



# EEG İşareti tabanlı anksiyete sınıflandırması için dalgacık dönüşümü ile öznelik çıkarma

## Feature extraction with wavelet transform for EEG signal based anxiety classification

Shams Qahtan Omar Omar<sup>1,\*</sup> , Cengiz Tepe<sup>2</sup> 

<sup>1</sup> Ondokuz Mayıs Üniversitesi, Lisansüstü Eğitim Enstitüsü, Akıllı Sistemler Mühendisliği Anabilim Dalı, 55200, Samsun Türkiye

<sup>2</sup> Ondokuz Mayıs Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, 55200, Samsun, Türkiye

### Öz

Anksiyete, üretkenliği ve yaşam kalitesini etkilediği kadar insan yeteneklerini ve davranışlarını da etkiler. Depresyon ve intiharın ana nedeni olarak kabul edilebilir. Günümüzde klinisyenler anksiyete bozukluklarını teşhis etmek için belirli kriterler kullanılmaktadır. Anksiyete tespitinin karmaşık görevini yerine getiren, invaziv olmayan güvenilir tekniklere ihtiyaç vardır. Bu çalışma, elektroensefalografi (EEG) sinyallerini analiz ederek ikili ve dördü sınıfları daha az EEG kanalı ve öznelik sınıflandırmayı amaçlamıştır. 23 kişinin 14 kanallı EEG sinyalini içeren DASPS veri tabanı kullanılmıştır. EEGLAB kullanarak 14 kanaldan 4 kanal seçilmiştir. Öznelik çıkarımı için dalgacık dönüşümü kullanılmıştır. MATLAB Classification learner toolbox'taki 8 yöntem ile sınıflandırma yapılmıştır. En yüksek doğrulukta başarımlar ikili sınıflandırmada %67.1 doğrulukta Karar ağaçları yönteminde, dördü sınıflandırmada %58.5 doğrulukta destek vektör makinesi ile elde edilmiştir

**Anahtar kelimeler:** EEG, Anksiyete, Kanal seçimi, Karar ağaçları, Destek Vektör Makinesi

### 1 Giriş

Anksiyete bozukluğu, beyindeki kimyasalların dengesini değiştirebilen aşırı korku veya endişe içeren psikiyatrik bozukluklardan biridir [1]. Anksiyete, sıklıkla acil bir tehlike olmasa bile, endişe ve korku içeren olumsuz bir zihin durumudur. Anksiyete, sık sık meydana geldiğinde ve gerçek tehdit seviyesiyle orantısız görünen yoğunluk seviyelerinde geniş bir sorun yelpazesine dönüşebilir. Son araştırmalar, stres etkeninin özellikleri ve çeşitli biyolojik ve psikolojik kırılmalıklar dahil olmak üzere, kişinin sağlığı üzerindeki stres/ anksiyete ile ilgili etkinin derecesini ve türünü belirleyen değişkenlere ışık tutmaya başlıyor. Stres ve özellikle anksiyete, nesnel yollarla kapsamlı bir şekilde ölçülmesi zor olan öznel, çok yönlü fenomenler olmasına rağmen, stres ve anksiyetenin kişinin sağlığı üzerindeki etkileri çeşitli şekillerde ölçülebilir. Bununla birlikte, bir kişinin normal şekilde çalışma ve yaşam olaylarına uyum sağlama yeteneği ve genel refahı üzerinde etkileri olduğuna dair kanıtlar vardır [2].

### Abstract

Anxiety affects productivity and quality of life as well as human abilities and behaviors. It can be considered the main cause of depression and suicide. Clinicians today use specific criteria to diagnose anxiety disorders. There is a need for reliable, non-invasive techniques that fulfil the complex task of detecting anxiety. This study aimed to classify binary and quadruple classes with fewer EEG channels and features by analyzing electroencephalography (EEG) signals. A DASPS database containing 14-channel EEG signals from 23 individuals was used. Using EEGLAB, 4 channels were selected from 14 channels. The wavelet transform is used for feature extraction. The MATLAB Classification learner toolbox contained eight methods for classification. The highest accuracy performances were obtained with the Decision trees method with an accuracy of 67.1% in binary classification, and with a support vector machine with an accuracy of 58.5% in quadruple classification.

**Keywords:** EEG, Anxiety, Channel selection, Decision Tree, Support Vector Machine

Elektroensefalografi (EEG), beynin nöronları içindeki iyonik akımın elektriksel voltaj dalgalanmalarını ölçer [3]. EEG, nöral bilgi işlemenin uzaysal ve zamansal dinamiklerini anlamak için potansiyel olarak yararlı sinyaller sağladığından, insan beyinin incelenmesi için önemli bir araçtır [4]. Günümüzde, EEG sinyalleri, Beyin Bilgisayar Arayüzünü (BBA) iyileştirmek için makine öğrenme algoritmalarıyla birleştirilir. BBA, protez uzuvlar, robotik, ev otomasyon sistemleri, cep telefonu uygulamaları, beyin bozukluklarının teşhisi, tekerlekli sandalye hareketleri ve ses tanıma sistemleri dahil olmak üzere çeşitli cihazları çalıştırmak için kullanılabilir [5, 6].

