



Depresyonda motor aktivitenin makine öğrenmesi ile değerlendirilmesi

Evaluation of motor activity in depression with machine learning

Selim Aras^{1,*}, Neriman Aras², M. Alptekin Engin³

¹ Ondokuz Mayıs Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, 55139, Samsun Türkiye

² Samsun Ruh Sağlığı ve Hastalıkları Hastanesi, Psikiyatri Bölümü, 55040, Samsun Türkiye

³ Bayburt Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, 69000, Bayburt, Türkiye

Öz

Psikiyatrik hastalıkların neredeyse tümünde olduğu gibi depresyonun da klinik olarak değerlendirilmesi gözleme ve subjektif hasta şikâyetlerine dayanmaktadır. Psikomotor retardasyon (gerileme) depresyonun önde gelen semptomlarından biridir ve bunun göstergesi olarak depresyonlu hastalarda fiziksel aktivite azalır. Bu çalışmada, depresyonu olan ve olmayan bireylerin günlük fiziksel aktivite verileri ile oluşturulmuş bir veri setini referans olarak kullanarak, depresyon tanısı için makine öğrenimi temelli objektif bir tanı destekleyici yöntem geliştirmek amaçlanmıştır. Geniş bir öznitelik araştırması yapıldıktan sonra, Fisher Öznitelik Seçimi ile en iyi dört öznitelik belirlenmiş ve Toplu Torbalı Ağaç yöntemini kullanarak 0,88 doğruluk ile referans çalışmasından daha iyi bir sınıflandırma sonucu elde edilmiştir. Ayrıca, referans çalışma ile karşılaştırmak için sınırlandırılan dört öznitelikten daha fazlası seçildiğinde doğruluğun 0,90'nın üzerine çıktığı belirlenmiştir. Böylece, fiziksel aktivite verilerini kullanarak geliştirilen makine öğrenimi temelli yöntemle depresyonu olan ve olmayan bireyleri yüksek doğruluk payı ile ayırt edilmesi başarılmıştır. Bu çalışma, aktivite verilerinin depresyonda tanı destekleyici bir araç olarak kullanılabileceğine dair umut verici sonuçlar ortaya koymuştur. Elde edilen sonuçlar, fiziksel aktivite gibi farklı biyobelirteçlerin de makine öğrenimi ile birlikte kullanıldığında, psikiyatrik değerlendirmedeki objektif tanı destekleyici kriterlerin eksikliğini giderebilecek potansiyele sahip olduğunu göstermektedir.

Anahtar kelimeler: Makine öğrenmesi; Öznitelik, Depresyon; Fiziksel aktivite; Psikomotor retardasyon

1 Giriş

Dünya Sağlık Örgütü'ne göre depresyon tüm dünyada 300 milyondan fazla kişiyi etkileyen ciddi ve yaygın bir ruhsal bozukluktur [1]. Depresyon, depresif duygudurum, anhedonia (hayattan zevk alamama), ilgi-istek azalması, iştah ve uyku değişiklikleri, psikomotor yavaşlama ya da ajitasyon, enerji azalması, yorgunluk, konsantrasyon güçlüğü gibi belirtilerle seyrederek, günlük hayatı etkiler ve kişinin işlevselliğinde bozulmaya yol açar [2]. Depresyon kliniğinde depresif duygudurum ön planda olsa da enerji azalması, isteksizlik, yorgunluk ve eşlik eden psikomotor retardasyon, gündelik aktivitelerin yerine getirilmesini

Abstract

The clinical assessment of depression is based on observation and subjective patient complaints of almost all psychiatric disorders. Psychomotor retardation is one of the leading symptoms of depression, and as an indicator of this, physical activity is reduced in depressed patients. In this study, we aimed to develop a machine learning-based objective diagnostic support method for diagnosing depression using a dataset of daily physical activity data of individuals with and without depression as a reference. After detailed feature searches, we identified the four best features by Fisher Feature Selection. Using the Ensemble Bagged Tree method, we achieved a better classification result than the reference study, with an accuracy of 0.88. In addition, we found that the accuracy exceeded 0.90 when more than the four features we limited to compare with the reference study were selected. Thus, we could distinguish between individuals with and without depression with high accuracy with the machine learning-based method, which we developed using physical activity data. This study has shown promising results that activity data can be used as a diagnostic tool for depression. Our results show that different biomarkers, such as physical activity, when used with machine learning, can potentially overcome the lack of objective diagnostic support criteria in psychiatric evaluation.

Keywords: Machine learning; feature; depression; physical activity; psychomotor retardation

zorlaştırır. Bu nedenle depresyon tüm dünyada yetiyitiminin (bireyin ruhsal veya genel tıbbi hastalığı nedeniyle genel yaşamsal işlevlerinde aksama) önde gelen nedenlerinden biridir [3, 4]. Depresyonun 2030 yılına kadar bir numaralı küresel hastalık yükü haline geleceği tahmin edilmektedir [5].

Psikomotor retardasyon (gerileme), depresyondan etkilenen kişinin emosyonel davranışlarını etkilemesinin yanında fiziksel hareketi de azaltır [6]. Depresyonda psikomotor retardasyon, konuşma, yüz ifadesi, duruş, hareketlerin hızı ve kapsamını içerir [7]. Psikomotor retardasyon, depresyonun şiddeti ve bipolarite ile ilişkilidir

* Sorumlu yazar / Corresponding author, e-posta / e-mail: selim.aras@omu.edu.tr (S. Aras)

Geliş / Received: 28.08.2023 Kabul / Accepted: 18.10.2023 Yayınlanma / Published: 15.01.2024

doi: 10.28948/ngumuh.1351103

[8]. Psikomotor retardasyonu fazla olan hastalarda daha erken depresyon başlangıç yaşı, daha uzun hastalık süresi, depresif atakların daha sık, yaşam boyu suicidal girişim sıklığının daha yüksek ve ailede psikiyatrik hastalık öyküsünün daha fazla olduğu bildirilmektedir [8]. Ayrıca psikomotor retardasyon antidepresanlara yanıt ile de ilişkilidir [9]. Psikomotor retardasyon varlığı depresyon alt tiplerinin (psikotik özellikli olan ve olmayan, melankolik depresyon, bipolar depresyon gibi) belirlenmesini sağlayabildiği belirtilmektedir [10].

Major depresyonda görülen psikomotor retardasyon beyin yapısı ve işlevinde değişikliklerle ilişkilidir. Psikomotor retardasyon ile beyin yapısı veya işlevi arasındaki ilişkileri araştıran araştırmaların sonuçları prefrontal beyin bölgelerine lokalize olmuştur. Depresyonlu bireylerde motor aktivite, prefrontal korteks motor devrelerindeki beyaz cevher bütünlüğü ile ilişkilidir. Beyin görüntüleme çalışmalarında, psikomotor retardasyonun beyinin davranışla ilişkili bölgeleri olan dorsolateral prefrontal korteks, anterior singulat korteks, orbitofrontal korteks, suplementer motor alan ve bazal ganglionlar ile ilişki olduğu bildirilmektedir [9].

İleri görüntüleme tekniklerinden olan difüzyon tensör görüntüleme çalışmalarında depresyonlu hastalarda gösterilen beyaz cevher mikro değişikliklerinin depresyonda motor planlamanın bozulması ve yürümenin yavaşlaması gibi motor davranışlarla ilişkili olduğu bildirilmiştir. Depresyonlu hastalarda fiziksel aktivitede azalma ve yürüyüşte yavaşlama olduğu gösterilmiştir [9]. İnce ve kaba motor aktivitede gecikme, depresyonda önemli bir semptomdur. Bu durum kaudat çekirdek ve putamende dopamin azalması ile ilişkilidir [9]. Hickie ve ark. nörogörüntüleme çalışmalarında kaudat çekirdek bölgesel serebral kan akışı yüzdesinin psikomotor yavaşlama ve beyaz cevher lezyonlarıyla ilişkili olduğunu bildirmiştir [11]. Depresyonda DTI ve 24 saatlik aktigrafi verilerini inceleyen bir çalışmada, majör depresyonda kortiko-kortikal beyaz cevher motor yollarında yapısal değişiklikler olduğu ve bunun depresyonda hareketin başlatılması ile ilişkili olduğu saptanmıştır [9].

Psikiyatrik hastalıkların tamamında olduğu gibi depresyon tanısı da altta yatan nedenlerden bağımsız olarak gözlem ve subjektif hasta şikâyetlerine dayanılarak belirlenir ve takip edilir. Aynı semptomun klinik görünümü hastadan hastaya çok farklı olabilmektedir. Tanı koydurucu herhangi bir tetkik ya da görüntüleme yöntemi henüz mevcut değildir. Klinik ölçekler sadece öngörülen tanıyı destekleyici olarak kullanılabilir, ancak tanı koydurucu özellikleri yoktur. Ayrıca kullanılan ölçekler farklı uygulayıcılar tarafından farklı skorlanabilmektedir.

