



Doğrusal olmayan EEG dinamikleri ile anksiyete tespiti

Detection of anxiety with non-linear EEG dynamics

Elif Uğurgöl¹, Turgay Batbat^{2,*}, Demet Yeşilbaş³, Miray Altınkaynak⁴, Ayşegül Güven⁵,
Esra Demirci⁶, Nazan Dolu⁷

^{1,3} Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Anabilim Dalı, Kayseri Türkiye

^{2,4,5} Erciyes Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü, Kayseri Türkiye

⁵ Erciyes Üniversitesi Klinik Mühendislik Araştırma ve Uygulama Merkezi (ERKAM), Kayseri Türkiye

⁶ Erciyes Üniversitesi, Tıp Fakültesi, Çocuk ve Ergen Ruh Sağlığı ve Hastalıkları Anabilim Dalı, Kayseri Türkiye

⁷ İstanbul Medipol Üniversitesi, Tıp Fakültesi, Fizyoloji Anabilim Dalı, İstanbul Türkiye

Özet

Anksiyete, toplum içerisinde sıklıkla rastlanılan ve aşırı kaygı ile karakterize edilen psikiyatrik bir bozukluktur. Mevcut subjektif yöntemler düşünüldüğünde bu bozukluğun kantitatif yöntemlerle tespiti önem kazanmaktadır. Bu amaçla yapılan çalışmada 4'lü likert tipli Beck Anksiyete Ölçeği kullanılıp gerekli klinik değerlendirmeler yapılmıştır. Değerlendirme sonucunda anksiyete bozukluğu bulunan grup ve kontrol grubu şeklinde iki katılımcı grubu belirlenmiştir. Katılımcılardan dinlenme durumunda Elektroensefalografi (EEG) kayıtları alınmış daha sonra EEG sinyallerinden entropi ve Hjorth (karmaşıklık, hareketlilik) parametreleri hesaplanmıştır. Hesaplanan öznetelikler makine öğrenmesinde K -En Yakın Komşu (K-Nearest Neighbor, kNN), Çok Katmanlı Algılayıcı (Multi-Layer Perceptron, MLP) ve Rastgele Orman (Random Forest, RF) sınıflandırma algoritmalarıyla sınıflandırılmışlardır. Bu sınıflandırıcılardan en başarılı sonuç veren model olan kNN %88.4 değerine kadar ulaşabilmiştir. Ayrıca farklı parametrelerin bir arada kullanımının başarı oranında 3 algoritma için yükselişe sebep olduğu gözlenmiştir. Bu sonuçlar makineli öğrenme tekniklerinin anksiyetenin tanı süreçlerinde kullanımına uygun olduğunu gösteren çalışmaları desteklemektedir.

Anahtar kelimeler: EEG, Anksiyete bozukluğu, Dinlenme durumu, Makineli öğrenme

1 Giriş

2013'te Amerikan Psikiyatri Birliği (APA) tarafından yayınlanan Mental Bozuklukların Teşhis ve İstatistik El Kitabı'nda anksiyete, aşırı korku ve endişe ile ilgili davranış bozukluklarını kapsayan ruhsal bir bozukluk olarak ele alınmıştır [1]. Bu bozukluğun en yaygın psikiyatrik bozukluklardan biri olduğu düşünülmekte ve yüksek hastalık yükü ile ilişkilendirilmektedir [2]. Dünya Sağlık Örgütü verilerine göre 2019 yılında dünya genelinde 301 milyon insanda anksiyete bozukluğu görülmüştür [3]. Anksiyetenin erken yaşlarda ortaya çıkması ve yüksek insidansa sahip olması, bu konudaki çalışmaların önemini göstermektedir [4].

Abstract

Anxiety is a psychiatric disorder characterized by excessive worry frequently encountered within society. Given the prevalence of anxiety and the limitations of current subjective assessment methods, the quantitative determination of this disorder gains significance. In pursuit of this objective, the study employed the 4-point likert-type Beck Anxiety Scale alongside essential clinical evaluations. As a result of the assessment, two participant groups were formed: one consisting of individuals with anxiety disorder and the other serving as the control group. Electroencephalography (EEG) recordings were obtained from the participants during resting states, followed by the computation of entropy and Hjorth (mobility, complexity) parameters from the EEG signals. The computed features were then classified using machine learning algorithms, namely K-Nearest Neighbor (kNN), Multi-Layer Perceptron (MLP), and Random Forest (RF), for classification purposes. The k-Nearest Neighbor (kNN) model, which yielded the most successful outcome among these classifiers, was able to reach an accuracy level of 88.4%. Furthermore, the combined utilization of diverse parameters was observed to lead to an increase in the success rate across all three algorithms.

Keywords: EEG, Anxiety disorder, Resting state, Machine learning

Günümüzde anksiyete gibi psikiyatrik bozukluklarda psikopatolojik tanı için kullanılan klinik parametreler hem değişken hem de öznel olduğu için nesnel yaklaşımlarla elde edilen biyobelirteçler son yıllarda önem kazanmıştır. Beyin görüntülemeye tanı amaçlı kullanılan mevcut teknolojiler fMRI (Fonksiyonel Manyetik Rezonans Görüntüleme), Pozitron Emisyon Tomografi (PET) gibi maliyetli yöntemleri kapsamaktadır. Bu yöntemlerin yanı sıra beyindeki zamana bağlı değişimi ve biyoelektriksel aktiviteyi görmede kullanılan Elektroensefalografi (EEG), düşük maliyetli ve etkili bir altın standarttır. Girişimsel olmayan bir elektrofizyolojik sinyal ölçüm tekniği olması, kolay ve güvenilir bir mekanizma ile beyindeki patolojileri anlamak için kullanılmasına imkân sağlar. Nörolojik

hastalıkların teşhisinde kullanılmasına aşına olduğumuz EEG psikolojik bozukluklar için de biyobelirteçler sağlamaktadır [5–8]. Birey dinlenim halindeyken beyni hem fizyolojik hem de psikolojik olarak dinamiktir [9,10]. Bu nedenle, zamana bağlı beyin dinamiğinin gösterim biçimi olarak etkin şekilde kullanılan EEG dinlenim halinde de beyin karakteristiğine dair bilgi sağlamaktadır [11]. Bu durum dinlenim kayıtlarında psikopatolojik durumların belirlenmesi yönündeki kullanımını son yıllarda arttırmıştır [12,13].

Bu çalışmada, düzensizliğin bir göstergesi olarak tanımlanan parametre olan entropi ve istatistiksel tabanlı matematiksel altyapıya sahip özelliklerden Hjorth parametreleri gibi doğrusal olmayan öznitelikler ele alınmıştır. Entropi, hastalıkların sağlıklılardan ayrıldığı çalışmalarda sık kullanılan önemli bir özelliktir [14,15]. Hjorth parametrelerinin (aktiflik, hareketlilik, karmaşıklık) nörolojik ve psikiyatrik çalışmalarda kullanımı son yıllarda artmaktadır [16–18]. Anksiyete özelinde EEG ile yapılan çalışmaların çoğu doğrusal parametrelerin analizine dayalı olsa da beyindeki karmaşık elektriksel aktivitelerin düzensiz ve doğrusal olmadığı bilinmektedir [19]. Birçok çalışma kaotik yapısı sebebiyle EEG'nin doğrusal olmayan parametrelerinin uygulanabilirliğini doğrulamıştır [20–25].

