

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



EEG SİNYALLERİ KULLANILARAK YENİ NESİL CÜMLE
SINIFLANDIRMA MODELLERİNİN GELİŞTİRİLMESİ

Tuğçe KELEŞ

Yüksek Lisans Tezi

ADLI BİLİŞİM MÜHENDİSLİĞİ ANABİLİM DALI

Adli Bilişim Mühendisliği Bilim Dalı

OCAK 2023

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Adli Bilişim Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

EEG SINYALLERİ KULLANILARAK YENİ NESİL CÜMLE SINIFLANDIRMA MODELLERİNİN GELİŞTİRİLMESİ

Tez Yazarı
Tuğçe KELEŞ

Danışman
Doç. Dr. Şengül DOĞAN

OCAK 2023
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Adli Bilişim Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Başlığı:	EEG Sinyalleri Kullanılarak Yeni Nesil Cümle Sınıflandırma Modellerinin Geliştirilmesi
Yazarı:	Tuğçe KELEŞ
İlk Teslim Tarihi:	01.07.2022
Savunma Tarihi:	13.01.2023

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Doç. Dr. Şengül DOĞAN Fırat Üniversitesi, Teknoloji Fakültesi	İmza Onayladım
Başkan:	Doç. Dr. Mehmet BAYĞIN Ardahan Üniversitesi, Mühendislik Fakültesi	Onayladım
Üye:	Doç. Dr. Türker TUNCER Fırat Üniversitesi, Teknoloji Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza

Prof. Dr. Burhan ERGEN
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “EEG Sinyalleri Kullanılarak Yeni Nesil Cümle Sınıflandırma Modellerinin Geliştirilmesi” Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

13.01.2023

Tuğçe KELEŞ



ÖNSÖZ

Günümüzde yaşanan teknolojik gelişmelerin ve değişimlerin insan hayatında önemli bir yere sahip olduğu inkar edilemez bir gerçektir. Yapılan çalışmalar incelendiğinde insan fizyolojisini bilgisayar sistemlerine aktarmayı hedefleyen araştırmalara rastlanmaktadır. Son yıllarda beyin-bilgisayar sistemleri alanında çalışmalar yapıldığı ve beyin sinyallerinin farklı disiplinlere konu olduğu görülmektedir. Beyin sinyallerinin kararlı, güvenilir ve değiştirilemez olması bu alanda yapılan çalışmaların artmasına neden olmaktadır. Literatürde yayınlanan çalışmalar incelendiğinde harf ve kelime sınıflandırması güncel konulardan biridir. Çalışmaların doğruluk oranı düşük ve kullanılan veri setleri de yetersizdir.

Bu tez çalışmasında literatürden farklı olarak hece veya kelime sınıflandırması değil de cümle sınıflandırmasına odaklanılmıştır. Çalışmada kullanılmak üzere 40 katılımcıdan 20 farklı cümle olmak üzere bilinen en kapsamlı iki adet EEG veri seti oluşturulmuştur. Bu doğrultuda iki farklı model kullanılarak EEG tabanlı cümle sınıflandırma çalışması gerçekleştirilmiştir.

Bu çalışmanın gerçekleşmesi sırasında, sürecin her anında maddi manevi desteklerini esirgemeyen her fırsatta değerli bilgilerini ve tecrübelerini benimle paylaşan, yaşadığım her sorun karşısında büyük bir sabır ve ilgiyle bana yardımcı olan hayatım boyunca örnek alacağım kıymetli hocalarım Doç. Dr. Şengül DOĞAN ve Doç. Dr. Türker TUNCER'e sonsuz teşekkürlerimi sunuyorum ve minnetimi özellikle belirtmek istiyorum.

Bu tez çalışması, TÜBİTAK tarafından 121E399 numaralı proje ile desteklenmiştir. Çalışmalar Fırat Üniversitesi Girişimsel Olmayan Etik Kurulunun 04/11/2021 tarih ve 2021/11-34 sayılı izni ile gerçekleştirilmiştir. Aynı zamanda bu tez çalışmasından 1 adet SCI makale üretilmiştir.

Tuğçe KELEŞ
ELAZIĞ, 2023

İÇİNDEKİLER

	Sayfa
ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	vi
ABSTRACT	vii
ŞEKİLLER LİSTESİ	viii
TABLOLAR LİSTESİ	ix
SİMGELER VE KISALTMALAR	x
1. GİRİŞ	1
1.1. Motivasyon.....	1
1.2. Yenilikler.....	2
1.3. Katkılar	3
1.4. Tezin Amacı	3
1.5. Tezin Organizasyonu	4
2. İNSAN BEYİNİ YAPISINA GENEL BAKIŞ	5
2.1. EEG Sinyalleri.....	6
2.2. EEG Sinyalleri Dalga Modelleri.....	6
2.3. EEG Elektrotları	7
2.4. EEG Sinyallerinin Kalitesini Etkileyen Faktörler.....	9
3. LİTERATÜR TARAMASI	11
4. MATERYAL VE METOTLAR.....	14
4.1. EEG Cümle Veri Setleri	14
5. MODELLER.....	17
5.1. Kare Toplamlı Graf Desen Tabanlı EEG Cümle Tanıma Modeli	17
5.2. Dinamik Boyutlu İkili Örüntü Tabanlı EEG Cümle Tanıma Modeli	22
5.2.1. Önerilen EEG cümle sınıflandırma modeli	25
6. DENEYSEL SONUÇLAR	31
6.1. Deneysel Kurulum.....	31
6.2. Performans Değerlendirme Metrikleri.....	32
6.3. Kanal Bazında Sonuçlar	33
6.4. Ağırlıklı Oylama Sonuçları	34
6.5. Sınıf Bazında Sonuçlar	36
6.5.1. Birinci Modele Ait Sonuçlar	36
6.5.2. İkinci Modele Ait Sonuçlar	38
7. BULGULAR VE TARTIŞMA.....	41
7.1. Toplamsal Kareler Tabanlı Yöntem	41
7.2. DSBP Tabanlı EEG Cümle Tanıma Modeli	45
8. SONUÇLAR.....	50
KAYNAKLAR.....	51
ÖZGEÇMİŞ	

ÖZET

EEG Sinyalleri Kullanılarak Yeni Nesil Cümle Sınıflandırma Modellerinin Geliştirilmesi

Tuğçe KELEŞ

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Adli Bilişim Mühendisliği Anabilim Dalı

Ocak 2023, Sayfa: x + 54

Elektroensefalografi (EEG) sinyalleri beynin harfleri olarak nitelendirilmektedir ve bilgisayar bilimciler bu harfleri yan yana getirerek anlamlı cümleler elde etmeyi amaçlamaktadırlar. Bu sebepten dolayı EEG sinyallerini işleme sinir bilim ve makine öğrenmesi için sıcak başlıklı bir konudur. Ancak literatürdeki EEG işleme ve sınıflandırma çalışmaları genellikle hastalık tespiti ve duygu tespiti ile ilgilidir. Bu tez kapsamında EEG sinyallerinden daha fazla bilgi çıkarmak için yeni bir proje başlatılmıştır ve bu projenin konusu EEG cümle sınıflandırmasıdır. Bu tez çalışmasında, iki adet EEG cümle veri seti her bir veri seti için 20 katılımcı olmak üzere 40 adet gönüllü katılımcıdan toplanmıştır. Toplanan veri setleri 20 adet sınıf içermektedir ve bu sınıfların her biri bir cümleyi temsil etmektedir. Otomatik sınıflandırma modelleri önermek için mikro tanımlayıcılar ve çizge tabanlı özellik çıkarıcılar kullanılmıştır.

Önerilen kare toplamı çizge deseni tabanlı EEG sinyal sınıflandırma modeli, %99,19 sınıflandırma doğruluğuna ulaşmıştır. Bu çalışmada, toplam-kare grafiğine dayalı bir fonksiyonun öznelilik çıkarma yeteneği araştırılmıştır. Önerilen dinamik boyutlu ikili model ve yinelemeli çok sınıflandırıcı ağırlıklı oylama tabanlı model ise gösterme ve dinleme modlarında sırasıyla %98,81 ve %98,19 ile en iyi genel sınıflandırma oranlarına ulaşmıştır. Elde edilen sonuçlar EEG sinyalleriyle cümle sınıflandırılmasının yapılabileceğini açıkça göstermiştir ve bu tez çalışması EEG cümle tanıma/sınıflandırma alanında yapılan ilk tezlerden biri olma özelliğini taşımaktadır. Elde edilen sonuçlar tez çalışmasının başarımını açık bir şekilde göstermektedir.

Anahtar Kelimeler: Kare toplamı çizge deseni, EEG cümle sınıflandırması, NCA, DSBP, IMCMV, TQWT

ABSTRACT

Development Of Next Generation Sentence Classification Models Using EEG Signals

Tuğçe KELEŞ

Master's Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences
Department of Digital Forensic Engineering

January 2023, Pages: x + 54

Electroencephalography (EEG) signals are described as the letters of the brain, and computer scientists aim to obtain meaningful sentences by combining these letters. For this reason, processing EEG signals is a hot topic for neuroscience and machine learning. However, EEG processing and classification studies in the literature are generally related to disease detection and emotion detection. Within the scope of this thesis, a new project has been started to extract more information from EEG signals and the subject of this project is EEG sentence classification. In this thesis study, two EEG sentence datasets were collected from 40 volunteer participants, 20 participants for each dataset. The collected data sets contain 20 classes and each of these classes represents a sentence. Micro descriptors and graph-based feature extractors are used to propose automatic classification models.

The proposed square-sum graph pattern-based EEG signal classification model achieved a classification accuracy of 99.19%. In this study, the feature extraction capability of a function based on the sum-square graph was investigated. The DSBP-IMCMV based model, on the other hand, achieved the best overall classification rates with 98.81% and 98.19%, respectively, in showing and listening modes. The results clearly showed that sentence classification can be done with EEG signals, and this thesis is one of the first theses in the field of EEG sentence recognition/classification. The results obtained clearly show the success of the thesis study.

Keywords: Square sum graph pattern, EEG Sentence Classification, NCA, DSBP, IMCMV, TQWT

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. Beyin Loblarının İşlevleri	5
Şekil 2.2. Uluslararası kabul edilen 10-20 sistemi	8
Şekil 4.1. Bilgisayar terminaline kablosuz olarak bağlanan ticari EMOTIV EPOC + mobil sistemi kullanılarak kadın (solda) ve erkek (sağda) gönüllülerden EEG sinyali toplama işlemi	16
Şekil 5.1. Kare Toplamlı Grafik Deseni	17
Şekil 5.2. Önerilen SSG tabanlı EEG cümle sınıflandırma modeline genel bakış	20
Şekil 5.3. DSBP tabanlı merkez simetrik ve merkez tabanlı özellik çıkarımı	23
Şekil 5.4. Sunulan DSBP özellik çıkarıcısının grafik gösterimi	23
Şekil 5.5 . Giriş TSEEG veri seti ile önerilen DSBP-IMCMV modelinin blok diyagramı	25
Şekil 5.6. Yedi seviyeli MDWT'nin gösterimi	27
Şekil 5.7. En iyi sınıflandırma sonucunu elde etmek için kullanılan IMCMV algoritması	29
Şekil 6.1. İkinci modele ait gösteri modunda elde edilen TSEEG sinyallerinde kullanılan tahmin vektörlerinin sayısına karşı oylanan doğruluk grafiği.....	36
Şekil 6.2. Karışıklık matrisi.....	37
Şekil 6.3. Sınıf bazında hatırlama, F1 puanı ve kesinlik değerleri.	38
Şekil 6.4. Gösterme modunda elde edilen TSEEG sinyalleri için oylanan sonuçların karışıklık matrisi	39
Şekil 6.5. Dinleme modunda kullanılan tahmin vektörlerinin sayısına karşı oylanan doğrulukların grafiği.....	40
Şekil 7.1. AF3 kanalı için kullanılan sınıflandırıcıların kıyaslaması.....	42
Şekil 7.2. Tahmini 26 vektörü kullanan hesaplanmış 26 sınıflandırma doğruluğu	43
Şekil 7.3. 10 katlı CV ile kNN sınıflandırıcıyı kullanan kanal konumlarına göre modelin kanal bazında sınıflandırma doğrulukları (%)	44
Şekil 7.4. Dinleme modunda alınan TSEEG sinyalleri için oylanan sonuçların karışıklık matrisi	47
Şekil 7.5. Veri setindeki yirmi sınıfın (Türkçe cümlelerin) deney modundaki doğruluğu	49

TABLÖLAR LİSTESİ

	Sayfa
Tablo 2.1. EEG Sinyalleri Dalga Modelleri.....	7
Tablo 2.2. Elektrotların Adlandırılması	9
Tablo 4.1. TSEEG Veri seti	14
Tablo 5.1. Kenar Numaralandırma Algoritması.....	18
Tablo 5.2. İstatistiksel özellikler oluşturmak için kullanılan istatistiksel momentler	21
Tablo 5.3. DSBP tabanlı ikili özellik çıkarımının sözde kodu.....	24
Tablo 5.4. IMCMV'nin sözde kodu	30
Tablo 6.1. Kare toplamı graf deseni tabanlı modelin parametreleri.....	31
Tablo 6.2. DSBP-IMCMV deseni tabanlı modelin parametreleri.....	32
Tablo 6.3. Birinci modelin kanal bazlı sonuçları (%)	33
Tablo 6.4. İkinci modelin kanal bazlı sonuçları (%)	34
Tablo 6.5. Birinci modele ait IMV kullanılarak oylanan sonuçlar (%).....	34
Tablo 6.6. KNN ve SVM sınıflandırıcıları kullanılarak dinleme modunda elde edilen kanal bazlı sonuçlar (%).....	40
Tablo 7.1. Farklı metotların kanal bazlı doğruluklarının karşılaştırılması	47

SİMGELER VE KISALTMALAR

Simgeler

$\phi(\cdot, \cdot)$	: Signum Fonksiyonu
$\chi(\cdot)$	: İstatistiksel Öznitelik Üreteci
$\gamma(\cdot)$	: Birleştirme fonksiyonu
$\varpi(\cdot)$	: İstatistiksel Özellik Çıkarıcı

Kısaltmalar

EEG	: Elektroensefalografi
TQWT	: Ayarlanabilir q-faktörü dalgacık dönüşümü
NCA	: Komşu bileşen analizi
kNN	: k en yakın komşu
IMV	: Yinelemeli mod tabanlı çoğunluk oylaması
SSG	: Kare toplamı model
DSBP	: Dinamik boyutlu ikili örüntü
MDWT	: Çok düzeyli ayrık dalgacık dönüşümü
SVM	: Destek vektör makinesi
IMCMV	: Yinelemeli çok sınıflandırıcı ağırlıklı oylama

1. GİRİŞ

İletişim, bireylerin bilgi, duygu ve düşüncelerini yazılı veya sözlü olarak diğer bireylere aktardığı önemli bir yaşam becerisi ve etkinliğidir [1]. Sesli iletişim, insanların duygu ve düşüncelerini diğer insanlara iletmek için kullandıkları yaklaşımdır. Sesli iletişimde taraflar birbirleriyle kelime ve işaretler kullanarak iletişim kurarlar. Pek çok gerçek dünya senaryosu, özellikle yazma veya konuşma yetisini kaybetmiş kişilerde sözlü olmayan iletişim gerektirir. Bununla birlikte hala bozulmamış bilişsel işlevi koruyan bireylerde [2], sözlü olmayan jestler, örneğin işaret dili kullanılarak iletişim hala mümkündür. Bu tür iletişime bir başka alternatif telepatik iletişimdir [3]. Telepatik iletişim temel olarak bilginin beyin dalgaları yoluyla aktarılmasıdır [4]. Bu aktarım sürecinde bireyler beş duyu organının yardımı olmadan iletişim kurarlar. Bu tür iletişim, özellikle konuşma yeteneğini kaybetmiş ancak bilişsel aktivitesi düzgün çalışan bireyler için önemlidir [2]. Alternatif olarak, bilgisayar tarafından üretilen metin/konuşma parçaları veya robotik destekli fiziksel hareketler olarak belirli düşünce tarafından üretilen aktivite sinyali çıkarmak için beyin aktivitelerini kaydetmek ve yorumlamak için kullanılabilen beyin-bilgisayar arayüz cihazları geliştirilmiştir [5].

Elektroensefalografi (EEG) sinyali, hayali kelimeler ve cümleler de dâhil olmak üzere beyin aktivitelerini çözmek için makine öğreniminde yaygın olarak kullanılan önemli bir fizyolojik sinyaldir [6]. EEG sinyallerinin çevrilmesi beyin aktivitesini anlamak için çok önemlidir [7]. Günümüzde birçok sinirbilimci EEG sinyallerini yorumlama ve anlama üzerinde çalışmaktadır [8]. Uzman nörologlar genellikle beyinle ilgili bazı hastalıkların ön tanısı için EEG sinyallerini kullanır [9]. Ayrıca bu sinyaller hem tıbbi hem de tıbbi olmayan alanlarda sıklıkla kullanılmaktadır [10]. Özellikle kullanıcılardan toplanan EEG sinyallerinin otomatik olarak yorumlanması ve yorumlanan sinyalin çıktısının alınması gerçek dünya problemlerinde kullanılan bir yaklaşımdır. Günümüzde EEG sinyalleri kullanılarak sesli harf ve hece sınıflandırması literatürde çalışılan güncel konulardan biridir [7]. Ancak bu çalışmalar genellikle ünlü, hece ve kelime sınıflandırmasına odaklanmıştır [11]. Bu tez çalışmasında, EEG sinyallerini kullanarak cümle sınıflandırması için yeni yöntemler önerilmektedir.