Psikomotor retardasyonun izlenmesi, majör depresyonda depresyonun şiddetinin belirlenmesinde ve tedavi seyrinin takibinde tanısız, prognostik ve klinik öneme sahiptir [8,10]. Ancak psikomotor retardasyon tipik olarak gözlemlenebilen belirti ve semptomlara dayanan ve görüşmeciler tarafından derecelendirilen ölçeklerle değerlendirilmektedir [8]. Bu nedenle depresyonda yapılabilecek objektif psikomotor değerlendirmeler, depresyonun şiddetinin belirlenmesi,

sınıflandırma ve tedavi sürecinin izlenmesinde faydalı olabilir [1].

Depresyon için kullanılacak objektif psikomotor değerlendirmelerden biri ses ve konuşma analizidir. Depresyonla ilişkili nörofizyolojik değişikliklerin laringeal dinamikleri etkilemesi nedeniyle konuşmada negatif içerik, yavaşlama, ritm ve ton değişiklikleri gözlemlenebilir [12,13]. Makine öğreniminin son yıllarda verimi artan teknikleri sayesinde [14-16] gibi konuşma verisi ile depresyon analizi çalışmaları hız kazanmıştır.

Ruhsal hastalıkların teşhisinde potansiyel bir biyobelirteç olarak kabul edilen bir diğer objektif yöntem olan göz hareketlerinin izlenmesi ve analizi, depresyonda dikkat, odaklanma ve duygusal tepkilerle ilişkilendirilebilir [17,18]. Bu nedenle göz hareketlerinin takibi de objektif psikomotor değerlendirme olarak kullanılabilir. Nitekim depresyonlu hastaların anormal göz hareketlerinin araştırıldığı bir çalışmada, Gao depresif hastalar ve sağlıklı kontroller arasındaki göz hareketlerindeki farklılıkları karşılaştırmak için prosaccade ve antisakkade görevleri kullanılmış ve elde edilen sonuçlar, depresif hastaların, depresif olmayan kontrollerle karşılaştırıldığında farklı göz hareketlerine sahip olduğunu kanıtlamıştır [19].

Depresyonda refleks ve koordinasyon değişikliklerinin yanında, görsel ve işitsel uyaranlara verilen tepkilerin ölçümlerindeki değişiklikler de objektif değerlendirme parametresi olarak kullanılabilir. Kangas, çalışmasında depresif bozukluğu olan hastaları ve depresif olmayan kontrolleri ayırmada işitsel olayla ilgili potansiyelleri inceleyen ayrıntılı bir meta analiz çalışması sunmuştur [20].

Bilişsel testler, depresyon hastalarının bilişsel işlev değişikliklerinin belirlenmesinde objektif bir ölçüm parametresi olarak kullanılabilir. Li, depresyon hastalarında bilişsel bozukluğun tanımlanması, eğitimi ve değerlendirilmesi sürecini araştırdığı hafif ila orta şiddette depresyonu olan deneklerle ortaya koyduğu çalışmasında VR teknolojisine dayalı bilişsel işlev eğitimi ve tedavisinin depresif hastaların bilişsel düzeyini etkili bir şekilde iyileştirebileceğini göstermiştir [21].

Depresyonda kortizol düzeyi, uyku düzeni gibi biyolojik belirteçler objektif değerlendirme imkânı sunabilir. Baek, orta yaşlı yetişkinlerde kısa süreli uyku kısıtlamasının özne parametreler (uykululuk, stres, yorgunluk) ve kortizolün de yer aldığı fizyolojik parametreler üzerindeki etkilerini, bu parametrelerin dinlenme sonrası iyileşme durumunu ve parametreler arasındaki ilişkiler araştırılmıştır [22]. Sonuç olarak, kısa süreli uyku kısıtlamasının bile orta yaşlı yetişkinlerde psikolojik ve fizyolojik stres parametreleri üzerinde olumsuz bir etkiye sahip olabileceğini ve bunları normal seviyelere getirmek için yeterli dinlenme ve uykunun gerekli olduğunu göstermiştir.

Bu çalışmadaki veri setini oluşturan hareketlilik ve fiziksel aktivite ölçümleri de depresyonun objektif psikomotor değerlendirmesinde kullanılacak önemli parametrelerden biridir.

Choi vd. ivmeölçer tabanlı aktigrafi verilerinden çıkarılan on dört sirkadiyen ritim özelliğini kullanmış, seçtiği dört sınıflandırma algoritması içinden XGBoost sınıflandırıcısının depresyon seviyelerini sınıflandırmada daha

başarılı bir sonuç elde ettiğini göstermiştir [23]. Yapılan çalışma hem depresyonun tanımlanması hem de aktigrafi verilerinin uygulanması açısından depresyon ve fiziksel aktivite arasındaki ilişkiye yeni bir bakış açısı getirmiştir.

Kim vd., majör depresif bozukluğu (MDB) olan hastalarda ve sağlıklı bireylerde psiko-davranışsal korelasyonları, özellikle de anlık depresif ruh hali ile nesnel olarak ölçülen davranış dinamikleri arasındaki istatistiksel ilişkileri araştırmıştır [24]. Lokomotor adı verilen bir cihaz ile günlük yaşamdaki spontan fiziksel aktivite sürekli olarak ölçülmüştür. Sonuçların, fiziksel aktivite örüntüsüne dayalı olarak anlık depresif ruh halini objektif olarak tahmin etmenin istatistiksel bir model kullanarak mümkün olabileceği; böylece MDB'nin patojenik süreçlerinin ve patolojik durumlarının sürekli izlenmesini sağlayabileceği bildirilmiştir.

Abbas vd. [25], apatik depresyonu olan ve olmayan ileri yaş erişkinleri belirlemek için bileğe takılan bir aktivite monitöründen alınan fiziksel aktivite verilerini kullanmıştır. Zamana bağlı olarak elde edilen verilerden önışleme sonrası altı adet öznelik çıkarılmıştır. Önerilen özellikler, sigmoidal fonksiyon kullanılarak doğrusal olmayan bir dönüşümden ve temel bileşenler analizi (PCA) ile ortogonal bir dönüşümden geçtikten sonra, öznelikleri ilişkisiz değişkenlere dönüştürerek, apatik bireyleri, diğer deneklerden oldukça kabul edilebilir bir doğrulukla ayırabilmiştir.

Thelagathoti [26], “Depresyon” veri setini [27] kullandığı çalışmada ilk adımda, her bir birey çifti arasındaki çift yönlü korelasyon değerlerini ölçerek temsili korelasyon ağı modeli oluşturan bir grafik modeli içeren hesaplama modeli sunmuştur. Ardından, oluşturulan ağın grafik özelliklerini kullanarak her bir katılımcının depresyon şiddet indeksini elde etmiştir. Elde edilen sonuçlar, önerilen korelasyon ağı modelinin depresyon tanısı konulan katılımcıları kontrol grubundan ayırt etme potansiyeline sahip olduğunu göstermektedir. Aynı veri setini kullanan Raihan, Rastgele Orman, AdaBoost ve Yapay Sinir Ağı gibi makine öğrenimi algoritmalarını kullandığı çalışmada ilgili veri setini ham ve sentezlenmiş şekilde üç farklı şekilde kullanmıştır [28]. Bu çalışma demografik bilgilerle birleştirilen motor aktivite sensörü verilerinin depresyonu tahmin etmede kullanılabileceğini göstermiştir. Benzer şekilde aynı veri setini kullanan bir diğer çalışmada, aktivite verisi özellikleri, değişken uzunluğa sahip kısa dönem bellek yöntemi kullanılarak çıkarılmış ve Destek Vektör Makinesi yöntemi ile temel derin öğrenme algoritmalarına kıyasla üstün performans elde edilebileceği belirtilmiştir [29]. Aynı veri setini kullanan bir diğer çalışmada ise düzgün manifold yaklaşımı ve projeksiyon tabanlı özellik çıkarma ve sinir ağı sınıflandırıcısının kullanıldığı bir yöntem önerilmiş, bu yöntemin internet üzerinden tıbbi cihazlar yardımıyla depresyonu tespit edilebileceği bir yöntem olduğunun üzerinde durmuştur [30].