EEG, sınıflandırma ve anksiyete ile ilgili yapılan çalışmalar incelendiğinde; yapılan bir çalışmada, yoga ve Sudarshan Kriya (SK) meditasyonunun birleşik etkisini ve istatistiksel parametreler kullanılarak beyin sinyalleri üzerinde analiz yapılmıştır. Araştırmacı, üç aylık düzenli yoga ve SK uygulaması öncesi ve sonrasında, kontrol ve çalışma grubundan EEG sinyalleri alınmıştır. Ayrık Dalgacık Dönüşümü (ADD), sinyali analiz için db4

\* Sorumlu yazar / Corresponding author, e-posta / e-mail: 20281248@stu.omu.edu.tr (S. Q. Omar)

Geliş / Received: 05.01.2023 Kabul / Accepted: 15.05.2023 Yayınlanma / Published: 15.07.2023

doi: 10.28948/ngumuh.1230092

dalgacığı kullanılarak alt bant ayrıştırmak için kullanılmıştır. Denekleri meditasyon yapanlar ve meditasyon yapmayanlar olarak sınıflandırmak için istatistiksel parametreler üzerinde Yapay Sinir Ağı (YSA) uygulanmıştır [7].

Aslam ve ark., yaptıkları çalışmada, büyük ölçekli özellik çıkarma ve özellik seçim algoritmalarını kullanarak optimal özellikleri seçmek için kapsamlı bir özellik setini analiz etmişlerdir. Doğrusal destek vektör makinesi kullanılarak duyguların tahmini için en iyi durum özellik seçim algoritmaları kullanılarak sekiz kanaldan oluşan bir dizi tanımlanmıştır. Bu çalışma, literatürde şimdiye kadar bildirilen doğrulama için en fazla sayıda kıyaslama veri setini ve deneklerini kullanmıştır [8].

Penchina ve ark., nörotipik ve otistik ergenlerde stres indüksiyonu sırasında yavaş tempolu nefes almanın algılanan anksiyete düzeyleri üzerindeki etkilerini araştırmışlardır. Daha sonra çok sınıflı bir uzun kısa vadeli tekrarlayan sinir ağı (UKVD TSA) derin öğrenme sınıflandırıcısı önermişler. Bu çalışma, endişeli durumları EEG'den ayırtmak için bir UKVD TSA sınıflandırıcısını etkili bir şekilde kullanan ilk çalışmadır [9].

Arsalan ve ark. EEG verilerini kullanarak sürekli bir anksiyete saptama çerçevesi sunmuşlardır. Önerilen çerçeve dört aşamadan oluşur: EEG veri toplama, ön işleme, özellik çıkarma ve seçme ve sınıflandırma. 65 katılımcının EEG verileri gözler açık durumda iki dakika süreyle kaydedilmiştir. Sürekli anksiyete puanları, katılımcıların EEG verilerini iki ( anksiyeteli ve anksiyetesiz ) ve üç (anksiyetesiz, hafif anksiyeteli ve çok anksiyeteli) sınıf olarak etiketleyen durumluk-sürekli anksiyete envanteri anketi kullanılarak toplanmıştır. Kaydedilen EEG verilerinin ön işleme, MUSE EEG baş bandının yerleşik gürültü azaltma şeması kullanılarak gerçekleştirilmiştir. Kanal seçimi, sırasıyla iki ve üç anksiyete sınıfı için güç spektral yoğunluklarına bir t-testi ve varyans analizi uygulanarak yapılmıştır. Seçilen EEG kanallarından beş zaman alanı özelliği çıkarılmıştır. Sürekli anksiyeteyi sınıflandırmak için kullanılan özelliklerin optimal bir alt kümesinin özellik seçimi için kaydırma yöntemi uygulanmıştır [10].

Asif ve ark. dört kanallı bir MUSE kafa bandı kullanarak yirmi yedi denek için beyin sınıflarını kullanarak İngilizce ve Urduca dilindeki müzik parçalarının insan stres düzeyi üzerindeki etkisini incelemişlerdir. Çalışmada, öznenin stres düzeyini iki ve üç sınıfa ayırmak için sıralı minimal optimizasyon, stokastik uygun gradyan, Lojistik Regresyon (LR) ve çok katmanlı algılayıcı olmak üzere dört sınıflandırıcı algoritma kullanılmıştır [11].

Baghdadi ve ark. yüz yüze psikolojik uyarılar aracılığıyla kaygı uyandırma sırasında 23 katılımcının 14 kanallı EEG sinyallerini içeren DASPS veri tabanını oluşturmuşlardır. EEG sinyalleri, kablosuz giyilebilir düşük maliyetli bir ekipman olduğu için Emotiv EPOC kulaklık ile alınmıştır. Özellikle deneme süresi, özellik türü, özellik kombinasyonu ve kaygı seviyeleri sayısı gibi farklı parametrelerin etkisini araştırmışlardır. Bulgular, kaygının 1 saniyede iyi bir şekilde ortaya çıktığını göstermiştir [12].

Agrawal ve ark., DASPS veritabanını kullanarak öz nitelikler arasındaki fazlalığı azaltmak ve sonuçları iyileştirmek için sınıflandırıcılarla birlikte özyinelemeli

öz nitelik seçim yöntemi kullanmışlardır. İki sınıflı kaygı sınıflandırması için zaman-frekans düzlemi ile Karar Ağacı kullanarak %66.70 sınıflandırma doğruluğu elde etmişlerdir [13].

Maheshwari ve ark. çalışmalarında, çok kanallı EEG sinyallerini kullanarak duygu tanıma için ritme özgü çok kanallı Evrişimli Sinir Ağı (ESA) tabanlı bir yaklaşım önermişlerdir. Her kanal için EEG sinyalinin delta, teta, alfa, beta ve gama ritimleri bant geçiren filtreler kullanılarak değerlendirilmiştir. Önerilen çok kanallı ritme özgü derin ESA sınıflandırma modeli, alfa-ritim kullanarak DASPS veri tabanı ile ortalama %57.14 doğruluk değeri elde etmiştir [14].

