



**T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
AKILLI SİSTEMLER MÜHENDİSLİĞİ ANA BİLİM DALI**

**ELEKTROENSEFALOGRAFİ İŞARETLERİNİN MAKİNE
ÖĞRENME TABANLI SINIFLANDIRILMASINDA EN İYİ
ÖZNİTELİK SEÇİMİNİN ARAŞTIRILMASI**

Yüksek Lisans Tezi

Shams Qahtan Omar OMAR

Danışman
Doç. Dr. Cengiz TEPE

SAMSUN
2023

**T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
AKILLI SİSTEMLER MÜHENDİSLİĞİ ANA BİLİM DALI**



**ELEKTROENSEFALOGRAFİ İŞARETLERİNİN MAKİNE
ÖĞRENME TABANLI SINIFLANDIRILMASINDA EN İYİ
ÖZNİTELİK SEÇİMİNİN ARAŞTIRILMASI**

Yüksek Lisans Tezi

Shams Qahtan Omar OMAR

Danışman

Doç. Dr. Cengiz TEPE

SAMSUN
2023

TEZ KABUL VE ONAYI

Shams Qahtan Omar OMAR tarafından, Doç. Dr. Cengiz TEPE danışmanlığında hazırlanan “ELEKTROENSEFALOGRAFİ İŞARETLERİNİN MAKİNE ÖĞRENME TABANLI SINIFLANDIRILMASINDA EN İYİ ÖZNİTELİK SEÇİMİNİN ARAŞTIRILMASI” başlıklı bu çalışma, jürimiz tarafından 8.8.2023 tarihinde yapılan sınav sonucunda oy birliği ile başarılı bulunarak Yüksek Lisans Tezi olarak kabul edilmiştir.

	Unvanı Adı Soyadı Üniversitesi Ana Bilim/Ana Sanat Dalı	Sonuç
Başkan	Doç. Dr. Mehmet Serhat ODABAŞ Ondokuz Mayıs Üniversitesi Akıllı Sistemler Mühendisliği Ana Bilim Dalı	☒ Kabul ☐ Ret
Üye (Danışman)	Doç. Dr. Cengiz TEPE Ondokuz Mayıs Üniversitesi Elektrik-Elektronik Mühendisliği Ana Bilim Dalı	☒ Kabul ☐ Ret
Üye	Dr. Öğr. Üyesi Nurettin ŞENYER Samsun Üniversitesi Yazılım Mühendisliği Ana Bilim Dalı	☒ Kabul ☐ Ret

Bu tez, Enstitü Yönetim Kurulunca belirlenen ve yukarıda adları yazılı jüri üyeleri tarafından uygun görülmüştür.

Prof. Dr. Ahmet TABAK
Enstitü Müdürü

BİLİMSEL ETİĞE UYGUNLUK BEYANI

Hazırladığım Yüksek Lisans tezinin bütün aşamalarında bilimsel etiğe ve akademik kurallara riayet ettiğimi, çalışmada doğrudan veya dolaylı olarak kullandığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin Kaynaklar'da gösterilenlerden oluştuğunu, her unsurun enstitü yazım kılavuzuna uygun yazıldığını ve TÜBİTAK Araştırma ve Yayın Etiği Kurulu Yönetmeliği'nin 3. bölüm 9. maddesinde belirtilen durumlara aykırı davranılmadığını taahhüt ve beyan ederim.

Etik Kurul Gerekli mi?

Evet ☐ (Gerekli ise ekler kısmına ekleyiniz)

Hayır ☒

08 /08/ 2023

Shams Qahtan Omar OMAR

TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI

Tez Başlığı: TEZ ADI (TÜMÜ BÜYÜK HARF VE KOYU DEĞİL)

Yukarıda başlığı belirtilen tez çalışması için şahsım tarafından 20/06/2023 tarihinde intihal tespit programından alınmış olan özgünlük raporu sonucunda;

Benzerlik oranı : % 6

Tek kaynak oranı : % 4 çıkmıştır.

08 /08/ 2023

Doç.Dr.Cengiz TEPE

ÖZET

ELEKTROENSEFALOGRAFİ İŞARETLERİNİN MAKİNE ÖĞRENME TABANLI SINIFLANDIRILMASINDA EN İYİ ÖZNİTELİK SEÇİMİNİN ARAŞTIRILMASI

Shams Qahtan Omar OMAR
Ondokuz Mayıs Üniversitesi
Lisansüstü Eğitim Enstitüsü
Akıllı Sistemler Mühendisliği Ana Bilim Dalı
Yüksek Lisans, Ağustos/2023
Danışman: Doç. Dr. Cengiz TEPE

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 öznitelik sayısı kullanarak sınıflandırmayı amaçlamıştır. 23 kişinin 14 kanallı EEG sinyalini içeren DASPS veri tabanı kullanılmıştır. EEGLAB kullanarak 14 kanaldan 4 kanal seçilmiştir. Öznitelik çıkarımı için dalgacık dönüşümü, fourier dönüşümü ve istatistiksel yöntemler kullanılmıştır. MATLAB sınıflandırma öğrencisi araç kutusundaki 4 farklı yöntem ile sınıflandırma yapılmıştır. En yüksek doğrulukta oranları, ikili sınıflandırmada %68,3 doğrulukta destek vektör makinesi, dördü sınıflandırmada %61 doğrulukta destek vektör makinesi ile elde edilmiştir.

Anahtar Sözcükler: EEG, Anksiyete, Kanal seçimi, Destek vektör makinesi, K-en yakın komşu.

ABSTRACT

INVESTIGATION OF THE BEST FEATURE SELECTION IN THE MACHINE LEARNING BASED CLASSIFICATION OF ELECTROENCEPHALOGRAPHY SIGNS

Shams Qahtan Omar OMAR
Ondokuz Mayıs University
Institute of Graduate Studies
Department of Intelligent Systems Engineering
Master, August/2023
Supervisor: Assoc. Prof. Dr. Cengiz TEPE

Anxiety affects productivity, quality of life, 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 to perform the complex anxiety detection task. This study aimed to classify binary and four-class categories by analyzing electroencephalography (EEG) signals with fewer EEG channels and features. The DASPS database was used, containing EEG signals from 23 individuals with 14 channels. Using EEGLAB, 4 channels were selected from 14 channels. The wavelet transform, Fourier transform, and statistics were used for feature extraction. The classification was performed using four methods from the MATLAB Classification Learner Toolbox. The highest accuracy rates were achieved with support vector machines for binary classification with 68.3% accuracy and with support vector machines for four-class classification with 61% accuracy.

Keywords: EEG, Anxiety, Channel selection, K-nearest neighbors, Support vector machine

ÖN SÖZ VE TEŞEKKÜR

Bu tez çalışmasının ortaya çıkmasında, değerli danışmanım Doç. Dr. Cengiz TEPE 'ye, değerli görüşleri ve önerileriyle beni desteklemesi ve zamanını ayırması için içten teşekkürlerimi sunarım. Ayrıca, tez süresince evde yaptığım çalışmalarda her türlü desteği sağlayan aileme ve araştırmam sırasında yardımlarını esirgemeyen herkese sonsuz teşekkürlerimi iletme istiyorum.

Shams Qahtan Omar OMAR

İÇİNDEKİLER

TEZ KABUL VE ONAYI	i
BİLİMSEL ETİĞE UYGUNLUK BEYANI	ii
TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI	ii
ÖZET	iii
ABSTRACT	iv
ÖNSÖZ VE TEŞEKKÜR	v
İÇİNDEKİLER	vi
SİMGELER VE KISALTMALAR	vii
ŞEKİLLER DİZİNİ	viii
TABLolar DİZİNİ	ix
1. GİRİŞ	1
1.1. Anksiyete	2
1.2. Elektroensefalografi	3
2. LİTERATÜR TARAMASI	8
3. MATERYAL VE METOT	17
3.1. DASPS Veri Seti	17
3.2. Kanal Seçimi	18
3.2.1. EEGLAB	18
3.3. Öznitelik Çıkarma	21
3.3.1. Dalgacık Dönüşümü	21
3.3.2. Fourier Dönüşümü	23
3.3.3. İstatistiksel Öznitelik (İÖ)	24
3.4. Ardışıl İleri Yönlü Öznitelik Seçimi (AİYOS)	25
3.5. Makine Öğreniminde Sınıflandırma Algoritmaları	25
3.5.1. Karar Ağaçları	27
3.5.2. Destek Vektör Makinesi	28
3.5.3. K-En Yakın Komşu Sınıflandırması	29
3.5.4. Sinir Ağları Sınıflandırması	30
3.1. Öznitelik İndirgeme	31
3.1.1. Komşu Bileşen Analizi	31
3.1.2. Temel Bileşen Analizi	31
4. BULGULAR VE TARTIŞMA	32
5. SONUÇLAR	48
KAYNAKLAR	49
ÖZ GEÇMİŞ	56

SİMGELER VE KISALTMALAR

AB-E	: Anksiyete Bozukluğu İle Epilepsinin
AB-O-E	: Anksiyete Bozukluğu Olmayan Epilepsi
ADD	: Ayrık Dalgacık Dönüşümü
AİYÖS	: Ardışıl İleri Yönlü Öznitelik Seçme
BBA	: Beyin-Bilgisayar Arayüzünü
Coif	: Coiflet
db	: Daubechies
DVM	: Destek Vektör Makineleri
db	: Dalgacık dönüşümü
EEG	: Elektroensefalografi
ESA	: Evrişimli Sinir Ağlarını
GSY	: Güç Spektral Yoğunluğunu
HFD	: Hızlı Fourier Dönüşümü
f1	: Özniteliklerin Tepe-Büyüklik- Kök Kare Ortalama Oranı
f2	: Özniteliklerin Yaklaşık Entropisi
f3	: Özniteliklerin Lyapunov Üssüsü
f4	: Özniteliklerin Toplam Harmonik Bozulması
f5	: Özniteliklerin Ortanca Değeri
f6	: Özniteliklerin Aritmetik Ortalaması
f7	: Özniteliklerin Kök Kare Ortalaması
f8	: Özniteliklerin Bant Gücü
f9	: Özniteliklerin Varyansı
f10	: Özniteliklerin Ortalama Veya Medyan Mutlak Sapması
f11	: Özniteliklerin Sinyalin Spektral Entropisi
f12	: Özniteliklerin Medyan Frekansı
f13	: Özniteliklerin Basıklığı
f14	: Özniteliklerin Çarpıklığı
f15	: Özniteliklerin Entegre Elektroensefalografini (IEEG)
f16	: Özniteliklerin Basit Kare İntegralı (SSI)
f17	: Özniteliklerin Minimum Değeri

f18	: Özniteliklerin Maksimum Deęeri
f19	: Özniteliklerin Standart Sapması
f20	: Özniteliklerin Mobilitesi
f21	: Özniteliklerin Karmaşıklığı
FPG	: Fotopletismogramdan
KA	: Karar Ağaçları
K-EK	: K-en Yakın Komşu
LR	: Lojistik Regresyon
MÖ	: Makine Öğrenimi
OSB	: Otizm spektrum bozukluğu
TSK	: Takagi-Sugeno-Kang
SAM	: Kendini Deęerlendirme Mankeni
SDD	: Sürekli Dalgacık Dönüşümü
SÖAK	: Sınıflandırma Öğrenicisi Araç Kutusundaki
Sym	: Symlet
TBA	: Temel Bileşen Analizi
UKSH TSA	: Uzun Kısa Süreli Hafıza Tekrarlayan Sinir Ağları
YSA	: Yapay Sinir Ağı

ŞEKİLLER DİZİNİ

Şekil 1.1. Uluslararası 10/20 EEG kanal yerleşim sistemi.....	4
Şekil 1.2. Ham EEG sinyalinin dalga formunda gösterimi.....	4
Şekil 1.3. EEG sinyalinin içerdği frekans bantlarının dalga formunda gösterimi	7
Şekil 3.1. Anksiyete sınıflandırma blok şeması.....	17
Şekil 3.2. (a) İki düzey (b) Dört düzey için SAM puanına dayalı etiketleme kullanan örneklerin yüzdesi	18
Şekil 3.3. Örnek EEGLAB oturumu.	19
Şekil 3.4. EEGLAB kaydırmalı kanal etkinliklerin çizimi.	20
Şekil 3.5. Üç farklı birey için güç tayf yoğunluğu.....	20
Şekil 3.6. Dalgacık dönüşümü 5. Seviyeden bileşenlere ayrıştırılması (Chen vd, 2017)	22
Şekil 3.7. ADD dönüşümünden beşinci seviye ayrıştırma katsayıları.	23
Şekil 3.8. EEG sinyali tek taraflı genlik spektrum çizimi.....	24
Şekil 3.9. SÖAK aracının arayüz görüntüsü	27
Şekil 3.10. KA algoritması kavramı (Charbuty vd, 2021)	28
Şekil 3.11. DVM algoritması kavramı (URL 1)	29
Şekil 3.12. K-EK algoritması kavramı (URL 2)	30
Şekil 3.13. YSA algoritması kavramı (Mohan vd, 2016)	30
Şekil 4.1. ikili ve dörtlü seviyeli kaygı sınıflandırması karmaşıklık matrisi.....	47

TABLÖLAR DİZİNİ

Tablo 1.1. EEG sinyalinin içerdığı frekans bantları.....	7
Tablo 2.1. Literatürdeki Benzer Çalışmaların özeti.....	15
Tablo 3.1. Kanallar arasında en çok anlamlı olan kanalın belirlemeesi.....	20
Tablo 3.2. İstatistiksel öznelilikler.....	25
Tablo 4.1. AİYÖS yöntemi kullanılarak HFD ile gerçekleştirilen ikili sınıflandırma eğitim kümesi sonuçları.....	33
Tablo 4.2. AİYÖS yöntemi kullanılarak ADD ve db8 ile gerçekleştirilen ikili sınıflandırma eğitim kümesi sonuçları	34
Tablo 4.3. AİYÖS yöntemi kullanılarak ADD ve Coif4 ile gerçekleştirilen ikili sınıflandırma eğitim kümesi sonuçları	35
Tablo 4.4. AİYÖS yöntemi kullanılarak ADD ve Sym2 ile gerçekleştirilen ikili sınıflandırma eğitim kümesi sonuçları	36
Tablo 4.5. İstatistik parametreleri kullanılarak AİYÖS yöntemiyle gerçekleştirilen ikili sınıflandırma eğitim kümesi sonuçları.	37
Tablo 4.6. AİYÖS yöntemi kullanılarak HFD ile gerçekleştirilen dörtlü sınıflandırma eğitim kümesi sonuçları.....	39
Tablo 4.7. AİYÖS yöntemi kullanılarak ADD ve db8 ile gerçekleştirilen dörtlü sınıflandırma eğitim kümesi sonuçları	40
Tablo 4.8. AİYÖS yöntemi kullanılarak ADD ve Coif4 ile gerçekleştirilen dörtlü sınıflandırma eğitim kümesi sonuçları	41
Tablo 4.9. AİYÖS yöntemi kullanılarak ADD ve Sym2 ile gerçekleştirilen dörtlü sınıflandırma eğitim kümesi sonuçları	42
Tablo 4.10. İstatistik parametreleri kullanılarak AİYÖS yöntemiyle gerçekleştirilen dörtlü sınıflandırma eğitim kümesi sonuçları	44
Tablo 4.11. İkili sınıflandırma yöntemlerinin kendi içerisinde karşılaştırılması (test kümesi sonuçları).....	45
Tablo 4.12. Dörtlü sınıflandırma yöntemlerinin kendi içerisinde karşılaştırılması (test kümesi sonuçları).....	45
Tablo 4.13. Bu tez çalışmasının literatürdeki diğer çalışmalarla karşılaştırılması (test kümesi sonuçları).....	46
Tablo 4.14. İkili sınıf için test kümesi değerlendirme ölçütleri	47
Tablo 4.15. Dörtlü sınıf için test kümesi değerlendirme ölçütleri	47

1. GİRİŞ

Yapılan literatür taraması sonucunda, Makine Öğrenimi (MÖ) kullanılarak Elektroensefalografinin (EEG) incelenmesinin, insan hayatının birçok alanında yardımcı olduğu görülmektedir. Bu alanlar aşağıdaki gibi sıralabilir:

- Epilepsi (Pascual vd, 2021; Yoo vd, 2013),
- Duygu durumu(Khare ve Bajaj, 2021; Zheng vd, 2019),
- Beyin-bilgisayar arayüzleri (Abibullaev ve Zollanvari, 2021; Cecotti ve Graser, 2011),
- Uyku evreleri(Banluesombatkul vd, 2021; Supratak vd, 2017),
- Devinimsel görselleştirme(Lu vd, 2017; Sun vd, 2021),
- Zihinsel iş yükü(Kakkos vd, 2021; Zhang vd, 2019),
- Alzheimer (Durongbhan vd, 2019; Klepl vd, 2021),
- Sürücü dikkati (Lin vd, 2014; Zhang ve Etemad, 2021),
- Şizofreni (Chang vd, 2021; Santos-Mayo vd, 2017),
- Robotik (Jeong vd, 2020; Kim vd, 2018),
- Dikkat (Delvigne vd, 2021; Zhang vd, 2020a) ,
- Alkol(Anuragi vd, 2020; Farsi vd, 2021),
- Göz kırpmak(Cao vd, 2021; Sreeja vd, 2018),
- Algı (Jeong, 2020; Scholler vd, 2012) ,
- Niyet (Avilov vd, 2021; Novak vd, 2013),
- Nesnelerin interneti(Akmandor vd, 2018; Tazrin vd, 2021),
- Kişi kimliği (Jin vd, 2021; Wilaiprasitporn vd, 2020),
- Beyin hastalığı (Jacob vd, 2019; Vivaldi vd, 2021).

Bu tez çalışmasında ise duygusal durumlar arasında yer alan anksiyete durumu üzerine bir çalışma yapılmıştır.

1.1. Anksiyete

Anksiyete durumu, klinik toplum psikoloğu Charles D. Spielberger tarafından öznel gerilim ve korku duyguları olarak tanımlanan duygusal durumlardan biridir. Anksiyete bozukluğu ise beyindeki kimyasalların dengesini değiştirebilen aşırı korku veya endişe içeren psikiyatrik bozukluklardan biridir (Chen vd, 2021).

Webster'ın sözlüğü kaygıyı "Gelecekteki belirsizliklerle ilgili bir tedirginlik ve endişe hali" olarak tanımlar. Anksiyete, doğru zamanda fark edilmezse, bu anksiyete bozukluklarından birine sebep olabilir. Bu bozukluklar: yaygın anksiyete bozukluğu, panik bozukluğu, obsesif kompulsif bozukluk, sosyal fobi ve travma sonrası stres bozukluğu (Juliana ve Rangaswamy, 2018).

Anksiyete, sıklıkla acil bir tehlike olmasa bile, endişe ve korku içeren olumsuz bir zihin durumudur ve sık sık meydana geldiğinde ve gerçek tehdit seviyesiyle orantısız görünen yoğunluk seviyelerinde geniş bir sorun yelpazesine dönüşebilir. Son araştırmalara göre stres etkeninin özellikleri çeşitli biyolojik ve psikolojik kırılganlıklarda dahil olmak üzere, kişinin sağlığı üzerindeki stres/kaygı ile ilgili etkinin derecesini ve türünü belirleyen değişkenlere ışık tutmaya başlamaktadır. Stres ve özellikle kaygı, nesnel yollarla kapsamlı bir şekilde ölçülmesi zor olan öznel, çok yönlü fenomenler olmasına rağmen kişinin sağlığı üzerindeki etkileri çeşitli şekillerde ölçülebilmektedir. Bununla birlikte, bir kişinin normal şekilde çalışma ve yaşam olaylarına uyum sağlama yeteneği ve genel refahı üzerinde etkileri olduğuna dair kanıtlarda bulunmaktadır (Giannakakis vd, 2017).

Kardiyolojide kaygı, morbidite ve mortalitedeki kötü sonuçlara bilinen bir katkıda bulunmaktadır (Tripp vd, 2019). Anksiyete, otizm spektrum bozukluğu (OSB) olan gençlerde yaygındır ve günlük fırsatları ciddi şekilde sınırlayan ve yaşam kalitesini düşüren benzersiz yaşam boyu zorluklara neden olmaktadır (Penchina vd, 2020b).

Anksiyete Bozukluğu ile Epilepsinin (AB-E) prezentasyonu karmaşık bir komorbiditedir ve sistematik psikiyatrik tarama hastalar üzerinde ağır bir ekonomik yük oluşturmaktadır. Tipik olarak, AB-E hastaları ile Anksiyete Bozukluğu Olmayan Epilepsi (AB-O-E) arasında ayırım yapmak, yüksek maliyetler nedeniyle inanılmaz derecede zor olan birden fazla değerlendirme gerektirir. Bu nedenle, iki tip hasta arasında önceden ayırım yapmak için güvenilir bir değerlendirme protokolüne acilen


ihtiyaç vardır (Zhang vd, 2022).

