



T.C.

Ardahan Üniversitesi

Lisansüstü Eğitim Enstitüsü

İleri Teknolojiler Ana Bilim Dalı

İleri Teknolojiler

EEG SİNYALLERİNİ KULLANAN MAKİNE ÖĞRENMESİ TABANLI KATEGORİK DUYGU SINIFLANDIRMA MODELİ

Hakan KÖKSAL

Doç. Dr. Mehmet BAYĞIN

Yüksek Lisans Tezi

Ardahan, 2023

EEG SİNYALLERİNİ KULLANAN MAKİNE ÖĞRENMESİ TABANLI
KATEGORİK DUYGU SINIFLANDIRMA MODELİ

Hakan KÖKSAL

Doç. Dr. Mehmet BAYĞIN

Ardahan Üniversitesi Lisansüstü Eğitim Enstitüsü
İleri Teknolojiler Ana Bilim Dalı
İleri Teknolojiler

Yüksek Lisans Tezi

Ardahan, 2023

KABUL VE ONAY

Hakan KÖKSAL tarafından hazırlanan “EEG Sinyallerini Kullanan Makine Öğrenmesi Tabanlı Kategorik Duygu Sınıflandırma Modeli” başlıklı bu çalışma, 25.04.2023 tarihinde yapılan savunma sınavı sonucunda başarılı bulunarak jürimiz tarafından yüksek lisans tezi olarak kabul edilmiştir.

Doç. Dr. Türker TUNCER(Başkan)

Doç. Dr. Mehmet BAYĞIN (Danışman)

Dr. Öğr. Üyesi Arif Cem TOPUZ

Yukarıdaki imzaların adı geçen öğretim üyelerine ait olduğunu onaylarım.

Prof. Dr. Mustafa ŞENEL

Enstitü Müdürü

YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezimin tamamını veya herhangi bir kısmını, basılı (kağıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma iznini Ardahan Üniversitesine verdiğimi bildiririm. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları bana ait olacaktır.

Tezin kendi orijinal çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinleri yazılı izin alınarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim Kurulu tarafından yayınlanan **“Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge”** kapsamında tezim aşağıda belirtilen koşullar haricince YÖK Ulusal Tez Merkezi / Ardahan Üniversitesi Açık Erişim Sisteminde erişime açılır.

- Enstitü / Fakülte yönetim kurulu kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren 2 yıl ertelenmiştir. ⁽¹⁾
- Enstitü / Fakülte yönetim kurulunun gerekçeli kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren ay ertelenmiştir. ⁽²⁾
- Tezimle ilgili gizlilik kararı verilmiştir. ⁽³⁾

25/04/2023

Hakan KÖKSAL

“Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge”

(1) Madde 6. 1. Lisansüstü teze ilgili patent başvurusu yapılması veya patent alma sürecinin devam etmesi durumunda, tez **danışmanının** önerisi ve **enstitü anabilim dalının** uygun görüşü üzerine **enstitü** veya **fakülte yönetim kurulu** iki yıl süre ile tezin erişime açılmasının ertelenmesine karar verebilir.

(2) Madde 6. 2. Yeni teknik, materyal ve metotların kullanıldığı, henüz makaleye dönüşmemiş veya patent gibi yöntemlerle korunmamış ve internetten paylaşılması durumunda 3. şahıslara veya kurumlara haksız kazanç imkanı oluşturabilecek bilgi ve bulguları içeren tezler hakkında tez **danışmanının** önerisi ve **enstitü anabilim dalının** uygun görüşü üzerine **enstitü** veya **fakülte yönetim kurulunun** gerekçeli kararı ile altı ayı aşmamak üzere tezin erişime açılması engellenebilir.

(3) Madde 7. 1. Ulusal çıkarları veya güvenliği ilgilendiren, emniyet, istihbarat, savunma ve güvenlik, sağlık vb. konulara ilişkin lisansüstü tezlerle ilgili gizlilik kararı, **tezin yapıldığı kurum** tarafından verilir *. Kurum ve kuruluşlarla yapılan işbirliği protokolü çerçevesinde hazırlanan lisansüstü tezlere ilişkin gizlilik kararı ise, **ilgili kurum ve kuruluşun önerisi** ile **enstitü** veya **fakültenin** uygun görüşü üzerine **üniversite yönetim kurulu** tarafından verilir. Gizlilik kararı verilen tezler Yükseköğretim Kuruluna bildirilir.

Madde 7.2. Gizlilik kararı verilen tezler gizlilik süresince enstitü veya fakülte tarafından gizlilik kuralları çerçevesinde muhafaza edilir, gizlilik kararının kaldırılması halinde Tez Otomasyon Sistemine yüklenir.

* Tez **danışmanının** önerisi ve **enstitü anabilim dalının** uygun görüşü üzerine **enstitü** veya **fakülte yönetim kurulu** tarafından karar verilir.

ETİK BEYAN

Bu alıřmadaki bütn bilgi ve belgeleri akademik kurallar erevesinde elde ettiđimi, grsel, iřitsel ve yazılı tm bilgi ve sonuları bilimsel ahlak kurallarına uygun olarak sunduđumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, yararlandığım kaynaklara bilimsel normlara uygun olarak atıfta bulunduđumu, tezimin kaynak gsterilen durumlar dıřında zgn olduđunu, Tezin **Do. Dr. Mehmet BAYĐIN** danıřmanlığında tarafımdan retildiđini ve Ardahan niversitesi Lisansst Eđitim Enstits Tez Yazım Ynergesine gre yazıldıđını beyan ederim.

Hakan KKSAL

TEŞEKKÜR

Bu tez çalışmasının her aşamasında bana her anlamda desteğini esirgemeyen, önerileri ve birikimleriyle beni yönlendiren, tezime büyük katkı sağlayan başta danışman hocam Doç. Dr. Mehmet BAYĞIN'a çok teşekkür ederim.

Bilimsel araştırmalar konusunda kendisinden çok şey öğrendiğim Dr. Öğr. Üyesi Arif Cem TOPUZ'a ve derslerine girdiğim bütün üniversite hocalarıma saygı ve sevgiyle teşekkür ederim.

Çalışmamızın veri setinin hazırlanmasında büyük katkıları olan görev yaptığım Ardahan Kazım Karabekir Yatılı Bölge Okulu Müdürü Fatih ÖZDEMİR'e, M. Yardımcılarımız Gülşah AYDEMİR'e ve Umut ÖZTÜRK'e, tüm öğretmenlerimize ve duygu konusunda bilgilerinden faydalandığım psikolojik danışmanımız Selin KARADAĞ YILMAZ'a sonsuz teşekkür ederim.

Ayrıca, bu tez çalışmasında manevi desteklerini hiçbir zaman esirgemeyen ve göstermiş olduğu sabırdan dolayı değerli eşim Gülşen Arslan KÖKSAL'a ve canım oğlum İbrahim Aybars KÖKSAL'a teşekkürü borç bilirim.

ÖZET

KÖKSAL, Hakan. *EEG Sinyallerini Kullanan Makine Öğrenmesi Tabanlı Kategorik Duygu Sınıflandırma Modeli*, Yüksek Lisans Tezi, Ardahan, 2023.

Son yıllarda otomatik duygu tespiti ve sınıflandırma literatürde sıklıkla çalışılan konuların başında gelmektedir. Duygular, bireylerin dış dünyayla olan ilişkilerinde, aldığı kararlarda ve eylemlerde etkili olmaktadır. Bu nedenle duygu tanıma insan bilgisayar etkileşiminde önemli bir role sahiptir. Literatür çalışmaları duyguların tespitinde EEG sinyallerinin bazı nörolojik ve beyinsel aktiviteleri tespit edebileceğini göstermektedir. Bu tez çalışmasında, duyguların tespiti ve analizi için ayırt edici nitelik taşıyan sinyaller üretildiğinden EEG sinyalleri kullanılmıştır. Bu kapsamda özgün bir veri seti oluşturulması ve EEG sinyal yorumlaması için etkili yöntemler önerilerek yüksek doğruluğa sahip otomatik duygu tanıma için yeni bir makine öğrenmesi modeli geliştirilmesi amaçlanmıştır. Yeni geliştirilen bu modelle, özgün veri seti kullanılarak özellik çıkarma, özellik seçimi ve sınıflandırma olmak üzere makine öğrenmesi modelinin tüm aşamaları gerçekleştirilmiştir. Bu çalışmada, VitC-Pat (Vitamin C Pattern) tabanlı bir özellik çıkarıcı önerilmiştir. Ek olarak, EEG sinyallerini alt bantlara ayırmak için Ayrık Dalgacık Dönüşümü (DWT) tabanlı decomposition yöntemi kullanılmıştır. Geliştirilen modelin özellik çıkarma fazında VitC-Pat, Yerel İkili Örüntüler (LBP) ve istatistiksel yöntemler kullanılmıştır. Makine öğrenmesi modelinin ikinci fazında özellik seçme işlemi uygulanmıştır. Bu aşamada, İteratif Komşuluk Bileşen Analizi (INCA) yöntemi kullanılmış olup, geliştirilen modelin son aşamasında ise Destek Vektör Makineleri (SVM) kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Tez çalışması kapsamında özgün olarak toplanan veri seti üzerinde test edilen bu model ile Arousal eksenini için %92.74 ve Valence için %96.85 doğruluk değerleri sağlanmıştır.

Anahtar Sözcükler:

EEG, makine öğrenmesi, duygu tanıma, sınıflandırma

ABSTRACT

KÖKSAL, Hakan. *Machine Learning-Based Categorical Emotion Classification Model Using EEG Signals*, Master's Thesis, Ardahan, 2023.

In recent years, automatic emotion detection and classification is one of the most frequently studied topics in the literature. Emotions are effective in individuals' relations with the outside world, in their decisions and actions. Therefore, emotion recognition has an important role in human-computer interaction. Literature studies show that EEG signals can detect some neurological and cerebral activities in detecting emotions. In this thesis, EEG signals were used as distinctive signals were produced for the detection and analysis of emotions. In this context, it is aimed to develop a new machine learning model for automatic emotion recognition with high accuracy by creating a unique data set and proposing effective methods for EEG signal interpretation. With this newly developed model, all stages of the machine learning model, including feature extraction, feature selection and classification, were carried out using the original data set. In this study, a feature extractor based on VitC-Pat (Vitamin C Pattern) is proposed. In addition, the Discrete Wavelet Transform (DWT) based decomposition method was used to separate the EEG signals into subbands. In the feature extraction phase of the developed model, VitC-Pat, Local Binary Patterns (LBP) and statistical methods were used. In the second phase of the machine learning model, feature selection is applied. At this stage, the Iterative Neighborhood Component Analysis (INCA) method was used, and in the last stage of the developed model, the classification process was carried out using Support Vector Machines (SVM). With this model, which was tested on the data set originally collected within the scope of the thesis study, accuracy values of 92.74% for the Arousal axis and 96.85% for Valence were provided.

Keywords:

EEG, machine learning, emotion recognition, classification

İÇİNDEKİLER

KABUL VE ONAY	
YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI BEYANI.....	
ETİK BEYAN.....	
TEŞEKKÜR	
ÖZET.....	5
ABSTRACT	6
İÇİNDEKİLER	7
KISALTMALAR DİZİNİ	9
TABLolar DİZİNİ	10
ŞEKİLLER DİZİNİ	11
SİMGELER DİZİNİ	12
GİRİŞ	13
1.BÖLÜM.....	15
1.1. TEZİN AMACI VE KAPSAMI	15
1.2. TEZİN YAPISI	16
2. BÖLÜM.....	17
EEG TABANLI DUYGU TANIMA.....	17
2.1. EEG (ELEKTROENSEFALOGRAFİ)	17
2.2. DUYGU TANIMADA EEG	17
2.3. LİTERATÜR ÖZETİ	18
3. BÖLÜM.....	33
MATERYAL	33
3.1. DENEY PROSEDÜRÜ	33
4. BÖLÜM.....	37
ÖNERİLEN YÖNTEM	37
4.1. VITC-PAT TABANLI OTOMATİK DUYGU SINIFLANDIRMA MODELİ.....	37
4.2. SİNYAL AYRIŞTIRMA	39
4.3. ÖZELLİK ÇIKARMA	40

4.3.1. VitC-Pattern	40
4.3.2. Yerel İkili Örüntüler (LBP)	43
4.3.3. İstatiksel Özellik Çıkarımı	44
4.4. ÖZELLİK SEÇME.....	47
4.5. SINIFLANDIRMA	47
5. BÖLÜM.....	49
DENEYSEL SONUÇLAR VE TARTIŞMA.....	49
5.1. DENEYSEL PLATFORM.....	49
5.2. PERFORMANS ÖLÇÜM PARAMETRELERİ	49
5.3. DENEYSEL SONUÇLAR	50
5.4. TARTIŞMA.....	53
5.5. ÖNE ÇIKAN NOKTALAR, KISITLAR VE ÖNERİLER.....	57
SONUÇ.....	59
KAYNAKÇA	61
EKLER.....	67
Ek 1. EMOTİV EPOC X Teknik Özellikleri	67
Ek 2. SAM Ölçeği	68
Ek 3. VitC-Pat Kod Parçası.....	69
Ek 4. Etik Komisyon Muafiyet Formu	71
Ek 5. Etik Kurul İzni	72
Ek 6. Teşekkür.....	73
ÖZGEÇMİŞ.....	74

KISALTMALAR DİZİNİ

AERG	: Ardahan Emotion Research Group
AMIGOS	: Dataset for Affect, Personality and Mood on Individuals and Groups
BoHDF	: Bag of Hybrid Deep Features
CNN	: Convolutional Neural Network
DE	: Diferansiyel Entropi
DEAP	: Database for Emotion Analysis using Physiological Signals
DREAMER	: Database for Emotion Recognition Through EEG and ECG Signals from Wireless
DVM	: Destek Vektör Makinası
DWT	: The Discrete Wavelet Transformation
EEG	: Elektroensefalografi
GAMEEMO	: EEG Signals and Various Computer Games
INCA	: Iterative Neighborhood Component Analysis
LBP	: Local Binary Pattern
mRMR	: Minumum Artıklık Maksimum Alaka Düzeyi
NCA	: Neighborhood Component Analysis
SEED	: Shanghai Jiao Tong University (SJTU) Emotion EEG Dataset
SVM	: Support Vector Machine
VitC-Pat	: Vitanim C Pattern
YSA	: Yapay Sinir Ağları

TABLÖLAR DİZİNİ

Tablo 1. AERG veri seti özellikleri.....	35
Tablo 2. Test işlemlerinin gerçekleştirildiği platform detayları.....	49
Tablo 3. Arousal eksenini için SVM sınıflandırıcı kullanılarak elde edilen performans metrik değerleri	51
Tablo 4. Valence eksenini için SVM sınıflandırıcı kullanılarak elde edilen performans metrik değerleri	51



ŞEKİLLER DİZİNİ

Şekil 1. Değerlik-uyarılma duygu modeli.....	18
Şekil 2. Tez kapsamında gerçekleştirilen veri toplama prosedürü.....	34
Şekil 3. Veri toplama sırasında alınan bir görüntü.....	35
Şekil 4. Kayıt esnasında Emotiv EPOC X cihazından alınmış EEG sinyalleri	36
Şekil 5. Önerilen Vit-C modeline dayalı duygusal EEG sınıflandırma sisteminin blok diyagramı.....	38
Şekil 6. DWT tabanlı alçak ve yüksek geçirgen filtre	40
Şekil 7. Askorbik asit-C vitamini kimyasal çizge yapısı	41
Şekil 8. Kimyasal örüntüden faydalanılarak elde edilen yönlü graf.....	41
Şekil 9. Yerel ikili örüntü yöntemi.....	43
Şekil 10. 10-katlamalı çapraz doğrulama işlemine ait bir blok diyagram	48
Şekil 11. Örnek bir hata matrisi	50
Şekil 12. EEG sinyalinin 13 numaralı kanalı için arousal ve valence eksenlerine ait hata matrisleri (a) Arousal (b) Valence.....	52
Şekil 13. Kanal bazlı seçilen özellik sayıları (a) Arousal ve (b) Valence.....	54
Şekil 14. Arousal ve valence eksenleri için kNN ve SVM sınıflandırıcılarının kanal bazlı karşılaştırmalı sonuçları (a) Arousal ve (b) Valence.....	56
Şekil 15. Uluslararası 10-20 sistemine göre yerleştirilmiş sensör konumları.....	67

SİMGELER DİZİNİ

$F1$	: F1-Skor
g	: EEG sinyali
Ln	: Sinyal uzunluğu
OA	: Doğruluk
Pr	: Hassasiyet
Rec	: Hatırlama
S	: Sinyal
$Std(.)$	: Standart sapma fonksiyon



GİRİŞ

Duygular, daha çok kelimeler ve davranışlarla temsil edilen zihinsel bir olgudur (Sampath ve diğerleri, 2022). Duygu, organizma sistem işleyişinin farklı alt sistemlerde oluşan karmaşık değişimlerdir. Duygular genel olarak davranışlara ve düşüncelere etki eden fiziksel ve psikolojik değişimlere neden olan karmaşık bir yapıdır. Duygunun tamamlayıcı öğeleri; geçmiş olaylar, duygusal denetim, düzenleyici süreç, ifade ve davranış, değerlendirme gibi kavramları içinde barındırmaktadır (Trémeau, 2022). Bunlara ek olarak, duyguyu bağımsız olarak üzüntü, korku, öfke, neşe vb. olarak tanımlayan ayrık modellerinde içinde olduğu teorik duygu modelleri meydana getirilmiştir (Colombetti, 2009; Liu, Zhang, Liu ve Cao, 2022). İnsan duygusu ise, bireyin iç veya dış uyarıcılarla karşılaştığı anda edindiği kendine özgü ve bilinçli bir deneyimdir (Ngai, Xie, Zou ve Chou, 2022). Duyguların; yüz ifadesi, konuşma, uzun metin, kısa ifadeler, konuşma, kısa mesaj ve video gibi girdiler kullanılarak analizi yapılabilir (Hossain ve Muhammad, 2019).

EEG sinyallerinin otomatik yorumlanması ile otizm, parkinson, uyku problemleri, epilepsi nöbetleri gibi hastalıkların takibi ve tespiti yapılabilmektedir (Yıldırım, 2022). Bunlara ek olarak otomatik duygu tanıma çevrimiçi oyun, müşterilerin geri bildirimlerinin analiz edilmesi ve dijital reklam hizmetleri gibi çeşitli akıllı sistemlerde de aktif olarak kullanılmaktadır (Hossain ve Muhammad, 2019).