EEG sinyallerinden hesaplanan öznitelikler, istatistiksel yöntemler ve makine öğrenmesi algoritmalarıyla sıklıkla değerlendirilmektedir. Makine öğrenmesi metotlarının tanı süreçlerine nesnel yaklaşım sunmakta olduğu görülmektedir. Sınıflandırma başarı oranları veri türüne veya sınıflandırıcının matematiksel altyapısına göre değişebilmektedir. Yapılan çalışmalar incelendiğinde görev tabanlı veya dinlenim halindeki EEG kayıtlarından çıkarılan farklı parametrelerin makinelere öğrenme yöntemleri ile değerlendirildiğinde birçok psikiyatrik bozukluğun yüksek başarımlarla tespit edilebildiği görülmektedir [26,27]. Örneğin dinlenim durumu EEG'sinden hesaplanan istatistiksel temelli parametreler ve Hjorth parametrelerinin kullanılarak depresyonun incelendiği bir çalışmada farklı sınıflandırıcılar içerisinde en yüksek başarı oranı K-En Yakın Komşu (K-Nearest Neighbor, kNN) Algoritmasıyla elde edilmiştir [28].

Bu çalışma literatürde EEG'nin doğrusal olmayan özniteliklerinin bir arada kullanılarak makine öğrenmesi metotlarıyla anksiyeteli kişilerin verilerini tespit etmeyi hedefleyen çalışmalardan biri olacaktır. Prospektif şekilde gerçekleştirilen bu çalışmada anksiyetenin sebep olduğu anormal nöral mekanizmaların tespit edilip tanı süreçlerinin kantitatif yöntemlerle desteklenmesi amaçlanmıştır. Bu doğrultuda EEG segmentlerine ait öznitelikler hesaplatılmış ve farklı makine öğrenmesi algoritmaları ile verilere sınıflandırma çalışması yapılmıştır.

2 Materyal ve metot

2.1 Katılımcılar

Katılımcılar 18-23 (21.2 ort 1.6 standart sapma) yaş grubundaki 22 anksiyeteli (anksiyete haricinde bir psikiyatrik/nörolojik rahatsızlığı bulunmayan) ve yine 18-23 (20.95 ort 1.7 standart sapma) yaş grubundaki 21 sağlıklı erkek üniversite öğrencisi olarak belirlenmiştir. Çalışma için

gerekli etik izinler Helsinki Kriterlerine uygun olacak şekilde Erciyes Üniversitesi Klinik Araştırmalar Etik Kurulu tarafından 2022/312 numaralı karar ile onaylanmıştır.

Tüm katılımcılar Beck Anksiyete Ölçeği ve Beck Depresyon Ölçeği'nin Türkçe versiyonlarına tabi tutulmuş [29,30], klinik özellikleri ölçülmüştür. Katılımcıların psikiyatri uzmanı tarafından değerlendirilmeleri yapıldıktan sonra anksiyete şiddetine göre gruplandırılmışlardır. Beck Anksiyete Ölçeği'nin Türkçe versiyonu psikiyatride geçerli ve güvenilir bir metottur [31]. 0-3 arasında 4'lü likert tipine göre değerlendirmeye elde edilen toplam puan, 8'in altında sağlıklı, 8 ile 15 arasında hafif anksiyete, 16 ile 25 arasında orta derecede anksiyete ve 26 ile 63 arasında ise şiddetli anksiyete olarak değerlendirilir. Beck Anksiyete Ölçeği el kitabına göre, klinik olarak anlamlı anksiyete için önerilen kesme puanı 16'dır [32, 33]. Çalışmada 16 puan eşliğinin altında puan alan katılımcılar sağlıklı gruba dahil edilmiş ve bu grubun puan ortalamasının 3.76 (std 2.34) olduğu görülmüştür. 16 puanın üzerinde anksiyete şiddetine sahip katılımcılardan oluşan anksiyeteli grubun ise ortalama 25.09 (std 7.04) puana sahip olduğu görülmüştür. Katılımcıların demografik/klinik özellikler Tablo 1'de verilmiştir.

Tablo 1. Katılımcıların demografik/klinik özellikleri

	Kişi Sayısı	Yaş	Beck Anksiyete
Kontrol Grubu	21	20.95 ± 1.7	3.76 ± 2.34
Anksiyeteli Grup	22	21.2 ± 1.6	25.09 ± 7.04

2.2 Prosedür

Katılımcılara gerekli bilgilendirmeler yapıldıktan sonra bilgilendirilmiş gönüllü olur formları imzalatılmıştır. Anksiyetenin durumuna göre grupların belirlenmesinden sonra denekler Faraday kafesli karanlık odada dik pozisyonda koltuğa oturtulmuş ve kendilerinden dinlenim pozisyonunda kalmaları istenmiştir. Yalnızca kayıtları alan araştırmacıların ve denegin bulunduğu deney ortamında katılımcıların ilk 4 dakika gözler açık, sonra 2 dakika gözler kapalı olmak suretiyle toplam 6 dakika süren EEG kayıtları alınmıştır. Katılımcılardan kayıt sürecinde olabildiğince hareketsiz kalmaları ve zihinlerini rahat bırakmaları istenmiştir. Gözler açık durumdayken göz hareketleri ve göz kırpmaya nedeniyle EEG sinyali daha gürültülü olabildiğinden ayrıca sinyalin baseline durumu düşünülerek 4 dk'lık kayıt alınmış, bu kaydın son 2 dakikası değerlendirmeye katılmıştır. Bu süreler belirlenirken anksiyete dinlenim durumu yayınları baz alınarak 2 dk gözler açık, 2 dk gözler kapalı durum ele alınmıştır [34]. Yapılan analizlerde anksiyeteli bireyler ve kontrol grubu arasında anlamlı farklılık gösteren gözlerin kapalı olduğu 2 dakikalık süreç esas alınarak çalışma sürdürülmüştür.

2.3 EEG kaydı

Katılımcıların EEG kaydı Erciyes Üniversitesi Klinik Mühendisliği Araştırma ve Uygulama Merkezinde bulunan ışık, ses ve elektromanyetik alan izolasyonlu Faraday Kafesli elektrofizyolojik işaret kayıt odasına alınmıştır. Uluslararası 10-20 standardına göre tasarlanan EEG kepi ve EB Neuro

firmasının BE-Light 36 EEG cihazı kullanılarak 17 kanaldan (F7, F3, Fz, F4, F8, T3, C3, Cz, C4, T4, T5, P3, Pz, P4, T6, O1 ve O2) EEG kaydı alınmıştır. Sistemin toprak bağlantısı sağ mastoid, referans kanalı ise sol kulak memesi olarak belirlenmiştir. Elektrot dirençleri 5 kΩ değerinin altında tutulmuştur. Veriler saniyede 512 örnekleme frekansı ile kaydedilmiştir. Şekil 1’de gözlerin kapalı olduğu sürece ait 20 saniyelik örnek sinyal çizimi verilmiştir. Siyah renkteki sinyal kontrol grubunda bulunan bir katılımcıya, kırmızı renkteki sinyal ise anksiyete tespit edilen grupta bulunan bir katılımcıya aittir.

