



**T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



YÜKSEK LİSANS TEZİ

**ALGIYA İLİŞKİN KARARLARDAKİ ÖZNEL GÜVEN DÜZEYİNİN
EEG SİNYALLERİ KULLANILARAK SINIFLANDIRILMASI**

Gülay ERDOĞAN

**DANIŞMAN
Prof. Dr. Aydın AKAN**

Biyomedikal Mühendisliği Anabilim Dalı


Biyomedikal Mühendisliği Programı

İSTANBUL-2019

Bu çalışma, 9.07.2019 tarihinde aşağıdaki jüri tarafından Biyomedikal Mühendisliği Anabilim Dalı, Biyomedikal Mühendisliği Programında Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi


Prof. Dr. Aydın AKAN(Danışman)
İzmir Katip Çelebi Üniversitesi
Mühendislik Fakültesi


Dr. Öğr. Üyesi Mahmut ÖZTÜRK
İstanbul Üniversite-Cerrahpaşa
Mühendislik Fakültesi

Dr. Öğr. Üyesi Ezgi TUNA ERDOĞAN
İstinye Üniversite
Tıp Fakülte



20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi-Cerrahpaşa’nın abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

.

ÖNSÖZ

Bu çalışmamda kişinin kararıyla ilgili öznel değerlendirmeleri esnasında elde edilen EEG sinyalleri belli sınıflandırma algoritmaları kullanılarak birbirlerinden ayrılmaya çalışılmıştır. Benimle EEG verilerini paylaşan sevgili Prof. Dr. Tamer Demiralp'e ve desteğini hiçbir zaman esirgemeyen sevgili eşim Basri Erdoğan'a çok teşekkür ederim. Beni destekleyen, nezaketi ve bilgisiyle her zaman yanımda olan tez danışmanım sayın Prof. Dr. Aydın Akan'a sonsuz teşekkürlerimi sunarım.

Temmuz 2019

Gülay ERDOĞAN



İÇİNDEKİLER

ÖNSÖZ	iv
İÇİNDEKİLER.....	v
ŞEKİL LİSTESİ	vii
TABLO LİSTESİ.....	viii
SİMGE VE KISALTMA LİSTESİ.....	ix
ÖZET	x
SUMMARY	xii
1.GİRİŞ ve AMAÇ.....	1
1.1 BEYİN BİLGİSAYAR ARAYÜZÜ	2
1.2 KARAR VERME SÜREÇLERİNİN EEG KORELATLARI	2
2. GENEL KISIMLAR	4
2.1. ELEKTROENSEFALOGRAFİ	4
2.2 SİNYAL İŞLEME VE ÖZNİTELİK ÇIKARMA	5
2.2.1 Görgül Kip Ayrışımı.....	5
2.2.2 Sürekli Dalgacık Dönüşümü.....	6
2.2.3 Merkezi Momentler	7
2.3 MAKİNE ÖĞRENMESİ VE SINIFLANDIRMA.....	8
2.3.1 Destek Vektör Makineleri	9
2.3.1.1 Doğrusal Destek Vektör Makineleri	9
2.3.1.2 Doğrusal Olmayan Destek Vektör Makineleri	10
2.3.2 k-En Yakın Komşuluk.....	11
2.3.3 Rastgele Orman	11
2.3.4 Lojistik Bağlanım	12
2.3.5 Dengesiz Veri Seti İçin Örnek Arttırma veya Örnek Azaltma	12
2.3.6 k - Katlı Çapraz Doğrulama	13
3. MALZEME VE YÖNTEM	14
3.1 EEG KAYIT SİSTEMİ.....	14
3.2 EEG KAYIT PARADİGMASI.....	15
3.3 EEG ÖN İŞLEME	16
3.4 ÖZNİTELİK ÇIKARMA.....	17

3.4.1 Uyarana Kilitli Veri Seti.....	17
3.4.1.1 Öz Kip Fonksiyonlarından Zaman Alanında Öznitelik Çıkarılması.....	17
3.4.1.2 Öz Kip Fonksiyonlarından Frekans Alanında Öznitelik Çıkarılması.....	18
3.4.1.3 Öz Kip Fonksiyonlarından İstatistiksel Moment Öznitelik Çıkarılması.....	18
3.4.1.4 Dalgacık Dönüşümü	18
3.4.2 Yanıtla Kilitli Veri Seti.....	19
3.4.2.1 Öz Kip Fonksiyonlarından Zaman Alanında Öznitelik Çıkarılması.....	19
3.4.2.2 Öz Kip Fonksiyonlarından Frekans Alanında Öznitelik Çıkarılması.....	19
3.4.2.3 Öz Kip Fonksiyonlarından İstatistiksel Moment Öznitelik Çıkarılması	20
3.4.2.4 Dalgacık Dönüşümü	20
3.5 SINIFLANDIRMA	20
3.5.1 Algoritma Seçimi.....	20
3.5.2 10-kat Çapraz-Doğrulama	21
3.5.3 Normalizasyon.....	21
3.5.4 Veri Seti Dengeleme.....	22
3.5.4.1 Örnek artırma	22
3.5.4.2 Örnek azaltma.....	22
4. BULGULAR	24
4.1 SINIFLANDIRMA ALGORİTMASININ SEÇİLMESİ.....	24
4.2 EEG VERİLERİNİN GAUSS DVM KULLANILARAK SINIFLANDIRILMASI.....	24
4.2.1 Uyarana Kilitli EEG Dilimlerinin Sınıflandırılması.....	25
4.2.2 Yanıtla Kilitli EEG Dilimlerinin Sınıflandırılması	30
4.3 ÜST-DEĞİŞKEN ENİYİLEMESİ.....	35
5. TARTIŞMA VE SONUÇ	38
KAYNAKLAR.....	41
EKLER	43
ÖZGEÇMİŞ	45

ŞEKİL LİSTESİ

Şekil 2.1: EEG elektrot yerleşimi (10-20 sistemi).....	5
Şekil 2.2: DVM sınıflandırıcı yapısı. Destek vektörleri daire içine alınmıştır.	9
Şekil 3.1: Oddball daire paradigması.....	15
Şekil 3.2: GKA kullanılarak elde edilmiş ÖKF'lere örnek	18
Şekil 3.3: Tek dilimlik EEG'nin Dalgacık Dönüşümü.....	19
Şekil 4.1: Uyarana kilitli durumda DD sınıflandırma başarımının sınıflandırma matrisinde gösterimi	27
Şekil 4.2: DE-YE sınıflandırıcısı için alıcı işletim karakteristiği eğrileri.....	28
Şekil 4.3: YE-ED sınıflandırıcısı için alıcı işletim karakteristiği eğrileri.....	29
Şekil 4.4: DE-ED sınıflandırıcısı için alıcı işletim karakteristiği eğrileri (ROC).....	29
Şekil 4.5: Yanıt kilitli durumda DD sınıflandırma başarımının sınıflandırma matrisinde gösterimi..	32
Şekil 4.6: 4 öznitelik için DE-YE ROC eğrileri.	33
Şekil 4.7: 4 öznitelik için YE-ED ROC eğrileri.	34
Şekil 4.8: DE-ED ROC eğrileri.	34
Şekil 4.9: DE-YE için üst değişken parametrelerine göre sınıflandırma başarımı yüzeyi.....	36
Şekil 4.10: YE-ED için üst değişken parametrelerine göre sınıflandırma başarımı yüzeyi.....	36
Şekil 4.11: DE-ED için üst değişken parametrelerine göre sınıflandırma başarımı yüzeyi.....	36
Şekil 4.12: DE-YE-ED için üst değişken parametrelerine göre sınıflandırma başarımı yüzeyi.	37

TABLO LİSTESİ

Tablo 3.1: Katılımcılara göre her bir duruma ait EEG dilim sayısı	17
Tablo 4.1: DE, YE ve ED sınıfı verilerinin 6 farklı sınıflandırma algoritması ile sınıflandırılması	24
Tablo 4.2: GKA ve DD temelli öznelikler için % cinsinden sınıflandırma başarımı.....	25
Tablo 4.3: DE-YE eğri altında kalan alan (AUC) değerleri.....	28
Tablo 4.4: YE-ED durumu için AUC değerleri.....	29
Tablo 4.5: DE-ED AUC değerleri.....	30
Tablo 4.6: Yanıtla kilitli dilimlerde % cinsinden sınıflandırma başarımı	30
Tablo 4.7: DE-YE AUC değerleri.....	33
Tablo 4.8: YE-ED AUC değerleri.....	34
Tablo 4.9: DE-ED AUC değerleri.....	35
Tablo 4.10: Üst değişken eniyilemesi sonucunda elde edilen üst değişken değerleri.....	35

SİMGE VE KISALTIMA LİSTESİ

Kisaltmalar	Açıklama
AUC	: Eğri Altında Kalan Alan (Area Under Curve)
BBA	: Beyin-Bilgisayar Arayüzü
DD	: Dalgacık Dönüşümü
DVM	: Destek Vektör Makinesi
DE	: Doğru Emin
ED	: Emin Değil
EEG	: Elektroensefalografi
EOG	: Elektrokülogram
GKA	: Görgül Kip Ayrışımı
kNN	: k-en yakın komşuluk
OİP	: Olaya İlişkin Potansiyel
OİS	: Olaya İlişkin Salınım
ÖKF	: Öz Kip Fonksiyonu
ROC	: Alıcı İşletim Karakteristiği (Receiver Operating Characteristic)
YE	: Yanlış Emin

ÖZET

ALGIYA İLİŞKİN KARARLARDAKİ ÖZNEL GÜVEN DÜZEYİNİN EEG SİNYALLERİ KULLANILARAK SINIFLANDIRILMASI

YÜKSEK LİSANS TEZİ

Gülay ERDOĞAN

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Aydın AKAN

Beyin bilgisayar arayüzü (BBA) arařtırmaları insanlar ile makineler arasındaki iletiřimi güçlendirmeye çalıřmaktadır. Bu çabaya bir katkı sunmak adına karar verme süreçlerine dair zihinsel süreçlerin Elektroansefalogram kayıtları kullanılarak birbirinden otomatik olarak ayrılması amaçlanmıřtır. Bu çalıřmada oddball deneyi sırasında kaydedilen EEG sinyalleri kullanılmıřtır. Deney esnasında kiřinin verdiđi kararlarla ilgili öznel deđerlendirilmesi alınarak, bu deđerlendirmeler; dođru-emin (dođru yapılmıř ve dođruluđundan emin olunan durumlar), yanlıř-emin (yanlıř yapılmıř ve yanlıřlıđından emin olunan durumlar) ve emin-deđil (dođru ya da yanlıř yapıldıđından emin olunmayan deđerlendirmeler) olmak üzere üç grup altında incelenmiřtir. Üç kořulla alakalı EEG kayıtlarına yansıyan olaya iliřkin salınımlar (OİS) ve olaya iliřkin potansiyeller (OİP), tek denemeli (single trial) veride ayrılmaya çalıřılmıřtır. Farklı zihinsel durumların ayrılmasında kullanılacak öğrenme algoritmalarının uygulanmasından önce EEG verisi 4 farklı öznitelik çıkarma yöntemi ile iřlenmiř ve EEG verisi içindeki ayrıřtırıcı sinyal bileřenlerinin daha iyi temsilleri elde edilmeye uğrařılmıřtır. Sonuç olarak elde edilen dört farklı öznitelik kümesi řunlardır; öz kip fonksiyonlarına ayrıřtırılmıř sinyalde belli zaman aralıklarında alınan ortalamalar, yine öz kip fonksiyonlarına ayrılmıř sinyalin frekans alanına tařınması ile elde edilen öznitelikler, istatistiksel moment temelli öznitelikler ve dalgacık dönüşümü temelli öznitelikler. Makine öğrenmesi algoritması olarak, örnek bir veri kümesinin 6 farklı algoritma ile sınıflandırılması neticesinde en yüksek başarıyı

sağladığı tespit edildiği için Gauss Destek Vektör Makinesi seçilmiştir. Sınıflandırma başarımını doğru kestirmek amacı ile 10-katlı çapraz doğrulama kullanılmıştır. Sınıflar arası gözlem sayısındaki dengesizliği gidermek için örnek artırma/azaltma ve öğrenme algoritmasının verimli çalışmasını sağlamak amacı ile özniteliklere z-skoru normalizasyonu uygulanmıştır. Eğitim kümesinden elde edilen ortalama ve standart sapma değerleri kullanılarak test kümesi ayrıca normalize edilmiştir. Üç farklı zihinsel (doğru emin, yanlış emin ve emin değil) durum dört farklı kombinasyon için sınıflandırılmış ve bu işlemler uyarana kilitli ve yanıt kilitli veri kümeleri için ayrı ayrı yapılmıştır. Sonuçlar incelendiğinde en yüksek başarımın yanıt kilitli veri kümesinde, dalgacık dönüşümü temelli öznitelikler ile elde edildiği gözlenmiştir. İki sınıflı durumlarda en yüksek başarım %75 ile doğru emin ve yanlış emin durumlarının ayrılmasında, en düşük başarım ise %63 ile yanlış emin ile emin değil durumlarının ayrılmasında elde edilmiştir. Üç sınıflı durum olan doğru emin, yanlış emin ve emin değil verilerinin sınıflandırma başarımı %54 olarak gerçekleşmiştir.

Temmuz 2019, 58. sayfa.

Anahtar kelimeler: EEG, Beyin bilgisayar arayüzü, BBA, Karar verme, sınıflandırma, dalgacık dönüşümü

SUMMARY

CLASSIFICATION OF THE SUBJECTIVE CERTAINTY LEVEL OF PERCEPTUAL DECISIONS USING EEG SIGNALS

M.Sc. THESIS

Gülay ERDOĞAN

Istanbul University-Cerrahpasa

Institute of Graduate Studies

Department of Biomedical Engineering

Supervisor: Prof. Dr. Aydın AKAN

Brain computer interface (BCI) research attempts to strengthen communication between humans and machines. In order to contribute to this effort, it was aimed to separate the mental states of decision-making processes using single trial EEG records. EEG signals recorded during the oddball experiment were used in this study. During the experiment, subjective evaluation of the decision making was obtained and these assessments are; certain-hit (hit trails in which the subject was sure about their response), certain-error (false trails in which the subject was sure about their response), and uncertain (unsure whether correct or wrong). Event-related oscillations (ERO) and event-related potentials (ERP) which were acquired from EEG recordings related to that three conditions were attempted to be separated in single trial data. Before the application of learning algorithms to differentiate mental states, EEG data was processed by 4 different feature extraction methods and a better representation of the distinctive signal components in EEG data was tried to be obtained. The resulting four different sets of features are as follows; Time averages taken at certain time intervals in the signal which was decomposed to intrinsic mode functions (IMF), the features obtained by transferring the IMFs to the frequency domain, statistical moment-based features and wavelet transform based features. Gaussian Support Vector Machine which provided the highest performance on a

sample data set classification test within 6 different algorithms was chosen as machine learning algorithm. 10-fold cross-validation was applied to accurately predict classification performance. Oversampling/undersampling processes were applied to eliminate the imbalanced observation numbers among the classes and z-score normalization was applied to the features to ensure that the learning algorithm operated efficiently. The test set was normalized using the mean and standard deviation values attained from the training set. Three different mental states (certain hit, certain false, and uncertain) were classified for four different combinations, and these operations were performed separately for stimulus-locked and response-locked data sets. When the results were analyzed, it was observed that the highest performance was acquired with wavelet transform based features in the response locked data set. The highest performance in two-classed cases was achieved in separation of certain-hit and certain-false states with 75%, and the lowest performance was achieved in the separation of the certain false and uncertain states with 63%. The classification performance of the three-classed case, which is certain hit, certain false, and uncertain was 54%.