Şu anda, klinik uygulamada depresyon ve anksiyeteyi teşhis etmek için profesyonel ölçekleri yalnızca profesyonel doktorlar kullanabilmektedir. Son yıllarda, EEG kullanarak anksiyete veya depresyon varlığını tespit etmede ki problemler, yardımcı tanıyı uygulamanın bir yolu olarak dikkat çekmiştir ve bazı araştırmacılar anksiyete ve depresyon hastaları ile normal insanlar arasında, prefrontal yan allaşma derecesinde ve beyin ağlarının fonksiyonel bağlantısında farklılıklar olduğunu keşfetmişlerdir (Xie vd, 2020).

Yukarıda bahsedildiği gibi kısaca kaygı; yakın ya da uzak gelecekte olabilecek veya olması beklenen herhangi bir olayla ilgili bir korku veya endişe biçimi olarak tanımlanabilir. Aynı zamanda, geçmişte yaşanmış ve bir bireyin kaygılanmasına neden olan bir etkiye sahip olabilecek herhangi bir olayın bir yansıması olarak da olabilir. Anksiyete uygun şekilde tedavi edilmezse anksiyete bozukluğuna yol açarak ruh sağlığını etkileyebilir ve sağlıkta ciddi komplikasyonlara neden olabilir. Dolayısıyla bu çalışma, herhangi bir tıp pratisyenine veya sıradan kişiye kaygıyı erken bir aşamada tespit etmek, tehlikelerinden kaçınmak ve önlemek sürecinde büyük yardımcı olacaktır (Juliana ve Rangaswamy, 2018).


1.2. Elektroensefalografi

EEG, beynin nöronları içindeki iyonik akımın elektriksel voltaj dalgalanmalarını ölçmektedir (Mirzaei vd, 2021). EEG, nöral bilgi işlemenin uzaysal ve zamansal dinamiklerini anlamak için potansiyel olarak yararlı sinyaller sağladığından, insan beyninin incelenmesi için önemli bir araçtır (de Magalhaes Júnior vd, 2021). Bu teknik, tarih boyunca nöbet, Alzheimer hastalığı ve epilepsi gibi hastalıkları olan hastaları değerlendirmek için kullanılmıştır (Guerrero vd, 2021; MalathiRavindran ve Ieee, 2014). EEG, kafa derisine yerleştirilen elektrotlar aracılığıyla beyin aktivitesini ölçebilir. 10-20 elektrot sistemine göre elektrotların yerleşim Şekil 1.1’de gösterilmiştir.



Şekil 1.1. Uluslararası 10/20 EEG kanal yerleşim sistemi.

EEG invaziv değildir, uygun maliyetlidir ve doğal ortamlarda dinlenme halindeki beyin aktivitesini ölçmek için uygundur ve büyük miktarda verinin kolayca elde edilmesini sağlar (Park vd, 2021). EEG işaretleri durağan ve periyodik değildir. Genlik, faz ve frekansları değişkendir. Bu nedenle yorumlanması oldukça zor bir morfolojiye sahiptir. Dolayısıyla anlamlı bir veri elde edebilmek için uzun süre ölçüm yapılması gerekir. Son zamanlarda, EEG kullanılarak duygusal tanıma üzerine çeşitli incelemeler araştırılmıştır (Al-Qazzaz vd, 2021). Şekil 1.2’de ham EEG sinyalinin dalga formunda göstermektedir.



Şekil 1.2. Ham EEG sinyalinin dalga formunda gösterimi

Günümüzde, EEG sinyalleri, Beyin-Bilgisayar Arayüzünü (BBA) iyileştirmek için makine öğrenme algoritmalarıyla birleştirilmektedir. BBA, protez uzuvlar, robotik, ev otomasyon sistemleri, cep telefonu uygulamaları, tekerlekli sandalye hareketleri ve ses tanıma sistemleri dahil olmak üzere çeşitli cihazları çalıştırmak için kullanılmaktadır(Akmal vd, 2021).

Sürekli EEG sinyallerinin veya beyin dalgalarının analizi, tüm elektrotlardan alınan verilerin sayısının çokluğundan dolayı karmaşıktır. Kişinin bilinç durumu bazı frekans bantlarını diğerlerinden daha belirgin hale getirebilir. EEG sinyali şekline göre değil içerdiği frekans bantlarına göre değerlendirilir. EEG frekans bantlarının tanımı çalışmalar arasında biraz farklılık gösterir. Farklı frekans değerlerine göre değişen 5 tane önemli beyin dalgası vardır.

Delta(δ) dalgaları:

Delta beyin dalgaları yavaş, gürültülü beyin dalgalarıdır (düşük frekans, bir davul ritmi gibi derinlemesine nüfuz eder). En çok beynin sağ bölgesinde belirgindir ve frekansı 4 Hz 'in altındaki beyin dalgalarıdır. Genlikleri 20-400 μ V arasında değişir. Bu dalgalar çoğunlukla düşük beyin aktivitesi ile ilişkilidir ve derin uyku durumlarında, meditasyon, ciddi beyin hasarında ve bazen de uyanıklık veya genel anestezi gibi beynin çok düşük aktivite gösterdiği durumlarda ortaya çıkarlar. Bu aralıktaki çoklu frekanslara, iyileşmede yararlı olan insan büyüme hormonunun salınması eşlik eder. Bu nedenle derin onarıcı uyku insan sağlığına için çok önemlidir (Dzedzickis vd, 2020).

Teta(θ) dalgaları:

Yetişkinler çoğunlukla hafif uyku ve rüya görme sırasında teta dalgaları üretir. Bu dalgalar genellikle gözler kapalıyken ortaya çıkar ve gözler açıldığında kaybolur. Ancak derin meditasyon sırasında da ortaya çıkabilir. Teta dalgaları öğrenme ve hafızaya açılan bir kapı görevi görür. Duyularımız dış dünyadan uzaklaşır ve içimizden gelen sinyallere odaklanır. Teta dalgası 4-8 Hz' lik bir frekans bandı vardır. Genliği 5 ile 100 μ V arasında değişir. Çocuklarda özellikle başın parietal ve temporal bölgelerinde bulunur. Normal bireylerde; rüyalı uyku, orta derinlikte anestezi, uykunun başlangıç evrelerinde, yaratıcı ilham ve derin düşünme, duygusal gerginlik,

anıların hatırlanmasıyla ve düş kırıklığı gibi beynin düşük aktivite gösterdiği durumlarda ortaya çıkar. Korkularımızı, sıkıntılarımızı ve kabuslarımızı tuttuğumuz yer burasıdır (Dzedzickis vd, 2020).

Alfa(α) dalgaları:

Oksipital bölgeden elde edilir ve genellikle beynin arka tarafında bulunur. Frekans band aralığı 8-16 Hz ve genliği 2-10 μ V arasında değişir. Genellikle sinüzoidaldir. Nadiren keskin açılar görülebilir. Normal, sakin kişilerde uyanıkken, konsantre olmadıklarında veya dikkatlerini herhangi bir şeye vermediklerinde, dış uyaranlar olmadığında ve gözleri kapalı olduğunda, yani rahat bir bilinç durumunda görülür. Alfa, zihinsel olarak rahatlamışken, gözler kapalıyken, yürürken, kitap okurken veya yoga yaparken ortaya çıkar (Dzedzickis vd, 2020).

Beta(β) dalgaları:


Uyanıkken, düşünce davranışı, konsantrasyon ve anksiyete sırasında ortaya çıkar. Frekans band aralığı 16-32 Hz genliği 1- 5 μ V arasında değişir. Ritmik beta durumları esas olarak beynin frontal ve merkezi bölgelerinde elde edilir. Beta dalgaları, beyin aktif olarak düşünürken, dikkatini bir şeye verirken, dış dünyaya konsantre olurken veya zor bir problemi çözerken ortaya çıkar ve normal yetişkinlerde bulunur. Panik halindeki kişilerde çok yüksek beta seviyeleri gözlenir (Dzedzickis vd, 2020).

Gama(γ) dalgaları:

Gama beyin dalgaları en hızlı dalgalardır ve beynin farklı bölgelerindeki süreçlerde anlık değişikliklerle ilişkilidir. Genlikleri, 2 μ V' dan daha küçüktür ve frekansı 302 Hz' den büyüktür. Beyin dalgalarının en ince frekansıdır ve bilginin hızlı bir şekilde iletilmesini sağlar. Gama dalgaları, araştırmacılar evrensel sevgi, fedakârlık ve yüksek erdemler durumlarında oldukça işlevsel oldukları keşfedilene kadar 'yedek beyin gürültüsü' olarak kabul ediliyordu. Gama ritmini algıyı ve bilinci düzenlediği düşünülmektedir ve en hızlı beyin dalgaları beynin karar verme sürecinde yer almaktadır (Dzedzickis vd, 2020). Tablo 1.1, EEG sinyalinin içerdiği frekans bantlarının özelliklerini özetlemektedir. Şekil 1.3'de bir kanaldan gelen EEG sinyali ve buna ait alt frekans bantlarının dalgaları gösterilmektedir.

Tablo 1.1. EEG sinyalinin içerdği frekans bantları

Beyin dalgası	Spektrum (Hz)	Genlik (μV)
Delta (δ)	0.5- 4	20-400
Teta (θ)	4- 8	5-100
Alfa (α)	8-16	2-10
Beta β)	16- 32	1- 5
Gama (γ)	32 ve üzeri	2



Şekil 1.3. EEG sinyalinin içerdği frekans bantlarının dalga formunda gösterimi

2. LİTERATÜR TARAMASI

Bu tez çalışması hazırlanırken literatürdeki benzer çalışmalar incelenmiş ve özetlenmiştir. Çalışmaların literatüre katkıları, kullanılan veri setleri, öznelite vektörlerinin oluşturulması, kullanılan sınıflandırma algoritmaları ve elde edilen doğruluklar araştırılmıştır.

Chen vd., (2021), yaptıkları çalışmada, bireylerin zihinsel durumunu ayarlamak için üç deneysel aşama içeren kapalı bir neurofeedback deneyi tasarlamıştır. EEG dinlenme durumu sinyali otuz dört denekten kaydedilmiştir. Her deneğin EEG verilerini işledikten sonra, Destek Vektör Makinesi (DVM) sınıflandırıcıları ve Güç Spektral Yoğunluğu (GSY) modeli olarak kullanarak iki zihinsel durumu (kaygısızlık ve kaygı) sınıflandırılıp tanımlanmıştır. Gauss çekirdeği işlevi ve polinom çekirdek işlevi kullanılarak yapılan bu sınıflandırmada doğrulukları sırasıyla %92,48 ve %88,60 bulunmuştur. Sonuçlar, EEG neurofeedback tabanlı sınıflandırma yaklaşımın, anksiyete bozukluğu durumlarının saptanması ve değerlendirilmesi için etkili bir BBA sistemi geliştirmede kullanılabileceğini göstermiştir(Chen vd, 2021).

Umrani vd., (2022), yaptıkları çalışmada, optimize edilmiş bir Yapay Sinir Ağı (YSA) ile dinamik bir kaygı algılama modeli geliştirmişlerdir. Bu çalışmada, veri tabanından gelen giriş EEG sinyali, Bant Geçiren Filtre kullanılarak sinyaldeki gürültünün ve artefaktların giderilmesi için önceden işlenmiş ve ardından karmaşıklığın azaltılması için önemli özellikler çıkarılmıştır. Daha sonra ise gelişmiş algılama yeteneği elde etmek için kurtarma arama ajanlarının ve Finch'lerin özelliklerinin kombinasyonu ile tasarlanan İz ve Yem optimizasyonu algoritması kullanılarak eğitilen kaygının tespiti için YSA kullanılmıştır. Analiz, özgünlük, duyarlılık ve doğruluk gibi metrikler açısından DEAP ve SEED veri kümeleri gibi iki standart veri tabanı kullanılarak bant bazında yapılmıştır. Önerilen kaygı saptama modeli ile eğitim yüzdesine uygun olarak DEAP yardımıyla %96.67'lik bir doğruluk elde edilmiştir (Umrani vd, 2022).

Xei vd., (2020) çalışmalarında EEG verilerini kullanarak anksiyete ve depresyonun tanısında beyin ağlarının işlevsel bağlantılarını ve Evrişimli Sinir Ağlarını (ESA) birleştiren yeni bir yaklaşım önermişlerdir. Bu yaklaşımın doğruluğu, anksiyete veya depresyonu olan on hasta ve on sağlıklı kontrol grubu üzerinde test edilmiş ve sonuçların %67,67 sınıflandırma doğruluğu elde edildiği bildirilmiştir. Bu

çalışma, EEG verilerinin anksiyete ve depresyonun tanısında kullanılabileceğini ve derin öğrenme teknolojisinin uygulanmasının bu alanda daha fazla keşfedilme potansiyeline sahip olduğunu göstermektedir (Xie vd, 2020).

Arsalan vd., (2021), EEG verilerini kullanarak sürekli bir kaygı saptama çerçevesi sunmuşlardır. Önerilen çerçeve dört aşamadan oluşur: EEG veri toplama, ön işleme, özellik çıkarma ve seçme ve sınıflandırmadır. 65 katılımcının EEG verileri gözler açık durumda iki dakika süreyle kaydedilmiştir. Sürekli kaygı puanları, katılımcıların EEG verilerini iki (kaygılı ve kaygısız) ve üç (kaygısız, hafif kaygılı ve çok kaygılı) sınıf olarak etiketleyen durumluk-sürekli kaygı 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 kaygı sınıfı için güç spektral yoğunluklarına bir t-testi ve varyans analizi uygulanarak yapılmıştır. Seçilen EEG kanallarından beş zaman düzlemi özelliği çıkarılmıştır. Sürekli kaygıyı sınıflandırmak için kullanılan özelliklerin optimal bir alt kümesinin özellik seçimi için kaydırma yöntemi uygulanmıştır. Rastgele orman sınıflandırıcısı kullanılarak en yüksek sınıflandırma doğruluğu sırasıyla %87.69 ve %83.07 ile iki ve üç kaygı sınıflandırması elde edilmiştir (Arsalan vd, 2021).

Penchina vd., (2021), yaptıkları çalışmada, gerçek zamanlı değerlendirme ve kaygının, kapalı döngü uyarlaması yoluyla hafifletilmesi için EEG tabanlı bir BBA'nun fizibilite değerlendirmesi amacıyla çeşitli MÖ sınıflandırıcılarını ve derin öğrenme yöntemlerini karşılaştırmışlardır. Zihinsel aritmetik stres indüksiyonu, rehberli nefes alma ve rehbersiz nefes alma bloklarını dönüşümlü olarak uygulayan nöro tipik ve OSB katılımcılarının EEG'leri üzerinde dördü geleneksel BBA yöntemleriyle ve yedisi derin öğrenme yaklaşımlarıyla olmak üzere toplam on bir konuya bağlı modeli eğittiler. EEG'den endişeli durumları %93.27 genel doğrulukla tanımlayabilen çok sınıflı iki katmanlı Uzun Kısa Süreli Hafıza Tekrarlayan Sinir Ağları (UKSH TSA) derin öğrenme sınıflandırıcısı öneriyorlar (Penchina vd, 2020a).

Sharma vd., (2019), yaptıkları çalışmada, yoga ve Sudarshan Kriya meditasyonunun birleşik etkisini ve istatistiksel parametreler kullanılarak beyin sinyalleri üzerinde analiz yapılmıştır. Araştırmacı, üç aylık düzenli yoga ve Sudarshan Kriya uygulaması öncesi ve sonrasında, kontrol ve çalışma grubundan EEG sinyalleri

alınmıştır. Ayırık Dalgacık Dönüşümü (ADD), sinyali analiz için db4 dalgacığı kullanılarak alt bant ayrıştırmak için kullanılmıştır. Denekleri meditasyon yapanlar ve meditasyon yapmayanlar olarak sınıflandırmak için istatistiksel parametreler üzerinde YSA uygulanmıştır. Deneysel sonuçlar, önerilen yöntemin sınıflandırma için %87,2 doğruluk elde ettiğini göstermiştir (Sharma vd, 2019).

Aslam vd., (2022), yaptıkları çalışmada, büyük ölçekli özellik çıkarma ve özellik seçim algoritmalarını kullanarak optimal özellikleri seçmek için kapsamlı bir özellik setini analiz etmişlerdir. Doğrusal DVM 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 (5) ve deneklerini (99) kullanmıştır (Aslam vd, 2022).

Penchina vd., (2020), nörotipik ve otistik ergenlerde stres indüksiyonu sırasında yavaş tempolu nefes almanın algılanan kaygı düzeyleri üzerindeki etkilerini incelemiştir. Çalışmada, çok sınıflı bir Uzun Kısa Süreli Hafıza Tekrarlayan Sinir Ağı (UKSH TSA) derin öğrenme sınıflandırıcısı kullanılmıştır. Bu sınıflandırıcı, tüm sınıflarda ortalama %93,27 doğruluk sağlamış ve kaygılı ve kaygısız sınıfları %90,82 doğrulukla başarıyla ayırt etmiştir. Bu çalışma, bir UKSH TSA sınıflandırıcısını EEG verilerini kullanarak endişeli durumları ayırt etmek için etkili bir şekilde kullanan ilk çalışmadır (Penchina vd, 2020b).

Asif vd., (2019), 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 incelemiştir. 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. Sonuçlar, LR' nun iki ve üç seviyeli sınıflandırma için sırasıyla %98.76 ve %95.06'lık bildirilen en yüksek doğrulukla stresi tanımlamada iyi performans gösterdiğini belirtmişlerdir (Asif vd, 2019).

Zhang vd., (2022), AB-E hastaları (epilepsi ve depresyon/anksiyete bozukluğu) ile AB-O-E hastaları (sadece epilepsi) arasında ayırım yapmak için dinlenme durumu EEG sinyallerini toplamış ve bu sinyallerden işlevsel ağlar oluşturmuştur. İki grup arasındaki farklılıklar, bağlantı gücü ve farklı frekans bantlarının karşılık gelen ağ özneteliklerini kullanarak istatistiksel olarak karşılaştırılmıştır. Farklı ağ öznetelikleri,

temel bileşen analizi (TBA) ve uzamsal modelleri (SPN) dahil olmak üzere, fonksiyonel ağ bağlantısının SPN özniteliğinin iki hasta grubu arasında ayrım yapmak için geleneksel ağ özniteliğine göre çok daha iyi bir sınıflandırma performansı sergilediği gösterilmiştir. Bu öznitelik kullanılarak, DVM kullanılarak AB-O-E hastalarından 4416 EEG segmentinin ve AB-E hastalarından 6346 EEG segmentinin ayrıştırılmasında %89,90'lık kayda değer bir sınıflandırma doğruluğu, %87,37'lik hassasiyet ve %91,67'lik özgüllük elde edilmiştir (Zhang vd, 2022).

Zhang vd., (2020), göz hareketi bilgilerini EEG verilere entegre etmiş ve özniteliklerini ilgili özniteliklerine göre gruplara ayırmıştır. Daha sonra, gruplar arasındaki yapı bilgisini araştırmak ve anksiyete ruh halinin daha kesin tespitini sağlamak için, EEG ve göz hareketi öznitelikleri arasındaki etkili bir füzyon temsili elde etmek için grup seyrek kanonik korelasyon analizi kullanılmıştır. Çalışma, Sağlıklı Beyin Ağı veri setinden elde edilen deneysel sonuçları incelemiştir. Bu sonuçlar, grup seyrek kanonik korelasyon analizinin farklı kafa derisi bölgelerindeki EEG öznitelikleri ile çeşitli yönlerden göz hareketi öznitelikleri arasındaki korelasyonu araştırmak için etkili bir şekilde kullanılabileceğini göstermiştir. Ayrıca, sakkadlar ve fiksasyon dahil olmak üzere görsel davranışların, beynin görsel bölgesine karşılık gelen kafa derisi alanındaki EEG'nin güç spektrumu ile daha doğrusal olarak ilişkili olduğu bulunmuştur. Nihai füzyon temsili, EEG'nin gama bandında DVM sınıflandırıcısı ile yüzde 82,70'lik bir optimal sınıflandırma doğruluğu elde etmiştir (Zhang vd, 2020b).