1.1. Motivasyon

EEG beynin harfleri olarak kabul edilir ve birçok sinirbilimci beyin aktivitelerini anlamak için EEG sinyallerini doğru çevirmek ister [12, 13]. Bu çalışmada telepatik iletişim problemi bir EEG cümle sınıflandırması olarak tanımlanmıştır. Bu nedenle 40 katılımcıdan 20 cümlelik EEG sinyalleri toplanmıştır. Bu doğrultuda yeni bir EEG sinyal sınıflandırma alanı tanımlanmış ve EEG cümle sınıflandırması olarak adlandırılmıştır. Günümüzde derin öğrenme modelleri, yüksek sınıflandırma

sonuçları elde etmek için yaygın olarak kullanılmaktadır [14, 15]. Bununla birlikte, derin modeller, uygulamaları çok pahalı olduğu için üstel zaman karmaşıklığına sahiptir [16, 17]. Bu nedenle hafif ve doğruluğu yüksek bir model önerilmelidir. Bu problemin üstesinden gelmek için yeni birçok seviyeli öznetelik çıkarma modeli önerilmiştir. Bu tez çalışmasında önerilen ilk model, graf tabanlı bir özellik çıkarıcı kullanır. Bu grafiği oluşturmak için bir matematik probleminin çözümü kullanılmıştır. Bu problem kare toplam problemi olarak adlandırılır. Kare toplam problemine bir çözüm kullanılarak bir grafik elde edilmiştir ve bu grafik bir özellik çıkarıcı olarak kullanılır ve bu özellik çıkarıcı dokusal özellikler üretir. Ancak, bu özellik çıkarıcı, el yapımı bir fonksiyondur ve bu tip bir fonksiyon, yüksek düzeyde özellikler üretemez. Çok düzeyli öznetelik çıkarma problemini çözmek için etkin bir ayrıştırma modeli kullanılmış ve ayrıştırma modeli olarak TQWT [18] seçilmiştir. TQWT ile alt bantlar oluşturulur ve önerilen model, özellikleri oluşturmak için bu alt bantları uygular. Özellik seçiminde NCA [19] kullanılmış ve en iyi özellik kombinasyonu seçilmiştir. Bu özellikler kNN sınıflandırıcı [20] kullanılarak sınıflandırılmış ve oylama sonuçlarını hesaplamak için IMV [21] kullanılmıştır.

Bu tez çalışmasında önerilen ikinci modelde ise çok düzeyli ayırık dalgacık dönüşümü (MDWT) [22] ile birleştirilmiş hesaplama açısından derin modeller kullanarak çok düzeyli özneteliklerin çıkarılması taklit edilmeye çalışılmıştır. İstatistiksel özellik çıkarıcılar ve yeni bir dinamik boyutlu ikili model (DSBP) dokusal özellik çıkarma işlevi, EEG sinyallerinden düşük ve yüksek seviyeli özellikler üretir. Bu nedenle, çoklu sınıflandırıcılardan ve EEG sinyal kanallarından hesaplanan çeşitli tahmin vektörlerinden elde edilen en iyi genel sonuçları belirlemek için yeni bir yinelemeli çoklu sınıflandırıcı tabanlı çoğunluk oylama (IMCMV) modeli kullanılmıştır. Sonuç olarak, önerilen DSBP-IMCMV tabanlı EEG cümle sınıflandırma modeli, çalışma veri setinde %98'in üzerinde sınıflandırma doğruluğuna ulaşmıştır.

1.2. Yenilikler

Önerilen EEG cümle sınıflandırma modelinin yeni yönleri;

- Literatürde EEG ile ilgili birçok makine öğrenmesi çalışması bulunmaktadır. Bu çalışmalar genellikle duygu veya hastalık tanıma tabanlıdır. Ancak, EEG verisini girdi olarak kullanarak cümlelerin sınıflandırılmasıyla ilgili yöntem sayısı çok azdır ve EEG cümle sınıflandırma modellerinin test edilebileceği açık veri setleri bulunmamaktadır. Bu boşluğu doldurmak için iki adet yeni EEG veri seti toplanmıştır.
- EEG sinyallerinden cümle tanıma problemi sınıflandırma problemi olarak tanımlanmıştır.
- Graf tabanlı modeller, makine öğreniminde çok popüler ve etkilidir. Bu modelde, yeni bir graf tabanlı özellik çıkarım ve dinamik boyutlu ikili örüntü tabanlı özellik çıkarım modeli önerilmiştir.

- Bu tez çalışmasında iki adet yüksek başarıma sahip EEG cümle sınıflandırma modeli önerilmiştir.

1.3. Katkılar

Tezin literatüre sağladığı katkılar aşağıdaki gibi verilmiştir.

- Bu tez çalışması kapsamında ilk kez 20 sınıflı EEG cümle veri setleri toplanmıştır. Bu yönüyle cümle sınıflandırması için bilindiği kadarıyla en kapsamlı veri setleri toplanmıştır.
- Yeni bir kare toplamı grafik, istatistiksel öznitelik çıkarımı, TQWT, NCA, kNN ve IMV kullanılarak etkili bir EEG sinyal sınıflandırma modeli önerilmiştir. Aslında, elle modellenen yeni bir öğrenme mimarisi önerilmiştir. Bu öğrenme mimarisi, özellik çıkarmada dokusal özellik çıkarma, istatistiksel özellik çıkarma ve dönüştürme olmak üzere üç ana bölüm içerir. Bu bölümlerde, kullanıcılar diğer işlevleri kullanabilir. Ayrıca, en iyi özellik kombinasyonlarını seçmek için NCA kullanılmıştır. kNN basit/sıg bir sınıflandırıcıdır ve bu sınıflandırıcı üretilen özniteliklerin gücünü göstermek için kullanılmıştır. Bu aşamada diğer sınıflandırıcılar kullanılabilir. Önerilen mimarinin son aşamasında, sonuç sayısını artırmak ve oylan sonuçları elde etmek için IMV kullanılmıştır. Açgözlü algoritma (Greedy Algorithm) kullanarak oluşturulan mimari en iyi sonuçları seçebilir. Bu açıdan önerilen model parametrik ve kendi kendini organize eden bir mimaridir.
- Dokusal özellikler oluşturmak için sabit olmayan boyutta örtüşen bloklar kullanan yeni bir özellik çıkarıcı olan DSBP önerilmiştir. Önerilen tez bu açıdan yenilikçi bir tezdur.
- Genel performans ölçümlemlerini oluşturmak için EEG kaydındaki tüm kanallardaki iki sınıflandırıcının sonuçlarını kullanan yeni bir çoğunluk oylama modeli olan IMCMV önerilmiştir.
- Veri seti toplamak için iki adet model kullanılmıştır. Bu modeller (i) gösterim ve (ii) dinleme tabanlı EEG toplama yöntemleridir.
- Oluşturulan otomatik DSBP-IMCMV EEG cümle sınıflandırma modeli, hesaplama açısından hafiftir ve %98'in üzerinde genel sınıflandırma doğruluğu elde etmiştir.

1.4. Tezin Amacı

Günümüzde insan-makine etkileşiminin artmasıyla birlikte insan fizyolojisinin bilgisayar sistemlerine aktarılması amaçlanmıştır. Son yıllarda beyin sinyallerinin farklı alanlara konu olduğu görülmektedir. EEG sinyallerinden hece ve kelime sınıflandırması bu alandaki güncel çalışmalardan biridir. Bu tez çalışması, hece ve kelime sınıflandırmasından farklı olarak tam bir cümle sınıflandırmasını amaçlamaktadır. Literatürde daha önce böyle bir çalışmaya rastlanmamış

olup EEG alanında kullanılan veri setleri de yetersizdir. Bu amaç doğrultusunda yeni bir EEG sinyalleri içeren veri seti oluşturulacaktır. Oluşturulan veri setleri kullanılarak yeni nesil özellik mühendisliği yöntemleri önerilmiştir. Özellik mühendisliği yöntemlerinin temel amacı, düşük algoritmik karmaşıklık ile yüksek performans elde etmektir. Tezin temel amaçları aşağıda verilmiştir:

- Literatür taramasından da anlaşılabacağı üzere EEG cümle sınıflandırmasıyla ilgili çalışma sayısı sınırlıdır. Bunun temel nedeni ise açık kaynak EEG sinyal veri setlerinin yetersiz olmasıdır. EEG cümle sınıflandırma konusuna katkı sağlamak ve bu konunun geliştirilmesini desteklemek için yeni EEG sinyal veri setleri toplanmıştır.
- Derin öğrenme mimarileri günümüzde popüler olan mimarilerdir çünkü derin öğrenme mimarileri yüksek performansa sahiptirler. Ancak, derin öğrenme mimarileri yüksek hesapsal karmaşıklığa sahip olduğundan pahalı donanımların kullanılması gerekmektedir. Bu problemi çözebilmek için iki adet özellik mühendisliği mimarisi önerilmiştir.

1.5. Tezin Organizasyonu


Bu tez çalışması 8 bölümden oluşmaktadır. Tezin geriye kalan kısımları şu şekilde organize edilmiştir. İkinci bölümünde insan beyninin genel yapısı, EEG sinyalleri ve sinyallerin toplanma süreci hakkında bilgi verilmiştir. Üçüncü bölümde gerçekleştirilen literatür taraması sunulmuştur. Dördüncü bölümde, materyaller ve metotlar, Beşinci bölümde önerilen kare toplamı grafik deseni ve dinamik boyutlu ikili örüntü tabanlı EEG cümle tanıma yöntemlerinin çalışma prensibinden bahsedilmiştir. Altıncı bölümde, önerilen yöntemin uygulama adımları gerçekleştirilmiş ve deney süreci hakkında bilgi verilmiştir. Yedinci bölümde elde edilen bulgular tartışılmıştır. Sekizinci ve son bölümde ise sonuç ve önerilerden bahsedilmiştir.

2. İNSAN BEYİNİ YAPISINA GENEL BAKIŞ

Sinir merkezlerinin en büyüğü olan beyin, kafatasının yukarı kısmında bulunur. İnsan vücudundaki nöronların %90'ından fazlasını içerir. Öğrenme, hafıza, duyguların ve mantık yürütmenin merkezidir. Beynin üst tabakası sinir hücrelerinden oluşurken alt tabakası sinir hücrelerinin uzantılarından oluşmaktadır. Beyin, Şekil 2.1'de gösterildiği gibi üzerinde kıvrımlar bulunan iki yarım küreye ayrılmıştır [23, 24].

Sol yarım küre: İnsan beyninin mantıksal kısmıdır. Matematiksel işlemler, analitik düşünme becerisi, sayı ve sembollerle ilgilenen kısımdır. Beynin sol lobu insan vücudunun sağ tarafındaki organlarını yönetir. Konuşma ve dil merkezidir. Akademik ve bilimsel konularda başarılıdır.

Sağ yarım küre: İnsan beyninin yaratıcı kısmıdır. Görsel ve sanatsal konularla ilgilenir ve sezgileri yönetir. Duygusaldır. Beynin sağ lobu insan vücudunun sol tarafındaki organları yönetir.



Şekil 2.1. Beyin Loblarının İşlevleri

Temelde sağ ve sol yarım kürelerden oluşan beyin, incelemelerin daha detaylı ve anlaşılır olması açısından loblara ayrılmıştır [24]:

Ön (Frontal) Lob: Simetrik bir yapıya sahip olan ön beyin ilkel hayvanlarda bulunmaz. Alnın hemen arkasında bulunmakta ve beyin yapısının yaklaşık olarak yarısını oluşturmaktadır. Beynin kontrol merkezi olup mantık yürütme, problem çözme, empati, cömertlik duyguları ve davranışlarla ilgilidir.

Şakak (Temporal) Lob: Beynin iki yanında kulak hizasında bulunur ve işitsel görevleri gerçekleştirir. Ses ve kokuları tanımlar ve hatırlar.

Yan (Parietal) Lob: Beynin sağ ve sol bölümlerinde iki tane bulunur. Şekil ve renkleri algılama, görme algısı gibi yetenekleri kontrol eder. Yan loblardaki herhangi bir sinir hücresinin zarar görmesi Alzheimer hastalığına neden olabilir.

Arka (Oksipital) Lob: Beynin en arkasında bulunur ve görsel uyarıları algılar. Görmeye dair tüm görevler burada gerçekleşir. Bu lobda meydana gelen herhangi bir hasar görme bozukluğuna yol açabilir.

Beyincik (Serebellum) Lobu: Vücut dengesinin sağlanmasında önemli role sahiptir. Kol ve bacak kaslarının uyumlu çalışması beyincik lobu sayesinde.

Beyinde bulunan bu kısımların hangi alanda geliştiğini ve çalıştığını bilmek, yapılan çalışmalar için alınacak EEG kayıtlarında kafatasının hangi alanlarından ölçümler yapılması gerektiğinin bilinmesi açısından önemlidir.

2.1. EEG Sinyalleri

Beyin içerisinde bulunan sinir hücrelerinin elektriksel aktiviteleri akımları oluşturur. Bu akımların meydana getirdiği gerilim değişimlerinin kaydedilmesi ile elde edilen işaretlere Elektroenfalogram (EEG) sinyalleri denir.

EEG işaretlerinin varlığı tarihte ilk kez 1875 yılında Caton tarafından hayvanlar üzerinde yapılan çalışmalar neticesinde tespit edilmiştir. İnsan beynindeki elektriksel faaliyetler ise 1929 yılında Hans Berger'in kafatasına yerleştirdiği elektrotlar ve elektrotlara bağlı galvanometre ile ortaya çıkmıştır. Daha sonra Berger, yaptığı çalışmalar neticesinde gözlerin açılıp kapanmasının EEG işaretlerinde değişimlere neden olduğunu göstermiştir.

Gelişen teknolojiyle birlikte EEG sinyallerinin analizinde de kullanılan yöntemlerde de büyük gelişmeler yaşanmaya devam etmektedir. EEG sinyallerinin analizi yalnızca tıp alanı ile sınırlı kalmayıp farklı disiplinlere de konu olmaktadır.

Çalışmalarda gerek kullanım kolaylığı gerekse ekonomik olması nedeniyle EEG, en çok kullanılan yöntemlerin başında gelmektedir. Teknolojinin gelişmesiyle birlikte EEG cihazları herkesin ulaşabileceği şekilde üretilmeye başlanmıştır. Bu sayede büyük cihazlara gerek kalmadan Wi-Fi, Bluetooth aracılığıyla da EEG işaretleri elde edilebilmektedir.

EEG kafa derisine belirli bir düzen içinde yerleştirilen elektrotlar aracılığıyla beyindeki elektriksel aktiviteyi ölçer. Ölçüm esnasında beyne veya vücudun herhangi bir yerine elektrik iletimi söz konusu değildir bu nedenle işlem ağrısız ve zararsızdır [23].

2.2. EEG Sinyalleri Dalga Modelleri

EEG sinyalleri durağan olmayan özelliğe sahip olup genliği 2-100 μ V arasında, frekansı ise 1-100 Hz arasında değişmektedir. Bireylerin uyku, uyanıklık, hareket etme durumlarına göre EEG sinyallerinin genlik ve frekansları değişiklik gösterir (Tablo 2.1). Frekans bantları insan beyninin çeşitli görevlerini tanımlamak için kullanılabilir [25]:

Tablo 2.1. EEG Sinyalleri Dalga Modelleri

Dalga Boyu	Frekans Aralığı
Delta	0 – 4 Hz
Teta	4 – 8 Hz
Alfa	8 – 13 Hz
Beta	13 – 30 Hz
Gama	30 – 100 Hz

Delta dalgaları: 0 ile 4 Hz arasında değişir. Derin uyku ile ilgili olup yavaş dalgalardır. Bebeklerde görülür. Uyanık gençlerin ve yetişkinlerin EEG verilerinin bileşeni değildir.

Teta dalgaları: 4 ile 8 Hz arasında değişir. Yetişkinlerde uyku ve meditasyon sırasında gözlenir.

Alfa dalgaları: 8 ile 13 Hz arasında değişir. Genel olarak görsel işleme, hafıza aktiviteleri ile ilişkilidir. Sakin ve stressiz zamanlarda beyindeki oksipital kısımda bulunur.

Beta dalgaları: 13 ile 30 Hz arasında değişir. Beyin aktif bir şekilde çalışırken beyin ön ve orta kısımlarında oluşur. İnsanlar korktuğunda veya paniğe kapıldığında yüksek seviyeli beta dalgaları yansıyabilir.

Gama beyin dalgası ise 30 Hz'in üzerindeki yüksek frekanslı dalgalardır. EEG kayıtlarında genellikle filtrelendir. Bilgi analizi, görsel/işitsel uyaran sentezi gibi yüksek seviyeli beyin aktivitesi ile ilişkili alanlardır.

Beta ve Gama yüksek frekanslı sinyaller duygu tanıma çalışmalarında diğer sinyallere oranla daha başarılı sonuçlar sunmaktadır.

2.3. EEG Elektrotları

EEG kayıt sistemleri elektrotlardan oluşmaktadır. Elektrotlar, insan kafası derisi üzerinden beyin dalgalarını kaydetmek amacıyla kullanılır. Duygu tanıma çalışmasının en önemli aşamalarından biri de elektrot yerleştirmesidir. Beynin ürettiği sinyallerin özellikleri, beyin farklı bölgelerinde değişiklik göstermektedir. Bu nedenle beyin loblarının işlevlerini bilmek yapılacak çalışmalarda elektrotların yerleştirileceği alanın bilinmesi açısından önem sağlar.