Bu çalışmada, daha az sayıda EEG kanalı ve öz nitelik kullanımının anksiyete sınıflandırması başarımına etkisi araştırılmıştır. DASPS veri tabanı [12] kullanılarak EEGLAB ile 14 kanal arasında AF3, P8, FC6 ve F8 olmak üzere 4 kanal seçilmiştir. Matlab'ın "Classification Learner" araç kutusundaki Karar Ağacı (KA), Diskriminant Analizi (DA), Lojistik regresyon (LR), Naive bayes (NB), Topluluk sınıflandırması (TB), K-en yakın komşu (KEK), Destek vektör makinesi (DVM) ve YSA yöntemleri kullanılmıştır. Bu sekiz yöntem kullanılarak sınıflandırmanın performansını artırmak için seçilen dört kanal EEG sinyali üzerinden Ardışıl İleri Yönlü Öz nitelik Seçme (AİYÖS) metodu kullanılmıştır. Böylelikle en yüksek başarıyı veren öz nitelik kümesi elde edilmeye çalışılmıştır.

## 2 Materyal ve metod

Bu çalışma, Şekil 1'de görüleceği üzere DASPS veri tabanından veri toplama, kanal seçimi, özellik çıkarma, veri etiketleme, özellik seçimi ve anksiyete sınıflandırması olmak üzere altı bölümden oluşmaktadır.



Şekil 1. Anksiyete sınıflandırma blok şeması

### 2.1 Veri tabanı

Bu makale, anksiyete düzeyi tespiti için Bağdadi ve ark. [12] tarafından toplanan kamuya açık DASPS Veri kümesini kullanılmıştır. Bu veri kümesi yaş ortalaması 30 olan ve cinsiyet dağılımı 10 erkek ve 13 kadın olan 23 katılımcıdan oluşmaktadır. EEG sinyalini 14 kanallı ve 128 Hz örnekleme hızında alınmıştır.

Deneklerin etiketlenmesi şu şekilde yapılmaktadır: Bireyin "değerlik 5'ten küçük ve uyarılma 5'ten büyük olan EEG verisi Normal olarak, değerlik puanları 0 ile 2 arasında ve uyarılma puanı 7 ile 9 arasında olan veriler Şiddetli olarak etiketlenir. Değerlik puanları 2-4 ve uyarılma puanları 6-7

arasında olanlar Orta düzeyde anksiyete, değerlik puanı 4 ile 5 arasında ve uyarılma puanı 5-6 arasında olanlar Hafif anksiyete olarak etiketlenir [12].

İki seviyeli anksiyete tespiti için 15 saniyelik bir deneme süresi ele alındığında Hafif Anksiyete: 176 ve Şiddetli Anksiyete: 100 olarak bulunmuştur. Benzer şekilde, dört seviyeli anksiyete tespiti için vaka sayısı Normal Anksiyete:165, Hafif Anksiyete: 20, Orta Anksiyete: 10 ve Şiddetli Anksiyete: 90 olarak bulunmuştur. Bu sayılar yüzdelik değer olarak Şekil 2’de verilmektedir.

## 2.2 EEGLAB

Hesaplamalı Sinirbilim Merkezi'nin (SCCN) açık kaynaklı bir yazılım projesi olan EEGLAB veri analiz yapan bir araçtır [15, 16].

Bu çalışmada da kanal seçimi için EEGLAB kullanıldı. Önemli olmayan kanallar güç tayf yoğunluğu grafiği üzerinden seçildi. Şekil 3’te örnek olarak sadece üç farklı bireyin için güç tayf yoğunluğu verilmiştir. Her bir birey için, bu grafik üzerinde çakışık olan kanallara “1” değeri verildi. Diğerlerine ise “0” değeri verildi. Tüm bireyler (23 kişi) için bu değerlerin toplamı alındı. Değişimin en az olduğu ilk dört kanal seçildi.


## 2.3 Ardışıl ileri yönlü öznelik seçimi (AİYÖS)

Ardışıl ileri yönlü öznelik seçme (AİYÖS) yöntemi, bir veri kümesindeki gereksiz ve ilgili olmayan özneliklerin çıkartılarak verilerin boyut azaltımı yapılması işlemidir. Bu yöntemde, belirli bir öznelik kümesi oluşturulur. Sonrasında her bir adımda seçilen yöntemle göre öznelik kümesinden bir öznelik eklemek işlemi yapılır. Örnek olarak, ilk belirlenen öznelik alt kümesi tek bir öznelikten oluşmaktadır. Belirlenen sınıflandırma algoritmasının doğruluk oranına göre her bir adımda sınıflandırma doğruluk oranı en yüksek olan öznelikler seçilir. Bu seçilen öznelik bir sonraki adıma dahil edilir. İkinci belirlenen öznelik alt kümeleri ise ikili özneliklerden oluşmaktadır. Burada da yine doğruluk oranı en yüksek olan öznelik alt kümesi belirlenerek bir sonraki adıma dahil edilir. Tüm öznelikler tek tek seçim kümesine eklenene kadar bu işlemler devam ettirilir. Sonrasında en yüksek doğruluk oranı olan öznelik alt kümesi seçilmiş olur [17-18].