2.4 EEG veri işleme

Kayıtlardan elde edilen EEG sinyalleri Matlab R2021b programı ile işlenmiştir. EEG sinyallerine 0.5-35 Hz aralığında bant geçiren filtre uygulanmıştır. 2 dakikalık gözler kapalı ve 2 dakikalık gözler açık kaydın nispeten daha gürültüsüz olan orta bölümünden (35-55 s ve 65-85 s aralığı) 20 s’lik segmentler alınmıştır. Böylece her katılımcıya ait 2 adet segment oluşturulup bu segmentler üzerinden çalışma sürdürülmüştür [35]. Bu işlem 17 kanalın tümü için gerçekleştirilmiştir. Ardından tüm segmentlere ait zaman domeninde entropi, karmaşıklık, hareketlilik özellikleri hesaplanmıştır.

2.4.1 Entropi

Belirsizliğin bir ölçütü olarak bilinen entropinin EEG için bir öznitelik olarak kullanımına literatürde sıkça rastlanmaktadır [36]. Bu çalışmada kullanılan entropinin Shannon modeli Denklem (1)’de görüldüğü üzere olasılık temelli bir denkleme dayanmaktadır [37, 38].

$$E(n) = - \sum_{i=0}^{N-1} P_i^2 [n] \log_2(P_i^2 [n]) \quad (1)$$


2.4.2 Hjorth parametreleri

Hjorth parametreleri EEG sinyallerine ait özellikleri tanımlamada kullanılan doğrusal olmayan bir öznitelik grubudur [39]. İstatistiksel temelli bir yaklaşımla hesaplanan Hjorth parametrelerinden Denklem (2)’de görülen hareketlilik, verideki eğimlere ait bir ölçütken Denklem (3)’te görülen karmaşıklık ise verideki eğim sayısını ifade eder [17, 38, 40]. Anlamsal bakıldığında hareketlilik sinyalin ortalama frekansına ait bir bilgi iken karmaşıklık frekanstaki değişimin yaklaşık olarak hesaplanmasına dayanır [41].

$$\text{Hareketlilik (H)} = \sqrt{\frac{\text{var}\left(\frac{x(n)dx}{dn}\right)}{\text{var}(x(n))}} \quad (2)$$

$$\text{Karmaşıklık (K)} = \frac{H(x(n))dx}{H(x(n))} \quad (3)$$

Elde edilen bu özellikler anksiyete gruplandırması esas alınarak karakterize edilip veri sınıfları oluşturulduktan sonra Waikato Environment for Knowledge Analysis (WEKA Software 2022) programında fizyolojik parametrelerde başarılı sonuçlar veren kNN, Çok Katmanlı Algılayıcı (Multi-Layer Perceptron, MLP) ve Rastgele Orman (Random Forest, RF) sınıflandırma algoritmalarına tabi tutulmuşlardır.



Şekil 1. Gözlerin kapalı olduğu sürece ait 20 saniyelik EEG segmentlerinin örnek çizimi

2.5 Sınıflandırma

2.5.1 K-en yakın komşu algoritması

Sınıflandırma ve regresyon yapmaya imkân sağlayan bu algoritma parametrik olmayan temel bir denetimli makine öğrenmesi metodudur. Bu algoritma, test veri noktasına en yakın olan k komşu veri noktalarının etiketlerine dayanan bir karar süreci izler. kNN algoritması, eğitim veri seti üzerinde çalışır. Her bir veri noktası, özellik değerleri ve ilgili sınıf etiketiyle birlikte temsil edilir. Sınıflandırma durumunda, bir test veri noktasının sınıfını tahmin etmek için, kNN algoritması öncelikle en yakın k veri noktasını belirler. Bu çalışmada kullanılan k değeri 1 olarak belirlenmiştir [42]. Bu belirleme sürecinde, genellikle bu çalışmada da kullanılan Öklid mesafesi veya başka bir mesafe metriği kullanılabilir. Daha sonra, en yakın k veri noktasının sınıf etiketleri dikkate alınarak, çoğunluk oylaması yöntemiyle test veri noktasının sınıfı tahmin edilir [43]. Bu algoritma EEG sinyallerinin özneliklerini sınıflandırmak için kullanılabilir [36, 44, 45].

2.5.2 Çok katmanlı algılayıcı

Yapay Sinir Ağlarındaki perceptronlar, doğrusal olarak sınıflandırma zorluklarını aşmakta başarısız olabilmektedir. Özellikle lineer olmayan problemlerdeki zorlukları çözebilmek adına yapılan araştırmalar, MLP modelinin geliştirilmesine yol açmıştır. MLP, tam bağlantılı bir yapay sinir ağı modeli olarak karşımıza çıkmakta ve denetimsiz bir şekilde işlev görmektedir. Giriş verileri, özel ağırlıklarla çarpılarak aktivasyon fonksiyonları kullanılarak gizli katmanlardan çıktılar üretir. Son katmanda ise hedeflenen sonuçlar elde edilir.

MLP, geri yayılım algoritması yardımıyla eğitilerek non-lineer ilişkileri öğrenebilme yeteneğine sahiptir. Ayrıca, geniş bir makine öğrenimi uygulama yelpazesi içerisinde de etkili bir şekilde kullanılabilir [46]. MLP, EEG çalışmalarında umut verici sonuçlar veren bir algoritma olarak görülmektedir [47].

2.5.3 Rastgele orman

Birçok karar ağacının bir araya gelerek oluşturduğu topluluk tipinde bir makine öğrenme modelidir [48,49]. Denetimli olarak çalışan Rastgele Orman algoritmasında her bir karar ağacı, veri setinin rastgele örneklemelerini kullanarak eğitilir. Bu rastgele örnekleme süreci, veri setinin bir alt kümesini oluşturarak yapılır. Ayrıca, her bir ağaç için düğüm bölünmesi sırasında rastgele özelliklerin bir alt kümesi kullanılır. Sınıflandırmada en çok oy alan ağaçlar kullanılarak ezberleme etkisinden uzak bir sınıflandırma işlemi gerçekleştirilir. Bu modelin EEG ile nörolojik patolojilerin görülmesinde doğru bir sınıflandırıcı olabileceğini gösteren çalışmalara sıklıkla rastlanmaktadır [50-53].

Çalışmada tüm kanallardan elde edilen entropi ve Hjorth parametreleri, anksiyeteli olan ve anksiyeteli olmayan grup şeklinde kategorize edilerek bu algoritmalara tabi tutulmuşlardır. Algoritmaların başarısı doğruluk, kesinlik, duyarlılık, F-ölçütü, ROC alanı ve PRC (Precision-Recall

Curve Area, Kesinlik-Duyarlılık Eğrisi Alanı) sınıflandırma ölçütleri ile değerlendirilmiştir.

Doğru pozitif oranı (TP: true positive), doğru negatif oranı (TN: true negative), yanlış negatif oranı (FN: false negative) ve yanlış pozitif oranı (FP: false positive) ile oluşan karmaşıklık matrisi modelin başarısının değerlendirildiği yapıdır. Karmaşıklık matrisi bileşenlerinden elde edilen en temel ölçütlerden biri olan doğruluk, başarının anlaşılması ve yorumlanmasını sağlar (Denklem (4)). Bu değer 0 ve 1 aralığında olur ve 1'e yakın olması modelin başarılı olmasıyla ilişkilendirilir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FN + FP} \quad (4)$$

Makine öğrenmesi ve istatistikte kullanılan bir ölçüt olan kesinlik ise algoritmanın pozitif olarak tahmin ettiği örneklerin gerçekte ne kadar pozitif olduğunu gösterir (Denklem (5)). Bu ölçüt bir modeli değerlendirmek için tek başına yeterli olmadığı için duyarlılık ve F-ölçütü gibi ölçütlere de bakılmalıdır.