Bu çalışmada, depresyon grubu ve kontrol grubunda olan bireylerden giyilebilir bir aktigraftan alınan fiziksel aktivite verileri kullanılarak oluşturulan “Depresyon” veri seti [27] kullanılmıştır. Zamana bağlı olarak kaydedilen fiziksel aktivite verilerini ayrıştırabilecek zaman bölgesi için uygun

11 adet özneliğin (karekök ortalama, ortalama mutlak değer, varyans, dalga formu uzunluğu, basit kare integrali, standart sapma, aritmetik ortalama, minimum ve maksimum değer, çarpıklık, basıklık) araştırılması yapılmıştır. Etkin özneliklerin belirlenmesi için 6 farklı filtre tipi öznelik seçim yöntemi (sonsuz gizli, sonsuz, relief-f, karşılıklı bilgi, fisher ve korelasyon tabanlı) kullanılarak 8 farklı makine öğrenmesi tabanlı sınıflandırıcılar (k-en yakın komşuluk, toplu torbalı ağaç, karar ağacı, geniş yapay sinir ağları, naive bayes, doğrusal ve radyal tabanlı destek vektör makineleri, karesel diskriminant analizi) aracılığı ile ayrıntılı bir yöntem geliştirme araştırılması yapılmıştır. Fisher öznelik seçim algoritmasının belirlediği dört öznelik ve toplu torbalı ağaç sınıflandırıcısı ile %88 in üzerinde sınıflandırma başarımları elde edilmiştir.

2 Materyal ve metot

Bu çalışmada ilk adım olarak ilgili veri seti içeri aktarılmış ve ön işleme sonucu günlük aktivite verileri elde edilmiştir. Daha sonra öznelikler, bu veriler üzerinden hesaplanmıştır. Öznelikler etiket verileri ile birlikte sınıflandırma modelinin eğitiminde ve sınanmasında kullanılmak üzere, %80 eğitim ve %20 test olacak şekilde ikiye bölünmüştür. Eğitim aşamasında filtre tipi farklı öznelik seçim yöntemleri uygulanarak özneliklerin önem sırasına göre sıralanması sağlanmıştır. Daha sonra sınırlı sayıda öznelik, 10 kat çapraz doğrulama tekniği kullanılarak farklı makine öğrenmesi tabanlı sınıflandırma algoritmaları uygulanmıştır. Son aşamada ise test verileri ile sınıflandırıcıların başarımları hesaplanmıştır. Şekil 1’de yonteme ait akış şeması gösterilmektedir.




Şekil 1. Sistemin akış şeması

2.1 Veri seti

Geliştirdiğimiz yöntemi ortak bir tabanda karşılaştırmak amacıyla literatürde yer alan ‘Depresyon’ veri seti [27] kullanılmıştır. Veri kümesi, hastaların depresif durumunun şiddeti, Montgomery-Asberg Depresyon Derecelendirme Ölçeği (MADRS) üzerinde tıbbi uzmanlar tarafından yapılan derecelendirmeler kullanılarak etiketlenen unipolar ve bipolar depresyonu olan 23 hastanın ve 32 sağlıklı kontrolün motor aktivite kayıtlarını içermektedir. Hasta kişilerin yaş ortalamaları $42,8 \pm 11$, Sağlıklı kontrollerin ise $38,2 \pm 13$ olarak verilmektedir. Ayrıca hasta kişilerden 13’ünün (%57) ve sağlıklı kontrollerden 12’sinin (%38) erkek olduğu da belirtilmektedir.

Motor aktivite verileri, kişinin tüm yönlerdeki hareketinin yoğunluğunu, miktarını ve süresini bir piezoelektrik ivmeölçer sensörü kullanılarak ölçen ve sağ bileğe takılan bir aktigraf saat yardımıyla elde edilmiştir (Actiwatch, Cambridge Neurotechnology Ltd, İngiltere, model AW4). Örnekleme frekansı 32Hz olan aktigraf saati ile 0,05 g değerinin üzerindeki hareketleri toplam aktivite sayıları bir dakikalık aralıklarla olacak şekilde sürekli olarak kaydedilmiştir. Aktigraf cihazları, 5 ile 20 gün arasında değişebilecek şekilde kontrol ve koşul gruplarında ortalama 12,6 gün boyunca kullanılmıştır. Bu çalışmada kullanılan veriler gece yarısı başlangıcından itibaren bir tam gün geçecek şekilde hazırlanmış ve ham veriden elde edilmiştir. Şekil 2’de veri setindeki unipolar depresyonu olan bir hastanın 24 saatlik aktivite değerlerine ait örnek değerler gösterilmektedir.



Şekil 2. Aktivite verisi

2.2 Kullanılan öznitelikler

Öznitelikler, farklı sınıflara ait verileri belirgin şekilde ayırtmak için hesaplanan parametrelerdir. Örneğin, gün boyunca fiziksel aktivite verisi elde edilen bireylerden depresyon hatalarının, sağlıklı bireylere göre gün içinde ya da uzun süre boyunca ortalama olarak daha az hareket etmeleri beklenir. Dolayısıyla fiziksel verilerin ortalamasını gösteren parametre öznitelik olarak adlandırılır. Çoğu zaman sadece tek bir öznitelik kullanarak doğru bir sınıflandırma tahmini yapmak çok zordur. Bu nedenle detaylı bir öznitelik araştırması yapılması, her öznitelikğin başarıma katkısının

irdelemesi ve özniteliklerin birlikte kullanıldığı kombinasyonların başarımları da incelenmelidir.

Referans veri setini sunan çalışmada [27] gün bazında ortalama etkinlik seviyesi, ilgili standart sapma ve etkinlik olmayan olayların yüzdesi öznitelikleri kullanılmıştır. Gün içerisinde birer dakikalık aralıklarla toplam olarak kaydedilen fiziksel aktivite verileri zamana bağlı genlik değeri olarak elde edildiğinden çalışmamızda zaman alanında değerlendirilmesine uygun özniteliklerin başarımları araştırılmış ve bu özniteliklerin sınıflandırma sonucuna katkıları sonuçlar bölümünde sunulmuştur. Bu çalışmada sırasıyla aşağıda verilen öznitelikler kullanılmıştır.

2.2.1 Karekök ortalama

Karekök Ortalama (KO), bir dizi değerlerin ortalamasını belirlemek için kullanılan istatistiksel bir terimdir. Özellikle değerler zamanın bir fonksiyonu olarak değiştiğinde kullanışlıdır. $x_n, n = 1, \dots, N$ değer kümesinin Karekök Ortalaması, kareleri hesaplanan değerlerin ortalaması alındıktan sonra elde edilen değerlerin kare kökünü alınması ile Denklem 1’deki gibi hesaplanır. Özellikle değerler zamanın bir fonksiyonu olarak değiştiğinde kullanışlıdır.

$$KO = f_1 = \sqrt{\frac{1}{N} \sum_{n=1}^N x_n^2} \quad (1)$$

2.2.2 Ortalama mutlak değer

Ortalama mutlak değer (OMD), her bir veri değeri ile ortalama arasındaki ortalama mesafeyi gösterir. OMD, x_n değer kümesinin mutlak değerlerinin ortalamasıdır. Denklem 2’de gösterildiği şekilde tanımlanır.

$$OMD = f_2 = \frac{1}{N} \sum_{n=1}^N |x_n| \quad (2)$$

2.2.3 Varyans

Varyans, x_n değer kümesi içindeki verilerin ne kadar yayılmış olduğunun istatistiksel bir ölçüsüdür ve standart sapmanın karesi olarak Denklem 3’teki gibi hesaplanır.

$$\sigma^2 = f_3 = \sum_{n=1}^N \frac{(x_n - \mu)^2}{N} \quad (3)$$

2.2.4 Dalga formu uzunluğu

Dalga Formu Uzunluğu (DFU) özniteliği, x_n değer kümesi içinde hareketin gerçekleştiği bölgeyi belirlemek için kullanılmıştır. DFU, karmaşıklığın bir ölçüsünü gösterir ve dalga formunun zaman segmentindeki kümülatif uzunluğudur. Denklem 4’te belirtildiği şekilde hesaplanır;

$$DFU = f_4 = \sum_{n=1}^{N-1} |x_{n+1} - x_n| \quad (4)$$

2.2.5 Basit kare integrali

Basit Kare İntegrali (BKİ), x_n değer kümesinin kare değerlerinin toplamı olarak tanımlanır. Bu çalışmada aktivite verilerinin günlük enerjisi olarak da tanımlanabilir ve [Denklem 5](#)'teki gösterildiği üzere hesaplanır.

$$BKİ = f_5 = \sum_{n=1}^N |x_n|^2 \quad (5)$$

2.2.6 Standart sapma

Dalga Formu Uzunluğu (DFU) özneliği, x_n değer kümesi içinde hareketin gerçekleştiği bölgeyi belirlemek için kullanılmıştır. DFU, karmaşıklığın bir ölçüsünü gösterir ve dalga formunun zaman segmentindeki kümülatif uzunluğudur. Hesaplanması [Denklem 6](#)'da verilmektedir.

$$\sigma = f_6 = \sqrt{\frac{\sum_{n=1}^N (x_n - \mu)^2}{N}} \quad (6)$$

2.2.7 Aritmetik ortalama

Aritmetik Ortalama (μ), x_n değer kümesindeki tüm değerler toplamının değer sayısına bölünmesiyle [Denklem 7](#)'de gösterildiği şekilde hesaplanır.

$$\mu = f_7 = \frac{\sum_{n=1}^N x_n}{N} \quad (7)$$

2.2.8 Minimum ve maksimum değer

Minimum değer (f_9), veri setindeki en küçük değer iken maksimum değer (f_8) ise veri setindeki en büyük değerdir. Kullandığımız veri setinde bu değerler en hareketli ve hareketsiz olunan aktivite durumlarını ifade etmektedir.