## 2.4 Öznelik çıkarımı ve seçimi

Dalgacık dönüşümü(DD), EEG sinyali gibi durağan olmayan sinyal işleme için iyi bir yöntemdir. DD, sinyalin zaman-frekans gösterimini sunar [19]. Bu çalışmada Ayrık Dalgacık Dönüşümü (ADD) kullanılmıştır. ADD, EEG işaretini detay(D) ve yaklaşık (A) katsayılarına ayırır. EEG sinyalleri genellikle 0.5- 4 Hz Delta( $\delta$ ), 4- 8 Hz Teta( $\theta$ ), 8-16 Hz Alfa( $\alpha$ ), 16- 32 Hz Beta( $\beta$ ), 32 Hz ve üstündeki sinyaller Gama( $\gamma$ ) olmak üzere beş frekans bandından oluşmaktadır [20-22]. DD yöntemi, EEG sinyalini zaman-frekans düzlemine aktarır. DD yöntemi ile doğru EEG alt frekans bandlarını elde etmek için 5. seviye dalgacık dönüşümü kullanılmıştır. Ayrıca yapılan kaynak taramasında EEG sinyalleri sınıflandırmada başarımları en yüksek olan Daubechies 5 [23, 24] verdiği için bu çalışmada da bu dalgacık kullanılmıştır.

Ayrıştırma seviyesi 5, dalgacık tipi Daubechies 5 olarak seçilmiştir. Beşinci seviyeden ayrıştırılan sinyal ve alt frekans bantları Şekil 4’te gösterilmiştir [25].



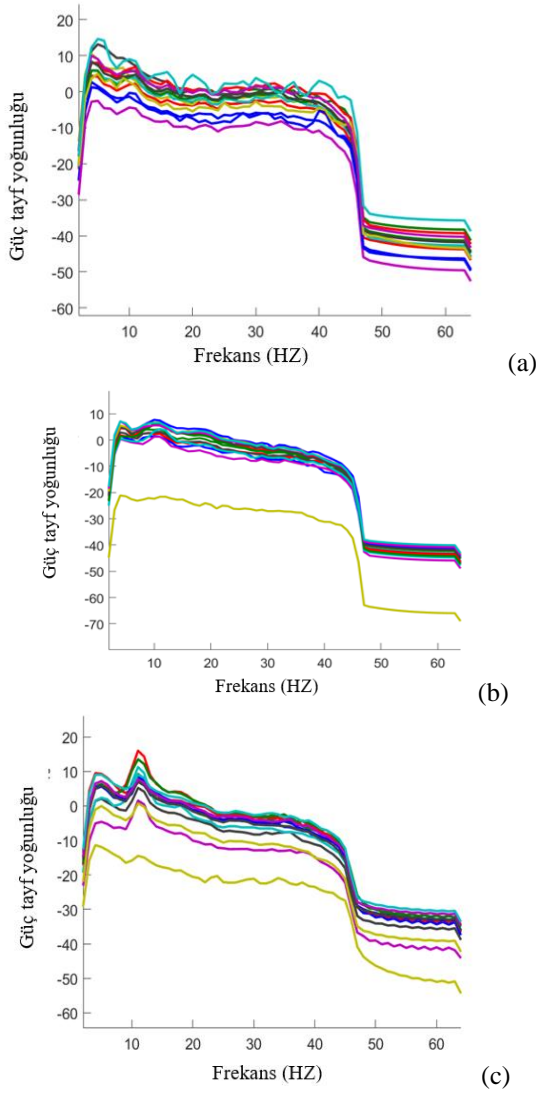
Şekil 2. (a) İkili sınıflandırma (b) Dörtlü sınıflandırma için etiketleme yüzdeleri

Her bir ayrıntı ve detay katsayıları Tablo 1’de verilen matematiksel formüller kullanılarak öznelikler hesaplanır. Bu çalışmada AİYÖS yöntemine göre gereksiz ve ilgisiz öznelikler çıkartılarak en anlamlı (en yüksek başarımları veren) alt öznelik kümesi belirlenmiştir. Bilindiği üzere EEG işareti alfa, beta, teta, gama ve delta alt frekans bandlarından oluşmaktadır. Bu alt öznelik kümesi hala beş adet EEG işareti alt frekans bandlarını içermektedir. Bu çalışmada ayrıca seçimi yapılan alt öznelik kümesinde ilgisiz ve gereksiz alt frekans bandlarının seçimi de yapılmıştır. Bu seçimde de yine AİYÖS kullanılmıştır [17-18].

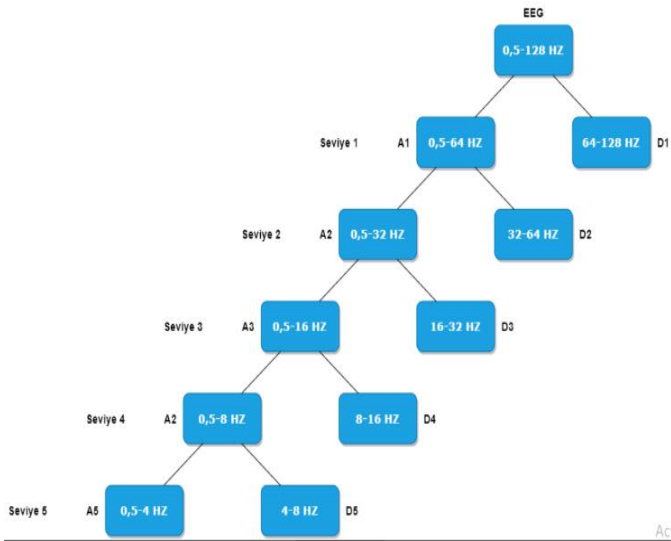
Bu öznelikler içerisinde, AİYÖS yöntemi kullanılarak en iyi başarımları veren öznelik kümesi elde edilir.