Trambaiolli vd., (2020), çalışma, dinlenme durumundaki EEG küresel bağlantısını, depresif ve anksiyete semptomları için potansiyel bir biyobelirteç olarak değerlendirmiştir. Çalışmaya, 75 sağlıklı ve 44 majör depresif bozukluğu olan toplam 119 kişi dahil edilmiştir. Bu kişiler için altı farklı spektral bantta (teta, alfa1, alfa2, beta1, beta2 ve gama) 60 EEG kanalı kurulumunda küresel bağlantıyı (spektral tutarlılık) hesaplanmıştır. Bu küresel bağlanabilirlik puanları, Beck Depresyon Envanteri ve Spielberger Sürekli Kaygı Envanteri tarafından ölçülen semptomları tahmin etmek için bir Destek Vektör Regresörü eğitilmiştir. Sonuçlar, her iki semptom için ortalama mutlak hata değerleri sırasıyla 8.07 ± 6.98 ve 11.52 ± 8.7 olarak bulunmuştur (Trambaiolli ve Biazoli, 2020).

Shen vd., (2022), yaptıkları çalışmada, çok boyutlu EEG öznitelik çıkarma ve MÖ tekniklerini birleştirerek otomatik yaygın anksiyete bozukluğu tespiti için bir analiz çerçevesi geliştirmeyi amaçlamışlardır. Spesifik olarak, yaygın anksiyete bozukluğu sahip 45 hastadan ve 36 sağlıklı kişi kontrolden 10 dakika süreli dinlenme durumu EEG sinyalleri elde edilmiştir. Ardından, çok boyutlu EEG özniteliklerinin tek değişkenli güç spektral yoğunluğu (GSY) ve bulanık entropi ve EEG bilgilerini üç farklı boyuttan çözebilen çok değişkenli fonksiyonel bağlantı dahil analiz çerçevesi, aberasyonlu çok boyutlu ayıklamak için tanıtılmıştır. Bu saptırılmış öznitelikler daha sonra birleştirilmiş ve otomatik hasta tespiti için sınıflandırma performansını değerlendirmek üzere önceden onaylanmış üç MÖ yöntemine beslenmiştir. Hastaların, tüm frekans bantlarında frontal ve diğer beyin alanları arasındaki uzun menzilli fonksiyonel bağlantının azalmasıyla birlikte, GSY'nun beta ritminde önemli bir artış ve alfa-1 ritminde azalma sergilediğini göstermişlerdir. Ayrıca bu aberasyon öznitelikleri, 97.83 ± 0.40 doğruluk, 97.55 ± 0.31 hassasiyet, 97.78 ± 0.36 özgüllük ve 97.95 ± 0.17 F1 ile çok iyi bir sınıflandırma yapılmıştır (Shen vd, 2022).

Mokatren vd., (2019), yaptıkları çalışmada, Yapılandırmayı göz ardı eden (model 1) ve farklı enterpolasyon yöntemleriyle kullanan (model 2) iki sınıflandırma modelini incelenmişlerdir. Bu iki modelin performansı, her biri beş frekans bandından oluşan ve bir filtre bankası ile ayrıştırılan 34 EEG veri kanalının analizi karşılaştırılmıştır. Veriler, sağlıklı ve Sosyal Kaygı Bozukluğu sahp hastalardan oluşan 64 denekten toplanmıştır. Model 2'nin model 1'den önemli ölçüde daha iyi performans göstereceği hipotezinin geçerliliği, araştırdığımız her MÖ algoritması için model 2'nin %6-7 daha yüksek doğrulukla sonuçlarda doğrulanmıştır. ESA, DVM ve K-en Yakın Komşu (K-EK)'lerden çok daha iyi performans sağladığı bulunmuştur (Mokatren vd, 2019).

Li vd., (2019), çalışmada 12 sağlıklı üniversite öğrencisinin çeşitli kaygı durumları EEG kaydı ile uyarılmış ve kaygı düzeyi değişiklikleri ile EEG öznitelikleri arasındaki korelasyon analizi yapmışlardır. Bu amaçla, çeşitli bantlardaki ve beyin konumlarındaki EEG öznitelikleri çıkarılmış ve Likert ölçeği kullanılarak bireylerin kaygı düzeyleri ölçülmüştür. Bu verilere dayanarak, en ilgili EEG öznitelikleri toplanmış ve farklı sınıflandırıcılar kullanılarak kaygı durumlarının sınıflandırılması deneyimlendirilmiştir. Sonuç olarak, DVM kullanılarak kaygı durumlarının tanımlanmasının doğruluğu yüzde 62,56 olarak tespit edilmiştir. Ayrıca, lineer EEG

özniteliklerinin (öznitelikle toplam güç, ortalama kare ve varyans gibi öznitelikler) kaygı tanımadaki önemine işaret edilmiş ve beta bandındaki ve frontal lobdaki EEG özniteliklerinin diğer bantlardaki veya diğer beyin lokasyonlarındaki özniteliklerden daha fazla kaygı tanımaya katkıda bulunduğu iddia edilmiştir (Li vd, 2019).

Baghdadi ve ark. (2019), yaptıkları çalışmada, yüz yüze psikolojik uyaranlar aracılığıyla kaygı uyandırma sırasında 23 katılımcının kaydedilmiş EEG sinyallerini içeren DASPS veri tabanını kullanmışlardır. EEG sinyalleri, kablosuz giyilebilir düşük maliyetli bir ekipman olduğu için Emotiv Epoc kulaklık ile alınmıştır. Öznitelikle farklı parametrelerin etkisini araştırırlar. Bunlar: deneme süresi, öznitelik türü, öznitelik kombinasyonu ve kaygı seviyeleri sayısı. Bulgular, kaygının 1 saniyede iyi bir şekilde ortaya çıktığını gösterdi. Örneğin, farklı özniteliklere sahip yığınla seyrek oto kodlayıcı, 2 ve 4 kaygı düzeyi tespiti için sırasıyla %83,50 ve %74,60'a ulaşmaktadır (Baghdadi vd, 2019).

Agrawal ve ark., DASPS veri tabanı ile daha az sayıda öznitelikler kullanarak ve sonuçları iyileştirmek için sınıflandırıcılarla birlikte özyinelemeli öznitelik seçim yöntemi kullanmışlardır. İkili kaygı sınıflandırması için Karar Ağacı (KA) ile zaman-frekans düzleminde %66,70 ve zaman düzleminde 70,25 sınıflandırma doğruluğu elde etmişlerdir (Agrawal vd, 2021).

Maheshwari ve ark. çalışmalarında, çok kanallı EEG sinyallerini kullanarak duygu tanıma için ritme özgü çok kanallı 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 (Maheshwari vd, 2021).

Penchina ve arkadaşları çalışmalarında, OSB olan gençlerde anksiyetnin yaygın, günlük fırsatları ciddi şekilde sınırlayıcı ve yaşam kalitesini düşüren olarak belirlemişler. Otizmli nörotipik ergenlerde ve sağlıklı ergenlerde kaygı düzeyleri etkilerini araştırmışlar. EEG sinyallerin durumlarına dayanarak kaygıyı tanımlayabilen çok sınıflı, UKSH TSA derin öğrenme sınıflandırıcısını önermişlerdir. Kullanılan derin öğrenme sınıflandırıcı, kaygılı ve kaygısız sınıfları %90,82'lik bir doğrulukla ayırt edebilmiş ve tüm sınıflarda ortalama %93,27'lik bir doğruluk sağlamıştır (Penchina vd, 2020b).

Yamada ve arkadaşları çalışmalarında, EEG sinyallerinin beyinden çıkarılması için Muse Brain System'i kullanmışlar. Bu sinyalleri MBS-CMF yazılımı kullanılarak analiz edilmiş. θ -bandı, α -bandı ve β -bandındaki bir güç spektrumu, Hızlı Fourier Dönüşümü (HFD) kullanılarak hesaplanmışlardır. Deney, birey tekerlekli sandalyede otururken EEG sensörünü taktığında gerçekleştirilmiş. Yokuş aşağı inerken beyin dalgası kaydedilmiş. DVM kullanılarak kaygı sınıflandırılmış. θ dalga (4[Hz] ~ 7[Hz]) ve β -dalga (20[Hz] ~ 25[Hz]) kombinasyonun kaygı ifadesini sınıflandırmak için en yüksek ortalama doğruluk %80,29' elde edilmiş. EEG kontrollü tekerlekli sandalyenin güvenliğini artıracak oluğunu açıklamışlardır (Yamada vd, 2019).

Üniversite öğrencilerinin psikolojik gelişimlerine etkin bir şekilde önem vermek ve ruh sağlığı eğitimlerini güçlendirmek önemlidir, Meng ve arkadaşları bu konu ele almışlardır, bir Takagi-Sugeno-Kang (TSK) bulanık sistemi ve derin öznitelikleri kullanarak üniversite öğrencilerinin kaygılarını otomatik olarak belirlemek için bir yöntem önermişlerdir. İlk olarak, üniversite öğrencilerinin toplanan EEG'lerini önceden işlemişler. İkinci olarak, girdi verilerinden derin öznitelikler çıkarmak için ESA kullanmışlar. Son olarak, nihai tanıma sonucunu elde etmek için öznitelikleri sınıflandırmak için TSK bulanık sistemi kullanmışlardır (Meng ve Zhang, 2020).

Zheng ve arkadaşları çalışmalarında, giyilebilir kulaklık ve gözlüklerden toplanan EEG ve Fotopletismogramdan (FPG) elde edilen özniteliklere dayalı olarak kaygı için nesnel bir indeks geliştirmeyi amaçlamışlar. EEG ve FPG'den çeşitli öznitelikler çıkarılmış. Çalışmanın sonuçları, alfa bandı dalgacık katsayılarının ve beta bandının ortalama değerinin ve ortalama gücünün kaygı düzeyi ile yüksek oranda ilişkili olduğunu göstermiştir. Hem EEG hem de FPG özniteliklerini kullanarak, K-EK ile üç seviyeli kaygının sınıflandırma doğruluğu %62,5'e ulaşmışlardır (Zheng vd, 2016).

Yukarıdaki sunulan çalışmalar Tablo 2.1'de özet bir şekilde gösterilmiştir.

Bu çalışmada, daha az sayıda EEG kanalı ve öznitelik kullanımının anksiyete sınıflandırması başarımına etkisi araştırılmıştır. DASPS veri tabanı (Baghdadi vd, 2019) kullanılarak EEGLAB ile 14 kanal arasından AF3, P8, FC6 ve F8 olmak üzere 4 kanal seçilmiştir. Matlab'ın Sınıflandırma Öğrenicisi Araç Kutusundaki (SÖAK) Karar Ağaç (KA), K-en yakın komşu (K-EK), Destek vektör makinesi (DVM) ve Yapay Sinir Ağı (YSA) yöntemleri kullanılmıştır. Bu sekiz yöntem kullanılarak

sınıflandırmanın performansını artırmak için seçilen dört kanal EEG sinyali üzerinden Ardışıl İleri Yönlü Öznitelik Seçme (AİYÖS) metodu kullanılmıştır. Böylelikle en yüksek başarıyı veren öznitelik kümesi elde edilmeye çalışılmıştır.


Tablo 2.1. Literatürdeki Benzer Çalışmaların özeti

no	Kaynak	Veri seti	Sınıflandırma yöntemi	Kanal sayısı	Sınıf sayısı	Birey sayısı	Doğruluk %
1	(Chen vd, 2021)	Kendi	DVM	6	2	34	92,48
2	(Umrani vd, 2022)	DEAP, SEED	YSA	31	2	32	96,67
3	(Xie vd, 2020)	Kendi	ESA	31	2	20	67,67
4	(Arsalan vd, 2021)	Kendi	forest classifier RF	4	2 3	65	87,69 83,07
5	(Penchina vd, 2020a)	Kendi	UKSH TSA	16	2	13	93.27
6	(Sharma vd, 2019)	Kendi	YSA	32	2	50	87.2
7	(Aslam vd, 2022)	DEAP, SEED, DREAMER	DVM	8	2	99	95 92 90
8	(Asif vd, 2019)	Kendi	LR	4	2 3	27	98.76 95.06
9	(Zhang vd, 2022)	Kendi	DVM	21	2	26	89.90
10	(Zhang vd, 2020b)	HBN	DVM	128	2	92	82.70
11	(Trambaiolli ve Biazoli, 2020)	Depression RL	DVM	60	2	119	*
12	(Shen vd, 2022)	Kendi	DVM	16	2	81	97.55
13	(Mokatren vd, 2019)	Kendi	YSA	34	2	64	87
14	(Li vd, 2019)	Kendi	DVM	128	4	12	62.56
15	(Baghdadi vd, 2019)	DASPS	k-EK	14	2 4	23	81.40 73.60

16	(Agrawal vd, 2021)	DASPS	RF	14	2	23	70.25
17	(Maheshwari vd, 2021)	DASPS	ESA	14	2	23	57.14
18	(Penchina vd, 2020b)	Kendi	UKSH TSA		2		93.27
19	(Yamada vd, 2019)	*	DVM	5	2	14	80.29
20	(Meng ve Zhang, 2020)	DEAP ve Kendi	TSK	32	2	32	76.86
21	(Zheng vd, 2016)	Kendi	K-EK	1	3	20	62.5
22	(Rajendran vd, 2022)	Kendi	-	8		14	*

3. MATERYAL VE METOT

Bu çalışma, Şekil 3.1’de görüleceği üzere DASPS veri tabanından veri alma, kanal seçimi, öznelik çıkarma, veri etiketleme, öznelik seçimi ve anksiyete sınıflandırması olmak üzere altı bölümden oluşmaktadır.



Şekil 3.1. Anksiyete sınıflandırma blok şeması

3.1. DASPS Veri Seti


Anksiyete düzeyi tespiti için Bağdadi ve ark.(Baghdadi vd, 2019) tarafından toplanan kamuya açık DASPS Veri Kümesini kullanılmıştır. Bu çalışmada, 23 katılımcı (10 erkek, 13 kadın; ortalama yaş 30) için Emotiv EPOC adlı bir kablosuz EEG kulaklığı kullanılarak 14 kanallı EEG verileri toplanmıştır. Örnekleme hızı 128 Hz olup, katılımcıların gözleri kapalı ve hareketleri minimumda tutularak altı farklı durum gösterilmiştir. Veri tabanı, ham EEG verilerini. Edf formatında ve ön işlem görmüş verileri de mat formatında saklamaktadır.

Bu veri seti oluşturulurken, Hamilton Pre-Stimuli adı verilen bir yöntem kullanılmıştır. Bu yöntemde, ilk aşamada katılımcılar 5 dakika boyunca bir uyarım olmadan bekletilir. İkinci aşamada ise, bir psikoterapist bir senaryo okur ve katılımcılar bu senaryoyu 15 saniye boyunca hatırlamaya çalışır. Bu prosedür altı koşulun her biri için tekrarlanır. Altı koşulun sonunda, Kendi Kendini Değerlendirme Mankeni (SAM) kullanılarak katılımcıların uyarım sırasında nasıl hissettikleri değerlendirilir. SAM derecelendirmesi bir veri tabanında iki sütun olarak saklanır: Valenc ve Arousal (Baghdadi vd, 2019).

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.

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 3.2’de verilmektedir.



3.2. Kanal Seçimi

Bu çalışmada, kanal seçmek için EEGLAB aracı kullanılmıştır.

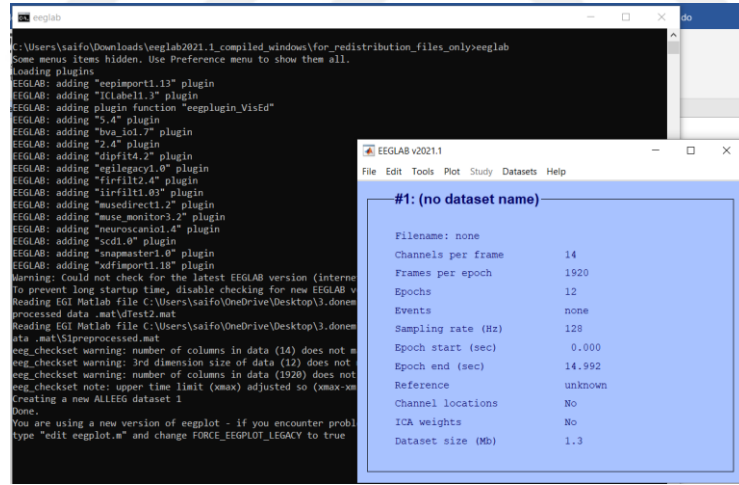
3.2.1. EEGLAB

EEGLAB, Scott Makeig tarafından 1997 yılında geliştirilen ve 2001 yılında halka açık olarak piyasaya sürülmüş bir yazılım ortamıdır. Kaliforniya San Diego Üniversitesi'nin Swartz Hesaplamalı Sinirbilim Merkezi (SCCN) tarafından geliştirilen EEGLAB, elektrofizyolojik veri analizi için en yaygın kullanılan yazılım ortamı olmuştur. EEGLAB, EEG ve diğer elektrofizyolojik araştırma çalışmalarını destekleyen bir araç kutusudur ve platformlar arası MATLAB ortamında çalışmaktadır. EEGLAB artık birçok araştırmacının katkılarıyla geniş EEG ve diğer elektrofizyolojik araştırma çalışmalarını destekleyen bir standart haline gelmiştir


(Brunner vd, 2013).

EEGLAB, EEG verilerini içe aktarma ve kanal ve olay bilgilerini içerir; veri görselleştirme (kaydırma, kafa derisi haritası ve dipol model çizimi, çoklu deneme ERP-görüntü çizimleri gibi); ön işleme (yapay reddetme, filtreleme, dönem seçimi ve ortalama alma gibi); bağımsız bileşen analizi ve veri yeniden örnekleme ile desteklenen istatistiksel yöntemler kullanılarak kanal ve bileşen çapraz tutarlılığı analizi yapılır. Ayrıca zaman/frekans ayrıştırmaları da gerçekleştirilebilir.

Bu işlevler, MATLAB sözdizimini kullanma ihtiyacını azaltmaktadır. EEGLAB, sinyal işleme ve bilgi ölçümlerinden elde edilen görsel olarak işaretlenmiş EEGLAB önerilerini kabul ederek veya reddederek, kullanıcıların nöral yapaylıkların hâkim olduğu veri kanallarını, dönemlerini veya bileşenleri kaldırmasına olanak tanıyan yöntemler içermektedir. EEG kafa derisi haritaları ve kanal konumları, yaygın olarak kullanılan birkaç kartezyen, kutupsal ve küresel koordinat sistemi arasında dönüştürülebilir ve daha sonra iki veya üç boyutlu olarak görselleştirilebilmektedir (Delorme ve Makeig, 2004) Şekil 3.3ve Şekil 3.4'te EEGLAB'ın ekran ara yüzü göstermektedir.




Şekil 3.3. Örnek EEGLAB oturumu.



Şekil 3.4. EEGLAB kaydırmalı kanal etkinliklerin çizimi.

Bu çalışma da kanal seçimi için EEGLAB kullanıldı. Önemli olmayan kanallar, güç tayf yoğunluğu grafiği kullanılarak belirlendi. Örnek olarak, Şekil 3.5’te sadece üç farklı bireyin için güç tayf yoğunluğu verilmiştir. Tablo 3.1’de gösterdiği gibi 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.



Şekil 3.5. Üç farklı birey için güç tayf yoğunluğu

Tablo 3.1. Kanallar arasında en çok anlamlı olan kanalın belirlenmesi

	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10	K11	K12	K13	K14
	AF3	F7	F3	FC5	T7	P7	O1	O2	P8	T8	FC6	F4	F8	AF4
s01	1	0	0	0	1	0	0	0	0	1	1	1	0	0
s02	1	0	0	1	0	1	1	1	1	0	0	0	1	0
s03	1	1	1	0	0	0	0	0	0	1	1	0	1	1
s04	1	1	0	0	0	0	0	0	0	1	1	0	0	1
s05	0	1	0	0	1	0	0	0	1	0	1	0	1	0
s06	0	1	1	1	0	0	1	1	1	1	1	0	1	0

s07	1	0	1	0	0	0	1	0	1	1	1	0	1	1
s08	0	0	1	1	1	1	1	0	1	1	1	0	0	0
s09	0	0	0	1	0	1	0	1	1	0	0	0	0	0
s10	0	0	1	1	1	0	1	0	0	1	1	0	0	0
s11	0	0	0	0	0	0	0	1	0	0	1	1	1	1
s12	0	1	1	1	1	0	0	1	1	0	0	0	0	1
s13	1	1	1	1	0	0	1	0	1	0	1	0	0	0
s14	1	0	1	1	0	0	1	0	1	0	1	1	1	1
s15	0	0	0	0	0	0	0	0	1	1	1	1	1	1
s16	1	0	0	0	0	0	0	0	0	0	1	1	1	0
s17	1	0	0	0	1	0	1	0	1	1	1	0	1	1
s18	0	1	0	0	1	0	1	1	0	1	1	0	1	0
s19	0	1	1	0	0	0	0	0	1	0	1	1	1	1
s20	1	1	0	1	0	0	1	1	1	0	1	1	1	1
s21	0	1	1	0	1	0	1	0	0	0	1	1	0	1
s22	1	0	0	0	1	0	0	0	1	0	1	1	0	0
s23	1	0	0	0	1	0	0	0	0	1	1	0	0	0
toplam	12	10	10	9	10	3	11	7	14	11	20	9	13	11

3.3. Öznitelik Çıkarma

EEG sinyali sınıflandırma başarısı sinyalden çıkarılan bilginin niteliğine bağlıdır. Zaman veya frekans düzlemi gibi veri türüne bağlı olarak özellik çıkarmanın birçok yolu vardır. Bu tezde, öznitelik çıkarımına dayalı olarak Anksiyete sınıflandırmak için üç yöntem önerilmiştir. Bu yöntemler istatistiksel öznitelik (İÖ), Hızlı Fourier dönüşümü (HFD) yönteminin istatistiksel bir öznitelikle birleşimi ve Ayırık Dalgacık Dönüşümü (ADD) yönteminin istatistiksel bir öznitelikle birleşimidir.

