doğruluğu (%91.492) yakalanmıştır. Literatürde çeşitli makine öğrenmesi yaklaşımlarının kullanıldığı görülmektedir. Bu çalışmada ise en başarılı yöntem kNN olmuştur. Uzaklığa dayalı yapılarına bağlı olarak Mahalanobis uzaklığı tabanlı aykırı veri tespiti ve kNN yönteminin birbiri ile çok uyumlu bir yaklaşım olduğu sonucuna varılabilir.

7 Conclusions

This study presents an effective outlier data cleaning and feature selection approach for stress detection through smartphone typing characteristics. After the Mahalanobis distance-based outlier detection and cleaning, the size of the dataset was reduced by about 13%. With the presented approach, an increase of 1.77 points was observed in the detection of stress. With the ReliefF feature evaluation approach, both memory and time savings were achieved by preventing the use of inefficient features. The highest classification accuracy (91.492%) was achieved by using only 26% of the extracted features. It is seen that various machine learning approaches are used in the literature. In this study, the most successful method was kNN. Depending on their distance-based structure, it can be concluded that Mahalanobis distance-based outlier detection and the kNN method are very compatible with each other.

8 Teşekkür

Deneye gönüllü olarak katıldıkları için Ege Üniversitesi Bilgisayar Mühendisliği Bölümü personeline ve Lisans öğrencilerine teşekkür ederiz.

9 Yazar katkı beyanı

Gerçekleştirilen çalışmada bütün yazarlar fikrin oluşturulması ve tasarımın yapılmasında eşit katkıda bulunmuşlardır. Çalışmada kullanılan mobil uygulama Ensar Arif SAĞBAŞ tarafından geliştirilmiştir. Serdar KORUKOĞLU ve Serkan BALLI yazım denetimi ve içerik açısından makalenin kontrol edilmesinde katkı sunmuşlardır.

10 Etik kurul onayı ve çıkar çatışması beyanı

Ege Üniversitesi Bilimsel Araştırma ve Yayın Etik Kurulları tarafından gözden geçirilmiş ve onaylanmıştır. (Etik kurul onay protokol numarası: 11/01-362, Tarih: 26.11.2019).

Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır.

Tablo 9. Akıllı telefon ile gerçekleştirilen stres tespiti çalışmalarının karşılaştırması.

Table 9. Comparison of stress detection studies performed with the smartphone.

Yazar	Yıl	# Sınıf	Algılayıcılar	Başarı metriği	Başarı değeri	Yöntem
Lu ve diğ. [7]	2012	2	Ses	Doğruluk oranı	%81	GMMs
Bauer ve Lokowicz [14]	2012	2	GPS, WiFi, Arama ve SMS kayıtları	Korelasyon incelenmiştir.		
Gao ve diğ. [21]	2012	4	Ekran dokunmuş özellikleri	Doğruluk oranı	%77	Doğrusal DVM
Kim ve Choi [22]	2012	7	Dokunmatik panel, İvmeölçer, Jiroskop	F-Ölçütü	0,82	Karar Ağacı
Lee ve diğ. [24]	2012	7	Yazma karakteristiği, Konum, Hava durumu, Işık	Doğruluk oranı	%67,52	Bayes Ağları
Muaremi ve diğ. [13]	2013	3	Ses, İvmeölçer, GPS, Batarya, Arama kayıtları, Adres defteri, Takvim	Doğruluk oranı	%61	MLR
Wang ve diğ. [8]	2014	4	GPS, Bluetooth, İvmeölçer, Işık, Ses	Korelasyon incelenmiştir.		
Bogomolov ve diğ. [17]	2014	2	Bluetooth, Hava durumu, Arama ve SMS kayıtları	Doğruluk oranı	%72,28	Rastgele Orman
Ciman ve diğ. [18]	2015	2	Ekranı kaydırma, metin girişi	F-Ölçütü	0,92	Karar Ağacı
Sysoev ve diğ. [15]	2015	2	Ses, Jiroskop, İvmeölçer, Işık, Ekran açma kapama	Doğruluk oranı	%77,5	Simple Lojistik
Gjoreski ve diğ. [16]	2015	3	İvmeölçer, Ses, GPS, WiFi, Işık, Arama kayıtları	Doğruluk oranı	>%60	Rastgele Orman
Stütz ve diğ. [12]	2015	2	SMS kayıtları, Işık, Ses, Ekran açma kapama, Yeniden başlatma, Uygulama kullanımı, Ağ trafiği	Korelasyon incelenmiştir.		
Ferdous ve diğ. [11]	2015	5	Uygulama kullanımı	Doğruluk oranı	%75	DVM
Garcia-Ceja ve diğ. [9]	2016	3	İvmeölçer	Doğruluk oranı	%71	Naive Bayes
Ghosh ve diğ. [19]	2017	4	Yazma karakteristiği	Doğruluk oranı	%84	Rastgele Orman
Vildjiounaite ve diğ. [10]	2018	7	Uygulama kullanımı	Doğruluk oranı	%70	HMM
Ciman ve Wac [23]	2018	2	Dokunma istatistiği, Uygulama kullanımı, Aktivite, Işık, Ekran açma kapama	F-Ölçütü	0,88	kNN
Ghosh ve diğ. [20]	2019	4	Yazma karakteristiği	Doğruluk oranı	%78	Rastgele Orman
Sağbaşı ve diğ. [6]	2020	2	Yazma karakteristiği (Dokunmatik panel), İvmeölçer, Jiroskop	Doğruluk oranı	%87,56	Kazanç oranı + kNN
Bu çalışma		2	Yazma karakteristiği (Dokunmatik panel), Yerçekimi, Doğrusal ivme, Jiroskop	Doğruluk oranı	%91,492	Mahalanobis + ReliefF + kNN