Elektrotlar, bir harf ve bir rakam ile birlikte isimlendirilmektedir. Ara elektrotlarda ise iki harf kombinasyonu bulunmaktadır. Harfler, elektrotun bulunduğu beyin kısımlarını ifade eder. (Tablo 2.2)

Çift sayılı elektrotlar (2,4,6,8) kafatasının sağ tarafına ve tek sayılı elektrotlar (1,3,5,7) kafatasının sol tarafına yerleştirilir [25].

Tablo 2.2. Elektrotların Adlandırılması

Fp	Frontal Kutup	FC	Frontal ve merkez elektrotlar arası
F	Frontal (ön lob)	PO	Parietal ve oksipital elektrotlar arası
C	Central (merkez)	Fz	Frontal Lob merkezi
T	Temporal (şakak lobu)		
P	Parietal (yan lob)		
O	Oksipital (arka lob)		
A	Kulak Elektrodu		

2.4. EEG Sinyallerinin Kalitesini Etkileyen Faktörler

EEG sinyalleri son derece hassas veriler olduğu için kayıt esnasında laboratuvar ortamındaki faktörlerden olumsuz etkilenebilir. Bunun sonucunda EEG sinyalleri parazitler ile birlikte kaydedilebilir. Bu parazitler artefakt ya da gürültü olarak adlandırılır. EEG sinyallerinin her türlü iç ve dış etkenlerden etkilenmesi nedeniyle elde edilen kayıtlarda mutlaka artefaktlar olup bu duruma engel olunamamaktadır. Çalışmalarda yapılacak ölçümlerin doğru sonuçlar vermesi için de işlemlere başlamadan önce bu gürültülerin sinyalden kaldırılması gerekir.

Artefaktların oluşumunun birden fazla nedeni olabilir. Genel olarak oluşumları deneyde bulunan katılımcılara ve kullanılan kayıt cihazına bağlıdır:

Biyolojik artefaktlar: Genellikle deneklerin göz ve göz kapağının hareketine, kalp atışlarına, terlemelerine ve kas kasılması gibi sebeplere bağlı olarak oluşan artefaktlardır.

Hareket sonucu oluşan artefaktlar: Katılımcıların el titremesi, kafa hareketleri, kol veya vücudun herhangi bir uzvunun hareketi sonucu oluşan artefaktlardır.

Elektrotlara bağlı oluşan artefaktlar: Kayıt cihazında bulunan elektrotların deride bulundukları yerden oynaması, doğru yerleştirilmemesi veya elektrotların bozuk olmalarından kaynaklanan artefaktlardır.

Bu durumlarda alınan tedbirler sonucu artefakt oluşmaya devam edildiği takdirde cihazdan kaynaklı bir sorun olduğu düşünülebilir. Bu durumda cihazın yetkili servisiyle iletişime geçilmelidir.



3. LİTERATÜR TARAMASI

Literatürde bu konu ile ilgili çalışma sayısı oldukça sınırlıdır. Bu çalışmada önerilen yöntemler ile bu problem çözülmeye çalışılmış ve EEG cümle sınıflandırması yapılmıştır.

DaSalla ve arkadaşları [26] 2009 yılında /a/ ve /u/ ünlülerini sınıflandırmak için 2 erkek 1 kadın katılımcıdan oluşan bir çalışma gerçekleştirmiştir. 5 kat çapraz doğrulama, ortak uzamsal desen ve destek vektör makinesi yöntemlerini kullanarak %78 doğruluk bildirmişlerdir. Çalışmada düşük sınıf sayısı ve az sayıda katılımcı bulunup doğruluk değeri düşüktür. Garcia ve arkadaşları [27] 2012’de gerçekleştirdikleri çalışmada ayırık dalgacık dönüşümü ve rastgele ormanlar kullanarak “arriba”, “abajo”, “izquierda”, “derecho”, “seleccionar” kelimelerini sınıflandırmayı amaçlamışlardır. 21 katılımcının bulunduğu çalışma düşük doğruluk değerine sahiptir. Min ve arkadaşları [28] 2016 yılında ünlü harfleri sınıflandırmak için özellik çıkarma (ortalama, varyans, standart sapma, çarpıklık), özellik seçimi için seyrek regresyon modeli, sınıflandırma aşamasında aşırı makine öğrenmesi yöntemini kullanarak /a/, /e/, /i/, /o/, /u/ ve MUTE şeklinde altı sınıftan oluşan çalışma gerçekleştirmişlerdir. Çalışmada /a/ ve /e/, /a/ ve mute vb. şeklinde ikili sınıflandırma kullanılmış olup yalnızca 5 erkek katılımcı bulunmaktadır. Qureshi ve arkadaşları [29] 2017’de bağlantı ölçüm yöntemleri, aşırı öğrenme makinesi kullanarak “go”, “back”, “left”, right, “stop” kelimelerini sınıflandırmayı amaçlamışlardır. Çalışmada 2 kadın, 6 erkek olmak üzere 8 katılımcı bulunmaktadır ve çalışma düşük bir doğruluk değerine sahiptir. Balaji ve arkadaşları [30] 2017 yılında spektral güç özellik çıkarımı, yapay sinir ağı kullanarak Hintçe ve İngilizce olmak üzere 2 farklı dilde kelime sınıflandırma çalışması yapmışlardır. Hintçe “Haan”, “Na” ve İngilizce “Yes”, “No” kelimelerinin sınıflandırılmasını amaçlayan bu çalışmada 5 katılımcı bulunmaktadır. Sınıf sayısının ve katılımcı sayısının az olması çalışmadaki dezavantajlardan bazılarıdır. Cooney ve arkadaşları [31] 2018 yılında Mel frekansı cepstral katsayıları, istatistiksel özellik çıkarımı, destek vektör makinesi yöntemlerini kullandıkları çalışmada /iy/, /uw/, /piy/, /tiy/, /diy/, /m/, /n/, “pat”, “pot”, “knew”, “gnaw” olmak üzere 7 hece ve 4 kelimeyi sınıflandırmaya çalışmışlardır. 14 katılımcının bulunduğu çalışmanın doğruluk değeri düşüktür. Tottrup ve arkadaşları [32] 2019 yılında zamansal ve spektral özellikler ve rastgele orman yöntemlerini kullanarak “go”, “stop”, “viborg” kelimelerini sınıflandırmaya çalıştılar. 5 kadın 2 erkek olmak üzere 7 katılımcının bulunduğu bu çalışmada sınıf ve katılımcı sayısı düşük olmakla birlikte çalışmanın doğruluk değeri de düşüktür. Jahangiri ve arkadaşları [33] 2019’da yaptıkları çalışmayla /ba/, /fo/, /le/, /ry/ hecelerini sınıflandırmayı amaçlamışlardır. Çalışmada ayırık gabor dönüşümü ve lineer diskriminant analizi kullanılmış olup 6 katılımcı bulunmaktadır. Pawar ve Dhage [34] 2020 yılında yaptıkları çalışmayla “left”, “right”, “up”, “down” kelimelerini sınıflandırmayı amaçlamışlardır. Çalışmada 2 kadın, 4 erkek olmak üzere 6 katılımcı bulunmaktadır ve çalışmanın doğruluk değeri

çok sınıflı sınıflandırma için düşüktür. Cooney ve arkadaşları [35] 2020 yılında evrişimli sinir ağlarını kullanarak /a/, /e/, /i/, /o/, /u/ sesli harfleri ve “arriba”, “abajo”, “izquierda”, “derecho”, “seleccionar” kelimelerini sınıflandırmayı amaçlamışlardır. Çalışmada 15 katılımcı bulunmaktadır ve çalışma düşük doğruluk değerine sahiptir. M.A. ve arkadaşları [36], 2022 yılında bağlantı matrisleri ve destek vektör makinesi yöntemlerini kullanarak /æ/, /o/, /a/, /u/ ünlülerini sınıflandırmayı amaçlamışlardır. Çalışmada 2 kadın, 6 erkek olmak üzere 8 katılımcı bulunmaktadır. Dash ve arkadaşları [37] 2022 yılında çok değişkenli hızlı ve uyarlanabilir deneysel mod ayrıştırması ve sözlük öğrenme yöntemlerini kullanarak 15 katılımcı ile “Left”, “Right”, “Up”, “Down”, “Forward”, “Backward” kelimelerini sınıflandırmayı amaçlamışlardır. Çalışma çok sınıflı sınıflandırma için düşük doğruluk değerine sahiptir. Kamble ve arkadaşları [38], üç farklı veri kümesi üzerinde ikili ve çoklu sınıf sınıflandırması için değerlendirdikleri, ayrıştırma işleme, istatistiksel özellik çıkarımı, Kruskal Wallis testine dayalı özellik seçimi ve sınıflandırmayı birleştiren, hayali kelime tanıma için bir EEG sınıflandırma modeli önermişlerdir. Bakhshali ve arkadaşları [39] sekiz denekten toplanan EEG sinyallerinden dört kelime ve yedi fonem/heceyi sınıflandırmak için modellerinde korrentropi spektral yoğunluk matrisleri, Riemann mesafesi ve k-en yakın komşu (kNN) sınıflandırıcı kullanmışlardır. Benzer bir çalışmada, evrişimli sinir ağı (CNN), 15 denekten toplanan EEG sinyallerinden beş ünlü ve altı kelimelerin sınıflandırılmasını gerçekleştirmek için transfer öğrenme ile birleştirilmiştir [40]. Salinas ve arkadaşları [41] önerdikleri yöntemi kullanarak 27 deneğin EEG sinyallerinden beş kelimeyi sınıflandırmak için %68.18 doğruluk elde ettiler. Panachakel ve arkadaşları [42] 9 kanallı EEG sinyallerinden hayali konuşmanın kodunu çözmek için ayrık dalgacık dönüşümü (DWT) ile birleştirilmiş bir derin öğrenme mimarisi önererek %86.2 doğruluk elde etmişlerdir. Aynı yazarlar, farklı bir veri setinde aynı modeli kullanarak ortalama sınıflandırma doğruluğunun %57.15 olduğunu bildirdiler [43]. [44]’de, hayali konuşma tanıma problemine yeni bir model geliştirmek için iki farklı evrişimli sinir ağı, ortak bir uzamsal model ve bir lineer diskriminant analizi sınıflandırıcısı kullanılmış ve %62.37’lik maksimum doğruluk elde edilmiştir. Ayrıca literatürde biyomedikal alanda EEG işaret sınıflandırması ile ilgili birçok çalışma bulunmaktadır. Goshvarpour [45] EEG sinyali kullanan bir epileptik nöbet saptama yöntemi önermiştir. Epileptik nöbetleri tespit etmek için iki adet iki parçalı gül sarmal eğri modeli kullandı ve SVM ve kNN sınıflandırıcıları ile %100.0 doğruluk değerine ulaştı. Buriro ve arkadaşları [46] alkollü EEG sinyallerini otomatik olarak saptamak için dalgacık saçılma dönüşümü ve evrişimli sinir ağı kullandı. UCI veri seti üzerinde (20 alkolik denek ve 20 sağlıklı deneğin EEG sinyalleri) SVM sınıflandırıcısı kullanılarak alkollü EEG sinyallerinin saptanmasında %100 doğruluk bildirmişlerdir. Cherloo ve arkadaşları [47] motor imgeleme için bir EEG sinyal sınıflandırma modeli geliştirdiler. Topluluk düzenlileştirilmiş ortak uzamsal-spektral modeli uyguladılar. BCI III ve BCI IV için sırasıyla %86.91 ve %82.64 doğruluk bildirdiler. Wen ve arkadaşları [48], EEG sinyallerini kullanan düşük güçlü bir epilepsi saptama yaklaşımı sundular.

Kaldırma dalgacık dönüşümü ve SVM sınıflandırıcı kullanarak %91.86 doğruluk elde ettiler. Wang ve arkadaşları [49] EEG sinyallerini kullanarak en ayırt edici özelliği seçmek için istatistiksel yöntem uygulamışlardır. Çalışmalarının temel amacı, etkili bir öznitelik çıkarma yöntemi önermek ve yöntemin performansını test etmektir. Yöntemleri SVM sınıflandırıcı ile %81.99 doğruluk elde etmiştir. Baygın ve arkadaşları [16], EEG sinyalleri ile şizofreni saptaması için Collatz desen modeli ve yinelemeli komşu bileşen analizi kullanmışlardır. 19 kanallı veri setleri için sırasıyla %99,47 ve 10 kanallı veri setleri için %93,58 doğruluk değerine ulaşmışlardır. Aydemir ve arkadaşları [50] epilepsi hastalığı tespiti için dördü simetrik bir model önermiştir. Bonn EEG veri setini kullanarak kNN sınıflandırıcı ile %98.40 doğruluk elde etmişlerdir. Tuncer ve arkadaşları [51] yerel altılı modelini kullanan bir epilepsi saptama yöntemi sunmuştur. 5 sınıf Bonn EEG veri seti kullanarak SVM sınıflandırıcı ile %93.00 doğruluk bildirmişlerdir.

Literatür çalışmaları incelendiğinde EEG sinyalleri genellikle kelime ve heceleri sınıflandırmak için kullanılmıştır [11]. Ayrıca bu çalışmalarda kullanılan yöntemler genellikle düşük doğruluk değerleri üretmiştir. Kelime veya hece sınıflandırması için toplanan EEG sinyalleri genellikle az sayıda özneye sahiptir. Ayrıca bu sinyaller çok sınırlı sayıda kelime ve hece grupları için toplanmıştır. Bu noktada literatürde önemli bir boşluk bulunmaktadır. Bu boşluk EEG cümle sınıflandırmasıdır. Bu çalışmada literatürden farklı olarak önerilen yöntemlerle cümle sınıflandırması için EEG sinyalleri kullanılmıştır. Bilindiği kadarıyla bu tez çalışması EEG cümle sınıflandırması ile ilgili ilk çalışmadır. Ayrıca önerilen yöntemler yüksek doğruluk sağlamıştır ve literatürdeki birçok çalışmanın sonuçlarının üzerindedir.

4. MATERYAL VE METOTLAR

Tezin bu bölümünde, toplanan veri setleri ve bu veri setlerine uygulanan makine öğrenmesi modelleri verilmiştir. Aynı zamanda tezin materyalleri TÜBİTAK 1002 kapsamında desteklenen bir proje ile toplanmıştır. Oluşturulan EEG veri setleri ve bu veri setlerine uygulanan modeller aşağıdaki gibi verilmiştir. Özellik mühendisliği yöntemlerinin kullanılmasının temel sebebi düşük zaman karmaşıklığında yüksek performansa ulaşmaktır. Bu açıdan önerilen modeller, derin öğrenme modellerine alternatif olarak geliştirilmiştir. Bunu yanı sıra, bu tez çalışması, literatür taramasından elde edilen verilere göre EEG sinyallerinden cümle tanımayı konu alan ilk tez çalışmasıdır.

4.1. EEG Cümle Veri Setleri

Bu çalışmada kullanılan Türkçe cümle-EEG cümlesi (TSEEG) veri seti, katılımcılara sırasıyla gösterme ve dinleme modlarında gösterilirken veya okunurken kaydedilmiştir [11]. Son olarak 20 adet Türkçe dilinde yaygın olarak kullanılan standartlaştırılmış cümleler (Tablo 4.1) elde edilmiştir.

Tablo 4.1. TSEEG Veri seti

No	Türkçe Cümle	İngilizce Cümle	EEG bölümleri, (gösterme modu)	EEG bölümleri (dinleme modu)
1	Merhaba, hoş geldiniz	Hello, welcome	80	80
2	Yine görüşürüz	See you again	80	80
3	Güle güle	Bye bye	80	80
4	Sağlık olsun	Never mind	80	80
5	Afiyet olsun	Enjoy your meal	80	80
6	Neye bakmıştınız?	What are you looking for?	82	82
7	Bugün canlı ders var mı?	Is there any online lecture today?	80	80

8	Hangi bölümde okuyorsun?	In which department are you a student?	79	79
9	Mesleğiniz nedir?	What is your job?	80	80
10	Bana güvenebilirsin	You can trust me	80	80
11	Sakin ol	Calm down	79*	79*
12	Defol git	Get out of here	80	80
13	Kolay gelsin	Good luck	80	80
14	Haydi gidelim	Let's go	80	80
15	Acele et	Hurry up	80	80
16	Hiç yoktan iyidir	It is better than nothing	80	80
17	Rica ederim	You're welcome	80	80
18	Sen bilirsin	It is your choice	80	80
19	Rezil ettiler bizi, rezil olduk	They disgraced us, we became disgraced	81	81
20	Hiçbir şey bilmiyorsun	You know nothing	79	79

Gösteri modunda 20 cümle, 20 gönüllüye (16 erkek, yaş aralığı 19-23, ortalama yaş 21.35 ± 1.20 ; 4 kadın, yaş aralığı 19-23, ortalama yaş 20.50 ± 1.73) bilgisayar terminal ekranları aracılığıyla gösterildi.

Dinleme modunda cümleler bilgisayar ses çıkışı aracılığıyla 20 gönüllüye daha (17 erkek, yaş aralığı 19-24, ortalama yaş 21.74 ± 1.39 ; 3 kadın, yaş aralığı 20-23, ortalama yaş 21 ± 1.73) okundu.

16 kafa derisi bölgesinden 14 kanallı EEG sinyalleri toplayan EMOTIV EPOC + mobil sistemi (AF3 (1), F7 (2), F3 (3), FC5 (4), T7 (5), P7 (6), O1 (7), O2 (8), P8 (9), T8 (10), FC6 (11), F4 (12), F8 (13), AF4 (14), P3(referans bölgesi) ve P4 (referans bölgesi) (Şekil 4.1)) kullanılarak tüm gönüllülerden EEG sinyalleri alındı.