3.3.1. Dalgacık Dönüşümü


Dalgacık Dönüşümü (DD); çok çözünürlüklü, analize dayalı sinyalleri farklı frekans bantlarına ayırtıran bir tekniktir. DD, sinyalin zaman-frekans gösterimini sunar. DD, bir dalgacık pencere işlevini genişleterek ve daraltarak sinyali dönüştürür (Jang ve Lee, 2020). DD, EEG sinyali gibi durağan olmayan sinyal işleme için daha iyi bir yöntem olduğunu kanıtlanmıştır. DD Sürekli Dalgacık Dönüşümü (SDD) ve Ayırık Dalgacık Dönüşümü (ADD) olmak üzere ikiye ayrılır.

ADD bir grup filtreden oluşan filtre bankasını kullanarak sinyali farklı

seviyelere ayırıştırır (Sharmila ve Geethanjali, 2016).

ADD sinyal ayırıştırma için çeşitli seviyelerde dalgacıkları kullanan son derece etkili bir yöntemdir. Detay (D) ve Yaklaşık (A) katsayıları elde etmek için sinyal, uygun frekans aralığına ulaşılan kadar yüksek geçiş ve düşük geçiş filtrelerine uygulanır. Her filtrelenmiş çıktı ikişer aşağı örneklenir. Daha sonra, yeniden yapılandırmaya yardımcı olmak için sinyal yukarı örneklendikten sonra ters ADD kullanılır (Sharma, 2017).


Bu tezde öznitelik çıkarmak için ADD yöntemi kullanılmıştır. ADD, EEG işaretini detay(D) ve yaklaşık (A) katsayılarına ayırıştırır. EEG sinyalleri genellikle 0.5- 4 Hz Delta(δ), 4- 8 Hz Teta(θ), 8-16 Hz Alfa(α), 16- 32 Hz Beta(β), 32 Hz ve üstündeki sinyaller Gama(γ) olmak üzere beş frekans bandından oluşmaktadır (Al-Qazzaz vd, 2021; Aydın vd, 2016; Guerrero vd, 2021). DD yöntemi ile doğru EEG alt frekans bantlarını elde etmek için 5.seviye dalgacık dönüşümü kullanılmıştır. Beşinci seviyeden ayırıştırılan sinyal ve alt frekans bantları Şekil 3.6'de gösterilmiştir.



Şekil 3.7. Dalgacık dönüşümü 5. Seviyeden bileşenlere ayırıştırılması (Chen vd, 2017)

Her seviye, 2'ye kadar bir alt-örnekleyiciye sahip filtrelerden oluşur. EEG sinyalleri kullanılarak 19200 ardışık nokta tek bir sinyal olarak oluşturulmuştur. Çalışmamızda kullanılmak üzere çok çeşitli ADD aile dalgacıkları mevcuttur. Ancak benzer uygulamalarda Daubechies (Db), Symlet (Sym) ve Coiflet (Coif) dalgacıklarının en uygun aileler olduğu kanıtlanmıştır (Alomari vd, 2014). Dolayısıyla, bu çalışmada dalgacık tipi Daubechies dalgacıkları Db8, Symlet dalgacıkları Sym2 ve Coiflet dalgacıkları Coif4'ün hesaplanmıştır. Bununla birlikte

ayırıştırma seviyesi 5 olarak seçilmiştir. DD, Dalgacık katsayıları olan detay(D) katsayılarını (D, D2, D3, D4, D5) ve yaklaşık (A) katsayılarını (A1, A2, A3, A4, A5) çıkarmak için oluşturulan ve ölçek düzeyi 5'ye kadar çıkarılan sinyaller üzerinde gerçekleştirilmiştir. Her bir ayrıntı ve detay katsayıları Şekil 3.7'te verilen matematiksel formüller kullanılarak öznitelikler hesaplanmıştır.



Şekil 3.8. ADD dönüşümünden beşinci seviye ayrıştırma katsayıları.

3.3.2. Fourier Dönüşümü


Fourier dönüşümü, Fransız matematikçi Joseph Fourier tarafından geliştirilmiş matematiksel bir tekniktir. Bu dönüşüm periyodik olarak tanımlanır ve bir fonksiyon periyodik olarak kabul edildiğinde uygulanır. Fourier dönüşümünün kullanımı, zaman düzlemindeki bir sinyalin frekans içeriğini analiz etmek için çok kullanışlıdır. Bu dönüşüm, zaman düzlemini frekans düzlemine haritalar. Daha sonra sinyalin frekans içeriği analiz edilir. Bunun nedeni, dönüştürülen fonksiyonun Fourier katsayılarının her bir frekans değerindeki sinüs ve kosinüs fonksiyonlarının ilgili katkılarını temsil etmesidir.

HFD, bu çalışmada verilerimizle başa çıkmak için kullanılan özellik çıkarma yöntemidir. HFD, zaman düzlemindeki sinyalleri frekans etki düzlemine sahip sinyallere dönüştürme işlevi gören matematiksel bir tekniktir bu işlemin çıktısına spektrum denir (Hindarto vd, 2019). Ayrıca, çoğu çalışma ve araştırma, frekans düzleminde çıkarılan özniteliklerin EEG sinyallerine dayalı zihinsel görevleri tanımlamak için en uygun olduğunu göstermiştir. Fourier denklemi aşağıdaki gibidir:

$$X(f)=\int_{-\infty}^{\infty} x(t).e^{-2\pi ft}d(t)$$

Burada frekansı ve x dönüştürülecek sinyali temsil eder. Fourier dönüşümü, EEG sinyal verilerinden frekans spektrumunu bulmak için kullanılır. Sinyalin frekans spektrumu için, genlik, faz ve güç spektrumu HFD kullanarak karmaşık sayılardan daha basit bir şekilde elde edilebilir (Erdoğan, 2006).

EEG verisindeki kanal sayısının fazla olması ve her bir kanaldaki EEG verilerinin de alt frekans bandlarının olmasından dolayı veri boyutu çok büyük olmaktadır. Bu nedenle Tablo 3.2’te verilen matematiksel formüller kullanılarak öznitelikler hesaplanmıştır.



Şekil 3.9. EEG sinyali tek taraflı genlik spektrum çizimi.

3.3.3. İstatistiksel Öznitelik (İÖ)

Matematiksel istatistiksel analiz yöntemleri, sinyaller üzerinde ana sinyalden elde edilemeyen daha fazla bilgiyi elde etmek için sinyallere uygulanır. Bu yöntem, öznitelik çıkarmanın kolay bir yoludur. Bu tezde, istatistiksel öznitelik çıkarmak için Tablo 3.2’de görüldüğü gibi ortalama, Ortanca, standart sapma, varyans, medyan Frekans, maksimum, minimum, Kök Kare Ortalama, Bant Gücü, Ortalama Mutlak Sapma, Sinyalin Spektral Entropisi, Basıklık, çarpıklık, mobilite, karmaşıklık, Entegre Elektroansefalogram, Basit Kare İntegral, Tepe-büyük- Kök Kare Ortalama oranı, Toplam harmonik bozulma, Yaklaşık entropi, Lyapunov üssü olmak üzere 21 tane öznitelik kullanılmıştır.

Tablo 3.2. İstatistiksel öznitelikler

Kısaltma = öznitelik = Denklem	Kısaltma = öznitelik = Denklem
f1= Tepe-büyüklik- Kök Kare Ortalama oranı= $\frac{\ X\ _{\infty}}{\sqrt{\frac{1}{N} \sum_{n=1}^N x_n ^2}}$	f11= Sinyalin Spektral Entropisi = $\sum_n p_n \log \log \left(\frac{1}{p_n}\right)$
f2= Yaklaşık entropi = $\Phi_m - \Phi_{m+1}$, $\Phi_m = (N - m + 1)^{-1} \sum_{i=1}^{N-m+1} \log N_i$	f12= Medyan Frekans = $\left(\frac{n+1}{2}\right)^{th} term$ (n, tek ise) Medyan Frekans = $\frac{\left(\frac{n}{2}\right)^{th} term + \left(\frac{n}{2}+1\right)^{th} term}{2}$ (n, çift ise)
f3= Lyapunov üssü = $polyfit([K_{min} K_{max}], \lambda(i))$	f13= Basıklık (k) = $\frac{1}{N} \sum_{j=1}^N \left(\frac{x_j - \mu}{\sigma}\right)^4$
f4= Toplam harmonik bozulma = $\sqrt{\frac{\sum_{n=2}^{\infty} A_n^2 - r_{ms}}{A_1 - r_{ms}}}$	f14= çarpıklık (s) = $\frac{1}{N} \sum_{j=1}^N \left(\frac{x_j - \mu}{\sigma}\right)^3$
f5= Ortanca = $\frac{n+1}{2}$	f15= Entegre Elektroensefalografi (IEEG) = $\sum_{n=1}^N x(n) $
f6= Ortalama(μ) = $\frac{\sum_{i=1}^N (x_i)}{N}$	f16= Basit Kare İntegral (SSI) = $\sum_{n=1}^N x(n) ^2$
f7= Kök Kare Ortalama = $\sqrt{\frac{1}{N} \sum X^2}$	f17= Minimum = $\min(x_i)$
f8= Bant Gücü = $\frac{1}{2N+1} \sum_{n=-N}^{n=N} x(n) ^2$	f18= Maksimum = $\max(x_i)$
f9= Varyans (σ^2) = $\frac{1}{N-1} \sum_{j=1}^N x_j^2(n) = \sigma^2(m(t))$	f19= Standart sapma = $\sqrt{\frac{\sum_{i=1}^N (x_i - \mu)^2}{N}}$
F10= Ortalama veya Medyan Mutlak Sapma = $\frac{1}{N} \sum_{i=j}^{j+N-1} r_i - R_{ave} $	f20= mobilite = $\frac{\sigma(m'(t))}{\sigma(m(t))}$
	f21= karmaşıklık = $\frac{mob(m'(t))}{mob(m'(t))}$

3.4. Ardışıl İleri Yönlü Öznitelik Seçimi (AİYÖS)

Ardışıl ileri yönlü öznitelik seçme (AİYÖS) yöntemi, bir veri kümesindeki gereksiz ve ilgili olmayan özniteliklerin çıkartılarak verilerin boyut azaltımı yapılması işlemidir. Bu yöntemde, belirli bir öznitelik kümesi oluşturulur. Sonrasında her bir adımda seçilen yönetime göre öznitelik kümesinden bir öznitelik ekleme işlemi yapılır. Örnek olarak, ilk belirlenen öznitelik yalnızca tek bir öznitelikten oluşmaktadır. Belirlenen sınıflandırma algoritmasının doğruluk oranına göre her bir adımda sınıflandırma doğruluk oranı en yüksek olan öznitelikler seçilir. Bu seçilen öznitelik bir sonraki adıma dahil edilir. İkinci belirlenen öznitelik alt kümeleri ise ikili özniteliklerden oluşmaktadır. Burada da yine doğruluk oranı en yüksek olan öznitelik alt kümesi belirlenerek bir sonraki adıma dahil edilir. Tüm öznitelikler tek tek seçim kümesine eklenene kadar bu işlemler devam ettirilir. Sonrasında en yüksek doğruluk oranı olan öznitelik alt kümesi seçilmiş olur (Al-Zubaidi ve Aras, 2022; AYDEMİR, 2017).

3.5. Makine Öğreniminde Sınıflandırma Algoritmaları


Makine Öğrenimi (MÖ), makinelere verileri nasıl daha verimli şekilde kullanacaklarını öğretmek için kullanılmaktadır. Mevcut veri setlerinin çokluğu ile ÖM'ne olan talep de artmaktadır. Birçok endüstri, ilgili verileri çıkarmak için MÖ'ni

uygulamaktadır. MÖ'nin amacı verilerden anlamlı bilgiler çıkarmaktır. Programlanmadan makinelerin kendi kendine öğrenmesinin nasıl sağlanabileceği konusunda birçok çalışma yapılmıştır. Birçok matematikçi ve programcı, büyük veri setlerine sahip olan bu sorunun çözümünü bulmak için çeşitli yaklaşımlar uygulamışlardır (Mahesh ve . 2020).

MÖ, yapay zekâ, bilgisayar bilimleri ve matematik gibi birçok alandan etkilenmiştir ve bu alanların her biri, MÖ'ne katkıda bulunmuştur. Bu farklı gelenekler, MÖ'nde kullanılan farklı yöntemleri ve kelimeleri getirmiştir ve bu yüzden MÖ, çeşitli disiplinler arasında birleşik bir disiplin olarak kabul edilir. MÖ'ne katkıda bulunan bazı disiplinler aşağıda sıralanmıştır (Zhang, 2010):

- İstatistik
- Brian Modelleri
- Adaptif Kontrol Teorisi
- Fizyolojik Modeller
- Yapay Zekâ
- Evrimsel Modeller

Kullanılan sınıflandırma yöntemlerinin başarımı hangisinin daha olumlu etkilediğini gözlemlemek için MATLAB da yer alan SÖAK Kullanılmaktadır. Şekil 3.10'te yapılan sınıflandırma çalışması ile SÖAK aracının arayüz görüntüsü verilmiştir.




Şekil 3.10. SÖAK aracının arayüz görüntüsü

MÖ, veri sorunlarını çözmek için farklı algoritmalara dayanmaktadır. Veri bilimcileri, bir sorunu çözmek için en iyi olan, her duruma uyan tek bir algoritma türü olmadığını belirtmektedirler. Kullanılan algoritmanın türü, çözmek istenilen sorunun türüne, değişken sayısına kısacası ona en uygun modelin türüne bağlıdır. MÖ’de yaygın olarak kullanılan bazı algoritmalar:

3.5.1. Karar Ağaçları


Karar Ağaçları (KA), popüler bir MÖ yöntemidir. Adından da anlaşılacağı gibi, bir KA, insanlar tarafından da kullanılan ortak bir karar verme mekanizması olan ağaç yapılarına dayalı kararlar verir. KA, makine öğrenmesi, görüntü işleme ve örüntü tanımlama gibi çeşitli alanlarda yaygın olarak kullanılan güçlü yöntemlerden biridir. Şekil 3.11’de görüleceği üzere tipik olarak, bir KA bir kök düğüm, birden çok dahili düğüm ve birden çok yaprak düğümünden 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 düğümünden yaprak düğüme giden her yol bir karar dizisidir. Amaç, görünmeyen örnekleri tahmin etmek için genelleme yapabilen bir ağaç üretmektir (Charbuty vd, 2021; Zhou, 2021).



Şekil 3.11. KA algoritması kavramı (Charbuty vd, 2021)

3.5.2. Destek Vektör Makinesi

DVM, istatistiksel öğrenme teorisine dayalı olarak Vapnik tarafından oluşturulmuştur. DVM, Küçük örnek boyutları, doğrusal olmayan ilişkiler ve çoklu sınıflandırmalarla ilgili sorunları çözebilmektedir (Ma vd, 2016). DVM, karar sınırlarını tanımlayan karar düzlemleri kavramına dayanmaktadır. Karar düzlemi, farklı sınıf üyeliklerine sahip bir dizi nesne arasında ayrım yapan düzlemdir (Nazir vd, 2016). Şekil 3.12’de gösterildiği gibi DVM sınıflandırma yapmak için iki sınıfı ayıran bir çizgi çizer ve bu çizginin ± 1 'ine kadar olan yeşil alana marjin denir. Marjin boşluğu ne kadar geniş olursa, iki veya daha fazla sınıf o kadar iyi ayırır. 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 (Zhou, 2022), insan vücudunun hareket amacını tahmin etmesi (Li vd, 2013) ve epileptik nöbetin sınıflandırılması (Zhao vd, 2016) gibi ve daha pek çok alanda kullanılmaktadır.




Şekil 3.12. DVM algoritması kavramı (URL 1)

3.5.3. K-En Yakın Komşu Sınıflandırması

K-en yakın komşu (K-EK), yüksek etkili, uygulaması kolay ve kullanışlı bir yöntemdir. MÖ’nde yaygın olarak kullanılan ilk on veri madenciliği algoritmasından biridir (Na vd, 2021). K-EK sınıflandırıcı parametrik olmayan, doğrusal olmayan ve nispeten basit bir sınıflandırıcıdır. Bu yöntem, daha büyük eğitim setleri için yoğun olarak çalışır. Eğitim ve test seti arasındaki benzerlik ölçüsüne dayanır. Veri kümelerindeki 'n' öznitelikler, kategorilere ayrılır. Her set n boyutlu uzayda bir noktadır ve eğitim setleri n boyutlu model uzayını oluşturur. Bir test veri seti, yakındaki k eğitim veri setine dayalı olarak sınıfa atanır. Veri kümeleri 'yakınlık', aşağıda ki denklem kullanılarak ölçülür(Sharmila ve Geethanjali, 2016):

$$(ED) = \sqrt{\sum_{i=1}^n (Y_{1i} - Y_{2i})^2} \dots\dots\dots(4)$$

Şekil 3.13’da, bilinmeyen örnek noktalarına en yakın olan K örneğini bulmak ve kategorisini belirlemektedir çıkarmaktır (Li vd, 2018).




Şekil 3.13. K-EK algoritması kavramı (URL 2)

3.5.4. Sinir Ağları Sınıflandırması

Yapay Sinir Ağları (YSA), Yapay Zekâ biliminin altında araştırmacıların çok yoğun ilgi gösterdikleri bir araştırma alanıdır. Genellikle sinir ağı olarak adlandırılan yapay sinir ağı, beyindeki sinirlerin çalışmasını taklit ederek sistemlere öğrenme, matematiksel (veya hesaplamalı) bir modeldir. Ayrıca genelleme yapma ve hatırlama gibi yetenekler kazandırmayı amaçlayan bilgi işleme sistemidir. YSA'ların örnekler ile öğrenebilme ve genelleme yapabilme özellikleri onlara çok esnek ve güçlü araçlar olma özelliği sağlamaktadır(Suzuki, 2013).

Bir sinir ağının işlevi, Şekil 3.14'de göstereceği gibi bir girdi modeli sunulduğunda bir çıktı modeli üretmektir. Bu kavram oldukça soyuttur, bu nedenle bir sinir ağının yapabileceği işlemlerden biri de örüntü sınıflandırmasıdır. Örüntü sınıflandırması, örüntüleri bir gruba veya birden fazla ayırma işlemidir(Graupe, 2013).



Şekil 3.14. YSA algoritması kavramı (Mohan vd, 2016)

3.1. Öznitelik İndirgeme

MÖ’de her zaman kompakt modellere sahip olmak arzu edilir. Önemsiz veya birbiriyle ilişkili öznitelikler, modele gereksiz karmaşıklık katar ve yanlış sınıflandırmalara neden olabilir (Rahman vd, 2018). Bu nedenle, öznitelik indirgeme tekniği kullanılır.

3.1.1. Komşu Bileşen Analizi

Komşu Bileşen Analizi (KBA), zaman, frekans ve istatistiksel alan tabanlı öznitelikler arasından en uygun öznitelik setini belirlemek için kullanılır. KBA algoritması, diğer öznitelik seçme yöntemlerine göre tercih edilir çünkü denetimli öğrenme yeteneğine sahiptir. KBA algoritması, K-NN algoritmasına dayalı olarak geliştirilmiş bir parametrik olmayan ve gömülü bir tekniktir. Öznitelik setinin tipik bir Gauss dağılımını takip etmesi gerekmeyen bir kriteri vardır. KBA, sınıflandırma doğruluğunu en üst düzeye çıkarmak için öznitelik ağırlık vektörlerini öğrenir ve bir düzenleme terimi kullanarak gereksiz öznitelikleri eler. Dahası, KBA boyut azaltma işlemi sırasında bilgi kaybı olmaz. Bu nedenle, KBA algoritması kullanılarak önemli öznitelikler seçilir (Raghu ve Sriraam, 2018; Rahman vd, 2018).