Beyin-bilgisayar arayüzü (BCI), merkezi sinir sistemleri tarafından üretilen sinirsel aktiviteleri analiz eden bilgisayar tabanlı iletişim modelidir. Bu model, referans ve aktif elektrotlar arasındaki voltaj farkını ifade eden EEG sinyallerine dayandırılmaktadır (Grimm ve Kroschel, 2005; Topic, Russo, Stella ve Saric, 2022). İnsan-makine arasında etkileşim sağlanarak oluşturulan duygu tanıma yöntemleriyle engelli, yaşlı veya bakıma muhtaç bireylerin evlerinde onlara yardımcı olacak insansı özellikler taşıyan bir robotun davranışlarını yönlendirmek için kullanılabilir (Grimm ve Kroschel, 2005).

EEG (elektroensefalogram) sinyalleri, durağan ve doğrusal olmayan hareketli elektriksel beyin aktiviteleridir (Özdemir, Yıldırım ve Yıldırım, 2015). EEG sinyalleri, duygusal uyaranlara karşı oluşturulan beyin aktivasyonları hakkında benzersiz bilgiler sağlamaktadır. Bu durum duygu tanımda ses tonu, yüz ifadesi ve konuşmayla karşılaştırıldığında EEG sinyallerinin önemini artırmaktadır (Kalashami, Pedram ve Sadr,

2022). Beynin elektriksel hareketliliğini analiz etmek için kullanılan EEG sinyalleri, beyin biliminde çeşitli alanlarda yaygın bir şekilde kullanılmaktadır (Wan, Yang, Huang, Zeng ve Liu, 2021).

EEG sinyallerinin elde edilmesi invaziv ve non-invaziv (cerrahi ve cerrahi olmayan) yöntemler şeklinde iki gruba ayrılmaktadır. İnvaziv metodu, yüksek sinyal yoğunluğu içermektedir. Tıbbi cerrahiyle kafatası boşluğuna eklenmesi gerekmektedir ve analiz edilmesi için uzman görüşüne ihtiyaç duyulmaktadır. Non-invaziv metodu ise, beyin-bilgisayar ara yüzünü kullandığı için daha basit ve kolaydır (J. Wang ve Wang, 2021). EEG sinyalleri, çok sayıda boyutsallığı artıran elektrot uygulanarak giyilebilir invaziv olmayan cihazlar aracılığıyla kayıt altına alınabilmektedir (Topic ve diğerleri, 2022).

EEG sinyalleri kullanarak otomatik duygu tanıma ve yorumlama için yöntemler geliştirilmiş ve kullanılmıştır (He, Zhuang, Bao, Zeng ve Yan, 2022). Duygu analizi yapılırken kullanılan EEG sinyallerinde kanal seçimi çok kritiktir. Ek olarak, yüksek performansa sahip bir model için doğru özellik çıkarma ve sınıflandırma algoritması kullanmak oldukça önemlidir (Çizmeci, 2022).

1.BÖLÜM

1.1. TEZİN AMACI VE KAPSAMI

Gerçekleştirilen bu tez çalışmasında EEG sinyalleri kullanılarak otomatik duygu sınıflandırılması amaçlanmıştır. Bu amaç doğrultusunda tamamen özgün ve araştırmacı tarafından hazırlanan “AERG” adında yeni bir veri seti toplanmıştır. Araştırmacı tarafından toplanan bu veri seti yine bu tez çalışmasında özgün olarak önerilen bir örüntü tanıma yöntemiyle otomatik olarak sınıflandırılmıştır.

Duygu tanıma literatürde çalışılan önemli konulardan biridir. EEG sinyalleri genel olarak beyinle ilişkili rahatsızlıkların (otizm, parkinson, uyku problemleri, epilepsi nöbetleri) takibi ve tespiti için nöroloji uzmanları tarafından aktif olarak kullanılmaktadır. Ancak gelişen teknolojiyle birlikte bu sinyaller sadece beyinle ilişkili hastalıkların ön tanısı dışında farklı amaçlarla da kullanılabilir hale gelmiştir. Nitekim bu tez çalışmasında da EEG sinyallerinin duygu tanıma için kullanılabileceği araştırılmaktadır. EEG sinyali toplama cihazları günümüz teknolojisinde mobil hale gelmiştir. Beyin şapkası adı verilen bu mobil cihazlar ile EEG sinyalleri toplanabilmektedir. Gerçekleştirilen bu tez çalışmasında da gönüllü katılımcılardan (9 kadın, 13 erkek) toplanan EEG sinyallerinin otomatik sınıflandırılması ve yorumlanması amaçlanmıştır. Bu amaç doğrultusunda literatüre yeni bir veri seti kazandırılmıştır. Tez süresince toplanacak veri seti için gönüllü katılımcılara çeşitli duygu durumlarını (hüzün, neşe, korku vb.) yaşatacak videolar izletilmiştir. Video izletilmesi sırasında gönüllü katılımcılardan bir beyin şapkası (Emotiv EPOC X) aracılığıyla EEG sinyalleri alınmış ve kayıt edilmiştir. Gönüllü katılımcılara farklı duygu durumlarını tetikleyen videoların izletilmesinin ardından toplanan EEG sinyalleri katılımcılara uygulanan bir anket sonrası etiketlenmiştir. Tez çalışmasının veri toplama safhasının ardından model geliştirme aşamasına geçilmiştir. Bu aşamada, sinyal ön işleme, sinyal alt bantlarına ayırma, özellik çıkarma, özellik seçme ve sınıflandırma adımları uygulanmış ve toplanan EEG sinyallerinin otomatik yorumlanması sağlanmıştır. Ek olarak, tez kapsamında önerilen modelin doğruluğunu gözlemleyebilmek için doğruluk, kesinlik, hassasiyet gibi çeşitli performans metrik değerleri hesaplanmış olup, elde edilen sonuçlar tez kapsamında önerilen modelin arousal ve valence eksenleri için %90 üzerinde doğruluk değerine ulaşılması amaçlanmıştır.

1.2. TEZİN YAPISI

Gerçekleştirilen bu tez çalışmasının birinci bölümünde genel bir EEG tanımı sunulmuş olup, tez çalışmasının amacı ve kapsamı paylaşılmıştır. Tez çalışmasının ikinci bölümünde EEG tabanlı sinyal işleme ve duygu tanımanın detayları verilmiştir. Bu bölümde duygu tanıma üzerine literatürde gerçekleştirilmiş olan çalışmalar detaylı bir şekilde verilmiştir. Bu tez çalışmasının üçüncü bölümünde araştırmacı tarafından toplanan EEG sinyallerinin detaylarına yer verilmiştir. Bu bölümde, duygu tanıma veri setinin oluşturulması aşamasında uygulanan adımlar, kullanılan cihaz ve gönüllü katılımcı bilgileri sunulmaktadır. Gerçekleştirilen bu tez çalışmasının dördüncü bölümünde ise özgün olarak önerilen yöntemin detayları verilmiştir. Bu bölümde özellik çıkarma, özellik seçme ve sınıflandırma fazları detaylı bir şekilde incelenmiş olup, yine bu bölümde VitC-Pat, LBP, istatistiksel özellik çıkarımı, NCA ve SVM yöntemlerinin detayları ile kullanım yaklaşımları özetlenmiştir. Tez çalışmasının beşinci bölümünde deneysel sonuçlar ve tartışma bölümü yer almaktadır. Bu bölümde tez çalışması süresince toplanan EEG sinyallerinin yine tez çalışması kapsamında özgün olarak önerilen VitC-Pat yöntemi ile değerlendirme sonuçları verilmiştir. Bu tez çalışmasının altıncı ve son bölümünde ise sonuçlar ile gelecek çalışmalara yönelik önerilere yer verilmiştir.

2. BÖLÜM

EEG TABANLI DUYGU TANIMA

2.1. EEG (ELEKTROENSEFALOGRAFI)


Beyin sinyalleri, bir bireyin çeşitli senaryo veya durumlara maruz kaldığında sürekli olarak üretilen ve içerisinde bulunduğu ruh halini doğrudan yansıtan bir sinyal çeşididir (Sakalle ve diğerleri, 2022). Bu sinyaller EEG adı verilen bir yöntemle toplanabilmekte ve incelenebilmektedir. Temel olarak bir beyin sinyallerini kaydeden bu cihazlar ile toplanan sinyallere EEG sinyali adı verilmektedir.

EEG sinyallerinin kayıt altına alınması Alman bilim insanı Hans BERGER tarafından 1929 yılında önerilmiştir. EEG sinyallerinin toplanış biçimi invaziv veya non-invaziv olabilmektedir. İnvaziv yaklaşımlar cerrahi müdahale gerektirirken non-invaziv yaklaşımlarda kafa derisi üzerine yerleştirilen elektrotlar sayesinde sinyaller alınmaktadır. Bu yöntemlerden invaziv yaklaşım, doğrudan kafatasının içerisine yerleştirildiğinden sinyal kalitesi ve yoğunluğu oldukça yüksektir. Bu işlem için EEG sinyal toplama cihazının tıbbi cerrahiyle kafatası boşluğuna eklenmesi gerekmektedir. Ek olarak, bu tür sinyallerin analizi ve yorumlanması oldukça güç olup, alanında uzman bir nöroloğun incelemesi gerekmektedir. Non-invaziv yaklaşımlarda ise beyin-bilgisayar arayüzleri kullanılarak sinyaller toplanmaktadır. Bu yaklaşım oldukça kolay ve ağrısız bir yöntemdir (J. Wang ve Wang, 2021). EEG sinyalleri, çok sayıda boyutsallığı artıran elektrot uygulanarak giyilebilir invaziv olmayan cihazlar aracılığıyla kayıt altına alınabilmektedir (Topic ve diğerleri, 2022). EEG sinyalleri temel olarak bir boyutlu, düşük genliklere sahip, durağan olmayan ve gürültüden kolaylıkla etkilenen sinyallerdir. Bu sebeple yüksek çözünürlüklü, çok az gürültünün olduğu ortamlarda EEG cihazlarıyla ölçüm yapılması gerekmektedir (Balım, 2018).

2.2. DUYGU TANIMADA EEG

EEG tabanlı duygu tanıma son yıllarda literatürde sıklıkla çalışılan konuların başında gelmektedir. Bu durumun nedeni gelişen teknolojiye bağlı olarak EEG sinyali toplama cihazlarının yüksek zaman çözünürlüğü, taşınabilirlik ve basitlik gibi birçok özelliği bir

arada sunabilmesidir (Zhang, Zhong ve Liu, 2022). EEG sinyalleri kullanılarak duygu sınıflandırma, duygusal hesaplamanın temel unsurlarının başında gelmektedir (Ahmed, Sinha, Ghaderpour ve Phadikar, 2023). Literatürde EEG sinyali tabanlı gerçekleştirilen duygu tanıma çalışmaları incelendiğinde, duygu modellerinin iki gruba ayrıldığı görülmektedir. Bunlar sırasıyla kategorik ve ayrık duygu modelleridir. Kategorik model valence(değerlik), arousal(uyarılma) ve dominance (baskınlık) olarak adlandırılan üç durum içermektedir. Ayrık model ise üzüntü, korku, mutluluk, öfke, şaşkınlık, tiksinti olmak üzere altı temel duygusal durumdan meydana gelen pozitif ve negatif duygulardan oluşmaktadır. Gerçekleştirilen bu tez çalışmasında kategorik duygu sınıflandırma yaklaşımı önerilmiştir. Bu durumun görsel ifadesi şekil 1’de gösterilmiştir.



Şekil 1. Değerlik-uyarılma duygu modeli

2.3. LİTERATÜR ÖZETİ

Ahmed ve diğerleri, (2023) bu çalışmalarında duyguların daha başarılı bir şekilde sınıflandırılması amacıyla InvBase adında yeni bir yöntem geliştirilmiştir. Önerilen bu yöntemle özellik çıkarılmadan önce oluşan çeşitli gürültüleri kaldırmak için kullanılmıştır. DEAP veri seti kullanılarak NBC ve Subtarctive metotlarıyla kıyaslama yapılmıştır. Kıyaslamalarda SVM, MLP ve kNN olmak üzere üç farklı sınıflandırıcı kullanılmıştır. Bu yöntemle, özellik çıkarma yöntemi kıyaslandığında uyarılma ve

değerlik sınıflandırma değerleri diğerlerine göre daha yüksek sınıflandırma doğruluğu elde edilmiştir. Önerilen yöntemle, MLP sınıflandırıcı kullanılarak %86.9'luk değerle en yüksek doğruluk değerine ulaşılmıştır.

Alotaibi, (2023) bu araştırmasında duyguların daha verimli sınıflandırılmasını için yeni bir özellik çıkarma metodu olan BoHDF (bag of hybrid deep features) yöntemi önerilmiştir. Önerilen bu yöntem, SEED ve DEAP veri setleri üzerinden deneysel çalışmalar yapılmıştır. Deneyin ilk aşamasında veri setlerinin sadece 32 kanalı kullanılmıştır. Ham verilerin ön işleme aşamasında, gürültüleri gidermek için Bandpass Butterworth filtresi uygulanmıştır. Özellik seçme aşamasında ise, katman özellik değerleri için GoogLeNET ve doku özellik değeri için ise OMTLBP_SCM metotları önerilmiştir. Önerilen bu metodla, AlexNet, Resnet-50, Inception V3, ResNet-101, GoogLeNet sinir ağları kullanılarak test edilmiştir. Yapılan çalışmalarda veriler %70 eğitim, %30 test olacak şekilde ayrılarak 5 kat çapraz doğrulama yöntemi uygulanmıştır. Çalışmanın sonuncunda DEAP veri seti için GoogLeNet yapısı ve KNN sınıflandırıcıyla %93.83 doğruluk değerine, SEED veri seti için ise GoogLeNet yapısı ve KNN sınıflandırıcıyla %96.95 doğruluk değerine ulaşılmıştır.

Yuvara, Thagavel, Thomas ve Fogarty, (2023) yapılan bu çalışma, uyarılma ve değerlik boyutları göz önüne alınarak duygusal durumların analizi için geniş kapsamlı EEG özellik setlerinin sınıflandırma performansı karşılaştırılmıştır. Araştırmada, yüksek dereceli spektumlar, frantal boyut, dalgacık analizi, Hjortj parametleri ve istatistiksel özellikler olarak beş farklı EEG özellik setinin sınıflandırılma doğruluğu incelenmiştir. Performans değerlendirilmesi için regresyon ağacı ve destek vektör makinası sınıflandırıcı metodu kullanılmıştır. Bu deney için DEAP, AMIGOS, DREAMER, MAHNOB-HCI ve SEED veri setleri karşılaştırma için kullanılmıştır. FD-CART özellik sınıflandırma metoduyla, beş farklı veri setinde uyarılma (%84.55) ve değerlik (%85.06) değerleri için en iyi ortalama doğruluk değeri bulunmuştur. Bu sonuçların beş farklı veri setinin kararlılığı ve EEG verilerinden üretilen FD özelliklerine dayalı olarak duygu tanıma için güvenilir olduğu anlaşılmıştır.

He ve diğerleri, (2022) çalışmasında 14 kişiye 12 video uyarıcısı verilerek 4 duygu durumu (eğlenme, üzgün, öfke, korku) araştırması yapılmıştır. Kendilerin oluşturduğu video kitaplığından faydalanan Çin afektif video sistemi kullanılmıştır. Her konu için 6 gün boyunca EEG sinyalleri alıp EEG veri tabanı oluşturulmuştur. Duyguların nöral

kalıpları için EEG sinyalleri incelenmiştir. Beyin topografi analizi yapılarak ve farklı zamanlarda ölçülen EEG sinyalleri kullanılarak ey iyi hareket özellik eşleştirilmiştir. TCA tabanlı uyarılama stratejisiyle, sınıflandırmada farklı günlerde yapılan duygu tanımlamalarında 4 duygu durumu (korku, üzgün, öfke, eğlenme) ortalama duygu doğrulukları sırasıyla %85.13, %86.38, %88.12 ve %90.18 olarak tespit edilmiş ve %2.34-%3.55 arasında iyileşme yaşanmıştır.

Houssein, Hammad ve Ali, (2022) makine öğrenmesinde kullanılan EEG tabanlı beyin-bilgisayar arayüzünün insan duygusunu tanımaya yönelik 2015-2021 yılları arasında yayımlanan duygu tanımlamaya yönelik çalışmaların kapsamlı bir incelemesi yapılmıştır. Bu inceleme, beyin-bilgisayar arayüzüne dayalı çok kanallı EEG tabanlı insan duygularını tanımaya yönelik yöntemler gözden geçirilmiş ve bu alanda neler yapıldığı ve başarıldığıyla ilgili genel bir bakış açısı kazandırılmıştır. Çalışmanın içeriğine bakıldığında duygu durumlarını ortaya çıkarmaya yarayan metodlar ve duygu tanımda sıklıkla kullanılan veri setleri incelenmiştir. Bunlara ek olarak incelemede duygu tanımda yaygın olarak kullanılan özellik çıkarma, özellik seçme, derin öğrenme ve makine öğrenmesi yöntemleri incelenmiştir. Farklı EEG veri setleri, farklı makine ve derin öğrenme algoritmaları kıyaslaması yapılmıştır.

Çizmecı, (2022)'ye göre, çalışmalarında bireylerin duygu durum analizlerinde yüksek doğruluk oranına sahip iki çalışma yapılmıştır. Birinci incelemede, EEG sinyallerine ek olarak duygu tanıma için hiyerarşik düzen ve komşuluk ilişkisi ağa öğretilerek gelişmiş kapsül ağı sınıflandırma modeli kullanmıştır. SEED veri setinde 3 duygu durumu (pozitif, negatif ve nötr) analiz edilip %98.21 yüksek doğruluk oranı bulunmuştur. Bu çalışma sonucunda uygun kanalların seçimi, Welch güç spektral yoğunluğuyla özellik çıkarma ve gelişmiş ağ kapsülüne dayalı yöntemin uygulanmasıyla diğer yöntemlere göre daha başarılı olduğu tespit edilmiştir. İkinci incelemede ise, nötr, pozitif ve negatif duyguların tahmini için SEED veri seti üzerinden en doğru kanallar için DisABC algoritması kullanılmıştır. Welch güç spektral yoğunluk tahminiyle özellik çıkarımı yapılmıştır. Bu sayede ölçüm verilerine ait kanalların tutarlı ve sağlam çıkması amaçlanmıştır. Araştırmanın sonucunda %99.83 oranında yüksek sınıflandırma doğruluğuna ulaşılmıştır.

Aguiñaga, Delgado, López-López ve Téllez, (2022) çalışmalarında yaşları 23-47 arasında olan 18 erkek ve 3 kadın içeren toplam 21 katılımcının olduğu BED veri setini

kullanılmıştır. Yorgunluk durumları dikkate alınarak yöntem kısımlarında özellik seçiminde iki strateji belirlenmiştir. İlk olarak veri setinde mevcut olan konfigürasyon kullanmıştır. İkinci olarak, M3GP genetik algoritma kullanılarak özellik seçimi ve dönüşüm uygulanmıştır. M3GP algoritması uygulandıktan sonra duygu tanıma oranı %14.76'lık artış göstermiştir. Araştırma sonucunda, spektral niteliklerin ayrılabilirliğini artırılarak %92'lik ortalama sınıflandırma oranına ulaşılmıştır.