July 2019, 58. pages.

Keywords: EEG, BCI, decision making, classification, wavelet transform

1.GİRİŞ VE AMAÇ

Nörogörüntüleme tekniklerindeki ilerlemeler sayesinde beyin arařtırmalarında kullanılan davranıřsal yöntemlerin yerine beyin iřlevlerinin, zamanlaması ve yerleřimi hakkında da bilgi veren biliřsel prosedürler kullanılmaya bařlanmıřtır. Nörogörüntüleme teknikleri kullanılarak öğrenme, hafıza, dikkat ve dil gibi süreçler hakkında literatüre önemli katkılar saęlanmaktadır.

Karar verme, insan davranıřının karmařık ve hayati süreçlerinden biridir ve birçok disiplinde yoęun bir řekilde çalıřılmaktadır. Son yapılan çalıřmalarda birçok farklı yöntem kullanılarak karar verme sürecinin altında yatan bileřenler ve bu bileřenleri üreten beyin bölgeleri bulunmaya çalıřılmaktadır [1]. Karar verme süreci, kiřinin dıř dünya ile iliřkisi bakımından çok temel bir süreçtir. Dikkat, motivasyon, harekete geçiren neden ve kiřinin beklentisi ile alakalıdır.

Karar verme, genellikle, kiřinin tercihlerinin fayda ya da zararlara yol açıp açmayacağına dair belirsizlik karşısında gerçekleşir [2]. Bu etki farklı düzeylerde bilinç ve bilinç dıřı řeklinde olabilir. Karar verme ve eylem monitorizasyonu süreçleri, nörogörüntüleme sistemleriyle analiz edilebilen biliřsel aktivitelerdir. Bu aktiviteler sırasıyla, fiziksel uyarının algılanıp alternatif motor yanıtlardan uygun olanın sečilmesi ve kararın uygulanması; hatalı bir cevap verildięinde de durumun saptandıęı süreçlerdir. Duysal ve motor süreçlerle doğrudan iliřkili olan bu iřlevler karar verme durumundaki mantıksal ve duygusal řartlardan da etkilenmektedir [3].

Karar verme süreci esnasında kararın doğruluęundan emin olma derecesi, bu esnada kullanılan beyin bölgelerinin belirlenmesi açısından katkı saęlamakla beraber, pratik olarak da ayırt edilmesi deęer arz etmektedir. Beyin-bilgisayar etkileřimi araçları hem insanların performansını artırmak hem de yorucu ve dikkat daęıtıcı kořullarda çalıřanların hata yaptıęı veya hata yapma olasılıęının arttıęı durumları algılayıp gerekli geribildirimleri saęlamak açısından potansiyel taşımaktadır. Bilgisayarla etkileřime giren kiřinin aldıęı kararların güvenilirlik düzeyi EEG yolu ile belirlenip, gerekli aksiyonun alınmasına yardımcı olan bir beyin bilgisayar ara yüzünün geliřtirilmesi birey konforu, çalıřma verimlilięi ve güvenlik konularında katkı saęlayacaktır.

1.1 BEYİN BİLGİSAYAR ARAYÜZÜ

Aynı zamanda Beyin-Makine arayüzü olarak da tanımlanan Beyin-Bilgisayar arayüzü (BBA) sistemleri insanın amacını yansıtan beyin sinyallerindeki değişiklikleri tespit eder ve bu sinyaller harici cihazları kontrol etmek için kullanılır. BBA'lar tipik olarak nöral aktiviteden kaynaklanan elektrik sinyallerini ölçer. Gelişmiş örüntü tanıma ve sınıflandırma algoritmaları, nöral aktiviteyi gerekli kontrol sinyallerine dönüştürür. BBA araştırmaları, nöral aktiviteyi doğru bir şekilde sınıflandırmak için güçlü sinyal işleme ve makine öğrenme teknikleri geliştirmeye yoğunlaşmıştır [4].

Amyotrofik Lateral Skleroz (ALS) gibi ciddi nörolojik rahatsızlıklarla mücadele eden insanlarda, beyin sapı felci veya omurilik hasarı gibi motor yetenekleri etkileyen hastalıklarda kişiler günlük hayatlarını idame ettirmekte zorlanmanın yanı sıra bilgisayar etkileşmesini sağlayacak kas hareketlerini de yapamayabilirler. Bu durumlar için BBA insanların motor yeteneklerini veya iletişim yeteneklerini artırmanın bir yolu olarak öne çıkmaktadır. Örneğin hareketin hayal edilmesi (motor imagery) üzerinden kontrol edilen bir tekerlekli sandalye veya P300-heceleyici ile iletişim kurmaya yardımcı olmak ve çeşitli gereçleri kontrol etmek mümkün olabilmektedir [5, 6]. BBA, hasta ve engelli kişilere yardımcı olmak amacı ile kullanılması dışında, oyun sektöründe, güvenlik uygulamalarında, eğitim ve daha birçok alanda uygulanma potansiyeline sahiptir [7].

Bilgisayar ile etkileşirken beyindeki nöral aktiviteyi ölçmek için kullanılan çeşitli yöntemler vardır. Nöral aktivite monitorizasyonunda en yaygın kullanılan modaliteler arasında, Elektrokortigografi, Yakın Kızılötesi Spektroskopi, fonksiyonel Manyetik Rezonans Görüntüleme, Magnetoensefalografi ve Elektroensefalografi sayılabilir. Bu yöntemler beyin bilgisayar etkileşimi çerçevesinde değerlendirildiğinde, görece düşük maliyeti, uygulanmasının kolaylığı ve hareketli bir kurulum içinde kullanımının mümkün olması gibi avantajları nedeni ile EEG öne çıkmaktadır.

1.2 KARAR VERME SÜREÇLERİNİN EEG KORELATLARI

EEG gibi nöral görüntüleme teknikleri karar verme ile sonuçlanan bilişsel süreçlerin anlaşılmasında kullanılabilir. P1 ve N1 gibi erken uyarılmış potansiyellerin yürütülen bir görev esnasındaki dikkat seviyesine hassas olduğu gösterilmiştir, örneğin N1 genliği dikkat

seviyesindeki düşüşle birlikte azalmaktadır [8]. Bir görevin zorluğunun aynı zamanda P300 potansiyel genliğini ve gecikmesini modüle ettiği de bir başka çalışmada gösterilmiştir [9]. Buraya kadar bahsedilen olaya ilişkin potansiyeller erken algısal ve bilişsel işlemleri yansıtırken CNV (contingent negative variation) gibi motor yanıt hazırlığı yansıtan geç bileşenler de karar alma süreçleri ile ilişkilendirilmektedir. CNV genliğinin yanlış cevap öncesinde doğru cevaba kıyasla daha düşük olduğu rapor edilmiştir [10]. Hatalı yanıtın 50 ila 80ms sonra ortaya çıkan Hataya İlişkin Negativite de karar verme sürecindeki güven seviyesini tespit etmekte bir gösterge olarak kullanılabilir [11]. Bahsedilen çalışmalar ortalama Olaya İlişkin Potansiyel (OİP) sonuçlarını yansıtmaktadır. OİP sinyalleri tekli deneme (single trial) verileri için sinyal gürültü oranlarının düşük olması nedeni ile çok verimli değildir, fakat EEG sinyalinde karar verme süreçlerinden etkilenen bileşenler olduğunu göstermesi açısından önemlidir. Karar verme süreçlerinin incelenmesinde faydalanılabilecek bir diğer EEG bileşeni olaya ilişkin salınımlardır (OİS) ve OİS'lerin bilgi işleme ve davranış ile ilintisini gösteren çalışmalar bulunmaktadır [12,13]. OİS'ler, OİP'lerden farklı olarak uyarıcı anı ile sabit bir faz ilişkisi göstermezler, bu nedenle konvansiyonel ortalama alma yolu ile elde edilen OİP sinyal ölçümlerinde OİS sinyaline rastlanmaz, fakat düşük sinyal/gürültü oranları yüzünden OİP'lerin elde edilmesinin bir şartı olarak kullanılan ortalama alma işlemi OİS'ler için zorunlu değildir.

Bu çalışmada çeşitli sinyal işleme ve öznitelik çıkarma yöntemleri ile OİP ve OİS sinyallerinin tekli deneme verisinde belirgin hale getirilmesi ve öğrenme algoritmaları yoluyla, karar verme süreçleri ile ilgili farklı zihinsel durumların bu sinyaller üzerinden ayrılması hedeflenmektedir.


2. GENEL KISIMLAR

2.1. ELEKTROENSEFALOGRAFI

Elektroensefalografi (EEG), özellikle beynin serebral korteksinde oluşan elektriksel aktivitenin kafa derisi boyunca yerleştirilen elektrotlar aracılığıyla elde edilip kaydedildiği ölçümdür. EEG aktivitesi hücresel temelinde, çoğunlukla korteksin 5.-6. tabakalarında bulunan ve kafa yüzeyine göre dik konumda olan birer dendritik ağaca sahip piramidal nöronlarda oluşan potansiyeller sonucu ekstraselüler bölgedeki iyonların hareketinden kaynaklanmaktadır. Elektrot ve dipol arasında düşük iletkenliğe sahip yapılar (cilt, kafatası, beyin zarları) nedeniyle kaydedilen sinyal önemli ölçüde zayıfladığından, EEG'deki potansiyel değişimler ancak çok sayıda kortikal nöronun benzer yönde sinaptik girdileri alınarak oluşan senkronizasyon sayesinde gözlenebilir.

EEG, klinikte birçok hastalığın teşhisinde kullanımının yanı sıra kısıtlı uzamsal çözünürlüğüne rağmen değerli bir araştırma aracıdır. Belirli beyin bölgesindeki aktivitelerle spesifik zihinsel işlevler arasındaki ilişkileri anlamak için kullanılan fonksiyonel bir nörogörüntüleme yöntemidir. Kullanılan diğer yöntemlerden bazıları, magnetoensefalografi (MEG), tek foton emisyonu bilgisayarlı tomografi (SPECT), fonksiyonel manyetik rezonans görüntüleme (fMRI), pozitron emisyonu tomografisi (PET) ve yakın kızılötesi spektroskopik (NIRS) görüntülemelerdir. Bu yöntemlerden MEG hariç diğer yöntemler nöral aktivite ile alakalı serebral kan akışını ve metabolik aktivitedeki değişiklikleri ölçerler. PET ve fMRI yöntemlerinin uzamsal çözünürlüğü EEG'ye göre çok daha iyi olmasına karşın zamansal çözünürlükleri düşük ve maliyetleri fazladır. PET invazif olmayan bir yöntem olmakla beraber radyoaktif maddelerin kullanımından dolayı organizmaya zararlı olabilir ve bu sebeple sıklıkla kullanılması mümkün değildir. MEG, EEG'ye benzer şekilde iyi bir zamansal çözünürlüğü ve görece yüksek uzamsal çözünürlüğü olmasına karşın EEG'ye göre maliyeti yüksektir ve mevcut teknoloji dahilinde oldukça yer kaplayan bir yöntemdir. Kısaca EEG'nin düşük maliyetli olması, oldukça az yer kaplaması ve yüksek zamansal çözünürlüğü nedeniyle klinikte ve araştırma aracı olarak hala çokça tercih edilen bir sistemdir.

En yaygın olarak kullanılan 10-20 sistemindeki EEG elektrot dizilimi Şekil 2.1'de görülmektedir.



Şekil 2.1: EEG elektrot yerleşimi (10-20 sistemi).

2.2 SİNYAL İŞLEME VE ÖZİNTELİK ÇIKARMA

EEG verisinden öznitelik çıkarımı, bilişsel performans değerlendirmelerinin kalitesini artırdığı ve özellikle sınıflandırıcının performansını doğrudan etkilediği için önemlidir. EEG sinyalinin sinyal gürültü oranının düşüklüğü öznitelik çıkarma adımının EEG veri sınıflandırmasının en kritik adımı olmasına sebep olmuştur.

Özelde beyin-bilgisayar arayüzü ve genel olarak EEG literatüründe birçok öznitelik çıkarma yöntemi bildirilmiştir. Bunlar zaman alanı öznitelikleri, frekans temelli öznitelikler, zaman frekans temelli öznitelikler ve son olarak uzam, zaman ve frekans bilgisinin bir arada kullanıldığı öznitelikler olarak sınıflandırılabilir [14]. Bu çalışmada zaman alanı, frekans alanı ve zaman frekans alanı (Dalgacık Dönüşümü) temelli yaklaşımlar denenmiştir.

2.2.1 Görgül Kip Ayrışımı

Son yıllarda doğrusal ve durağan olmayan sinyallerin analizinde kullanılan metotlardan biri görgül kip ayrışımı (GKA) yöntemidir. Uyarlanabilir bir yöntemdir ve bu nedenle de oldukça etkilidir. Yöntemin en önemli kısmı, karmaşık bir veri setinin sonlu ve az sayıda öz kip fonksiyonlarına (ÖKF) ayrıştırılmasıdır [15].

GKA yöntemi, sinyali düşük frekanslı ve yüksek frekanslı bileşenler olarak ayırır. Yüksek frekans kısmına öz kip fonksiyonu (ÖKF) ve düşük frekans kısmına artık denir. Daha sonra prosedür artık sinyale (yeni zaman serisi olarak kabul edilir) tekrar uygulanarak yeni bir ÖKF ve yeni bir artık sinyal elde edilir. Bir $x(t)$ sinyali için GKA algoritması aşağıdaki gibidir:

1. $x(t)$ 'nin tüm extremum noktaları (maximum ve minimum) tespit edilir;
2. maximum ve minimum noktaları kübik spline ile ayrı ayrı birleştirilerek üst ve alt zarf ($e_{\min(t)}$, $e_{\max(t)}$) oluşturulur;
3. yerel ortalama hesaplanır $m(t) = (e_{\min(t)} + e_{\max(t)})/2$;
4. detay sinyal çıkarılır $d(t) = x(t) - m(t)$;
5. artık sinyal $m(t)$ üzerinde işlemler tekrarlanır.

Ayrıştırma işleminin sonunda, GKA yöntemi, $x(t)$ sinyalini sınırlı sayıda ÖKF ve son bir artık sinyalin toplamı olarak ifade eder:

$$x(t) = \sum_{k=1}^K d_k(t) + m_k(t) \quad (2.1)$$

$d_k(t)$ 'ler ÖKF'leri ve $m_k(t)$ son artık sinyali ifade eder [16].