Her bir EEG sinyali segmenti 15 saniye sürdü (örnekleme hızı 128 Hz, bant genişliği 0,16–43 Hz) ve EEG sınıflandırma modeline girmeden önce EMOTIV EPOC + sisteminde ön işleme tabi tutuldu. Bu çalışmada sınıflandırma için, her EEG kaydı 14 EEG sinyal kanalı içermektedir. Bu nedenle, her Türkçe cümle bir sınıf olarak kabul edildi, yani sonuçlar ya kanal bazında ya da 20 sınıf sınıflandırma performansında raporlanmıştır. Sistem, deneyler için gönüllülerin kafa

derilerine uygun şekilde uygulanabilen, ayarlanmış konumlarda ıslak EEG elektrotlarından oluşmaktadır. Türkçe cümleler gösterme modunda bilgisayar ekranlarında gönüllülere gösterilmiştir. Ayrıca aynı Türkçe cümleler gönüllülere bilgisayar ses çıkışı üzerinden dinleme modunda okunmuştur. Her Türkçe cümle için bir adet 15 saniyelik 14 kanallı EEG kaydı alınmıştır. Deneylerin gösteri ve dinleme modları, kadın ve erkek gönüllülerden oluşan ayrı gruplarda gerçekleştirilmiştir.




Şekil 4.1. Bilgisayar terminaline kablosuz olarak bağlanan ticari EMOTIV EPOC + mobil sistemi kullanarak kadın (solda) ve erkek (sağda) gönüllülerden EEG sinyali toplama işlemi

5. MODELLER

Bir önceki bölümde detayları verilen veri setleri kullanılarak otomatik cümle sınıflandırma için iki adet model önerilmiştir ve bu modellerin detayları alt bölümlerde verilmiştir. Önerilen yöntemler özellik mühendisliği tabanlı yöntemlerdir.

5.1. Kare Toplamlı Graf Desen Tabanlı EEG Cümle Tanıma Modeli

Bu araştırmada yeni bir grafik deseni önerildi ve kare toplamı desenin bir grafiği kullanıldı. Kare toplam grafiğinde, iki komşu düğümün toplamı bir sayının karesine eşittir. Bu nedenle, bireysel bir kuralı vardır. Bu örüntüyü yaratmadaki temel amaç, tek boyutlu dokusal özellik çıkarıcı gibi yerel bir ikili örüntü sunmaktır. Burada kullanılan sayılar 1, 2, ..., 16'dır. Bu sayılar kullanılarak 16 adet düğüm oluşturulmuş ve kenarlar kare toplam kuralı tanımlanmıştır. Düğüm oluşturmak için 16 eleman/değer uzunluğunda örtüşen bir blok ve bu bloğun indeksleri kullanılmıştır. Kullanılan desen Şekil 5.1'de gösterilmiştir.



Şekil 5.1. Kare Toplamlı Grafik Deseni

Kullanılan kare toplam deseni Şekil 5.1'de gösterilmiştir. Bu grafikte, kare toplam kuralı kullanılarak kenarlar oluşturulur, bu desen için bir kenar numaralandırma algoritması önerilmiştir. Önerilen kenar numaralandırma algoritması Tablo 5.1'de verilmiştir.

Tablo 5.1. Kenar Numaralandırma Algoritması

Girdi: Kullanılan numaralar
Çıktı: Numaralandırılmış kenarlar
01: Kullanılan sayı dizisinin maksimumunu (m) bulun. Bu iş için maksimum sayı 16'dır. 02: Kare diziyi hesapla: $sq = \{2^2, 3^2, \dots, \lfloor \sqrt{2 \times m - 1} \rfloor^2\}$. Burada sq bir kare dizidir. 03: for i=1 to m do 04: <i>counter</i> = 1; 05: for j=1 to length(sq) do 06: <i>diff</i> = <i>sq</i> (j) - i; // <i>diff</i> farkı ifade eder. 07: if <i>diff</i> > i and <i>diff</i> ≤ m then 08: <i>edge</i> [i][<i>counter</i>] = <i>diff</i> ; // <i>edge</i> matrisi kenarları temsil eden matristir. 09: <i>counter</i> = <i>counter</i> + 1; // <i>counter</i> değişkeni sayaç olarak kullanılmaktadır. 10: end if 11: end for j 12: end for i

Tablo 5.1 kullanılarak kenarların numaralandırılması hesaplanmış ve kullanılan desen oluşturulmuştur (bkz. Şekil 5.1).

Kare toplam modelinin ayrıntılarını net bir şekilde veren açıklama aşağıda adım adım verilmiştir.

1: Kullanılan sinyal 16 uzunluğunda örtüşen bloğa bölünür.

$$p^t = s(t + k - 1), t \in \{1, 2, \dots, lg - 15\}, k \in \{1, 2, \dots, 16\} \quad (5.1)$$

Denklem (5.1)'de, kullanılan örtüşen blok bölümü tanımlanmıştır ve bu denklemde (Denklem (5.1)) kullanılan değişkenler şunlardır: p^t 16 uzunluğunda t'nci bloktur, s tek boyutlu bir sinyaldir ve lg sinyal(ler)in uzunluğudur.

2: Verilen grafik (bkz. Şekil 5.1) ve signum fonksiyonu kullanılarak 16 bit ayıklanır. LBP işlevinde sekiz bit çıkarılır. Bu nedenle, çıkarılan bitler iki gruba ayrılmıştır.

$$bf_1^t = \phi \begin{pmatrix} p^t(1), p^t(3) \\ p^t(1), p^t(8) \\ p^t(1), p^t(15) \\ p^t(2), p^t(7) \\ p^t(2), p^t(14) \\ p^t(3), p^t(6) \\ p^t(3), p^t(13) \\ p^t(4), p^t(5) \end{pmatrix} \quad (5.2)$$

$$bf_2^t = \phi \begin{pmatrix} p^t(4), p^t(12) \\ p^t(5), p^t(11) \\ p^t(6), p^t(10) \\ p^t(7), p^t(9) \\ p^t(9), p^t(16) \\ p^t(10), p^t(15) \\ p^t(11), p^t(14) \\ p^t(12), p^t(13) \end{pmatrix} \quad (5.3)$$

$$\phi(a, b) = \begin{cases} 0, & a - b < 0 \\ 1, & a - b \geq 0 \end{cases} \quad (5.4)$$

Burada, bf_t^1 ve bf_t^2 , örtüşen her bir bloktan (p^t) çıkarılan ikili özelliklerdir ve her ikili özellik vektörü (bf) sekiz bite sahiptir, $\phi(.,.)$ signum fonksiyonunu tanımlar ve a ve b olarak iki giriş parametresi alır.

3: bf vektörlerini kullanarak iki harita (map) sinyalinin değerleri hesaplanır.

$$map^1(t) = \sum_{j=1}^8 bf_1^t(j) \times 2^{8-j} \quad (5.5)$$

$$map^2(t) = \sum_{j=1}^8 bf_2^t(j) \times 2^{8-j} \quad (5.6)$$

Burada map^1 and map^2 oluşturulan haritalardır.

4: Oluşturulan haritaların histogramları çıkarılır. Bu haritalar sekiz bit ile kodlanmıştır. Böylece, çıkarılan her bir histogramın uzunluğu 256 ($=2^8$) olarak hesaplanmıştır.

5: 512 uzunluğunda bir özellik vektörü elde etmek için çıkarılan histogramlar birleştirilir.

$$fvc(j + 256 \times (h - 1)) = map^h(j), h \in \{1, 2\}, j \in \{1, 2, \dots, 256\} \quad (5.7)$$


Burada fvc, 512 uzunluğunda oluşturulan öznitelik vektörüdür.

Yukarıdaki bu beş adımda, sunulan kare toplamı model (SSG(.)) tanımlanmıştır.

Bu çalışmada elle modellenmiş bir sinyal sınıflandırma modeli önerilmiştir. Öneri dört temel aşama içerir ve bunlar:

- (i) Önerilen kare toplamı grafik deseni ve istatistiksel özellikler kullanılarak çok düzeyli hibrit el yapımı özellik çıkarma,
- (ii) NCA tabanlı özellik seçimi,
- (iii) k-NN kullanarak kanal bazında sonuçların hesaplanması,
- (iv) Oylanan sonuçların IMV kullanılarak hesaplanması ve ağgözlü algoritmayı kullanarak hesaplanan sonuçlar arasından en iyi sonucun seçilmesi.

Önerilen modelin genel görünümü de Şekil 5.2'de gösterilmektedir.



Şekil 5.2. Önerilen SSG tabanlı EEG cümle sınıflandırma modeline genel bakış

Bu modelde her kanalın EEG sinyali okunmuştur. Okunan EEG sinyalinin özelliklerini çıkarmak için TQWT kullanılır ve 12 dalgacık katsayısı (w) üretilir. Sunulan hibrit el yapımı özellik oluşturucuyu kullanarak, 13 özellik vektörü (ham EEG sinyalinden oluşturulan ilk özellik vektörü ve TQWT bantlarından oluşturulan diğerleri) üretildi. Burada önerilen kare toplamı grafiği deseni (SSG) kullanılarak 512 öznelik çıkarılır ve kullanılan istatistiksel momentler kullanılarak 40 öznelik üretilir. Dolayısıyla, her bir özellik vektörünün (f) uzunluğu 552'dir ($=512+40$). Oluşturulan 13 öznelik vektörünün birleştirilmesiyle 7176 ($=552 \times 13$) özellikten oluşan birleşik/son öznelik vektörü oluşturulmuştur. 7176 özellikten en iyi 552'si NCA seçim işlevi kullanılarak seçilir. kNN kanal bazında sınıflandırma tahmin vektörlerini ($p_1, p_2, \dots, p_{14}$) hesaplar ve bu vektörler ve IMV kullanılarak 12 oy tahmini vektörü ($p_{15}, p_{16}, \dots, p_{26}$) hesaplanır. 26

sonuç, oluşturulan tahmin edilen vektörler kullanılarak hesaplanır. Açgözlü algoritma uygulanarak en iyi sınıflandırma sonucu seçilir.

Şekil 5.2, sunulan SSG tabanlı EEG cümle sınıflandırma yönteminin genel görünümünü göstermektedir. Ayrıca, önerilen EEG cümle sınıflandırma modelinin ayrıntılarını vermek için bu yöntemin (SSG tabanlı yöntem) adımları aşağıda listelenmiştir.

Adım 1: Dalgacık alt bantlarını hesaplamak için TQWT EEG sinyaline uygulanır.

$$w = TQWT(s, 1, 3, 11) \quad (5.8)$$

Burada w dalgacık alt bantlarıdır, $TQWT(., ., ., .)$ TQWT alt bant oluşturma fonksiyonudur ve dört parametre alır, bu parametreler sinyal, salınım değeri (q), artıklık faktörü (r) ve seviye sayısıdır [18, 52]. Bu çalışma, 12 dalgacık alt bandı oluşturmak için q , r ve J değerlerini 1, 3 ve 11 olarak seçer.

Adım 2: Önerilen kare toplamı grafik desen çıkarıcı ve istatistiksel özellik oluşturucu kullanılarak dalgacık alt bantlarından ve orijinal EEG sinyalinden öznitelikler çıkarılır. Özellik çıkarma işlemi aşağıda verilmiştir.

$$f_1 = merge(\chi(s), SSG(s)) \quad (5.9)$$

$$f_{k+1} = merge(\chi(w_k), SSG(w_k)), k \in \{1, 2, \dots, 12\} \quad (5.10)$$

f , 552 uzunluğundaki öznitelik vektörlerini tanımlar, $\chi(.)$ istatistiksel öznitelik üreticidir, $SSG(.)$ önerilen kare toplamı grafik modeli ve $merge(.)$ birleştirme fonksiyonudur. $\chi(.)$ 'de 20 istatistiksel moment kullanılmış ve bu momentler sinyalin ham sinyal ve mutlak değerlerine uygulanmıştır. Bu nedenle, bir sinyalden 40 istatistiksel özellik çıkarılmıştır [18]. Kullanılan momentler Tablo 5.2'de verilmiştir.

Tablo 5.2. İstatistiksel özellikler oluşturmak için kullanılan istatistiksel momentler

Numara	Moment	Numara	Moment
1	Higuchi	11	Quartile 1
2	Lyapunov exponent	12	Quartile range
3	Fraktal	13	Tsallis entropi
4	Mean	14	Shannon entropi
5	Medyan	15	Sure entropi
6	Mod	16	Wavelet entropi
7	Minimum	17	Enerji
8	Maksimum	18	Varyans
9	Range	19	Skewness
10	Quartile 3	20	Kurtosis

$\chi(\cdot)$ ve $SSG(\cdot)$ fonksiyonları kullanılarak, kullanılan tek boyutlu sinyallerden 552 öznitelik (=40+512) çıkarılmıştır.

Adım 3: Oluşturulan özellikler birleştirilir.

$$X = f^k(j + 552 \times (k - 1)), j \in \{1, 2, \dots, 552\}, k \in \{1, 2, \dots, 13\} \quad (5.11)$$

Burada X, uzunluğu 7176 (=552×13) olan özellik vektörünü temsil eder.

Adım 4: Üretilen 7176 öznitelikten en iyi 552 özniteliği (her öznitelik vektörünün uzunluğu 552'dir. Dolayısıyla 552 öznitelik seçilmiştir) seçmek için NCA uygulanır. NCA, yaygın olarak bilinen mesafe tabanlı özellik seçicidir. Bu nedenle, kNN'in bir özellik seçim versiyonu olarak adlandırılmıştır. NCA, pozitif ağırlıklar üretir ve bu ağırlıklar kullanılarak en iyi özellikler seçilir.

Adım 5: Seçilen 552 öznitelik kNN sınıflandırıcısında kullanılmıştır. kNN'de k: 1, mesafe Manhattan, oylama: yok, 10 kat çapraz doğrulama özellikleri kullanılmıştır.

Adım 6: Adım 5 kullanılarak, her sınıfın doğrulama tahmini/tahmin vektörleri hesaplanmıştır. Kullanılan veri seti 14 kanal içermektedir. Böylece tahmin edilen 14 vektör elde edilmiştir. Öngörülen bu 14 vektörün doğrulukları hesaplanmış ve bu tahmin edilen vektörler azalan doğruluğa göre sıralanmıştır. Daha sonra mod fonksiyonu, nitelikli tahmin vektörlerine iteratif olarak uygulanmıştır. Bu yinelemeli süreç (IMV) kullanılarak, tahmin edilen 12 vektör daha hesaplanmıştır. Kullanılan IMV aşağıda matematiksel olarak tanımlanmıştır.

$$id = sort(acc, desc) \quad (5.12)$$

$$p^{h+12}(i) = \omega(p^{id(1)}(i), p^{id(2)}(i), \dots, p^{id(h)}(i)), h \in \{3, 4, \dots, 14\}, i \in \{1, 2, \dots, n\} \quad (5.13)$$

Burada IMV, Denklemler (5.12) ve (5.13) kullanılarak tanımlanmıştır.

Döngünün başlangıç değeri 3 olduğu için 12 oylanmış vektör hesaplanmıştır. id doğruluk (acc) değerleri kullanılarak nitelenmiş dizinlerdir, sort(.,) sıralama işlevidir ve desc azalan sıralamayı tanımlar, $\omega(\cdot)$ mod işlevidir. p, tahmin edilen vektörleri tanımlar ve n, kullanılan EEG sinyallerinin sayısıdır.


Adım 7: Tahmin edilen bu 26 vektörün doğrulukları hesaplanır ve en iyisi seçilir.

Yukarıdaki bu yedi adım (Adım 1-7) önerilen EEG cümle sınıflandırma modelini açıklamıştır.


5.2. Dinamik Boyutlu İkili Örüntü Tabanlı EEG Cümle Tanıma Modeli

Bu çalışmada, klasik dokusal özellik çıkarıcının özellik çıkarma yeteneğini geliştirmek için yeni bir dokusal özellik çıkarıcı önerilmiştir. DSBP, merkez simetrik ve merkez tabanlı özellik çıkarma stratejileri kullanarak ikili özellikleri çıkarmak için özdeş merkezlere ve dinamik olarak boyutlandırılmış pencere uzunlukları 3, 5, 7 ve 9'a sahip dört örtüşen blok kullanan tek boyutlu bir yerel ikili modelin [53] geliştirilmiş bir versiyonudur. (Şekil 5.3). Dikdörtgenler, blokların sinyal veri öğelerini temsil eder ve merkez değerleri kırmızı ile gösterilir. Uzunlukları 3, 5, 7 ve 9 olan örtüşen pencereler merkez değeri tanımlar. Merkez simetrik öznitelik çıkarımında merkezden eşit

uzaklıkta olan ve merkeze dayalı öznitelik çıkarımında merkeze göre öğelerin ilişkilerine dayalı olarak toplam 30 bit üretilmiştir.



Şekil 5.3. DSBP tabanlı merkez simetrik ve merkez tabanlı özellik çıkarımı



Şekil 5.4. Sunulan DSBP özellik çıkarıcısının grafik gösterimi

DSBP özellik çıkarımının ayrıntılı adımları aşağıda verilmiştir:

1. Tek boyutlu sinyal dokuz uzunluğa sahip örtüşen bloklara bölünür.

$$blc^1 = signal(k + l - 1), k \in \{1, 2, \dots, len\}, l \in \{1, 2, \dots, 9\} \quad (5.14)$$

burada blc^1 , uzunluğu dokuz olan örtüşen bloğu temsil eder.

2. blc kullanılarak alt bloklar oluşturulur.

$$blc^h = blc^{h-1}(1 + t), t \in \{1, 2, \dots, leng(blc^{h-1}) - 2\}, h \in \{2, 3, 4\} \quad (5.15)$$

burada $leng(.)$ uzunluk hesaplama fonksiyonudur.

