

**T.C.
DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**İMLEÇ HAREKETLERİNE AİT EEG SİNYALLERİNİN
SINIFLANDIRILMASINDA ADAPTİF VE ADAPTİF OLMAYAN
FİLTRELERİN UYGULAMALARI**

Zeynelabidin SEVGİLİ

YÜKSEK LİSANS TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**DIYARBAKIR
Haziran 2019**

T.C.
DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜ
DİYARBAKIR

Zeynelabidin SEVGİLİ tarafından yapılan “İmleç Hareketlerine Ait EEG Sinyallerinin Sınıflandırılmasında Adaptif ve Adaptif Olmayan Filtrelerin Uygulamaları” konulu bu çalışma, jürimiz tarafından Elektrik Elektronik Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

Jüri Üyesinin

Ünvanı Adı Soyadı

Başkan: Prof. Dr. Mehmet AKIN

Üye : Prof. Dr. Necmettin SEZGİN

Üye : Dr. Öğr. Üyesi Abdulnasır YILDIZ

Tez Savunma Sınavı Tarihi: 24/07/2019

Yukarıdaki bilgilerin doğruluğunu onaylarım.

.../...../2019

Prof.Dr.Sevtap SÜMER EKER

ENSTİTÜ MÜDÜR V.

TEŞEKKÜR

Bu tez çalışması boyunca bilgi, birikim ve tecrübelerini benden esirgemeyen değerli ve sürekli mütebessim danışmanım Prof. Dr. Mehmet AKIN’a saygıyla teşekkürlerimi sunuyorum.

Beni her daim maddi-manevi büyük fedakarlıklar ile destekleyen aileme teşekkürlerimi sunuyorum.

Ayrıca fikirlerini cömertçe paylaşıp zaman ayıran değerli bölüm hocalarıma, hususi olarak da Hüseyin ÖZMEN hocama hürmetlerimi sunuyorum.



İÇİNDEKİLER

	<u>Sayfa</u>
TEŞEKKÜR.....	I
İÇİNDEKİLER.....	II
ÖZET.....	IV
ABSTRACT.....	V
ÇİZELGE LİSTESİ.....	VI
ŞEKİL LİSTESİ.....	VIII
KISALTMA VE SİMGELER.....	IX
1. GİRİŞ.....	1
1.1 Sinyal Ölçüm Yöntemleri.....	2
1.1.1 İnvazif ve Non-İnvazif.....	3
1.1.2 Electroencephalography (EEG)	3
1.1.3 Magnetoencephalography (MEG)	4
1.1.4 Electrocorticography (ECoG)	4
1.1.5 Near-infrared spectrophotometry (NIRS) ve Functional Magnetic Resonance Imaging (fMRI)	4
1.2 Nörofizyolojik Sinyal Türleri.....	6
1.2.1 Olay Bazlı Potansiyeller(ERPs)	6
1.2.1.1 P300.....	6
1.2.1.2 Steady-State Visual Evoked Potential(SSVEP)	7
1.2.2 Beyin Frekans Dalgaları(Oscillatory Brain Activity)	7
1.2.2.1 Delta- δ Dalgaları.....	8
1.2.2.2 Teta- θ Dalgaları.....	8
1.2.2.3 Alfa- α Dalgaları.....	8
1.2.2.4 Beta- β Dalgaları.....	9
1.2.2.5 Gama- γ Dalgaları.....	9
1.2.2.6 Mu- μ Ritmi.....	9
1.3 Temel Bir BBA Senaryosu	9
1.3.1 Özellik Çıkarımı.....	10
1.3.2 Özellik Seçimi.....	11
1.3.3 Sınıflandırma.....	11