Tablo 1. Zaman-frekans özellikleri

Kısaltma = Özellik = Denklem
f1= Minimum= $\text{Min}(x_i)$
f2= Maksimum= $\text{max}(x_i)$
f3= Ortanca = $\frac{n+1}{2}$
f4= Ortalama = $\frac{\sum_{i=1}^N (x_i - \mu)^2}{N}$
f5= Standart sapma= $\sqrt{\frac{\sum_{i=1}^N (x_i - \mu)^2}{N}}$
f6= Kök Kare Ortalama= $\sqrt{\frac{1}{N} \sum X^2}$
f7= Bant Gücü = $\frac{1}{2N+1} \sum_{n=-N}^{n=N}  x(n) ^2$
f8= Ortalama Mutlak Sapma = $\frac{1}{n} \sum_{i=1}^n  x_i - m $
f9= Sinyalin Spektral Entropisi = $\sum_n p_n \log \log \left( \frac{1}{p_n} \right)$
f10= Varyans = $\frac{\sum x^2}{N-1}$
f11= Medyan Frekans = $\left( \frac{n+1}{2} \right)^{\text{th}}$ term (n, tek ise) Medyan Frekans = $\frac{\left( \frac{n}{2} \right)^{\text{th}} \text{term} + \left( \frac{n}{2} + 1 \right)^{\text{th}} \text{term}}{2}$ (n, çift ise)



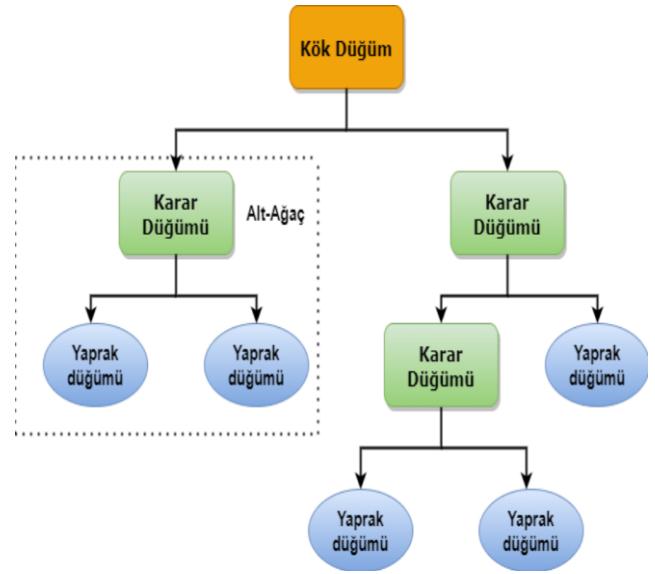
Şekil 3. a)1. b)2. ve c)3. bireye ait güç tayf yoğunluğu



Şekil 4. ADD alt frekans bantları ve ayrıştırma seviyeleri [26]

## 2.5 Karar ağaçları

Karar Ağaçları(KA), popüler bir makine öğrenimi yöntemidir. KA, makine öğrenmesi, görüntü işleme ve örüntü tanımlama gibi çeşitli alanlarda yaygın olarak kullanılan güçlü yöntemlerden biridir. Şekil 5'te görüleceği üzere tipik olarak, bir karar ağacı bir kök düğüm, birden çok dahili düğüm ve birden çok yaprak düğümden oluşur. Yaprak düğümler karar sonuçlarına karşılık gelir ve diğer her düğüm bir özellik testine karşılık gelir. Her düğümdeki örnekler, özelliklerin bölme sonuçlarına göre alt düğümlere bölünür. Kök düğümden yaprak düğüme giden her yol bir karar dizisidir. Amaç, görünmeyen örnekleri tahmin etmek için genelleme yapabilen bir ağaç üretmektir [27, 28].



Şekil 5. KA algoritması kavramı [28]

## 2.6 Destek vektör makineleri

Destek Vektör Makineleri (DVM), istatistiksel öğrenme teorisine dayalı olarak Vapnik tarafından oluşturulmuştur. Doğrusal olmayan ilişkiler ve çoklu sınıflandırmalarla ilgili sorunları [29]. DVM, karar sınırlarını tanımlayan karar düzlemleri kavramına dayanmaktadır. Karar düzlemi, farklı sınıf üyeliklerine sahip bir dizi nesne arasında ayrım yapan düzlemdir [30]. DVM son yıllarda örüntü sınıflandırma ve regresyon için son derece güçlü ve önemli araçlar olarak ortaya çıkmıştır. DVM, EEG sinyallerinin sınıflandırmasında yoğun olarak kullanılmaktadır, depresyon hastaları tanınması [31], insan vücudunun hareket amacını tahmin etmesi [32], epileptik nöbetin sınıflandırılması [33] gibi ve daha pek çok çalışmalar vardır.

## 3 Bulgular ve tartışma

İkili sınıflandırma sonuçlarına göre tek öznitelik ve tüm sınıflandırma yöntemleri kullanıldığında en yüksek başarıyı DVM yöntemi ile f3 özniteligi %66.7 ortalama doğruluk oranı ile vermiştir. AİYÖS yöntemine göre f3 sabit tutularak ikinci adımda diğer öznitelikler ile f3'un birleştirilmesi ile elde edilen öznitelik kombinasyonlarının başarıları araştırılmıştır. Bu kombinasyonlar elde edilen başarımdan düşene kadar veya özniteliklerin tamamı kullanılına kadar