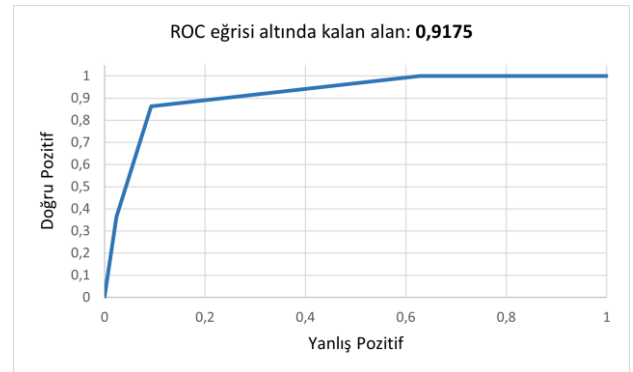
$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (5)$$

Duyarlılık gerçek pozitif örneklerin ne kadarının tespit edildiğini bulmaya yönelik çalışır (Denklem (6)).

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (6)$$

Kesinlik ve duyarlılık ölçütleri birbirine zıt olacak şekilde çalışır. Bu noktada iki ölçütü birleştirip genel bir değerlendirme sonucu sağlayan F-ölçütü devreye girer. Denklem (7)'de görüldüğü üzere F-ölçütü, kesinlik ve duyarlılık ölçütlerinin harmonik ortalaması alınarak hesaplanır ve doğruluğun bir ölçüsü olarak kabul edilir [54, 55].

$$F \text{ Skoru} = \frac{2 \times \text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (6)$$



Şekil 2. Entropi ve Hjorth parametrelerinin bir arada kNN sınıflandırıcısına verilmesi sonucu elde edilen ROC eğrisi grafiği.

Değerlendirme yapılan bir diğer ölçüt olan ROC alanı, ikili sınıflandırmalarda ortaya çıkan işlem karakteristik eğrisinin altında kalan toplam alanı ifade eder. PRC Alanı modelin yeteneklerini tanımlayan bir sayısal değerdir. Bir modelde yüksek kesinlik ve yüksek duyarlılığın tercih edilmesi sebebiyle bu iki ölçütten hesaplanan PRC grafiklerinin ROC grafiklerinden daha bilgilendirici olabileceği öne sürülmüştür [55, 56]. Örnek bir ROC eğrisi Şekil 2'e görülmektedir.


3 Bulgular

Bu çalışmanın amacı anksiyete bozukluklarının tanı süreçlerini kantitatif yaklaşımlarla desteklemektir. Bu bağlamda biyobelirteçler kullanılmış olup makine öğrenmesi metotlarıyla anksiyete bozukluğu bulunan öğrencilerin ve kontrol grubu öğrencilerinin verilerine yönelik sınıflandırma uygulamaları yapılmıştır. Ele alınan öznelikler için sınıflara göre grafikler aşağıda verilmiştir. Entropi Şekil 3'te, Hjorth hareketlilik Şekil 4'te, Hjorth karmaşıklık Şekil 5'te verilmiştir. Kontrol grubu "k", Anksiyeteli grup "a" ile belirtilmiştir. Şekil 3'te bulunan grafiklere bakıldığında tüm kanallar için entropi ortalamalarının, anksiyeteli grupta


kontrol grubuna göre daha fazla olduğu görülmektedir. Şekil 4'te bulunan hareketlilik değerleri incelendiğinde C3, C4, CZ, P3, PZ ve T3 kanallarında kontrol grubu değerleri ortalama bakımından daha yüksek iken diğer 11 kanalda anksiyeteli grubun değerleri kontrolden daha fazla olduğu görülmektedir. Şekil 5'teki karmaşıklık değerleri ise FZ ve T6 kanallarında kontrol grubunda anksiyeteli gruptan daha yüksek olarak hesaplanmışken diğer 15 kanala bakıldığında anksiyeteli grupta kontrole göre daha yüksek bir ortalama ile sonuçlanmıştır. İki gruptan dörder katılımcı için örnek parametre hesaplama sonuçları Tablo 2'de görülmektedir.

3.1 Klinik bilgi analizi

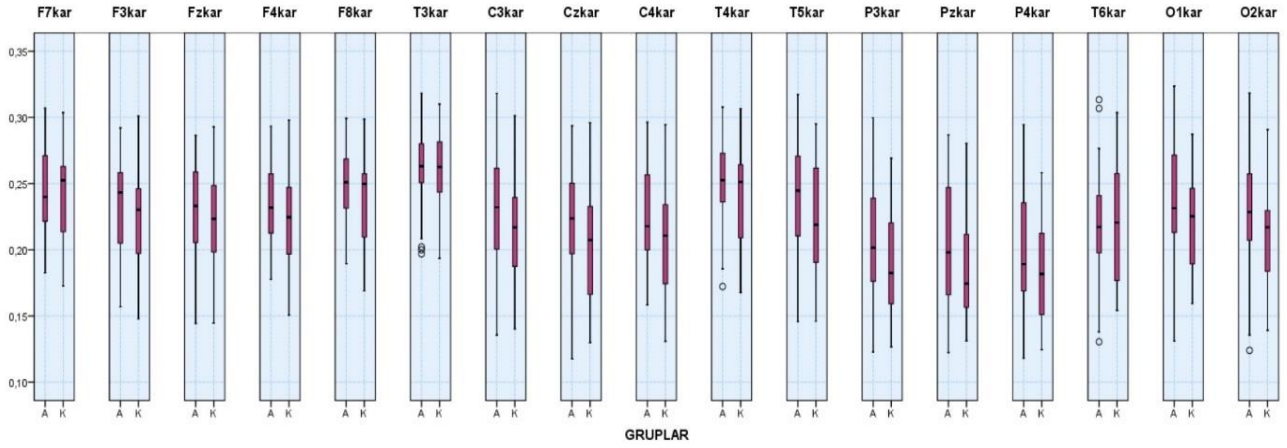
Katılımcıların anksiyeteyle ilgili durumuna göre belirlenen grupların Beck Depresyon Ölçeği puan skorları elde edilmiştir. Bu puanlar bağımsız değişken t-testi ile karşılaştırılmıştır. Anksiyeteli grup ile kontrol grubu arasında yapılan t-testinin ortaya çıkardığı yüksek anlamlılık, literatürdeki depresyon ve anksiyete bozukluğunun komorbid olma durumunu destekler niteliktedir.