3. Oluşturulan sabit olmayan boyutlu örtüşen bloklar ve signum işlevi kullanılarak ikili özellikler çıkarılır. DSBP özellik çıkarma fonksiyonunun şematik gösterimi, Şekil 5.4'te gösterilmektedir.

Tablo 5.3. DSBP tabanlı ikili özellik çıkarımının sözde kodu

Giriş: Uzunluğu 3,5,7,9 olan bloklar (blc). Çıktı: Uzunluğu 30 olan ikili özellikler (bit).
<pre> 01: $cnt = 1$; // Merkez simetrik bit çıkarma 02: for $k=1$ to 4 do 03: for $i=1$ to $\left\lfloor \frac{length(blc^k)}{2} \right\rfloor$ do 04: $bit(cnt) = \rho(blc^k(i), blc^k(length(blc^k) + 1 - i))$; 05: $cnt = cnt + 1$; 06: end for i 07: end for k // Merkez tabanlı bit çıkarma 08: for $k=1$ to 4 do 09: $center = \left\lfloor \frac{length(blc^k)}{2} \right\rfloor$; // Merkez değeri atanır 10: for $i=1$ to $length(blc^k)$ do 11: if $i \neq center$ then 12: $bit(cnt) = \rho(blc^k(i), blc^k(center))$; 13: $cnt = cnt + 1$; 14: end if 15: end for i 16: end for k </pre>

Tablo 5.3'te cnt sayacı temsil eder; $length(\cdot)$, uzunluk hesaplama fonksiyonu; $\rho(\cdot)$, matematiksel olarak aşağıdaki şekilde tanımlanan signum fonksiyonudur:

$$\rho(a, b) = \begin{cases} 0, & a - b < 0 \\ 1, & a - b \geq 0 \end{cases} \quad (5.16)$$

Burada a , b giriş parametrelerini temsil eder.

4. Oluşturulan 30 bit, her biri altı bitten oluşan, birbiriyle örtüşmeyen beş bit grubuna bölünür.

$$bg^t(i) = bit(i + 6 \times (t - 1)), i \in \{1, 2, \dots, 6\}, t \in \{1, 2, \dots, 5\} \quad (5.17)$$

Burada bg^t , t ninci bit grubudur.

5. Oluşturulan beş adet 6 bitlik grup kullanılarak beş harita sinyali hesaplanır.

$$m^t(i) = \sum_{j=1}^6 b g^t(j) \times 2^{6-j} \quad (5.18)$$

Burada ikiliden ondalığa dönüştürme gerçekleştirilmiştir ve m^t , t'inci harita sinyalini tanımlar.

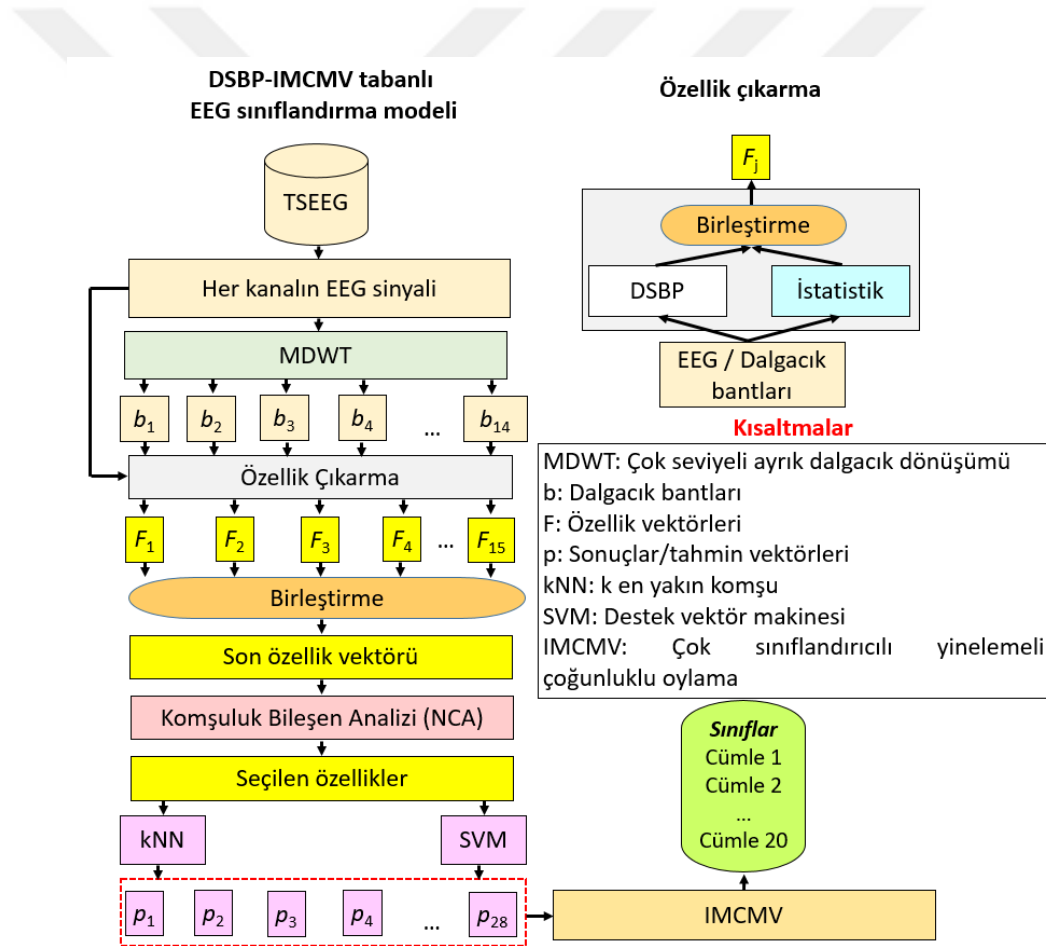
6. Hesaplanan harita sinyallerinin histogramları oluşturulur. Her histogramın uzunluğu 64'tür ($=2^6$).

7. DSBP'nin özellik vektörünü elde etmek için oluşturulan histogramlar birleştirilir.

$$x(j) = h^t(j + 64 \times (t - 1)), j \in \{1, 2, \dots, 64\}, t \in \{1, 2, \dots, 5\} \quad (5.19)$$

burada x, 320 uzunluğunda üretilen özellik vektörünü temsil eder ve h^t , t'ninci harita sinyalinin histogramını temsil eder.

Denklemler (1-7), önerilen DSBP özellik oluşturma fonksiyonunu ($\delta(.)$) tanımlar.



Şekil 5.5 . Giriş TSEEG veri seti ile önerilen DSBP-IMCMV modelinin blok diyagramı

5.2.1. Önerilen EEG cümle sınıflandırma modeli

Tek boyutlu sinyal sınıflandırma modeli dört aşamadan oluşur:

(i) DSBP, istatistik [54] ve MDWT [55] kullanılarak hibrit özellik çıkarımı;

- (ii) komşu bileşen analizi (NCA) [56] kullanılarak en önemli özelliklerin seçimi;
- (iii) kNN ve SVM kullanılarak her kanalın sinyal sınıflandırması ve IMCMV algoritması kullanılarak tüm kanallardan gelen sonuçların oylanması (Şekil 5.5).

Gösterilen veya okunan Türkçe cümlelere yanıt olarak alınan her 15 saniyelik EEG kaydını oluşturan 14 kanalın tümünden EEG sinyal segmentlerinin yüksek geçiren ve alçak geçiren filtre alt bantlarını hesaplamak için 7 seviyeli bir MDWT kullanıldı. 14 MDWT'den türetilmiş alt bantların her birinden ve kanalın orijinal giriş EEG sinyalinden sırasıyla 320 ve 40 özellik çıkarmak için DSBP ve istatistiksel üreteç işlevleri kullanıldı. Her bir EEG sinyal bölümü için üretilen 360 özellikten oluşan 15 özellik vektörü (f), NCA seçici kullanılarak en iyi 512 özelliğin seçildiği 5.400 ($=15 \times 360$) uzunluğunda büyük bir özellik vektörü oluşturmak üzere birleştirildi. Her kanalda iki doğrulama tahmin vektörünü hesaplamak için on kat çapraz doğrulamalı SVM ve kNN kullanıldı, yani her 14 kanallı EEG kaydı için 28 tahmin vektörü hesaplandı. Son olarak, kanal başına tüm EEG sinyal girişlerinde en iyi genel sınıflandırma sonucunu belirlemek için IMCMV algoritması kullanıldı.

Önerilen özellik mühendisliği modeli dört ana aşamadan oluşmaktadır. Bu aşamalar:

- (i) MDWT ve iki özellik seçme fonksiyonu (DSBP ve istatistik) ile hibrit ve çok düzeyli öznitelik çıkarma,
- (ii) NCA tabanlı en bilgilendirici öznitelik seçimi,
- (iii) İki klasik sınıflandırıcı (kNN ve SVM) ile sınıflandırma,
- (iv) En iyi sonuç seçimi için çoğunluk oylama kullanılır.

Ayrıca, DSBP-IMCMV tabanlı modelin ayrıntılı adımları aşağıda aşamalı olarak verilmiştir:

Özellik çıkarma: El yapımı bir özellik mühendisliği modeli önerilmiştir. Bu nedenle, bu modelin en önemli aşaması özellik çıkarımıdır. Bu aşamada, çok düzeyli bir öznitelik çıkarma yöntemi oluşturmak için MDWT kullanılmıştır. Ayrıca, el yapımı özellik çıkarımı istatistiksel ve dokusal olmak üzere iki ana metodoloji içerir. Bu nedenle, istatistiksel özellikler oluşturmak için iyi bilinen 20 doğrusal ve doğrusal olmayan istatistiksel moment kullanıldı ve dokusal özellikleri çıkarmak için yeni bir özellik oluşturma işlevi (DSBP) önerildi.


Adım 1: Ayrı kanallardan her bir EEG sinyal segmenti girişi (örnekleme hızı 128 Hz, süre 15 s) okunur. Her bir sinyal segmentinin uzunluğu 1.920'dir ($=128 \times 15$).

Adım 2: MDWT dönüşümü (Şekil 3) kullanılarak EEG sinyali alt bantlara (b) ayrıştırılır. Burada yedi seviyeli MDWT kullanılmıştır. Seviye sayısı aşağıdaki formül kullanılarak hesaplanmıştır:

$$lev = \left\lceil \log_2 \left(\frac{len}{lb} \right) \right\rceil \quad (5.20)$$

burada lev seviye sayısını temsil eder; len , EEG sinyalinin uzunluğu; ve lb , yerleştirilmiş örtüşen blokların maksimum uzunluğunu temsil eder.

MDWT'nin şematik ifadesi, Şekil 5.6'da gösterilmiştir.



Şekil 5.6. Yedi seviyeli MDWT'nin gösterimi

Symlet 4 ana dalgacık fonksiyonu, her biri alçak geçiren (L) ve yüksek geçiren (H) filtre katsayıları içeren b alt bantlarını oluşturmak için kullanıldı. Literatürde, genel olarak, çok seviyeli dalgacık dönüşümü, özelliklerin frekans alanında oluşturulması için kullanılmaktadır. Bunun yanı sıra çok seviyeli dalgacık dönüşümü kullanılarak çok seviyeli bir özellik mimarisi elde edilir ve bu mimari kullanılarak hem düşük hem de yüksek seviyeli özellikler çıkarılır. Yüksek geçiren filtre alt bantlarının özellik oluşturma yeteneğinden faydalanmak istendiği için hibrit bir yaklaşım kullanılmıştır. Bu nedenle, dalgacık paket ayrışımı [57], gibi özellikler oluşturmak için yüksek geçiren filtre alt bantları kullanıldı.

Ayrıca symlet4 filtresi kullanılmıştır. Bu filtre genellikle sinyal gürültü giderme için kullanılır. MDWT modeli kullanılarak alt bant üretimi aşağıda matematiksel olarak açıklanmıştır.

$$[L_1, H_1] = \Psi(EEG, sym4) \quad (5.21)$$

$$[L_g, H_g] = \Psi(L_{g-1}, sym4), g \in \{2, 3, \dots, 7\} \quad (5.22)$$

burada L ve H sırasıyla alçak geçiren ve yüksek geçiren filtre katsayılarını temsil eder; ve $\Psi(., .)$, ayrı dalgacık dönüşüm fonksiyonudur ve giriş sinyali ve dalgacık filtresi olmak üzere iki parametre alır. Burada symlet 4 (sym4) filtresi kullanılmıştır. Oluşturulan alt bantlar (L ve H) kullanılarak modelin bant veri yapısı oluşturulmuştur (Şekil 5.3).

$$b_{2k-1} = L_k, k \in \{1,2, \dots, 7\} \quad (5.23)$$

$$b_{2k} = H_k \quad (5.24)$$

Adım 3: İstatistiksel ve DSBP özellik çıkarıcıları kullanılarak b ve orijinal EEG sinyalinin özellik vektörleri oluşturulur.

$$f_1 = \gamma(\varpi(EEG), \delta(EEG)) \quad (5.25)$$

$$f_{j+1} = \gamma(\varpi(b_j), \delta(b_j)), j \in \{2,3, \dots, 14\} \quad (5.26)$$

Burada f özellik vektörleridir; $\gamma(\cdot)$ birleştirme işlevi; $\varpi(\cdot)$, istatistiksel özellik çıkarıcı; ve $\delta(\cdot)$, DSBP özellik çıkarıcıdır.

Her bir alt banttan veya giriş EEG sinyalinin sırasıyla 40 ve 320 özellik çıkaran $\varpi(\cdot)$ ve $\delta(\cdot)$ 'nin detayları aşağıda verilmiştir. Kullanılan istatistiksel özellik çıkarımı aşağıda açıklanmıştır.

İstatistiksel özellik çıkarımı hızlı ve etkili bir yöntemdir [58]. Bu çalışmada, her bir tek boyutlu sinyalden 40 özellik çıkarmak için her bir tek boyutlu sinyale ve onun mutlak değerine yaygın olarak kullanılan yirmi istatistiksel moment uygulanmıştır. Bu çalışmada kullanılan istatistiksel özellik çıkarımı, hem doğrusal (medyan, maksimum, minimum, mod, varyans, çarpıklık, standart sapma, basıklık, ortalama, aralık, Higuchi, en büyük Lyapunov üssü) hem de doğrusal olmayan (enerji, Renyi, Shannon, Kolmogorov-Sinai, Fuzzy, Tsallis, Wavelet ve Permutation entropi) yöntemleri içerir [59].

Birleştirilmiş bir özellik vektörü oluşturmak için dokusal ve istatistiksel özellikler kullanılmıştır.

Adım 4: Oluşturulan özellik vektörleri birleştirilir.

$$X(q + 360 \times (l - 1)) = f^l(q), q \in \{1,2, \dots, 360\}, l \in \{1,2, \dots, 15\} \quad (5.27)$$

burada X, 5.400 (=360 × 15) uzunluğunda hesaplanan nihai/birleşik özellik vektörünü temsil eder. Yukarıdaki 1'den 4'e kadar olan adımlar, önerilen çok düzeyli hibrit özellik çıkarma sürecini tanımlar.

Öznitelik Seçimi: Bu çalışmada, mesafe tabanlı bir fonksiyon olan basit bir özellik seçme fonksiyonu kullanılmıştır. Bu fonksiyon NCA'dır ve NCA, kNN'nin seçim versiyonudur.

NCA, en bilgilendirici özellikleri seçmek için kullanılmış olan özellikler için negatif olmayan ağırlıklar üretir (yüksek ağırlıklar ayırt edici özellikleri ve düşük ağırlıklar gereksiz özellikleri tanımlar). Böylece üretilen ağırlıklar, özniteliklerin nitelikli indekslerini elde etmek için azalan oranlarda sıralanmıştır. Hesaplanan indeksler kullanılarak en bilgilendirici/değerli özellikler seçilebilir. Ayrıca, NCA hem basit hem de etkili bir özellik seçme işlevidir. Bu nedenle, özellik seçici olarak NCA tercih edilmiştir. Bu araştırmada en değerli 512 özellik seçilmiştir.

Adım 5: NCA özellik seçiciyi kullanarak en değerli/önemli 512 özellik seçilir.

kNN'nin özellik seçim karşılığı olan NCA, literatürde yaygın olarak kullanılan basit bir seçicidir.

Sınıflandırma: Önerilen özellik çıkarma yöntemi ve NCA kullanılarak oluşturulan özelliklerin yüksek sınıflandırma yeteneğini göstermek için kNN ve SVM olarak iki sığ sınıflandırıcı

kullanmıştır. En uygun sınıflandırıcıları seçmek için MATLAB kullanılmıştır. Hesaplanan test sonuçlarına göre, en iyi iki sınıflandırıcı kNN ve SVM'dir. Bu nedenle, bu sınıflandırıcılar doğrulama tahmin vektör üreticileri olarak kullanılmıştır.

Adım 6: 10 kat çapraz doğrulama ile kNN ve SVM kullanılarak doğrulama tahmin vektörleri hesaplanır. Önerilen IMCMV'nin ilk adımı olan her kanalın EEG sinyal segmenti için iki tahmin vektörü oluşturuldu.

$$p^{2c-1} = K(sf_c, y, 10), c \in \{1, 2, \dots, 14\} \quad (5.28)$$

$$p^{2c} = \Phi(sf_c, y, 10) \quad (5.29)$$


burada p tahmin edilen vektörleri temsil eder; sf , NCA tarafından seçilen özellikler; y , gerçek çıktı; "10" değeri, 10 kat çapraz doğrulama; $K(\cdot)$, kNN sınıflandırıcısı; ve $\Phi(\cdot)$, DVM sınıflandırıcısıdır.