ettirilmiştir Fakat ikili sınıflandırmada yüksek başarımlar üçüncü adımda f3+f8+f11 öznitelik kombinasyonunu ile %70.3 eğitim kümesi ile ve %63.4 test kümesinde en iyi sonuca ulaşılmıştır. Sınıflandırmanın performansını daha artırabilmek için ayrıca f3+f8+f11 özniteliği kullanılarak alt frekans bantları üzerinden de AİYÖS metodu kullanılmıştır. Burada her bir öznitelige 5. Seviyeden dalgacık dönüşümü uygulandığı için her bir öznitelik 5 boyutludur. Her bir boyutta EEG işaretinin alt frekans bandlarına denk gelmektedir. Her alt frekans bantları üzerinden de AİYÖS metodu kullanılarak ikili sınıflandırmada 2 alt frekans ve dörtlü sınıflandırmada 3 alt frekans boyutuna indirgenmiştir. Sınıflandırma sonuçları değerlendirildiğinde birinci adım beta frekans bandının %69.1 ortalama ile en yüksek sınıflandırma sonucunu verdiği görülmektedir. AİYÖS yöntemine göre beta sabit tutularak ikinci adımda diğer frekans bantları kombinasyonlarının başarısı araştırılmıştır. Bu kombinasyonlar elde edilen başarımlar düşene kadar devam ettirilmiştir. İkili sınıf için f3+f8+f11 öznitelikler ile beta ve theta frekans bantlarının KA yöntemi ile %70.6 eğitim ve Tablo 2’de gösterildiği gibi %67.1 test kümesi ile en yüksek doğruluk elde edilmiş ve tüm yöntemlerin doğruluk sonuçları verilmiştir. Böylelikle ikili sınıflandırma en az sayıda ve en yüksek doğrulukta sonuç veren öznitelikleri içeren theta+beta alt frekans literatüre kazandırılmıştır.

**Tablo 2.** Anksiyete ikili sınıflandırma yöntemlerinin theta+beta frekans bantları için test doğruluk sonuçları (%)

KA	DVM	TB	KEK	LR	DA	YSA	NB
67.1	65.9	65.9	63.4	62.2	59.8	58.5	57.3

Dörtlü sınıflandırmada ise AİYÖS yöntemine göre birinci adımda f9 özniteliğinin %59.8 ortalama ile en yüksek sınıflandırma sonucunu verdiği görülmektedir. AİYÖS yöntemine göre f9 sabit tutularak ikinci adımda diğer öznitelikler ile f9’un birleştirilmesi ile elde edilen öznitelik kombinasyonlarının başarısı araştırılmıştır. Bu kombinasyonlar elde edilen başarımlar düşene kadar veya özniteliklerin tamamı kullanılabilece kadar devam ettirilmiştir Fakat dörtlü sınıfta en yüksek başarımlar birinci adımda f9 öznitelik ile %59.8 eğitim kümesi ve %56.1 test kümesinde en iyi sonuca ulaşılmıştır. Sınıflandırmanın performansını daha artırabilmek için ayrıca f9 özniteliği kullanılarak alt frekans bantları üzerinden de AİYÖS metodu kullanılmıştır.

**Tablo 6.** Sınıflandırma performansının en son yaklaşımla karşılaştırılması

Çalışma	Sınıf Sayısı	Kanal sayısı	Frekans bandı	Sınıflandırıcı	Öznitelik sayısı	Doğruluk (%)
Baghdadi et al [12]	İkili	14	Alpha, beta, theta, gamma, delta	k-EK	112	67.10
	4 sınıf	14	Alpha, beta, theta, gamma, delta	DVM	112	59.70
Agrawal et al [13]	İkili	14	Theta, alpha, beta, gamma	RF	336	66.7
Maheshwari et al [14]	İkili	14	alpha	ESA	828	57.14
Bu çalışma	İkili	4	Beta, theta	KA	24	67.10
	4 sınıf	4	Gamma, delta ve alpha	DVM	12	58.5

Sınıflandırma sonuçları değerlendirildiğinde birinci adım gamma frekans bandının %58.8 ortalama ile en yüksek sınıflandırma sonucunu verdiği görülmektedir. AİYÖS yöntemine göre gamma sabit tutularak ikinci adımda diğer frekans bantları kombinasyonlarının başarısı araştırılmıştır. Bu kombinasyonlar elde edilen başarımlar düşene kadar devam ettirilmiştir Dörtlü sınıf için f9 öznitelik ile gamma, delta ve alpha frekans bantlarının DVM ile %59.3 eğitim ve Tablo 3’te gösterildiği gibi %58.5 test kümesi ile en yüksek doğruluk elde edilmiştir. Böylelikle dörtlü sınıflandırma için en az sayıda ve en yüksek doğrulukta sonuç veren öznitelikleri içeren gamma+delta+alpha alt frekans literatüre kazandırılmıştır.

**Tablo 3.** Anksiyete dörtlü sınıflandırma yöntemlerinin gamma +delta+alpha frekans bantları için test doğruluk sonuçları

KA	DVM	TB	K-EK	DA	YSA	NB
%54.9	%58.5	%54.9	%56.1	%57.3	%40.2	%43.9

Bu çalışmada elde edilen veriler hem kendi içerisinde hem de aynı veri tabanını kullanan Baghdadi ve arkadaşlarının [12]’çalışması ile karşılaştırılmıştır.

Tablo 6’da görüleceği üzere, Baghdadi ve ark. [12] yaptığı çalışmada hem ikili hem de dörtlü sınıflandırma için 14 kanal EEG, tüm alt frekans bantları ve 112 tane öznitelik kullanılmıştır. Maheshwari ve ark.[14] yaptığı çalışmada sadece ikili sınıflandırma için 14 kanal EEG, alpha alt frekans bantı ve 828 tane öznitelik kullanılmıştır. Agrawal ve ark.[13] yaptığı çalışmada sadece ikili sınıflandırma için 14 kanal EEG, Theta, alpha, beta ve gamma alt frekans bantları ve 336 tane öznitelik kullanılmıştır. Bu çalışmada ise, ikili sınıflandırma için Tablo 2’de görüleceği üzere kullanılan sekiz yöntemden KA en yüksek başarımlar %67.1 doğruluk oranı vermiştir. Dörtlü sınıflandırma için Tablo 3’te görüleceği üzere bu çalışmada kullanılan sekiz yöntemden DVM en yüksek başarımlar %58.5 doğruluk oranı vermiştir. Bu çalışmada ise 14 kanal yerine 4 kanal EEG verisi kullanılmıştır. Tablo 6’da görüleceği üzere, her EEG kanalı için, ikili sınıflandırmada beta, theta alt frekans bantları ve 24 tane öznitelik, dörtlü sınıflandırmada ise gamma, delta ve alpha alt frekans bantları ve 12 tane öznitelik kullanılmıştır.