Şekil 3. Kullanılan 17 EEG kanalının Shannon Entropi değerlerinin grafikleri (a: Anksiyeteli grup, k: Kontrol grubu)



Şekil 4. Kullanılan 17 EEG kanalının hareketlilik değerlerinin grafikleri (A: Anksiyeteli grup, K: Kontrol grubu)



Şekil 5. Kullanılan 17 EEG kanalının karmaşıklık değerlerinin grafikleri (A: Anksiyeteli grup, K: Kontrol grup)

3.2 Sınıflandırma

Çalışma, literatürde benzer problemlere yönelik sınıflandırma çalışmalarında yaygın olarak kullanılan algoritmalarından kNN, MLP ve RF kullanılarak gerçekleştirilmiştir. Yalnızca entropi değerleri kullanılarak yapılan ikili sınıflandırma işlemleri neticesinde sınıflandırıcılardan elde edilen sonuçlara bakıldığında kNN algoritmasının entropi verilerini ayırmada %70.9 ile diğer sınıflandırıcılardan yüksek bir başarı elde etmiş olduğu görülmektedir (Tablo 3). Karmaşıklık için gerçekleştirilen

sınıflandırmalarda 3 algoritmadan en yüksek başarı oranı olan %86 değeri, kNN sınıflandırıcısı ile sağlanmıştır. kNN, hareketlilik parametresi için de %82.6 ile en yüksek başarı sonucunu vermiştir. Diğer sınıflandırıcılardan MLP, karmaşıklık ve hareketlilik parametrelerinin sınıflandırılmasında RF'den daha yüksek başarıyla sonuçlanmışken entropi değerlerinin sınıflandırılmasında RF'den daha düşük bir başarı getirmiştir. Ayrıca tüm parametrelerin bir arada sınıflandırıcılara verilmesi 3 algoritma için de başarı sonucunun artmasına neden olmuştur.

Tablo 2. Çalışmaya katılan 4 anksiyeteli ve 4 sağlıklı kişinin FZ kanalına ait örnek parametre değerleri

FZ Kanalı	Katılımcı	Parametreler		
		Entropi	Karmaşıklık	Hareketlilik
Kontrol Grubu	Katılımcı 3	-1.048E+07	0.2689	0.0674
	Katılımcı 6	-1.334E+07	0.2003	0.1348
	Katılımcı 7	-1.577E+07	0.1444	0.0968
	Katılımcı 12	-1.553E+07	0.2394	0.0702
Anksiyeteli Grup	Katılımcı 23	-1.560E+07	0.2752	0.0594
	Katılımcı 25	-1.413E+07	0.2567	0.1423
	Katılımcı 34	-1.383E+07	0.2287	0.0842
	Katılımcı 41	-1.017E+07	0.2090	0.1207

Değerler, 4 kontrol ve 4 anksiyete tespiti yapılmış katılımcının FZ kanallarından elde edilmiştir.

Tablo 3. Parametreye göre sınıflandırma başarısı

Model	Karmaşıklık	Hareketlilik	Entropi	Tüm Param.
KNN	0.860	0.826	0.709	0.884
MLP	0.779	0.791	0.581	0.849
RF	0.721	0.709	0.663	0.767

KNN: k- En Yakın Komşu Algoritması, MLP: Çok Katmanlı Algılayıcı Algoritması, RF: Rastgele Orman Algoritması. Özellik isimleriyle başlıklandırılan sütunlarda yalnızca ilgili özelliğin kullanılarak sınıflandırmasının sonuçları gösterilmektedir. Tüm parametre başlığına sahip sütun ise 3 parametrenin bir arada kullanılarak yapıldığı sınıflandırma sonuçlarını göstermektedir.

Tablo 4. Tüm parametrelerin bir arada verildiği sınıflandırmanın sonuçlarına ait ölçütler

	Doğruluk	Grup	Kesinlik	Duyarlılık	F-Ölçütü	ROC Alanı	PRC Alanı
kNN	%88.4	Kontrol	0.864	0.905	0.884	0.899	0.851
		Anksiyete	0.905	0.864	0.884	0.918	0.879
		Ağırlıklı Ort.	0.885	0.884	0.884	0.909	0.865
MLP	%84.9	Kontrol	0.854	0.833	0.843	0.925	0.940
		Anksiyete	0.844	0.864	0.854	0.924	0.882
		Ağırlıklı Ort.	0.849	0.849	0.849	0.924	0.910
RF	%76.7	Kontrol	0.775	0.738	0.756	0.842	0.819
		Anksiyete	0.761	0.795	0.778	0.842	0.825
		Ağırlıklı Ort.	0.768	0.767	0.767	0.842	0.822

Tüm parametrelerin bir arada kullanılarak gerçekleştirildiği sınıflandırmalarda kNN %88.4 ile en yüksek başarı sonucu verirken RO sınıflandırıcısı %76.7 ile en düşük başarı oranıyla sonuçlanmıştır. MLP ise kNN'e göre düşük fakat RO'dan çok daha yüksek olan %84.9 oranıyla sonuçlanmıştır. Bu sınıflandırıcıların ölçütleri Tablo 4'te detaylı olarak gösterilmektedir.

4 Tartışma ve sonuç


Bu çalışma toplum içinde sıkça görülen anksiyete bozukluğunun beyin aktivitesi üzerindeki etkisini sinyal işleme ve makine öğrenmesi metotlarıyla anlamayı amaçlamıştır.

Son yıllarda anksiyete bozukluğu olan bireylerde dinlenme durumundaki beyin fonksiyonlarının ve fonksiyonel bağlantısallığın incelenmesine yönelik çalışmalar artış göstermiştir. Ancak çalışmalarda kullanılan küçük örneklem büyüklükleri, kullanılan yöntemlerin farklılık göstermesi gibi nedenlerle sonuçlarda tutarsızlık görülmektedir, dolayısıyla daha fazla çalışmaya ihtiyaç duyulmaktadır [57, 58]. Bu çalışmada herhangi bir görev olmaksızın, anksiyete özelinde beyin nörobiyolojisinin daha iyi anlaşılabilmesi ve psikiyatrik tanı doğruluğunu artırmak amacıyla objektif yöntemler kullanılarak dinlenme durumu EEG kaydı incelenmiştir. Görevlere dayalı yöntemlere kıyasla dinlenme durumu, görev performansının getirebileceği karmaşıklıklardan etkilenmez yani görev performansının potansiyel karıştırıcı etkilerine sahip değildir [58]. Görev olmaksızın alınan elektrofizyolojik kayıtlar anksiyete gibi klinik durumların altında yatan içsel beyin mekanizmalarının anlaşılmasına özellikle fayda sağlar. Dinlenme durumu EEG'si diğer birçok psikiyatrik bozukluğun değerlendirilmesinde de sıkça kullanılmaktadır [59]. Son yıllarda psikiyatrik tanıların nörobiyolojik ölçümlerle desteklenmesinin öneminin artmasıyla makine öğrenme teknikleri ile tanı ve tedavi cevaplarının değerlendirilmesine yönelik çalışmalar ivme kazanmıştır. Mokaten ve arkadaşları, Evrişimli Sinir Ağrı kullanarak EEG verilerinden anksiyete düzeyini belirlemeyi %87'lik bir başarıyla gerçekleştirebilmişlerdir [60]. Al-Ezzi ve arkadaşlarının yaptığı çalışmada fuzzy entropi kullanılarak sınıflandırma yapılmış ve entropi şiddetine göre yüksek doğrulukla sınıflandırma yapabilmişlerdir [61]. Bu çalışmada ise farklı özneliklerin ayrı ayrı veya bir arada kullanılma durumunun makine öğrenmesinde sınıflandırma

başarısı üzerindeki etkisi incelenmiş ve farklı algoritmalar için bu sonuçlar sunulmuştur. Li ve arkadaşları yaptıkları çalışmada katılımcıların kayıtları anksiyeteyi tetikleyecek görevlerle gerçekleştirmişlerdir [41]. Aynı kişilerden beş farklı kaygı seviyesi için alınan EEG kayıtlarının analizi gerçekleştirilmiştir ve dinlenme durumu EEG kayıtları anksiyetenin olmadığı referans durum olarak değerlendirilmiştir. 5 durum anksiyetenin sürekli olmadığı durumlar için kademeli tetikleme ile uyaran tipine göre sağlıklı kişilerde karşılaştırılmıştır. Lineer ve lineer olmayan özellikler kullanılarak iki farklı sınıflandırmada karşılaştırmalar yapılmıştır. Bizim çalışmamızda ise anksiyetenin belirlenmesinde süregelen etki ele alınmış ve klinik değerlendirmelere uygun olarak gruplar oluşturulmuştur. Böylece psikiyatri açısından bir değerlendirme metodu oluşturulması amaçlanmıştır.