2.2.2 Sürekli Dalgacık Dönüşümü

Dalgacık dönüşümü, sinyalin içinde farklı ölçeklerde var olan bilgiyi ortaya çıkarır. Dalgacık hem frekans hem de zaman alanında iyi lokalizasyona sahip bir matematik fonksiyonudur ve tüm frekans aralıklarında optimum zaman-frekans çözünürlüğü sağlar. Bir dalgacık ailesi $\psi_{a,b}(t)$, anne dalgacığın $\psi(t)$ genişlemesi ve yer değiştirilmesi ile oluşan bir dizi fonksiyondur.

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) \quad (2.2)$$

Formülde, t zaman, a genişleme parametresi, b yer değiştirme parametresi, $a, b \in R$ ve $a \neq 0$ dır. Genişleme parametresi salınım frekansına ve dalgacık uzunluğuna karar verir, yer değiştirme parametresi kayma konumuna karar verir.

Gerçek zamanlı bir $x(t)$ sinyalinin sürekli dalgacık dönüşümü, sinyal $X(t)$ ve dalgacık fonksiyonu $\psi_{a,b}(t)$ arasındaki korelasyon olarak tanımlanır.

$$(W_{\psi}X)(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} X(t) \psi\left(\frac{t-b}{a}\right) dt \quad (2.3)$$

Morlet dalgacığı (Gabor dalgacığı) bir Gauss fonksiyonunun ikinci türevinden üretilmiştir [17].

$$\psi(t) = e^{2i\pi ft} e^{-\frac{t^2}{2\sigma^2}} \quad (2.4)$$

2.2.3 Merkezi Momentler

Olasılık teorisi ve istatistikte, merkezi moment, rastgele değişkenin ortalaması etrafındaki olasılık dağılımının bir momentidir; yani, rasgele değişkenin ortalamadan sapmasının belirli bir tamsayı gücünün beklenen değeridir.

$$m_r = \frac{1}{n} \sum_{k=1}^n (x_k - m)^r \quad (2.5)$$

r . örnek merkezi momenti m_r dir. n örnek boyutu ve x_k k . örnek değeridir.

Basıklık (b) bir olasılık dağılımında asimetriklik derecesini yansıtan bir ölçüdür.

$$b = \frac{m_3}{s^3} \quad (2.6)$$

s örnek standart sapmayı ve m_3 3. merkezi momenti belirtir.

Çarpıklık (k) standart sapma değerine göre olasılık dağılımının yüksekliği hakkında bilgi sağlar yani verilerin normal dağılmış bir girdiden elde edilip edilmediğini belirler [18].

$$k = \frac{m_4}{s^4} \quad (2.7)$$

m_4 4. merkezi momenti belirtir.

2.3 MAKİNE ÖĞRENMESİ VE SINIFLANDIRMA

Sınıflandırma öznitelik vektörünü temel alarak veri sınıflarını ve kavramlarını tanımlayan ve ayıran bir model bulma sürecidir. Sınıflandırmanın amacı, verinin içindeki her örnek için hedef sınıfı doğru bir şekilde tahmin etmektir.

Bir sınıflandırma işi, atanmış sınıfları içeren bir veri setiyle başlar. Eğitim (training) sürecinde, sınıflandırma algoritması, bağımsız değişken değerleri ile hedef verilerin değerleri arasındaki ilişkileri bulur. Farklı sınıflandırma algoritmaları, ilişkileri bulmak için farklı teknikler kullanır. Bu ilişkiler bir modelde özetlenir ve daha sonra sınıf tipinin bilinmediği farklı bir veri setine uygulanabilir.

Sınıflandırma modelleri, bir dizi test verisindeki bilinen hedef değerlerle öngörülen değerleri karşılaştırılarak test eder. Test verileri, modeli oluşturmak için kullanılan verilerle uyumlu olmalı ve bu verilerin hazırlandığı şekilde hazırlanmalıdır. Özetle sınıflandırma algoritmaları tipik olarak iki aşama içerir:

- Eğitim Aşaması: Bu aşamada, eğitim örneklerinden bir model oluşturulur.
- Test Aşaması: Bu aşamada, model etiketlenmemiş bir test verisine bir etiket atamak için kullanılır [19].

Makine öğrenmesi, bilgisayar sistemlerinin belirli bir görevi etkin bir şekilde gerçekleştirmesi için, açık talimatlar kullanmadan, bunun yerine kalıplara ve çıkarımlara dayanan algoritmaların ve istatistiksel modellerin bilimsel çalışmasıdır. Makine öğrenme algoritmaları, görevi gerçekleştirmek üzere açıkça programlanmadan öngörülerde veya kararlarda bulunmak için "eğitim verileri" olarak bilinen örnek verilere dayanan matematiksel bir model oluşturur.

Makine öğrenmesinde, ham verilerden çıkarmaya çalışılan öngörü veya bilgiler verilere bakmadan açıkça anlaşılmaz. Makine öğrenmesi verileri bilgiye dönüştürüyor.

Beyin verileri, denemeden-denemeye ve denekten-deneğe göre değişim gösterdiği için analizini yapmak oldukça zordur. Sinyal-gürültü oranı oldukça elverişsiz olan bu veriler az sayıda örnek içerir ve yüksek boyutludur, bu sebeple bir modele uygulanmaları zordur. İyi tanımlanmamış bir veride sinyal ve gürültü birbirinden ayırt edilemeyebilir. Bu değişkenlikler sebebiyle, tek

dilimli verilerin online analizinde makine öğrenmesi yöntemleri tercih edilen bir araç haline gelmiştir [20].

2.3.1 Destek Vektör Makineleri

2.3.1.1 Doğrusal Destek Vektör Makineleri

Destek Vektör Makinesi (DVM) bir dizi etiketli eğitim verisinden giriş-çıkış eşleme fonksiyonu üreten eğiticili bir öğrenme yöntemidir. Bu yöntemde veriler daha yüksek boyutlu bir giriş uzayına eşleştirilir ve bu alanda optimum bir ayırma hiper düzlemi oluşturulur.


Eğitim verilerini $\{x_i, y_i\}$, $i = 1, \dots, l$ $y_i \in \{-1, 1\}$, $x_i \in R^d$. Pozitif örnekleri negatiflerden ayıran bir hiper düzlem olduğunu varsayalım (bir "ayırıcı hiper düzlem"). Hiper düzlem üzerinde bulunan x noktaları $w \cdot x + b = 0$ denklemini de sağlamaktadır. Burada w hiper düzlem için normaldir ve aynı zamanda ağırlık vektörüdür, $|b| / \|w\|$ hiper düzlemden orijine olan dik mesafedir ve $\|w\|$ w 'nun Öklid normudur. $d_+(d_-)$ ayırıcı hiper düzlemden en yakın pozitif (negatif) örneğe olan en kısa mesafedir. Doğrusal olarak ayrılabilir durum için, destek vektör algoritması basitçe en büyük mesafeye sahip ayırıcı hiper düzlemi arar.

$$y_i = +1 \text{ için } x_i \cdot w + b \geq +1 \quad (2.8)$$

$$y_i = -1 \text{ için } x_i \cdot w + b \leq -1 \quad (2.9)$$

Bu iki eşitsizlik şu şekilde birleştirilebilir:

$$y_i(x_i \cdot w + b) - 1 \geq 0 \quad \forall i \quad (2.10)$$



Şekil 2. 2: DVM sınıflandırıcı yapısı. Destek vektörleri daire içine alınmıştır.

H1 normali \mathbf{w} olan $\mathbf{x}_i \cdot \mathbf{w} + b = +1$ hiper düzlemdir ve orijinden dik uzaklığı $|1-b|/\|\mathbf{w}\|$ dir. Benzer şekilde H2 normali \mathbf{w} olan $\mathbf{x}_i \cdot \mathbf{w} + b = -1$ hiper düzlemdir ve orijinden dik uzaklığı $|-1-b|/\|\mathbf{w}\|$ dir. Dolayısıyla $d_+ = d_- = 1/\|\mathbf{w}\|$ ve hiper düzlemler arası mesafe $2/\|\mathbf{w}\|$. H1 ve H2 birbirine paraleldir ve bu sebeple aynı normale sahiptir. H1 ve H2 arasına hiçbir eğitim noktası düşmemektedir. Böylelikle öyle iki hiper düzlem bulunabilir ki (2.10) denklemindeki kısıtı sağlamak koşuluyla $\|\mathbf{w}\|^2$ değerini minimize ederken aralarındaki mesafeyi maksimuma çıkarır.

Yukarıda ele alınan denklemler ve kısıtlar Lagrange formülasyonunda birleştirilir. Bu, prosedürü doğrusal olmayan duruma genelleştirmemize sağlayacak çok önemli bir özelliktir. Pozitif Lagrange çarpanı α_i $i = 1, \dots, l$

$$L_P = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^l \alpha_i y_i (\mathbf{x}_i \cdot \mathbf{w} + b) + \sum_{i=1}^l \alpha_i \quad (2.11)$$

L_P , \mathbf{w} ve b 'ye göre minimize edilir.

$$\sum_i \alpha_i y_i = 0 \quad (2.12)$$

$$\mathbf{w} = \sum_i \alpha_i y_i \mathbf{x}_i \quad (2.13)$$

Bu eşitlikler (2.11) denkleminde yerine konular ve elde edilen yeni L_D eşitliği α_i 'ye göre maksimize edilir.

$$L_D = \sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j \mathbf{x}_i \cdot \mathbf{x}_j \quad (2.14)$$

2.3.1.2 Doğrusal Olmayan Destek Vektör Makineleri

Karar fonksiyonunun doğrusal fonksiyon olmadığı durumlarda veriler önce Φ adı verilen bir eşleştirme kullanılarak başka bir (muhtemelen sonsuz boyutlu) Öklid uzayına (\mathcal{H}) eşleştirilir. Verinin eğitim probleminde görünmesinin tek yolu denklem (2.14)'te bulunan skaler çarpım $(\mathbf{x}_i \cdot \mathbf{x}_j)$ biçimindedir.

$$\Phi : \mathbb{R}^d \rightarrow \mathcal{H}$$

Eğitim algoritması sadece \mathcal{F} 'deki $\Phi(x_i) \cdot \Phi(x_j)$ formunda olan skaler çarpımdan elde edilen verilere bağlı olacaktır. Eğitim algoritmasında kullanılan $K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j)$ şeklinde bir "kernel fonksiyonu" var olduğunda Φ 'nun ne olduğunu açıkça bilmeye gerek yoktur [21].

Sıkça kullanılan bazı doğrusal olmayan kernel fonksiyonları:

$$K(\mathbf{x}, \mathbf{y}) = (\mathbf{x} \cdot \mathbf{y} + 1)^p \quad (2.15)$$

$$K(\mathbf{x}, \mathbf{y}) = e^{-\|\mathbf{x}-\mathbf{y}\|^2 / 2\sigma^2} \quad \text{Gaussian radial basis function} \quad (2.16)$$

$$K(\mathbf{x}, \mathbf{y}) = \tanh(\kappa \mathbf{x} \cdot \mathbf{y} - \delta) \quad (2.17)$$

2.3.2 k-En Yakın Komşuluk

k-en yakın komşuluk (kNN), etiketleri olan eğitim setine etiketi olmayan yeni bir veri verildiğinde bu yeni veri parçasını mevcut veri ile karşılaştırır. Daha sonra en benzer veri parçalarını (en yakın komşular) alır ve etiketlerine bakar. Yeni veriye en çok benzeyen k tane komşunun etiketleri incelenir (k bir tamsayıdır ve genellikle 20'nin altındadır). Son olarak, bu benzer komşular arasında çoğunluğu elde eden sınıf yeni verinin sınıfı olarak atanır.

2.3.3 Rastgele Orman

Rastgele orman sınıflandırıcısı, her sınıflandırma çıktısı için belirli bir ağırlığa (weight) sahip özgün birçok sınıflandırma ağacından oluşur. Tüm ağaçların sınıflandırma çıktıları, yapılacak genel sınıflandırma çıkışı belirlemek için kullanılır.

Rastgele ormanlar sınıflandırıcısının oluşturulması için gereken adımlar aşağıdaki gibi özetlenebilir:

- Rastgele orman sınıflandırıcısının öğrenme prosedürü, her bir ağacın oluşturulmasıyla başlar.
- Bir sonraki adım, her ağaç için eğitim veri setlerini hazırlamaktır.
- Her ağaç için, rastgele sayıda öznitelik seçilir ve rastgele ağaç sınıflandırıcısının düğümlerini ve yapraklarını oluşturmak için kullanılır.

- Rastgele bir ağaç oluşturmak, tüm eğitim veri setiyle ağacın tepesinde başlar. İlk adım, kök düğümde bir öznitelik seçmeyi ve ardından özneliğin her olası değeri için eğitim verilerini alt bölümlere ayırmayı içerir.

- Tüm ağaçları oluşturduktan sonra, (out of bag) veriler, tek tek ağaçları ve tüm ormanı test etmek için kullanılır. Ortalama yanlış sınıflandırma hatası her bir ağacın ağırlığını ayarlamak için kullanılabilir [22].

2.3.4. Lojistik Bağlanım

Araştırma hedeflerine ve değişken biçimine bağlı olarak farklı bağlanım türleri vardır, doğrusal bağlanım en sık kullanılanlardan biridir. Doğrusal bağlanım, sürekli çıktıları (continuous outcome) analiz eder ve çıktı ile bağımsız değişkenler arasındaki ilişkinin düz bir çizgi izlediğini varsayar. Doğrusal bağlanıma benzer şekilde, lojistik bağlanım yalnızca bir veya birden fazla bağımsız değişken içerebilir, ancak birden fazla değişkeni incelemek genellikle daha bilgilendiricidir, çünkü diğer değişkenler için düzeltme yapıldıktan sonra her değişkenin benzersiz katkısını ortaya çıkar. Her değişkene bakmak yerine, birden fazla bağımsız değişkenin aynı anda değerlendirilmesi önemlidir [23].

2.3.5 Dengesiz Veri Seti İçin Örnek Arttırma veya Örnek Azaltma

Kavram öğrenme probleminde, veri setinin içinde bir sınıfın diğerine göre çok daha fazla örnek içermesi halinde sınıf dengesizliği oluşur. Böyle bir durum sınıflandırıcılar için zorluklar ortaya çıkarmaktadır. Sonuç olarak, sınıflandırıcılar büyük sınıfları doğru sınıflandırmaya odaklanırken küçük sınıfları görmezden gelme eğilimindedir. Ne yazık ki, birçok alanda sınıf dengesizliği oldukça yaygındır.

İki farklı yeniden örnekleme yaklaşımı göz önünde bulundurulmaktadır: küçük sınıfı, büyük sınıfa yakın bir boyuta ulaştırmak için küçük sınıfta örnek arttıran (oversampling) yöntemler ve büyük sınıfı küçük sınıfa yakın bir boyuta ulaşmak için büyük sınıftan örnek azaltan (undersampling) yöntemler [24].

Yapılan bazı çalışmalar ampirik olarak sınıf dağılımını dengelemek için bir ön işleme adımının uygulanmasının genellikle yararlı bir çözüm olduğunu kanıtlamıştır. Ayrıca, bu tekniklerin asıl avantajı, temel sınıflandırıcıdan bağımsız olmalarıdır [25, 26].