3.1.2. Temel Bileşen Analizi

Temel Bileşen Analizi (TBA), örüntü tanıma ve öznitelik çıkarma için en yaygın kullanılan bir yöntemdir. TBA, değişken sayısının fazla olduğu ve değişkenler arasında fazlalık bulunduğu durumlarda kullanılır ve değişken indirgeme prosedürü olarak adlandırılır. Bu süreçte, değişkenler arasındaki korelasyon yapısını koruyarak daha düşük boyutlu bir temsil üretilir. Temel bileşenler, en iyi şekilde ağırlıklandırılmış gözlenen değişkenlerin doğrusal bir kombinasyonu olarak tanımlanabilir (Kottaimalai vd, 2013; Lekshmi vd, 2014).

4. BULGULAR VE TARTIŞMA

Bu bölüm, DASPS veri seti için optimum frekans bandı kombinasyonundan seçilen öznitelik alt kümesine dayalı olarak hem iki hem de dört seviyenin kaygı sınıflandırma sonuçlarını verir.

Bu tezde, zaman-frekans, frekans ve zaman düzlemi öznitelikleri seçilen EEG kanallarından çıkarıldı. ADD ve HFD kullanarak EEG sinyallerin alt frekanslarına elde edildikten sonra daha önce yapılan çalışmaya (OMAR ve Cengiz, 2022) ve literatürdeki diğer benzer çalışmalara dayanarak (Yamada vd, 2019; Zheng vd, 2016), teta ve beta frekans bantlarının en iyi sonuçları verdiği görüldü. Bu nedenle, bu tezde sadece teta ve beta frekans bantlarına odaklanarak öznitelik seçme işlemleri gerçekleştirildi. Seçilen öznitelikler alt kümesi, MATLAB'deki “sınıflandırma öğrenen” araç kutusundaki dört farklı makine öğrenme algoritmasına, yani kaygı sınıflandırması için KA, K-EK, DVM ve YSA'ya beslenir.

Tablo 3.2'deki istatistik öznitelikleri ilk 9 tanesi (f1-f9) kullanarak, Tablo 4.1'deki frekans düzelme ile HFD kullanarak eğitim kümeleri için elde edilen ikili sınıflandırma (Anksiyete ve Normal) sonuçlarının ortalama doğrulukları gösterilmektedir. İkili sınıflandırma sonuçlarına göre tek öznitelik kullanıldığında f8 özniteliklerinin %71,1 ortalama doğruluk ile en yüksek sınıflandırma sonucunu verdiği görülmektedir. AİYÖS yöntemine göre f8 sabit tutularak ikinci adımda diğer öznitelikler ile f8'un birleştirilmesi ile elde edilen öznitelik kombinasyonlarının başarıları araştırılır. Bu kombinasyonlar elde edilen başarı düşene kadar veya özniteliklerin tamamı kullanılabildiği kadar devam ettirilir. Fakat ikili sınıflandırmada yüksek başarı beşinci adımda f8+f7+f2+f3+f6 öznitelik kombinasyonunun %70,1 eğitim kümesi ile ve %62,2 test kümesinde en iyi sonuca DVM ile ulaşılmıştır. Böylece, AİYÖS yöntemine göre iki sınıflandırma süreci tamamlanmıştır.

TBA ve KBA uygulandığında, eğitim kümesi için en iyi kombinasyonun f8+f7+f2+f3+f6 (TBA için vektör uzunluğu 20 ve KBA için vektör uzunluğu 1) özniteliklerinden oluştuğu belirlenmiştir. Bu durumda, TBA için eğitim kümesinde %63,9 K-EK ile doğruluk değeri, KBA için ise %67 DVM ile doğruluk değeri elde edilmiştir. Test kümesinde ise TBA için K-EK ile %63,4 ve KBA için ise DVM ile %61 doğruluk değeri elde edilmiştir. Öte yandan, TBA ve KBA uygulanmadığında aynı öznitelik kombinasyonunun (vektör uzunluğu 40) test kümesinde %62,2

doğruluk değeri elde edilmiştir. Sonuç olarak, TBA uygulandığında daha yüksek bir başarı elde edildiğini gözlemlenmiştir.

Tablo 4.1. AİYÖS yöntemi kullanılarak HFD ile gerçekleştirilen ikili sınıflandırma eğitim kümesi sonuçları

öznitelik kombina syonu	f1	f2	f3	f4	f5	f6	f7	f8	f9
Tekli	63.9 K-EK DVM	66.5 K-EK	69.1 KA	63.9 tum	70.6 DVM	66 K-EK	63.9 K-EK DVM	71.1 KA	65.5 YSA
İkili	63.9 K-EK DVM	64.9 KA	67 DVM	63.9 tum	63.9 K-EK DVM	66 K-EK	67.5 K-EK	f8	64.9 YSA
Üçlü	64.4 DVM K-EK	70.1 K-EK	69.1 KA	63.9 tum	68.6 YSA	66 KA	f7	f8	68.6 DVM
Dörtlü	67 K-EK	f2	69.1 DVM	63.9 YSA K-EK DVM	67 KA	63.9 K-EK DVM	f7	f8	63.9 K-EK DVM
Beşli	64.4 KA	f2	f3	63.9 YSA K-EK DVM	67 YSA	70.1 DVM	f7	f8	63.9 K-EK DVM
Altılı	70.6 DVM	f2	f3	63.9 YSA K-EK DVM	63.9 K-EK DVM	f6	f7	f8	63.9 K-EK DVM
Yedili	f1	f2	f3	64.4 KA	65.5 K-EK YSA	f6	f7	f8	66.5 K-EK
Sekizli	f1	f2	f3	63.9 YSA K-EK DVM	f5	f6	f7	f8	63.9 K-EK DVM
Döktüz lü	f1	f2	f3	f4	f5	f6	f7	f8	63.9 tum

Tablo 3.2'deki istatistik öznitelikleri sadece on bir tanesi (f6-f16) kullanarak, Tablo 4.2, ADD ve db8 ile eğitim kümeleri için elde edilen ikili sınıflandırma (Anksiyete ve Normal) sonuçlarının ortalama doğrulukları gösterilmektedir. TBA ve KBA uygulanmadan önceki İkili sınıflandırma sonuçlarına göre tek öznitelik kullanıldığında f9 özniteliğinin %68,6 ortalama doğruluk 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 araştırılır. Bu kombinasyonlar elde edilen başarıya düşene kadar veya özniteliklerin tamamı kullanılabilece kadar devam ettirilir. Fakat, bu bölümde ikili sınıflandırmada yüksek başarıyı ikinci adımda f9+f15 öznitelik kombinasyonunun %70,1 eğitim kümesi ile ve %68,3 test kümesinde en iyi sonuca DVM ile ulaşılmıştır.

TBA ve KBA uygulandığında, en iyi kombinasyonun eğitim kümesi için f9+f15+f11+f10+f8+f7 (TBA için vektör uzunluğu 48 ve KBA için vektör uzunluğu 4) özniteliklerinden oluştuğu belirlenmiştir. Doğruluk değeri ikisinde de %65,50 olarak elde edilmiştir. Test kümesinde ise TBA için DVM ile %58,5 ve KBA için ise K-EK ile %63,4 doğruluk değeri elde edilmiştir. Öte yandan, TBA ve KBA uygulanmadığında f9+f15 (vektör uzunluğu 16) öznitelik kombinasyonunun test kümesinde %68,3 doğruluk değeri ile en iyi performansı göstermiştir.

Tablo 4.2. AİYÖS yöntemi kullanılarak ADD ve db8 ile gerçekleştirilen ikili sınıflandırma eğitim kümesi sonuçları

f6	f7	f8	f9	f10	f11	f12	f13	f14	f15	f16
64.4 DVM	63.9 DVM K-EK	64.4 DVM	68.6 YSA	65.5 DVM	63.9 DVM K-EK	63.9 DVM K-EK	64.9 DVM	63.9 DVM	64.9 YSA	63.9 DVM
63.9 DVM K-EK	69.1 DVM	63.9 DVM K-EK	f9	67.5K- EK	63.9 DVM K-EK	64.4 DVM	63.9 K-EK	52.4 K-EK	70.1 DVM	64.4 KA
63.9 DVM K-EK	68 KA	63.9 DVM K-EK	f9	64.4 DVM	69.1 DVM	64.4 DVM	63.9 K-EK	65.5 DVM	f15	68 DVM
63.9 DVM K-EK	63.9 DVM	63.9 DVM K-EK	f9	65.5 DVM	f11	64.4 DVM	64.9 DVM	63.9 DVM K-EK	f15	64.4 DVM
63.9 DVM K-EK	67 K-EK	71.1 KA	f9	f10	f11	63.9 DVM K-EK	63.9 DVM K-EK	64.9 K-EK	f15	63.9 DVM K-EK
63.9 DVM K-EK	67 YSA	f8	f9	f10	f11	63.9 DVM K-EK	63.9 DVM K-EK	66.5 DVM	f15	63.9 DVM K-EK
64.9 KA	f7	f8	f9	f10	f11	63.9 DVM K-EK	63.9 DVM K-EK	66.5 DVM YSA	f15	63.9 DVM K-EK
64.9 DVM	f7	f8	f9	f10	f11	63.9 DVM K-EK	64.9 DVM	f14	f15	64.4 KA
66 K-EK	f7	f8	f9	f10	f11	64.4 DVM	f13	f14	f15	64.4 DVM
f6	f7	f8	f9	f10	f11	64.4 DVM	f13	f14	f15	64.9 DVM
f6	f7	f8	f9	f10	f11	63.9 DVM K-EK	f13	f14	f15	f16

Aynı istatistik öznitelikleri (f6-f16) kullanarak, Tablo 4.3, ADD ve Coif4 ile eğitim kümeleri için elde edilen ikili sınıflandırma (Anksiyete ve Normal) sonuçlarının ortalama doğrulukları gösterilmektedir. İkili sınıflandırma sonuçlarına göre tek öznitelik kullanıldığında f8 özneliğinin %67 ortalama doğruluk ile en yüksek sınıflandırma sonucunu verdiği görülmektedir. AİYÖS yöntemine göre f8 sabit tutularak ikinci adımda diğer öznitelikler ile f8'un birleştirilmesi ile elde edilen öznitelik kombinasyonlarının başarısı araştırılır. Bu kombinasyonlar elde edilen başarıyı düşene kadar veya özniteliklerin tamamı kullanılına kadar devam ettirilir. Bu

bölümde, yüksek başarımlı ikinci adımda f9+f12 öznitelik kombinasyonunun %70,6 eğitim kümesi ile ve %57 test kümesinde en iyi sonuca KA ile ulaşılmıştır.

TBA ve KBA uygulandığında, en iyi kombinasyonun eğitim kümesi için tüm özniteliklerinden oluştuğu belirlenmiştir (TBA için vektör uzunluğu 44 ve KBA için vektör uzunluğu 1) ve doğruluk değeri sırasıyla %63,90 ve %66,50 olarak DVM ile elde edilmiştir. Öte yandan, TBA ve KBA uygulanmadığında f9+f12 (vektör uzunluğu 16) öznitelik kombinasyonunun test kümesinde %57 doğruluk değeri ile elde edilmiştir. TBA uygulandığında test başarımlı %57,3 elde edilmiştir, KBA uygulandığında test başarımlının %59,80'e yükseldiği gözlemlenmiştir.

Tablo 4.3. AİYÖS yöntemi kullanılarak ADD ve Coif4 ile gerçekleştirilen ikili sınıflandırma eğitim kümesi sonuçları

f6	f7	f8	f9	f10	f11	f12	f13	f14	f15	f16
64.9 DVM K-NN	65.5 K-NN	67 KA	65.5 DVM	66 DVM	64.4 DVM	64.9 DVM	63.9 DVM K-NN	63.9 DVM K-NN	66 KA	63.9 DVM K-NN
63.9 K-NN DVM	63.9 K-NN	f8	64.4 KA	66 DVM K-NN	63.9 DVM K-NN	70.6 KA	63.9 DVM K-NN	65.5 YSA	64.9 DVM	64.9 K-NN
63.9 DVM K-NN	63.9 DVM K-NN	f8	63.9 DVM K-NN KA	64.9 DVM	66 KA	f12	74.7 KA	69.1 KA	63.9 DVM K-NN	63.9 K-NN YSA
67 YSA	64.4 DVM	f8	64.9 K-NN	63.9 K-NN	63.9 DVM K-NN	f12	f13	63.9 DVM K-NN	66 DVM	63.9 DVM K-NN
f6	64.9 DVM	f8	64.4 K-NN	66 KA DVM	63.9 DVM K-NN	f12	f13	63.9 DVM K-NN	63.9 DVM K-NN	63.9 DVM K-NN
f6	66.5 KA	f8	64.9 KA	f10	67 YSA	f12	f13	63.9 DVM K-NN	63.9 DVM K-NN	63.9 DVM K-NN
f6	64.9 KA	f8	63.9 DVM K-NN	f10	f11	f12	f13	63.9 DVM K-NN KA	63.9 DVM K-NN	63.9 DVM K-NN
f6	f7	f8	65.5 KA	f10	f11	f12	f13	63.9 DVM K-NN	63.9 DVM K-NN	64.4 DVM
f6	f7	f8	f9	f10	f11	f12	f13	64.9 KA	63.9 DVM K-NN	64.4 DVM
f6	f7	f8	f9	f10	f11	f12	f13	f14	63.9 DVM K-NN	66.5 K-NN
f6	f7	f8	f9	f10	f11	f12	f13	f14	66 KA	f15

Aynı istatistik öznitelikleri (f6-f16) kullanarak, Tablo 4.4, ADD ve Sym2 ile eğitim kümeleri için elde edilen ikili sınıflandırma (Anksiyete ve Normal) sonuçlarının ortalama doğrulukları gösterilmektedir. İkili sınıflandırma sonuçlarına göre tek öznitelik kullanıldığında f6 özneliğinin %67 ortalama doğruluk ile en yüksek

sınıflandırma sonucunu verdiği görülmektedir. AİYÖS yöntemine göre f6 sabit tutularak ikinci adımda diğer öznitelikler ile f6'un birleştirilmesi ile elde edilen öznitelik kombinasyonlarının başarısı araştırılır. Bu kombinasyonlar elde edilen başarımlar düşene kadar veya özniteliklerin tamamı kullanılabildiği kadar devam ettirilir. Bu bölümde, yüksek başarımlar altıncı adımda f6+f16+f15+f8+f7+f11 öznitelik kombinasyonunun %66,5 eğitim kümesi ile ve %64,4 test kümesinde en iyi sonuca K-EK ile ulaşılmıştır.

TBA ve KBA uygulandığında, eğitim kümesi için en iyi kombinasyonun f6+f16+f15+f8+f7+f11 (TBA için vektör uzunluğu 24 ve KBA için vektör uzunluğu 6) özniteliklerinden oluştuğu belirlenmiştir. Bu durumda, TBA için eğitim kümesinde %69,10 doğruluk değeri, KBA için ise %66,50 doğruluk değeri elde edilmiştir. Test kümesinde ise TBA ile %67,10 doğruluk değeri elde edilmiştir. Öte yandan, TBA ve KBA uygulanmadığında aynı öznitelik kombinasyonunun (vektör uzunluğu 48) test kümesinde %64,4 doğruluk değeri elde edilmiştir. KBA uygulandığında test başarımları %64,4 elde edilmiştir, TBA uygulandığında ise bu başarımların K-EK ile %67,10'ye yükseldiği olduğu gözlemlenmiştir.

Tablo 4.4. AİYÖS yöntemi kullanılarak ADD ve Sym2 ile gerçekleştirilen ikili sınıflandırma eğitim kümesi sonuçları

f6	f7	f8	f9	f10	f11	f12	f13	f14	f15	f16
67 DVM	63.9 DVM K-NN	64.9 DVM	63.9 DVM K-NN	64.9 KA	63.9 DVM K-NN	63.9 DVM K-NN	63.9 DVM K-NN	63.9 DVM K-NN	63.9 DVM K-NN	63.9 K-NN
f6	63.9 DVM K-NN	64.9 DVM	64.9 KA	63.9 DVM K-NN	63.9 DVM K-NN	63.9 DVM K-NN	63.9 K-NN	63.9 DVM K-NN	65.5 K-NN	67.5 KA
f6	63.9 DVM K-NN	63.9 DVM K-NN	63.9 K-NN	64.4 DVM	67 YSA	63.9 DVM K-NN	66.5 K-NN	66 K-NN	72.2 KA	f16
f6	64.4 DVM	68.8 DVM	64.9 YSA K-NN	63.9 DVM YSA K-NN	63.9 DVM	63.9 DVM K-NN	64.9 KA	66.5 KA	f15	f16
f6	69.1 KA	f8	64.4 DVM	64.4 KA	68.6 YSA	63.9 DVM K-NN	64.9 DVM K-NN	63.9 DVM K-NN KA	f15	f16
f6	f7	f8	65.5 K-NN	63.9 DVM K-NN	66.5 K-NN	63.9 DVM K-NN	66 DVM	65.5 DVM	f15	f16
f6	f7	f8	64.9 K-NN	64.9 DVM	f11	63.9 DVM K-NN	63.9 DVM K-NN	65.5 KA	f15	f16
f6	f7	f8	63.9 DVM K-NN	63.9 DVM K-NN	f11	68.6 YSA	63.9 DVM K-NN	f14	f15	f16
f6	f7	f8	63.9 DVM K-NN	66 DVM	f11	f12	66.5 DVM	f14	f15	f16

f6	f7	f8	67 K-NN	63.9 DVM K-NN	f11	f12	f13	f14	f15	f16
f6	f7	f8	f9	66 YSA	f11	f12	f13	f14	f15	f16

Tablo 3.2'deki istatistik öznitelikleri son 17 tanesi (f5-f21) kullanarak, Tablo 4.5'deki Zaman düzlemindeki öznitelikleri seçimi için istatistik parametreleri ile eğitim kümeleri için elde edilen ikili sınıflandırma (Anksiyete ve Normal) sonuçlarının ortalama doğrulukları gösterilmektedir. İkili sınıflandırma sonuçlarına göre tek öznitelik kullanıldığında f20 özniteliğinin %67 ortalama doğruluk ile en yüksek sınıflandırma sonucunu verdiği görülmektedir. AİYÖS yöntemine göre f20 sabit tutularak ikinci adımda diğer öznitelikler ile f20'un birleştirilmesi ile elde edilen öznitelik kombinasyonlarının başarısı araştırılmıştır. Bu kombinasyonlar elde edilen başarıya düşene kadar veya özniteliklerin tamamı kullanılabilece kadar devam eder. Fakat ikili sınıflandırmada yüksek başarıya sekizinci adımda f20+f10+f18+f9+f19+f17+f16+f6 öznitelik kombinasyonunun %70,1 eğitim kümesi ile ve %62,2 test kümesinde en iyi sonuca KA ile ulaşılmıştır. Böylece, AİYÖS yöntemine göre iki sınıflandırma süreci tamamlanmıştır.

TBA ve KBA uygulandığında, eğitim kümesi için en iyi kombinasyonun tüm özniteliklerinden oluştuğu belirlenmiştir (TBA için vektör üzgünlüğü 3 ve KBA için vektör üzgünlüğü 1). Bu durumda, TBA için eğitim kümesinde %63,90 doğruluk değeri, KBA için ise %66 doğruluk değeri elde edilmiştir. Öte yandan, TBA ve KBA uygulanmadığında f20+f10+f18+f9+f19+f17+f16+f6 öznitelik kombinasyonunun (vektör normal 32) test kümesinde %62,2 doğruluk değeri elde edilmiştir. TBA ve KBA uygulandığında ise bu başarımın %63,40'ye yükseldiği olduğu gözlemlenmiştir.