Sınıflandırıcı performansların karşılaştırıldığı Şekil 6'da sarı renkte karmaşıklık verilerinin sınıflandırılma sonuçları verilmiştir. Turuncu renk hareketliliği, yeşil renk ise entropi değerlerinin kullanıldığı sınıflandırılma başarılarını göstermektedir. Sınıflandırma sonuçlarına bakıldığında entropi, karmaşıklık ve hareketlilik parametrelerinin hem ayrı ayrı kullanıldığı durumlarda hem de bir arada kullanıldığı durumda kNN algoritması, başarı oranı en yüksek çıkan sınıflandırıcı olmuştur. Ayrıca entropi ve Hjorth parametreleri birlikte kullanıldığında parametrelerin tek başlarına kullanıldığı durumla karşılaştırıldığında tüm sınıflandırıcılar için başarı oranının arttığı gözlenmiştir. Bu sonuç EEG'de farklı özelliklerin bir arada kullanılmasının sınıflandırıcı başarısını artırabileceğini göstermiştir.

Anksiyeteli kişilerde genellikle depresyon gözleendiği bilinmektedir [62-64]. Çalışmada katılımcılara Beck Anksiyete Ölçeği'nin yanı sıra Türkçeye uyarlanmış Beck Depresyon Ölçeği de uygulanmıştır. Anksiyete ve depresyon puanlarının korelasyonuna bakıldığında iki parametre arasında pozitif yönlü anlamlı bir ilişki gözlenmiştir ($r=0.552$; $p=0.000$). Bu sonuç literatürle uyumludur [64]. Sonuç olarak, getirdiği negatif sonuçlar düşünüldüğünde (bireylerin yaşam kalitesindeki düşüş, eşlik eden komirbiditeler, ekonomik yük vb.) anksiyetenin teşhisine yönelik biyobelirteçlerin belirlenmesi oldukça önemlidir. İleride yapılacak çalışmalarda daha fazla katılımcı olması durumunda anksiyete dereceleri ile sınıflandırma yapıp anksiyete konusunun bütünüyle ele alınması planlanmaktadır.



Şekil 6. Parametreler ayrı ayrı veya bir arada verilmesine ilişkin sınıflandırıcı performansların karşılaştırıldığı grafik

Teşekkür

Çalışma TÜBİTAK tarafından 121E502 proje koduyla desteklenmiştir.

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %8

Kaynaklar

- [1] American Psychiatric Association, Diagnostic and Statistical Manual of Mental Disorders, American Psychiatric Association Publishing, 2022. <https://doi.org/10.1176/appi.books.9780890425787>.
- [2] R.C. Kessler, M. Petukhova, N.A. Sampson, A.M. Zaslavsky, H.U. Wittchen, Twelve-month and lifetime prevalence and lifetime morbid risk of anxiety and mood disorders in the United States. *The International Journal of Methods in Psychiatric Research*, 21, 169–184, 2012. <https://doi.org/10.1002/mpr.1359>.
- [3] X. Yang, Y. Fang, H. Chen, T. Zhang, X. Yin, J. Man, L. Yang, M. Lu, Global, regional and national burden of anxiety disorders from 1990 to 2019: results from the Global Burden of Disease Study 2019, *Epidemiology and Psychiatric Sciences*, 30, e36, 2021.
- [4] B.J. Casey, F.S. Lee, Optimizing treatments for anxiety by age and genetics. *Annals of the New York Academy of Sciences*, 1345, 16–24, 2015. <https://doi.org/10.1111/nyas.12746>.
- [5] T. Allison, Recording and interpreting event-related potentials, in: E. Donchin (Ed.). *Cogn. Psychophysiol. Event-Related Potentials Study Hum. Cogn.*, Laurence Erlbaum Associates, Hillsdale NJ, 1986.
- [6] Ü.İ. Alkaç, Beyin Araştırmaları Tarihinde Bir Gezinti : Elektronörofizyoloji. *Klinik gelişim*, 3, 14–19, 2009.
- [7] S. Aliakbaryhosseinabadi, E.N. Kamavuako, N. Jiang, D. Farina, N. Mrachacz-Kersting, Classification of EEG signals to identify variations in attention during motor task execution. *Journal of Neuroscience*

Methods, 284, 27–34, 2017. <https://doi.org/10.1016/j.jneumeth.2017.04.008>.

- [8] S.M. Snyder, T.A. Rugino, M. Hornig, M.A. Stein, Integration of an EEG biomarker with a clinician's ADHD evaluation. *Brain and Behavior*, 5, 1–17, 2015. <https://doi.org/10.1002/brb3.330>.
- [9] J.S. Damoiseaux, S.A.R.B. Rombouts, F. Barkhof, P. Scheltens, C.J. Stam, S.M. Smith, C.F. Beckmann, Consistent resting-state networks across healthy subjects. *Proceedings of the National Academy of Sciences of the United States of America*, 103, 13848–13853, 2006. <https://doi.org/10.1073/pnas.0601417103>.
- [10] D. Mantini, M.G. Perrucci, C. Del Gratta, G.L. Romani, M. Corbetta, Electrophysiological signatures of resting state networks in the human brain. *Proceedings of the National Academy of Sciences of the United States of America*, 104, 13170–13175, 2007. <https://doi.org/10.1073/pnas.0700668104>.
- [11] F. Li, L. Jiang, Y. Liao, Y. Si, C. Yi, Y. Zhang, X. Zhu, Z. Yang, D. Yao, Z. Cao, P. Xu, Brain variability in dynamic resting-state networks identified by fuzzy entropy: A scalp EEG study. *Journal of neural engineering*, 18, 46097, 2021. <https://doi.org/10.1088/1741-2552/ac0d41>.
- [12] O. Al Zoubi, A. Mayeli, A. Tsuchiyagaito, M. Misaki, V. Zotev, H. Refai, M. Paulus, J. Bodurka, R.L. Aupperle, S.S. Khalsa, J.S. Feinstein, J. Savitz, Y.H. Cha, R. Kuplicki, T.A. Victor, EEG microstates temporal dynamics differentiate individuals with mood and anxiety disorders from healthy subjects. *Frontiers in Human Neuroscience*, 13, 1–10, 2019. <https://doi.org/10.3389/fnhum.2019.00056>.
- [13] A. Al-Ezzi, N. Kamel, I. Faye, E. Gunaseli, Analysis of default mode network in social anxiety disorder: Eeg resting-state effective connectivity study. *Sensors*, 21, 1–19, 2021. <https://doi.org/10.3390/s21124098>.
- [14] S.M. Pincus, Approximate entropy as a measure of irregularity for psychiatric serial metrics. *Bipolar*