#### 4 Sonuçlar

Bu çalışmada, anksiyete bozukluğu sınıflandırmasında sekiz tane yöntemin başarımı incelenmiştir. İki sınıflandırmada KA, dördü sınıflandırma ise DVM en yüksek başarımı vermiştir. 14 kanal EEG yerine 4 kanal kullanılarak ikili sınıflandırmada toplam 24 öznitelik, dördü sınıflandırmada ise 12 öznitelik kullanılmıştır.

Sonuç olarak bu çalışmada, Baghdadi ve arkadaşlarının [12] ve Maheshwari ve arkadaşlarının [14] çalışmalarına göre daha az EEG kanalı, öznitelik sayısı ve alt frekans bandı kullanılarak benzer sonuçlar elde edilmiştir. Agrawal ve arkadaşlarının [13] çalışmalarına göre daha az EEG kanal ve öznitelik sayısı kullanılarak daha yüksek bir sonuçlar elde edilmiştir. Aynı zamanda öznitelik matrisinin boyutunda indirgeme yapılarak işlemsel hesap yükü ve süresi azaltılmıştır.

Gelecekteki çalışmalarda, sinyalin zaman ve frekans düzlemindeki başarımları incelenecektir. Ek olarak sonuçları doğrulamak ve genelleştirilmiş bir anksiyete bozukluğu sınıflandırma modeli oluşturmak için daha kapsamlı bir veri seti oluşturulabilir. Anksiyete farklı etnik kökene sahip bireylerde farklı olabilir. Bundan dolayı farklı etnik kökene sahip katılımcılardan EEG verileri alınarak bunun etkisi araştırılabilir

#### Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

#### Benzerlik oranı (iThenticate): %14

#### Kaynaklar

- [1] Zhang, X. Wang, W. Tan, Q. Gao, D. J. J. o. m. Shin, and b. Engineering, EEG-based anxious states classification using affective BCI-based closed neurofeedback system. *Journal of Medical and Biological Engineering*, 41, 155–164, 2021. <https://doi.org/10.1007/s40846-020-0096-7>.
- [2] G. Giannakakis, M. Pedititis, D. Manousos, E. Kazantzaki, F. Chiarugi, P. G. Simos, K. Marias, M. J. B. S. P. Tsiknakis, and Control, Stress and anxiety detection using facial cues from videos. 31, 89-101, 2017. <https://doi.org/10.1016/j.bspc.2016.06.020>.
- [3] S. Mirzaei, P. J. B. S. P. Ghasemi, and Control, EEG motor imagery classification using dynamic connectivity patterns and convolutional autoencoder. 68, 102584, 2021. <https://doi.org/10.1016/j.bspc.2021.102584>.
- [4] R. G. de Magalhaes Júnior, F. T. Rocha, and C. E. J. I. L. A. T. Thomaz, Comparison Between Linear and Tensor Models of EEG Signals Representation. 19, 01, 132-137, 2021. <https://doi.org/10.1109/TLA.2021.9423856>.
- [5] M. Akmal, S. Zubair, and H. J. I. A. Alquhayz, Classification analysis of tensor-based recovered missing EEG data. 9, 41745-41756, 2021. <https://doi.org/10.1109/ACCESS.2021.3063382>.
- [6] S. Q. O. OMAR, and T. J. B. Ü. F. B. D. Cengiz, EEG Sinyallerini İşlemek İçin Makine Öğreniminin

- [7] H. Sharma, R. Raj, and M. J. N. I. Juneja, EEG signal based classification before and after combined Yoga and Sudarshan Kriya. 707, 134300, 2019. <https://doi.org/10.1016/j.neulet.2019.134300>.
- [8] A. R. Aslam, N. Hafeez, H. Heidari, and M. A. B. J. F. i. N. Altaf, Channels and Feature Identification with Large Scale Feature Extraction for Emotions and ASD Classification. 1094, 2022. <https://doi.org/10.3389/fnins.2022.844851>.
- [9] B. Pechina, A. Sundaresan, S. Cheong, and A. Martel, Deep LSTM recurrent neural network for anxiety classification from EEG in adolescents with autism. 227-238. [https://doi.org/10.1007/978-3-030-59277-6\\_21](https://doi.org/10.1007/978-3-030-59277-6_21).
- [10] A. Arsalan, M. J. J. o. A. I. Majid, and H. Computing, A study on multi-class anxiety detection using wearable EEG headband. 1-11, 2021. <https://doi.org/10.1007/s12652-021-03249-y>.
- [11] A. Asif, M. Majid, S. M. J. C. i. b. Anwar, and medicine, Human stress classification using EEG signals in response to music tracks. 107, 182-196, 2019. <https://doi.org/10.1016/j.combiomed.2019.02.015>.
- [12] A. Baghdadi, Y. Aribi, R. Fourati, N. Halouani, P. Siarry, and A. M. J. a. p. a. Alimi, DASPS: A Database for Anxious States based on a Psychological Stimulation. 2019. <https://doi.org/10.48550/arXiv.1901.02942>.
- [13] M. Agrawal, M. A. Anwar, and D. Sethia, Stacked Sparse Autoencoder and Machine Learning Based Anxiety Classification Using EEG Signals. *The First International Conference on AI-ML-Systems*. Ekim 2021, pp. 1-7 <https://doi.org/10.1145/3486001.3486227>.
- [14] D. Maheshwari, S. K. Ghosh, R. Tripathy, M. Sharma, U. R. J. C. i. B. Acharya, and Medicine, Automated accurate emotion recognition system using rhythm-specific deep convolutional neural network technique with multi-channel EEG signals, *Computers in Biology and Medicine*, 134, 104428, 2021. <https://doi.org/10.1016/j.combiomed.2021.104428>.
- [15] C. Brunner, A. Delorme, and S. J. B. E. B. T. Makeig, Eeglab—an open source matlab toolbox for electrophysiological research. 58, SI-1-Track-G, 000010151520134182, 2013. <https://doi.org/10.1515/bmt-2013-4182>.
- [16] A. Delorme, and S. J. J. o. n. m. Makeig, EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. 134, 1, 9-21, 2004. <https://doi.org/10.1016/j.jneumeth.2003.10.009>.
- [17] Ö. J. D. Ü. M. F. M. D. AYDEMİR, Ardışıl ileri yönlü öznitelik seçim algoritmasında etkin özniteliklerin belirlenmesi. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 8, 3, 495-501, 2017.
- [18] M. L. A. Al-Zubaidi, and S. Aras, Investigation of Appropriate Classification Method for EOG Based