2.2.9 Çarpıklık

Çarpıklık (ζ) simetri eksikliğinin bir ölçüsüdür. x_n değer kümesindeki dağılımın simetrik olmadığı durumlarda çarpıklık söz konusudur. Normal bir dağılımda ise çarpıklık sıfırdır. [Denklem 8](#)'de belirtildiği gibi hesaplanmaktadır.

$$\zeta = f_{10} = \frac{(x_n - \pi)^3}{\sigma^3} \quad (8)$$

2.2.10 Basıklık

Çarpıklık (ζ) simetri eksikliğinin bir ölçüsüdür. x_n değer kümesindeki dağılımın simetrik olmadığı durumlarda

çarpıklık söz konusudur. Normal bir dağılımda ise çarpıklık sıfırdır. [Denklem 9](#)'da belirtildiği şekilde hesaplanmaktadır.

$$B = f_{11} = \frac{(x_n - \pi)^4}{\sigma^4} \quad (9)$$

2.3 Özneliklerin seçimi

Sınıflandırma sürecinde öznelikler hesaplandıktan sonra ilgili grupları en iyi temsil eden özneliklerin seçilmesi önemlidir. Öznelik seçimi vasıtasıyla gereksiz veriler kaldırılarak öznelik vektör boyutu azaltılır ve bu sayede makine öğrenmesi yöntemlerinin tatbik edilmesinde ilgili yonteme ait algoritmanın çalışma süresi kısalmıştır [31]. Öznelik seçim yöntemleri literatürde filtre, sarıcı ve gömülü olmak üzere üç farklı başlıkta incelenmektedir [32]. Kullanılan sınıflandırma yönteminden bağımsız hesaplanabilmesi sebebiyle yapılan çalışmada bu yöntemlerden sadece filtre tipi olan yöntemler kullanılmıştır. Bir sınıflandırma işleminde farklı sınıflandırıcıların başarımının hesaplanması amaçlanıyor ise filtre tipi öznelik seçim yöntemlerinin kullanılması işlem yükünün az olması sebebi ile hızlı çalışacaktır. Yapılan çalışmada mevcut çalışmalarda çokça tercih edilen Sonsuz Gizli (ILFS) [33], Sonsuz (Inf-FS) [34], Relief-F [35], Karşılıklı Bilgi [36], Fisher [37] ve Korelasyon Tabanlı (CFS) [38], Öznelik Seçimi yöntemleri kullanılmıştır. İlgili yöntemlere ait hesaplama karmaşıklıkları [Tablo 1](#)'de gösterilmektedir.

Tablo 1. Seçim yöntemlerine ait işlem yükleri

Yöntem	Hesaplama Karmaşıklığı
ILFS	$O(n^{2.37} + in + T + C)$
Inf-FS	$O(n^{2.37}(1 + T))$
Relief-F	$O(iTnC)$
MI	$O(iT^2n^2)$
Fisher	$O(Tn)$
CFS	$O\left(\frac{n^2}{2}T\right)$

2.4 Kullanılan sınıflandırma yöntemleri

Yapılan çalışmada öznelik seçim yöntemleri sonucu sıralanmış özneliklerden ilk dört tanesi kullanılarak makine öğrenmesi tabanlı farkı sınıflandırıcılar aracılığı ile sınıflandırma modeli oluşturulmuştur. Kullanılan yöntemler aşağıda başlıklar halinde tanımlanmaktadır.

2.4.1 K-En yakın komşuluk (KNN)

Kullanım kolaylığı ve hızlı sonuç vermesi nedenleri ile sıklıkla tercih edilen makine öğrenme algoritmalarından biri olan KNN algoritması, diğer çoğu sınıflandırıcıların aksine verilerin iç içe girdiği zor durumlarda yüksek başarımla elde edebilir. Ancak bunun için veri kümesinin tüm değişken koşullara uygun şekilde ve sayıda oluşturulması gerekir. Bir test verisinin sınıfı tahmin edilmek istendiğinde, test edilecek veriye eğitim kümesindeki en yakın k adet noktanın sınıfına bakılır. En yakın noktaların belirlenmesinde bu çalışmada Öklid uzaklığı hesabı kullanılmıştır. Elde edilen k adet en yakın eğitim kümesi verilerinin en çok hangi sınıfa ait verisi var ise test verisinin o sınıfa ait olduğuna karar

verilir. Bu nedenle kesin karar verebilmek için çoğu zaman k katsayısı tek sayı olarak seçilir. Diğer durumlarda ise sınıfın belirlenmesinde uzaklık sıralamasına bakılır. Yapılan çalışmada k katsayısı bir olarak alınmıştır.

2.4.2 Toplu torbalı ağaç (TTA)

Toplu (ensemble) sınıflandırma yöntemleri, birkaç karar ağacından oluşan kombinasyonu bir araya getirerek karar ağacı tahminlerin birleştirilmesi ile daha etkin bir sınıflandırma sonucunu sağlamak amacıyla geliştirilmiştir. Dolayısıyla, tek bir karar ağacı sınıflandırıcısından daha güvenilirdir ve daha yüksek bir performans sunar. Aşırı uymayı (overfitting) azaltığı ve karar ağacı sınıflandırıcısındaki varyansı en aza indirdiği için torbalı ağaç (bagged tree) işlemi tercih edilmiştir [39].

Yöntemde öncelikle eğitim kümesi, birbiri ile çakışmayacak şekilde aynı boyutta alt veri kümelerine bölünür. Böylece birbirinden benzersiz bir veri örnekleme sağlanmış olur. Her alt küme için ayrı bir karar ağacı oluşturulur. Karar Ağacında torbalama kullanmak, birden fazla Karar Ağacından elde edilen sonuçların birleştirilmesi anlamına gelir [40]. Yapılan çalışmada maksimum bölünme sayısı 1592 eğitilen sayısı ise 30 olarak alınmıştır.

2.4.3 Karar ağacı (KA)

Karar Ağacı algoritması, regresyonun yanında sınıflandırmada da kullanılan bir makine öğrenimi algoritmasıdır. Karar ağacı algoritmasının temel avantajlarından biri, dolaylı olarak özellik seçimi yapmasıdır [41]. Öznitelikleri değerlendirerek, verileri adım adım sınıflara atayan bir ağaç yapısı oluşturur. Bazı metrikler kullanılarak veriyi en iyi şekilde sınıflara ayıran en iyi özneliği belirler. Seçilen öznelik kullanılarak veri kümesi alt gruplara ayrılır. Oluşturulan her alt grup için aynı işlemler tekrarlanır. Benzer şekilde, her alt grup için en iyi öznelik belirlenir ve yeni alt gruplar ve düğümler oluşturulur. Oluşan bu dallanma işlemi sonucunda elde edilen son düğümler yaprak düğümlerdir. Bu düğümlerde ise sınıflandırmanın nihai sonucu elde edilir. Yapılan çalışmada maksimum bölünme sayısı 100 ve bölünme kriteri olarak Gini'nin çeşitlilik endeksi kullanılmıştır.

2.4.4 Geniş yapay sinir ağları (YSA)

Geniş Yapay Sinir Ağları (Wide Neural Networks), genellikle girdi katmanında daha fazla nöron veya düğüm içeren yapılardır. Böylece daha karmaşık öğrenme işlevlerini gerçekleştirebilmektedir. Ancak, Geniş Yapay Sinir Ağları daha fazla hesaplama yükü gerektirmektedir. Yapılan çalışmada 1 adet tam bağlı katman, ilk katman boyutu 100, aktivasyon ReLU ve yineleme sınırı 1000 olarak alınmıştır.