- Disorders, 8, 430–440, 2006. <https://doi.org/10.1111/j.1399-5618.2006.00375.x>.
- [15] N. Kannathal, M.L. Choo, U.R. Acharya, P.K. Sadasivan, Entropies for detection of epilepsy in EEG. *Computer Methods and Programs in Biomedicine*, 80, 187–194, 2005. <https://doi.org/10.1016/j.cmpb.2005.06.012>.
- [16] T. Batbat, A. Güven, N. Dolu, Evaluation of divided attention using different stimulation models in event-related potentials. *Medical & Biological Engineering & Computing*, 57, 2069–2079, 2019. <https://doi.org/10.1007/s11517-019-02013-x>.
- [17] S.-H. Oh, Y.-R. Lee, H.-N. Kim, A Novel EEG Feature Extraction Method Using Hjorth Parameter. *International Journal of Electronics and Electrical Engineering*, 2, 106–110, 2014. <https://doi.org/10.12720/ijeee.2.2.106-110>.
- [18] T. Elbert, W. Lutzenberger, B. Rockstroh, P. Berg, R. Cohen, Physical aspects of the EEG in schizophrenics. *Biological psychiatry*, 32, 595–606, 1992. [https://doi.org/10.1016/0006-3223\(92\)90072-8](https://doi.org/10.1016/0006-3223(92)90072-8).
- [19] X.T. Li, The distribution of left and right handedness in Chinese people. *Acta Psychologica Sinica*, 3, 268–276, 1983.
- [20] M. Altunkaynak, Dikkat Eksikliği Ve Hiperaktivitesi Olan Hastalarda Kognitif Fonksiyonların Uyarılmış Potansiyel Ve Fonksiyonel Yakın Kızıl Ötesi Spektroskopisi Yöntemleriyle İncelenmesi. Doktora Tezi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Türkiye, 2021.
- [21] L. Guo, Y. Wu, L. Zhao, T. Cao, W. Yan, X. Shen, Classification of mental task from EEG signals using immune feature weighted support vector machines. *IEEE Transactions on Magnetics*, 47, 866–869, 2011. <https://doi.org/10.1109/TMAG.2010.2072775>.
- [22] Q. Meng, W. Zhou, Y. Chen, J. Zhou, Feature analysis of epileptic EEG using nonlinear prediction method. 2010 Annual International Conference of the IEEE Engineering in Medicine and Biology, Soc. EMBC'10, pp. 3998–4001, IEEE, 2010. <https://doi.org/10.1109/IEMBS.2010.5628001>.
- [23] Y. Li, Y. Fan, C. Qian, EEG nonlinear feature detection in brain-computation interface. 2009 3rd International Conference on Bioinformatics and Biomedical Engineering, pp. 1–4, IEEE, 2009. <https://doi.org/10.1109/ICBBE.2009.5162681>.
- [24] W.X. He, X.G. Yan, X.P. Chen, H. Liu, Nonlinear feature extraction of sleeping EEG signals. 2005 IEEE engineering in medicine and biology 27th annual conference, pp. 4614–4617, IEEE, 2005. <https://doi.org/10.1109/iembs.2005.1615498>.
- [25] X.W. Wang, D. Nie, B.L. Lu, Emotional state classification from EEG data using machine learning approach. *Neurocomputing*, 129, 94–106, 2014. <https://doi.org/10.1016/j.neucom.2013.06.046>.
- [26] M. Čukić, V. López, J. Pavón, Classification of depression through resting-state electroencephalogram as a novel practice in psychiatry: review. *Journal of Medical Internet Research*, 22, e19548, 2020. <https://doi.org/10.2196/19548>.
- [27] D. Librenza-Garcia, B.J. Kotzian, J. Yang, B. Mwangi, B. Cao, L.N. Pereira Lima, M.B. Bermudez, M.V. Boeira, F. Kapczinski, I.C. Passos, The impact of machine learning techniques in the study of bipolar disorder: A systematic review. *Neuroscience & Biobehavioral Reviews*, 80, 538–554, 2017. <https://doi.org/10.1016/j.neu.biorev.2017.07.004>.
- [28] H. Cai, J. Han, Y. Chen, X. Sha, Z. Wang, B. Hu, J. Yang, L. Feng, Z. Ding, Y. Chen, J. Gutknecht, A Pervasive Approach to EEG-Based Depression Detection. *Complexity*, 2018, 1–13, 2018. <https://doi.org/10.1155/2018/5238028>.
- [29] D. Şayık, D. Yiğit, A. Açıkgoz, E. Çolak, Ö. Mumcu, Koronavirüs anksiyete ölçeğinin Türkçe geçerliliği ve güvenilirliği. *Eskisehir Medical Journal*, J. 2, 16–22, 2021.
- [30] F. Yıldırım, İ.Ö. İlhan, Genel öz yeterlilik ölçeği Türkçe formunun geçerlilik ve güvenilirlik çalışması. *Türk Psikiyatri Dergisi*, 21, 301–308, 2010.
- [31] M. Ulusoy, N. H. Sahin, & H. Erkmén, Turkish version of the Beck Anxiety Inventory: psychometric properties. *Journal of cognitive psychotherapy*, 12(2), 163, 1998.
- [32] A. T. Beck, N. Epstein, G. Brown & Steer, R., Beck anxiety inventory. *Journal of consulting and clinical psychology*, 7(3), 195–205, 1993.
- [33] A. Babayigit, & E. Erdem, Şanlıurfa Örneğinde Depresif Belirtiler ve Anksiyete Yaygınlığının COVID-19 ve Psikolojik Dayanıklılık ile İlişkisinin İncelenmesi. *Kıbrıs Türk Psikiyatri ve Psikoloji Dergisi*, 5(3), 239–249, 2023.
- [34] L. A. Schmidt, K. L. Poole, R. Hassan, T. Willoughby, Frontal EEG alpha-delta ratio and social anxiety across early adolescence. *International Journal of Psychophysiology*, 175, 1–7, 2022. <https://doi.org/10.1016/j.ijpsycho.2021.12.011>.
- [35] Ü. Işık, A. Güven, T. Batbat, Evaluation of Emotions from Brain Signals on 3D VAD Space via Artificial Intelligence Techniques. *Diagnostics*, 13, 2141, 2023. <https://doi.org/10.3390/diagnostics13132141>.
- [36] H.U. Amin, A.S. Malik, R.F. Ahmad, N. Badruddin, N. Kamel, M. Hussain, W.T. Chooi, Feature extraction and classification for EEG signals using wavelet transform and machine learning techniques. *Australasian Physical & Engineering Sciences in Medicine*, 38, 139–149, 2015. <https://doi.org/10.1007/s13246-015-0333-x>.
- [37] O. Bahadır, H. Türkmençalıkoğlu, Bilgi Kuramında Shannon Entropisi ve Uygulamaları. *The European Journal of Science and Technology*, 491–497, 2022. <https://doi.org/10.31590/ejosat.1039771>.
- [38] T. Batbat, İşitsel ve görsel uyarılar ile elde edilen uyarılmış potansiyel sinyallerinden farklı dikkat durumlarının değerlendirilmesi. Doktora Tezi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Türkiye, 2020.
- [39] R.M. Mehmood, H.J. Lee, A novel feature extraction method based on late positive potential for emotion recognition in human brain signal patterns. *Computers*