Gao, Yang, Kang, Tian ve Song, (2022) araştırmalarında EEG sinyalleri aracılığıyla duygu analizi yapabilmek için DEAP veri setini kullanarak uzamsal-zamansal duygusal bilgiyi öğrenmek amacıyla zamansal sinir ağ yapılarından faydalanarak yeni bir füzyon ağı önerilmiştir. Çalışmanın duygu tanıma yöntem kısmında iki bilinen öznelik türü olan zaman ve frekans alanı özneliklerini kullanılmıştır. Özellik seçimi için tamamen bağlı katmanlar kullanılmış olup duygu özelliklerini sınıflandırmak için de SVM sınıflandırıcı seçilmiştir. Araştırmanın sonucunda, değerlik ve uyarılma sınıflandırma değerleri sırasıyla %75.2 ve %80.22 ortalama duygu tanıma doğruluğu elde edilmiştir.

Chowdary, Anitha ve Hemanth, (2022)'a göre çalışmanın amacı EEG sinyallerinden gelen duyguları farklı tekrarlanan sinir ağ mimarilerini kullanarak sınıflandırmaktır. Bu üç mimari sırasıyla GRU (kapalı tekrarlayan birim), LSTM (uzun kısa süreli bellek ağı) ve RNN (tekrarlanan sinir ağı) yapıları olarak belirlenmiştir. Verilerin bir kadın ve bir erkek için 3 dakika boyunca toplandığı pozitif, negatif ve nötr duygu durumlarını içeren EEG Brain Wave veri seti kullanılmıştır. Bu veri setinde üç duygu için toplam 2132 örnek bulunmaktadır. Bunlar pozitif için 708, nötr için 716, negatif için 708 örnektir. Farklı sinir ağları karşılaştırıldığı RNN ağı, patlayan ve kaybolan gradyanların nedeniyle LSTM ve GRU ağları yüksek doğruluk değerine ulaşmıştır. GRU ise LSTM'den daha az parametre kullandığı için daha az bellek kullanır ve daha hızlı olduğu anlaşılmıştır. Fakat LSTM ise daha büyük veri setinde daha verimli çalıştığı tespit edilmiştir. Bu araştırma neticesinde GRU sinir ağı yapısı için %96, LSTM sinir ağı için %97, RNN sinir ağı için %95 ortalama doğruluk tespit edilmiştir. Sonuç olarak, LSTM sinir ağı EEG Brain Wave veri setinde %96'lık ortalama doğruluk değeriyle en yüksek duygu analizi tespitinde bulunmuştur.

T. Tuncer, Dogan ve Subasi, (2022) yeni nesil duygu tanıma modeli ortaya koymuştur. Bu modelin temel amaçlarından birincisi, kendine özgü öznelik ve derin bir sınıflandırıcı kullanarak daha hassas bir duygu tanıma tespiti hedeflenmiştir. Çok düzeyli

birleştirilmiş özellik oluşturma ağı amacıyla üç özellik; TQWT (q faktörlü ayarlanabilir dalgacık dönüşümü), doğrusal olmayan dokusal ve istatistiksel özellik oluşturma aşamaları kullanılmıştır. Bu modelin genel şeması ön işleme, istatistiksel özellik üretme ve Led-Pattern kullanarak özellik oluşturma, RFICHi ile özellik seçimi ve SVM sınıflandırıcı olarak tasarlanmıştır. LedpatNet19 modeliyle, DREAMER ve GAMEEMO veri setlerini kullanarak %92 üzerinde sınıflandırma doğruluğu ulaşılmıştır. DREAMER veri setiyle yapılan çalışmada uyarılma, baskınlık ve değerlik için sırasıyla %94.58, %92.86 ve %94.44 sınıflandırma sonucuna varılmıştır. Önerilen modelin GAMEEMO veri setiyle yapılan çalışmada ise en iyi sınıflandırma değeri %99.29 olarak bulunmuştur. Diğer duygu tanıma sınıflandırmalarına göre daha başarılı olduğu tespit edilmiştir.

Suhaimi, Mountstephens ve Teo, (2022) bu çalışmasında dört farklı duygu durumu (sakin, sıkılmış, korkmuş, mutlu) uyarmak için sanal gerçeklik kullanılmıştır. Aynı zamanda düşük maliyetli EEG sinyal toplayıcı cihaz kullanarak EEG sinyalleri toplanmıştır. Her duygu durumu için YouTube'dan 32 sağlıklı bireye (25 erkek, 7 kadın) 80sn'lik 4 video izletilmiştir. İlk aşamada, halka açık ve sanal gerçeklik uyaranlarını kullanan duygu tanımlama çalışmalarına katkı sağlayabilecek etkili bir VR (sanal gerçeklik) veri tabanı oluşturmak amaçlanmıştır. İkinci aşamada ise kafa derisine zarar vermeyen küçük ve uyumlu, VR kullanırken hareket özurluğu sağlayan EEG cihazı kullanmıştır. Son olarak, SVM, KNN, GBM, FANN, NB ve DRF gibi sınıflandırıcıların kıyaslanmasıyla duygu tanıma işlemleri yapılmıştır. Sonuç olarak sınıflandırıcılar arasında SVM sınıflandırıcısı, 4 farklı duygu tanıma durumu için %85.01 en yüksek doğruluk değeri tespit etmiştir. Bu araştırmanın başka bir özelliği de EEG sinyallerini kullanarak dört duygu durumunu tespit etmek için gerçek zamanlı duygu sınıflandırma yaparak duygu sisteminin tanınmasını geliştirmektir.

Bardak, Seyman ve Temurtaş, (2022) sinir ağ modellerini kullanarak EEG tabanlı duygu tanıma yapılarak yüksek doğruluk elde edilmeye çalışılmıştır. Bir kadın ve erkek alınan EEG sinyalleri, pozitif, negatif ve nötr duygu durumlarının yer aldığı MUSE veri seti kullanmıştır. Kişilere uyarıcı olarak altı video izletilmiştir. EEG sinyalleriyle üç duygu durumu analiz edilen bu çalışmada, SVM, MLP, PNN, KNN ve karar ağaçları sınıflandırıcıları kullanılmıştır. En iyi 150 özellik seçilerek oluşturulan EEG sinyalleri MLP sınıflandırıcı kullanılarak %90.21'lik bir doğruluk değeri elde edilmiştir. Çalışmanın devamında öğrenme hızı artırıp AdaBoost sınıflandırıcıyla test edildiğinde

doğruluk değerinin arttığı gözlemlenmiştir. Ayrıca torbalı ağaç ve PNN yaklaşımlarından yararlanılarak sırasıyla %98.60, %94.32 doğruluk değeri elde edilmiştir.

Kalashami ve diğerleri, (2022) duygu tanıma EEG veri artırma ve özellik çıkarma üzerine öneriler sunmuştur. Bu çalışmanın amacı, yüksek boyutlu veri problemini ve veri eksikliğine çözüm bulmak için veri büyütme ve özellik çıkarma yöntemleri önerilmiştir. Çalışmada, Conditional Wasserstein (GAN) adı verilen ek EEG öznitelikleri yeniden oluşturmak için kullanılan veri büyütme stratejisi ve derin üretici modelleri kullanılmıştır. Öneride, 32 kişiye 40 video izletilerek EEG sinyallerinin alındığı DEAP veri seti kullanılmıştır. Bu veri seti kullanılarak önerilen yöntemin etkililiği analiz edilmiştir. Çalışmanın diğer aşamalarında, destek vektör makinası ve derin sinir ağı sınıflandırıcıları kullanılmıştır. Araştırma sonucunda artırılmış veriler kullanılmasıyla EEG tabanlı duygu performansının arttığı gözlemlenmiştir. Veri büyümesinden sonra sınıflandırmanın ortalama doğruluğu uyarılma ve değerlik için sırasıyla %6.5 ve %3.0 oranında artmıştır. Yıldırım, (2022) çalışmasında önerilen modelinin temel amaçlarından birincisi yüksek doğruluğu hedefleyen otomatik duygu tanıma için anlaşılabilir ve efektif metotlar geliştirmektir. İkincisi ise, tek boyutlu sinyaller kullanılarak yeni öğrenme modeliyle çok daha iyi sınıflandırma geliştirerek daha yüksek doğruluk elde edilerek otomatik duygu tanıma hedeflenmiştir. Önerilen yönteminin ilk aşamasında çok düzeyli ayırık dalgacık dönüşümü, K-en yakın komşu, yerel ikili desen ve komşuluk bileşen analizi sınıflandırıcılar kullanılmıştır. Bu modelde kullanılan GAMEEMO veri setiyle sınıflandırma oranı %100 olarak bulunmuştur. Diğer önerilen yöntem birlikte, AQDD ve asal örüntü özellik çıkarma modeli önerilmiştir. Bu yöntemle makine öğrenmesi modeli içerisinde bulunan özellik seçimi, özellik çıkarma ve sınıflandırma yöntemlerinin tüm aşamaları kullanılmıştır. Önerilen PrimePatNet87 geliştirilmesi için DREAMER, GAMEEMO ve DEAP veri setlerinden yararlanılmıştır. Bu modelle, tüm veri setlerinde sınıflandırma doğruluğu %99'un üzerinde bulunmuştur.

Ye, Alnemari ve Bagherzadeh, (2022) çalışmasında EEG sinyalleri kullanarak duygu tanıma için iki aşamadan oluşan verimli çalışan 3D modeli önermiştir. Bu çalışma genel olarak verimli tasarım ve algoritma odaklı öneriler sunulmuştur. Yapılan çalışmada, 32 kişiye 40 video izletilerek EEG sinyallerinin alındığı DEAP veri seti kullanılmıştır. Bu veri seti, veri işleme teknikleri uygulamak ve üç boyutlu girdiler oluşturmak için çalışmada kullanılmıştır. İlk aşamada önerilen model, uyarılma ve değerlik durumlarında

yüksek performans göstermiştir. Öğrenme parametresinin az olduğu ve EEGNet kompakt model boyutuyla sırasıyla EEGNet V1 %90, EEGNET V2 %96.6 ve EEGNET V3 %99.5 ortalama sınıflama doğruluğu elde edilmiştir. İkinci aşamada ise, üç yeni teknik uygulanarak daha çok sıkıştırma ve verimli bit düzeyinden faydalanmak için bu model ikili hale getirilmiştir. İkileme modeliyle hesaplama kaynakları ve depolama maliyetlerinde %40'tan daha fazla tasarruf edilmiştir.

Haq, Yao, Rahmani, Fawad ve Islam, (2022) duygunun doğru tespiti için diferansiyel entropi tabanlı yeni özellik seçme tekniği önerilmiştir. Bu modelle histogram ve yakın özellikler kümesine bağlı çoklu özellikler çıkarılmasıyla öğrenme süresinin hızlanması amaçlanmıştır. Doğru tanımlamayı yapabilmek için birden çok makine öğrenmesi modeli kullanılmıştır. Yapılan çalışmada, 15 kişiye 15 video izletilerek EEG sinyallerinin alındığı SEED veri seti kullanılmıştır. Sonuç olarak, AlexNet, ResNet-101, GoogleNet, ResNet-50 ve Inception-ResNET V2 farklı derin sinir ağı modelleri kıyaslaması yapılmıştır. Alexnet 28 kanallı derin sinir ağı kNN sınıflandırıcıyla %96.2, Resnet-50 40 kanallı derin sinir ağı kNN sınıflandırıcıyla %96.2, Resnet-101 29 kanallı sinir ağı Emsemble sınıflandırıcıyla %94.9, InceptionresnetV2 32 kanallı derin sinir ağı Tree ve Emsemble sınıflandırıcılarıyla %95.8 doğruluk değerlerine ulaşılmıştır. GoogleNet 26 kanallı sinir ağı kullanılarak yapılan çalışmada ise SVM sınıflandırıcıyla %96.7'lik en yüksek doğruluk değeri elde edilmiştir.

Topic ve diğerleri, (2022) çalışmalarında açık kaynaklı veri setlerinden yararlanılarak elektrot seçimi araştırılıp, holografik özellikler kullanılarak yüksek düzeyde doğruluk elde edilmesi amaçlanmıştır. NCA ve The RELieff yöntemleri en iyi özellikleri seçmek için kullanılmıştır. Holografik özellik haritaları için bilgisayar kullanılarak oluşturulan holografi (CGH) uygulanmıştır. Oluşturulan 2 boyutlu haritalar için CNN özellik çıkarma yöntemi önerilmiştir. Yapılan çalışmada farklı kanal sayına sahip dört veri seti (AMIGOS, DEAP, SEED ve DREAMER) kullanılmıştır. Çok kanallı EEG cihazının kullanılmasını hesaplama ve donanım karmaşıklığına neden olmuştur. Bazı kanalların kullanılması gereksiz gürültüye neden olduğu ve duygu tanımda faydalı olmadığı sonucuna varılmıştır. Araştırmada yapılan kıyaslamalarda azaltılmış kanal sayısı sınıflama doğruluğunu arttırdığı anlaşılmaktadır. NHOLO-FM ve RHOLO-FM özellik haritaları kullanılarak EEG sinyalleriyle bilgisayar aracılığıyla hologram kullanılmıştır. Makine öğrenimi ve derin sinir ağı yöntemleriyle belirgin bir şekilde duygu tanıma

oranında artış gözlenmiştir. Çalışmada kullanılan tüm veri setleri cinsiyete göre duygusal durumları analiz edildiğinde değerlik, uyarılma ve baskınlık değerleri açık bir şekilde farklı çıkmıştır. Sonuç olarak, kanal seçim yöntemlerinin uygulanması uyarılma (%92.92), değerlik (%90.76) ve baskınlık (%92.97) doğruluk değerleri üzerinde önemli bir etki oluşturmuştur.

Sakalle ve diğerleri, (2022) bu çalışmada genetik-programlama tabanlı özellik seçimi (FSGB) yöntemi kullanılarak duygu tanımda yüksek doğruluğa sahip sınıflandırma önerisi sunulmuştur. 14 kanallı EMOTİV EPOC cihazı kullanılarak 50 gönüllü katılımcıdan (25 kadın, 25 erkek) EEG sinyalleri toplanmıştır. Katılımcılara yaklaşık 60 video izletilerek negatif ve pozitif duygu durumları kayıt altına alınmıştır. Son analizlerde cihazda yaşanan aksaklıklar ve sinyallerdeki gürültüden dolayı 5 katılımcı değerlendirmeye alınmamıştır. Özellik seçiminde, özelliklerin tümünün ağırlığı alınıp ortalamaları hesaplanmıştır. Ortalamanın üstünde kalan özellik ağırlığı için F_{so} , altında kalanlar için ise F_{no} olarak adlandırılan iki gruba ayrılmıştır. Özellik seçimi için GP tekniği kullanılmıştır. Önerilen FSGB modeli, random forest, SVM, GPmtfs, netural network metodları oluşturulan veri seti kullanılarak karşılaştırılmalar yapılmıştır. Bu yaklaşımları analiz edilirken veri seti %80 eğitim, %20 test temelli model seçilmiştir. GPmtfs ve FSGP modelleri minimum, maksimum ve ortalama sınıflandırma doğrulukları kıyaslaması yapılmıştır. GPmtfs modeli minimum(%68), maksimum(%75) ve ortalama(%71) sınıflandırma doğruluk değerlerine ulaşılmıştır. FSGB model için minimum(%80), maksimum (%85) ve ortalama(%82) sınıflandırma doğruluk değerlerine ulaşılmıştır. FSGP modeli, Random forest, Neural network, Genetic programming ve SVM maksimum doğruluk açısından değerlendirilmiştir. FSGB %85 maksimum doğruluk değeriyle en yüksek değer olarak bulunmuştur.

W. Li ve Yong, (2022) iki parçalı grafik etiket yayılımı ve yarı denetimli regresyon (TSRBG) kombinasyon edilerek oluşturulan EEG özellik transferi metodu bu çalışmada önerilmiştir. Bu yöntem, yarı denetimli ortak tahmini ve EEG özellik dağılımının hizalanması için gerçekleştirilmiştir. Önerilen yöntemde, dört duygu durumunun olduğu (korku, tiksime, mutlu ve mutsuz), 15 katılımcının 24 video izletilerek EEG sinyallerinin alındığı SEED-IV veri seti kullanılmıştır. TRSBG performansını analiz etmek için MIDA, GAKT, JDA, FSTSL derin olmayan transfer öğrenme metoduyla iki derin öğrenme metodu LRS ve DGCNN ve yarı denetimli sınıflandırma metodu SOBG

karşılaştırılmak için seçilmiştir. Üç farklı yapılan oturumda da TSRBG metodu diğer yaklaşımlara göre EEG duygu tanıma doğruluğu daha yüksek çıkmıştır. En yüksek duygu doğruluğu 2. oturumun 15. kişisinde ortaya çıkmıştır. Önerilen metot, üç oturumda yapılan yedi metoda göre ortalama duygu doğruluğu sırasıyla %72, %76.49 ve %77.50 olarak bulunmuştur.

Ari ve diğerleri, (2022) çalışmalarında etkili bir duygu tanıma için iki amaç belirlenmiştir. İlk amaç, EEG veri setiyle derin öğrenme mimarisini kullanarak dört duygu durumu test edilmiştir. Diğer amaç ise, kullanılan veri setinde örneklem sayısında artış sağlamaktır. Bu amaçlar doğrultusunda dalgacık otomatik kodlayıcı aşırı öğrenme makinası (ELM-W-AE) isminde yeni bir veri artırma modeli önerisi sunulmuştur. Bu modelinin diğer veri artırma modellerine göre daha hızlı ve basit olduğu belirtilmiştir. ELM-AE yapısı, Mexican, Shannon, Morlet ve Gaussian ve GGW dalgacık fonksiyonlarını kullanmıştır. Görüntü sınıflandırmak için derinlik azalmasıyla birlikte performans artan ResNET18 yapısı tercih edilmiştir. ELM-W-AE yaklaşımı test etmek için GAMEEMO veri seti ve Fırat üniversitesinin yazılım mühendisliği tarafından 28 kişiden toplanan veri seti analizler için kullanılmıştır. Önerilen yöntemle, GAMEEMO veri seti üzerinden üç çalışma metodu ve sınıflandırıcı kıyaslaması yapılmıştır. Karşılaştırma sonucunda, ortalama sınıflandırma doğruluğu %99.6 çıkarak bu üç karşılaştırma arasında en yüksek değere ulaşılmıştır. Bu metot, Fırat üniversitesi tarafından yapılan veri seti GGW, Gauss, Mexican, Meyer, Marlot ve Shannon dalgacık fonksiyonları kullanılarak doğru sınıflandırma oranları bulunmuştur. GGW dalgacık fonksiyonuyla en iyi değerlendirme skoru elde edilmiştir.