11 Kaynaklar

- [1] Sano A, Picard RW. "Stress recognition using wearable sensors and mobile phones". *Humaine Association Conference on Affective Computing and Intelligent Interaction*, Geneva, Switzerland, 2-5 September 2013.
- [2] Can YS, Arnrich B, Ersoy C. "Stress detection in daily life scenarios using smart phones and wearable sensors: A survey". *Journal of Biomedical Informatics*, 92, 1-22, 2019.
- [3] Ballı S, Sağbaşı EA, Peker M. "Human activity recognition from smart watch sensor data using a hybrid of principal component analysis and random forest algorithm". *Measurement and Control*, 52(1-2), 37-45, 2019.
- [4] Güven Z, Diri B, Çakaloğlu T. "Comparison of n-stage latent dirichlet allocation versus other topic modeling methods for emotion analysis". *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35(4), 2135-2145, 2020.
- [5] Gokalp O, Tasci E, Ugur A. "A novel wrapper feature selection algorithm based on iterated greedy metaheuristic for sentiment classification". *Expert Systems with Applications*, 146, 1-10, 2020.
- [6] Sağbaşı EA, Korukoğlu S, Ballı S. "Stress detection via keyboard typing behaviors by using smartphone sensors and machine learning techniques". *Journal of Medical Systems*, 44(4), 1-12, 2020.
- [7] Lu H, Fraundorfer D, Rabbi M, Mast MS, Chittaranjan GT, Campbell AT, Gatica-perez D, Choudhury T. "Stressense: detecting stress in unconstrained acoustic environments using smartphones". *ACM Conference on Ubiquitous Computing*, Pittsburg, USA, 5-8 September 2012.
- [8] Wang R, Chen F, Chen Z, Li T, Harari G, Tignor S, Zhou X, Ben-Zeev D, Campbell AT. "StudentLife: assessing mental health, academic performance and behavioral trends of college students using smartphones". *ACM International Joint Conference on Pervasive and Ubiquitous Computing*, Seattle Washington, 3-14, September 2014.
- [9] Garcia-Ceja E, Osmani V, Mayora O. "Automatic stress detection in working environments from smartphones' accelerometer data: a first step". *IEEE Journal of Biomedical and Health Informatics*, 20(4), 1053-1060, 2015.
- [10] Vildjiounaite E, Kallio J, Kyllönen V, Nieminen M, Määttänen I, Lindholm M, Mäntyjärvi J, Gimel'farb G. "Unobtrusive stress detection on the basis of smartphone usage data". *Personal and Ubiquitous Computing*, 22(4), 671-688, 2018.
- [11] Ferdous R, Osmani V, Mayora O. "Smartphone app usage as a predictor of perceived stress levels at workplace". *International Conference on Pervasive Computing Technologies for Healthcare*, Istanbul, Turkey, 20-23 May 2015.