2.4.5 Destek vektör makineleri (DVM)

Destek Vektör Makineleri (DVM), sınıflandırma problemlerinde kullanılan denetimli öğrenme metodlarından biridir [42]. Bu yöntemde bir düzlem üzerindeki sınıflara ait noktaları ayırmak için iki sınıfa da maksimum uzaklıkta olan bir doğru çizilir. Karar noktalarına çizilecek en yakın noktalar destek olarak adlandırılır. Doğrusal olarak bir vektör ile sınıflar ayrılabilirse bu durumda lineer çekirdek kullanılmıştır. DVM, boyutu düşük olan veri setlerinde daha

gerçekçi sonuçlar ortaya koysa da çoğu zaman bir doğru çizilerek sınıfları ayırtmak yeterli olmaz. Bu durumda Radyal tabanlı işlev çekirdeği (RBF) gibi farklı kernel fonksiyonları eksenleri çarpmada kullanılır ve doğrusal olmayan bir çizgi ile de sınıflar ayrıştırılır. Çalışmada hem lineer hem de RBF yöntemleri kullanılmış ve karşılaştırılmıştır.

2.4.6 Naive bayes (NB)

Bayes teoremini temel alan Naive Bayes (NB) sınıflandırıcı, bir örneğin önceki olasılığına dayanarak yeni örneğin belirli bir sınıfa ait olma olasılıklarının en yüksek değerine göre tahmin eden bir sınıflandırma yöntemidir [43]. Bu algoritma için her özellik olasılığa katkıda bulunur, ancak birbirleriyle ilişkisiz olarak değerlendirilirler [44]. Yapılan çalışmada sayısal tahmin ediciler için Gauss dağılımı kullanılmıştır.

2.4.7 Karesel diskriminant analizi (KDA)

Karesel diskriminant analizi (KDA), maksimum olabilirlik tahminine dayanan basit bir doğrusal olmayan diskriminant analizidir [45]. İstatistiksel bir sınıflandırma yöntemi olan bu yöntemin adı kuadratik bir karar yüzeyine sahip olmasından gelmektedir. Bu yöntemde veri noktaları, her sınıfın kendi iç dağılımına uygun bir şekilde modellenir. Temel amaç, sınıflar arasındaki istatistiksel farklılıkları kullanarak verileri en iyi şekilde sınıflandırmaktır. Yapılan çalışmada tam kovaryans yapısı kullanılmıştır.

2.5 Karşılaştırma metrikleri

Sınıflandırma modelinin sınanmasında hata matrisi ve bu matristen elde edilen metrikler kullanılmaktadır. Hata matrisi bir sınıflandırma modelindeki gerçek etiket değerleri ile tahmin edilen etiket değerlerinin gösterildiği bir tablodur. Tablo 2'de bu değerlerin detaylı gösterimlerine yer verilmektedir.

Tablo 2. Hata matrisi

Hata Matrisi		Gerçek	
		Pozitif	Negatif
Tahmin	Pozitif	Doğru Pozitif (TP)	Yanlış Pozitif (FP)
	Negatif	Yanlış Negatif (FN)	Doğru Negatif (TN)

Tablo 2'de verilen değerlere göre hesaplanan metrikler ise Tablo 3'te yüzde olarak belirtilmektedir.

Tablo 3. Sınıflandırmada başarımlı ölçüm metrikleri

Metrik	Denklem	Numara
Doğruluk	$\frac{TP + TN}{(TP + TN + FP + FN)}$	(10)
Duyarlılık	$\frac{TP}{(TP + FN)}$	(11)
Özgüllük	$\frac{TN}{(TN + FP)}$	(12)
Kesinlik	$\frac{TP}{(TP + FP)}$	(13)
F1 Skoru	$\frac{2 \times (\text{Kesinlik} \times \text{Duyarlılık})}{\text{Kesinlik} + \text{Duyarlılık}}$	(14)

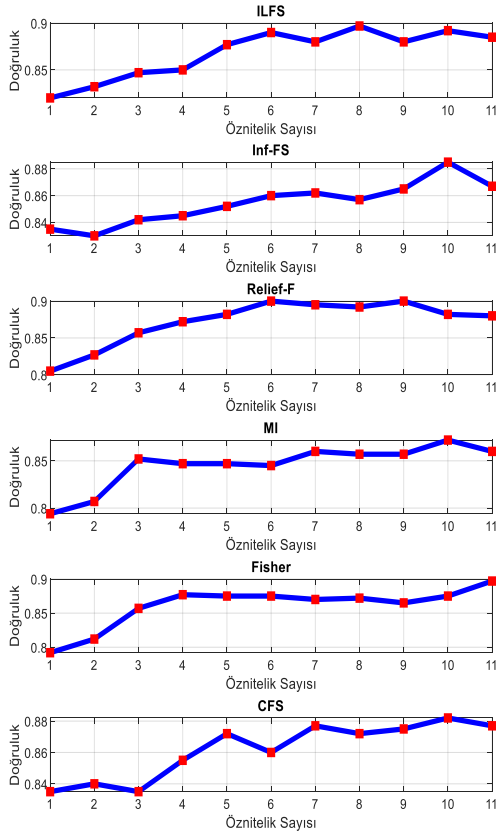
3 Bulgular ve tartışma

Fiziksel aktivite verileri birer dakikalık aralıklarla zamana göre alınan veriler içerdiğinden bu çalışmada zaman bölgesi öznelik çıkarma yöntemleri geniş şekilde araştırılmıştır. Ayrıca, farklı öznelik seçim yöntemleri kullanılarak özneliklerin önem sırasına göre sıralanması sağlanmıştır. Öznelik seçim algoritmasının çalışma süresi ve ilgili veri tabanına ait özneliklerin sıralanması Tablo 4'te belirtilmektedir.

Tablo 4. Kullanılan seçim yöntemlerine ait sonuçlar

Yöntem	Çalışma Süresi (sn.)	Öznelik Sıralaması
ILFS	0.056991	f3, f5, f6, f1, f4, f8, f2, f7, f10, f11, f9
Inf-FS	0.016444	f5, f9, f6, f1, f4, f8, f3, f2, f7, f11, f10
Relief-F	0.362623	f4, f8, f9, f10, f6, f2, f7, f1, f11, f5, f3
MI	0.041658	f9, f3, f5, f6, f8, f1, f4, f11, f10, f2, f7
Fisher	0.063520	f9, f6, f1, f4, f8, f5, f3, f2, f7, f11, f10
CFS	0.012652	f3, f9, f8, f6, f11, f5, f10, f1, f4, f2, f7

Yapılan çalışmada öznelikler ilgili seçim algoritması ile sıralandıktan sonra Toplu Torbalı Ağaç sınıflandırıcısı kullanılarak kullanılan öznelik sayısına göre sınıflandırılmıştır. Elde edilen sınıflandırma doğruluklarına karşılık kullanılan öznelik sayısı grafiği Şekil 3'te gösterilmektedir.



Şekil 3. Öznelik seçim yöntemlerinin sınıflandırma başarımına etkisi

Öznelik seçim yöntemlerinin kullanılması sonucu tüm özneliklerin önem sırasına göre sıralanması sağlanmasına rağmen, Şekil 3'te görüleceği üzere belirli sayıda özneliğin kullanılması durumunda tüm özneliklerin kullanıldığı duruma göre daha yüksek sınıflandırma başarımının edilebileceği görülmektedir. Yapılan çalışmada diğer çalışmalar ile eşit şartlarda karşılaştırma yapılabilmesi açısından öznelik sayısı 4 ile sınırlandırılmıştır. Bu şartlar altında farklı sınıflandırıcılarında kullanılması ile elde edilen sonuçlar Tablo 5'te gösterilmektedir. Tablo 5'teki sonuçların elde edilmesinde veri tabanındaki tüm veriler %80 eğitim ve %20 test olarak ayrılmıştır. Eğitim aşamasında kullanılan öznelik seçim yöntemleri 10 katmanlı çapraz doğrulama ile ele alınmıştır. Eğitim aşamasında oluşturulan sınıflandırma modeli daha sonra test verileri ile sınanmıştır. Tüm bu işlemler her sınıflandırma yöntemi için 10 defa tekrarlanmış ortalama doğruluk ve standart sapma değerleri Tablo 5'te verilmiştir.