Tablo 4.5. İstatistik parametreleri kullanılarak AİYÖS yöntemiyle gerçekleştirilen ikili sınıflandırma eğitim kümesi sonuçları.

f5	f6	f7	f8	f9	f10	f11	f12	f13	f14	f15	f16	f17	f18	f19	f20	f21
64.9 DVM	64.9 DVM K-EK	64.9 DVM	63.9 DVM K-EK	63.9 DVM K-EK	63.9 DVM K-EK	63.9 DVM K-EK	63.9 DVM K-EK	65.5 DVM	65.5 DVM K-EK	63.9 DVM K-EK	64.9 KA	65.5 DVM	63.9 DVM K-EK	64.9 KA	67 DVM	66.5 DVM
63.9 KA DVM K-EK	66 K-EK	64.4 K-EK	64.4 YSA K-EK	63.9 DVM K-EK	69.1 KA	65.5 K-EK	63.9 DVM K-EK	63.9 DVM K-EK	65.5 DVM	67.5 DVM	63.9 DVM K-EK	63.9 DVM K-EK	63.9 DVM K-EK	63.9 DVM K-EK	f20	64.9 KA
65.5 DVM	66.5 DVM	64.4 K-EK	63.9 DVM K-EK	66 DVM	f10	63.9 DVM K-EK	64.4 DVM	63.9 DVM K-EK	63.9 DVM K-EK	66.5 YSA	65.5 DVM	63.9 DVM K-EK	67.5 DVM	63.9 DVM K-EK	f20	63.9 DVM K-EK
63.9 DVM K-EK	63.9 DVM KA	64.9 KA	63.9 DVM K-EK	65.5 DVM	f10	63.9 DVM K-EK	65.5 DVM	63.9 DVM K-EK	63.9 DVM K-EK	63.9 DVM K-EK	64.9 DVM	63.9 DVM	f18	64.4 DVM K-EK	f20	63.9 DVM K-EK
64.4 DVM	64.9 K-EK	64.9 DVM	63.9 DVM K-EK	f9	f10	63.9 DVM K-EK	64.4 DVM	64.4 KA	66 YSA	64.4 DVM K-EK	63.9 K-EK	63.9 DVM K-EK	f18	67 KA	f20	64.9 DVM

64.4 DVM	63.9 DVM K-EK	64.9 KA	63.9 DVM K-EK	f9	f10	63.9 DVM K-EK	65.5 DVM	63.9 DVM K-EK	66.5 DVM	64.9 DVM K-EK	63.9 DVM K-EK	67 KA	f18	f19	f20	63.9 DVM K-EK
63.9 K-EK	64.4 KA	64.4 K-EK	63.9 DVM K-EK	f9	f10	63.9 DVM K-EK	63.9 DVM KA	63.9 K-EK	63.9 DVM K-EK	64.4 DVM	64.9 DVM	f17	f18	f19	f20	63.9 DVM K-EK
64.9 DVM	70.1 KA	64.9 DVM	63.9 DVM KA	f9	f10	64.4 DVM	64.9 K-EK	66 KA	64.9 DVM	64.4 KA K-EK	f16	f17	f18	f19	f20	63.9 DVM K-EK
67 KA	f6	67 K- EK	65.5 KA	f9	f10	63.9 DVM K-EK	66 K- EK	66 KA	63.9 DVM K-EK	67 K-EK	f16	f17	f18	f19	f20	63.9 DVM K-EK
63.9 DVM K-EK	f6	69.6 KA	65.5 DVM	f9	f10	64.9 K-EK DVM	63.9 DVM K-EK	64.4 DVM	64.9 K-EK	f15	f16	f17	f18	f19	f20	64.4 KA K-EK
64.4 DVM	f6	f7	63.9 DVM K-EK	f9	f10	64.4 K-EK	67 KA	64.9 DVM	64.9 DVM	f15	f16	f17	f18	f19	f20	64.4 DVM
63.9 DVM KA	f6	f7	63.9 DVM	f9	f10	66.5 DVM	f12	63.9 DVM K-EK	63.9 DVM K-EK	f15	f16	f17	f18	f19	f20	64.9 DVM
63.9 DVM KA	f6	f7	63.9 DVM K-EK	f9	f10	63.9 DVM K-EK	f12	63.9 DVM K-EK	63.9 DVM K-EK	f15	f16	f17	f18	f19	f20	65.5 DVM
63.9 DVM KA	f6	f7	63.9 DVM KA	f9	f10	63.9 DVM KA	f12	64.9 DVM	63.9 DVM K-EK	f15	f16	f17	f18	f19	f20	f21
66.5 K-EK	f6	f7	64.9 DVM	f9	f10	64.4 KA	f12	f13	63.9 DVM K-EK	f15	f16	f17	f18	f19	f20	f21
f5	f6	f7	63.9 DVM K-EK	f9	f10	63.9 DVM K-EK	f12	f13	67.5 KA	f15	f16	f17	f18	f19	f20	f21
f5	f6	f7	63.9 DVM K-EK	f9	f10	65.5 DVM	f12	f13	f14	f15	f16	f17	f18	f19	f20	f21

DÖRTLÜ SINIFLANDIRMA

Tablo 3.2'deki istatistik öznitelikleri ilk 9 tanesi (f1-f9) kullanarak, Tablo 4.6'deki frekans düzlemi ile HFD kullanarak eğitim kümeleri için elde edilen dörtlü sınıflandırma (Normal, Hafif, Orta ve Şiddetli Anksiyete) sonuçlarının ortalamaları gösterilmektedir. Dörtlü sınıflandırmada ise AİYÖS yöntemine göre birinci adımda f8 özniteliğinin %60,8 ortalama ile en yüksek sınıflandırma sonucunu verdiği görülmektedir. AİYÖS yöntemine göre f8 sabit tutularak ikinci adımda diğer öznitelikler ile f8'un birleştirilmesi ile elde edilen öznitelik kombinasyonlarının başarıları araştırılmıştır. Bu kombinasyonlar elde edilen başarımların tamamı kullanılabilecek kadar devam ettirilmiştir fakat dörtlü sınıfta en yüksek başarımlar birinci adımda f8 öznitelik ile %60,8 eğitim kümesi ve %59,8 test kümesinde en iyi sonuca K-EK ile ulaşılmıştır. Böylece, AİYÖS yöntemine göre sınıflandırma süreci tamamlanmıştır.

TBA ve KBA uygulandığında, eğitim kümesi için en iyi kombinasyonun f8+f9+f1+f6 (TBA için vektör uzunluğu 16 ve KBA için vektör uzunluğu 32) özniteliklerinden oluştuğu belirlenmiştir. Bu durumda, TBA için eğitim kümesinde %59,30 K-EK ile doğruluk değeri, KBA için ise %61,30 DVM ile doğruluk değeri elde edilmiştir. Test kümesinde ise TBA ile %56,1 ve KBA ile %61 doğruluk değeri elde edilmiştir. Öte yandan, TBA ve KBA uygulanmadığında aynı öznitelik kombinasyonunun (vektör uzunluğu 32) test kümesinde %59,8 doğruluk değeri elde edilmiştir. Sonuç olarak, TBA uygulandığında ise bu başarımların %61'e yükseldiği

olduğunu gözlemlenmiştir.

Tablo 4.6. AİYÖS yöntemi kullanılarak HFD ile gerçekleştirilen dörtlü sınıflandırma eğitim kümesi sonuçları

f1	f2	f3	f4	f5	f6	f7	f8	f9
56.7 tum	60.8 KA	57.2 DVM	59.3 K-EK	59.3 DVM	61.9 DVM	57.2 DVM	60.8 K-EK	59.3 K-EK
56.7 tum	62.4 K-EK	56.7 DVM K-EK	58.8 DVM	56.7 DVM K-EK	63.9 DVM	59.3 DVM	f8	61.9 K-EK
61.3 K-EK	62.9 DVM	57.7 YSA	57.2 KA	58.2 DVM K-EK	63.9 YSA	61.9 DVM 53.9	f8	f9
f1	60.8 DVM YSA	57.7 DVM	56.7 YSA DVM K-EK	57.7 KA	62.4 DVM	60.3 DVM	f8	f9
f1	60.8 K-EK	57.2 KA	59.3 KA	58.8 DVM	f6	59.8 K-EK	f8	f9
f1	59.8 K-EK	62.4 K-EK	57.2 KA	65.5 DVM	f6	f7	f8	f9
f1	57.2 KA	58.2 KA	63.4 KA	f5	f6	f7	f8	f9
f1	59.3 KA	56.7 DVM K-EK YSA	f4	f5	f6	f7	f8	f9
f1	f2	58.8 KA	f4	f5	f6	f7	f8	f9

Tablo 3.2'deki istatistik öznitelikleri sadece on bir tanesi (f6-f16) kullanarak, Tablo 4.7, ADD ve db8 ile Eğitim kümeleri için elde edilen dörtlü sınıflandırma (Normal, Hafif, Orta ve Şiddetli Anksiyete) sonuçlarının ortalama doğrulukları gösterilmektedir. İkili sınıflandırma sonuçlarına göre tek öznitelik kullanıldığında f14 öznitelisinin %59,3 ortalama doğruluk ile en yüksek sınıflandırma sonucunu verdiği görülmektedir. AİYÖS yöntemine göre f14 sabit tutularak ikinci adımda diğer öznitelikler ile f14'un birleştirilmesi ile elde edilen öznitelik kombinasyonlarının başarıları araştırılmıştır. Bu kombinasyonlar elde edilen başarımların tamamı kullanılabilecek kadar devam eder. Fakat dörtlü sınıflandırmada yüksek başarımlar altıncı adımda f14+f15+f11+f6+f10+f9 öznitelik kombinasyonunun %59,3 eğitim kümesi ile ve %54,9 test kümesinde en iyi sonuca DVM ile ulaşılmıştır.

TBA ve KBA uygulandığında, eğitim kümesi için en iyi kombinasyonun f14+f15+f11 (TBA için vektör uzunluğu 12 ve KBA için vektör uzunluğu 2) özniteliklerinden oluştuğu belirlenmiştir. Bu durumda, TBA için eğitim kümesinde %56,7 doğruluk değeri, KBA için ise %59,80 doğruluk değeri elde edilmiştir. Test kümesinde ise TBA için 54,9 ve KBA için %57,30 doğruluk değeri DVM ile elde

edilmiştir. Öte yandan, TBA ve KBA uygulanmadığında aynı öznitelik kombinasyonunun (vektör uzunluğu 48) test kümesinde %54,9 doğruluk değeri elde edilmiştir. Bu halde, KBA uygulandığında bu başarımın %57,30'ye yükseldiği olduğunu gözlemlenmiştir.

Tablo 4.7. AIYÖS yöntemi kullanılarak ADD ve db8 ile gerçekleştirilen dörtlü sınıflandırma eğitim kümesi sonuçları

f6	f7	f8	f9	f10	f11	f12	f13	f14	f15	f16
58.8 KA	57.2 DVM	57.7 K-EK	57.7 DVM	56.7 K-EK	57.7 DVM	57.2 K-EK	56.7 DVM K-EK	59.3 KA	56.7 KA DVM K-EK	57.7 DVM
56.7 DVM K-EK	56.7 DVM K-EK	56.7 DVM K-EK	57.2 DVM	57.7 K-EK	56.7 DVM K-EK	56.7 DVM K-EK	57.7 DVM	f14	59.8 DVM	56.7 K-EK DVM
58.2 DVM	56.7 DVM K-EK	58.8 DVM	56.7 DVM K-EK	57.7 DVM	64.4 K-EK	57.2 DVM	56.7 DVM K-EK	f14	f15	57.2 DVM K-EK YSA
59.3 DVM	58.2 DVM	58.2 DVM	58.2 K-EK	58.2 K-EK	f11	56.7 DVM K-EK	57.2 DVM K-EK	f14	f15	56.7 K-EK DVM
f6	56.7 DVM K-EK	56.7 DVM K-EK	57.2 DVM	60.8 K-EK	f11	56.7 DVM K-EK	56.7 DVM K-EK	f14	f15	56.7 K-EK DVM
f6	56.7 DVM K-EK	56.7 DVM K-EK	59.3 DVM	f10	f11	56.7 DVM K-EK	56.7 DVM K-EK	f14	f15	57.7 K-EK
f6	56.7 DVM K-EK	59.3 DVM	f9	f10	f11	62.4 K-EK	56.7 DVM K-EK	f14	f15	56.7 DVM K-EK
f6	56.7 DVM K-EK	57.2 DVM	f9	f10	f11	f12	57.7 DVM	f14	f15	56.7 DVM K-EK
f6	57.7 DVM	59.3 DVM	f9	f10	f11	f12	f13	f14	f15	57.7 K-EK
f6	60.8 KA	f8	f9	f10	f11	f12	f13	f14	f15	57.2 DVM
f6	f7	f8	f9	f10	f11	f12	f13	f14	f15	57.2 DVM KA

Aynı istatistik öznitelikleri (f6-f16) kullanarak, Tablo 4.8, ADD ve Coif4 ile eğitim kümeleri için elde edilen ikili sınıflandırma (Normal, Hafif, Orta ve Şiddetli Anksiyete) sonuçlarının ortalama doğrulukları gösterilmektedir. Dörtlü sınıflandırma sonuçlarına göre tek öznitelik kullanıldığında f8 özneliliğinin %60,8 ortalama doğruluk ile en yüksek sınıflandırma sonucunu verdiği görülmektedir. AIYÖS yöntemine göre f8 sabit tutularak ikinci adımda diğer öznitelikler ile f8'un birleştirilmesi ile elde edilen öznitelik kombinasyonlarının başarısı araştırılır. Bu kombinasyonlar elde edilen başarım düşene kadar veya özniteliklerin tamamı kullanılabilece kadar devam ettirilir. Bu bölümde, yüksek başarım altıncı adımda f8+f16+f14+f12+f13+f10 öznitelik kombinasyonunun %59,3 eğitim kümesi ile ve

%57,3 test kümesinde en iyi sonuca DVM ile ulaşılmıştır.

TBA ve KBA uygulandığında, en iyi kombinasyonun eğitim kümesi için f8+f16+f14+f12 özniteliklerinden oluştuğu belirlenmiştir (TBA için vektör uzunluğu 12 ve KBA için vektör uzunluğu 5) ve doğruluk değeri sırasıyla %60,80 KA ile ve %58,20 K-EK ve DVM ile, test kümesi için ise TBA ile %57,3 ve KBA ile %51,2 olarak elde edilmiştir. Öte yandan, TBA ve KBA uygulanmadığında f8+f16+f14+f12+f13+f10 (vektör üzgünlüğü 48) öznitelik kombinasyonunun test kümesinde %57,3 doğruluk değeri ile elde edilmiştir. Sonuç olarak, TBA uygulandığında en iyi sonuca ulaşılmıştır.

Tablo 4.8. AİYÖS yöntemi kullanılarak ADD ve Coif4 ile gerçekleştirilen dörtlü sınıflandırma eğitim kümesi sonuçları

f6	f7	f8	f9	f10	f11	f12	f13	f14	f15	f16
56.7 DVM	59.8 KA DVM	60.8 KA	58.2 DVM	58.8 DVM	56.7 DVM K-EK	56.7 DVM K-EK	56.7 DVM K-EK	57.2 K-EK	58.2 KA	57.7 DVM
57.2 DVM	56.7 K-EK	f8	56.7 K-EK DVM	59.8 K-EK	57.7 DVM	57.7 DVM	57.2 K-EK	56.7 DVM K-EK	60.8 DVM	60.3 DVM
58.2 DVM	57.2 DVM	f8	57.7 DVM	57.2 DVM	56.7 DVM K-EK	56.7 DVM K-EK	58.2 DVM	58.8 DVM	57.2 DVM	f16
57.7 DVM	57.7 DVM	f8	56.7 K-EK DVM	57.2 DVM	56.7 K-EK DVM	58.2 KA	57.2 KA	f14	56.7 K-EK	f16
56.7 K-EK DVM	56.7 K-EK DVM	f8	57.2 DVM	56.7 K-EK DVM	57.2 DVM	f12	58.2 DVM	f14	56.7 K-EK DVM	f16
56.7 K-EK DVM	57.2 DVM	f8	58.8 KA	59.3 DVM	56.7 K-EK DVM	f12	f13	f14	56.7 K-EK	f16
57.7 DVM	56.7 K-EK DVM	f8	56.7 K-EK DVM	f10	56.7 K-EK DVM	f12	f13	f14	58.2 DVM	f16
56.7 K-EK DVM	56.7 K-EK DVM	f8	56.7 K-EK DVM	f10	57.7 DVM	f12	f13	f14	f15	f16
56.7 K-EK DVM	56.7 K-EK DVM	f8	56.7 K-EK DVM	f10	f11	f12	f13	f14	f15	f16
f6	56.7 K-EK DVM	f8	57.2 DVM	f10	f11	f12	f13	f14	f15	f16
f6	f7	f8	56.7 K-EK DVM	f10	f11	f12	f13	f14	f15	f16

Aynı istatistik öznitelikleri (f6-f16) kullanarak, Tablo 4.9, ADD ve Sym2 ile

eğitim kümeleri için elde edilen ikili sınıflandırma (Normal, Hafif, Orta ve Şiddetli Anksiyete) sonuçlarının ortalama doğrulukları gösterilmektedir. Dörtlü sınıflandırma sonuçlarına göre tek öznitelik kullanıldığında f8 özniteliğinin %59,8 ortalama doğruluk ile en yüksek sınıflandırma sonucunu verdiği görülmektedir. AİYÖS yöntemine göre f8 sabit tutularak ikinci adımda diğer öznitelikler ile f8'un birleştirilmesi ile elde edilen öznitelik kombinasyonlarının başarısı araştırılır. Bu kombinasyonlar elde edilen başarıma düşene kadar veya özniteliklerin tamamı kullanılabilece kadar devam ettirilir. Bu bölümde, yüksek başarıma altıncı adımda f8+f16+f7+f9+f10+f11 öznitelik kombinasyonunun %60,8 eğitim kümesi ile ve %56,1 test kümesinde en iyi sonuca DVM ile ulaşılmıştır.

TBA ve KBA uygulandığında, eğitim kümesi için en iyi kombinasyonun f8+f16+f7+f9+f10+f11 (TBA için vektör uzunluğu 24 ve KBA için vektör uzunluğu 2) özniteliklerinden oluştuğu belirlenmiştir. Bu durumda, TBA için eğitim kümesinde %59,30 doğruluk değeri, KBA için ise %58,2 doğruluk değeri elde edilmiştir. Test kümesinde ise TBA ile %56,10 ve KBA ile 47,6 doğruluk değeri elde edilmiştir. Öte yandan, TBA ve KBA uygulanmadığında aynı öznitelik kombinasyonunun (vektör uzunluğu 48) test kümesinde %56,1 doğruluk değeri elde edilmiştir. TBA uygulandığında ise aynı başarıma olduğunu gözlemlenmiştir.

Tablo 4.9. AİYÖS yöntemi kullanılarak ADD ve Sym2 ile gerçekleştirilen dörtlü sınıflandırma eğitim kümesi sonuçları

f6	f7	f8	f9	f10	f11	f12	f13	f14	f15	f16
56.7 K-EK DVM	57.2 DVM	59.8 DVM	56.7 K-EK DVM	56.7 K-EK DVM	59.8 KA	58.8 K-EK	56.7 K-EK DVM	57.2 DVM	56.7 K-EK DVM	57.2 K-EK
57.2 DVM	56.7 K-EK DVM	f8	56.7 K-EK DVM	57.2 DVM	56.7 K-EK DVM	58.2 K-EK	56.7 K-EK DVM	57.7 DVM	57.5 DVM	58.8 DVM
56.7 K-EK	58.2 DVM	f8	56.7 K-EK	56.7 K-EK DVM	56.7 K-EK DVM	57.7 DVM	56.7 KA K-EK DVM	56.7 K-EK DVM	57.2 DVM	f16
56.7 K-EK DVM	f7	f8	58.8 KA	57.2 DVM	58.2 DVM	56.7 K-EK DVM	56.7 K-EK	58.2 DVM	56.7 K-EK DVM	f16
56.7 K-EK	f7	f8	f9	58.8 KA	58.2 KA	56.7 K-EK DVM	57.2 DVM	57.7 DVM	58.2 DVM	f16

56.7 K-EK DVM	f7	f8	f9	f10	60.8 DVM	57.2 K-EK	56.7 KA K-EK DVM	57.7 DVM	58.8 DVM	f16
56.7 K-EK DVM	f7	f8	f9	f10	f11	56.7 K-EK DVM	58.8 K-EK	56.1 K-EK DVM	61.1 KA	f16
59.3 K-EK DVM	f7	f8	f9	f10	f11	57.2 DVM	56.7 K-EK DVM	56.7 K-EK	f15	f16
f6	f7	f8	f9	f10	f11	62.9 KA	58.2 K-EK DVM	61.9 K-EK	f15	f16
f6	f7	f8	f9	f10	f11	f12	56.7 K-EK DVM	57.2 DVM	f15	f16
f6	f7	f8	f9	f10	f11	f12	f13	56.7 K-EK DVM	f15	f16

Tablo 3.2'deki istatistik öznitelikleri son 17 tanesi (f5-f21) kullanarak, Tablo 4.10'daki zaman düzlemindeki öznitelikleri seçimi için istatistik parametreleri ile eğitim kümeleri için elde edilen dörtlü sınıflandırma (Normal, Hafif, Orta ve Şiddetli Anksiyete) sonuçlarının ortalama doğrulukları gösterilmektedir. Dörtlü sınıflandırma sonuçlarına göre tek öznitelik kullanıldığında f6 özniteliğinin %60,8 ortalama doğruluk ile en yüksek sınıflandırma sonucunu verdiği görülmektedir. AİYÖS yöntemine göre f6 sabit tutularak ikinci adımda diğer öznitelikler ile f6'un birleştirilmesi ile elde edilen öznitelik kombinasyonlarının başarısı araştırılmıştır. Bu kombinasyonlar elde edilen başarıya düşene kadar veya özniteliklerin tamamı kullanılabilece kadar devam ettirilir. Fakat dörtlü sınıflandırmada yüksek başarıya altıncı adımda f6+f17+f7+f13+f8+f18 (4*6=24) öznitelik kombinasyonunun %61,9 eğitim kümesi ile ve %57,3 test kümesinde en iyi sonuca DVM ve K-EK ile ulaşılmıştır. Böylece, AİYÖS yöntemine göre iki sınıflandırma süreci tamamlanmıştır.