Moctezuma, Abe ve Molinas, (2022) çok amaçlı evrimsel algoritma aracılığıyla seçilen EEG kanallarından iki boyutlu CNN yöntemini kullanarak yüksek doğruluğa sahip duygu tanıma modeli sunulmuştur. Çalışmada, 32 katılımcıya 40 video izletilen 32 kanallı DEAP veri seti kullanılmıştır. İlk aşamada, bütün kanallar kullanılarak 32 katılımcının verileri üzerinden tek model üzerinden maksimum doğruluk değeri hesaplanmıştır. Çalışmanın devamında, bazı kanalların düşük/yüksek uyarılma ve değerlik arasındaki ayrımının yapılabilmesi ve daha çok bilginin olup olmadığı anlamak için her seferinde tek kanal kullanılmıştır. Sonuçlara göre, tek kanal kullanımıyla tüm kanalların kullanımı kıyaslandığında doğruluk değerinde artışa neden olmamıştır. Yüksek ve düşük değerlik/uyarılma değerlerinin sınıflandırılması için ML ve DWT tabanlı özellik çıkarma

uygulanmıştır. Bu çalışmada yüksek doğruluk elde etmek için, EEG kanal seçimi için domine edilmeyen genetik II (NSGA-II) algoritması kullanılmıştır. Bu algoritma, sınıflandırma doğruluğunu en yükseğe çıkarmak ve sınıflandırma aşamasında gerekli EEG kanalların sayısını azaltmak amacıyla farklı gruplardan gelen EEG sinyallerini, sınıflandırılmamış iki durumu çözümleyerek tekrarlı test edip tüm kanalların kromozom temsillerini uyguladıktan sonra tüm olasılık kombinasyonları deneyerek sonuca ulaşmıştır. Sonuç olarak bu modelle, 8-10 arasında seçilen kanal sayısı ile EEG sinyal tasarımının daha kolay yapılmasına ve sınıflandırma doğruluğun da daha başarılı olmasında daha etkili olduğu değerlendirilmesi yapılmıştır.

Ngai ve diğerleri, (2022) çalışmasında duygu tanıma için çoklu model yaklaşımı önerisi sunulmuştur. Bu yaklaşım, duygu tanıma performansını artırmak için EEG sinyalleri, yüz ve göz duygu tanıma modelleme yöntemleri kullanılmıştır. Göz metodunda duygu analizi için bakış pozisyonu ve gözbebeği çapı referans alınarak değerlendirme yapılmıştır. Yüz yönteminde duygu tanıma için yüz görüntüsü veya yüz derinliği dikkate alınmıştır. 49 üniversite öğrencisine 14 kısa video izletilerek veriler toplanmıştır. Çalışmanın metalojisinde, katılımcıların göz, yüz ve EEG verileri ön işlemeye alınmıştır. Bu işlemden sonra performans değerleri artırmak için çok dallı sinir ağı mimarisi kullanılmıştır. Bu mimari, göz ve yüz ifadelerine göre daha doğru duygu sınıflandırma performansı göstermiştir. Katılımcılara, her kısa videodan sonra değerlik-uyarılma değerleri için SAM anketi uygulanmıştır. Önerilen sistemle, sırasıyla uyarılma %77, değerlik %67.8 olarak bulunmuştur.

Asadzadeh, Yousefi Rezaii, Beheshti ve Meshgini, (2022) bu çalışmada duygu tanıma analizi yapmak için EEG sinyallerinden DGCNN tabanlı algoritma önerisinde bulunulmuştur. Her duygunun modelini bulmak için Bernoulli-Laplace tabanlı bayes model tercih edilmiştir. Bu model, EEG sinyalleri kullanarak hesaplama yapmadan önce sLORETA yöntemini kullanır. EEG kaynak lokasyonu için de LOTERA yöntemi seçilmiştir. Bu yöntem, beynin farklı bölgelerindeki aktiviteler hakkında uzay-zamansal bilgi edinmek için kullanılmıştır. Çalışmanın devamında DGCNN algoritması kullanılarak grafik desen sınıflandırılması yapılmasıyla EEG sinyalleri negatif ve pozitif duygu durumları olarak iki grupta sınıflandırılmıştır. Önerilen metod, Tebriz üniversitesi tarafından 16 kişiye (6 kadın-10 erkek) duygusal müzikler izletilerek oluşturulan veri seti, SEED ve DEAP veri setleri mevcut metodlarla kıyaslama yapılmıştır. Önerilen yöntemle,

bağımlı ve bağımsız senaryo olmak üzere her veri seti için farklı yöntemler kullanılarak önceden var olan çalışmalarla karşılaştırılmıştır. Tebriz üniversitesinin oluşturduğu veri seti üzerinden yapılan çalışmada, bağımlı ve bağımsız doğruluk değerleri sırasıyla %98.51, %97.77 olarak bulunmuştur. SEED veri seti üzerinden yapılan çalışmada, bağımlı ve bağımsız doğruluk değerleri sırasıyla %99.25, %98.51 olarak tespit edilmiştir. DEAP veri seti üzerinden yapılan çalışmada, bağımlı ve bağımsız doğruluk değerleri sırasıyla %98.96, %98.31 olarak bulunmuştur.

Uyanık, Ozcelik, Duranay, Sengur ve Acharya, (2022) çalışmalarında EEG sinyalleri temelli diferansiyel entropiyi (DE) kullanarak sanal ortamda duygu tanıma önerisi sunmuştur. Çalışmalarında, halka açık olan EEG tabanlı VREED adında yeni bir veri seti önerisinde bulunmuşlardır. Bu veri seti sanal gerçeklik ortamında 25 (10 kadın, 15 erkek) katılımcıya 60 video izletilerek oluşturulmuştur. Bu önerilen yöntem, ilk başta EEG sinyalleri dört alt ritim çıkarma (alpha, gamma, theta ve beta) işlemine alınmıştır. Alt ritimler çıkarıldıktan sonra DE yöntemiyle her EEG ritimleri bütün kanallar için özellik gruplaması yapılmıştır. Bu yöntemle, EEG sinyallerinin dört bandı kullanılarak pozitif ve negatif duygular sınıflandırılmıştır. Duyguların sınıflandırması için kNN, SVM, DT, NB ve LR sınıflandırıcılar uygulanarak yüksek doğruluk veren sınıflandırıcı belirlenmiştir. Çalışmanın sonucunda, önerilen yöntemle SVM sınıflandırıcıyla %76'lık doğruluk değeri elde edilmiştir. Frekans bantlarıyla kıyaslandığında ise Gamma frekansı en yüksek doğruluk çıkmıştır.

T. Tuncer, Dogan, Baygin ve Acharya, (2022) bu araştırmanın temel amacı oyun tabanlı yeni nesil özellik çıkarıcı kullanarak yüksek duygu tanıma oranı çıkarmaktır. Yeni oluşturulan dokusal özellik yöntemi olan Tetromino metodunu kullanarak EEG sinyalleriyle yüksek sınıflandırma doğruluğu amaçlanmıştır. Bu yöntem, üç veri seti sırasıyla DEAP, DREAMER ve GAMEEMO üzerinde incelemeler yapılmıştır. Metodoloji kısmında, EEG sinyalleri, çeşitli ayrışma seviyelerini belirlemek için altı kez ayrık dalgacık dönüşümü (DWT) uygulaması yapılmıştır. Daha sonra, ayrışmış DTW alt bantlarından yeni özellikler üretebilmek için Tetromino yöntemi kullanarak her alt bant için 2048 özellik çıkarılmıştır. Maksimum ilgi düzeyi ve minimum fazlalık (mRMR) yöntemi kullanılarak en fazla ayırt edici özellik seçimi yapılmıştır. Son olarak, Liner SVM sınıflandırıcıyla GAMEEMO ve DREAMER veri setlerinde %100 sınıflandırma

doğruluğu elde edilmiştir. DEEP veri seti üzerinde %99 üzerinde bir sınıflandırma doğruluğu bulunmuştur.

Z. Wang ve diğerleri, (2022) EEG duygu tanıma sürecinde etkili bir doğruluk değeri elde etmek ve ayrıca katılımcılar arasındaki bireysel farklılıkları ve yüksek boyutsallık problemi çözmek amacıyla STFFNN füzyon stratejisi önerilmiştir. Bu strateji, çoklu alan özelliği füzyonu ve özellik temsil öğrenme olarak iki bölüm oluşturulmuştur. İlk bölümde, özellik temsil öğrenme kısmında SDLN ve TFLN ağları kullanılmıştır. SDLN yapısı, BN ve IN kombinasyonları alan değiştirmeyen ayırt edici bilgileri korumak ve bireysel farklılıkları azaltmak için tercih edilmiştir. TFLN yapısında ise, CEF tabanlı ızgara arama stratejisi kullanılarak etkili bir şekilde ağ yapılandırılması optimize edilmiştir. İkinci bölümde, çoklu baskın özellik füzyonu kısmında FFN ağına yer verilmiştir. Bu ağda ise, Bi-LSTM yapısı diğer özellik ve karar düzeyindeki füzyon stratejilerine oranla daha başarılı performans göstermesinin nedeni karşılıklı bilgi öğrenmesiyle ortaya çıkmıştır. Bu çalışma, 32 sağlıklı bireyin katıldığı DEAP veri seti kullanılarak 10 kat çapraz doğrulama ve bağımlı denek olarak bu veri seti eğitim ve test aşamasından geçirilmiştir. Bağımlı denek üzerinde yapılan çalışmada, değerlik ve uyarılma doğruluk değerleri sırasıyla %85.42 ve %86.16 olarak, 10 kat çapraz doğrulama çalışmasında ise değerlik ve uyarılma doğruluk değerleri %80.17 ve %81.28 olarak bulunmuştur.

C. Li ve diğerleri, (2022) çalışmalarında gürültü etiketlerinin de içinde olduğu EEG tabanlı bir duygu tanıma yapısı önerilmiştir. Önerilen bu çalışma, EEG sinyallerinde oluşan gürültü problemini çözmek için tasarlanmıştır. Kapsül ağına dayalı olan ortak bir optimizasyon stratejisi (JO CapsNet) gürültü etiket sınıflandırma yöntemi kullanılmıştır. JOCapsNet stratejisi, EEG duygu sınıflandırma için test ve eğitim örneklerinin oluşturulması, test kısmı ve eğitim süreci olarak üç kısma ayrılmıştır. DREAMER ve DEAP veri setleri önerilen yöntemin avantajlarını göstermek için tercih edilmiştir. Yöntemi değerlendirmek için on kat çapraz doğrulama kullanılmıştır. Veri setleri önerilen metotla birlikte altı farklı (SVM, DT, MLP, geForest, CNN-RNN, Orijinal CapsNet) metotla karşılaştırması yapılmıştır. DEAP veri setinde farklı gürültü oranlarına göre (%10, %20, %30) önerilen yöntem, diğer yöntemlerle karşılaştırılması sonucunda uyarılma ve değerlik ortalama doğruluk değerleri sırasıyla %94.33, %92.64, %87.00 ve 94.38, %92.15, %85.26 elde edilmiştir. Diğer yöntemlere göre en yüksek ortalama

sınıflandırma doğruluk değerlerine ulaşılmıştır. DREAMER veri setinde farklı gürültü oranlarına göre (%10, %20, %30) önerilen yöntem, diğer yöntemlerle karşılaştırılması sonucunda uyarılma, değerlik ve baskınlık ortalama doğruluk değerleri sırasıyla uyarılma (%88.44, %87.46, %86.24), değerlik (%81.82, %80.04, %76.67) ve baskınlık (%89.28, %88.19, %86.97) elde edilmiştir. Diğer yöntemlere göre en yüksek ortalama sınıflandırma doğruluk değerlerine ulaşılmıştır. Sonuç olarak, yapılan çalışmada daha az gürültü oranıyla daha başarılı sonuçlar elde edildiği anlaşılmıştır.

Liu ve diğerleri, (2022) çalışmalarında duygu sınıflandırmak için minimum yayılma ağacı (MST) tabanlı grafik sinir ağı metodu sunulmuştur. Farklı duyguları tanımlamak için MST topolojisiyle yeni bir yöntem anlayışını önerilmiştir. MST yapısını araştırmak için hiyerarşik toplama tabanlı grafik sinir ağları (GNNs) kullanılmıştır. Önerilen yöntem, DEAP veri setinde deneyimlenmiştir. EEG sinyallerinden özellik çıkarımı için ağırlıklı faz gecikme indeksi (wPLI) yapısı kullanılmıştır. EEG tabanlı duygu tanımda önerilen modelle beş farklı model performansları karşılaştırıldığında farklı frekans bantlarında farklı performans değerleri elde edilmiştir. Önerilen yaklaşımla, Upper beta, Alpha, Theta, Gama ve Lower Beta bant frekanslarında sırasıyla %72.09, %74.79, %87.23, %90.27 ve %92.31 performans değerleriyle diğer yaklaşımlara göre en yüksek performans değerlerine ulaşılmıştır. Sonuç olarak, duygu tanıma yapılırken sadece tek frekans bantla sınırlamanın yapılamayacağını ve çok frekanslı bantlar değerlendirildikten sonra en iyi sonuç veren frekans bandın seçilmesi önerilmektedir. Gama, alt beta ve teta frekans bantları duyguları tespitinde daha hassas olduğu görülmüştür.

Xiao ve diğerleri, (2022) çalışmalarında EEG duygu tanıma amacıyla yeni yöntem olarak adlandırılan dört boyutlu dikkat tabanlı yapay sinir ağı (4D-aNN) yöntemi kullanılarak değerlendirme yapılmıştır. Bu deney için SEED, DEAP ve SEED IV veri setleri tercih edilmiştir. Bu yöntem, EEG sinyallerini spektral, zamansal ve uzamsal bilgilerinin yer aldığı 4D spektral, zamansal ve uzamsal boyutları girdi olarak referans alınmıştır. Bu yöntemde LSTM ve CNN modülü ilave edilmiştir. CNN modülünün görevi, EEG sinyallerinin spektral ve uzamsal bilgileriyle spektral uzamsal uyarı mekanizmalarını önemli frekans bantlarını ve beyin bölgelerini yakalamaktır. LSTM modülü ise CNN modülünün çıktılarından geçici bağımlılıkları çıkararak geçici uyarı mekanizmasıyla farklı geçici dilimlerin önemi araştırılmıştır. Bu deney için SEED, DEAP ve SEED IV veri setleri tercih edilmiştir. Önerilen yöntem, dört farklı metotla kıyaslama yapılmıştır.

4D-aNN metodu kullanılarak DEAP veri seti üzerinde yapılan deneyde değerlik ve uyarılma değerleri sırasıyla %96.90 ve %97.39 ortalama doğruluk sınıflandırma değerine ulaşılmıştır. SEED veri setinde %96.25 ortalama doğruluk değeri bulunmuştur. SEED IV veri setinde ise %86.77 ortalama doğruluk değerine varılmıştır. Bu yöntem, daha önce yapılan araştırmalara göre daha yüksek doğruluk değerine ulaşılmıştır.

Zhang ve diğerleri, (2022) araştırmalarında EEG tabanlı duygu tanımlama yapabilmek için GANSER adında yeni model önerilmiştir. Bu model, kendi kendini denetleyen üretken çekişmeli ağ tabanlı veri büyütme yapısını benimsemiştir. Bu yapı, AAN ve MTN olarak iki ağdan oluşmaktadır. Önerilen bu model, DEAP, SEED ve DREAMER veri setleri üzerinde uygulanmıştır. DEAP veri seti, on iki farklı modelle değerlik ve uyarılma doğruluk değerleri karşılaştırılarak analiz yapılmıştır. Çalışmada kullanılan model, beş-kat çapraz doğrulama metoduyla uyarılma ve değerlik değerleri sırasıyla %94.21 ve %93.21 olarak en yüksek doğruluk değerlerine ulaşılmıştır. SEED veri seti, yedi farklı modelle üç sınıf doğrulaması karşılaştırılarak analiz yapılmıştır. Çalışmada kullanılan model, beş kat çapraz doğrulama ve rastgele ayırma (8:2) ortalama doğruluk değeri %97.71 olarak en yüksek doğruluk değerleri bulunmuştur. DREAMER veri seti, on farklı modelle değerlik ve uyarılma doğruluk değerleri karşılaştırılmıştır. Çalışmada kullanılan model, on kat çapraz doğrulama metoduyla uyarılma ve değerlik değerleri sırasıyla %85.28 ve %84.16 olarak en yüksek değerlik doğruluk değerlerine ulaşılmıştır.

G. Li ve diğerleri, (2022) çalışmalarında az sayıda EEG kanal kullanılarak yüksek doğruluğa sahip yeni bir duygu tanıma yaklaşımı önerilmiştir. Bu yaklaşımı test etmek için SEED veri seti kullanılmıştır. Özellik çıkarımı için güç spektral yoğunluğu (PSD) ve diferansiyel entropi (DE) yöntemleri kullanılmıştır. Daha sonra duygu analizi için temporel loblar kullanılarak dokuz kanal seçilmiştir. Duygu tanıma üzerinde bireysel farklılıkları azaltmak için deney seviyesinde toplu normalleştirme (BN) yöntemi kullanılmıştır. Önerilen bu metot, on bir farklı (SVM, LR, KNN, BA, LSTM, CNN, DT, RF, XGB, MLP, GNB) sınıflandırıcıyla duygu tanıma doğruluğu elde edilmiştir. PSD ve BN yöntemleri aynı anda kullanılarak sınıflandırıcılar arasında MLP sınıflandırıcıyla %72.81 en yüksek doğruluk değerine ulaşılmıştır. DE ve BN yöntemleri aynı anda kullanılarak sınıflandırıcılar arasında LR sınıflandırıcıyla %89.63 doğruluk değeri elde edilmiştir. Bunlara ek olarak, önerilen yöntem daha az maliyetli EEG cihazlarında kullanılması potansiyeline sahiptir.

Dogan ve diğerkleri, (2022) bu çalışmada EEG sinyalleriyle yeni bir özellik çıkarma yöntemi olan Clefia-pattern modeli kullanılarak yüksek sınıflandırma doğruluğuna sahip otomatik duygu sınıflandırma modeli önerilmiştir. Bu model, DEAP ve DREAMER veri setleri üzerinden çalışılmıştır. EEG sinyalleri ham veriler üzerinden Clefia pattern ve TQWT yöntemleri uygulanarak özellik çıkarımı yapılmıştır. Özellik çıkarımından sonra özellik seçimi için mRMR metodu kullanılarak en iyi 1000 özellik seçilmiştir. Özelliklerin sınıflandırılması içinde Linear SVM sınıflandırıcı kullanılmıştır. Sonuç olarak, önerilen yöntemle DEAP veri setinde değerlik ve uyarılma doğruluk değerleri sırasıyla %98.02, %99.33, DREAMER veri setinde ise değerlik ve uyarılma doğruluk değerleri sırasıyla %99.66, %98.98 olarak yüksek sınıflandırma doğruluğu elde edilmiştir.