Tablo 5. Öznelik seçim yöntemlerinin farklı sınıflandırma yöntemleriyle birlikte kullanılması


Yöntem	KNN	TTA	KA	YSA
ILFS	0.843±0.013	0.845±0.017	0.795±0.014	0.781±0.023
Inf-FS	0.846±0.014	0.854±0.008	0.848±0.003	0.806±0.007
Relief-F	0.842±0.016	0.865±0.011	0.848±0.010	0.855±0.020
MI	0.831±0.016	0.846±0.009	0.820±0.018	0.804±0.019
Fisher	0.845±0.008	0.882±0.005	0.833±0.023	0.826±0.009
CFS	0.849±0.012	0.872±0.016	0.842±0.036	0.807±0.018
	Lineer DVM	RBF DVM	NB	KDA
ILFS	0.748±0.018	0.697±0.001	0.718±0.013	0.721±0.018
Inf-FS	0.779±0.011	0.768±0.008	0.714±0.009	0.717±0.008
Relief-F	0.746±0.018	0.787±0.011	0.783±0.018	0.691±0.009
MI	0.724±0.012	0.777±0.014	0.726±0.009	0.699±0.017
Fisher	0.765±0.028	0.784±0.019	0.736±0.015	0.719±0.035
CFS	0.769±0.014	0.697±0.009	0.719±0.040	0.691±0.018

Tablo 5'e bakıldığında seçili ilk 4 özneliğe göre en başarılı sonuçlara, Fisher öznelik seçim algoritmasının TTA sınıflandırıcısı ile beraber kullanıldığında ulaşılabildiği tespit edilmiştir. En başarılı sonuçlara ait hata matrisi Şekil 4'de gösterilmektedir.


True Class	1	94	27
	2	20	258
		1	2
		Predicted Class	

Şekil 4. Fisher ve TTA yöntemlerinin beraber kullanılması ile elde edilen test hata matrisi

Şekil 5'te her bir sınıf için alıcı işletim karakteristiği (receiver operating characteristic, ROC) eğrileri gösterilmektedir. Bu eğriler, en iyi öznelik birleşimi durumu için doğru pozitif oranına karşı yanlış pozitif oranını göstermektedir. Eğri altındaki alan (area under the curve, AUC) değeri sınıflandırıcının genel başarımının bir ölçüsüdür. Bu alan değeri büyüdükçe ilgili sınıfa ait daha başarılı bir sınıflandırma işleminin gerçekleştiği tespit edilmektedir.



(a)



(b)

Şekil 5. Fisher ve TTA yöntemlerinin beraber kullanılması ile elde edilen ROC ve AUC değerleri (a) Depresyon (b) Depresyonda değil

Sunulan yöntemden elde edilen sınıflandırma doğruluklarının referans çalışma [27] ile karşılaştırıldığı bulgular Tablo 6'de verilmektedir.

Geliştirilen yöntemden elde edilen sınıflandırma doğruluk değerlerinin kullanılan tüm sınıflandırıcılarda referans çalışmaya göre daha iyi sonuç verdiği görülmektedir. Ayrıca, referans çalışmada sunulan en iyi dört öznelik seçimi ile yöntemimizden elde edilen en iyi dört özneliğin diğer başarımlar ölçüm metriklerine göre karşılaştırması Tablo 7'de sunulmaktadır. Standart sapma ve minimum değerleri ortak öznelik olarak yer alırken Dalga Formu Uzunluğu ve Karekök Ortalama öznelikleri referans çalışmaya göre tüm metriklerde daha yüksek değerlere sahip olduğu görülmektedir.

Tablo 6. Bulguların referans çalışma ile karşılaştırılması

Sınıflandırma Yöntemi	Referans Çalışmanın Doğruluğu [27]	Sunulan Yöntemin Doğruluğu
KNN	0.675	0.845
DVM (Linear)	0.727	0.784
DVM (RBF)	0.724	0.765
KA	0.707	0.833
YSA	0.719	0.826
NB	0.694	0.736
KDA	0.700	0.719

Tablo 7. Bulguların referans çalışma ile karşılaştırılması

Başarım Ölçüm Metrikleri	Referans Çalışma [27] DVM (Linear) (Dört öznelik: ortalama, standart sapma, max, min)	Sunulan Yöntem TTA, Fisher Öznelik Seçimi (Dört öznelik: (min, standart sapma, DFU, KO))
Kesinlik	0.735	0.780
Duyarlılık	0.729	0.820
Doğruluk	0.727	0.880
Özgüllük	0.726	0.910
F1-Skoru	0.724	0.800

Sunulan yöntemin, referans çalışmasına [27] göre genel olarak daha doğru tahminler yaptığı yüksek doğruluk değerinden anlaşılmaktadır. Ancak, veri setindeki verilerin denge durumuna göre F1-Skorunun daha anlamlı sonuç vermesi beklenir. Tablo 7 incelendiğinde, benzer şekilde F1-Skor değerinin de referans çalışmasına göre daha yüksek olduğunu, dolayısıyla, geliştirdiğimiz modelin daha dengeli bir performans sergilediği görülmektedir.

Literatürde Depresyon veri setini kullanan ve yüksek başarımlar sunan fakat veri seti üzerinde değişiklikler yapan çalışmalar da bulunmaktadır. Örneğin, 0.99 doğruluk elde eden Zakariah ve Alotaibi [46], 0.84 doğruluk elde eden Jakobsen vd. [47]'nin çalışmasında olduğu gibi %98 F1-Skoru elde eden Raihan vd. [28]'nin çalışmasında da sentetik veri üretilmesini sağlayan bir aşırı örnekleme algoritması (SMOTE) kullanılarak yapay veri üretimi yapılmış ve veri seti yapay olarak büyütülmüştür. Ayrıca, bu çalışmaların bazılarında mevcut veri seti sentez açısından üçe bölünmüş ve aktivite verilerinin dışında demografik veriler de sınıflandırmaya dâhil edilmiştir. Benzer şekilde Aminifar vd. [48] de yapay veri artırma tekniği uyguladığı çalışmada

dağıtık makine öğrenimi yaklaşımı ile %76.8 doğruluk elde etmiştir.

Kumar vd. [49], veri setinde yer alan bireylerin 48 saatlik verisini kullanmış ve bu verilerin ikişer saatlik ortalamalarını alarak Konvülsiyonel nöro bulanık modeli ile 0.851 doğruluk elde etmiştir. Calzada vd. [50] ise grup sayısını dengelemek amacıyla bazı verileri veri setinden çıkararak ilerlemiş ve numunelerin seçiminde 1 saat boyunca elde edilen 60 değerini sadece ilk değeri tutmuştur. İstatistiksel öznelikleri kullanarak rastgele orman sınıflandırıcısı ile 0.893 doğruluk elde etmiştir.

Salinas vd. [51] veri seti içinden yedi günlük verileri seçerek yedi günün altında kaydı olan verileri elemiştir. Kalan veriler, dakika başına her motor aktivite kaydının bir görüntünün pikseli olarak temsil edildiği iki boyutlu bir evrişimsel ağa (2D-CNN) verilmek üzere önceden işlenmiş ve %76.72'lik doğruluk oranı elde etmiştir.

Yapılan çalışmada farklı öznelik seçim yöntemleri kullanılarak mevcut öznelikler önem sırasına göre **Tablo 4**'te belirtildiği üzere sıralanmaktadır. Öznelik sayısının sınırlandırıldığı durum için Fisher öznelik seçimi yönteminde kullanılan ilk dört özneliğin ilgili sınıfları diğer yöntemlere göre daha iyi temsil edebildikleri deneysel olarak ispat edilmiştir. Ayrıca yapılan çalışmada öznelik sayısının sınırlandırılmadığı ve en az özneliğin kullanıldığı durum için en yüksek sınıflandırma doğruluğu, Relief-F öznelik seçimi yöntemi akabinde tespit edilen ilk 6 adet özneliğin TTA sınıflandırma yöntemi ile beraber kullanıldığı modelde % 90.05 olarak tespit edilmiştir.

4 Sonuçlar

Bu çalışmada, günlük fiziksel aktivite verilerinden yola çıkarak depresyonda tanı destekleyici makine öğrenimi temelli bir yöntem geliştirilmiştir. Ayrıca 24 saatlik tam gün verilerini kullanarak referans çalışmada sunulan veri setine bağlı kalınmıştır. Çalışmada gün içinde birer dakikalık aralıklarla sunulan veri setindeki değerler üzerinden Fisher öznelik seçimi yöntemi ile belirlenen minimum değer, standart sapma, dalga formu uzunluğu ve karekök ortalama öznelikleri kullanılmıştır. Temelinde birkaç karar ağacından oluşan kombinasyonu kullanan Toplu Torbalı Ağaç sınıflandırma yöntemi ile referans çalışmasına göre doğruluğu 0,153 kadar artırarak 0,88 doğruluk değerinde ulaşım başarılmıştır. F1-Skoru da referans çalışmaya göre 0.724'ten 0,800 değerine çıkarılmıştır.

Literatürde yüksek başarıma sahip yapılan çalışmaların çoğu veri setini bölerek, azaltarak ya da yapay olarak çoğaltarak başarıyı artırmaktaydı. Bu durum daha geniş bir veri seti ihtiyacının olduğuna işaret etmektedir. Yeterli bir veri setinde tüm yöntemlerin ortak bir paydada karşılaştırılması mümkün olacaktır.