2.3.6 k - Katlı Çapraz Doğrulama

Çapraz doğrulama, eldeki tüm örnekleri eğitim ve test setleri olarak kullanan, hesap yoğun bir tekniktir. Bazen döndürme kestirimi olarak adlandırılan k -katlı çapraz doğrulamada, veri kümesi (D) rastgele bir şekilde eşit büyüklükteki k tane birbirini dışlayan alt kümeye (katlar) D_1, D_2, \dots, D_t ayrılır. Sınıflandırıcı k kez eğitilir ve test edilir; her seferinde $t \in \{1, 2, \dots, k\}$, $D \setminus D_t$ 'de eğitilir ve D_t 'de test edilir. Çapraz doğrulama kestiriminin isabetliliği, tüm doğru sınıflandırılan örnek sayısının veri kümesindeki örnek sayısına bölünmesiyle elde edilir [27].



3. MALZEME VE YÖNTEM

3.1 EEG KAYIT SİSTEMİ

Bu çalışmada, 2008 yılında İstanbul Üniversitesi, İstanbul Tıp Fakültesi, Fizyoloji ABD. Öğretim üyesi Prof. Dr. Tamer DEMİRALP yürütücülüğünde alınmış olan EEG, kayıtları kullanılmıştır.

Katılımcılar ortalama 24.4 (\pm 2.5) yaşında sağ elini kullanan 17 (10 erkek, 7 kadın) kişiden oluşmaktadır. Tüm katılımcılar lisans, yüksek lisans ve uzmanlık öğrencileridir. Hepsi normal ya da düzeltilmiş görüşe sahiptir. Deneyden önce katılımcılara EEG kayıt prosedürleri ve deney paradigması ile ilgili bilgi verilmiştir. Kayıt sonrasında gerekli standartları sağladığı tespit edilen 13 katılımcıya ait veriler kullanılmıştır.

Denekler loş olarak aydınlatılmış kayıt odasına görsel uyarının sunulacağı monitörün önüne oturtulmuş, ses ve elektromanyetik izolasyonu sağlanmış bir odada deney süresince monitörün merkezinde sabit bir noktaya odaklanmışlardır.

EEG kaydı, uluslararası 10-20 sistem ile FP1, FP2, F3, Fz, F4, FC3, FCz, FC4, F7, F8, FT7, FT8, C3, C2, C4, CP3, CPz, CP4, T7, T8, TP7, TP8, P3, Pz, P4, P7, P8, O1, Oz, O2 bölgelerine yerleştirilen 30 Ag/AgCl elektrottan iki kulak memesinin ortalaması alınarak yapılmıştır. Göz hareketlerini monitörize etmek için kullanılacak olan elektro-okülogram (EOG) kaydı sağ gözün dış kantus ve nazyon bölgesine yerleştirilen elektrotlar aracılığı ile alınmıştır.

La Mont Medical Inc. şirketinin 32-kanallı EEG aleti kullanılarak elde edilen sinyaller 0.1 Hz yüksek geçiren ve 70 Hz alçak geçiren filtre uygulanarak yükseltilmiştir. Veri, 200Hz örnekleme frekansı ile örneklenip, sayısallaştırılarak bilgisayara kaydedilmiştir.


Kayıt esnasında iki bilgisayar kullanılmıştır. İlki uyarın sunumu ve deneklerin düğmeye basma yanıtlarını toplamıştır. Diğeri ise EEG verisinin toplanmasında ve birinci bilgisayardan gelen uyarınların sunum ve deneklerin yanıt anlarının EEG kaydının üzerine işaretlenmesinde kullanılmıştır.

3.2 EEG KAYIT PARADİGMASI

Bu çalışmada kullanılan kayıtlarda, Jeon ve Polich tarafından tasarlanan deney deseni değiştirilerek hazırlanan Oddball daire paradigması kullanılmıştır [28]. Bu paradigmada, katılımcıların eşit olasılıkla ekranda rastlantısal olarak beliren biri büyük biri küçük iki mavi daireye sağ elin işaret ve orta parmaklarıyla büyük daire için 8 ve küçük daire için 9 tuşlarına basılarak cevap vermeleri gerekiyordu (Şekil 3.1). Deneyde kullanılan büyük daire 5cm, küçük daire ise 4.6cm çapındadır. Katılımcılardan, kararlarından emin olmadıkları durumlarda bir sonraki uyarandan sonra o uyarana uygun yanıt vermek yerine sol ellerinin orta parmaklarıyla klavyenin “Q” tuşuna basmaları; hatalı cevap verdiklerini düşündükleri durumlarda ise sol ellerini işaret parmaklarıyla klavyenin “W” tuşuna basmaları istendi. Deney günü, EEG kaydına başlamadan önce, kısa bir deneme seansı yapılmıştır.

Monitör katılımcıya 1m mesafede konumlanmış olup, daireler, siyah zemin üzerine parlak mavi renkte boyanmıştı.

EEG sinyali, bu paradigma ile eş zamanlı olarak ve bölüm 3.1’de tarif edilen kayıtlama sistemi kullanılarak 32 kanaldan kaydedilmiştir.



Şekil 3.1: Oddball daire paradigması.

Göz ve kas artefaktına sahip dilimler belirlenip ham veriden çıkarılmıştır. Daha sonra uyarana kilitli durumda, uyarın öncesi 0.5sn ve uyarın sonrası 1sn zaman aralığını, yanıtla kilitli durum için ise yanıt öncesi 0.5sn ve yanıt sonrası 1sn arasındaki zaman aralığını kapsayacak şekilde EEG dilimleri elde edilmiştir.

Tüm katılımcıların EEG kayıtları, kişilerin kendinden emin olma seviyelerine göre 3 bölüme ayrılmıştır:

1. Doğru-emin: hiçbir değerlendirilmede bulunulmayan doğru yanıt verilen durumlar
2. Emin-değil: “emin değilim” değerlendirilmesinin yapıldığı durumlar
3. Yanlış-emin: sonrasında “yanlış yaptım” değerlendirmesinin bulunduğu yanlış yanıtlanmış durumlar.

3.3 EEG ÖN İŞLEME

Uyarana ve yanıtla kilitli durumlar için ayrı ayrı olmak üzere 13 katılımcıdan Doğru Emin (DE), Yanlış Emin (YE) ve Emin Değil (ED) durumları için EEG verisi kaydedilmiştir. EEG verisi 32 kanal olarak kaydedilmiş olup, bu kanalların ikisi EOG kanalıdır. Artefakt giderilmesinden sonra EOG kanallarına ihtiyaç kalmadığından ve bu kanalların aranan nörolojik sinyalleri içermesi mümkün olmadığından veriden çıkarılarak EEG verisi 30 kanallı hale getirilmiştir.

Bir buçuk saniyelik EEG dilimlerinden oluşan iki ayrı veri seti üzerinde öncelikle 1-40Hz arası bant-geçiren 3. dereceden butterworth filtre uygulanmıştır. Uyarana kilitli veri, uyarana öncesi 200ms'lik zaman dilimi ve yanıtla kilitli veri yanıt sonrası 350-550ms arasındaki bölge kullanılarak referansla zemin hattı düzeltme (baseline correction) işlemine tabi tutulmuştur.

Yanıta kilitli toplam 1472 adet 30 kanallık EEG dilimi bulunmaktadır. Bu 1472 dilim içinde 731 tanesi DE, 485 tanesi YE ve 256 tanesi ED durumlarına aittir.

Uyarana kilitli toplam 1468 adet 30 kanallık EEG dilimi bulunmaktadır. Toplam 1468 dilim içinde 709 tanesi DE, 470 tanesi YE ve 289 tanesi ED durumlarına aittir.

Tablo 3.1: Katılımcılara göre her bir duruma ait EEG dilim sayısı.

		1. denek	2. denek	3. denek	4. denek	5. denek	6. denek	7. denek	8. denek	9. denek	10. denek	11. denek	12. denek	13. denek
Uyarana Kilitli EEG	DE	25	35	30	15	50	30	70	125	20	30	44	55	180
	YE	25	25	27	12	35	24	67	124	15	30	18	52	16
	ED	17	24	12	5	50	28	30	15	11	21	44	7	25
Yanıta Kilitli EEG	DE	28	35	27	15	48	30	70	125	20	33	40	54	206
	YE	28	33	27	8	35	24	70	124	12	33	21	52	18
	ED	20	18	11	7	48	24	26	15	13	5	39	7	23

3.4 ÖZİNİTELİK ÇIKARMA


Öznitelik çıkarmak için aşağıda detayları verilmiş olan dört farklı yöntem uygulanmıştır. Bu yöntemlerin ilk üçünde sinyale ilk adım olarak GKA uygulanmış, dördüncü yöntem olan dalgacık dönüşümü öncesinde ise GKA uygulanmamıştır.

GKA uygulanarak Öz Kip Fonksiyonlarına ayrıştırılmış veride ve her bir EEG dilimi için 3 ÖKF elde edilmiştir.

3.4.1 Uyarana Kilitli Veri Seti

3.4.1.1 Öz Kip Fonksiyonlarından Zaman Alanında Öznitelik Çıkarılması

Öznitelik vektör boyutunu sınırlandırmak ve sinyal gürültü oranını artırmak amacı ile 301 noktalı ÖKF verisinin 3 değere indirgenmesine karar verilmiştir. Bu doğrultuda literatür ve [11] çalışması baz alınarak zamanda anlamlı sinyal gözlemlenen 3 farklı zaman aralığı belirlenmiş ($[0 - 0.2\text{sn}]$, $[0.35 - 0.45\text{sn}]$ ve $[0.45 - 0.7\text{sn}]$) ve belirlenen zaman aralıklarının her birinde aritmetik ortalama hesaplanmıştır. Böylece her EEG diliminde 3 zaman ortalaması x 3 ÖKF x 30 kanal için toplam 270 elemanlı öznitelik vektörleri elde edilmiştir.



Şekil 3.2: GKA kullanılarak elde edilmiş ÖKF'lere örnek.

3.4.1.2 Öz Kip Fonksiyonlarından Frekans Alanında Öznitelik Çıkarılması


Her bir EEG dilimi için elde edilen öz kip fonksiyonlarından zaman alanında uyarana kilitli 0-1sn arasında 1sn'lik dilimlerde 201 noktalı ayrık Fourier dönüşümü uygulanarak 1Hz çözünürlüklü frekans izgeleri elde edilmiştir. Frekans alanına taşınan veride 3 ayrı öz kip fonksiyonu için gücün yoğunlaştığı tespit edilen frekans bantlarındaki (1. kip 1–20Hz, 2. kip 1–10Hz ve 3. kip 1–5 Hz) her bir frekansa ait genlik değerleri vektörize edilmiştir. Sonuç olarak 35 frekans x 30 kanal için 1050 elemanlı öznitelik vektörleri elde edilmiştir.

3.4.1.3 Öz Kip Fonksiyonlarından İstatistiksel Moment Öznitelik Çıkarılması

Her bir EEG dilimi için elde edilen öz kip fonksiyonlarından zaman alanında uyarandan sonrasi 1sn'lik dilimlerde 3 merkezi moment (2, 3 ve 4. momentler) ile dağılım çarpıklığı (skewness) ve savrukluk (kurtosis) değerleri hesaplanmıştır. Sonuç olarak 5 moment x 3 ÖKF x 30 kanal için 450 elemanlı öznitelik vektörleri elde edilmiştir.

3.4.1.4 Dalgacık Dönüşümü

Zemin hattı düzeltmesi ve bant geçiren filtreleme uygulanmış EEG dilimlerine 6 döngülü Morlet dalgacık dönüşümü uygulanmış ve verinin [-0.5 – 1sn] ve 1–20Hz arasında zaman frekans temsili elde edilmiştir. Elde edilen zaman frekans verisinin uyarandan sonrasi [0 – 0.7sn] zaman aralığında ortalaması alınmış ve böylece veri zamanda tek bir değere indirgenmiştir. Sonuç olarak 20 frekans x 30 kanal için 600 elemanlı öznitelik vektörleri elde edilmiştir. Tek bir EEG dilimi için örnek dalgacık dönüşümü sonucu şekil 3.3'te görülmektedir.



Şekil 3.3: Tek dilimlik EEG'nin Dalgacık Dönüşümü.

3.4.2 Yanıt Kilitli Veri Seti

3.4.2.1 Öz Kip Fonksiyonlarından Zaman Alanında Öznitelik Çıkarılması

Öznitelik vektör boyutunu sınırlandırmak ve sinyal gürültü oranını artırmak amacı ile 301 noktalı ÖKF verisinin 3 değere indirgenmesine karar verilmiştir. Bu doğrultuda literatür ve [11] çalışması baz alınarak zamanda anlamlı sinyal gözlemlenen 3 farklı zaman aralığı belirlenmiş ($[-0.05 - 0.05\text{sn}]$, $[0.1 - 0.2\text{sn}]$ ve $[0.25 - 0.35\text{sn}]$) ve belirlenen zaman aralıklarının her birinde ortalama hesaplanmıştır. Böylece her EEG diliminde 3 zaman ortalaması x 3 ÖKF x 30 kanal için toplam 270 elemanlı öznitelik vektörleri elde edilmiştir.

3.4.2.2 Öz Kip Fonksiyonlarından Frekans Alanında Öznitelik Çıkarılması

Her bir EEG dilimi için elde edilen öz kip fonksiyonlarından zaman alanında yanıt kilitli durum için yanıtta önce 0.3sn ve yanıtta sonra 0.7sn ($[-0.3 - 0.7\text{sn}]$) arasında 1sn'lik dilimlerde 201 noktalı ayırık Fourier dönüşümü uygulanarak 1Hz çözünürlüklü frekans izgeleri elde edilmiştir. Frekans alanına taşınan veride 3 ayrı öz kip fonksiyonu için gücün yoğunlaştığı tespit edilen frekans bantlarındaki (1. kip 1–20Hz, 2. kip 1–10Hz ve 3. kip 1–5 Hz) her bir frekansa ait genlik değerleri vektörize edilmiştir. Sonuç olarak 35 frekans x 30 kanal için 1050 elemanlı öznitelik vektörleri elde edilmiştir.

3.4.2.3 Öz Kip Fonksiyonlarından İstatistiksel Moment Öznitelik Çıkarılması

Her bir EEG dilimi için elde edilen öz kip fonksiyonlarından zaman alanında yanıtın önce 0.3sn ile yanıtın sonra 0.5sn ($[-0.3 - 0.5\text{sn}]$) arasında 3 merkezi moment (2, 3 ve 4. momentler) ile dağılım çarpıklığı (skewness) ve savrukluk (kurtosis) değerleri hesaplanmıştır. Sonuç olarak 5 moment x 3 ÖKF x 30 kanal için 450 elemanlı öznitelik vektörleri elde edilmiştir.