2	KAYNAK ÖZETLERİ.....	13
3	MATERYAL VE METOT.....	19
3.1	Materyal.....	19
3.2	Metot.....	22
3.2.1	Veri Temizleme ve Motor Hareket Hayali Frekans Bandı	22
3.2.1.1	Recursive Least Square(Teori).....	22
3.2.2	Common Spatial Patterns(CSP).....	25
3.2.3	Sınıflandırma Algoritmaları.....	27
3.2.3.1	Lineer Diskriminant Analizi(LDA)	27
3.2.3.2	Naive Bayes(NB)	28
3.2.3.3	K En Yakın Komşu Algoritması(KNN)	29
3.2.3.4	Destek Vektör Makinaları(DVM)	30
3.2.4	Performans Kriterleri.....	31
3.2.4.1	Kappa Skor.....	32
4.	BULGULAR VE TARTIŞMA.....	35
4.1	Yarışmada Kullanılan Deneme Paradigması ve Sinyallerin Güç Spektrumları.....	36
4.2	Çalışmanın Akış Diyagramı.....	39
4.3	Chebyshev Tip 1 İle Filtrelenen 9 Deneğin Verilerinin, SVM, LDA, Naive Bayes ve KNN Algoritmalarına Göre Başarı Performansları.....	40
4.4	Chebyshev Tip 2 İle Filtrelenen 9 Deneğin Verilerinin, SVM, LDA, Naive Bayes ve KNN Algoritmalarına Göre Başarı Performansları.....	51
4.5	Elliptik Filtre İle Filtrelenen 9 Deneğin Verilerinin, SVM, LDA, Naive Bayes ve KNN Algoritmalarına Göre Başarı Performansları.....	61
4.6	Adaptif Filtre İle Filtrelenen 9 Deneğin Verilerinin, SVM, LDA, Naive Bayes ve KNN Algoritmalarına Göre Başarı Performansları.....	71
4.7	Farklı 4 filtre ile elde edilen ortalama sınıflandırma performansları.....	81
5.	SONUÇ VE ÖNERİLER.....	83
6.	KAYNAKLAR.....	85
	ÖZGEÇMİŞ	87

ÖZET

İMLEÇ HAREKETLERİNE AİT EEG SİNYALLERİNİN SINIFLANDIRILMASINDA ADAPTİF VE ADAPTİF OLMAYAN FİLTRELERİN UYGULAMALARI

YÜKSEK LİSANS TEZİ

Zeynelabidin SEVGİLİ

DİCLE ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI

2019

Beyin Bilgisayar Arayüzü(BBA), herhangi fiziksel bir yeteneğe ihtiyaç duymadan insanın niyetinin veya kasıtlı düşüncesinin sınıflandırılmasını esas alınır. BBA çalışmalarında, veriler elektroensefalografi(EEG) yöntemi kullanılarak elde edilirken çevre kaynaklı(şebeke gürültüleri vs.) veya içsel(göz hareketleri, ECG vs.) bazı gürültülere maruz kalır. EEG verilerinin hassas bir şekilde sınıflandırılmasını önemli derecede etkileyebilecek gürültülerden biri de elektrookulografik(EOG) gürültülerdir. Bu çalışmada, Graz Üniversitesi tarafından yapılan BCI-IV yarışmasının 2a veri seti kullanılmıştır. 4 sınıflı veri seti 2 sınıfa indirgenerek sadece sağ ve sol imleç hareketlerinin offline sınıflandırılması amaçlanmıştır. 22 kanaldan alınan EEG verileri ile eş zamanlı, göz çevresine montajı yapılan 3 elektrottan da EOG verileri elde edilmiştir. Kullanılan veri setinde, EOG gürültülerini EEG sinyallerinden arındırmak için geleneksel bant geçiren filtreler ve recursive least square(RLS) adaptif filtresi kullanılmıştır. Motor hareket hayali ile uygun bantlara filtrelenmiş sinyallerden, ortak uzamsal örüntüler(CSP) metodu ile çıkarılan öznitelik vektörleri, lineer diskriminant analizi(LDA), destek vektör makinaları(DVM), naive bayes(NB) ve k-NN sınıflandırma algoritmalarının girişlerine uygulanmıştır. Chebyshev tip 2 ve DVM kombinasyonu %72'lik ortalama doğruluk oranı ile en yüksek sınıflandırma performansını sağlamıştır. Ayrıca RLS adaptif filtresi ile elde edilen sınıflandırma sonuçları bant geçiren filtrelerin sonuçları ile mukayese edilmiştir. RLS algoritması ve LDA kombinasyonu, %64 doğruluk oranı ile geleneksel bant geçiren filtreler ile elde edilen sonuçlardan daha düşük performans göstermiştir. Çalışmada elde edilen bulgular literatürü destekler niteliktedir. Çalışmanın bulguları, gelecekte yapılacak çalışmalara da ışık tutabilecek niteliktedir.