Literatürdeki diğer çalışmaların sonuçları ile birlikte bu çalışmadan elde ettiğimiz sonuçlar da değerlendirildiğinde, fiziksel aktivite verilerinin makine öğrenim algoritmaları ile yorumlandığı uygun bir modelin depresyonda destekleyici tanı olarak katkı potansiyelinin yüksek olduğu görülmektedir.

Özetle bu çalışmada, depresyonu olan ve olmayan bireyleri fiziksel aktivite verilerini kullanarak geliştirdiğimiz

makine öğrenimi temelli yöntemle %88 doğruluk payı ile ayırt etme sağlanmıştır. Sadece dört öznelik kullanarak elde ettiğimiz bu başarımın, öznelik sayısını arttırdığımızda %90'ın üzerine çıkabildiğini de gösterilmiştir.

Elde edilen sonuçlar, depresyonun en temel özelliklerinden biri olarak kabul edilen psikomotor retardasyonun (konuşma, yüz ifadesi, ses tonu, göz hareketleri ve duruş yanında fiziksel hareketlerin hızı vb.) makine öğrenimi ile objektif olarak hem niceliksel hem de niteliksel olarak analiz edilebileceği potansiyeli taşıdığını göstermektedir. Bu yöntem sayesinde, klinik görüşme ve sübjektif hasta şikayetlerine dayanan depresyon tanısının desteklenmesi, semptom şiddetinin değerlendirilmesi ve tedavi sürecinin takibinde bireysel değerlendirmelerden kaynaklanan farklılıkların en aza indirgenmesinin mümkün olabileceği değerlendirilmektedir.

Bu çalışmadan elde edilen tecrübe sayesinde, sonraki çalışmalarımızda, fiziksel aktivitenin yanında farklı biyobelirteçlerin de değerlendirilebileceği geniş ve dengeli bir veri seti oluşturmak ve mevcut çalışmalarda yaygın olarak kullanılan temel istatistiksel özneliklerin yanında bu biyobelirteçleri daha iyi temsil edebilecek farklı özneliklerin de eklenmesi ile depresyon tanısını destekleme ve tedavi takibini sağlamada kullanılacak en uygun modeli araştıracağız. Ayrıca bu modelin tespitinde Poligon Alan Ölçütü Yaklaşımı [52] gibi yenilikçi karşılaştırma metriklerinin de kullanılması planlanmaktadır. Uygun modelin bulunması ve kullanılması, gerçek zamanlı uygulamalarda öznelik vektör boyutunu ve hesaplama karmaşıklığını azaltacağı için gelecekteki çalışmalarımızda tamamen otomatik olarak çalışan ve depresyon tespitinde hekimlere yardımcı olabilecek bir cihazın tasarımına odaklanacağız.

Çıkar çatışması

Yazarlar arasında çıkar çatışması bulunmamaktadır.

Benzerlik oranı (iThenticate): %7

Kaynaklar

- [1] Z. S. Syed, K. Sidorov, and D. Marshall, Depression severity prediction based on biomarkers of psychomotor retardation. Proceedings of the 7th Annual Workshop on Audio/Visual Emotion Challenge, pp. 37-43, Mountain View, CA, USA, 2017.
- [2] American Psychiatric Association, Desk reference to the diagnostic criteria from DSM-5 (R). Arlington, TX: American Psychiatric Association Publishing, 2013.
- [3] D. Schrijvers, E. R. A. de Bruijn, Y. Maas, C. De Grave, B. G. C. Sabbe, and W. Hulstijn, Action monitoring in major depressive disorder with psychomotor retardation, *Cortex*, 44(5), 569-579, 2008. <https://doi.org/10.1016/j.cortex.2007.08.014>.
- [4] W. H. Liu, L. Z. Wang, H. R. Shang, Y. Shen, Z. Li, E. F. Cheung, R. C. Chan, The influence of anhedonia on feedback negativity in major depressive disorder, *Neuropsychologia*, 53, 213-220, 2014. <https://doi.org/10.1016/j.neuropsychologia.2013.11.023>.

- [5] S. A. Almaghrabi, S. R. Clark, and M. Baumert, Bioacoustic features of depression: A review, *Biomed. Signal Process. Control*, 85, 105020, 1-16 2023. <https://doi.org/10.1016/j.bspc.2023.105020>.
- [6] D. Bennabi, P. Vandel, C. Papaxanthis, T. Pozzo, and E. Haffen, Psychomotor retardation in depression: a systematic review of diagnostic, pathophysiological, and therapeutic implications, *Biomed Res. Int.*, 2013, 158746, 1-13, 2013. <https://doi.org/10.1155/2013/158746>.
- [7] T. Bracht, A. Federspiel, S. Schnell, H. Horn, O. Höfle, R. Wiest, T. Dierk, W. Strik, T. J. Müller, S. Walther, Cortico-cortical white matter motor pathway microstructure is related to psychomotor retardation in major depressive disorder, *PLoS One*, 7(12), 1-8. e52238, 2012.
- [8] S. Calugi, G. B. Cassano, A. Litta, P. Rucci, A. Benvenuti, M. Miniati, L. Lattanzi, V. Mantua, V. Lombardi, A. Fagiolini, and E. Frank, Does psychomotor retardation define a clinically relevant phenotype of unipolar depression?, *J. Affect. Disord.*, 129(1-3), 296-300, 2011.
- [9] S. Walther, S. Hügli, O. Höfle, A. Federspiel, H. Horn, T. Bracht, R. Wiest, W. Strik, and T. J. Müller, Frontal white matter integrity is related to psychomotor retardation in major depression, *Neurobiol. Dis.*, 47(1), 13-19, 2012.
- [10] D. Schrijvers, W. Hulstijn, and B. G. C. Sabbe, Psychomotor symptoms in depression: a diagnostic, pathophysiological and therapeutic tool, *J. Affect. Disord.*, 109(1-2), 1-20, 2008.
- [11] I. B. Hickie, S. L. Naismith, P. B. Ward, C. L. Little, M. Pearson, and E. M. Scott, Psychomotor slowing in older patients with major depression: relationships with blood flow in the caudate nucleus and white matter lesions, *Psychiatry Res.*, 155(3), 211-220, 2009.
- [12] T. F. Quatieri and N. Malyska, Vocal-source biomarkers for depression: A link to psychomotor activity Proc, Conf. Int. Speech Commun. Assoc., Interspeech, International Speech Communication Association (ISCA), pp. 1059-1062, 2012.
- [13] N. Cummins, S. Scherer, J. Krajewski, S. Schnieder, J. Epps, and T. F. Quatieri, A review of depression and suicide risk assessment using speech analysis, *Speech Commun.*, 71, 10-49, 2015.
- [14] D. Shin, W. I. Cho, C. H. K. Park, S. J. Rhee, M. J. Kim, H. Lee, N. S. Kim, and Y. M. Ahn, Detection of minor and major depression through voice as a biomarker using machine learning, *J. Clin. Med.*, 10(14), 3046, 2021. <https://doi.org/10.3390/jcm10143046>.
- [15] S. Suparatpinyo and N. Soonthornphisaj, Smart voice recognition based on deep learning for depression diagnosis, *Artificial Life and Robotics*, 28(2), 332-342, 2023. <https://doi.org/10.1007/s10015-023-00852-4>
- [16] H. Tian, Z. Zhu, and X. Jing, Deep learning for depression recognition from speech, *Mob. Netw. Appl.*, 1-16, 2023.
- [17] P. J. Benson, S. A. Beedie, E. Shephard, I. Giegling, D. Rujescu, and D. St. Clair, Simple viewing tests can detect eye movement abnormalities that distinguish schizophrenia cases from controls with exceptional accuracy, *Biol. Psychiatry*, 72(9), 716-724, 2012.
- [18] S. Brakemeier, A. Sprenger, I. Meyhöfer, J. E. McDowell, L. H. Rubin, S. K. Hill, M. S. Keshavan, G. D. Pearlson, C. A. Tamminga, E. S. Gershon, S. S. Keedy, J. A. Sweeney, B. A. Clementz, and R. Lencer, Smooth pursuit eye movement deficits as a biomarker for psychotic features in bipolar disorder—Findings from the PARDIP study, *Bipolar Disord.*, 22(6), 602-611, 2020. <https://doi.org/10.1111/bdi.12865>
- [19] M. Gao, R. Xin, Q. Wang, D. Gao, J. Wang, and Y. Yu, Abnormal eye movement features in patients with depression: Preliminary findings based on eye tracking technology, *Gen. Hosp. Psychiatry*, 84, 25-30, 2023. <https://doi.org/10.1016/j.genhosppsy.2023.04.010>
- [20] E. S. Kangas, E. Vuoriainen, S. Lindeman, and P. Astikainen, Auditory event-related potentials in separating patients with depressive disorders and non-depressed controls: A narrative review, *Int. J. Psychophysiol.*, 179, 119-142, 2022. <https://doi.org/10.1016/j.ijpsycho.2022.07.003>
- [21] F. Li and Y. Ding, Data mining in cognitive function training of depression patients applications, in 2019 10th International Conference on Information Technology in Medicine and Education (ITME), pp. 98-101, Qingdao, China, 2019.
- [22] Y. Baek, K. Jung, and S. Lee, Effects of sleep restriction on subjective and physiological variables in middle-aged Korean adults: an intervention study, *Sleep Med.*, 70, 60-65, 2020.
- [23] J.-G. Choi, I. Ko, and S. Han, Depression level classification using machine learning classifiers based on actigraphy data, *IEEE Access*, 9, 116622-116646, 2021. <https://doi.org/10.1109/access.2021.3105393>
- [24] J. Kim, T. Nakamura, H. Kikuchi, K. Yoshiuchi, T. Sasaki, and Y. Yamamoto, Covariation of depressive mood and spontaneous physical activity in major depressive disorder: toward continuous monitoring of depressive mood, *IEEE J. Biomed. Health Inform.*, 19(4), 1347-1355, 2015.
- [25] M. Abbas, J.-C. Roy, G. Robert, and R. L. Bouquin Jeannes, Utility of actimetry to detect apathy in old-age depression: A pilot study, in 2022 30th European Signal Processing Conference (EUSIPCO), pp. 1203-1207, Belgrade, Serbia, 2022.
- [26] R. K. Thelagathoti and H. H. Ali, A correlation network Model for analyzing mobility data in depression related studies, 16th International Conference on Health Informatics HEALTHINF, pp. 416-423, 2023
- [27] E. Garcia-Ceja, M. Riegler, P. Jakobsen, J. Tørresen, T. Nordgreen, K. J. Oedegaard, and O. B. Fasmer, Depression: a motor activity database of depression episodes in unipolar and bipolar patients, in Proceedings of the 9th ACM multimedia systems conference, pp. 472-477, 2018.
- [28] M. Raihan, A. K. Bairagi, and S. Rahman, A machine learning based study to predict depression with