3.4.2.4 Dalgacık Dönüşümü

Zemin hattı düzeltmesi ve bant geçiren filtreleme uygulanmış EEG dilimlerine 6 döngülü Morlet dalgacık dönüşümü uygulanmış ve verinin $[-0.5 - 1\text{sn}]$, 1–20Hz arasında zaman frekans temsili elde edilmiştir. Elde edilen zaman frekans verisi yanıtın önce 0.3sn ve yanıtın sonra 0.5sn ($[-0.3 - 0.5\text{sn}]$) arası bir pencerede zaman alanında ortalaması alınmış ve böylece veri zamanda tek bir değere indirgenmiştir. Sonuç olarak 20 frekans x 30 kanal için 600 elemanlı öznitelik vektörleri elde edilmiştir.

3.5 SINIFLANDIRMA

3.5.1 Algoritma Seçimi

Sınıflandırma işlemleri MATLAB ortamında gerçekleştirilmiştir. MATLAB makine öğrenmesi araç kutusu altında sunulan aşağıda verilmiş olan algoritmalar, en iyi modelin bulunması amacı ile var sayılan üst değişken (hyperparamater) değerleri ile kullanılmıştır. Bu algoritma arama aşamasında yanıtla kilitli veri kümesi kullanılmış ve veri seti dengelenmesi amacıyla örnek azaltma yönteminden faydalanılmıştır.

Veri azaltma yönteminin seçilmiş olmasının sebebi çok sayıda algoritmanın bir arada denenmesine imkân sağlayan aracın, çapraz doğrulama esnasında veri dengeleme işlemi yapılmasına izin vermemesidir. Eğer veriye çapraz doğrulama uygulamadan önce örnek artırma uygulanır ve bu veri seti üzerinden sınıflandırma yapılırsa, test setine eğitim seti içinden veri sızması olacaktır. Bu halde yanlış bir şekilde yüksek sınıflandırma başarımı elde etmek mümkündür. Yapılan bir denemede elde edilen veri setinde bu şekilde %87'ye yakın sınıflandırma “doğruluk” değerleri gözlemlenmiştir.

Yanıta kilitli örnek azaltılmış veriye öznitelik çıkarma bölümünde açıklanmış olan yöntemler uygulanmış ve elde edilen öznitelik veri kümesi aşağıda verilen algoritmalar kullanılarak

sınıflandırılmıştır. Bu sınıflandırma işlemi sonucunda en yüksek başarıyı veren Gauss Destek Vektör Makine algoritmasının kullanılmasına karar verilmiştir.

- Gauss Destek Vektör Makinesi
- Karese Destek Vektör Makinesi
- K-NN
- Karar Verme Ağacı
- Rastgele Orman
- Lojistik Bağlanım (Bu algoritma sadece iki sınıflı durumların sınıflandırılmasında denenmiştir).

3.5.2 10-kat Çapraz-Doğrulama

Sınıflandırma başarımının doğru kestirimi için 10 Kat Çapraz-Doğrulama yöntemi kullanılmıştır. Bu yöntemde veri seti rastgele bir şekilde 10 farklı parçaya ayrılıp 10 kere eğitime tabi tutulmuş, her seferinde farklı bir parça test kümesine geri kalan parçalar ise eğitim kümesine atanıp bu şekilde eğitim yapılmıştır. Sonuç olarak her bir test kümesi için elde edilen başarımlar bir araya getirilerek toplam başarımlar hesaplanmıştır.

Her 10 eğitim adımında dikkat edilmesi gereken en önemli nokta eğitim kümesi ile test kümesi arasında bilgi sızıntısı olmamasıdır. Bu nedenle normalizasyon ve veri dengeleme işlemleri veri kümesi parçalara ayrıldıktan sonra her bir parçaya ayrı ayrı uygulanmıştır.

3.5.3 Normalizasyon

Elde edilen öznitelik vektörlerinin öznitelik uzayındaki temsilinin olabildiğince simetrik olması, öğrenme algoritmalarının başarımını etkileyebildiğinden, eğitime işlemi öncesinde bütün katılımcılar için koşullara (Doğru Emin, Yanlış Emin ve Emin Değil) bağlı tüm denemelerin (trial) bir araya getirilmesiyle oluşan veride her bir öznitelik için ortalama değeri sıfıra, standart sapmayı bir e eşitleyen z-skoru yöntemi kullanılarak ortalama ve standart sapma normalizasyonu yapılmıştır.

Test kümesi özniteliklerinin normalizasyonu için eğitim setinden her bir öznitelik için elde edilen ortalama ve standart sapma değerleri kullanılmıştır.

3.5.4 Veri Seti Dengeleme

Farklı durumlar için elde edilen EEG gözlem sayısı eşit değildir, bu durum öğrenme aşamasında yüksek gözlem sayısına sahip sınıflara artı yönde bir yanlılık şeklinde yansımaktadır. Bu sorunu aşmak ve sınıflandırma başarımının doğru kestirimi adına sık kullanılan örnek artırma ve örnek azaltma yöntemlerinden bu tezde faydalanılmıştır.

3.5.4.1 Örnek artırma

Az elemana sahip olan sınıf verisinden rastgele örnekler seçilip tekrar edilerek yüksek elemana sahip sınıfın veri sayısına ulaşmayı hedefler. Elimizdeki EEG kümesinde örnek artırma işlemi öncesi veri sayıları yukarıda verilmişti, örnek artırma sonrası elde edilen veri sayıları ise şu şekildedir.

Uyarana Kilitli Durumda

DE-YE: Her iki sınıftan 709 adet gözlem, toplam 1418

DE-ED: Her iki sınıftan 709 adet gözlem, toplam 1418

YE-ED: Her iki sınıftan 470 adet gözlem, toplam 940

DE-YE-ED: Her üç sınıftan 709, toplam 2127 adet gözlem

Yanıta Kilitli Durumda

DE-YE: Her iki sınıftan 731 adet gözlem, toplam 1462

DE-ED: Her iki sınıftan 731 adet gözlem, toplam 1462

YE-ED: Her iki sınıftan 485 adet gözlem, toplam 970

DE-YE-ED: Her üç sınıftan 731, toplam 2193 adet gözlem

3.5.4.2 Örnek azaltma

Daha çok elemana sahip olan sınıf veri adedini az elemana sahip sınıf veri adedine eşitlemeyi hedefler, bunu büyük sınıf içinden az elemana sahip sınıf eleman adedi kadar elemanı rastgele

seçerek yapar. Elimizdeki EEG kümesinde örnek azaltma işlemi öncesi veri sayıları yukarıda verilmişti, örnek azaltma sonrası elde edilen veri sayıları ise şu şekildedir.

Uyarana Kilitli Durumda

DE-YE: Her iki sınıftan 470 adet gözlem, toplam 940

DE-ED: Her iki sınıftan 289 adet gözlem, toplam 578

YE-ED: Her iki sınıftan 289 adet gözlem, toplam 578

DE-YE-ED: Her üç sınıftan 289, toplam 867 adet gözlem

Yanıta Kilitli Durumda

DE-YE: Her iki sınıftan 485 adet gözlem, toplam 570

DE-ED: Her iki sınıftan 256 adet gözlem, toplam 512

YE-ED: Her iki sınıftan 256 adet gözlem, toplam 512

DE-YE-ED: Her üç sınıftan 256, toplam 768 adet gözlem

4. BULGULAR

4.1 SINIFLANDIRMA ALGORİTMASININ SEÇİLMESİ

Sınıflandırma için kullanılacak algoritmanın tespitinde öncelikle ampirik bir yol izlenmiş olup veri seti 2 sınıflı ve 3 sınıflı durumlar için aşağıda verilen yöntemler, varsayılan üst değişken (hyper parameters) değerleri kullanılarak sınıflandırıldı. Bu adımın amacı model seçiminde en uygun algoritmanın tespit edilmesiydi. Bu aşamada elde edilen sınıflandırma doğruluk değerleri Tablo 4.1’de verilmiştir.

Tablo 4.1: DE, YE ve ED sınıfı verilerinin 6 farklı sınıflandırma algoritması ile sınıflandırılması.

	Karar Verme Ağacı	Gauss DVM	Karesel DVM	KNN	Rastgele Orman	Lojistik Bağlanım
DE-YE-ED	44	52.1	50.9	48.4	46.5	-
DE-YE	61	72.4	69	67.2	68.6	57.9
DE-ED	64.5	74	71.7	70.9	70.1	52.5
YE-ED	59.4	64.6	62.9	64.5	61.3	51.4

Yukarıda verilmiş olan sınıflandırma sonuçları, yanıtla kilitli veride dalgacık dönüşümü ve veri dengeleme için veri azaltma yöntemi kullanılarak elde edilmiştir. Tablodan da görüleceği üzere, Gauss DVM algoritması tutarlı bir biçimde eldeki verinin sınıflandırılmasında karşılaştırılan yöntemlerin tamamından daha başarılıdır. Tezin geri kalanında bu tablo referans alınarak Gauss DVM’sinden faydalanılmıştır. Sonuçlar tekli deneme verisi sonuçlarını yansıtmaktadır.

4.2 EEG VERİLERİNİN GAUSS DVM KULLANILARAK SINIFLANDIRILMASI

Elimizde uyarana kilitli ve yanıtla kilitli olmak üzere temelde iki veri seti bulunmaktadır. Bu veri setleri ayrı ayrı işlenmiş fakat verilerin işlenmesinde ve özneliklerin çıkarılmasında bazı küçük farklılıklar olmakla birlikte aynı sinyal işleme ve öznelik çıkarma yöntemlerinden faydalanılmıştır. Sırası ile uyarana kilitli ve yanıtla kilitli EEG dilimlerinin sınıflandırma sonuçları aşağıdaki gibidir.

4.2.1 Uyarana Kilitli EEG Dilimlerinin Sınıflandırılması

Görgül kip ayrışımı (GKA) ve dalgacık dönüşümü (DD) temelli dört farklı öznitelik çıkarma yöntemi ile elde edilen tekli deneme sınıflandırma sonuçları aşağıdaki gibidir.

Tablo 4.2: GKA ve DD temelli öznitelikler için % cinsinden sınıflandırma başarımı.

		GKA + zaman alanı öznitelikleri	GKA + frekans alanı öznitelikleri	GKA + istatistiksel momentler	Dalgacık dönüşümü
Örnek Artırılmış	DE-YE-ED	39.06	46.59	48.00	53.69
	DE-YE	58.39	66.71	64.10	70.38
	YE-ED	55.31	60.43	58.51	60.96
	DE-ED	56.27	68.19	69.39	70.01
Örnek Azaltılmış	DE-YE-ED	38.75	47.64	46.83	52.10
	DE-YE	55.74	65.31	64.36	68.4
	YE-ED	56.57	60.20	58.82	61.94
	DE-ED	56.57	65.57	67.13	69.38

Tablodan görüleceği üzere en yüksek sınıflandırma başarımı Dalgacık Dönüşümü yöntemi ile elde edilen zaman frekans temelli öznitelikler ile elde edilmiştir. Sınıflandırma sonuçları 10 katlı çapraz doğrulama ile elde edilen değerleri yansıtmaktadır. Tabloda dört farklı sınıflandırma kombinasyonu görülmektedir. İlk satır üç sınıfın bir arada değerlendirildiği durumu yansıtmaktadır. Uyarana kilitli EEG dilimlerinin Doğru Emin, Yanlış Emin ve Emin Değil sınıfları için ayrılmasında en yüksek başarımlar %49,65 ile dalgacık dönüşümü temelli özniteliklerden elde edilmiştir. Bu değer şans eseri elde edilecek olan %33'lük değerden anlamlı derecede farklıdır. Üç sınıflı durumda en düşük başarımlar, zaman alanı Öz Kip Fonksiyonlarından çıkarılan öznitelikler ile elde edilen %39,06'dır. Üç sınıflı durumdan sonra her durumun bir diğer durum ile karşılaştırıldığı iki sınıflı kombinasyonların ayrılmasına geçilmiştir.

Doğru Emin ile Yanlış Emin durumlarının birbirinden ayrılmasında en yüksek başarımlar %70,38 ile dalga dönüşümü sonrasında elde edilmiştir. Bu başarımlar iki sınıflı durum için geçerli %50 rastgele seçim değerinden anlamlı derecede farklıdır. Üç sınıflı durumda olduğu gibi en düşük başarımlar %58,39 ile zaman alanı Öz Kip Fonksiyon verisine aittir.

Yanlış Emin ve Emin Değil durumlarının birbirinden ayrılması söz konusu olduğunda en yüksek başarımlar %60,96 ile dalgacık dönüşümüne aittir. YE ve ED durumları için sınıflandırma başarımları her ne kadar %50'den önemli oranda yüksek ise de iki sınıflı durumda en kötü ayırma performansı bu sınıflarda elde edilmiştir. YE-ED sınıflandırmasında en düşük başarımlar %55,31 ile zaman alanı Öz Kip Fonksiyonu verisine aittir.

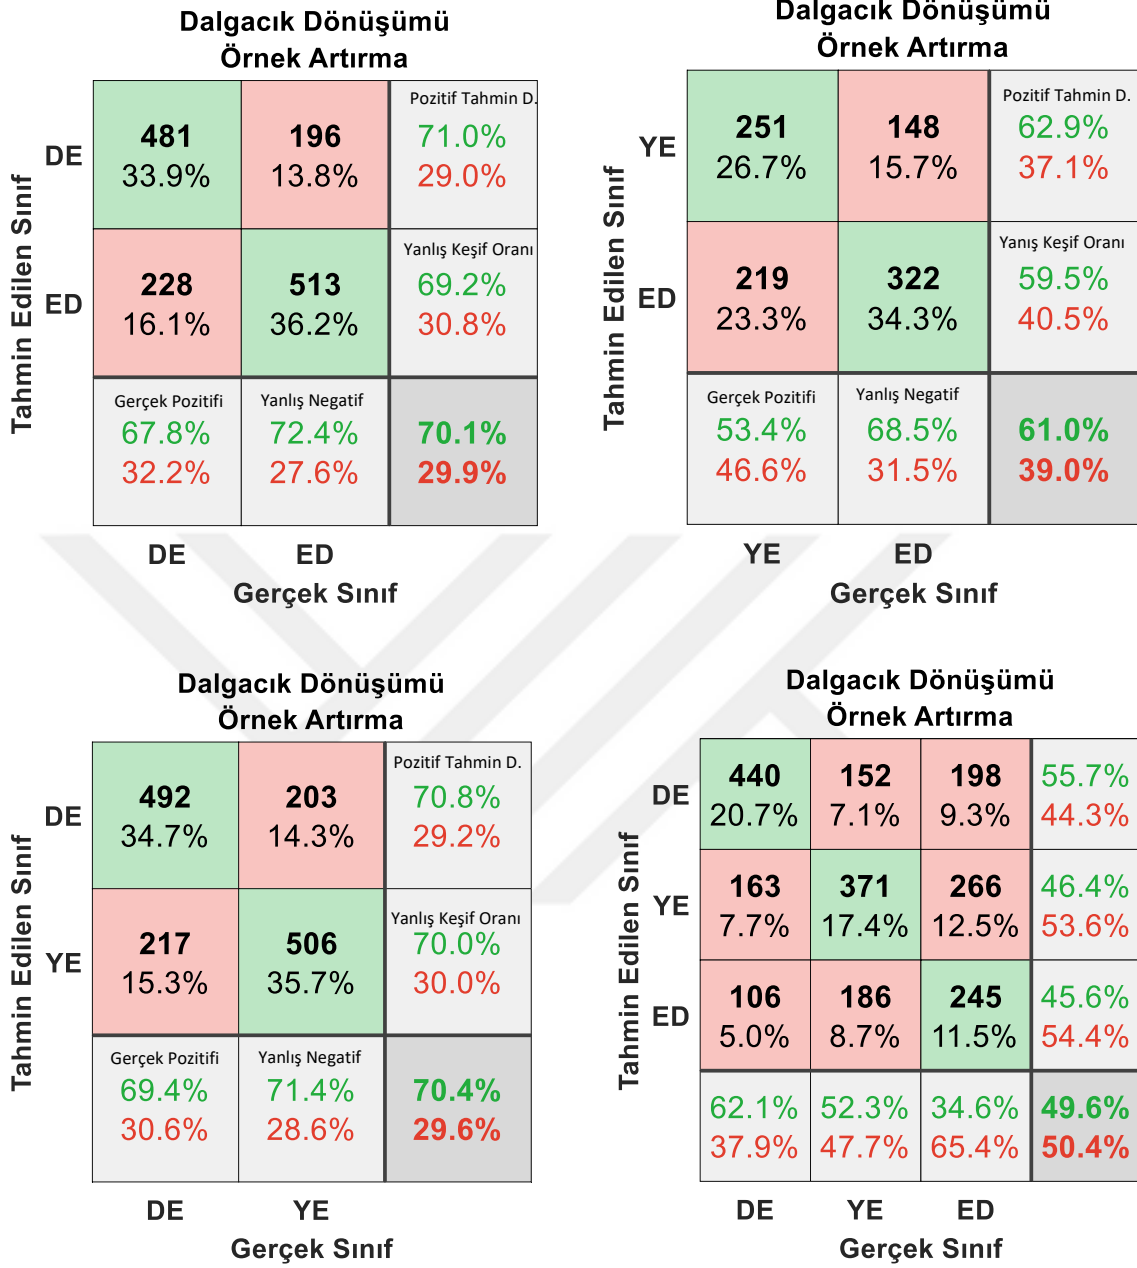
Doğru Emin ile Emin Değil durumlarının ayrılmasında en yüksek başarımlar %70,01 ile dalgacık dönüşümü yöntemi ile elde edilirken en düşük başarımlar %56,27 ile zaman alanı GKA ile elde edilmiştir. Frekans alanı GKA ve GKA istatistiksel moment yöntemleri orta bir başarımlar elde etmiş ve birbirlerine yakın sonuçlar vermiştir.