TBA ve KBA uygulandığında, eğitim kümesi için en iyi kombinasyonun f6+f17+f7+f13+f8+f18 (TBA için vektör üzgünlüğü 12 ve KBA için vektör üzgünlüğü 3) özniteliklerinden oluştuğu belirlenmiştir. Bu durumda, TBA için eğitim kümesinde %57,2 doğruluk değeri, KBA için ise %56,2 doğruluk değeri elde edilmiştir. Test kümesinde ise TBA için DVM ile %56,1 ve KBA için ise K-EK ile %54,9 doğruluk değeri elde edilmiştir. Öte yandan, TBA ve KBA uygulanmadığında aynı öznitelik

kombinasyonunun (vektör üzgünlüğü 24) test kümesinde %57,3 doğruluk değeri elde edilmiştir. Bu halde, TBA ve KBA uygulanmadığında başarımın daha yük olduğunu gözlemlenmiştir.

Tablo 4.10. İstatistik parametreleri kullanılarak AİYÖS yöntemiyle gerçekleştirilen dörtlü sınıflandırma eğitim kümesi sonuçları

f5	f6	f7	f8	f9	f10	f11	f12	f13	f14	f15	f16	f17	f18	f19	f20	f21
56.7 DVM	60.8 DVM	56.7 DVM K-EK	58.2 DVM	56.7 DVM K-EK	56.7 DVM K-EK	59.3 KA	56.7 DVM K-EK	58.2 DVM	56.7 DVM K-EK	56.7 DVM K-EK	56.7 DVM K-EK	59.3 KA	56.7 K-EK	56.7 K-EK	56.7 DVM K-EK	56.7 DVM K-EK
58.8 DVM	f6	58.2 DVM	58.2 DVM	58.8 K-EK	59.3 K-EK	56.7 DVM K-EK	57.2 K-EK	57.2 DVM	57.7 K-EK	59.8 K-EK	59.8 K-EK	61.9 DVM	58.2 DVM	58.2 DVM K-EK	58.8 DVM	56.7 DVM K-EK
56.7 DVM K-EK	f6	62.4 K-EK	59.3 DVM	59.3 DVM	58.2 DVM	56.7 DVM K-EK	56.7 DVM K-EK	58.8 DVM	56.7 DVM K-EK	58.8 K-EK	56.7 K-EK	f17	58.2 DVM K-EK	59.8 KA	58.2 KA	58.8 DVM
56.7 K-EK	f6	f7	57.7 K-EK	59.8 KA K-EK	59.3 DVM	57.7 DVM	58.8 K-EK	63.9 K-EK	62.9 KA	59.8 KA	57.2 DVM	f17	57.2 K-EK	57.7 DVM	59.8 KA	56.7 DVM K-EK
57.2 DVM	f6	f7	61.9 K-EK	60.3 KA	56.7 DVM K-EK	56.7 DVM K-EK	56.7 DVM K-EK	f13	57.7 K-EK	57.2 DVM	57.7 K-EK	f17	60.8 K-EK	56.7 DVM K-EK	59.3 DVM	57.7 DVM
56.7 DVM K-EK	f6	f7	f8	59.8 K-EK	60.3 YSA	56.7 DVM K-EK	56.7 DVM K-EK	f13	59.3 DVM	58.8 DVM	56.7 DVM K-EK	f17	61.9 DVM K-EK	57.7 DVM	59.3 DVM	58.8 K-EK
56.8 DVM K-EK	f6	f7	f8	57.2 DVM	60.8 K-EK	56.7 DVM K-EK	60.3 DVM	f13	60.3 DVM	61.3 KA	56.7 DVM K-EK	f17	f18	57.7 DVM K-EK	61.3 DVM	59.3 DVM
57.7 DVM	f6	f7	f8	60.8 K-EK	57.7 DVM	56.7 DVM K-EK	59.3 K-EK	f13	58.2 K-EK	f15	58.8 K-EK	f17	f18	56.7 K-EK	57.7 DVM	56.7 DVM K-EK
56.7 K-EK	f6	f7	f8	f9	57.2 DVM	56.7 DVM K-EK	57.2 DVM	f13	57.2 DVM	f15	60.8 DVM	f17	f18	56.7 DVM K-EK	57.2 DVM	60.8 DVM/ 52.4
59.3 DVM	f6	f7	f8	f9	58.2 DVM	56.7 DVM K-EK	57.2 K-EK	f13	58.8 DVM	f15	f16	f17	f18	58.2 DVM	56.7 DVM K-EK	56.7 DVM K-EK
f5	f6	f7	f8	f9	56.7 DVM K-EK	56.7 DVM K-EK	56.7 DVM K-EK	f13	57.2 DVM	f15	f16	f17	f18	56.7 DVM K-EK	60.3 K-EK	58.8 K-EK
f5	f6	f7	f8	f9	58.5 DVM	56.7 DVM K-EK	57.7 DVM	f13	60.8 K-EK	f15	f16	f17	f18	57.7 K-EK	f20	58.2 KA
f5	f6	f7	f8	f9	57.2 DVM	56.7 DVM K-EK	58.5 DVM	f13	f14	f15	f16	f17	f18	56.7 DVM K-EK	f20	59.3 KA
f5	f6	f7	f8	f9	56.7 DVM K-EK	57.2 DVM	57.7 DVM	f13	f14	f15	f16	f17	f18	56.7 DVM K-EK	f20	f21
f5	f6	f7	f8	f9	58.8 KA	57.2 DVM	f12	f13	f14	f15	f16	f17	f18	57.2 DVM	f20	f21
f5	f6	f7	f8	f9	f10	59.3 DVM	f12	f13	f14	f15	f16	f17	f18	58.8 DVM	f20	f21
f5	f6	f7	f8	f9	f10	56.1 DVM K-EK	f12	f13	f14	f15	f16	f17	f18	f19	f20	f21

Bu çalışmada elde edilen veriler hem kendi içerisinde hem de aynı veri tabanını kullanan Baghdadi ve ark. (Baghdadi vd, 2019), DakshMaheshwari 2021 ve M Agrawal, vd, 2021) çalışmaları ile karşılaştırılmıştır.

Bu çalışmada, ikili sınıflandırma için Tablo 4.11’te görüleceği üzere kullanılan üç öznitelik çıkarma yöntemlerden zaman-frekans düzlemi en yüksek performansı göstermiştir. Zaman-frekans düzlemi ile ADD kullanarak üç aile dalgacıklardan Db8 en iyi sonuç verdiğini görülmektedir. Bununla birlikte dört sınıflandırma yöntemden DVM en yüksek başarımı %68,3 doğruluk oranı vermiştir.

Dörtlü sınıflandırma ise Tablo 4.12’te görüleceği üzere bu çalışmada kullanılan üç öznitelik çıkarma yöntemlerden frekans düzlemi en yüksek performansı göstermiştir. Frekans düzlemi ile HFD kullanmaktadır. Bununla birlikte dört

sınıflandırma yöntemden DVM en yüksek başarımı %61 doğruluk oranı vermiştir.

Tablo 4.11. İkili sınıflandırma yöntemlerinin kendi içerisinde karşılaştırılması (test kümesi sonuçları)

	Dalgacık tipi	Sınıflandırıcı	Öznitelik sayısı	Doğruluk (%)
Frekans (HFD)	-	K-EK	20 (TBA)	63,4
Zaman- frekans (ADD)	Db8	DVM	16	68,3
	Coif4	DVM	1 (KBA)	59,8
	Sym2	K-EK	24 (TBA)	67,1
Zaman	-	DVM	3(TBA),1(KBA)	63,4

Tablo 4.12. Dörtlü sınıflandırma yöntemlerinin kendi içerisinde karşılaştırılması (test kümesi sonuçları)

	Dalgacık tipi	Sınıflandırıcı	Öznitelik sayısı	Doğruluk (%)
Frekans (HFD)		DVM	32 (KBA)	61
Zaman- frekans (ADD)	Db8	DVM	2 (KBA)	57,3
	Coif4	KA	12 (TBA)	57,3
	Sym2	DVM	24 (TBA)	56,1
Zaman		DVM, K-EK	24	57,3

Ayrıca bu çalışmada elde edilen veriler aynı veri tabanını kullanan Baghdadi ve ark. (Baghdadi vd, 2019), Mahesh ve ark. ve Agrawal ve ark. çalışmaları ile de karşılaştırılmıştır.

Baghdadi ve ark. (Baghdadi vd, 2019), DASPS veri setini oluşturmuşlardır., Analizlerinde çeşitli zaman , frekans, zaman-frekans düzlemi özniteliklerini ikili ve dörtlü sınıflandırmada kullanmışlardır.

Agrawal ve ark. (Agrawal vd, 2021), da aynı veri kümesi üzerinde çalışmışlar. Analizlerinde çeşitli zaman, frekans, zaman-frekans düzlemi özniteliklerini kullanmışlardır.


Mahesh ve ark. (Maheshwari vd, 2021) ise aynı veri kümesi üzerinde çalışmışlardır. Ancak sadece frekans düzlemi öznitelikleri kullanmışlardır.

Bu tez çalışmasında, DASPS adlı kamuya açık olan EEG sinyalleri veri kümesi kullanıldı ve literatürde bu veri kümesini kullanan çalışmaların (Baghdadi vd, 2019) sonuçları iyileştirilmeye çalışılmıştır. Bu çalışmada zaman, frekans, zaman-frekans düzlemi öznitelikleri kullanılmıştır. 15 saniyelik iz süresini dikkate aldıklarında Tablo 4.13'te görüleceği üzere, Baghdadi ve ark, (Baghdadi vd, 2019) yaptıkları çalışmada hem ikili hem de dörtlü sınıflandırma için 14 kanal EEG kullanarak en yüksek sonuçları zaman-frekans düzleminde elde etmişlerdir. Tüm alt frekans bantlarını ve 112 tane öznitelik kullanmışlardır. Öte yandan, Mahesh ve ark. (Maheshwari vd, 2021) sadece ikili sınıflandırma için 14 kanal EEG kullanmış ve sonuçları frekans düzleminde, alpha alt frekans bandı ve 828 adet öznitelik kullanarak elde etmişlerdir. Agrawal ve ark. (Agrawal vd, 2021) ise sadece ikili sınıflandırma için 14 kanal EEG kullanarak en yüksek sonuçları zaman düzleminde ve 56 tane öznitelik kullanarak elde etmişlerdir. Bu tez çalışmasında ise 14 kanal yerine 4 kanal EEG verisi ve sadece beta ve teta frekans bantlarıyla ikili sınıflandırmada 16 tane öznitelik, dörtlü sınıflandırmada ise 32 tane öznitelik ile daha iyi bir sonuç elde edilmiştir.

Tablo 4.13. Bu tez çalışmasının literatürdeki diğer çalışmalarla karşılaştırılması (test kümesi sonuçları)

Çalışma	Sınıf Sayısı	Kanal sayısı	Frekans bantı	Sınıflandırıcı	Öznitelik sayısı	Doğruluk (%)
(Baghdadi vd, 2019)	İkili	14	Alpha, beta, teta, gamma, delta	K-EK	112	67.00
	Dörtlü	14		DVM	112	59.10
(Maheshwari vd, 2021)	İkili	14	Alfa	YSA	828	57.14
(M Agrawal, vd, 2021)	İkili	14	Zaman	KA	56	70,25
Bu tezde	İkili	4	Beta, teta	DVM	16	68,30
	Dörtlü	4		DVM	32	61

Şekil 4.1’de gösterdiği gibi ikili ve dörtlü seviyeli kaygı sınıflandırması karışıklık matrisi sunmaktadır, karışıklık matrisi üzerinde yapılan Hassasiyet, Özgünlük, pozitif tahmin değeri, negatif tahmin değeri ve f1 puanı hesaplamaları Tablo 4.14 ve Tablo 4.15’te ikili ve dörtlü sınıflandırma için sırasıyla vermektedir.



Şekil 4.1. ikili ve dörtlü seviyeli DVM ile kaygı sınıflandırması karmaşıklık matrisi

Tablo 4.1. ve Tablo 4.2. ‘te genel olarak, F1 puanı, özellikle dengesiz veri kümesi durumunda, modelin performansını daha iyi değerlendiren bir metrik olduğu için önemlidir. Yüksek F1 puanları, modelin hem doğruluk hem de sınıf dengesi açısından başarılı olduğunu gösterirken, düşük F1 puanları, modelin sınıf dengesizliği nedeniyle performansının düşük olduğunu işaret eder. Bu nedenle, F1 puanı, özellikle modelin pozitif sınıfı iyi tahmin etme yeteneğini anlamak için dikkate alınmalıdır.

Tablo 4.14. İkili sınıf için test kümesi değerlendirme ölçütleri

	Doğruluk (%)	Hassasiyet (%)	Özgünlük (%)	pozitif tahmin değeri (%)	negatif Tahmin Değeri (%)	f1 puanı (%)
DVM	68,3	63	63	65	65	60
K-EK	63,4	50	50	31,7	31,7	38,8
KA	61	60	60	59,4	59,4	85,1
YSA	56,1	56,2	56,2	55,8	55,8	79,4

Tablo 4.15. Dörtlü sınıf için test kümesi değerlendirme ölçütleri

	Doğruluk (%)	Hassasiyet (%)	Özgünlük (%)	pozitif tahmin değeri(%)	negatif Tahmin Değeri (%)	f1 puanı (%)
--	--------------	----------------	--------------	--------------------------	---------------------------	--------------

DVM	61	31,3	30,3	28,9	81,7	29,9
K-EK	57,3	29,3	28,9	26,6	79,8	27,9
KA	58,5	31,4	30,6	28,2	81	29,7
YSA	65,1	29,1	28,7	26,3	79,2	27,7

5. SONUÇLAR

Bu çalışmada, anksiyete bozukluğu sınıflandırmasında DVM, K-EK, KA ve YSA olmak üzere dört tane yöntemin başarımı incelenmiştir. Hem İkili sınıflandırmada hem de dörtlü sınıflandırma DVM yöntemi en yüksek başarıyı vermiştir. 14 kanal EEG yerine 4 kanal kullanılarak ikili sınıflandırmada toplam 16 öznitelik, dörtlü sınıflandırmada ise 4 öznitelik kullanılmıştır. Böylelikle literatüre daha az sayıda yeni öznitelik alt kümeleri önerilmiştir. Literatürdeki bilgiler incelendiğinde beynin sağ tarafının görevlerinden bir tanesi de duygusal görevleri yerine getirmektir. Bu çalışmada kullanılan 4 kanaldan 3 tanesi beynin sağ tarafındaki elektrotlardan gelen EEG verileridir. Bu veriler, yapılan kanal azaltma işlemlerinin doğru yapıldığını göstermektedir.

Sonuç olarak bu çalışmada, literatürdeki çalışmalara göre daha az sayıda EEG kanalı, öznitelik vektörü ve alt frekans bandı kullanılarak daha yüksek sonuçlar elde edilmiştir. Aynı zamanda bu çalışmada öznitelik matrisinin boyutunda indirgeme yapılarak işlemsel hesap yükü ve süresi azaltılmıştır

Gelecekteki çalışmalarda, bir anksiyete bozukluğu sınıflandırma modeli oluşturmak için daha büyük 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.

KAYNAKLAR

- Abibullaev, B. and Zollanvari, A. 2021. A Systematic Deep Learning Model Selection for P300-Based Brain-Computer Interfaces. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 1-13.
- Agrawal, M., Anwar, M. A. and Sethia, D. (2021). Stacked Sparse Autoencoder and Machine Learning Based Anxiety Classification Using EEG Signals. The First International Conference on AI-ML-Systems, 1-7.
- Akmal, M., Zubair, S. and Alquhayz, H. J. I. A. 2021. Classification analysis of tensor-based recovered missing EEG data. 9, 41745-41756.
- Akmandor, A. O., H, Y. I. N. and Jha, N. K. 2018. Smart, Secure, Yet Energy-Efficient, Internet-of-Things Sensors. *IEEE Transactions on Multi-Scale Computing Systems*, 4:4, 914-930.
- Al-Qazzaz, N. K., Sabir, M. K., Ali, S. H. M., Ahmad, S. A., Grammer, K. and Ieee (2021). The Role of Spectral Power Ratio in Characterizing Emotional EEG for Gender Identification. IEEE-EMBS Conference on Biomedical Engineering and Sciences (IECBES) - Leading Modern Healthcare Technology Enhancing Wellness, Mar 01-03, 334-338, Electr Network.
- Al-Zubaidi, M. L. A. and Aras, S. (2022). Investigation of Appropriate Classification Method for EOG Based Human Computer Interface. 2022 30th Signal Processing and Communications Applications Conference (SIU), IEEE, 1-4.
- Alomari, M. H., Awada, E. A., Samaha, A., Alkamha, K. J. C. and Science, I. 2014. Wavelet-based feature extraction for the analysis of EEG signals associated with imagined fists and feet movements. 7:2, 17.
- Anuragi, A., Sisodia, D. S. and Pachori, R. B. 2020. Automated Alcoholism Detection Using Fourier-Bessel Series Expansion Based Empirical Wavelet Transform. *IEEE Sensors Journal*, 20:9, 4914-4924.
- Arsalan, A., Majid, M. J. J. o. A. I. and Computing, H. 2021. A study on multi-class anxiety detection using wearable EEG headband. 1-11.
- Asif, A., Majid, M., Anwar, S. M. J. C. i. b. and medicine 2019. Human stress classification using EEG signals in response to music tracks. 107, 182-196.
- Aslam, A. R., Hafeez, N., Heidari, H. and Altaf, M. A. B. J. F. i. N. 2022. Channels and Feature Identification with Large Scale Feature Extraction for Emotions and ASD Classification. 1094.
- Avilov, O., Rimbert, S., Popov, A. and Bougrain, L. 2021. Optimizing Motor Intention Detection With Deep Learning: Towards Management of Intraoperative Awareness. *IEEE Transactions on Biomedical Engineering*, 68:10, 3087-3097.
- AYDEMİR, Ö. J. D. Ü. M. F. M. D. 2017. Ardışıl ileri yönlü öznelik seçim algoritmasında etkin özneliklerin belirlenmesi. 8:3, 495-501.
- Aydin, S., Demirtaş, S., Ateş, K. and Tunga, M. A. J. I. j. o. n. s. 2016. Emotion recognition with eigen features of frequency band activities embedded in induced brain oscillations mediated by affective pictures. 26:03, 1650013.
- Baghdadi, A., Aribi, Y., Fourati, R., Halouani, N., Siarry, P. and Alimi, A. M. J. a. p. a. 2019. DASPS: A Database for Anxious States based on a Psychological Stimulation.
- Banluesombatkul, N., Ouppaphan, P., Leelaarporn, P., Lakhan, P., Chaitusaney, B., Jaimchariyatam, N., Chuangsuwanich, E., Chen, W., Phan, H., Dilokthanakul, N. and Wilaiprasitporn, T. 2021. MetaSleepLearner: A Pilot Study on Fast Adaptation of Bio-