Sınıflandırıcıların hiperparametreleri aşağıda verilmiştir:

k-en yakın komşu (kNN): k 1'dir,

Destek vektör makinesi (DVM) [60]: İkinci dereceden bir polinom çekirdeği kullanılmış, kutu kısıtlama seviyesi bir ve kodlama 1-vs-1 olarak seçilmiştir.

Çoğunluk oylaması: Bu çalışmada, yeni bir çoğunluk oylama algoritması önerilmiştir.



Şekil 5.7. En iyi sınıflandırma sonucunu elde etmek için kullanılan IMCMV algoritması

Bu çoğunluk oylama modeli, birden fazla oylanan vektör oluşturmak için bir döngü kullanır ve iki sınıflandırıcının tahmin edilen vektörlerini kullanmıştır. Bu nedenle bu model, yinelemeli çoklu sınıflandırıcılara dayalı çoğunluk oylaması (IMCMV) olarak adlandırılır. Bu aşamanın grafiksel özeti Şekil 5.7'de ve adımları ise Tablo 5.4'te verilmiştir.

Adım 7: p ve y 'yi kullanarak her bir kanalın doğruluğu hesaplanır.

Adım 8: Genel sonuçları hesaplamak için yinelemeli (döngü tabanlı) mod tabanlı çoğunluk oylaması uygulanır.

Tablo 5.4. IMCMV'nin sözde kodu

Girdi: Tahminler (p), doğruluklar (oa).
Çıktı: Oylanan tahminler (vp).
01: Hesaplanan doğruluk kullanılarak sıralanmış dizinler (idx) hesaplanır. 02: for $g=3$ to 28 do // Yinelemeli oylama 03: for $i=1$ to $length(y)$ do 04: for $j=1$ to g do 05: $arr(j) = p_{idx(j)}(i)$; // arr oluşturulan diziyi temsil etmektedir. 06: end for j 07: $vp_{g-2}(i) = \mathcal{M}(arr)$; // $\mathcal{M}(\cdot)$ mode fonksiyonudur. 08: end for i 09: end for h

Adım 9: vp ve y kullanılarak oylanan doğruluklar hesaplanır.

Adım 10: En iyi sonuç seçilir.

6. DENEYSEL SONUÇLAR

Bu bölümde, toplanan EEG sinyal veri setini kullanarak elde edilen sınıflandırma sonuçları verilmiştir, sunulan öneri bir sinyal sınıflandırma modelidir.

6.1. Deneysel Kurulum

Önerilen SSG tabanlı EEG sınıflandırma modeli, el yapımı öznitelik tabanlı bir sinyal sınıflandırma modelidir ve MATLAB (2021a) ortamında uygulanmıştır. Bu modelin hafif özelliğini göstermek için basit/temel yapılandırılmış bir bilgisayar kullanılmış ve SSG tabanlı EEG sınıflandırması CPU modunda herhangi bir grafik işlemci ve paralel programlama kullanılmadan uygulanmıştır. Kullanılan bilgisayar Intel i7 7700 CPU, 16 GB RAM bellek, 256 GB SSD ve Windows 11 işletim sistemine sahiptir.

Bu tezde iki adet model önerilmiştir ve modellerin parametreleri aşağıdaki gibi verilmiştir.

Tablo 6.1. Kare toplamı graf deseni tabanlı modelin parametreleri

Metot	Parametreler
Kare toplamı graf deseni	Kernel: Signum Örtüşen blok uzunluğu: 16 Özellik uzunluğu: 512
İstatistiksel özellik çıkarma	Moment Sayısı: 20 Özelliklerin uzunluğu: 40
TQWT	Q:1, r:3 (yaygın olarak kullanılan salınımlı olmayan parametrelerdir), J:11 (en küçük bandın uzunluğu 16'nın üzerinde olduğundan maksimum seviye sayısı). TQWT kullanılarak, özellikler frekans alanından çıkarılır.
NCA	Oluşturulan 7176 özellik arasından 552 özellik seçildi
kNN	k:1, mesafe: L1-norm, oylama: hayır, doğrulama: 10 kat CV
IMV	Döngü aralığı 3 ile 14 arasındadır
Seçim	Maksimum doğru tahmin edilen vektör seçilir

Bu parametreler kullanılarak (bkz. Tablo 6.1) öneri, toplanan EEG veri setinde uygulanmıştır. Tablo 6.2' de DSBP tabanlı modelin oluşturulma parametreleri verilmiştir.

Tablo 6.2. DSBP-IMCMV deseni tabanlı modelin parametreleri

Metot	Parametreler
DSBP	Merkezi simetrik ve merkez tabanlı özellik çıkarma stratejileri kullanıldı Kernel: Signum Örtüşen Blok Uzunluğu: 9 Özellik vektörünün uzunluğu: 320
MDWT	EEG sinyal segmentlerinin yüksek geçiren ve alçak geçiren filtre alt bantlarını hesaplamak için 7 seviyeli bir MDWT kullanıldı
NCA	Oluşturulan 5400 özellik arasından 512 özellik seçildi
IMCMV	Oylanan sonuçları hesaplamak ve en iyi sonuçları seçmek için IMCMV kullanıldı
İstatistiksel özellik çıkarma	Moment Sayısı: 20 Özelliklerin uzunluğu: 40
kNN	k: 1, mesafe (L1-norm)
SVM	Polinomal çekirdekli SVM

6.2. Performans Değerlendirme Metrikleri

EEG cümle veri seti, genel sınıflandırma ölçümleri kullanıldığından 20 sınıf içerir. Literatürde en çok tercih edilen sınıflandırma ölçümü doğruluktur. Bu nedenle doğruluk kullanılmıştır. Ayrıca literatürde genellikle kesinlik, hatırlama ve F1-skor ölçümleri kullanılmıştır. Bu nedenle, doğruluğa ek olarak kesinlik, geri çağırma ve F1 puanı ölçümleri de kullanılmıştır [61,62]. Kullanılan performans değerlendirme ölçütlerinin matematiksel gösterimleri/denklemleri de aşağıda verilmiştir.

$$\text{doğruluk}(acc) = \frac{ntp + ntn}{ntp + ntf + nfp + nfn} \quad (6.1)$$

$$\text{hatırlama}(rec) = \frac{ntp}{ntp + nfn} \quad (6.2)$$

$$\text{kesinlik}(pre) = \frac{ntp}{ntp + nfp} \quad (6.3)$$

$$F1 \text{ puanı} = 2 \frac{rec \times pre}{rec + pre} \quad (6.4)$$

acc doğruluk, rec hatırlamayı tanımlar, pre kesinliği temsil eder, F1, F1 puanıdır. Bu performans değerlendirme ölçümlerini hesaplamak için dört değişken kullanılır ve bunlar ntp gerçek pozitiflerin sayısını, ntn gerçek negatiflerin sayısını, nfp yanlış pozitiflerin sayısını ve nfn yanlış negatiflerin sayısını temsil eder.

6.3. Kanal Bazında Sonuçlar

Toplanan veri kümesi 14 kanala sahiptir. Bu araştırmada, kanal bazında sınıflandırmayı göstermek için her bir kanalın sınıflandırma performansları hesaplanmıştır. Ayrıca kanal bazında sınıflandırma performansı hesaplanarak her bir kanalın cümle sınıflandırma etkisi değerlendirilmiştir. Kullanılan önerilere ait hesaplanan kanal bazında sonuçlar Tablo 6.3 ve 6.4'te gösterilmiştir.

Tablo 6.3. Birinci modelin kanal bazlı sonuçları (%)

Kanallar	Hatırlama	Kesinlik	F1 Puanı	Doğruluk
1: AF3	93	93,13	93,06	93
2: F7	94,19	94,20	94,19	94,19
3: F3	92,45	92,61	92,53	92,44
4: FC5	65,60	66,10	65,85	65,63
5: T7	89,22	89,36	89,29	89,25
6: P7	75,11	75,92	75,51	75,13
7: O1	92,73	93,03	92,88	92,75
8: O2	95,06	95,15	95,11	95,06
9: P8	93,07	93,29	93,18	93,06
10: T8	92,50	92,85	92,68	92,50
11: FC6	92,69	92,93	92,81	92,69
12: F4	89,50	89,61	89,55	89,50
13: F8	91,58	91,78	91,68	91,56
14: AF4	93,87	94	93,94	93,88

Tablo 6.3'den de anlaşılacağı gibi, O2 kanalında %95,06 sınıflandırma doğruluğu elde edildiği için en doğru kanal O2 kanalıdır. En kötü doğru kanal FC5'tir ve bu kanalın sınıflandırma doğruluğu %65,63'e eşittir. 20 sınıf bulunmakta olup tüm bireysel kanal bazında sonuçlar %60'ın üzerindedir.

Ayrıca kNN sınıflandırıcı kullanılarak önerilen modelin genel sınıflandırma doğruluğu (ortalama $\pm$ standart sapma) $\%89,33 \pm \%8,39$ olarak hesaplanmıştır.

Tablo 6.4. İkinci modelin kanal bazlı sonuçları (%)

Kanallar	kNN				SVM			
	<i>Oa</i> (%)	<i>Rc</i> (%)	<i>Pr</i> (%)	<i>F1</i> (%)	<i>Oa</i> (%)	<i>Rc</i> (%)	<i>Pr</i> (%)	<i>F1</i> (%)
1	88,38	88,38	88,48	88,43	91,31	91,32	91,65	91,48
2	91,06	91,06	91,15	91,11	90,75	90,75	90,89	90,82
3	89	89,01	88,99	89	90,50	90,51	90,70	90,60
4	87,75	87,74	87,84	87,79	90	90	90,48	90,24
5	89,50	89,46	89,56	89,51	90,88	90,85	91,01	90,93
6	90,25	90,24	90,29	90,26	88,88	88,87	89,27	89,07
7	89,75	89,72	90,04	89,88	90,38	90,36	90,81	90,59
8	94,69	94,69	94,83	94,76	93,69	93,69	93,98	93,83
9	92,13	92,11	92,30	92,20	92,06	92,06	92,52	92,29
10	92,38	92,37	92,49	92,43	92,63	92,62	92,85	92,73
11	92,31	92,32	92,43	92,37	91,81	91,82	92,17	91,99
12	86,44	86,43	86,64	86,53	88,69	88,68	89,23	88,95
13	83,56	83,58	83,65	83,62	87,56	87,56	87,88	87,72
14	90,31	90,32	90,36	90,34	91	91	91,22	91,11

Tablo 6.4'ten de anlaşılacağı gibi, 8 numaralı kanalda $\%94,69$ sınıflandırma doğruluğu elde edildiği için en doğru kanal 8 numaralı kanaldır.

6.4. Ağırlıklı Oylama Sonuçları

Birinci önerilen modelin sınıflandırma kabiliyetini artırmak için IMV algoritması kullanılmış ve 12 kanaldan 14 sonuç hesaplanmıştır. IMV'nin iterasyon aralığı 3 ile 14 arasındadır. Böylece IMV kullanılarak 12 oylama sonucu hesaplanmıştır. Hesaplanan oylama sonuçları aşağıdaki tablolarda gösterilmiştir.


Tablo 6.5. Birinci modele ait IMV kullanılarak oylanan sonuçlar (%)

Kanalların Numaraları	Hatırlama	Kesinlik	F1 Puanı	Doğruluk
-----------------------	-----------	----------	----------	----------

3	97,44	97,52	97,48	97,44
4	98,25	98,33	98,29	98,25
5	98,75	98,78	98,76	98,75
6	98,94	98,97	98,95	98,94
7	98,69	98,74	98,71	98,69
8	99,06	99,10	99,08	99,06
9	98,87	98,94	98,91	98,88
10	99	99,04	99,02	99
11	99	99,06	99,03	99
12	99,13	99,16	99,14	99,13
13	98,88	98,92	98,90	98,88
14	99,19	99,21	99,20	99,19

Tablo 6.5, hesaplanan en iyi doğruluğun %99,19'a eşit olduğunu göstermektedir ve bu doğruluk tüm (14) kanalların oylanmasıyla elde edilmiştir. IMV kullanılarak, tüm sonuçlar %97'nin üzerinde elde edilmiştir (en kötü genel doğruluk, ilk üç kanal kullanılarak %97,44'tür). Ayrıca, IMV en iyi sınıflandırma doğruluğunu %95.06'dan (kanal bazında en iyi doğruluktur) %99,19'a yükseltir. Açgözlülük temelli bir mimari önerilmiştir. Bu nedenle önerilen SSG tabanlı EEG cümle sınıflandırma modelinin elde edilen sınıflandırma doğruluğu %99,19'a eşittir.

İkinci modele ait gösteri modunda elde edilen TSEEG sinyallerinde kullanılan tahmin vektörlerinin sayısına karşı oylanın doğruluk grafiği ise Şekil 6.1'de verilmiştir.




Şekil 6.1. İkinci modele ait gösteri modunda elde edilen TSEEG sinyallerinde kullanılan tahmin vektörlerinin sayısına karşı oylanan doğruluk grafiği

6.5. Sınıf Bazında Sonuçlar


6.5.1. Birinci Modele Ait Sonuçlar

Birinci öneri, kendi kendini organize eden bir EEG cümle sınıflandırma modelidir. Önceki iki bölümden de görüleceği üzere (bkz. Bölüm 6.3 ve Bölüm 6.4), 14 kanal bazında ve 12 oylama sonucu hesaplanmıştır. Bu mimari, hesaplanan 26 sonuçtan en iyi sonuçları seçer. Hesaplanan sonuçlara göre önerilen model %99,19 sınıflandırma doğruluğu sağlamıştır. Ayrıca, kullanılan veri seti 20 kategori içermektedir.



Şekil 6.2. Karışıklık matrisi

Şekil 6.2, yanlış sınıflandırılan EEG sinyallerinin toplam sayısının 11 olduğunu göstermektedir. 14 sınıfın geri çağırma değerleri %100'e eşittir. En kötü doğru sınıf 9. sınıftır (Mesleğiniz nedir?) ve bu sınıfta %93,75 hatırlama (sınıf bazında doğruluk) elde edilmiştir. Ayrıca, sınıf bazında hatırlama, kesinlik ve F1 puanları Şekil 6.3'de gösterilmektedir.




Şekil 6.3. Sınıf bazında hatırlama, F1 puanı ve kesinlik değerleri.

Şekil 6.3, en iyi sonuçların %100'e eşit olduğunu göstermektedir. En kötü hatırlama, kesinlik ve F1 puanları sırasıyla %93.75 ile 9. kanala ait, %94.05 ile 17. kanala ait ve %96.15 ile 17. kanala aittir.

6.5.2. İkinci Modele Ait Sonuçlar

Gösteri modu sonuçları: Model, Kanal 8'de görülen en iyi performansla, kNN ve SVM sınıflandırıcılarını kullanarak kanal bazında sonuçlara ulaşmıştır. (Tablo 6.3).

Tüm kanallardaki genel sınıflandırma doğruluk oranları, kNN ve SVM sınıflandırıcıları kullanılarak sırasıyla $89,82 \pm 2,79$ ve $90,72 \pm 1,62$ olarak elde edilmiştir. IMCMV algoritması kullanılarak, karşılık gelen doğruluklarla oylanan 26 sonuç daha yinelenmeli olarak hesaplanmıştır. Model, IMCMV'yi dağıtarak, tahmin edilen üç vektörün minimumunu kullanarak %96,19'luk bir doğruluk elde etti (en kötü) ve tahmin edilen 28 vektörün tümünü kullanarak %98,81'lik en iyi doğruluk elde edildi (Şekil 6.1). Gösterim modunda elde edilen TSEEG sinyalleri kullanılarak elde edilen modelin karışıklık matrisi, düşük yanlış sınıflandırma oranlarını göstermektedir (Şekil 6.4). En kötü ihtimalle Türkçe cümle 9 Numara “Mesleğiniz nedir?” gösteri modunda sekiz kez Türkçe Cümle Numarası 17 “Rica ederim” olarak yanlış sınıflandırılmıştır (Tablo 4.1).




Şekil 6.4. Gösterme modunda elde edilen TSEEG sinyalleri için oylanan sonuçların karışıklık matrisi

Dinleme modu sonuçları: Model, sırasıyla kNN ve SVM sınıflandırıcıları için Kanal 7 ve 10 için elde edilen en iyi performansla, kanal bazında sonuçlara ulaştı (Tablo 6.6). Tüm kanallardaki genel sınıflandırma doğruluk oranları, kNN ve SVM sınıflandırıcıları kullanılarak sırasıyla %92,48 %±2,61 ve %92,27 %±1,94'tür. Model, IMCMV'yi dağıtarak, tahmin edilen en az üç vektörü kullanarak %96,56'lık bir doğruluk sonucu ve tahmin edilen 15 vektörü kullanarak %98,19'luk en iyi doğruluk sonucunu elde etti (Şekil 6.5). Dinleme modunda elde edilen TSEEG sinyalleri için modelin karışıklık matrisi, yanlış sınıflandırma oranlarını göstermektedir (Şekil 7.4). En kötü durumda, dinleme modundaki 3 Numaralı Türkçe cümle “Güle güle” on iki kez Türkçe 13 Numaralı “Kolay gelsin” cümlesi olarak yanlış sınıflandırılmıştır (Tablo 4.1). Numaralandırılmış her gerçek sınıf, Tablo 4.1'de listelenen numaralandırılmış Türkçe cümleye karşılık gelir.

Tablo 6.6. KNN ve SVM sınıflandırıcıları kullanılarak dinleme modunda elde edilen kanal bazlı sonuçlar (%).