Anahtar Kelimeler: Adaptif filtre, Recursive least square, Beyin bilgisayar arayüzü, Elektrookulogram, Elektroensefalografi, Geleneksel bant geçiren filtreler, Ortak uzamsal örüntüler

ABSTRACT

APPLICATIONS OF ADAPTIVE AND NON-ADAPTIVE FILTERS FOR CLASSIFICATION OF EEG SIGNALS OF MOTOR IMAGERY

MsC THESIS

Zeynelabidin SEVGİLİ

DEPARTMENT OF ELECTRICAL AND ELECTRONICS ENGINEERING
INSTITUTE OF NATURAL AND APPLIED SCIENCES
UNIVERSITY OF DICLE

2019

Brain Computer Interface(BCI) is based on the classification of human intentions or intentional thought without the need for any physical ability. In BCI studies, signals which obtained using Electroencephalography(EEG) exposed to some environmental or internal noise (eye movements, ECG, etc.). One of the artifacts that can significantly affect classification accuracy is electrooculogram(EOG). In this study, BCI competition IV dataset 2a was used which was organized by the University of Graz. The data set with 4 classes was reduced to 2 classes and only the right and left motor imagery data were classified according to the offline paradigm. Simultaneously with EEG data from 22 channels, EOG data were obtained from 3 electrodes mounted around the eye. Conventional bandpass filters and recursive least square (RLS) adaptive filters are used to remove EOG noise from EEG signals. Feature vectors extracted from filtered signals by CSP method were applied to the inputs of linear discriminant analysis (LDA), support vector machines (SVM), naive bayes (NB) and k-NN classification algorithms. The combination of Chebyshev type 2 filter and SVM achieved the highest classification performance with an average accuracy of 72%. Furthermore, the classification results obtained with the RLS adaptive filter were compared with those of the bandpass filters. The combination of the RLS algorithm and the LDA classifier showed lower performance than traditional bandpass filters with a 64% accuracy rate. The findings of the study support the literature and may shed light on future studies.

Keywords: Adaptive filter, Recursive least square, Brain Computer Interface, Electrooculogram, Electroencephalography, Traditional bandpass filters

ÇİZELGE LİSTESİ

<u>Çizelge No</u>		<u>Sayfa</u>
Çizelge 1.1	Sinyal edinim yöntemlerinin avantajları ve dezavantajları	5
Çizelge 3.1	Oturum dosyaları	19
Çizelge 3.2	Landis ve Koch'un kappa skor çıkarımları	33
Çizelge 4.1	Örnek Konfüzyon Matrisi	41
Çizelge 4.2	Denek-1, Chebyshev type 1 ile elde edilen başarı performansları	42
Çizelge 4.3	Denek-2, Chebyshev type 1 ile elde edilen başarı performansları	43
Çizelge 4.4	Denek-3, Chebyshev type 1 ile elde edilen başarı performansları	44
Çizelge 4.5	Denek-4, Chebyshev type 1 ile elde edilen başarı performansları	45
Çizelge 4.6	Denek-5, Chebyshev type 1 ile elde edilen başarı performansları	46
Çizelge 4.7	Denek-6, Chebyshev type 1 ile elde edilen başarı performansları	47
Çizelge 4.8	Denek-7, Chebyshev type 1 ile elde edilen başarı performansları	48
Çizelge 4.9	Denek-8, Chebyshev type 1 ile elde edilen başarı performansları	49
Çizelge 4.10	Denek-9, Chebyshev type 1 ile elde edilen başarı performansları	50
Çizelge 4.11	Chebyshev type 1 ile elde edilen başarı performansları ortalamaları	51
Çizelge 4.12	Denek-1, Chebyshev type 2 ile elde edilen başarı performansları	52
Çizelge 4.13	Denek-2, Chebyshev type 2 ile elde edilen başarı performansları	53
Çizelge 4.14	Denek-3, Chebyshev type 2 ile elde edilen başarı performansları	54
Çizelge 4.15	Denek-4, Chebyshev type 2 ile elde edilen başarı performansları	55
Çizelge 4.16	Denek-5, Chebyshev type 2 ile elde edilen başarı performansları	56
Çizelge 4.17	Denek-6, Chebyshev type 2 ile elde edilen başarı performansları	57
Çizelge 4.18	Denek-7, Chebyshev type 2 ile elde edilen başarı performansları	58
Çizelge 4.19	Denek-8, Chebyshev type 2 ile elde edilen başarı performansları	59
Çizelge 4.20	Denek-9, Chebyshev type 2 ile elde edilen başarı performansları	60
Çizelge 4.21	Chebyshev type 2 ile elde edilen başarı performansları ortalamaları	60
Çizelge 4.22	Denek-1, Eliptik filtresi ile elde edilen başarı performansları	62
Çizelge 4.23	Denek-2, Eliptik filtresi ile elde edilen başarı performansları	63
Çizelge 4.24	Denek-3, Eliptik filtresi ile elde edilen başarı performansları	64
Çizelge 4.25	Denek-4, Eliptik filtresi ile elde edilen başarı performansları	65
Çizelge 4.26	Denek-5, Eliptik filtresi ile elde edilen başarı performansları	66