- & Electrical Engineering, 53, 444-457, 2016. <https://doi.org/10.1016/j.compeleceng.2016.04.009>.
- [40] R. Jenke, A. Peer, M. Buss, Feature extraction and selection for emotion recognition from EEG. *IEEE Transactions on Affective Computing*, 5, 327–339, 2014. <https://doi.org/10.1109/TAFFC.2014.2339834>.
- [41] Z. Li, X. Wu, X. Xu, H. Wang, Z. Guo, Z. Zhan, L. Yao, The Recognition of Multiple Anxiety Levels Based on Electroencephalograph. *IEEE Transactions on Affective Computing*, 13, 519–529, 2022. <https://doi.org/10.1109/TAFFC.2019.2936198>.
- [42] P. Bhuvanawari, J.S. Kumar, Influence of linear features in nonlinear electroencephalography (EEG) signals. *Procedia Computer Science*, 47, 229–236, 2015. <https://doi.org/10.1016/j.procs.2015.03.202>.
- [43] N.S. Altman, An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*, 46, 175–185, 1992. <https://doi.org/10.1080/00031305.1992.10475879>.
- [44] S. Ibrahim, R. Djemal, A. Alsuwailem, S. Gannouni, Electroencephalography (EEG)-based epileptic seizure prediction using entropy and K-nearest neighbor (KNN). *Communications in Science and Technology*, 2, 6–10, 2017. <https://doi.org/10.21924/cst.2.1.2017.44>.
- [45] M.N.A.H. Sha'abani, N. Fuad, N. Jamal, M.F. Ismail, kNN and SVM Classification for EEG: A Review. *Lect. Notes Electr. Eng.*, pp. 555–565, Springer, 2020. https://doi.org/10.1007/978-981-15-2317-5_47.
- [46] F. Murtagh, Multilayer perceptrons for classification and regression. *Neurocomputing*, 2, 183–197, 1991. [https://doi.org/10.1016/0925-2312\(91\)90023-5](https://doi.org/10.1016/0925-2312(91)90023-5).
- [47] R. Chatterjee, T. Bandyopadhyay, EEG Based Motor Imagery Classification Using SVM and MLP. *Proceedings of the 5th International Conference on Electrical, Control & Computer Engineering*, 29th July 2019, pp. 84–89, Kuantan, Pahang, Malaysia, IEEE, 2016. <https://doi.org/10.1109/CINE.2016.22>.
- [48] L. Breiman, Random forests. *Machine Learning*, 45, 5–32, 2001.
- [49] M. Koçyiğit, A. Güven, F. Çam, Beyin Bilgisayar Arayüzünün Geliştirilmesi İçin Hayali Motor Görüntü Tabanlı Yakın Kızılötesi Spektroskopi Sinyallerinin Sınıflandırılması. *Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 9, 1–8, 2020. <https://doi.org/10.28948/ngumuh.606507>.
- [50] W. Chen, Y. Wang, G. Cao, G. Chen, Q. Gu, A random forest model based classification scheme for neonatal amplitude-integrated EEG. *Biomedical engineering online*, 13, 1–13, 2014. <https://doi.org/10.1186/1475-925X-13-S2-S4>.
- [51] A. Arsalan, M. Majid, A study on multi-class anxiety detection using wearable EEG headband. *J. Journal of Ambient Intelligence and Humanized Computing*, 13, 5739–5749, 2022. <https://doi.org/10.1007/s12652-021-03249-y>.
- [52] S.I. Dimitriadis, C.I. Salis, D. Liparas, An automatic sleep disorder detection based on EEG cross-frequency coupling and random forest model. *Journal of Neural Engineering*, 18, 46064, 2021. <https://doi.org/10.1088/1741-2552/abf773>.
- [53] C. Kamarajan, B.A. Ardekani, A.K. Pandey, D.B. Chorlian, S. Kinreich, G. Pandey, J.L. Meyers, J. Zhang, W. Kuang, A.T. Stimus, B. Porjesz, Random forest classification of alcohol use disorder using EEG source functional connectivity, neuropsychological functioning, and impulsivity measures. *Behavioral Sciences*, 10, 62, 2020. <https://doi.org/10.3390/bs10030062>.
- [54] A. Tharwat, Classification assessment methods. *Applied computing and informatics*, 17, 168–192, 2018. <https://doi.org/10.1016/j.aci.2018.08.003>.
- [55] Ž. Vujović, Classification Model Evaluation Metrics. *International Journal of Advanced Computer Science and applications*, 12, 599–606, 2021. <https://doi.org/10.14569/IJACSA.2021.0120670>.
- [56] T. Saito, M. Rehmsmeier, The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. *PLoS One*, 10, e0118432, 2015. <https://doi.org/10.1371/journal.pone.0118432>.
- [57] A. Zugman, L. Jett, C. Antonacci, A. M. Winkler, & D. S. Pine, A Systematic Review and Meta-Analysis of Resting-state fMRI in Anxiety Disorders: Need for Data Sharing to Move the Field Forward. *Journal of Anxiety Disorders*, 102773, 2023.
- [58] S. Mizzi, M. Pedersen, V. Lorenzetti, M. Heinrichs, & I. Labuschagne, Resting-state neuroimaging in social anxiety disorder: a systematic review. *Molecular Psychiatry*, 27(1), 164–179, 2022.
- [59] ND. Woodward, C.J. Cascio. Resting-State Functional Connectivity in Psychiatric Disorders. *JAMA Psychiatry*, 72(8), 743–4. 2015. <https://doi.org/10.1001/jamapsychiatry.2015.0484>.
- [60] L.S. Mokatren, R. Ansari, A.E. Cetin, A.D. Leow, O. Ajilore, H. Klumpp, F.T.Y. Vural, EEG Classification based on Image Configuration in Social Anxiety Disorder. *International IEEE/EMBS Conference on Neural Engineering (NER)*, pp. 577–580, IEEE, 2019. <https://doi.org/10.1109/NE R.2019.8717152>.
- [61] A. Al-Ezzi, A.A. Al-Shargabi, F. Al-Shargie, A.T. Zahary, Complexity Analysis of EEG in Patients With Social Anxiety Disorder Using Fuzzy Entropy and Machine Learning Techniques. *IEEE Access*, 10, 39926–39938, 2022. <https://doi.org/10.1109/ACCESS.2022.3165199>.
- [62] J.W.G. Tiller, Depression and anxiety. *The Medical Journal of Australia*, 199, 28–31, 2013. <https://doi.org/10.5694/mja12.10628>.
- [63] H. Türçapar, Anksiyete Bozukluğu ve Depresyonun Tanısal İlişkileri. *Klinik Psikiyatri*, 4, 12–16, 2004.
- [64] O. Karamustafaloğlu, H. Yumrukçal, Depresyon ve anksiyete bozuklukları. *Şişli Etfal Hastanesi Tıp Bülteni*, 45, 65–74, 2011.