Literatürde yapılan çalışmalar incelendiğinde, bu tez çalışması neticesinde elde edilen sonuçlar oldukça tatmin edicidir. Tez çalışması kapsamında önerilen özgün özellik çıkarma yöntemi ile hem arousal hem de valence eksenini üzerinde %90'ın üzerinde doğrulukla sınıflandırma başarısı elde edilmiştir. Ek olarak, bu tez çalışmasıyla literatüre "AERG" adında yeni ve özgün bir veri seti kazandırılmıştır. Bu veri setinin yanı sıra yeni ve özgün bir özellik çıkarma metodu olan VitC-Pat örüntü modeli de yine bu tez çalışması kapsamında geliştirilmiştir.

3. BÖLÜM

MATERYAL

Tez çalışmasının bu bölümünde, araştırmacı tarafından toplanan EEG sinyallerinin detayları verilmiştir. Tez çalışması süresince uygulanan veri toplama aşamaları ve katılımcılara ait bilgiler alt bölümler halinde sunulmuştur.

3.1. DENEY PROSEDÜRÜ

Literatürde EEG sinyalleri tabanlı duygu tanıma ile alakalı olarak toplanmış çeşitli veri setleri mevcuttur. Gerçekleştirilen bu tez çalışmasında, literatüre katkı sağlamak amacıyla tamamen özgün ve yeni bir veri seti toplanmıştır. Toplanan bu veri seti “AERG (Ardahan Emotion Research Group)” olarak adlandırılmıştır. Veri toplama sürecinde mobil bir EEG cihazı olan Emotiv Epoc X serisi beyin şapkası kullanılmış olup, bu cihaza ait teknik bilgiler tez çalışmasının EK-1 bölümünde yer almaktadır.

Veri setinin oluşturulma fazında öncelikle bir deney ortamı oluşturulmuştur. Bu amaçla kayıt yapılmadan önce katılımcıların dikkatini dağıtacak öğeler ortadan kaldırılıp sessiz bir ortam oluşturulmuştur. Deneye katılacak kişilere konunun amacı, kayıt öncesinde ve anında neler yapmaları gerektiğiyle ilgili ön bilgilendirme yapılmıştır. Ek olarak, gönüllü katılımcılara izleyecekleri videolara odaklanmaları hususunda öneriler verilmiştir. Bu kapsamda EEG sinyallerindeki bozulmaları (artefak) olabildiğince minimize etmek için katılımcılara hareket etmeme, çiğneme yapmama, gözlerini sürekli kırpmama ve sağa sola çevirmeme, dişlerini gıcırdatmama veya sıkıkmama, duygusal videolarda olabildiğince ağlamama gibi önerilerde bulunulmuştur. Deney sırasında katılımcılara yedi farklı video izletilmiştir. Bu videoların amacı kişilerde farklı duyguları tetikleyebilmektir. Videoların içeriği hüznün, korku, mutluluk, nötr, öfke, şaşırma ve tikslenme temalarından meydana gelmektedir. Katılımcılara izletilen videolar 1 dakikadan az olmamak üzere toplam 7 türdedir. Bu videolar sırasıyla 06.40sn, 01.54sn, 04.09sn, 03.04sn, 04.02sn, 02.35sn ve 02.03sn uzunluğundadır. Videoların toplam süresi 24.27 dk’dır. Katılımcılardan veri alınmadan önce deney ortamı hazırlanmış ve katılımcıların sakinleşmesi kendilerine telkin edilmiştir. Daha sonrasında kendini hazır hisseden katılımcılara bir bilgisayar aracılığıyla videolar izletilmeye başlanmıştır.

Gönüllü katılımcılardan veri toplama işlemi Emotiv EPOC X beyin şapkası cihazı kullanılarak gerçekleştirilmiştir. Gönüllü katılımcıların beyanlarının dikkate alındığı bu çalışmada, deneklerin herhangi bir nörolojik rahatsızlığı bulunmamaktadır. Bu kapsamda, 13 erkek ve 9 kadın katılımcı olmak üzere toplam 22 kişiden beyin şapkası aracılığıyla EEG sinyalleri alınmış ve kayıt edilmiştir. Katılımcılara temel olarak 7 türdeki tüm videolar izletilmiş olup, bu videoların izlenmeleri ve yeni videoya geçiş sırasında hazırlık ve dinlenme evreleri dâhil toplam 5 dk'lık (1) 3 dk hazırlık ve dinlenme-1, 2) 1 dk dinlenme-2 ve 3) bir süre harcanmaktadır. Bu işlemi özetleyen bir blok diyagram Şekil 2'de sunulmuştur.



Şekil 2. Tez kapsamında gerçekleştirilen veri toplama prosedürü

Şekil 2'den de görülebileceği üzere ilk aşama hazırlık ve dinlenme evresidir. Gönüllü katılımcılara tüm bilgiler verildikten sonra beyin şapkası katılımcının kafa derisi üzerine yerleştirilmekte bağlantı kontrolleri gerçekleştirilmektedir. Bu işlemlerin tamamlanmasının ardından katılımcıya hazır hissedip hissetmediği sorulmuş ve katılımcıdan hazırım işareti geldikten sonra 3 dk süresince beklenilmiş ve katılımcının sakinleşmesi sağlanmıştır. Hemen ardından video bilgisayarda başlatılmış ve aynı anda kayıt işlemine geçilmiştir. EEG cihazları çevresel faktörlerden oldukça kolay etkilenebilen cihazlardır. Bu nedenle, bazen cihaz kaynaklı bazen de katılımcı kaynaklı artefaktlar oluşabilmektedir. Veri toplama sırasında bu ve benzeri durumlar meydana geldiğinde kayıt işlemi durdurulmuş ve ilgili video en sona bırakılarak diğer videolar izlendikten sonra katılımcıya tekrar izletilmiştir. Ek olarak, cihaz kontrolü (şarj durumu, solüsyon yeterlilik seviyesi vs.) gerçekleştirilerek gerekirse yedek cihaza geçilmiştir. Veri toplama anına ait örnek bir görüntü Şekil 3'te verilmiştir.



Şekil 3. Veri toplama sırasında alınan bir görüntü


Kayıt işleminin tamamlanmasının ardından katılımcılar yaklaşık 1 dk boyunca dinlendirilmiştir. Bu işlemin ardından katılımcılara ilgili video için duygularını değerlendirebilmeleri amacıyla en çok kullanılan tekniklerden biri olan öz değerlendirme anketi (SAM) uygulanmıştır (Bradley ve Lang, 1994). Tahmin edilebileceği gibi her videonun katılımcılarda uyaraacağı duygu durumu farklı olabilmektedir. Bu nedenle, SAM testi her videodan sonra katılımcılara uygulanmıştır. Katılımcılara uygulanan ankete ait bir görüntü bu tez çalışmasının EK-2 bölümünde sunulmuştur. Bu bağlamda toplanan EEG sinyallerinin özellikleri Tablo 1’de verilmiştir.

Tablo 1. AERG veri seti özellikleri

Özellik	Değer
Sinyal Türü	EEG
Cihaz ve Kanal Sayısı	EMOTİV EPOC X 14 kanal
Frekans	128 Hz
Örnekleme Oranı	15 sn
Toplam Örnek sayısı	951
Video sayısı	7
Uyarılma	Duygu videoları
Duygusal durum	Uyarılma (Arousal) Değerlik (Valence)
Kişi sayısı	22 (13 erkek, 9 kadın)
Yaş aralığı	18-45
Kayıt süresi toplam	24 dk

Tablo 1’den de görülebileceği üzere gönüllü katılımcılardan Emotiv Epoc X cihazı ile alınan sinyaller 128 Hz’dir. Başka bir deyişle, saniye başına 128 örnekleme noktası

bulunmaktadır. Toplanan sinyaller bir sonraki aşamada katılımcıların anket sonuçlarına göre segmentleme işlemine tabi tutulmuştur. Bu işlemde segmentleme oranı 15 sn olarak belirlenmiştir. Bu şekilde katılımcılardan alınan tüm EEG sinyalleri 15 sn olacak şekilde parçalara bölünmüş ve etiketlenmiştir. Sonuç olarak AERG veri seti için toplam 951 segment elde edilmiştir. Ek olarak, her segment katılımcıların SAM anket sonuçlarına göre uyarılma ve değerlik ekseninde olacak şekilde 0 veya 1 olarak etiketlenmiştir. Bu şekilde toplanan EEG sinyalleri geliştirilecek makine öğrenmesi modelinde kullanılabilir hale getirilmiştir. Tez çalışması kapsamında Emotiv EPOC X cihazından alınan örnek bir sinyal görüntüsü Şekil 4’te verilmiştir.




Şekil 4. Kayıt esnasında Emotiv EPOC X cihazından alınmış EEG sinyalleri

4. BÖLÜM

ÖNERİLEN YÖNTEM

4.1. VITC-PAT TABANLI OTOMATİK DUYGU SINIFLANDIRMA MODELİ

Gerçekleştirilen bu tez çalışması kapsamında araştırmacı tarafından duygu tanıma için toplanan EEG sinyalleri yine bu tez çalışması kapsamında önerilen makine öğrenmesi modeli ile sınıflandırılmış ve yorumlanmıştır. Önerilen bu yöntem temel olarak dört ana fazdan meydana gelmektedir. Bu fazlar sırasıyla sinyal ayrıştırma, özellik çıkarma, özellik seçme ve sınıflandırma adımlarıdır. Sinyal ayrıştırma fazında ayrık dalgacık dönüşümü (DWT) yöntemi kullanılmış olup, bu yöntem ile sinyal alt bantlarına ayrıştırılmıştır. Modelin ikinci fazı özellik çıkarımıdır. Bu aşamada 3 farklı özellik çıkarım tekniği uygulanmıştır. Bunlar sırasıyla VitC-Pat, LBP ve istatistiksel özellik çıkarımıdır. Tez çalışmasının ana temasını oluşturan VitC-Pat yöntemi temel olarak askorbik asit'ten ilham alınarak oluşturulmuş olup, bilinen adıyla C vitaminidir. Geliştirilen modelin üçüncü fazında ise iteratif komşuluk bileşen analizi (INCA) tabanlı özellik seçim yöntemi kullanılmıştır. Bu sayede anlamsız özellikler elimine edilmiş ve özellik vektörünün boyutu azaltılmıştır. Önerilen yöntemin son fazında ise sınıflandırma işlemi uygulanmıştır. Bu aşamada, literatürde iyi bilinen klasik yöntemlerden biri olan destek vektör makineleri (SVM) kullanılmıştır. Tez çalışmasının bu adımlarını özetleyen bir blok diyagram Şekil 5'te verilmiştir.



Şekil 5. Önerilen Vit-C modeline dayalı duygusal EEG sınıflandırma sisteminin blok diyagramı

Şekil 5'ten görülebileceği üzere önerilen yöntem AERG veri setini giriş olarak almakta ve kanal bazlı sonuç hesaplamaktadır. Veri seti toplam 14 kanal içermektedir. Bu nedenle, Şekil 5'te verilen adımlar her kanal için yani 14 defa tekrar edilmektedir. Önerilen yöntem, hem ham EEG sinyalinden hem de DWT aracılığıyla üretilen alt bantlardan özellik çıkarmaktadır. Bu noktada, ham EEG sinyalinden de özellik çıkarılmasının temel amacı ana sinyalden de özellik vektörü elde edebilmektir. Geliştirilen modelin özellik çıkarma aşamasında üç farklı yöntem kullanılmakta ve bu yöntemlerden gelen özellik vektörleri birleştirilmektedir. Bu çalışmada, 4 seviye DWT, EEG sinyalinin yüksek ve düşük filtre alt bantlarını hesaplamak için kullanılmıştır. Bu nedenle beş adet özellik vektörü (1 özellik vektörü ham sinyalden + 4 özellik vektörü alt bantlardan) elde edilmektedir. Geliştirilen model de kullanılan özellik çıkarıcılardan VitC-Pat toplam 384


özellik, LBP yöntemi 256 özellik ve istatistik ise 40 adet özellik çıkarmaktadır. Bu özelliklerin toplamı 680 olmaktadır. Başka bir deyişle ham sinyal ve alt bantların her birinden 680 özellik elde edilmektedir. Modelin bir sonraki aşamasında ise bu özellik vektörleri birleştirilmekte ve 3400 (5x680) uzunluğunda büyük bir özellik vektörü elde edilmektedir. Modelin bir sonraki fazında İteratif NCA yöntemi kullanılarak bu özellik vektörünün boyutu azaltılmıştır. Bu sayede anlamsız özellikler elimine edilmiştir. Uygulamanın son aşamasında ise SVM yöntemi kullanılarak indirgenmiş özellik vektörleri sınıflandırılmıştır.

Tez çalışması kapsamında önerilen modeli geliştirmek için kullanılan bu yöntemlerin detayları alt bölümlerde sunulmuştur.

4.2. SİNYAL AYRIŞTIRMA

Ayrık dalgacık dönüşümü (DWT), sinyal analizi ve sinyalleri işlemek için literatürde iyi bilinen ve sıklıkla kullanılan bir yaklaşımdır. Makine öğrenmesi gibi yöntemlerde sinyalleri ayrıştırmak için aktif olarak kullanılmaktadır. Temel olarak sinyalleri yüksek ve düşük frekans bileşenlerine ayırmaktadır. DWT sinyalleri ayrıştırmak için çeşitli filtreleme işlemleri kullanmaktadır. Bu sayede sinyal farklı ölçeklerdeki bileşenlerine ayrılmaktadır. Bu işlem ile veriler zaman-frekans uzayında analiz edilebilmektedir. Ek olarak, ayrıştırılmış bileşenler orijinal sinyalin belirli özelliklerini taşımakta ve vurgulamaktadır.

Gerçekleştirilen bu tez çalışmasında da sinyal ayrıştırma yöntemi olarak DWT tercih edilmiştir. Uygulanması kolay olan bu yaklaşımda 4 seviye sinyal ayrıştırması yapılmış olup her seviyenin düşük frekans bileşenine özellik çıkarımı uygulanmıştır. Başka bir deyişle, özellik çıkarım aşamasında sadece düşük frekans bileşenleri kullanılmıştır. Ek olarak, DWT işleminde filtre olarak Daubechies 4 (db4) kullanılmıştır. Tez çalışmasında kullanıldığı şekliyle 4 seviye DWT işlemini gösteren bir blok diyagram Şekil 6'da verilmiştir.



Şekil 6. DWT tabanlı alçak ve yüksek geçirgen filtre


Şekil 6'dan da görülebileceği üzere DWT kendisine giriş olarak aldığı sinyali alt bantlarına ayırmaktadır. Bu işlem 4 seviye olarak gerçekleştirilmektedir. Her seviye de alt bantlardan özellik çıkarılmaktadır. Sistem bir sonraki seviyeye geçişte alçak bantı yeni sinyal girişi olarak kabul etmektedir.

4.3. ÖZELLİK ÇIKARMA

Gerçekleştirilen bu tez çalışmasında ham EEG sinyali ve alt bantlardan özellik çıkarımı yapılmaktadır. Bu fazda üç farklı özellik çıkarımı gerçekleştirilmektedir. Bunlar sırasıyla, VitC-Pat (Vitamin C Örüntüsü-Askorbik Asit Örüntüsü), LBP ve istatistiktir. Bu yöntemlerin detayları alt bölümler halinde verilmiştir.


4.3.1. VitC-Pattern

Askorbik asit insanlar için oldukça önemli ve hayati bir vitamin çeşididir. Halk arasında bu kimyasal bileşen C vitamini olarak adlandırılmaktadır. Gerçekleştirilen bu çalışmada da özellik çıkarıcı olarak C vitamininin kimyasal çizgesinden faydalanılmış ve özgün bir özellik çıkarıcı elde edilmiştir. Askorbik aside ait “PubChem” web sitesinden alınmış olan kimyasal çizgeye ait bir görüntü Şekil 7’de verilmiştir.



Şekil 7. Askorbik asit-C vitamini kimyasal çizge yapısı

Bu tez çalışmasında, askorbik asidin kimyasal çizgesinden ilham alınarak yeni ve özgün bir özellik çıkarıcı önerilmiştir. Bu özellik çıkarıcının haritalanmış yapısı Şekil 8’de verilmiştir.



Şekil 8. Kimyasal örüntüden faydalanılarak elde edilen yönlü graf

Şekil 8’den görülebileceği üzere askorbik asidin yani C vitaminin kimyasal çizgesi yönlü graflara dönüştürülmüştür. Bu sayede EEG sinyalinin özellik çıkarımı

yapılabilmektedir. Yönlü graflar kullanılarak özellik çıkarma işlemi literatürde sıklıkla kullanılan bir yöntemdir. Bu işlemde kimyasal çizgedeki kenarlar yönlü grafa dönüştürülmektedir. Yönlü grapta yer alan oklar örüntünün yolunu göstermektedir. Okun noktaları ise özellik çıkarmak için kullanılan değerleri göstermektedir. Bu işlemde özellik çıkarmak için signum ve ternary çekirdekleri kullanılmaktadır. Şekil 8’de görüleceği üzere 12 kenar bulunmaktadır. Bu kenarlar kullanılarak 12 bit üretilmektedir. Temel olarak 12 bit kullanılarak üretilebilecek özellik sayısı 2^{12} ’dir ve bu oldukça yüksek bir orandır. Bu nedenle kenarlar 2 gruba ayrılmış ve her grupta 6 bit kullanılmıştır. Bu sayede 2^6 (=64) özellik çıkarılmıştır. Özellik çıkarma işleminde signum ve ternary fonksiyonları kullanılmıştır. Bu fonksiyonlar temel olarak bir karşılaştırma işlemidir. Ternary fonksiyonu ise iki gruba ayrılmaktadır. Bunlar sırasıyla upper ternary ve lower ternary’dir. Bu fonksiyonların matematiksel karşılıkları Denklem 1-4 arasında verilmektedir.

$$Sgn(a, b) = \begin{cases} 0, & a - b < 0 \\ 1, & a - b \geq 0 \end{cases} \quad (1)$$

$$UT(a, b) = \begin{cases} 0, & a - b \leq thr \\ 1, & a - b > thr \end{cases} \quad (2)$$

$$LT(a, b) = \begin{cases} 0, & a - b \geq thr \\ 1, & a - b < thr \end{cases} \quad (3)$$

$$thr = \frac{std(sinyal)}{2} \quad (4)$$

Burada, $Sgn(a, b)$ signum fonksiyonunu gösterirken, $UT(a, b)$ ve $LT(a, b)$ sırasıyla upper ve lower ternary fonksiyonlarını göstermektedir. Ayrıca, thr ternary fonksiyonları için eşik değerini ifade etmektedir. Yine bu fonksiyonda kullanılan std ise sinyalin standart sapmasını göstermektedir. Eşik değerini hesaplamak için sinyalin standart sapmasının yarısı alınmaktadır. Bu fonksiyonlar kullanılarak ikilik tabandaki özellikler üretilmektedir. Daha sonrasında bu ikilik özellikler kullanılarak harita sinyalleri oluşturulmaktadır. VitC-Pat kullanılarak gerçekleştirilen özellik çıkarma işlemine ait adımlar detaylı bir şekilde aşağıda sunulmuştur.