Sınıflandırma modelinin eğitiminin sağlıklı yapılabilmesi için durumlara ait veri sayıları örnek azaltma ve örnek artırma yöntemleri ile dengelenmiştir. Tablodan görüleceği üzere, iki uygulama için elde edilen sonuçlar birbirine oldukça yakındır.

Şekil 4.1'deki sınıflandırma matrislerinde, satırlar tahmin edilen sınıfa ve sütunlar gerçek sınıfa karşılık gelir. Diyagonal hücreler, doğru şekilde sınıflandırılmış gözlemlere diyagonal olmayan hücreler ise yanlış sınıflandırılmış gözlemlere karşılık gelir. Her bir hücrede hem gözlem sayısı ve hem de toplam gözlem sayısına göre yüzdesi gösterilir.

Grafiğin en sağındaki sütun, doğru ve yanlış sınıflandırılmış her bir sınıfa ait olduğu tahmin edilen tüm örneklerin yüzdesini gösterir. Bu ölçümlere sırasıyla pozitif tahmin değeri ve yanlış keşif oranı denir. Grafiğin altındaki satır, her sınıfa ait tüm örneklerin yüzdesini doğru ve yanlış sınıflandırılmış olarak gösterir. Bu ölçümler sırasıyla gerçek pozitif oranı ve yanlış negatif oran olarak adlandırılır. Grafiğin sağ alt köşesindeki hücre genel doğruluğu gösterir.

Sınıflandırma sonuçlarının daha detaylı incelenmesi amacı ile en yüksek başarımlar veren yöntem olan, örnek artırılmış uyarana kilitli veride dalgacık dönüşümü sonrası sınıflandırma sonuçları sınıflandırma matrisine (confusion matrix) aktarılmıştır.



Şekil 4.1: Uyarana kilitli durumda DD sınıflandırma başarımının sınıflandırma matrisinde gösterimi.

DE-ED durumunda sınıf dağılımı dengelenmiş toplam 1418 gözlemde %33,9'u DE %36,2'si ise ED olarak doğru sınıflandırılmış, DE için doğru pozitif oranı %67,8 iken bu değer ED için %72,4 gözlemlenmiştir. Yanlış sınıflandırılan örnekler iki sınıf arasında dengeli dağılmıştır.

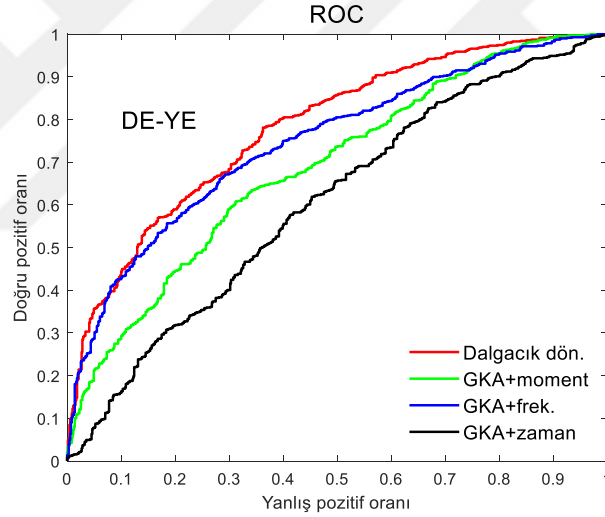
YE-ED karşılaştırmasında, toplam gözlem adedi 940, genel sınıflandırma başarımı %61,0 ve YE için doğru pozitif oranı %53,4'dür. Bu veriler ışığında YE-ED başarımının DE-ED'ye

kıyasla daha düşük olmasının, YE için yanlış negatif oranının görece yüksekliğinden kaynaklandığı sonucu çıkarılabilir.

DE-YE sınıflandırması en yüksek başarımının elde edildiği kombinasyondur ve toplam veri sayısı 1418'dir. Yanlış sınıflandırılan gözlem sayısı iki sınıf arasında görece eşit dağılmıştır.

DE-YE-ED sınıflandırmasında en yüksek hata katkısını gerçek sınıf ED olduğu halde YE olarak tahmin edilmiş olan 266 adet gözlem vermektedir. Örnek artırımı sonrası toplam gözlem sayısı 2127'dir.

Elde edilen sınıflandırıcıların farklı eşik değerlerine kullanıldığında iki sınıflı durumlarda Doğru Pozitif ve Yanlış Pozitif bulgularının nasıl değiştiğini gösteren alıcı işletim karakteristiği (ROC) eğrilerinin, dört farklı öznitelik çıkarma yöntemi çizimi aşağıda görülebilir.

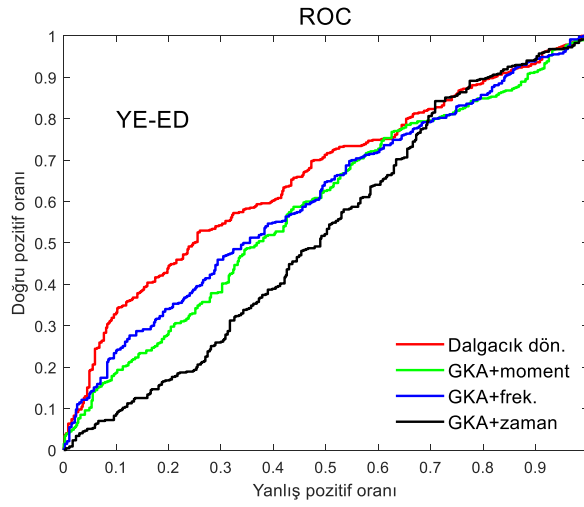


Şekil 4.2: DE-YE sınıflandırıcısı için alıcı işletim karakteristiği eğrileri.

Şekil 4.2'de DE-YE sınıfları için elde edilen uyarana kilitli EEG verilerinin dört farklı öznitelik çıkarma yöntemi sonrasında, eğitim sonucu elde edilen sınıflandırıcıların ROC eğrileri verilmiştir. Eğri altında kalan alan değerleri Tablo 4.3'de verilmiştir.

Tablo 4.3: DE-YE eğri altında kalan alan (AUC) değerleri.

Dalgacık dönüşümü	GKA moment	GKA frekans	GKA zaman
0.7807	0.6884	0.7470	0.6044




Şekil 4.3: YE-ED sınıflandırıcısı için alıcı işletim karakteristiği eğrileri.

Şekil 4.3’de YE-ED sınıfları için elde edilen ROC eğrileri görülmektedir. Eğri altında kalan alan değerleri Tablo 4.4’de verilmiştir.

Tablo 4.4: YE-ED durumu için AUC değerleri.

Dalgacık dönüşümü	GKA moment	GKA frekans	GKA zaman
0.6565	0.5844	0.6038	0.5234



Şekil 4.4: DE-ED sınıflandırıcısı için alıcı işletim karakteristiği (ROC) eğrileri.

Şekil 4.4’de DE-ED sınıfları için, ROC eğrileri verilmiştir. Eğri altında kalan alan değerleri Tablo 4.5’de görülebilir.

Tablo 4.5: DE-ED durumu için AUC değerleri.

Dalgacık dönüşümü	GKA moment	GKA frekans	GKA zaman
0.7687	0.7428	0.7236	0.5577

4.2.2 Yanıta Kilitli EEG Dilimlerinin Sınıflandırılması

Yanıta kilitli EEG dilimlerinin Görgül Kip Ayırışımı ve dalgacık dönüşümü temelli öznitelikler ile sınıflandırılması sonucu elde edilen sınıflandırma başarımları aşağıdaki gibidir.

Tablo 4.6: Yanıta kilitli dilimlerde % cinsinden sınıflandırma başarımları.

		GKA + zaman alanı öznitelikleri	GKA + frekans alanı öznitelikleri	GKA + istatistiksel momentler	Dalgacık dönüşümü
Örnek Artırılmış	DE-YE-ED	40.95	48.97	51.89	54.17
	DE-YE	60.19	68.88	69.42	75.44
	YE-ED	51.24	63.09	65.46	63.92
	DE-ED	58.28	68.47	66.89	71.81
Örnek Azaltılmış	DE-YE-ED	38.80	49.61	52.08	54.68
	DE-YE	59.38	68.55	68.24	73.40
	YE-ED	56.64	65.43	62.69	64.25
	DE-ED	61.52	72.07	66.60	71.48

Yanıta kilitli EEG dilimlerinden elde edilen sınıflandırma başarımlarında ilk göze çarpan, sınıflandırma başarımları değerlerinin uyarana kilitli EEG verisine kıyasla 3-5 puan daha yüksek olduğudur. Dört farklı sınıflandırma kombinasyonu için 10 katlı çapraz doğrulama sonucunda elde edilen değerler incelendiğinde, örnek artırılmış veride;

DE-YE-ED durumunda en yüksek başarımlar %54,17 ile dalgacık dönüşümüne aittir. Bu değer rastgele bir veriden elde edilecek %33'lük değerden oldukça üzerindedir. Bu sınıflandırma kombinasyonunda en düşük başarımlar uyarana kilitli durumda da olduğu gibi, zaman alanı GKA yöntemine aittir ve elde edilen sınıflandırma doğruluğu değeri %40,95'dir.

DE-YE durumları sınıflandırıldığında, en yüksek başarımların %75,44 ile dalgacık dönüşümüne ait olduğu görülmektedir, bu değer %50'lik rastgele seçim değerinin oldukça üzerindedir. GKA

frekans ve moment yöntemleri yaklaşık %69 ile ikinci sırada ve zaman alanı GKA yöntemi %60,19'luk başarımla son sıradadır.

YE-ED sınıflarında en yüksek başarımla %65,46 ile GKA momentleri yöntemine aittir, onu sırasıyla dalgacık dönüşümü, GKA frekans ve GKA zaman alanı yöntemi takip etmektedir.

DE-ED sınıfları %71,81 ile en iyi dalgacık dönüşümü öznelikleri ile ayrılmaktadır, ikinci sırada %68,47 ile GKA frekans ve son sırada %58,28 ile GKA zaman alanı vardır.

Aynı işlemler örnek azaltılma yöntemi ile dengelenmiş veride tekrar edildiğinde, örnek artırma yöntemi ile karşılaştırılabilir sonuçlar elde edilmekle birlikte, YE-ED ve DE-ED sınıflandırmalarında en yüksek değerleri GKA frekans yöntemi vermiştir. Dalgacık dönüşümü yöntemi sonuçları da bu değerlere oldukça yakındır.

Elde edilen sınıflandırma sonuçları en yüksek başarımla veren dalgacık dönüşümü için sınıflandırma matrisine aktarılmıştır. Dalgacık dönüşümü ile dört farklı sınıflandırma kombinasyonu için elde edilen matrisler aşağıdaki gibidir;

		Dalgacık Dönüşümü Örnek Artırma					Dalgacık Dönüşümü Örnek Artırma		
Tahmin Edilen Sınıf	DE	617 42.2%	298 20.4%	67.4% 32.6%	Tahmin Edilen Sınıf	YE	345 35.6%	210 21.6%	62.2% 37.8%
	ED	114 7.8%	433 29.6%	79.2% 20.8%		ED	140 14.4%	275 28.4%	66.3% 33.7%
		84.4% 15.6%	59.2% 40.8%	71.8% 28.2%			71.1% 28.9%	56.7% 43.3%	63.9% 36.1%
		DE	ED				YE	ED	
		Gerçek Sınıf					Gerçek Sınıf		

Şekil 4.5: Yanıta kilitli durumda DD sınıflandırma başarımının sınıflandırma matrisinde gösterimi.

		Dalgacık Dönüşümü Örnek Artırma			Dalgacık Dönüşümü Örnek Artırma			
Tahmin Edilen Sınıf	DE	576 39.4%	204 14.0%	73.8% 26.2%	474 21.6%	151 6.9%	166 7.6%	59.9% 40.1%
	YE	155 10.6%	527 36.0%	77.3% 22.7%	161 7.3%	411 18.7%	262 11.9%	49.3% 50.7%
		78.8% 21.2%	72.1% 27.9%	75.4% 24.6%	96 4.4%	169 7.7%	303 13.8%	53.3% 46.7%
		DE	YE		DE	YE	ED	
		Gerçek Sınıf			Gerçek Sınıf			

Şekil 4.6: Yanıta kilitli durumda DD sınıflandırma başarımının sınıflandırma matrisinde gösterimi.