Kanallar	kNN				SVM			
	$Oa(\%)$	$Rc(\%)$	$Pr(\%)$	$F1(\%)$	$Oa(\%)$	$Rc(\%)$	$Pr(\%)$	$F1(\%)$
1	91.94	91.92	91.98	91.95	92.56	92.54	92.75	92.65
2	93.38	93.36	93.45	93.41	92.38	92.36	92.47	92.42
3	90.13	90.12	90.23	90.18	90.13	90.11	90.60	90.35
4	93.75	93.75	93.80	93.77	92.50	92.49	92.67	92.58
5	92.94	92.93	93.13	93.03	93.69	93.69	93.95	93.82
6	93.50	93.49	93.71	93.60	92.94	92.94	93.12	93.03
7	95.25	95.24	95.39	95.32	94.31	94.31	94.48	94.40
8	95.06	95.06	95.09	95.08	93.75	93.73	93.96	93.85
9	95.06	95.06	95.13	95.09	93.81	93.80	93.98	93.89
10	94.25	94.24	94.34	94.29	94.63	94.62	94.74	94.68
11	92.63	92.62	92.76	92.69	92.44	92.43	92.51	92.47
12	89.19	89.17	89.40	89.29	89.75	89.73	90.09	89.91
13	85.88	85.86	85.88	85.87	87.81	87.80	88.33	88.07
14	91.81	91.80	91.80	91.80	91.13	91.11	91.27	91.19




Şekil 6.5. Dinleme modunda kullanılan tahmin vektörlerinin sayısına karşı oylanan doğrulukların grafiği

7. BULGULAR VE TARTIŞMA

Bu tez çalışmasında iki adet model önerilmiştir. Bu modellerle elde edilen bulgular ve sonuçlar bu bölümde tartışılmıştır.


7.1. Toplamsal Kareler Tabanlı Yöntem

Bu araştırmada yeni bir EEG sınıflandırma metodolojisi tanımlanmıştır ve bu metodoloji EEG cümle sınıflandırması olarak adlandırılmıştır. Önerilen SSG tabanlı EEG sinyal sınıflandırması, EEG sinyallerini kullanan bir makine öğrenme modelinin cümle sınıflandırma kapasitesini göstermek için yeni toplanmış bir EEG sinyal veri seti üzerinde test edilmiştir. Toplanan veri seti, 15 saniye uzunluğunda 1600 EEG sinyali içerir. Bu EEG sinyalleri 20 katılımcıdan toplanmıştır. Ayrıca bu EEG sinyal veri setinde 20 sınıf bulunmaktadır. Bu veri setini otomatik olarak sınıflandırmak için elle modellenmiş yeni bir gelişmiş sinyal işleme modeli önerilmiştir ve bu model yeni bir graf tabanlı öğrenme modeli kullanmaktadır. Sunulan graf tabanlı özellik çıkarıcı, kare toplamı bir problem kullanır. Sunulan SSG modeli, kendi kendini organize eden bir EEG sınıflandırma mimarisinde kullanılır. Bu mimaride, dalgacık alt bantlarından üst düzey öznitelikler çıkarılmıştır. Ayrıca, ham EEG sinyallerine SSG ve istatistiksel öznitelik çıkarıcılar uygulanır. Bu açıdan, sunulan öneri hem uzay hem de frekans alanlarından özellikler çıkarır. En iyi öznitelikler NCA (kNN'nin özellik seçim versiyonu) seçicisi ve kNN (Özellikler NCA kullanılarak seçilmiştir. Bu nedenle, kanal bazında sınıflandırma sonuçları elde etmek için kNN sınıflandırıcısı kullanılmıştır) kullanılarak seçilmiştir. Ayrıca, en iyi sınıflandırıcıyı seçmek için MATLAB kullanılmıştır. Karar ağacı, destek vektör makinesi, kNN, yapay sinir ağı ve torbalı ağaç sınıflandırıcıları kullanılmıştır. AF3 kanalı için bu beş sınıflandırıcının sınıflandırma sonuçları Şekil 7.1'de gösterilmiştir.




Şekil 7.1. AF3 kanalı için kullanılan sınıflandırıcıların kıyaslaması

Şekil 7.1, kullanılan sığ sınıflandırıcılardan bu problemi çözmek için en uygun sınıflandırıcının kNN olduğunu göstermiştir. IMV'yi konuşlandırarak, hesaplanan tahmin edilen vektör sayısı 14'ten 26'ya çıkarıldı. Tahmin edilen tüm vektörlerin sınıflandırma doğrulukları hesaplandı ve en iyisi önerilen SSG tabanlı kendi kendine organize EEG sinyal sınıflandırma modeli tarafından seçildi. Hesaplanan 26 doğruluk Şekil 7.2'de gösterilmiştir.



Şekil 7.2. Tahmini 26 vektörü kullanan hesaplanmış 26 sınıflandırma doğruluğu

Şekil 7.2, en iyi sınıflandırma doğruluğunun (%99,19), tahmin edilen 26. vektör kullanılarak elde edildiğini göstermiştir. Bu nedenle, bu (26.) tahmin edilen vektör, nihai tahmin edilen vektör olarak kullanıldı. Tahmin edilen ilk 14 vektör her kanala aittir ve 15. – 26. tahmin edilen vektörler IMV kullanılarak hesaplanır. Bu nedenle, oylanan tahmin vektörleri olarak adlandırılırlar. Önerinin kanal bazında sınıflandırma doğruluklarını daha iyi tartışmak için, Şekil 7.3 doğrulukları konumlarla birlikte göstermektedir.



Şekil 7.3. 10 katlı CV ile kNN sınıflandırıcıyı kullanan kanal konumlarına göre modelin kanal bazında sınıflandırma doğrulukları (%)

Sonuçları vurgulamak için üç renk kullanıldı. Sonuçları %93'e eşit ve üzerinde vurgulamak için kırmızı ve %90'dan %93'e kadar sınıflandırma doğruluklarını göstermek için siyah yazı tipi rengi kullanıldı. %90'dan daha düşük doğrulukları göstermek için mavi yazı tipi rengi kullanılmıştır.

Şekil 7.3, kullanılan cümlelerin sınıflandırma haritasını göstermektedir. Yalnızca kırmızı kanallar (AF3, AF4, F7, P8, O2) ve çoğunluk oylaması kullanılarak önerilen model %98,75 sınıflandırma doğruluğuna ulaşmıştır. Bu harita kullanılarak beynin cümle oluşturma/düşünme eylemi hakkında bilgi çıkarılabilir.

Sunulan SSG tabanlı EEG cümle sınıflandırma modelinin önemli nitelikleri/özellikleri şunlardır:

- Bu araştırmada EEG işaretlerini kullanarak cümle sınıflandırma/tahmin problemi tanımlanmış ve bu problem EEG cümle sınıflandırması olarak adlandırılmıştır.
- Kare toplamı bir problem kullanılarak graf tabanlı yeni bir öznetelik çıkarma işlevi önerilmiştir.
- Önerilen mimari 26 sonucu hesapladığından ve en iyi sonuç tahmin vektörünü otomatik olarak seçtiğinden, önerilen SSG öznetelik çıkarımı kullanılarak kendi kendini organize eden bir öğrenme mimarisi önerilmiştir.
- Önerilen öğrenme mimarisi, elle modellenen bir öğrenme yöntemidir. Burada hem dokusal (SSG kullanılarak) hem de istatistiksel özellikler çıkarılmıştır. TQWT kullanılarak frekans alt bantları oluşturulmuştur. Bu alt bantlar kullanılarak hem düşük hem de yüksek seviyelerde hibrit el yapımı özellikler çıkarılmıştır. Ayrıca, hem uzay alanından (ham EEG sinyali kullanılarak) hem de frekans alanından (TQWT kullanılarak) özellikler çıkarılmıştır.


- Özellikleri seçmek için basit bir özellik seçici (NCA) kullanılmıştır. kNN (genel olarak bilinen bir sığ sınıflandırıcıdır), sunulan SSG tabanlı çok düzeyli ve hibrit özellik çıkarıcının gücünü göstermek için kullanılmıştır. Burada NCA ve kNN kombinasyonunun etkinliğinden faydalanılmıştır.
- Kanal bazında sınıflandırma doğruluklarını sunulmuştur ve en iyi sonuçlar (%93'ün üzerinde elde ettiler) O2, F7, AF4, P8 ve AF3 kanallarına aittir. Bu alanlar beyindeki cümle oluşumu hakkında ipucu verir. Beyin cümlesi oluşturma/düşünme yapısı bu tür araştırmalar kullanılarak modellenabilir. Ayrıca, en kötü doğru kanallar FC5 ve P7'dir, çünkü bu kanallar %80'den daha düşük sınıflandırma doğruluğuna ulaşmıştır.
- IMV algoritması kullanılarak 12 oylanan tahmin vektörü oluşturuldu ve bu oylanan sonuçların tümü %97'nin üzerinde sınıflandırma doğruluğuna sahiptir.
- Önerilen SSG tabanlı modelin hesaplanan nihai sonucu %99,19'dur (sadece 11 yanlış sınıflandırılmış EEG gözlemidir).
- Önerilen model, 14 sınıfta %100 sınıf bazında sınıflandırma doğruluğuna (geri çağırma) ulaşmıştır.
- Önerilen mimari çok basit ve parametrik. Herhangi bir araştırmacı bu modeli kendi sinyal sınıflandırma problemine uygulayabilir ve bu mimari kullanılarak birçok model önerilebilir (bkz. Tablo 6.1).
- Elle modellenmiş tek boyutlu bir sinyal sınıflandırma mimarisi sunulmuştur. Yüksek sınıflandırma performansını hesaplamak için, derin öğrenme ağları kullanılmıştır.

7.2. DSBP Tabanlı EEG Cümle Tanıma Modeli

Bu çalışmada, sırasıyla okuma-gösterme ve dinleme modlarında gösterilen ana dillerinde standartlaştırılmış yirmi Türkçe cümle 40 gönüllüden oluşan iki farklı katılımcı grubundan elde edilen ileriye dönük bir EEG veri seti olan TSEEG kullanılarak bir EEG cümle sınıflandırma modeli geliştirilmiştir. İki farklı modun incelenmesi ve gösteri ve dinleme modları için ayrı gönüllü gruplarının kullanılması, deney düzeneğinde temel hususlardır. Beyindeki görsel ve işitsel nöral yollar farklıdır. Cümle tanıma ve indüklenen EEG sinyallerini işlemeleri farklı olacaktır. Yeni DSBP ve IMCMV yöntemlerini kullanan yeni bir hafif sınıflandırma modeli, doğru bir EEG cümle sınıflandırma sistemi geliştirmek için TSEEG veri seti üzerinde eğitildi ve test edildi. Yerel dokusal özellikleri ve düşük seviyeli istatistiksel özellikleri çıkarmak için DSBP ve istatistiksel özellik çıkarıcılar konuşlandırıldı. Bununla birlikte, MDWT, EEG sinyallerini düşük ve yüksek geçişli alt bantlara ayırır. Bu nedenle, çoklu seviyelerde üretilen hem düşük hem de yüksek seviyeli özellikler olan DSBP ve istatistiksel özellik çıkarıcıları besler. Giriş EEG segmenti başına 5.400 özellik üretildi ve en iyi 512 özelliği seçmek için NCA seçici kullanıldı. Sınıflandırma aşamasında, EEG sinyal kanalı başına iki tahmin vektörü oluşturmak için kNN ve SVM sınıflandırıcıları

kullanıldı. Gösteri modunda, kanal bazında en iyi sonuçlar, beyindeki oksipital loblardan birinin yakınında yüzey EEG sinyallerini toplayan Kanal 8'den (O2) elde edildi. Bu gözlem, çalışma deneylerinin gösteri modunda bir bilgisayar terminal ekranında katılımcılara gösterilen cümlelerle örneklendiği gibi, görsel bilgilerin işlenmesinde oksipital lobların temel rolünü desteklemektedir. Buna karşılık, dinleme modunda kanal bazında sonuçlar farklıdır ve en iyi performans sırasıyla kNN ve SVM sınıflandırıcılarla Kanal 7 (O1) ve 10'da (T8) gözlemlenmiştir. Temporal lob işitsel yönetimde kritik bir role sahiptir ve oksipital lob beyin görsel sistemini yönetir.

Bu tez çalışmasında, dinleme ve gösterme yoluyla EEG sinyalleri toplanmıştır. Ayrıca katılımcılardan sadece ekranda görüntülenen cümleyi düşünmeleri istenildi. Bu sayede veri toplama aşamasında bu loblar aktif hale getirildi ve en iyi sonuçlar 7,8 ve 10 numaralı kanallardan alındı. Her EEG kaydı 14 kanal içerdiğinden, TSEEG veri setinden 1.600 EEG kayıt örneğinin her biri için 28 tahmin vektörü üretildi. Oylanan sonuçları hesaplamak ve bireysel EEG kayıtlarının tüm kanalları arasından en iyi genel sonuçları seçmek için IMCMV kullanıldı. IMCMV kullanılarak en iyi genel doğruluk, hatırlama, kesinlik ve F1 puanı, gösteri modunda 28 tahmin vektörü ile sırasıyla %98,81, %98,81, %98,88 ve %98,84 olarak; ve dinleme modunda 15 tahmin vektörü ile sırasıyla %98,19, %98,19, %98,28 ve %98,23 olarak bulundu. Deneylerde yaygın olarak kullanılan 20 Türkçe cümle rastgele seçilmiş ve tüm cümlelerin modeli eğitmek ve test etmek için uygun olduğu önceden tespit edilememiştir. Buna göre, deneylerde kullanılan tüm sınıflar (Türkçe cümleler) için minimum tatmin edici performansı belirlemek için modelin sınıf bazında sınıflandırma sonuçlarının değerlendirilmesi esastır. Veri kümesindeki 1.600 kayıt örneğinin tamamının sınıf bazında doğruluk oranları mükemmeldir (Şekil 7.5). On iki ve dokuz sınıf, sırasıyla gösteri ve dinleme modlarında sınıf bazında %100 doğruluk oranlarına ulaştı. En kötü doğruluk oranları, sırasıyla gösteri ve dinleme modlarında 9. Sınıfta (%90) ve 3. Sınıfta (%85) gözlemlendi. Ayrıca karışıklık matrislerinin bulguları (Şekil 6.4 ve 7.4) bu durumu göstermektedir.



Şekil 7.4. Dinleme modunda alınan TSEEG sinyalleri için oylanan sonuçların karışıklık matrisi

Numaralandırılmış her gerçek sınıf, Tablo 4.1'de listelenen numaralandırılmış Türkçe cümleye karşılık gelir. Ancak, bu sonuçlar çalışma deneyleri için tatmin edici olarak kabul edilebilir. Karşılaştırmalı sonuçlar elde etmek için, gösteri ve dinleme veri kümeleri için en doğru kanallar seçilmiştir. Gösterim tabanlı EEG veri kümesi için en doğru kanal 8. kanaldır ve 7. kanal dinleme tabanlı EEG veri kümesi için en iyisidir. Böylece bu kanallar üzerinde testler uygulanmıştır.

Karşılaştırmalar için kullanılan modeller şunlardır: (i) istatistik, (ii) yerel ikili model, (iii) üçlü model, (iv) Hamsi modeli ve (v) Twine-shuffle modeli [22]

Tablo 7.1. Farklı metotların kanal bazlı doğruluklarının karşılaştırılması

Metot	Gösteri tabanlı EEG veriseti (Kanal 8)	Dinleme tabanlı EEG veriseti (Kanal 7)
İstatistik	85.34	78
Yerel ikili model	50.70	54.13
Üçlü model	51.99	53.98
Hamsi modeli	71.76	75.98

Twine-shuffle modeli	73.01	80.97
Önerilen model	94.69	95.25

Hesaplanan sınıflandırma doğrulukları Tablo 7.1'de listelenmiştir. Tablo 7.1'den görüldüğü gibi, önerilen model, bu modeller arasında en iyi sınıflandırma doğruluğunu elde etmiş ve önerilen DSBP-IMCMV tabanlı EEG sınıflandırma modelinin üstünlüğünü göstermiştir. Ayrıca Tablo 7.1, çok düzeyli ve hibrit öznitelik çıkarımının sınıflandırma performansını artırdığını vurgulamıştır. Önerilen modelin avantajları ve sınırlamaları aşağıda listelenmiştir.


Avantajlar:

- Ayrı gönüllü gruplarında, modeli geliştirmek için iki modda (gösterme ve dinleme) ileriye dönük olarak yeni bir EEG cümle veri seti elde edildi.
- Tek boyutlu yerel ikili modelin [63] geliştirilmiş bir versiyonu olan DSBP, MDWT tarafından ayrıştırılan EEG sinyallerinin alt bantlarından yüksek seviyeli özellikler dahil olmak üzere dokusal özellikleri çıkarmak için konuşlandırıldı.
- Yeni bir oylama modeli olan IMCMV, çoklu sınıflandırıcılardan ve çoklu EEG sinyal kanallarından en iyi genel sonuçları, artan sayıda hesaplanmış tahmin vektörü kullanılarak yinelemeli olarak oylanmış sonuçlardan seçmek için önerildi.
- Önerilen DSBP-IMCMV tabanlı model basit ve sağlamdır.
- Model, hem gösterim hem de dinleme modları için TSEEG veri setini kullanarak tek boyutlu EEG sinyalleri için %98'in üzerinde sınıflandırma doğruluğu oranlarına ulaşmıştır.

Bu nedenle, modelin diğer tek boyutlu sinyalleri sınıflandırmak için de kullanılması beklenmektedir.