- Human Computer Interface. 2022 30th Signal Processing and Communications Applications Conference (SIU), Safranbolu, Turkey, 15-18 Mayıs 2022. <https://doi.org/10.1109/SIU55565.2022.9864953>
- [19] S.-W. Jang, and S.-H. J. S. Lee, Detection of epileptic seizures using wavelet transform, peak extraction and PSR from EEG signals, 12, 8, 1239, 2020. <https://doi.org/10.3390/sym12081239>.
- [20] M. C. Guerrero, J. S. Parada, and H. E. Espitia, EEG signal analysis using classification techniques: Logistic regression, artificial neural networks, support vector machines, and convolutional neural networks. *Heliyon*, 7, 6, e07258, 2021/06/01/, 2021. <https://doi.org/10.1016/j.heliyon.2021.e07258>.
- [21] N. K. Al-Qazzaz, M. K. Sabir, S. H. M. Ali, S. A. Ahmad, K. Grammer, and Ieee, The Role of Spectral Power Ratio in Characterizing Emotional EEG for Gender Identification. *IEEE EMBS Conference on Biomedical Engineering and Sciences*. 334-338, 01-03 Mar, 2021.
- [22] S. Aydin, S. Demirtaş, K. Ateş, and M. A. J. I. j. o. n. s. Tunga, Emotion recognition with eigen features of frequency band activities embedded in induced brain oscillations mediated by affective pictures. 26, 03, 1650013, 2016. <https://doi.org/10.1142/S0129065716500131>.
- [23] C. M. Raj, and A. Harsha, Study on wavelet spectral band based EEG compression. 2016 International Conference on Data Science and Engineering (ICDSE), Cochin, India, 23-25 Ağustos 2016. <https://doi.org/10.1109/ICDSE.2016.7823955>.
- [24] G. Ekim, N. Ikizler, and A. Atasoy, The effects of different wavelet degrees on epileptic seizure detection from EEG signals. *IEEE International Conference on INnovations in Intelligent SysTems and Applications (INISTA)*, Gdynia, Poland, 03-05 Temmuz 2017. <https://doi.org/10.1109/INISTA.2017.8001178>.
- [25] R. Sharma, EEG signal denoising based on wavelet transform. 758-761, 2017. <https://doi.org/10.1109/ICECA.2017.8203645>.
- [26] D. Chen, S. Wan, J. Xiang, and F. S. J. P. o. Bao, A high-performance seizure detection algorithm based on Discrete Wavelet Transform (DWT) and EEG. 12, 3, e0173138, 2017. <https://doi.org/10.1371/journal.pone.0173138>.
- [27] Z.-H. Zhou, *Machine learning*: Springer Nature, 2021.
- [28] B. Charbuty, A. J. J. o. A. S. Abdulazeez, and T. Trends, Classification based on decision tree algorithm for machine learning. 2, 01, 20-28, 2021. <https://doi.org/10.38094/jastt20165>.
- [29] Y. Ma, X. Ding, Q. She, Z. Luo, T. Potter, Y. J. C. Zhang, and m. m. i. medicine, Classification of motor imagery EEG signals with support vector machines and particle swarm optimization. 2016. <https://doi.org/10.1155/2016/4941235>.
- [30] T. Nazir, X. Qi, and S. Silvestrov, Linear Classification of Data with Support Vector Machines and Generalized Support Vector Machines. *Engineering Mathematics II*, 355-375, 2016. <https://doi.org/10.1063/1.4972718>.
- [31] L. J. I. J. o. B. Zhou, Recognition of depression patients with electroencephalogram. *International Journal of Biometrics*, 14, 3-4, 481-491, 2022. <https://doi.org/10.1504/IJBM.2022.124684>.
- [32] K. Li, X. Zhang, and Y. Du, A SVM based classification of EEG for predicting the movement intent of human body. 10th International Conference on Ubiquitous Robots and Ambient Intelligence (URAI), Jeju, Korea (South), 30 October 2013 - 02 November 2013.
- [33] W. Zhao, J. Qu, Y. Chai, and J. Tang, Classification of Seizure in EEG Signals Based on KPCA and SVM. 201-207. [https://doi.org/10.1007/978-3-662-48365-7\\_21](https://doi.org/10.1007/978-3-662-48365-7_21).