Çizelge 4.27	Denek-6, Eliptik filtresi ile elde edilen başarı performansları	67
Çizelge 4.28	Denek-7, Eliptik filtresi ile elde edilen başarı performansları	68
Çizelge 4.29	Denek-8, Eliptik filtresi ile elde edilen başarı performansları	69
Çizelge 4.30	Denek-9, Eliptik filtresi ile elde edilen başarı performansları	70
Çizelge 4.31	Eliptik filtresi ile elde edilen başarı performansları ortalamaları	71
Çizelge 4.32	Denek-1, RLS algoritması ile elde edilen başarı performansları	72
Çizelge 4.33	Denek-2, RLS algoritması ile elde edilen başarı performansları	73
Çizelge 4.34	Denek-3, RLS algoritması ile elde edilen başarı performansları	74
Çizelge 4.35	Denek-4, RLS algoritması ile elde edilen başarı performansları	75
Çizelge 4.36	Denek-5, RLS algoritması ile elde edilen başarı performansları	76
Çizelge 4.37	Denek-6, RLS algoritması ile elde edilen başarı performansları	77
Çizelge 4.38	Denek-7, RLS algoritması ile elde edilen başarı performansları	78
Çizelge 4.39	Denek-8, RLS algoritması ile elde edilen başarı performansları	79
Çizelge 4.40	Denek-9, RLS algoritması ile elde edilen başarı performansları	80
Çizelge 4.41	RLS algoritması ile elde edilen başarı performansları ortalamaları	80
Çizelge 4.42	4 filtre ile elde edilen ortalama sınıflandırma performansları	81
Çizelge 4.43	En yüksek sınıflandırma performansları kombinasyonları	83
Çizelge 4.44	En yüksek sınıflandırma performansı(Eliptic filtre, 3. Denek)	84

ŞEKİL LİSTESİ

<u>Şekil No</u>		<u>Sayfa</u>
Şekil 1.1	10-20 sistemli elektrot konumlandırma sistemi	3
Şekil 1.2	Bir uyarana verilen P300 sinyali	6
Şekil 1.3	7.5-13 Hz aralığında sunulan görsel uyarana birlikte EEG sinyallerinde meydana gelen frekans değişimleri	7
Şekil 1.4	Beyin dalgalarının EEG kayıtları	7
Şekil 1.5	Örnek bir BBA sisteminin temel bileşenleri	10
Şekil 3.1	Örnek bir denemenin zamana bağlı olaylar silsilesi(University of Graz 2008)	20
Şekil 3.2	22 kanallı elektrot lokasyonları	20
Şekil 3.3	3 Monopolar EOG kanalının elektrod montajı	21
Şekil 3.4	EOG kayıt sırası	21
Şekil 3.5	RLS filtresinin blok diagramı	22
Şekil 3.6	KNN algoritması, temsili sınıflandırma	29
Şekil 3.7	SVM maximum tolerans temsili gösterimi	30
Şekil 4.1	10-20 evrensel sistemli EEG elektrotları	35
Şekil 4.2	EOG elektrot montajı	35
Şekil 4.3	Bir denemenin olaylar silsilesi ve hesaba katılacak zaman dilimi	36
Şekil 4.4	Örnek sağ el motor hayali EEG ve EOG sinyali	37
Şekil 4.5	Örnek sol el motor hayali EEG ve EOG sinyali	37
Şekil 4.6	Örnek sağ el motor hareket hayali C3 kanalı verisi ve EOG1 sinyalinin spektral gösterimi	38
Şekil 4.7	Örnek sol el motor hareket hayali C3 kanalı verisi ve EOG1 sinyalinin spektral gösterimi	38
Şekil 4.8	Çalışmanın akış diyagramı	40
Şekil 4.9	Örnek sol el motor hareket hayalinin C3 kanalının frekans gücü yoğunluğu	82
Şekil 4.10	Örnek sağ el motor hareket hayalinin C3 kanalının frekans gücü yoğunluğu	83

KISALTMA VE SİMGELER

EEG	: Elektroensefalogram
BBA	: Beyin Bilgisayar Arayüzü
BCI	: Brain Computer Interface
EOG	: Electrooculogram
MEG	: Magnetoencephalography
ECoG	: Electrocorticography
SNR	: Signal to noise ratio
NIRS	: Near-infrared spectrophotometry
fMRI	: Functional Magnetic Resonance Imaging
ERPs	: Olay Bazlı Potansiyeller(Event related potentials)
SSVEP	: Steady-State Visual Evoked Potential
MI	: Motor Imagery
CSP	: Common Spatial Patterns
VEOG	: Vertical Electrooculogram
HEOG	: Horizontal Electrooculogram
RLS	: Recursive least-squares
LDA	: Linear Discriminant Analysis
SVM	: Support Vector Machines
k-NN	: K-Nearest Neighbour
LDA	: Linear Discriminant Analysis
DSLVQ	: Distinctive Sensitive Learning Vektor Quantization
YSA	: Yapay Sinir Ağları
ECG	: Electrocardiography
FCV	: Fold Cross Validation