VitC-Pat Adımları:

Adım 1: Sinyali 80 uzunluğunda örtüşen bloklara böl.

Adım 2: 80 uzunluğundaki bloğu 10 x 8 matris boyutuna dönüştür.

Adım 3: Şekil 8’de verilen kimyasal örüntüyü bu matrise uygula.

Adım 4: Signum ve ternary fonksiyonlarını kullanarak ikilik tabandaki özellikleri oluştur.


Adım 5: İkilik tabandaki özellikleri 10’luk tabana çevir ve harita matrisine ekle.

Adım 6: Sinyalin uzunluğu kadar Adım 1’den itibaren tekrar et.

Adım 7: Harita matrisinin histogramını çıkar ve özellik matrisini döndür.

4.3.2. Yerel İkili Örüntüler (LBP)

Yerel ikili örüntüler (LBP), literatürde genellikle görüntüden özellik çıkarmak için kullanılmaktadır. LBP yöntemi, bir görselin merkez pikseli ile onu çevreleyen komşu pikseller arasındaki piksel farkının (negatif ve pozitif) karşılaştırılarak gri ölçekli görüntünün ikili kodlar oluşturularak özellik vektörlerine dönüştürülmesi işlemidir (Zhou, Du, Li, Mi ve Luan, 2018). Bu yöntemle görsel, 3 x 3 matrislere bölünmekte ve merkez pikselle komşu pikseller karşılaştırılmaktadır. Bu işlem temel olarak Denklem (1)’de verilen signum fonksiyonu ile gerçekleştirilmektedir. Daha sonra ikilik tabanda elde edilen sayı onluk tabana çevrilmekte ve merkez piksele yazılmaktadır (Yıldırım, 2022). Bu işlemi özetleyen bir blok diyagram Şekil 9’da verilmiştir.



Şekil 9. Yerel ikili örüntü yöntemi

Bölüm başında da belirtildiği üzere, yerel ikili örüntüler de tıpkı VitC-Pat yönteminde olduğu gibi hesaplanmaktadır. Bu özellik çıkarma yaklaşımında da sinyal örtüşen 9 bloğa

bölünmektedir. Daha sonra bu sinyal 3 x 3 boyutlarına dönüştürülmekte ve signum fonksiyonu kullanarak ikilik tabanda bir sayı elde edilmektedir. Bu işlemin ardında ikilik tabandaki sayı onluk sisteme dönüştürülmekte ve harita matrisine bu onluk tabandaki sayı eklenmektedir. Son olarak sinyalin uzunluğu tamamlandığında harita matrisinin histogramı çıkarılmakta ve özellik matrisi elde edilmektedir. Yerel ikili örüntüler ile bir sinyalden toplam 256 (2^8) adet özellik elde edilmektedir. LBP yönteminin adımları aşağıda maddeler halinde verilmiştir.

LBP Adımları:

Adım 1: Sinyali 9 uzunluğunda örtüşen bloklara böl.

Adım 2: 9 uzunluğundaki bloğu 3 x 3 matris boyutuna dönüştür.

Adım 3: Şekil 9'da verilen sistematiği bu matrise uygula.

Adım 4: Signum fonksiyonunu kullanarak ikilik tabandaki özellikleri oluştur.

Adım 5: İkilik tabandaki özellikleri 10'luk tabana çevir ve harita matrisine ekle.

Adım 6: Sinyalin uzunluğu kadar Adım 1'den itibaren tekrar et.

Adım 7: Harita matrisinin histogramını çıkar ve özellik matrisini döndür.

4.3.3. İstatiksel Özellik Çıkarımı

Özellik çıkarımı işleminde kullanılan bir diğer yöntem ise istatistiktir. Bu yöntem ile sinyale ait istatistiksel özellikler çıkarılmaktadır. Bu fazda sinyalden lineer ve non-lineer yani lineer olmayan özellikler çıkarılmaktadır. Toplam 40 adet istatistiksel moment hesaplanmaktadır. İstatistiksel özellik çıkarım işlemi de diğer yöntemlerde olduğu gibi hem ham EEG sinyaline hem de alt bantların tamamına uygulanmaktadır. Bu istatistiksel momentlerin 18 tanesi lineer olup geriye kalan 7'si lineer değildir. DWT yöntemi kullanılarak ham sinyaller ve alt bant sinyalleri aracılığıyla istatistiksel moment özellik çıkarımı yapılmıştır. Son durumda ise, her iki gruptan çıkarılan bu özellikler birleştirilmiştir. 25 istatistiksel momentin matematiksel denklemi (1-25) aşağıda sunulmuştur (Baygin, 2021).

$$f_1 = \frac{\sum x}{n}, \quad x = \text{sinyal} \quad (1)$$

$$f_2 = \frac{\sum (x - f_1)^2}{n - 1} \quad (2)$$

$$f_3 = \sqrt{\frac{\sum (x - f_1)^2}{n - 1}} \quad (3)$$

$$f_4 = \left\{ \frac{(n + 1)}{2} \right\} \quad (4)$$

$$f_5 = \max (x) \quad (5)$$

$$f_6 = \min (x) \quad (6)$$

$$f_7 = f_5 - f_6 \quad (7)$$

$$f_8 = \sqrt{\frac{\sum x^2}{n}} \quad (8)$$

$$f_9 = \sum x^2 \quad (9)$$

$$f_{10} = \frac{\sum y}{n}, \quad y = |x| \quad (10)$$

$$f_{11} = \frac{\sum (y - f_{10})^2}{n - 1} \quad (11)$$

$$f_{12} = \sqrt{\frac{\sum (y - f_{10})^2}{n - 1}} \quad (12)$$

$$f_{13} = \left\{ \frac{(n + 1)}{2} \right\} \quad (13)$$

$$f_{14} = |x_i| \leq p + \sum_i \min(x_i^2, p^2), \quad p = threshold \quad (14)$$

$$f_{15} = - \sum_i x_i^2 \log (x_i^2) \quad (15)$$

$$f_{16} = \sum_i \log(x_i^2) \quad (16)$$

$$f_{17} = - \sum_i y_i^2 \log(y_i^2) \quad (17)$$

$$f_{18} = |y_i| \leq p + \sum_i \min(y_i^2, p^2) \quad (18)$$

$$f_{19} = \sum_i \log(y_i^2) \quad (19)$$

$$f_{20} = \frac{E(y - f_{10})^4}{(f_{11})^4} \quad (20)$$

$$f_{21} = \frac{E(x - f_1)^4}{(f_2)^4} \quad (21)$$

$$f_{22} = \frac{E(y - f_{10})^3}{(f_{11})^3} \quad (22)$$

$$f_{23} = \frac{E(x - f_1)^3}{(f_2)^3} \quad (23)$$

$$f_{24} = \frac{\sum |y - f_{10}|}{n} \quad (24)$$

$$f_{25} = \frac{\sum |x - f_1|}{n} \quad (25)$$

Yukarıda denklemlerde, x sinyali, y ise sinyalin mutlak değerini göstermektedir. f_1, f_2, f_3, f_4, f_5 ve f_6 sırasıyla sinyalin ortalamasını, varyansını, standart sapmasını, ortancasını, maksimumunu ve minimumunu, f_7 maksimum ve minimum arasındaki farkı, f_8 ve f_9 ortalama karekökü ve toplamını gösterir. Ayrıca f_{10}, f_{11}, f_{12} ve f_{13} , sinyalin mutlak değerinin ortalama, varyans, standart sapma ve medyan değerlerini ifade etmektedir. f_{14}, f_{15} ve f_{16} sırasıyla süre, shannon, ve log enerji entropilerini hesaplamaktadır. Ayrıca f_{17}, f_{18} ve f_{19} sinyalin mutlak değerinin shannon, süre ve log enerji entropisinin formüle edilmiş halidir. f_{20} ve f_{21} kurtosis sürecini, f_{22} ve f_{23} skewness değerlerini temsil etmektedir. Son olarak, f_{24} ve f_{25} , sinyalin ortalama mutlak sapmasını hesaplayan formüllerdir.

4.4. ÖZELLİK SEÇME

Gerçekleştirilen tez çalışmasının üçüncü fazı özellik seçmedir. Özellik seçme işlemi temel olarak anlamsız özelliklerin elimine edilmesi ve sınıflandırma sonucu üzerinde baskın olabilecek özelliklerin seçilmesidir. Bu aşamada komşuluk bileşen analizi (NCA) yöntemi tercih edilmiştir. NCA yöntemi literatürde iyi bilinen ve sıklıkla kullanılan bir yaklaşımdır (Barua ve diğerleri, 2023). Bu yöntem ayrıca sınıflandırma tahmin doğruluğunu artırmayı amaçlayan özellik seçme algoritmasıdır (Goldberger, Roweis, Hinton ve Salakhutdinov, 2005).


Tahmin edilebileceği üzere optimum özellik sayısının bilinmesi oldukça zordur. Bu noktada uygulanabilecek iki yöntem vardır. Bunlar sırasıyla deneme-yanılma ve İteratif seçme işlemidir. Bu tez çalışmasında İteratif seçme yaklaşımı tercih edilerek maksimum doğruluk değerinin elde edilmesi amaçlanmıştır. Literatürde İteratif NCA algoritması INCA olarak bilinmektedir ve NCA algoritmasının gelişmiş bir versiyonudur (I. Tuncer ve diğerleri, 2023). Bu yöntem, çıkarılmış özelliklerin en bilgilendirici olanlarını seçmek için tercih edilmektedir. INCA yönteminde öncelikli olarak özellik vektörünün her bir sütunu için ağırlık değeri hesaplanmaktadır. Daha sonrasında bu ağırlık değerlerine göre büyükten küçüğe doğru sıralanan özellikler sırasıyla sınıflandırma algoritmasına verilmekte ve maksimum sınıflandırma doğruluğunun elde edildiği nokta optimum özellik sayısı olarak kabul edilmektedir. Optimum özellik sayısının belirlenmesinin ardından nihai özellik vektörü oluşturulmakta ve tez kapsamında geliştirilen makine öğrenmesi modelinin sınıflandırma fazına iletilmektedir.

4.5. SINIFLANDIRMA

Tez çalışmasının son aşaması sınıflandırmadır. Sınıflandırma işlemi bir önceki fazda INCA algoritması kullanılarak elde edilen özellik vektörünü giriş parametresi olarak almaktadır. Bu fazda yine literatürde iyi bilinen bir algoritma olan destek vektör makineler (SVM) kullanılmıştır. Bu yöntem uygulanması oldukça kolay olan bir yaklaşımdır. SVM, regresyon analizi ve sınıflandırma için kullanılan dizi halindeki etiketli eğitim verileri üzerinden girdi çıktı eşleştirme işlevleri üreten denetimli bir öğrenme biçimidir (L. Wang, 2005). Algoritma, ölçülebilir bellek ihtiyaçlarına sahiptir

ve daha çok destek vektör kullanılarak sorunları kolay ve verimli bir şekilde çözümlemektedir (Noble, 2006). SVM yöntemi, konuşma tanıma, görüntü kümele ve sınıflandırma, metin sınıflandırma, örüntü tanıma, el yazısı tanıma problemi vb. birçok alanda kullanılmaktadır (Pradhan, 2012).

Sınıflandırma algoritmasının test aşamasında k-katlamalı çapraz doğrulama metodu kullanılmıştır. Bu yöntemde veri setindeki tüm elemanlar hem eğitim hem de test bölümünde kullanılmaktadır. Burada k değeri 10 olarak seçilmiş olup, 10-katlamalı çapraz doğrulama işlemine ait bir blok diyagram Şekil 10'da verilmiştir.



Şekil 10. 10-katlamalı çapraz doğrulama işlemine ait bir blok diyagram

5. BÖLÜM

DENEYSEL SONUÇLAR VE TARTIŞMA

Gerçekleştirilen bu tez çalışmasında giriş olarak EEG sinyallerini kullanan otomatik duygu tanıma modeli geliştirilmiştir. Özgün bir veri seti ve yine özgün bir makine öğrenmesi modelinin geliştirildiği bu çalışmada deneysel çalışmalara ait sonuçlar alt bölümler halinde sunulmuştur.

5.1. DENEYSEL PLATFORM

Önerilen VitC-Pat tabanlı otomatik EEG sınıflandırma ve yorumlayıcı modeli MATLAB2021a platformu kullanılarak programlanmıştır. Ayrıca sınıflandırma işlemi Matlab Classification Learner Toolbox üzerinde gerçekleştirilmiştir. Geliştirilen modelin test işlemlerinin gerçekleştirildiği bilgisayara ait detaylar Tablo 2’de sunulmuştur.

Tablo 2. Test işlemlerinin gerçekleştirildiği platform detayları

Özellik	Değer
İşlemci	Intel Xeon (2 işlemci)
Hız	2.70 GHz
Yüklü Bellek	256 GB Ram
Harddisk	370 GB
İşletim Sistemi	Windows Server 2019
Sistem Türü	64 bit
Uygulama Platformu	MATLAB 2021a
Sınıflandırma Platformu	Matlab Classification Learner Toolbox

5.2. PERFORMANS ÖLÇÜM PARAMETRELERİ

Tez kapsamında geliştirilen modelin performansını gözlemleyebilmek için standart performans metrik değerleri kullanılmıştır. Bunlar sırasıyla doğruluk (Doğ), kesinlik (Kes), duyarlılık (Duy), F1-Skor (F1) ve geometrik ortalama (Gm) değerleridir. Bu değerler hesaplanırken bir hata matrisi kullanılmaktadır. Bu hata matrisi tablosu gerçek değerlere karşılık tahmin edilen değerlerin bir dağılımını göstermektedir. Bu tabloyu

gösteren bir blok diyagram Şekil 11’de verilmiş olup, yine bu tabloyu kullanarak hesaplanan performans metrik değerleri Denklem (31)-(35) arasında paylaşılmıştır.

Tahminlenen Sınıflar	
Doğru Sınıflar	Doğru Pozitif (TP)
	Yanlış Negatif (FN)
	Yanlış Pozitif (FP)
	Doğru Negatif (TN)

Şekil 11. Örnek bir hata matrisi

Şekil 11’de verilen hata matrisi kullanılarak hesaplanan performans metrik değerlerinin matematiksel eşdeğerleri aşağıdaki denklemlerde sunulmuştur.

$$Doğ = \frac{TP + TN}{TP + TN + FP + FN} \quad (31)$$

$$Kes = \frac{TP}{TP + FP} \quad (32)$$

$$Duy = \frac{TP}{TP + FN} \quad (33)$$

$$F1 = 2 * \frac{Kes * Duy}{Kes + Duy} \quad (34)$$

$$Gm = \sqrt{TP * Kes} \quad (35)$$

5.3. DENEYSEL SONUÇLAR

VitC-Pat tabanlı EEG sinyali kullanan otomatik duygu sınıflandırma ve yorumlama modeli sınıflandırma fazında 10-katlamalı çapraz doğrulama tekniği uygulanarak test edilmiştir. Bu test işlemleri arousal ve valence eksenleri için ayrı ayrı gerçekleştirilmiş olup kanal bazlı sonuçlar elde edilmiştir. Ek olarak, her kanal için hata matrisi hesaplanmış ve bu matris kullanılarak performans metrik değerleri hesaplanmıştır. Özgün olarak toplanan veri seti toplam 14 kanaldan meydana gelmektedir. Her kanal için

hesaplanan performans metrik değerleri arousal ve valence eksenleri için sırasıyla Tablo 3 ve 4'te paylaşılmıştır.

Tablo 3. Arousal eksenini için SVM sınıflandırıcı kullanılarak elde edilen performans metrik değerleri


Kanal No	Doğ	Kes	Duy	F1	Gm
1	91.17	91.15	90.84	90.98	90.81
2	89.06	89.07	88.62	88.81	88.55
3	88.85	88.61	88.77	88.68	88.77
4	86.65	87.01	85.81	86.22	85.57
5	89.27	89.90	88.41	88.91	88.17
6	85.91	86.95	84.68	85.29	84.16
7	83.39	83.95	82.25	82.73	81.79
8	88.43	88.82	87.67	88.07	87.47
9	87.28	88.14	86.19	86.77	85.80
10	87.49	87.62	86.86	87.15	86.73
11	87.28	87.97	86.28	86.80	85.95
12	86.75	86.48	86.63	86.55	86.63
13	92.74	92.88	92.35	92.57	92.30
14	90.54	90.56	90.14	90.32	90.10

Tablo 3'ten görülebileceği üzere 10-katlamalı çapraz doğrulama stratejisini kullanan SVM algoritması en yüksek sınıflandırma doğruluğunu 13 no'lu kanal üzerinde elde etmiştir. Benzer durum valence eksenini içinde geçerli olup, bu eksen için kanal bazlı elde edilen sonuçlar Tablo 4'te sunulmuştur.


Tablo 4. Valence eksenini için SVM sınıflandırıcı kullanılarak elde edilen performans metrik değerleri

Kanal No	Doğ	Kes	Duy	F1	Gm
1	92.11	91.50	90.62	91.03	90.50
2	93.38	93.02	91.96	92.46	91.86
3	85.17	85.01	80.84	82.36	79.78
4	92.32	92.42	90.14	91.14	89.90
5	92.32	93.08	89.59	91.02	89.21
6	85.07	86.14	79.73	81.76	78.11
7	87.91	88.50	83.91	85.61	83.05
8	89.80	89.99	86.75	88.07	86.27
9	89.06	88.51	86.51	87.38	86.18
10	87.70	87.34	84.46	85.64	83.90
11	89.06	89.71	85.41	87.05	84.70
12	89.27	88.69	86.83	87.65	86.52
13	96.85	95.88	97.24	96.50	97.23
14	92.95	92.76	91.25	91.94	91.10

Tablo 4’te verilen sonuçlar tıpkı arousal ekseninde olduğu gibi valence için de en yüksek sınıflandırma başarısının 13 no’lu kanalda olduğunu ortaya koymaktadır. Bu kapsamda hem arousal hem de valence eksenini için 13 numaralı kanala ait hata matrisleri ise Şekil 12’de verilmiştir.



(a)




(b)

Şekil 12. EEG sinyalinin 13 numaralı kanalı için arousal ve valence eksenlerine ait hata matrisleri (a) Arousal (b) Valence


Gerçekleştirilen bu test işlemlerinin tamamı 10-katlamalı çapraz doğrulama tekniği kullanılarak uygulanmıştır. Önerilen yöntem hem arousal hem de valence için 13 numaralı kanalda %90'nın üzerinde bir sınıflandırma başarısına ulaşmıştır. Bu duruma ek olarak, hem arousal hem de valence eksenini için 1 ve 14 numaralı kanalların her ikisi de %90'nın üzerinde başarıya ulaşmıştır.