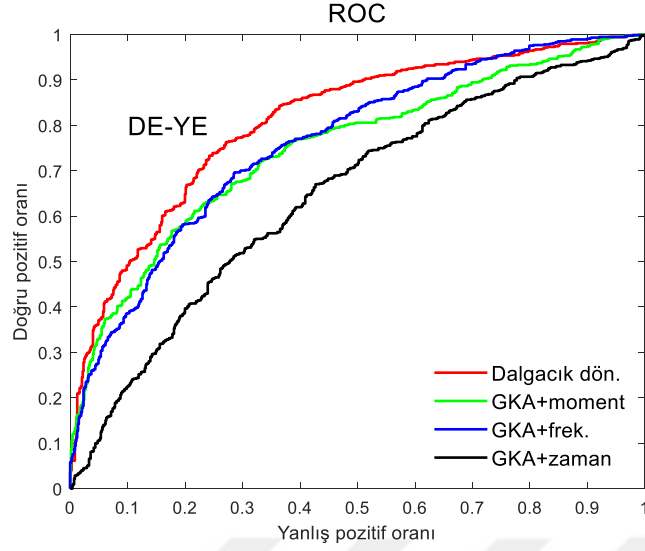
Örnek artırılmış veride dalgacık dönüşümü sonrasında sınıflandırma matrisi incelendiğinde DE-ED durumunda sınıf dağılımı dengelenmiş toplam 1462 gözlemde %42,2'si DE, %29,6'sı ise ED olarak doğru sınıflandığı görülmektedir. DE için doğru pozitif oranı %84,4 iken bu değer ED için %59,2'dir.

YE-ED karşılaştırmasında, toplam gözlem adedi 970, genel sınıflandırma başarımı %63,9 ve YE için doğru pozitif oranı %71,1'dir. Bu veriler ışığında YE-ED başarımının DE-ED'ye kıyasla daha düşük olmasının ED yanlış negatif oranının görece yüksekliğinden kaynaklandığı sonucu çıkarılabilir.

DE-YE sınıflandırması, çalışmanın genel olarak en yüksek başarımının elde edildiği kombinasyonu olup, toplam veri sayısı 1462'dir ve yanlış sınıflandırılan gözlem sayısının görece eşit dağıldığı görülmektedir.

DE-YE-ED sınıflandırmasında en yüksek hata katkısını, ED olduğu halde YE olarak sınıflandırılmış olan 262 adet gözlem vermektedir. Toplam gözlem sayısı 2193'dür.

Dört farklı öznitelik çıkarma yöntemi için eğitim sonrasında elde edilen sınıflandırıcıların ROC eğrileri aşağıdaki gibidir.




Şekil 4.7: 4 öznelik için DE-YE ROC eğrileri.

Şekil 4.7’de DE-YE sınıfları için elde edilen yanıtla kilitli EEG verilerinin dört farklı öznelik çıkarma yöntemi sonrasında sınıflandırılması sonucu elde edilen sınıflandırıcıların ROC eğrileri verilmiştir. Dalgacık dönüşümü yöntemi devamında elde edilen sınıflandırıcı ROC eğrisi, sınıflandırma başarımı sonuçlarından da anlaşılacağı üzere en başarılı sınıflandırıcıyı işaret etmektedir. Eğri altında kalan alan değerleri aşağıdaki gibidir.

Tablo 4.7: DE-YE AUC değerleri.

Dalgacık dönüşümü	GKA moment	GKA frekans	GKA zaman
0.8095	0.7498	0.7624	0.6466


Şekil 4.7’de YE-ED sınıflarında, yanıtla kilitli EEG verilerinin dört farklı öznelik çıkarma yöntemi için ROC eğrileri verilmiştir. Tablo 4.7’de eğri altında kalan alan değerleri verilmiştir.



Şekil 4.8: 4 öznelik için YE-ED ROC eğrileri.

Tablo 4.8: YE-ED AUC değerleri.

Dalgacık dönüşümü	GKA moment	GKA frekans	GKA zaman
0.6764	0.6660	0.6627	0.5144



Şekil 4.9: DE-ED ROC eğrileri.

Şekil 4.8'de DE-ED sınıfları için, ROC eğrileri verilmiştir. Eğri altında kalan alanlar değerleri Tablo 4.8'de görülmektedir.

Tablo 4.9: DE-ED için AUC değerleri.

Dalgacık dönüşümü	GKA moment	GKA frekans	GKA zaman
0.7880	0.7274	0.7662	0.6247

4.3 ÜST-DEĞİŞKEN ENİYİLEMESİ

Üst-değişken eniyilemenin (hyperparameter optimization) amacı doğrultusunda, Gauss Vektör Destek Makinesi üst değişkenlerinin ince ayarının yapılması sağlandı. Bu aşamada arama uzayı 2 boyutlu olup, MATLAB ortamında gerçekleştirilen Gauss VDM (fitcsvm) algoritması, üst-değişken olarak çekirdek boyutu (kernel size) ve kutu kısıtı (box constraint) kullanılmaktadır. En iyi parametrelerin bulunmasında arama uzayının görece sınırlı olmasından dolayı ızgara üzerinde arama (grid search) yönteminden faydalanılmıştır.

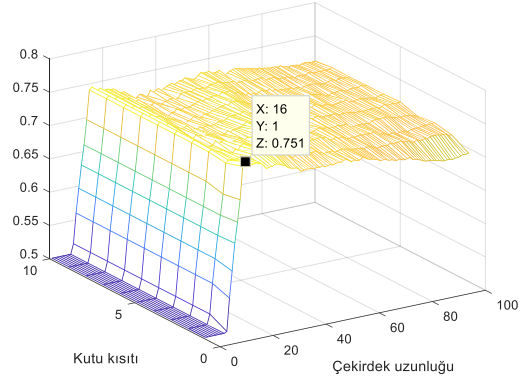
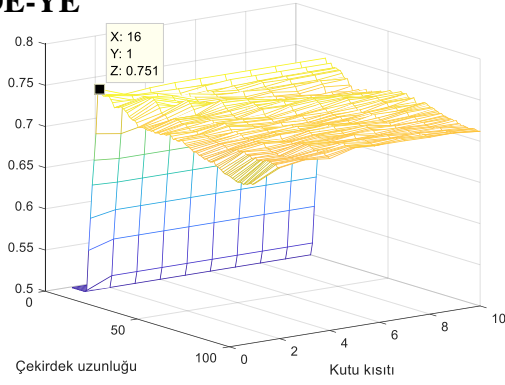
Çekirdek boyutu 1-100 arasında ve kutu kısıtı ise 1-10 değerleri arasında olacak şekilde belirlendikten sonra Gauss Destek Vektör Makinesi ile 10 katlı çapraz doğrulama yöntemi kullanılarak toplam 1000 üst değişken kombinasyonu için arama yapılmıştır. Bu aramada eniyileme kriteri olarak sınıflandırma başarımı kullanıldı. Şekil 4.10-13’de dalgacık dönüşümü öznelikleri ile yanıtla kilitli EEG verisinden elde edilen üst-değişken yüzeyleri ve bu yüzeyleri maksimum yapan çekirdek boyutu ve kutu kısıtı parametreleri görülmektedir.

Üst değişken eniyilemesi sonucu en yüksek sınıflandırma başarımını sunan parametre setleri aşağıdaki gibidir

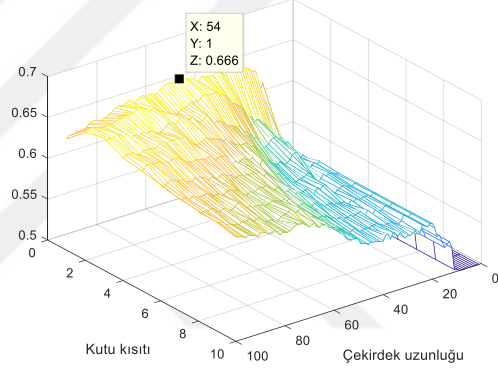
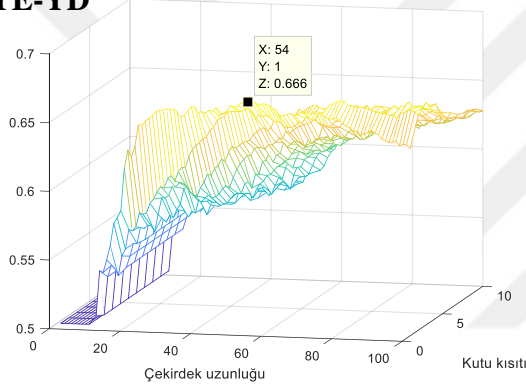
Tablo 4.10: Üst değişken eniyilemesi sonucunda elde edilen üst değişken değerleri.

	Çekirdek Boyutu (Kernel Size)	Kutu Kısıtı (Box Constraint)
DE-YE	16	1
YE-ED	54	1
DE-ED	45	1
DE-YE-ED	41	1


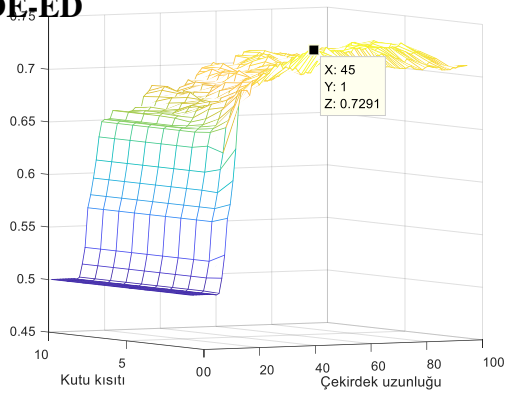
ızgara üzerinde arama yöntemi sonucunda elde edilen sınıflandırma başarımı yüzeyleri aşağıdaki gibidir.

DE-YE


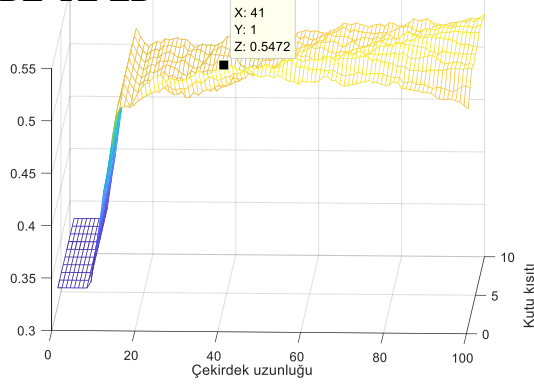
Şekil 4.10: DE-YE için üst değişken parametrelerine göre sınıflandırma başarıyı yüzeyi.

YE-YD

Şekil 4.11: YE-ED için üst değişken parametrelerine göre sınıflandırma başarıyı yüzeyi.

DE-ED

Şekil 4.12: DE-ED için üst değişken parametrelerine göre sınıflandırma başarıyı yüzeyi.

DE-YE-ED

Şekil 4.13: DE-YE-ED için üst değişken parametrelerine göre sınıflandırma başarıyı yüzeyi.



5. TARTIŞMA VE SONUÇ

Bu tez çalışmasında karar verme süreçleri ile ilgili kişinin verdiği kararın doğruluğundan emin olduğu durum, yanlış yaptığından emin olduğu durum ve kararından emin olmadığı durum olmak üzere 3 farklı durumun birbiri ile ilişkisi ve tekli deneme seviyesinde bu durumlara karşı oluşan beyin potansiyellerinin birbirinden ne derece ayrılabilirdiği incelenmiştir. Bu inceleme için EEG kullanılarak 3 durumun birbirinden ayrılmasını sağlamak adına çeşitli öznitelik çıkarma yöntemlerinden faydalanılmıştır. Bu öznitelik yöntemleri ile hedeflenen, EEG sinyalindeki OİP ve OİS sinyallerinin, gürültü ve arka plan EEG aktivitesinden arındırılarak etkilerinin ortaya çıkarılması ve farklı deneysel koşullarla değişen bu aktivite parametrelerinin tespit edilerek çok boyutlu bir öznitelik uzayında birbirinden ayrılması idi. Bu amaçla dört öznitelik çıkarma yöntemi belirledik, öncelikle sinyal gürültü oranının artırılmasına yönelik olarak kullanılan bir ayırıştırma yöntemi olan ve son zamanlarda literatürde kendine çokça yer bulmuş olan GKA yönteminden faydalandık. Bu yöntem doğrusal olmayan ve durağan olmayan sinyalleri ayırştırmak için kullanıldığından EEG sinyalleri için özellikle uygun görünmektedir. Yaptığımız deneylerde GKA ile EEG sinyalleri 3 ayrı kipe ayırştırıldı ve sonrasında hem OİP hem de OİS sinyal bileşenlerini hedefleyerek zaman alanı ve frekans alanında öznitelikler çıkarıldı.

Zaman alanında çıkarılan öznitelikler için literatürde rapor edilmiş zaman aralıklarından faydalandık, uyarana ve yanıtı kilitli olarak çıkarılan bu zaman bölgelerindeki ortalama genlik değerleri farklı ÖKF ve kanallar için vektörize edilerek sınıflandırıldı. Elde edilen sonuçlar rastgele seçime göre daha başarılı olsalar da diğer öznitelik çıkarma yöntemleri ile elde edilen başarımın gerisinde kalmışlardır. Bu sonuçlar değerlendirildiğinde, her ne kadar GKA gibi bir ayırıştırma yöntemi kullanılmışsa da zaman alanında tek denemeli veri kümesinde gerekli sinyal gürültü oranına ulaşmanın mümkün olmadığı görülmüştür.

Bir diğer öznitelik elde etme yöntemi olarak, GKA ile ayırştırılan veriye Fourier dönüşümü uygulandıktan sonra baskın frekans bantları tespit edildi, bu bantlar 3 farklı ÖKF için 1-20Hz, 1-10Hz ve 1-5Hz idi. Bu frekanslardaki verinin vektörize edilmesi ve sınıflandırılması ile elde edilen sonuçlar incelendiğinde, zaman alanında yapılan analizden elde edilen sonuçlara kıyasla çok daha yüksek olduğu görülmektedir. Örneğin Doğru Emin ile Yanlış Emin durumlarının yanıtı kilitli veride sınıflandırılması sonucunda frekans temelli öznitelikler

yaklaşık %69 doğruluğa ulaşırken, zaman alanı temelli öznitelikler yaklaşık %60'da kalmıştır. Buradan yola çıkarak tek denemeli EEG verisinin frekans alanında işlenmesinin çok daha başarılı olduğu ve tekli deneme BBA sistemleri için olaya ilişkin salınımların daha iyi bir seçenek olduğu yorumu yapılabilir.

Üçüncü öznitelik çıkarma yöntemi olarak kullanılan GKA + istatistiksel momentlerin bulunması ve bu momentler üzerinden yapılan sınıflandırmada, GKA + frekans verisi temelli öznitelikler ile benzer sonuçlara ulaşılmıştır. İki uygulama arasındaki fark istatistiksel moment temelli yaklaşımda elde edilen öznitelik vektör boyutu 450 iken frekans temelli yöntemde vektör uzunluğu 1050'dir. Her ne kadar Destek Vektör Makinelerinde kullanılan kutu kısıtı gibi parametreler ile modelin eğitim setine aşırı uyumlanması (overfitting) kontrol edilmeye çalışılsa da frekans temelli yöntemin bu problemden daha çok etkilenmiş olabileceği ihtimal dahilindedir.