- monitoring actigraph watch data, 12th International Conference on Computing Communication and Networking Technologies (ICCCNT), pp. 1-5, 2021.
- [29] A. Arora, P. Chakraborty, and M. P. S. Bhatia, Identifying digital biomarkers in actigraph based sequential motor activity data for assessment of depression: a model evaluating SVM in LSTM extracted feature space, *Int. J. Inf. Technol.*, 15 (2), 797-802, 2023.
- [30] M. M. Misgar and M. P. S. Bhatia, Detection of depression from IoMT time series data using UMAP features, in 2022 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS), pp. 623-628, Greater Noida, India, 2022.
- [31] L. Ladha and T. Deepa, Feature selection methods and algorithms, *International Journal on Computer Science and Engineering*, 3(5), 1787-1797, 2011.
- [32] I. Guyon, S. Gunn, M. Nikravesh, and L. A. Zadeh, *Feature Extraction: Foundations and Applications*. Berlin, Germany, Springer, 2006.
- [33] G. Roffo, S. Melzi, U. Castellani, and A. Vinciarelli, Infinite latent feature selection: A probabilistic latent graph-based ranking approach, *IEEE International Conference on Computer Vision (ICCV)*, pp. 1407-1415, Venice, Italy, 2017.
- [34] G. Roffo, S. Melzi, U. Castellani, A. Vinciarelli, and M. Cristani, Infinite Feature Selection: A graph-based feature filtering approach, *IEEE Trans. Pattern Anal. Mach. Intell.*, 43(12), 4396-4410, 2021.
- [35] H. Liu and H. Motoda, Eds., *Computational Methods of Feature Selection*. Chapman and Hall/CRC, 2007.
- [36] M. Zaffalon and M. Hutter, Robust feature selection using distributions of mutual information, in *Proceedings of the 18th International Conference on Uncertainty in Artificial Intelligence (UAI-2002)*, San Francisco, CA, pp. 577-584, 2002.
- [37] Q. Gu, Z. Li, and J. Han, Generalized Fisher score for feature selection, *arXiv [cs.LG]*, 2012.
- [38] M. A. Hall, *Correlation-based Feature Selection for Machine Learning*. Hamilton, 1999.
- [39] K. Bhavsar, V. Vakharia, R. Chaudhari, J. Vora, D. Y. Pimenov, and K. Giasin, A comparative study to predict bearing degradation using discrete wavelet transform (DWT), tabular generative adversarial networks (TGAN) and machine learning models, *Machines*, 10(3), pp.1-18, 2022.
- [40] J. Brownlee, *Machine learning algorithms from scratch with Python*, *Machine Learning Mastery*, 2016.
- [41] J. S. L. Senanayaka, H. Van Khang, and K. G. Robbersmyr, Towards online bearing fault detection using envelope analysis of vibration signal and decision tree classification algorithm, 20th International Conference on Electrical Machines and Systems (ICEMS), pp. 1-6 Sydney, NSW, Australia, 2017.
- [42] C. Cortes, and V. Vapnik, Support-vector networks. *Machine Learning*, 20(3), 273-297, 1995. <https://doi.org/10.1007/bf00994018>
- [43] F. Cheng, C. Yang, H. Zhu, Y. Li, and F. Zhang, A concentration interval identification method of cobalt ions based on optimal spectral bands selection and naive Bayes classification, *China Automation Congress (CAC)*, pp. 7762-7766, Beijing, China, 2021.
- [44] I. A. P. Banlawe, J. C. Dela Cruz, J. C. P. Gaspar, and E. J. I. Gutierrez, Decision tree learning algorithm and naïve Bayes classifier algorithm comparative classification for mango pulp weevil mating activity, *IEEE International Conference on Automatic Control & Intelligent Systems (I2CACIS)*, pp. 317-322, Shah Alam, Malaysia, 2021.
- [45] W. Jinjia, J. Shaonan, and Z. Yaqian, Quadratic discriminant analysis based on graphical lasso for activity recognition, in 2019 IEEE 4th International Conference on Signal and Image Processing (ICSIP), pp. 70-74, Wuxi, China, 2019.
- [46] M. Zakariah and Y. A. Alotaibi, Unipolar and bipolar depression detection and classification based on actigraphic registration of motor activity using machine learning and uniform manifold approximation and projection methods, *Diagnostics (Basel)*, 13(14), 2323, 2023. <https://doi.org/10.3390/diagnostics13142323>
- [47] P. Jakobsen, E. Garcia-Ceja, M. Riegler, L. A. Stabell, T. Nordgreen, J. Torresen, O. B. Fasmer, and K. J. Oedegaard, Applying machine learning in motor activity time series of depressed bipolar and unipolar patients compared to healthy controls, *PLoS One*, 15, e0231995, 1-16 2020.
- [48] A. Aminifar, F. Rabbi, V. K. I. Pun, and Y. Lamo, Monitoring motor activity data for detecting patients' depression using data augmentation and privacy-preserving distributed learning, *Annu. Int. Conf. IEEE Eng. Med. Biol. Soc.*, pp. 2163-2169, Mexico 2021.
- [49] A. Kumar, S. R. Sangwan, A. Arora, and V. G. Menon, Depress-DCNF: A deep convolutional neuro-fuzzy model for detection of depression episodes using IoMT, *Appl. Soft Comput.*, 122, 108863, 1-16, 2022.
- [50] L. A. Zanella-Calzada, C. E. Galván-Tejada, N. M. Chávez-Lamas, M. D. C. Gracia-Cortés, R. Magallanes-Quintanar, J. M. Celaya-Padilla, J. I. Galván-Tejada, and H. Gamboa-Rosales, Feature extraction in motor activity signal: Towards a depression episodes detection in unipolar and bipolar patients, *Diagnostics (Basel)*, 9(1), 1-13, 2019.
- [51] C. H. Espino-Salinas, C. E. Galván-Tejada, H. Luna-García, H. Gamboa-Rosales, J. M. Celaya-Padilla, L. A. Zanella-Calzada, and J. I. G. Tejada, Two-dimensional Convolutional Neural Network for depression episodes detection in real time using motor activity time series of depresjon dataset, *Bioengineering*, 9(9), 1-17, 2022.
- [52] O. Aydemir, A new performance evaluation metric for classifiers: polygon area metric. *Journal of Classification*, 38, 16-26. 2021. <https://doi.org/10.1007/s00357-020-09362-5>