5.4. TARTIŞMA

Bu tez çalışması kapsamında önerilen yöntem temel olarak özellik çıkarma, özellik seçme ve sınıflandırma fazlarından meydana gelmektedir. Önerilen yöntemin özellik çıkarma aşamasında bu tez çalışması kapsamında özgün olarak geliştirilen ve C vitamininden ilham alınan VitC-Pat adında yeni bir örüntü önerilmiştir. Bu yönteme ek olarak, literatürde iyi bilinen yerel ikili örüntüler ve istatistiksel özellik çıkarım yaklaşımları da kullanılmıştır. Tez çalışmasının ikinci fazında özellik seçme işlemi uygulanmıştır. Bu aşamada ise literatürde komşuluk bileşen analizi olarak bilinen NCA yöntemi kullanılmıştır. Modelin son aşamasında ise 10-katlamalı çapraz doğrulama stratejisini kullanan ve basit bir sınıflandırıcı olan destek vektör makineleri kullanılmıştır. Geliştirilen modelin özellik seçme aşamasında NCA yönteminin ileri bir versiyonu olan iteratif NCA kullanılmıştır. Bu sayede seçilmesi gereken optimum özellik sayısı iteratif olarak belirlenmiştir. Şekil 13'de kanal bazlı seçilen özellik sayıları arousal ve valence için verilmiştir.



(a)




(b)

Şekil 13. Kanal bazlı seçilen özellik sayıları (a) Arousal ve (b) Valence


Şekil 13'den de görülebileceği üzere her kanal için iteratif olarak seçilen özellik sayıları birbirinden farklıdır. Önerilen bu yöntem ile seçilecek özellik sayısının optimum noktası belirlenebilmekte ve en az sayıda özellik kullanılarak sınıflandırma işlemi

gerçekleştirilmektedir. Ek olarak, bu yöntem sayesinde geliştirilen modelin hesaplama karmaşıklığı azaltılmakta ve minimum özellik maksimum doğruluk prensibine göre sınıflandırma işlemi yapılmaktadır. Bu bağlamda, 13 numaralı kanal için seçilen özellik sayıları dikkate alındığında arousal için 127 ve valence için 363 adet özelliğin seçildiği görülmektedir.

Geliştirilen modelin son aşaması sınıflandırmadır. Bu aşamada 10-katlamalı çapraz doğrulama tekniği uygulanmış ve kanal bazlı performans metrik değerleri elde edilmiştir. En yüksek sınıflandırma doğruluğuna 13 numaralı kanal üzerinde SVM yöntemi ile ulaşılmış olup, arousal için %92.74 ve valence için %96.85 değerlerine ulaşılmıştır. Tahmin edilebileceği üzere literatürde çok çeşitli sınıflandırma yaklaşımları mevcuttur. Tez çalışmasında SVM yöntemi kullanılmış olsa da model geliştirme sürecinde yine literatürde iyi bilinen bir yöntem olan k-en yakın komşu (kNN) algoritması da test edilmiştir. 13 numaralı kanal üzerinde SVM ve kNN sınıflandırma algoritmaları kullanılarak gerçekleştirilen bu test işlemine ait karşılaştırmalı bir sonuç yine arousal ve valence için Şekil 14'te verilmiştir.



(a)



(b)

Şekil 14. Arousal ve valence eksenleri için kNN ve SVM sınıflandırıcılarının kanal bazlı karşılaştırmalı sonuçları (a) Arousal ve (b) Valence

Şekil 14'ten de görülebileceği üzere hem arousal hem de valence için en yüksek sınıflandırma doğruluğu SVM algoritması ile 13 numaralı kanalda elde edilmiştir. Ayrıca yine verilen grafikler incelendiğinde bazı kanallarda kNN algoritmasının daha performanslı olduğu görülmektedir. Fakat bu tez çalışmasında gerçekleştirilen test işlemleri sonucunda en yüksek sınıflandırma doğruluğunun elde edildiği algoritma (SVM) ve kanal (13) nihai çözüm olarak kabul edilmiştir.

Gao ve diğerleri, (2022) tarafından yapılan çalışmada DEAP veri seti kullanılarak zamansal sinir ağ metodu önerilmiş olup, SVM sınıflandırıcı kullanılarak değerlik ve uyarılma değerleri sırasıyla %75.2 ve %80.22 sınıflandırma doğruluk değeri elde edilmiştir. Aynı şekilde, Ngai ve diğerleri (2022) tarafından duygu tanıma üzerine yapılan bir çalışmada, 49 üniversite öğrencisine 14 kısa video izletilerek veriler toplanmıştır. Çok dallı sinir ağ yapısı kullanılarak uyarılma %77 ve değerlik %67.8 olarak tespit edilmiştir. Bunlara ek olarak, Zhang ve diğerleri (2022) bu çalışmada, 32 sağlıklı bireyin katıldığı DEAP veri seti kullanılarak 10 kat çapraz doğrulama yapılarak değerlik ve uyarılma doğruluk değerleri sırasıyla %85.42 ve %86.16 olarak bulunmuştur.

Bu çalışmalar ışığında, bu tez çalışmasında önerilen VİT-C modeli ve SVM sınıflandırıcı uygulanarak değerlik ve uyarılma değerleri bu araştırmalara göre daha üstün sınıflandırma doğruluğu ile elde edilmiştir.

5.5. ÖNE ÇIKAN NOKTALAR, KISITLAR VE ÖNERİLER

Bu tez çalışması ile araştırmacı tarafından duygu tanıma yönelik yeni bir EEG sinyali veri seti oluşturulmuş ve tez kapsamında önerilen makine öğrenmesi yaklaşımı ile bu veri seti sınıflandırılmıştır. Bu noktada, geliştirilen veri seti ve makine öğrenmesi modeli dikkate alındığında bu tez çalışmasının öne çıkan noktaları, kısıtları ve önerileri maddeler halinde aşağıda verilmiştir.

Öne çıkan noktalar:

- Tez çalışmasında yeni ve özgün bir duygu tanıma veri seti oluşturulmuştur. Bu kapsamda 22 gönüllü katılımcıdan EEG sinyalleri toplanmış ve bu sinyaller kullanılarak 951 EEG segmenti elde edilmiştir.
- Tez çalışmasında yeni ve özgün bir örüntü modeli önerilmiştir. Temel olarak, askorbik asit başka bir deyişle C vitamininden ilham alınan bu yaklaşım ile VitC-Pat adında yeni bir özellik çıkarımı geliştirilmiş ve literatüre sunulmuştur.
- Veri seti arousal ve valence olmak üzere iki ekseninde toplanmıştır. Bu değerleri elde edebilmek için gönüllü katılımcılara SAM anketi uygulanmış ve anket sonuçları dijital ortama aktarılmıştır.
- Tez kapsamında geliştirilen model ile arousal ve valence eksenleri için sırasıyla %92.74 ve %96.85 doğruluk değerlerine ulaşılmıştır. Bu değerler oldukça yüksek sınıflandırma oranları olup, elde edilen sonuçlar geliştirilen modelin performansını ortaya koymaktadır.
- Geliştirilen model lineer zaman karmaşıklığına sahiptir. Bu yönüyle literatürde CNN kullanılarak geliştirilen kompleks modellere karşı bir alternatiftir. Çünkü önerilen model yüksek hesaplama başarısına düşük zaman karmaşıklığı ile ulaşabilmektedir.

Kısıtlar:

- Tez çalışmasının en önemli kısıtlarından biri katılımcı sayısının yetersizliğidir. Gönüllü katılımcı sayısının arttırılması ve buna bağlı olarak segment sayısının arttırılması gelecek çalışmalar için hedeflenmektedir.
- Bu tez çalışmasında, sınıflandırma işleminde 10-katlamalı çapraz doğrulama tekniği uygulanmıştır. Daha genel sonuçların elde edilebilmesi için gelecekte Leave-One-Subject-Out (LOSO) doğrulama tekniğinin kullanılması planlanmaktadır.

Öneriler:

- Geliştirilen bu modelin literatürde yer alan açık erişimli veri setleri üzerinde de test edilmesi geliştirilen modelin performansını gözlemleme de oldukça önemli ipuçları sunacaktır.
- Araştırmacı tarafından toplanan bu veri setinin, literatürde yer alan başka özellik seçme modelleri de kullanılarak test edilmesi hedeflenmektedir.

SONUÇ

Gerçekleştirilen bu tez çalışmasında, otomatik duygu tanıma ve sınıflandırma için yeni bir makine öğrenmesi modeli geliştirilmiştir. Geliştirilen bu model ile “AERG” adını verdiğimiz ve araştırmacı tarafından gönüllü 22 katılımcıdan toplanan EEG sinyalleri sınıflandırılmıştır. Toplanan veriler arousal ve valence olmak üzere iki ekseninde incelenmiş olup, veri toplama sürecinde katılımcılara video izletilerek EEG sinyalleri toplanmıştır. Veri toplama işlemi mobil bir beyin şapkası olan Emotiv EPOC X cihazı kullanılarak gerçekleştirilmiştir. Toplanan EEG sinyalleri 14 kanala sahiptir ve bu kanalların her biri tez kapsamında geliştirilen model ile sırasıyla test edilmiştir.

Veri toplama sürecinin ardından model geliştirme aşamasına geçilmiştir. Bu süreçte klasik makine öğrenmesi adımları kullanılmıştır. Bunlar sırasıyla özellik çıkarma, özellik seçme ve sınıflandırmadır. Özellik seçme aşamasında tamamen özgün yeni bir örüntü çıkarma modeli geliştirilmiştir. Bu yöntem literatürde yenidir. Örüntü geliştirme sürecinde kimyasal eşdeğeri askorbik asit olan C vitamininden ilham alınmış ve geliştirilen örüntü yöntemi VitC-Pat (Vitamin C Pattern) olarak adlandırılmıştır. Ayrıca yerel ikili örüntüler (LBP) ve istatistiksel özellik çıkarım yaklaşımları da yine özellik çıkarma fazında kullanılan diğer yöntemlerdendir. Makine öğrenmesi modelinin ikinci fazında ise literatürde iyi bilinen bir yöntem olan komşuluk bileşen analizi (NCA) yaklaşımı kullanılmıştır. Bu fazda, NCA algoritmasının gelişmiş bir versiyonu olan iteratif NCA (INCA) algoritması tercih edilmiştir. Bu algoritmanın tercih edilmesinin temel nedeni modelin zamansal karmaşıklığını aşağıya düşürmektir. Uygulamanın son fazında ise sık bir sınıflandırıcı olan (SVM) algoritması kullanılmıştır. Bu algorithmada doğrulama tekniği olarak 10-katlamalı çapraz doğrulama stratejisi seçilmiştir. Geliştirilen model yine araştırmacı tarafından toplanan “AERG” veri seti üzerinde test edilmiştir. Test sonuçları ile arousal ekseninde %92.74 ve valence ekseninde %96.85 sınıflandırma başarısına ulaşılmıştır.

Duygu tanıma literatürde son zamanlarda sıklıkla çalışılan bir konudur. Özellikle makine öğrenmesi tekniklerinin gelişmesi ve mobil EEG veri toplama cihazlarının yaygınlaşmasıyla daha da dikkat çeken bir konu haline gelmiştir. Bu nedenle, tez çalışmasında bu konu tercih edilmiştir. Veri toplama ve model geliştirme sürecinin yürütüldüğü bu çalışma ile literatüre “AERG” adında yeni ve özgün bir veri seti

kazandırılmış, ayrıca VitC-Pat örüntü modeli tanıtılmıştır. Elde edilen sonuçlar oldukça tatmin edicidir. Çünkü hem arousal hem de valence ekseninde %90'nın üzerinde bir doğrulukla sınıflandırma başarısı elde edilmiştir. Tez çalışması kapsamında veri toplama süreci için Fırat Üniversitesi, 09.11.2021 tarih ve 4937 sayılı Etik Kurul Onayı alınmış ve veri toplama süreci bu onay doğrultusunda yürütülmüştür.

Gelecek çalışmalar kapsamında elde edilen sonuçların bilim dünyası ile paylaşılması planlanmaktadır. Ayrıca, gönüllü katılımcı sayısının arttırılarak veri setinin geliştirilmesi de yine gelecek çalışmalar arasında yer almaktadır.



KAYNAKÇA

- Aguñaga, A. R., Delgado, L. M., López-López, V. R. ve Téllez, A. C. (2022). EEG-Based Emotion Recognition Using Deep Learning and M3GP. *Applied Sciences (Switzerland)*, 12(5). doi:10.3390/app12052527.
- Ahmed, Z. I., Sinha, N., Ghaderpour, E. ve Phadikar, S. (2023). A Novel Baseline Removal Paradigm for Subject-Independent Features in Emotion Classification Using EEG. *Bioengineering*, 1–22. doi:10.3390/bioengineering10010054.
- Alotaibi, F. M. (2023). An AI-Inspired Spatio-Temporal Neural Network for EEG-Based Emotional Status. *Sensors*, 1–17. doi:10.3390/s23010498.
- Ari, B., Siddique, K., Alçin, Ö. F., Aslan, M., Şengür, A. ve Mehmood, R. M. (2022). Wavelet ELM-AE Based Data Augmentation and Deep Learning for Efficient Emotion Recognition Using EEG Recordings. *IEEE Access*, 10, 72171–72181. doi:10.1109/ACCESS.2022.3181887.
- Asadzadeh, S., Yousefi Rezaii, T., Beheshti, S. ve Meshgini, S. (2022). Accurate emotion recognition using Bayesian model based EEG sources as dynamic graph convolutional neural network nodes. *Scientific Reports*, 12(1), 1–14. doi:10.1038/s41598-022-14217-7.
- Balım, M. A. (2018). 8 Kanallı Taşınabilir EEG Ölçüm Cihazı. *Elektrik-Elektronik Mühendisliği Anabilim Dalı, Bursa Teknik Üniversitesi Fen Bilimleri Enstitüsü, Bursa*. Bursa Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- Bardak, F. K., Seyman, M. N. ve Temurtaş, F. (2022). EEG Based Emotion Prediction with Neural Network Models. *Tehnički glasnik*, 16(4), 497–502. doi:10.31803/tg-20220330064309.
- Barua, P. D., Keles, T., Dogan, S., Baygin, M., Tuncer, T., Demir, C. F., ... Rajendra Acharya, U. (2023). Automated EEG sentence classification using novel dynamic-sized binary pattern and multilevel discrete wavelet transform techniques with TSEEG database. *Biomedical Signal Processing and Control*, 79(P1), 104055. doi:10.1016/j.bspc.2022.104055.
- Baygin, M. (2021). An accurate automated schizophrenia detection using TQWT and statistical moment based feature extraction. *Biomedical Signal Processing and Control*, 68(May), 102777. doi:10.1016/j.bspc.2021.102777.

- Bradley, M. M. ve Lang, P. J. (1994). Measuring emotion: The self-assessment manikin and the semantic differential. *Journal of Behavior Therapy and Experimental Psychiatry*, 25(1), 49–59. doi:10.1016/0005-7916(94)90063-9.
- Chowdary, M. K., Anitha, J. ve Hemanth, D. J. (2022). Emotion Recognition from EEG Signals Using Recurrent Neural Networks. *Electronics*, 11(15), 2387. doi:10.3390/electronics11152387.
- Çizmecci, H. (2022). *Derin Sinir Ağları ile EEG ve Alın EOG Tabanlı Duygu Analizi. Bilgisayar Mühendisliği Anabilim Dalı, Doktora Tezi, Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü, Karabük.*
- Colombetti, G. (2009). From affect programs to dynamical discrete emotions. *Philosophical Psychology*, 22(4), 407–425. doi:10.1080/09515080903153600
- Dogan, A., Barua, P. D., Baygin, M., Tuncer, T., Dogan, S., Yaman, O., ... Acharya, R. U. (2022). Automated accurate emotion classification using Clefia pattern-based features with EEG signals. *International Journal of Healthcare Management*, 1–14. doi:10.1080/20479700.2022.2141694.
- EPOC X. (2022). EPOC X User Manual. 15 Aralık 2022 tarihinde <https://emotiv.gitbook.io/epoc-x-user-manual/getting-started/package-contents> adresinden erişildi.
- EPOC X User Manual. (2022). 15 Aralık 2022 tarihinde <https://emotiv.gitbook.io/epoc-x-user-manual/introduction/introduction-to-epoc-x/coverage> adresinden erişildi.
- Gao, Q., Yang, Y., Kang, Q., Tian, Z. ve Song, Y. (2022). EEG-based emotion recognition with feature fusion networks. *International Journal of Machine Learning and Cybernetics*, 13(2), 421–429. doi:10.1007/s13042-021-01414-5
- Goldberger, J., Roweis, S., Hinton, G. ve Salakhutdinov, R. (2005). Neighbourhood components analysis. *Advances in Neural Information Processing Systems*, 17, 513–520.
- Grimm, M. ve Kroschel, K. (2005). Evaluation of natural emotions using self assessment manikins. *Proceedings of ASRU 2005: 2005 IEEE Automatic Speech Recognition and Understanding Workshop, 2005*, 381–385. doi:10.1109/ASRU.2005.1566530
- Haq, Q. M. ul, Yao, L., Rahmaniar, W., Fawad ve Islam, F. (2022). A Hybrid Hand-Crafted and Deep Neural Spatio-Temporal EEG Features Clustering Framework for Precise Emotional Status Recognition. *Sensors*, 22(14). doi:10.3390/s22145158.