Sınırlamalar:

- TSEEG veri seti, gönüllülerin anadili olan yirmi Türkçe cümleden oluşmaktadır. Bu nedenle, deneylerin diğer dillerde toplanan cümleler kullanılarak çoğaltılması gerekebilir.
- Modelde kullanılan kNN ve SVM sınıflandırıcıları için önceden belirlenmiş hiperparametre ayarları kullanılmıştır. Bu hiperparametreler, sınıflandırma sonuçlarını optimize etmek için daha da geliştirilebilir.



Şekil 7.5. Veri setindeki yirmi sınıfın (Türkçe cümlelerin) deney modundaki doğruluğu

8. SONUÇLAR

EEG sinyalleri kullanarak insan fizyolojisinde çalışmalar yapılması ve bu alandaki ilerlemeler araştırmacılar tarafından en çok tercih edilen konulardan biri olmuştur. Araştırmacılar farklı koşullar içerisinde çalışmalarına en uygun çözümleri üretmeye devam etmektedirler. Bu tez çalışmasında yeni bir EEG tabanlı sınıflandırma problemi tanımlanmıştır ve bu sınıflandırma problemi EEG cümle sınıflandırmasıdır. EEG cümle sınıflandırmasının temel amacı telepatik iletişimi sağlamaktır. Bu nedenle katılımcılara cümleler gösterilerek bir EEG cümle veri seti toplanmıştır. Bu veri seti 20 sınıfa ait 1600 EEG sinyali içermektedir (20 cümle kullanılmıştır). Bu cümleleri otomatik olarak sınıflandırmak için iki farklı model önerilmiştir:

- Önerilen SSG modeli kullanılarak, kendi kendini organize eden bir sinyal sınıflandırma mimarisi önerilmiştir. Önerilen mimari, toplanan EEG cümle veri setinde %99,19 sınıflandırma doğruluğu elde etmiştir. Ayrıca kanal bazında oylama ve sınıf bazında sonuçlar bu çalışmada gösterilmiştir. Hesaplanan sonuçlar ve bulgular, önerilen modelin doğrusal karmaşıklık ile yüksek sınıflandırma doğruluğuna ulaştığını açıkça göstermiştir.
- Önerilen DSBP tabanlı EEG cümle tanıma modeli, TSEEG veri seti ile gösterme ve dinleme modlarında sırasıyla %98.81 ve %98.19 genel doğruluk oranlarına ulaşmıştır. Bu olumlu sonuçlar, önerilen DSBP-IMCMV tabanlı EEG sinyal sınıflandırma modelinin beyin bilgisayar arayüzü uygulamalarında cümle sınıflandırması için uygulanabileceğini göstermektedir. Ayrıca, modelin DSBP tabanlı öznitelik mühendisliği ve IMCMV tabanlı oylanan sonuç üretimi oldukça çok yönlüdür ve diğer fizyolojik sinyallerin sınıflandırılmasına uygulanabilir.

Bu çalışma, beyin bilgisayar etkileşiminin yakın gelecekte daha fazla cümle sınıfı ve daha sağlam EEG sinyal toplama/beyin görüntüleme cihazları kullanılarak uygulanabileceğini göstermektedir. Bunun yanı sıra EEG cümle sınıflandırma konusunda yapılan en sistematik çalışmalar bu tez kapsamında sunulmuştur.

KAYNAKLAR

- [1] Anılan, H. (2015). Yazılı anlatım becerilerinin geliştirilmesinde kelime ağı oluşturma yönteminin etkililiği: Anadolu University (Turkey).
- [2] Kumar, P.; Saini, R.; Roy, PP.; Sahu, PK.; Dogra, DP. (2018). Envisioned speech recognition using EEG sensors, *Personal and Ubiquitous Computing*, C. 22, 185-99.
- [3] Brigham, K.; Kumar, BV. (2010). Imagined speech classification with EEG signals for silent communication: a preliminary investigation into synthetic telepathy. 2010 4th International Conference on Bioinformatics and Biomedical Engineering: IEEE; p. 1-4.
- [4] Wang, K-J.; Zheng, CY.; Shidujaman, M.; Wairagkar, M.; von Mohr, M. (2020) Jean Joseph v2. 0 (REmotion): Make Remote Emotion Touchable, Seeable and Thinkable by Direct Brain-to-Brain Telepathy Neurohaptic Interface Empowered by Generative Adversarial Network. 2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC): IEEE; p. 3488-93.
- [5] Bulut, C. (2018). Beyin bilgisayar arayüzü uygulamaları için eeg sinyal analizi: Altınbaş Üniversitesi.
- [6] Omar, SQO.; Cengiz, T. (2022). EEG Sinyallerini İşlemek İçin Makine Öğreniminin Kullanıldığı Konular Üzerine Bir İnceleme. *Bayburt Üniversitesi Fen Bilimleri Dergisi*, C. 5, 124-37.
- [7] Panachakel, JT.; Ramakrishnan, AG. (2021). Decoding covert speech from EEG-a comprehensive review. *Frontiers in Neuroscience*.
- [8] Kumar, JS.; Bhuvaneswari, P. (2012). Analysis of Electroencephalography (EEG) signals and its categorization—a study. *Procedia engineering*, C. 38, 2525-36.
- [9] da Silva, FL. (2013). EEG and MEG: relevance to neuroscience. *Neuron*. C. 80, 1112-28.
- [10] Rodriguez-Bermudez, G.; Garcia-Laencina, PJ. (2015). Analysis of EEG signals using nonlinear dynamics and chaos: a review. *Applied mathematics & information sciences*. 9:2309.
- [11] Barua, PD.; Keles, T.; Dogan, S.; Baygin, M.; Tuncer, T.; Demir, CF. (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*. 79:104055.
- [12] Birbaumer, N.; Kubler, A.; Ghanayim, N.; Hinterberger, T.; Perelmouter, J.; Kaiser, J. et al. (2000). The thought translation device (TTD) for completely paralyzed patients. *IEEE Transactions on rehabilitation Engineering*. 8:190-3.
- [13] Lotte, F.; Bougrain, L.; Clerc, M. (2015). *Electroencephalography (EEG)-based brain-computer interfaces*. Wiley
- [14] Baygin, M.; Tuncer, T.; Dogan, S. (2022). New pyramidal hybrid textural and deep features based automatic skin cancer classification model: Ensemble DarkNet and textural feature extractor. *arXiv preprint arXiv:220315090*.
- [15] Karadal, CH.; Kaya, MC.; Tuncer, T.; Dogan, S.; Acharya, UR. (2021). Automated classification of remote sensing images using multileveled MobileNetV2 and DWT techniques. *Expert Systems with Applications*. 185:115659.
- [16] Baygin, M.; Yaman, O.; Tuncer, T.; Dogan, S.; Barua, PD.; Acharya, UR. (2021). Automated accurate schizophrenia detection system using Collatz pattern technique with EEG signals. *Biomedical Signal Processing and Control*. 70:102936.

- [17] Tuncer, T. (2021). A new stable nonlinear textural feature extraction method based EEG signal classification method using substitution Box of the Hamsi hash function: Hamsi pattern. *Applied Acoustics*. 172:107607.
- [18] Selesnick, IW. (2011). Wavelet transform with tunable Q-factor. *IEEE transactions on signal processing*. 59:3560-75.
- [19] Goldberger, J.; Hinton, GE.; Roweis, S.; Salakhutdinov, RR. (2004). Neighbourhood components analysis. *Advances in neural information processing systems*. C. 17.
- [20] Peterson, LE. (2009). K-nearest neighbor. *Scholarpedia*. 4:1883.
- [21] Dogan, A.; Akay, M.; Barua, PD.; Baygin, M.; Dogan, S.; Tuncer, T. et al. (2021). PrimePatNet87: Prime pattern and tunable q-factor wavelet transform techniques for automated accurate EEG emotion recognition. *Computers in Biology and Medicine*. 138:104867.
- [22] Tuncer, T.; Dogan, S.; Pławiak, P.; Acharya, UR. (2019). Automated arrhythmia detection using novel hexadecimal local pattern and multilevel wavelet transform with ECG signals. *Knowledge-Based Systems*. 186:104923.
- [23] Polat, H.; Özerdem, MS. (2016). Görsel-işitsel uyaranlar kaynaklı oluşan duyguların EEG işaretleri ile sınıflandırılması. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*. 7:33-40.
- [24] Ropper, AH.; MA, S. (2009). *Adams and Victor's Principles of Neurology*, 2009. McGraw Hill. New York.
- [25] Öztürk, H. (2016). EEG sinyallerinde farklı boyut indirgeme ve sınıflandırma yöntemlerinin karşılaştırılması, Yüksek Lisans Tezi, Adnan Menderes Üniversitesi, Sağlık Bilimleri Enstitüsü.
- [26] DaSalla, CS.; Kambara, H.; Sato, M.; Koike, Y. (2009). Single-trial classification of vowel speech imagery using common spatial patterns. *Neural networks*. 22:1334-9.
- [27] García ,AAT.; García, CAR.; Pineda, LV. (2012). Toward a Silent Speech Interface based on Unspoken Speech. *Biosignals*. p. 370-3.
- [28] Min, B.; Kim, J.; Park, H-j.; Lee, B. (2016). Vowel imagery decoding toward silent speech BCI using extreme learning machine with electroencephalogram. *BioMed research international*.
- [29] Qureshi, MNI.; Min, B.; Park, H-j; Cho, D.; Choi, W.; Lee, B. (2017). Multiclass classification of word imagination speech with hybrid connectivity features. *IEEE Transactions on Biomedical Engineering*. 65:2168-77.
- [30] Balaji, A.; Haldar, A.; Patil, K.; Ruthvik, TS.; Valliappan, C.; Jartarkar, M.; et al. (2017). EEG-based classification of bilingual unspoken speech using ANN. 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC): IEEE; p. 1022-5.
- [31] Cooney, C.; Folli, R.; Coyle, D.; (2018) Mel frequency cepstral coefficients enhance imagined speech decoding accuracy from EEG. 2018 29th Irish Signals and Systems Conference (ISSC): IEEE; p. 1-7.
- [32] Tøttrup, L.; Leerskov, K.; Hadsund, JT.; Kamavuako, EN.; Kæseler, RL.; Jochumsen, M. (2019). Decoding covert speech for intuitive control of brain-computer interfaces based on single-trial EEG: a feasibility study. 2019 IEEE 16th International Conference on Rehabilitation Robotics (ICORR): IEEE; p. 689-93.

- [33] Jahangiri, A.; Achanccaray, D.; Sepulveda, F. (2019). A novel EEG-based four-class linguistic BCI. 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC): IEEE, p. 3050-3.
- [34] Pawar, D.; Dhage, S. (2020). Multiclass covert speech classification using extreme learning machine. *Biomedical Engineering Letters*. 10:217-26.
- [35] Cooney, C.; Korik, A.; Folli, R.; Coyle, D. (2020). Evaluation of hyperparameter optimization in machine and deep learning methods for decoding imagined speech EEG. *Sensors*. 20:4629.
- [36] Bakhshali, MA.; Khademi, M.; Ebrahimi-Moghadam, A. (2022). Investigating the neural correlates of imagined speech: An EEG-based connectivity analysis. *Digital Signal Processing*. 123:103435.
- [37] Dash, S.; Tripathy, RK.; Panda, G.; Pachori, RB. (2022). Automated recognition of imagined commands from EEG signals using multivariate fast and adaptive empirical mode decomposition based method. *IEEE Sensors Letters*. C. 6, 1-4.
- [38] Kamble, A.; Ghare, P.; Kumar, V. (2022). Machine-learning-enabled adaptive signal decomposition for a brain-computer interface using EEG. *Biomedical Signal Processing and Control*. 74:103526.
- [39] Bakhshali, MA.; Khademi, M.; Ebrahimi-Moghadam, A.; Moghimi, S. (2020). EEG signal classification of imagined speech based on Riemannian distance of correntropy spectral density. *Biomedical Signal Processing and Control*. 59:101899.
- [40] Tamm, M-O.; Muhammad, Y.; Muhammad, N. (2020.) Classification of vowels from imagined speech with convolutional neural networks. *Computers*. 9:46.
- [41] García-Salinas, JS.; Villaseñor-Pineda, L.; Reyes-García, CA.; Torres-García, AA. (2019). Transfer learning in imagined speech EEG-based BCIs. *Biomedical Signal Processing and Control*. 50:151-7.
- [42] Panachakel, JT.; Ramakrishnan, A.; Ananthapadmanabha, T. (2020). A novel deep learning architecture for decoding imagined speech from EEG. *arXiv preprint arXiv:200309374*.
- [43] Panachakel, JT.; Ramakrishnan, A.; Ananthapadmanabha, T. (2019). Decoding imagined speech using wavelet features and deep neural networks. 2019 IEEE 16th India Council International Conference (INDICON): IEEE; p. 1-4.
- [44] Cooney, C.; Korik, A.; Raffaella, F.; Coyle, D. (2019). Classification of imagined spoken word-pairs using convolutional neural networks. *The 8th Graz BCI Conference, 2019: Verlag der Technischen Universität Graz*; p. 338-43.
- [45] Goshvarpour, A. (2022). A novel 2-piece rose spiral curve model: Application in epileptic EEG classification. *Computers in Biology and Medicine*. 142:105240.
- [46] Buriro, AB.; Ahmed, B.; Baloch, G.; Ahmed, J.; Shoorangiz, R.; Weddell, SJ. et al.(2021). Classification of alcoholic EEG signals using wavelet scattering transform-based features. *Computers in Biology and Medicine*. 139:104969.
- [47] Norizadeh, M.; Kashefi, H.; Daliri, MR. (2021). Ensemble Regularized Common Spatio-Spectral Pattern (ensemble RCSSP) model for motor imagery-based EEG signal classification.
- [48] Wen, Y.; Zhang, Y.; Wen, L.; Cao, H.; Ai, G.; Gu, M. et al. (2022). A 65nm/0.448 mW EEG processor with parallel architecture SVM and lifting wavelet transform for high-performance and low-power epilepsy detection. *Computers in Biology and Medicine*. 144:105366.

- [49] Wang, J.; Feng, Z.; Lu, N.; Luo, J. (2018). Toward optimal feature and time segment selection by divergence method for EEG signals classification. *Computers in biology and medicine*. 97:161-70.
- [50] Aydemir, E.; Tuncer, T.; Dogan, S. (2020). A Tunable-Q wavelet transform and quadruple symmetric pattern based EEG signal classification method. *Medical hypotheses*. 134:109519.
- [51] Tuncer, T.; Dogan, S.; Akbal, E. (2019) A novel local senary pattern based epilepsy diagnosis system using EEG signals. *Australasian Physical & Engineering Sciences in Medicine*. 42:939-48.
- [52] Subasi, A.; Tuncer, T.; Dogan, S.; Tanko, D.; Sakoglu, U. (2021). EEG-based emotion recognition using tunable Q wavelet transform and rotation forest ensemble classifier. *Biomedical Signal Processing and Control*. 68:102648.
- [53] Kaya, Y.; Uyar, M.; Tekin, R.; Yıldırım, S. (2014). 1D-local binary pattern based feature extraction for classification of epileptic EEG signals. *Applied Mathematics and Computation*. 243:209-19.
- [54] Kuncan, F.; Kaya, Y.; Kuncan, M. (2019). New approaches based on local binary patterns for gender identification from sensor signals. *Journal of the Faculty of Engineering and Architecture of Gazi University*. 34:2173-85.
- [55] Fang, S-H.; Chang, W-H.; Tsao, Y.; Shih, H-C.; Wang, C. (2016). Channel state reconstruction using multilevel discrete wavelet transform for improved fingerprinting-based indoor localization. *IEEE Sensors Journal*. 16:7784-91.
- [56] Raghu, S.; Sriraam, N. (2018). Classification of focal and non-focal EEG signals using neighborhood component analysis and machine learning algorithms. *Expert Systems with Applications*. 113:18-32.
- [57] HosseinAbadi, HZ.; Amirfattahi, R.; Nazari, B.; Mirdamadi, HR.; Atashipour, SA. (2014). GUW-based structural damage detection using WPT statistical features and multiclass SVM. *Applied acoustics*. 86:59-70.
- [58] Sudarshan, VK.; Acharya, UR.; Oh, SL.; Adam, M.; Tan, JH.; Chua, CK. et al. (2017). Automated diagnosis of congestive heart failure using dual tree complex wavelet transform and statistical features extracted from 2 s of ECG signals. *Computers in biology and medicine*. 83:48-58.
- [59] Baygin, M.; Barua, PD.; Dogan, S.; Tuncer, T.; Key, S.; Acharya, UR. et al. (2022). A Hand-Modeled Feature Extraction-Based Learning Network to Detect Grasps Using sEMG Signal. *Sensors*. 22:2007.
- [60] Noble, WS. (2006). What is a support vector machine? *Nature biotechnology*. 24:1565-7.
- [61] Powers, DM. (2020). Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. *arXiv preprint arXiv:201016061*.
- [62] Chicco, D.; Jurman, G. (2020). The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC genomics*. 21:1-13.
- [63] Pawar, D.; Dhage, S. (2023). EEG-based covert speech decoding using random rotation extreme learning machine ensemble for intuitive BCI communication. *Biomedical Signal Processing and Control*. 80:104379.

ÖZGEÇMİŞ

Tuğçe KELEŞ

AKADEMİK FAALİYETLER

Makaleler:

1. Barua, P. D., Keles, T., Dogan, S., Baygin, M., Tuncer, T., Demir, C. F., ... & Acharya, U. R. (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, 104055.

Projeler:

1. EEG Sinyallerinin Tercüme Edilmesi için Kimyasal Yapıların Çizgeleri Tabanlı Yeni Nesil Öğrenme Modellerinin Oluşturulması, 1002-A – TÜBİTAK Hızlı Destek Projesi, Proje Numarası: 121E399, 01/12/2021- 01/12/2022