Son öznitelik çıkarma yöntemi dalgacık dönüşümüdür ve veriye GKA gibi bir ayrıştırma yöntemi kullanılmaksızın direkt uygulanmıştır. Dalgacık dönüşümü konvansiyonel sinir bilim çalışmalarında da sıklıkla kullanılan bir yöntemdir ve OİS gibi denemeler (trial) arası faz kilidi ilişkisi göstermeyen sinyallerde özellikle tercih edilmektedir [11]. Dalgacık dönüşümü sonrasında tespit edilen zaman-frekans penceresinde verinin zaman alanında ortalaması alınmış ve frekans ve kanal boyutunda veri vektörize edilerek 600 elemanlı öznitelik vektörleri elde edilmiştir. Bu özniteliklerin sınıflandırıcıya verilmesi sonucunda kullanılan dört öznitelik çıkarma yöntemi içerisinde en yüksek sınıflandırma başarımları değerlerine ulaşılmıştır. Özellikle yanıtta kilitli veride DE ve YE durumlarında kaydedilen EEG sinyallerini tek deneme verilerinde %75 civarı bir başarımla ayırılabilmiş olması, zaman frekans temelli özniteliklerin karar verme süreçleri ile ilgili tek deneme seviyesinde kullanım potansiyeline dair umut vermektedir.

Dalgacık dönüşümü ile elde edilen özniteliklerin diğer durum kombinasyonları için de sınıflandırma başarımları rastgele seçimin oldukça üzerindedir. Yanıtta kilitli veride dalgacık dönüşümü ile elde edilen sonuçların sınıflandırma matrisine yerleştirilmesi ile görülmektedir ki yapılan hatalar genel olarak sınıflar arasında simetrik dağılmıştır. Sadece yanlış emin ve emin değil durumlarını birbirinden ayırmakta diğer kombinasyonlara göre görece başarısız kalmıştır. Bu sonuçlar aynı veri seti ile yapılan [11] çalışması ile de uyumlu görünmektedir.

Yanıta kilitli ve uyarana kilitli veri setinde elde edilen sonuçlar karşılaştırıldığında, yanıtla kilitli veri seti ile elde edilen sonuçların tutarlı olarak birkaç puan daha yüksek olduğu görülmektedir. Zaman alanında EEG dilimleri arasında bir ortalama alma işlemi gerçekleştirilmediği ve yanıtın uyarandan ortalama 0.5sn sonra geldiği hesaba katıldığında yanıtla kilitli EEG dilimlerinde hem uyarana ile ilgili algısal ve bilişsel süreçlere ait sinyalin hem de yanıt ile ilintili aktivitenin daha iyi yakalanmış olabileceği spekülasyonunda bulunabilir. Bizim uyguladığımız analizler için bu iki veri seti arasındaki temel fark bir veri setinin diğerine göre yaklaşık 0.5sn ötelenmiş olmasıdır.

Veri seti dengelenmesi için kullanılan örnek artırma ve azaltma yöntemleri ile elde edilen sonuçlar incelendiğinde iki yöntemin birbirine oldukça yakın sonuçlar verdikleri görülmüştür. Kullandığımız veri setinde bir sınıfa ait en küçük veri kümesinde 256 gözlem bulunmaktadır ve bu sayı çok küçük olmadığından bu iki yöntemin benzer sonuçlar vermesi mantıklı görünmektedir. Eğer bir sınıfa ait gözlem sayısı çok küçük olduğu durumlarda örnek artırma ile veri seti dengeleme yönteminden faydalanılabilir.

Bu çalışmada uzamsal filtreleme yöntemlerinin sistematik bir incelemesi yapılmamıştır. Çeşitli denemelerden sonra, bütün kanalların kullanılmasına karar verilmiştir. Her ne kadar bu tercih ile öznelik vektörleri yüksek boyutlara ulaşmışsa da elde edilen 10 kat çapraz doğrulama sonuçları sınıflandırma modelinin eğitim setine aşırı uyumlanması probleminin ciddi bir oranda yaşanmadığını göstermektedir. Gelecekteki çalışmalarda uzamsal filtrelemenin OİP ve OİS temelli kayıtlamalarda da sistematik incelenmesi ile aranan sinyale ait sinyal gürültü oranının artırılması ve sınıflandırma başarımının daha yukarılara çekilmesi olasıdır.

Son olarak, çalışmamın karar verme süreçlerinde farklı zihinsel durumların tekli deneme EEG ölçümleri vasıtası ile birbirinden ayrılması konusunda literatürde var olan boşluğun doldurulmasına ve gelecekte geliştirilecek çözümlere katkı sunmasını dilerim.

KAYNAKLAR

- [1]. Neuper C., Graimann B., Allison B., ve Pfurtscheller G., 2009, Neurofeedback Training for BCI Control, *Brain-Computer Interfaces*, Springer, Berlin, ISBN:978-3-642-02090-2, 65-78.
- [2]. Fellows L. K., 2004, The Cognitive Neuroscience of human decision making: a review and conceptual framework, *Behav cogn neurosci rev*, 3, 159-172.
- [3]. Naqvi N., Shiv B., Bechara A., 2006 The role of emotion in decision making: a cognitive neuroscience perspective, *Current directions in psychological science*, 15(5), 260-264.
- [4]. Graimann B., Allison B., Neuper C., ve Pfurtscheller G., 2009, Neurofeedback Training for BCI Control, *Brain-Computer Interfaces*, Springer, Berlin, ISBN:978-3-642-02090-2, 65-78.
- [5]. Guger C., Holzner C., ve Groenegrass C., 2008, Control of a smart home with braincomputer interface, *Brain Computer Interface*, 2–6.
- [6]. Kaufmann T., Herweg A., ve Kübler A., 2014, Toward brain-computer interface based wheelchair control utilizing tactually-evoked event-related potentials, *Journal of neuroengineering and rehabilitation*, 11(7), 1–17
- [7]. Abdulkader S.N., Atia A., Mostafa M.-S.M., 2015, Brain computer interfacing: applications and challenges, *Egypt. Inform. J.*, 16 (2), 213-230
- [8]. Luck S.J., Woodman G.F., Vogel EK, 2000, Event-related potential studies of attention, *Trends in cognitive sciences*, 4, 432–440.
- [9]. Hagen G.F., Gatherwright J.R., Lopez B.A., Polich J., 2006, P3a from visual stimuli: task difficulty effects. *International journal of psychophysiology* 59, 8–14.
- [10]. Padilla M.L., Wood R.A., Hale L.A., Knight RT, 2006, Lapses in a prefrontal-extrastriate preparatory attention network predict mistakes. *Journal of cognitive neuroscience* 18, 1477–1487
- [11]. Selimbeyoglu A., Keskin-Ergen Y., Demiralp T., 2012, What if you are not sure? Electroencephalographic correlates of subjective confidence level about a decision, *Clin Neurophysiol*, 123, 1158–1167
- [12]. Basar E., Schurmann M., Basar-Eroglu C., Karakas S., 1997, Alpha oscillations in brain functioning: an integrative theory, *Int J Psychophysiol*, 26, 5–29
- [13]. Klimesch W., Schimke H., Schwaiger J., 1994, Episodic and semantic memory: an analysis in the EEG theta and alpha band. *Electroencephalogr clin neurophysiol*, 91, 428–441
- [14]. Nicolas-Alonso L. F., Gomez-Gil J., 2012, Brain computer interfaces A review, *Sensors*, 12, 2, 1211-1279

- [15]. Huang N. E., Shen Z., Long S. R., Wu M. C., Shih H. H., Zheng Q., Ye N. C., Tung C.C., ve Liu H. H., 1998, Hilbert spectrum for nonlinear and non-stationary time series analysis, *The royal society*, 454, 903-995
- [16]. Flandrin P., Rilling G., Gonçalves P., 2004, Empirical Mode Decomposition as a Filter Bank, *IEEE Signal processing letters*, 11(2), 112-114
- [17]. Gandhi T., Panigrahi B.K., Anand S., 2011, A comparative study of wavelet families for EEG signal classification, *Neurocomputing*, 74, 3051–3057
- [18]. Sheskin D.J., 2000, Handbook of Parametric and Nonparametric Statistical Procedures, *Chapman & Hall/CRC*, Florida, ISBN 1-58488-133-X
- [19]. Aggarwal C.C., 2015, Data classification, *CRC Press*, ISBN:978-1-4665-8675-8
- [20]. Müller K.R., Tangermann M., Dornhege G., Krauledat M., Curio G., ve Blankertz B., 2008, Machine learning for real-time single-trial EEG-analysis: From brain-computer interfacing to mental state monitoring, *Journal of Neuroscience Methods*, 167(1), 82–90
- [21]. Burges C. J. C., 1998, A Tutorial on Support Vector Machines for Pattern Recognition, *Data Mining and Knowledge Discovery*, 2(2), 121–167
- [22]. Fraiwan, L., Lweesy, K., Khasawneh, N., Wenz, H., & Dickhaus, H., 2012, Automated sleep stage identification system based on time-frequency analysis of a single EEG channel and random forest classifier, *Computer Methods and Programs in Biomedicine*, 108(1), 10–19.
- [23]. Stoltzfus, J. C., 2011, Logistic Regression: A Brief Primer, *Academic Emergency Medicine*, 18(10), 1099–1104
- [24]. Estabrooks A., Jo T., Japkowicz N., 2004, A multiple resampling method for learning from imbalanced data sets, *Computational Intelligence*, 20(1), 18-36
- [25]. López V., Fernández A., García S., Palade V., Herrera F., 2013, An insight into classification with imbalanced data: Empirical results and current trends on using data intrinsic characteristics, *Information Sciences*, 250, 113–141.
- [26]. Batuwita R., Palade V., 2010, Efficient resampling methods for training support vector machines with imbalanced datasets, *Proceedings of the 2010 International Joint Conference on Neural Networks (IJCNN)*, Barcelona, IEEE, ISBN:9781424469178
- [27]. Kohavi R., 1995, A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection, *IJCAI'95 Proceedings of the 14th international joint conference on Artificial intelligence, Quebec*, Morgan Kaufmann Publishers, ISBN:1-55860-363-8, 1137-1143
- [28]. Jeon Y.W., Polich J., 2001, P3a from a passive visual stimulus task, *Clinical Neurophysiology*, 112, 2202-2208

EKLER

ETİK KURUL KARARI



T.C.
İSTANBUL ÜNİVERSİTESİ
İSTANBUL TIP FAKÜLTESİ
DEKANLIĞI
Yerel Etik Kurulu



Sayı : 2192

Tarih : 28/09/2007

Konu : Prof.Dr.Tamer DEMİRALP hk,

İSTANBUL TIP FAKÜLTESİ DEKANLIĞINA

İlgi : Rektörlüğün, 27.08.2007 tarihli, 40125 sayılı yazısı,

Sorumlu araştırmacılığını Üniversitemiz Deneysel Tıp Araştırma Enstitüsü Sinirbilim Anabilim Dalı Öğretim Üyesi Prof.Dr.Tamer DEMİRALP'in üslendiği ve Yüksek Lisans Öğrencisi Moleküler Biyolog ve Genetikçi Aslıhan SELİMBEYOĞLU'nun yürüteceği 2007/2077 dosya no'lu "Karar verme süreci ve eylem monitörizasyonuna ilişkin beyin potansiyelleri ve salınımları" başlıklı tez çalışması kurumumuzun 26.09.2007 tarihli, 09 sayılı toplantısında onaylanmış olup, tutanaklar ekte sunulmuştur.

Rektörlük Kanalı ile Üniversitemiz Deneysel Tıp Araştırma Enstitüsü Sinirbilim Anabilim Dalı Öğretim Üyesi Prof.Dr.Tamer DEMİRALP'a iletilebilmesi hususunda gereğini saygılarımla arz ederim.

Prof.Dr. Zafer ARI
İstanbul Tıp Fakültesi
Etik Kurul Başkanı

Eki: Tutanak



İSTANBUL TIP FAKÜLTESİ
YEREL ETİK KURUL TUTANAĞI

Toplantı Tarihi : 26/09/2007

Toplantı Yeri : Behçet Kütüphanesi Etik Kurul Toplantı Salonu

Toplantı Sayısı : 9

Scrumlu araştırıcılığını Üniversitemiz Deneysel Tıp Araştırma Enstitüsü Sinirbilim Anabilim Dalı Öğretim Üyesi Prof.Dr.Tamer DEMİRALP'in üstlendiği ve Yüksek Lisans Öğrencisi Moloküler Biyolog ve Genetikçi Aslıhan SELİMBEYOĞLU'nun yürüteceği 2007/2077 protokol numaralı "Karar verme süreci ve eylem monitörizasyonuna ilişkin beyin potansiyelleri ve salınımları" başlıklı tez çalışma dosyası kurumumuzda incelendi etik yönden bir sakınca taşımadığı görüldü, uygulamaya konulabileceğine karar verildi.

Prof.Dr. Zafer ARI
Etik Kurul Başkanı (Dekan Yardımcısı)

Prof.Dr. A.Yağız ÜRESİN
Farmakoloji ve Kll.F. A.D

Prof.Dr. Ahmet GÜL
İç Hast. A.D, Romatoloji Bilim Dalı

Prof.Dr. Berrin UMMAN
Kardiyoloji A.D.

Prof.Dr. Cahide GÖKKUŞU
Biyokimya A.D

Prof.Dr. Kamil PEMBEÇİ
Anesteziyoloji A.D.

Prof.Dr. Sevinç EMRE (Katılmadı)
Çocuk Sağ. Ve Hast. A.D

Prof.Dr. Nuran YILDIRIM
Dentoloji ve Tıp Tarihi A.D.

Prof.Dr. Oğuzhan ÇOBAN
Nöroloji A.D.

Prof.Dr. Pınar SAIP
İ.Ü. Onkoloji Enstitüsü

Prof.Dr. Ümit TÜRKÖĞLU
Biyokimya A.D

Prof.Dr. Çiçek BAYINDIR
Patoloji A.D., Nöropatoloji B.D.

Prof.Dr. Yeşim ERBİL
Genel Cerrahi A.D.

Prof.Dr. Neşe ÇOLAK
İç Hast.A.D. End. Ve Metabolizma Hast. B.D.

Prof.Dr. Nurhan ENGİNAR (Katılmadı)
Farmakoloji ve Kll.F. A.D

Fatma Ceyda DÖNMEZER
Sivil Toplum Örgütü Üyesi

Av. Dilek Temiz ÖZBEK
Hukukçu

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	Gülay ERDOĞAN
Doğum Yeri	İstanbul
Doğum Tarihi	06.01.1981
Uyruğu	<input checked="" type="checkbox"/> T.C. <input type="checkbox"/> Diğer:
Telefon	
E-Posta Adresi	gulaytezgel@gmail.com
Web Adresi	

Eğitim Bilgileri	
Lisans	
Üniversite	İstanbul Üniversitesi
Fakülte	Mühendislik Fakültesi
Bölümü	Elektronik Mühendisliği
Mezuniyet Yılı	2005

Yüksek Lisans	
Üniversite	İstanbul Üniversitesi-Cerrahpaşa
Enstitü Adı	Lisansüstü Eğitim Enstitüsü
Anabilim Dalı	Biyomedikal Mühendisliği Anabilim Dalı
Programı	Biyomedikal Mühendisliği Programı

Makale ve Bildiriler	