- Signals-Based Sleep Stage Classifier to New Individual Subject Using Meta-Learning. *IEEE Journal of Biomedical and Health Informatics*, 25:6, 1949-1963.
- Brunner, C., Delorme, A. and Makeig, S. J. B. E. B. T. 2013. Eeglab—an open source matlab toolbox for electrophysiological research. 58:SI-1-Track-G, 000010151520134182.
- Cao, J., Chen, L., Hu, D., Dong, F., Jiang, T., Gao, W. and Gao, F. 2021. Unsupervised Eye Blink Artifact Detection From EEG With Gaussian Mixture Model. *IEEE Journal of Biomedical and Health Informatics*, 25:8, 2895-2905.
- Cecotti, H. and Graser, A. 2011. Convolutional Neural Networks for P300 Detection with Application to Brain-Computer Interfaces. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 33:3, 433-445.
- Chang, Q., Li, C., Tian, Q., Bo, Q., Zhang, J., Xiong, Y. and Wang, C. 2021. Classification of First-Episode Schizophrenia, Chronic Schizophrenia and Healthy Control Based on Brain Network of Mismatch Negativity by Graph Neural Network. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 29, 1784-1794.
- Charbuty, B., Abdulazeez, A. J. J. o. A. S. and Trends, T. 2021. Classification based on decision tree algorithm for machine learning. 2:01, 20-28.
- Chen, C., Yu, X., Belkacem, A. N., Lu, L., Li, P., Zhang, Z., Wang, X., Tan, W., Gao, Q., Shin, D. J. J. o. m. and engineering, b. 2021. EEG-based anxious states classification using affective BCI-based closed neurofeedback system. 41:2, 155-164.
- Chen, D., Wan, S., Xiang, J. and Bao, F. S. J. P. o. 2017. A high-performance seizure detection algorithm based on Discrete Wavelet Transform (DWT) and EEG. 12:3, e0173138.
- de Magalhaes Júnior, R. G., Rocha, F. T. and Thomaz, C. E. J. I. L. A. T. 2021. Comparison Between Linear and Tensor Models of EEG Signals Representation. 19:01, 132-137.
- Delorme, A. and Makeig, S. J. J. o. n. m. 2004. EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. 134:1, 9-21.
- Delvigne, V., Wannous, H., Dutoit, T., Ris, L. and Vandeborre, J. P. 2021. PhyDAA: Physiological Dataset Assessing Attention. *IEEE Transactions on Circuits and Systems for Video Technology*, 1-1.
- Durongbhan, P., Zhao, Y., Chen, L., Zis, P., Marco, M. D., Unwin, Z. C., Venneri, A., He, X., Li, S., Zhao, Y., Blackburn, D. J. and Sarrianni, P. G. 2019. A Dementia Classification Framework Using Frequency and Time-Frequency Features Based on EEG Signals. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 27:5, 826-835.
- Dzedzickis, A., Kaklauskas, A. and Bucinskas, V. J. S. 2020. Human emotion recognition: Review of sensors and methods. 20:3, 592.
- Erdoğan, H. J. Y. T. Ü. F. B. E. Y. D. T., İstanbul 2006. Mühendislik yapılarındaki dinamik davranışların jeodezik ölçmelerle belirlenmesi.
- Farsi, L., Siuly, S., Kabir, E. and Wang, H. 2021. Classification of Alcoholic EEG Signals Using a Deep Learning Method. *IEEE Sensors Journal*, 21:3, 3552-3560.
- Giannakakis, G., Padiaditis, M., Manousos, D., Kazantzaki, E., Chiarugi, F., Simos, P. G., Marias, K., Tsiknakis, M. J. B. S. P. and Control 2017. Stress and anxiety detection using facial cues from videos. 31, 89-101.
- Graupe, D. 2013. *Principles of artificial neural networks*. World Scientific,
- Guerrero, M. C., Parada, J. S. and Espitia, H. E. 2021. EEG signal analysis using classification techniques: Logistic regression, artificial neural networks, support vector machines, and convolutional neural networks. *Heliyon*, 7:6, e07258.

- Hindarto, H., Muntasa, A. and Sumarno, S. (2019). Fourier transform for feature extraction of Electro Encephalo Graph (EEG) signals. 4th Annual Applied Science and Engineering Conference (AASEC), Apr 24, Univ Pendidikan Indonesia, Sch Postgraduate Studies, Tech & Vocat Educ St, Bali, INDONESIA.
- Jacob, S., Menon, V. G., Al-Turjman, F., V. P, G. and Mostarda, L. 2019. Artificial Muscle Intelligence System With Deep Learning for Post-Stroke Assistance and Rehabilitation. *IEEE Access*, 7, 133463-133473.
- Jang, S.-W. and Lee, S.-H. J. S. 2020. Detection of epileptic seizures using wavelet transform, peak extraction and PSR from EEG signals. 12:8, 1239.
- Jeong, J. H., Shim, K. H., Kim, D. J. and Lee, S. W. 2020. Brain-Controlled Robotic Arm System Based on Multi-Directional CNN-BiLSTM Network Using EEG Signals. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 28:5, 1226-1238.
- Jeong, T. 2020. Time-Series Data Classification and Analysis Associated With Machine Learning Algorithms for Cognitive Perception and Phenomenon. *IEEE Access*, 8, 222417-222428.
- Jin, X., Tang, J., Kong, X., Peng, Y., Cao, J., Zhao, Q. and Kong, W. 2021. CTNN: A Convolutional Tensor-Train Neural Network for Multi-Task Brainprint Recognition. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 29, 103-112.
- Juliana, M. J. M. and Rangaswamy, N. (2018). A Neoteric Approach Towards Anxiety Quantification by EEG Signal Analysis. 2018 International Conference on Power, Energy, Control and Transmission Systems (ICPECTS), IEEE, 51-59.
- Kakkos, I., Dimitrakopoulos, G. N., Sun, Y., Yuan, J., Matsopoulos, G. K., Bezerianos, A. and Sun, Y. 2021. EEG Fingerprints of Task-Independent Mental Workload Discrimination. *IEEE Journal of Biomedical and Health Informatics*, 25:10, 3824-3833.
- Khare, S. K. and Bajaj, V. 2021. Time–Frequency Representation and Convolutional Neural Network-Based Emotion Recognition. *IEEE Transactions on Neural Networks and Learning Systems*, 32:7, 2901-2909.
- Kim, K. T., Suk, H. I. and Lee, S. W. 2018. Commanding a Brain-Controlled Wheelchair Using Steady-State Somatosensory Evoked Potentials. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26:3, 654-665.
- Klepl, D., He, F., Wu, M., Marco, M. D., Blackburn, D. and Sarrigiannis, P. G. 2021. Characterising Alzheimer's Disease with EEG-based Energy Landscape Analysis. *IEEE Journal of Biomedical and Health Informatics*, 1-1.
- Kottaimalai, R., Rajasekaran, M. P., Selvam, V. and Kannapiran, B. (2013). EEG signal classification using principal component analysis with neural network in brain computer interface applications. 2013 IEEE international conference on emerging trends in computing, communication and nanotechnology (ICECCN), IEEE, 227-231.
- Lekshmi, S., Selvam, V. and Rajasekaran, M. P. (2014). EEG signal classification using principal component analysis and wavelet transform with neural network. 2014 International Conference on Communication and Signal Processing, IEEE, 687-690.
- Li, K., Zhang, X. and Du, Y. (2013). A SVM based classification of EEG for predicting the movement intent of human body. 2013 10th International Conference on Ubiquitous Robots and Ambient Intelligence (URAI), IEEE, 402-406.
- Li, M., Xu, H., Liu, X., Lu, S. J. T. and care, h. 2018. Emotion recognition from multichannel EEG signals using K-nearest neighbor classification. 26:S1, 509-519.
- Li, Z., Wu, X., Xu, X., Wang, H., Guo, Z., Zhan, Z. and Yao, L. J. I. T. o. A. C. 2019. The recognition of multiple anxiety levels based on electroencephalograph.

- Lin, C., Chuang, C., Huang, C., Tsai, S., Lu, S., Chen, Y. and Ko, L. 2014. Wireless and Wearable EEG System for Evaluating Driver Vigilance. *IEEE Transactions on Biomedical Circuits and Systems*, 8:2, 165-176.
- Lu, N., Li, T., Ren, X. and Miao, H. 2017. A Deep Learning Scheme for Motor Imagery Classification based on Restricted Boltzmann Machines. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25:6, 566-576.
- Ma, Y., Ding, X., She, Q., Luo, Z., Potter, T., Zhang, Y. J. C. and medicine, m. m. i. 2016. Classification of motor imagery EEG signals with support vector machines and particle swarm optimization. 2016.
- Mahesh, B. J. I. J. o. S. and ., R. 2020. Machine learning algorithms-a review. 9, 381-386.
- Maheshwari, D., Ghosh, S. K., Tripathy, R., Sharma, M., Acharya, U. R. J. C. i. B. and Medicine 2021. Automated accurate emotion recognition system using rhythm-specific deep convolutional neural network technique with multi-channel EEG signals. 134, 104428.
- MalathiRavindran, R. and Ieee (2014). Classification of Human Emotions from EEG Signals using Filtering and ANFIS Classifier. 2nd International Conference on Current Trends In Engineering and Technology (ICCTET), Jul 08, 113-119, Coimbatore, INDIA.
- Meng, X. and Zhang, J. J. I. A. 2020. Anxiety recognition of college students using a Takagi-Sugeno-Kang fuzzy system modeling method and deep features. 8, 159897-159905.
- Mirzaei, S., Ghasemi, P. J. B. S. P. and Control 2021. EEG motor imagery classification using dynamic connectivity patterns and convolutional autoencoder. 68, 102584.
- Mohan, Y., Chee, S. S., Xin, D. K. P. and Foong, L. P. (2016). Artificial neural network for classification of depressive and normal in EEG. 2016 IEEE EMBS conference on biomedical engineering and sciences (IECBES), IEEE, 286-290.
- Mokatren, L. S., Ansari, R., Cetin, A. E., Leow, A. D., Ajilore, O., Klumpp, H. and Vural, F. T. Y. (2019). EEG classification based on image configuration in social anxiety disorder. 2019 9th International IEEE/EMBS Conference on Neural Engineering (NER), IEEE, 577-580.
- Na, J., Wang, Z., Lv, S. and Xu, Z. J. I. A. 2021. An Extended K Nearest Neighbors-Based Classifier for Epilepsy Diagnosis. 9, 73910-73923.
- Nazir, T., Qi, X. and Silvestrov, S. 2016. *Engineering Mathematics II*. Springer, 355-375.
- Novak, D., Omlin, X., Leins-Hess, R. and Riener, R. 2013. Predicting Targets of Human Reaching Motions Using Different Sensing Technologies. *IEEE Transactions on Biomedical Engineering*, 60:9, 2645-2654.
- OMAR, S. Q. O. and Cengiz, T. J. B. Ü. F. B. D. 2022. EEG Sinyallerini İşlemek İçin Makine Öğreniminin Kullanıldığı Konular Üzerine Bir İnceleme. 5:1, 124-137.
- Park, S. M., Jeong, B., Oh, D., Choi, C. H., Jung, H. Y., Lee, J. Y., Lee, D. and Choi, J. S. 2021. Identification of Major Psychiatric Disorders From Resting-State Electroencephalography Using a Machine Learning Approach. *Frontiers in Psychiatry*, 12.
- Pascual, D., Amirshahi, A., Aminifar, A., Atienza, D., Ryvlin, P. and Wattenhofer, R. 2021. EpilepsyGAN: Synthetic Epileptic Brain Activities With Privacy Preservation. *IEEE Transactions on Biomedical Engineering*, 68:8, 2435-2446.
- Penchina, B., Sundaresan, A., Cheong, S., Grace, V., Valero-Cabré, A. and Martel, A. 2020a. Evaluating deep learning EEG-based anxiety classification in adolescents with autism for breathing entrainment BCI.

- Penchina, B., Sundaresan, A., Cheong, S. and Martel, A. (2020b). Deep LSTM recurrent neural network for anxiety classification from EEG in adolescents with autism. *International Conference on Brain Informatics*, Springer, 227-238.
- Raghu, S. and Sriraam, N. J. E. S. w. A. 2018. Classification of focal and non-focal EEG signals using neighborhood component analysis and machine learning algorithms. 113, 18-32.
- Rahman, M. M., Bhuiyan, M. I. H., Hassan, A. R. J. C. i. b. and medicine 2018. Sleep stage classification using single-channel EOG. 102, 211-220.
- Rajendran, V., Jayalalitha, S. and Adalarasu, K. J. I. 2022. EEG Based Evaluation of Examination Stress and Test Anxiety Among College Students. 43:5, 349-361.
- Santos-Mayo, L., San-José-Revuelta, L. M. and Arribas, J. I. 2017. A Computer-Aided Diagnosis System With EEG Based on the P3b Wave During an Auditory Odd-Ball Task in Schizophrenia. *IEEE Transactions on Biomedical Engineering*, 64:2, 395-407.
- Scholler, S., Bosse, S., Treder, M. S., Blankertz, B., Curio, G., Muller, K. and Wiegand, T. 2012. Toward a Direct Measure of Video Quality Perception Using EEG. *IEEE Transactions on Image Processing*, 21:5, 2619-2629.
- Sharma, H., Raj, R. and Juneja, M. J. N. I. 2019. EEG signal based classification before and after combined Yoga and Sudarshan Kriya. 707, 134300.
- Sharma, R. (2017). EEG signal denoising based on wavelet transform. 2017 International conference of Electronics, Communication and Aerospace Technology (ICECA), IEEE, 758-761.
- Sharmila, A. and Geethanjali, P. J. I. A. 2016. DWT based detection of epileptic seizure from EEG signals using naive Bayes and k-NN classifiers. 4, 7716-7727.
- Shen, Z., Li, G., Fang, J., Zhong, H., Wang, J., Sun, Y. and Shen, X. J. S. 2022. Aberrated Multidimensional EEG Characteristics in Patients with Generalized Anxiety Disorder: A Machine-Learning Based Analysis Framework. 22:14, 5420.
- Sreeja, S. R., Sahay, R. R., Samanta, D. and Mitra, P. 2018. Removal of Eye Blink Artifacts From EEG Signals Using Sparsity. *IEEE Journal of Biomedical and Health Informatics*, 22:5, 1362-1372.
- Sun, B., Zhao, X., Zhang, H., Bai, R. and Li, T. 2021. EEG Motor Imagery Classification With Sparse Spectrotemporal Decomposition and Deep Learning. *IEEE Transactions on Automation Science and Engineering*, 18:2, 541-551.
- Supratak, A., Dong, H., Wu, C. and Guo, Y. 2017. DeepSleepNet: A Model for Automatic Sleep Stage Scoring Based on Raw Single-Channel EEG. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25:11, 1998-2008.
- Suzuki, K. 2013. *Artificial neural networks: Architectures and applications*. BoD—Books on Demand,
- Tazrin, T., Rahman, Q. A., Fouda, M. M. and Fadlullah, Z. M. 2021. LiHEA: Migrating EEG Analytics to Ultra-Edge IoT Devices With Logic-in-Headbands. *IEEE Access*, 9, 138834-138848.
- Trambaiolli, L. R. and Biazoli, C. E. (2020). Resting-state global EEG connectivity predicts depression and anxiety severity. 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), IEEE, 3707-3710.
- Tripp, C., Huber, N. L., Kuhl, E. A., Sears, S. F. J. P. and Electrophysiology, C. 2019. Measuring ICD shock anxiety: Status update on the Florida Shock Anxiety Scale after over a decade of use. 42:10, 1294-1301.

- Umrani, A. T., Harshavardhanan, P. J. B. S. P. and Control 2022. Hybrid feature-based anxiety detection in autism using hybrid optimization tuned artificial neural network. 76, 103699.
- Vivaldi, N., Caiola, M., Solarana, K. and Ye, M. 2021. Evaluating Performance of EEG Data-Driven Machine Learning for Traumatic Brain Injury Classification. *IEEE Transactions on Biomedical Engineering*, 68:11, 3205-3216.
- Wilaiprasitporn, T., Ditthaporn, A., Matchaparn, K., Tongbuasirilai, T., Banluesombatkul, N. and Chuangsuwanich, E. 2020. Affective EEG-Based Person Identification Using the Deep Learning Approach. *IEEE Transactions on Cognitive and Developmental Systems*, 12:3, 486-496.
- Xie, Y., Yang, B., Lu, X., Zheng, M., Fan, C., Bi, X. and Li, Y. (2020). Anxiety and depression diagnosis method based on brain networks and convolutional neural networks. 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), IEEE, 1503-1506.
- Yamada, K., bin Wan Hamat, W. J., bin Ishak, H. M., Hashikura, K., Suzuki, T. J. E. T. o. E. E., Electronics, and Communications 2019. Detection of Anxiety Expression From EEG Analysis Using Support Vector Machine. 17:1, 87-94.
- Yoo, J., Yan, L., El-Damak, D., Altaf, M. A. B., Shueb, A. H. and Chandrakasan, A. P. 2013. An 8-Channel Scalable EEG Acquisition SoC With Patient-Specific Seizure Classification and Recording Processor. *IEEE Journal of Solid-State Circuits*, 48:1, 214-228.
- Zhang, G., Davoodnia, V., Sepas-Moghaddam, A., Zhang, Y. and Etemad, A. 2020a. Classification of Hand Movements From EEG Using a Deep Attention-Based LSTM Network. *IEEE Sensors Journal*, 20:6, 3113-3122.
- Zhang, G. and Etemad, A. 2021. Capsule Attention for Multimodal EEG-EOG Representation Learning With Application to Driver Vigilance Estimation. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 29, 1138-1149.
- Zhang, P., Wang, X., Zhang, W. and Chen, J. 2019. Learning Spatial–Spectral–Temporal EEG Features With Recurrent 3D Convolutional Neural Networks for Cross-Task Mental Workload Assessment. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 27:1, 31-42.
- Zhang, X., Pan, J., Shen, J., Din, Z. U., Li, J., Lu, D., Wu, M. and Hu, B. J. I. T. o. A. C. 2020b. Fusing of electroencephalogram and eye movement with group sparse canonical correlation analysis for anxiety detection.
- Zhang, Y. 2010. *New advances in machine learning*. BoD–Books on Demand,
- Zhang, Y., Lin, Y., Qu, Z., Zhang, Z., Guo, D., Chen, X., Shu, H., Yu, S. J. J. o. M. and Engineering, B. 2022. Identifying Patients with Epilepsy Having Depression/Anxiety Disorder Using Common Spatial Patterns of Functional EEG Networks. 1-10.
- Zhao, W., Qu, J., Chai, Y. and Tang, J. (2016). Classification of Seizure in EEG Signals Based on KPCA and SVM. Proceedings of the 2015 Chinese Intelligent Systems Conference, Springer, 201-207.
- Zheng, W., Zhu, J. and Lu, B. 2019. Identifying Stable Patterns over Time for Emotion Recognition from EEG. *IEEE Transactions on Affective Computing*, 10:3, 417-429.
- Zheng, Y., Wong, T. C., Leung, B. H. and Poon, C. C. J. I. S. J. 2016. Unobtrusive and multimodal wearable sensing to quantify anxiety. 16:10, 3689-3696.
- Zhou, L. J. I. J. o. B. 2022. Recognition of depression patients with electroencephalogram. 14:3-4, 481-491.

Zhou, Z.-H. 2021. *Machine learning*. Springer Nature,

URL1.< <https://medium.com/deep-learning-turkiye/nedir-bu-destek-vekt%C3%B6r-makineleri-makine-%C3%B6%C4%9Frenmesi-serisi-2-94e576e4223e/>>, Erişim tarihi 9 Ocak 2022.

URL2. < <https://helloacm.com/a-short-introduction-to-k-nearest-neighbors-algorithm/>>, Erişim tarihi 2 Ocak 2022.



ÖZ GEÇMİŞ

Shams Qahtan Omar OMAR, Irak'ta Anbar Üniversitesi Mühendislik Fakültesi, Elektrik Mühendisliği bölümünden 2015 yılında mezun oldu. 2021 yılında OMÜ LEE Akıllı Sistemler Mühendisliği Ana Bilim Dalı Yüksek Lisans programına girdi.

İletişim Bilgileri

ORCID ID : 0000-0002-9528-5875

Yayınlar:

1. OMAR, S. Q. O. and Cengiz, T. J. B. Ü. F. B. D. 2022. EEG Sinyallerini İşlemek İçin Makine Öğreniminin Kullanıldığı Konular Üzerine Bir İnceleme. Bayburt Üniversitesi Fen Bilimleri Dergisi, 5:1, 124-137. DOI: 10.55117/bufbd.1099025
2. OMAR, S. Q. O. and Cengiz, T. J. B. Ü. F. B. D. 2023. EEG İşareti tabanlı anksiyete sınıflandırması için Dalgacık dönüşümü ile öznelilik çıkarma. Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi, Cilt 12, Sayı 3, 2023. DOI: 10.28948/ngumuh.1230092