- He, Z., Zhuang, N., Bao, G., Zeng, Y. ve Yan, B. (2022). Cross-Day EEG-Based Emotion Recognition Using Transfer Component Analysis. *Electronics (Switzerland)*, 11(4). doi:10.3390/electronics11040651.
- Hossain, M. S. ve Muhammad, G. (2019). Emotion recognition using deep learning approach from audio–visual emotional big data. *Information Fusion*, 49, 69–78. doi:10.1016/j.inffus.2018.09.00.
- Houssein, E. H., Hammad, A. ve Ali, A. A. (2022). Human emotion recognition from EEG-based brain–computer interface using machine learning: a comprehensive review. *Neural Computing and Applications*, 1–31. doi:10.1007/s00521-022-07292-4.
- Kalashami, M. P., Pedram, M. M. ve Sadr, H. (2022). EEG Feature Extraction and Data Augmentation in Emotion Recognition. *Computational Intelligence and Neuroscience*, 2022. doi:10.1155/2022/7028517 Research.
- Li, C., Hou, Y., Song, R., Cheng, J., Liu, Y. ve Chen, X. (2022). Multi-channel EEG-based emotion recognition in the presence of noisy labels. *Science China Information Sciences*, 65(4), 1–16. doi:10.1007/s11432-021-3439-2.
- Li, G., Ouyang, D., Yuan, Y., Li, W., Guo, Z., Qu, X. ve Green, P. (2022). An EEG Data Processing Approach for Emotion Recognition. *IEEE Sensors Journal*, 22(11), 10751–10763. doi:10.1109/JSEN.2022.3168572.
- Li, W. ve Yong, P. (2022). Transfer EEG Emotion Recognition by Combining. *MDPI*. doi:10.3390/systems10040111.
- Liu, H., Zhang, J., Liu, Q. ve Cao, J. (2022). Minimum spanning tree based graph neural network for emotion classification using EEG. *Neural Networks*, 145, 308–318. doi:10.1016/j.neunet.2021.10.023.
- Moctezuma, L. A., Abe, T. ve Molinas, M. (2022). Two-dimensional CNN-based distinction of human emotions from EEG channels selected by multi-objective evolutionary algorithm. *Scientific Reports*, 12(1), 1–15. doi:10.1038/s41598-022-07517-5.
- Ngai, W. K., Xie, H., Zou, D. ve Chou, K. L. (2022). Emotion recognition based on convolutional neural networks and heterogeneous bio-signal data sources. *Information Fusion*, 77(July 2021), 107–117. doi:10.1016/j.inffus.2021.07.007.
- Noble, W. S. (2006). What is a support vector machine? *Nature Biotechnology*, 24(12),

- 1565–1567. doi:10.1038/nbt1206-1565.
- Özdemir, M. E., Yıldırım, E. ve Yıldırım, S. (2015). Classification of emotional valence dimension using artificial neural networks. *2015 23rd Signal Processing and Communications Applications Conference (SIU)* içinde (ss. 2549–2552). IEEE.
- Pradhan, A. (2012). SUPPORT VECTOR MACHINE-A Survey, 2(8), 82–85.
- Sakalle, A., Tomar, P., Bhardwaj, H., Iqbal, A., Sakalle, M., Bhardwaj, A. ve Ibrahim, W. (2022). Genetic programming-based feature selection for emotion classification using eeg signal. *Journal of Healthcare Engineering*, 2022. doi:10.1155/2022/8362091.
- Sampath, A., Durairaj, T., Chakravarthi, B. R., Priyadharshini, R., Cn, S., Shanmugavadivel, K., ... Hande, A. (2022). Findings of the shared task on Emotion Analysis in Tamil. *Proceedings of the Second Workshop on Speech and Language Technologies for Dravidian Languages* içinde (ss. 279–285). doi:http://dx.doi.org/10.18653/v1/2022.dravidianlangtech-1.42.
- Suhaimi, N. S., Mountstephens, J. ve Teo, J. (2022). A Dataset for Emotion Recognition Using Virtual Reality and EEG (DER-VREEG): Emotional State Classification Using Low-Cost Wearable VR-EEG Headsets. *Big Data and Cognitive Computing*, 6(1), 16. doi:10.3390/bdcc6010016.
- Topic, A., Russo, M., Stella, M. ve Saric, M. (2022). Emotion Recognition Using a Reduced Set of EEG Channels Based on Holographic Feature Maps. *Sensors*, 22(9). doi:10.3390/s22093248.
- Trémeau, F. (2022). A review of emotion deficits in schizophrenia. *Dialogues in clinical neuroscience*. doi:10.31887/DCNS.2006.8.1/ftremeau.
- Tuncer, I., Barua, P. D., Dogan, S., Baygin, M., Tuncer, T., Tan, R. S., ... Acharya, U. R. (2023). Swin-textural: A novel textural features-based image classification model for COVID-19 detection on chest computed tomography. *Informatics in Medicine Unlocked*, 36(December 2022), 101158. doi:10.1016/j.imu.2022.101158.
- Tuncer, T., Dogan, S., Baygin, M. ve Acharya, U. R. (2022). Tetromino pattern based accurate EEG emotion classification model. *Artificial Intelligence in Medicine*, 123, 102210. doi:10.1016/j.artmed.2021.102210.
- Tuncer, T., Dogan, S. ve Subasi, A. (2022). LEDPatNet19: Automated emotion recognition model based on nonlinear LED pattern feature extraction function using

- EEG signals. *Cognitive Neurodynamics*, 16(4), 779–790. doi:10.1007/s11571-021-09748-0.
- Uyanık, H., Ozcelik, S. T. A., Duranay, Z. B., Sengur, A. ve Acharya, U. R. (2022). Use of Differential Entropy for Automated Emotion Recognition in a Virtual Reality Environment with EEG Signals. *Diagnostics*, 12(10), 2508. doi:10.3390/diagnostics12102508.
- Wan, Z., Yang, R., Huang, M., Zeng, N. ve Liu, X. (2021). A review on transfer learning in EEG signal analysis. *Neurocomputing*, 421, 1–14. doi:10.1016/j.neucom.2020.09.017.
- Wang, J. ve Wang, M. (2021). Review of the emotional feature extraction and classification using EEG signals. *Cognitive Robotics*, 1, 29–40. doi:10.1016/j.cogr.2021.04.001.
- Wang, L. (2005). Support Vector Machines: Theory and Applications. *Springer Science & Business Media*, 177, 1–47. <https://books.google.com/books?hl=en&lr=&id=uTzMPJjVjsMC&oi=fnd&pg=PA1&dq=support+vector+machines&ots=GFAK9w2Hfb&sig=4AddZM1BrpsopEliErlIzeys6zI> adresinden erişildi.
- Wang, Z., Wang, Y., Zhang, J., Hu, C., Yin, Z. ve Song, Y. (2022). Spatial-Temporal Feature Fusion Neural Network for EEG-Based Emotion Recognition. *IEEE Transactions on Instrumentation and Measurement*, 71, 1–12. doi:10.1109/TIM.2022.3165280.
- Xiao, G., Shi, M., Ye, M., Xu, B., Chen, Z. ve Ren, Q. (2022). 4D attention-based neural network for EEG emotion recognition. *Cognitive Neurodynamics*, 1–14. doi:10.1007/s11571-021-09751-5.
- Ye, Q., Alnemari, M. ve Bagherzadeh, N. (2022). A Two-Stage Efficient 3-D CNN Framework for EEG Based Emotion Recognition. *arXiv preprint arXiv:2208.00883*. doi:10.48550/arXiv.2208.00883.
- Yıldırım, M. A. (2022). *EEG Sinyallerinden Duygu Tanıma İçin Akıllı Yöntemlerin Geliştirilmesi. Adli Bilişim Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ.*
- Yuvara, R., Thagavel, P., Thomas, J. ve Fogarty, J. (2023). Comprehensive Analysis of Feature Extraction Methods for Emotion Recognition from Multichannel EEG

Recordings. *Sensors*, 1–19. doi:10.3390/s23020915.

Zhang, Z., Zhong, S. ve Liu, Y. (2022). GANSER: A Self-supervised Data Augmentation Framework for EEG-based Emotion Recognition. *IEEE Transactions on Affective Computing*. doi:10.1109/TAFFC.2022.3170369.

Zhou, L. F., Du, Y. W., Li, W. S., Mi, J. X. ve Luan, X. (2018). Pose-robust face recognition with Huffman-LBP enhanced by Divide-and-Rule strategy. *Pattern Recognition*, 78, 43–55. doi:10.1016/j.patcog.2018.01.003.



EKLER

Ek 1. EMOTİV EPOC X Teknik Özellikleri

EEG Sensörleri

EEG cihazı, 14 kanal (AF3, AF4, F3, F4, F7, F8, FC5, FC6, T7, T8, P7, O1, P8, O2) ve 2 referans: P3,P4 elektrottan oluşmaktadır (EPOC X, 2022).



Hareket Sensörleri

Cihazda ICM-20948 hareket sensörleri mevcuttur.

Mevcut Algılamalar

Performans Metrikleri: Katılım, rahatlama, heyecan, stres, odaklanma, ilgi

Yüz ifadeleri: Sağ/sol göz kırpma, şaşırma, kaşlarını çatma, gülümseme, sıkma

EEG Sinyalleri

Çözünürlük: $LSB=0,1275\mu V$ (16 bit modu), $0,51\mu V$ (14 bit modu)

Bant genişliği: 0,16-43Hz, 50Hz ve 60 Hz digital filtreler

Güç


Pil ömrü: Bluetooth düşük enerji modunda 6 saate kadar, USB ile de 12 saate kadar

Ağırlık ve Boyut

170g, 9x15x15 cm

Kapsamı

EPOC X, prefrontal, frontal, oksipital, temporal ve parietal lobları kapsar. Aşağıda şekil 2’de uluslararası 10-20 sistemini kullanarak sensörler yerleştirilmiştir (“EPOC X User Manual”, 2022).



Şekil 15. Uluslararası 10-20 sistemine göre yerleştirilmiş sensör konumları

Ek 2. SAM Ölçeği

T.C.
Ardahan Üniversitesi
Lisansüstü Eğitim Enstitüsü
İleri Teknolojiler Anabilim Dalı
SAM Ölçeği

Katılımcı Bilgileri:






No :
Adı Soyadı :
Cinsiyet :
Yaş :

Tarih:

V Değeri:

A Değeri:

B Değeri:

ÜZGÜN						MUTLU			
	1	2	3	4	5	6	7	8	9
SAKİN						HEYECANLI			
	1	2	3	4	5	6	7	8	9
BASKINLIK						BASKINLIK			
	1	2	3	4	5	6	7	8	9

Ek 3. VitC-Pat Kod Parçası

```

function histo=ascorbicacid(sinyal)
h1=zeros(1,64);
h2=zeros(1,64);
h3=zeros(1,64);
h4=zeros(1,64);
h5=zeros(1,64);
h6=zeros(1,64);
thr=std(sinyal)/2;
for i=1:length(sinyal)-79
    m=reshape(sinyal(i:i+79),[10,8]);
    %%Signum function%%
    b(1)=m(8,3)>=m(6,5);
    b(2)=m(8,3)>=m(7,2);
    b(3)=m(3,7)>=m(6,6);
    b(4)=m(1,4)>=m(4,3);
    b(5)=m(9,8)>=m(9,7);
    b(6)=m(2,1)>=m(5,2);
    b(7)=m(10,1)>=m(7,2);
    b(8)=m(6,5)>=m(6,6);
    b(9)=m(6,5)>=m(4,3);
    b(10)=m(6,6)>=m(9,7);
    b(11)=m(4,3)>=m(5,2);
    b(12)=m(5,2)>=m(7,2);
    %%Upper ternary function%%
    bu(1)=(m(8,3)-m(6,5)>=thr);
    bu(2)=(m(8,3)-m(7,2)>=thr);
    bu(3)=(m(3,7)-m(6,6)>=thr);
    bu(4)=(m(1,4)-m(4,3)>=thr);
    bu(5)=(m(9,8)-m(9,7)>=thr);
    bu(6)=(m(2,1)-m(5,2)>=thr);
    bu(7)=(m(10,1)-m(7,2)>=thr);
    bu(8)=(m(6,5)-m(6,6)>=thr);
    bu(9)=(m(6,5)-m(4,3)>=thr);
    bu(10)=(m(6,6)-m(9,7)>=thr);
    bu(11)=(m(4,3)-m(5,2)>=thr);
    bu(12)=(m(5,2)-m(7,2)>=thr);
    %%Lower ternary function%%
    bl(1)=(m(8,3)-m(6,5)<-thr);
    bl(2)=(m(8,3)-m(7,2)<-thr);
    bl(3)=(m(3,7)-m(6,6)<-thr);
    bl(4)=(m(1,4)-m(4,3)<-thr);
    bl(5)=(m(9,8)-m(9,7)<-thr);
    bl(6)=(m(2,1)-m(5,2)<-thr);
    bl(7)=(m(10,1)-m(7,2)<-thr);

```


```

b1(8)=(m(6,5)-m(6,6)<-thr);
b1(9)=(m(6,5)-m(4,3)<-thr);
b1(10)=(m(6,6)-m(9,7)<-thr);
b1(11)=(m(4,3)-m(5,2)<-thr);
b1(12)=(m(5,2)-m(7,2)<-thr);
m1(i)=0;
m2(i)=0;
m3(i)=0;
m4(i)=0;
m5(i)=0;
m6(i)=0;
for j=1:6
    m1(i)=m1(i)+b(j)*2^(j-1);
    m2(i)=m2(i)+bu(j)*2^(j-1);
    m3(i)=m3(i)+b1(j)*2^(j-1);
end
for j=1:6
    m4(i)=m4(i)+b(j+6)*2^(j-1);
    m5(i)=m5(i)+bu(j+6)*2^(j-1);
    m6(i)=m6(i)+b1(j+6)*2^(j-1);
end
h1(m1(i)+1)=h1(m1(i)+1)+1;
h2(m2(i)+1)=h2(m2(i)+1)+1;
h3(m3(i)+1)=h3(m3(i)+1)+1;
h4(m4(i)+1)=h4(m4(i)+1)+1;
h5(m5(i)+1)=h5(m5(i)+1)+1;
h6(m6(i)+1)=h6(m6(i)+1)+1;
end

histo=[h1 h2 h3 h4 h5 h6 ];

```

Ek 4. Etik Komisyon Muafiyet Formu

	ARDAHAN ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ YÜKSEK LİSANS TEZ ÇALIŞMASI ORJİNALLİK RAPORU										
ARDAHAN ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ İLERİ TEKNOLOJİLER ANA BİLİM DALI BAŞKANLIĞI'NA											
Tarih: 20/03/2023											
Tez Başlığı: EEG Sinyallerini Kullanan Makine Öğrenmesi Tabanlı Kategorik Duygu Sınıflandırma Modeli Yukarıda başlığı gösterilen tez çalışmamın a) Kapak sayfası, b) Giriş c) Ana bölümler ve d) Sonuç kısımlarından oluşan toplam 73 sayfalık kısmına ilişkin, 20/03/2023 tarihinde şahsım/tez danışmanım tarafından ithenticate adlı intihal tespit programından aşağıda işaretlenmiş filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 7 'dir. Uygulanan filtrelemeler: 1- ☒ Kabul/Onay ve Bildirim sayfaları hariç 2- ☒ Kaynakça hariç 3- ☒ Alıntılar hariç/dâhil 4- ☒ 5 kelimedenden daha az örtüşme içeren metin kısımları hariç Ardahan Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği'nde belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim. Gereğini saygılarımla arz ederim.											
20/03/2023											
<table style="width: 100%; border-collapse: collapse;"> <tr> <td style="width: 30%;">Adı Soyadı:</td> <td>HAKAN KÖKSAL</td> </tr> <tr> <td>Öğrenci No:</td> <td>21408700003</td> </tr> <tr> <td>Anabilim Dalı:</td> <td>İLERİ TEKNOLOJİLER</td> </tr> <tr> <td>Programı:</td> <td>İleri Teknolojiler</td> </tr> <tr> <td>Statüsü:</td> <td>☒ Yüksek Lisans ☐ Doktora</td> </tr> </table>		Adı Soyadı:	HAKAN KÖKSAL	Öğrenci No:	21408700003	Anabilim Dalı:	İLERİ TEKNOLOJİLER	Programı:	İleri Teknolojiler	Statüsü:	☒ Yüksek Lisans ☐ Doktora
Adı Soyadı:	HAKAN KÖKSAL										
Öğrenci No:	21408700003										
Anabilim Dalı:	İLERİ TEKNOLOJİLER										
Programı:	İleri Teknolojiler										
Statüsü:	☒ Yüksek Lisans ☐ Doktora										
<u>DANIŞMAN ONAYI</u> UYGUNDUR.  Doç. Dr. Mehmet BAYÇIN											

Ek 5. Etik Kurul İzni

Evrak Tarih ve Sayısı: 04.11.2021-4937



T.C.
FIRAT ÜNİVERSİTESİ
GİRİŞİMSEL OLMAYAN ARAŞTIRMALAR
ETİK KURULU
GİRİŞİMSEL OLMAYAN ARAŞTIRMALAR
ETİK KURULU KARARLARI

Oturum Tarihi
04.11.2021

Oturum Saati
14:00

Oturum Sayısı
2021/11-34

Girişimsel Olmayan Araştırmalar Etik Kurulu 04.11.2021 tarihinde saat 14:00'da Kurul Başkanı Prof. Dr. Mustafa KAPLAN başkanlığında, aşağıda imzaları bulunan kurul üyelerinin katılımlarıyla toplanarak gündemdeki konuları görüşmüş ve aşağıdaki kararları almıştır.

Sorumlu Araştırmacı : Doç. Dr. Türker TUNCER

Diğer Araştırmacılar : Doç. Dr. Şengül DOĞAN, Dr. Öğr. Üyesi Mehmet BAYGIN, Prof. Dr. Caner Feyzi DEMİR

"EEG Sinyallerinin Yorumlanması İçin Kimyasal Çizge Tabanlı Yeni Nesil Yapay Zeka Modeli Geliştirilmesi" konulu proje kurulumuzda görüşülmüş olup; çalışmanın etik kurallara uygun olduğuna oy birliğiyle karar verilmiştir.

(Araştırmanın tüm süreçlerinde kurum ve kuruluşlardan gereken izinlerin alınmasından araştırmacı/lar sorumludur.)

Kurul Üyeleri:

Prof. Dr. Mustafa KAPLAN, Prof. Dr. Engin ŞAHNA (Bulunmadı), Prof. Dr. Demet ÇİÇEK (Bulunmadı), Prof. Dr. Erdal TAŞKIN, Prof. Dr. Seval YILMAZ, Doç. Dr. Nevzat GÖZEL, Doç. Dr. Fazilet ERMAN, Doç. Dr. Burcu GÜL, Dr. Öğr. Üyesi Turgay BÖRK, Dr. Öğr. Üyesi Adem GÖK

Prof. Dr. Mustafa KAPLAN
Kurul Başkanı

Prof. Dr. Erdal TAŞKIN

Prof. Dr. Seval YILMAZ

Doç. Dr. Nevzat GÖZEL

Doç. Dr. Fazilet ERMAN

Doç. Dr. Burcu GÜL

Dr. Öğr. Üyesi Turgay BÖRK

Dr. Öğr. Üyesi Adem GÖK

Ek 6. Teşekkür

Gerçekleştirilen bu tez çalışması, Ardahan Üniversitesi Bilimsel Araştırma Projeleri (ARUBAP) tarafından, 2021-005 no’lu “EEG ve EKG Sinyalleri Kullanılarak Makine Öğrenmesi Tabanlı Otomatik Duygu Tespiti ve Sınıflandırma” başlıklı proje ile desteklenmiştir.



ÖZGEÇMİŞ

Kişisel Bilgiler

Adı Soyadı : Hakan KÖKSAL

Doğum Yeri ve Tarihi :

Eğitim Durumu

Lisans Öğrenimi :

Yüksek Lisans : Ardahan Üniversitesi LEE İleri
Öğrenimi Teknolojiler Anabilim Dalı- İleri
Teknolojiler (Disiplinerarası)

Bildiği Yabancı Diller :

Bilimsel Faaliyetleri :

İş Deneyimi

Stajlar :

Projeler :

Çalıştığı Kurumlar : MEB-Kazım Karabekir Yatılı Bölge
Ortaokulu

İletişim

E-Posta Adresi

Tarih : 25.04.2023