- [12] Stütz T, Kowar T, Kager M, Tiefengrabner M, Stuppner M, Blechert J, Wilhelm FH, Ginzinger S. "Smartphone based stress prediction". *UMAP: International Conference on User Modeling, Adaptation and Personalization*, Dublin, Ireland, 29 June - 3 July 2015.
- [13] Muaremi A, Arnrich B, Tröster G. "Towards measuring stress with smartphones and wearable devices during workday and sleep". *BioNanoScience*, 3(2), 172-183, 2013.
- [14] Bauer G, Lukowicz P. "Can smartphones detect stress-related changes in the behaviour of individuals?". *International Conference on Pervasive Computing and Communications Workshops*, Lugano, Switzerland, 19-23 March 2012.
- [15] Sysoev M, Kos A, Pogačnik M. "Noninvasive stress recognition considering the current activity". *Personal and Ubiquitous Computing*, 19(7), 1045-1052, 2015.
- [16] Gjoreski M, Gjoreski H, Lutrek M, Gams M. "Automatic detection of perceived stress in campus students using smartphones". *International Conference on Intelligent Environments*, Prague, Czech Republic, 15-17 July 2015.
- [17] Bogomolov A, Lepri B, Ferron M, Pianesi F, Pentland A. "Daily stress recognition from mobile phone data, weather conditions and individual traits". *ACM international conference on Multimedia*, Orlando, Florida, USA, 3-7 November 2014.
- [18] Ciman M, Wac K, Gaggi O. "iSenseStress: assessing stress through human-smartphone interaction analysis". *International Conference on Pervasive Computing Technologies for Healthcare*, Istanbul, Turkey, 20-23 May 2015.
- [19] Ghosh S, Ganguly N, Mitra B, De P. "Tapsense: Combining self-report patterns and typing characteristics for smartphone based emotion detection". *International Conference on Human-Computer Interaction with Mobile Devices and Services*, Vienna, Austria, 4-7 September 2017.
- [20] Ghosh S, Sahu S, Ganguly N, Mitra B, De P. "EmoKey: an emotion-aware smartphone keyboard for mental health monitoring". *International Conference on Communication Systems & Networks*, Bengaluru, India, 7-11 January 2019.
- [21] Gao Y, Bianchi-Berthouze N, Meng H. "What does touch tell us about emotions in touchscreen-based gameplay?". *ACM Transactions on Computer-Human Interaction*, 19(4), 1-30, 2012.
- [22] Kim HJ, Choi YS. "Exploring emotional preference for smartphone applications". *IEEE Consumer Communications and Networking Conference*, Las Vegas, NV, USA, 14-17 January 2012.
- [23] Ciman M, Wac K. "Individuals' stress assessment using human-smartphone interaction analysis". *IEEE Transactions on Affective Computing*, 9(1), 51-65, 2016.
- [24] Lee H, Choi YS, Lee S, Park IP. "Towards unobtrusive emotion recognition for affective social communication". *IEEE Consumer Communications and Networking Conference*, Las Vegas, NV, USA, 14-17 January 2012.
- [25] Sağbaşı EA, Ballı S. "Akıllı telefon sensörlerinin kullanımı ve ham sensör verilerine erişim". *XVII. Akademik Bilişim Konferansı*, Eskişehir, Türkiye, 4-6 Şubat 2015.
- [26] Stroop JR. "Studies of interference in serial verbal reactions". *Journal of Experimental Psychology*, 18(6), 643-662, 1935.
- [27] Sağbaşı EA, Ballı S. "Akıllı telefon algılayıcıları ve makine öğrenmesi kullanılarak ulaşım türü tespiti". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 22(5), 376-383, 2016.
- [28] Sağbaşı EA, Ballı S. "Akıllı saat algılayıcıları ile insan hareketlerinin sınıflandırılması". *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 21(3), 980-990, 2017.
- [29] Witten IH, Frank E. "Data mining: practical machine learning tools and techniques with Java implementations". *ACM Sigmod Record*, 31(1), 76-77, 2002.
- [30] Ghorbani H. "Mahalanobis distance and its application for detecting multivariate outliers". *Facta Universitatis, Series: Mathematics and Informatics*, 34(3), 583-95, 2019.
- [31] Yuksel AS, Senel, FA, Cankaya IA. "Classification of soft keyboard typing behaviors using Mobile device sensors with machine learning". *Arabian Journal for Science and Engineering*, 44(4), 3929-3942, 2019.
- [32] Peker M, Arslan A, Şen B, Çelebi FV, But A. "A novel hybrid method for determining the depth of anesthesia level: Combining ReliefF feature selection and random forest algorithm (ReliefF+ RF)". *International Symposium on Innovations in Intelligent Systems and Applications*, Madrid, Spain, 2-4 September 2015.
- [33] Ballı S, Sağbaşı EA. "Diagnosis of transportation modes on mobile phone using logistic regression classification". *IET Software*, 12(2), 142-151, 2018.
- [34] Kononenko I. "Estimating attributes: analysis and extensions of Relief". *ECML: European Conference on Machine Learning*, Catania, Italy, 6-8 April 1994.
- [35] Robnik-Šikonja M, Kononenko I. "Theoretical and empirical analysis of ReliefF and RReliefF". *Machine Learning*, 53(1), 23-69, 2003.