1. GİRİŞ

İnsanoğlu olağanüstü donanımlar ile teçhiz edilmiş ve doğada tasarruf yeteneğine sahip tek canlıdır diyebiliriz. Diğer canlılar kendi habitatları içerisinde, genel ekosisteme kabiliyetleri ölçüsünde katkı yaparken insanoğlu aklı, vücut uzuvları ve diğer kabiliyetleri ile dünya dışı yaşamı bile etkileyebilecek donanımlara sahiptir. Bu donanımların en önemli olanlarından biri de şüphesiz iletişim yeteneğidir. İnsan sahip olduğu beyin, dil, gırtlak vs. gibi organların koordinasyonu ile diğer insanlar hatta gelişen teknoloji vasıtasıyla cihazlar dahi iletişim kurabiliyor. Bu şekilde hayatı için lazım olan ihtiyaçlarını karşılamaya çalışır. Fakat bu durum bütün insanlar için geçerli değildir. ALS(Amyotrophic Lateral Sclerosis), felç, MS (Multiple Skleroz) vs. gibi hastalıklar insanın motor becerilerinin tamamen kısıtlanmasına neden olabilir. Bunun sonucunda kişi, kasıtlı kas hareketlerinden mahrum kalır. Bu durumda beyin normal aktivitesine devam ederken beyinden uzuvlarına komutlar aktarılamaz. Yani diğer bir deyişle beyin her şeyin farkındadır.(Akıncı 2010) Fakat her hangi bir uzvunu hareket ettirecek kabiliyetten mahrum kalmıştır. Beyin bilgisayara arayüzü(BBA) bu tarz hastalara çözümler sunmak için geliştirilen önemli teknolojilerden biridir. Bunun haricinde BBA, sanal gerçeklik, etkin ifade, internete erişim, tekerlekli sandalye kontrolü, video oyunları gibi bir çok alan için uygulamalar geliştirmektedir.(R. Wolpaw ve Birbaumer)

Beyin Bilgisayar Arayüzü(BBA) çalışmalarında, beynin aktivitelerini anlamlandırma esastır. Bu aktiviteler ile insanın niyeti anlamlandırılmaya çalışılır. Bu şekilde vücudun diğer organlarına ihtiyaç duymadan insanın niyetinin okunması amaçlanır. Yine Sinyal işleme teknikleri(DSP) ve çeşitli sınıflandırma algoritmaları ile insanın isteklerinin komutları, harici bir cihaza aktarılması amaçlanır. Bunlar büyük oranda başarılı olduğu takdirde BBA, insanların hayatlarını kolaylaştıracak çok büyük gelişimlere kapı açabilir. Dolayısıyla bu teknoloji hayata hizmet hususunda büyük anlamlar kazanır.

BBA çalışmaları ile ilgili ilk girişimler 1964'te başlamıştır. Fakat bu alanla ilgili dikkate değer çalışmaların başlaması 1990'lı yılların başında başlamıştır. Bu süreçle birlikte her yıl, yapılan çalışma ve yayınlanan yayın sayısında önemli derecede artışlar olmuştur. BBA, bilim kurgu filmlerinde 50 yıl öncesinde işlenmesine rağmen bilim adamları 2000'li yılların başından itibaren bu tarz sistemler ile ilgili uygulamalar geliştirmeye başlamışlardır.(Grainman ve ark.)

BBA ile ilgili bu tarihi süreçte çok fazla çalışılıp her geçen yıl daha iyi ilerlemeler sağlanmasına rağmen etkili bir BBA sisteminin geliştirilmesinin önünde hala aşılması gereken çok büyük zorluklar mevcuttur. Yeterli ve etkin öznelik vektörleri seçimi, uygun frekans bandı/bantları seçimi, EEG sinyaline karışan gürültülerin temizlenmesi, uygun sınıflandırma algoritması seçimi ve çeşitli sinyal işleme teknikleri ile araştırmacılar bu zorlukları aşmaya çalışmaktadırlar.

Bu çalışmada, bir önceki paragrafta bahsi geçen zorluklardan, EOG gürültülerinin temizlenmesi ve bant geçiren filtreler ile uygun spektral bant seçimi gibi konuların üzerinde durulacaktır. EOG gürültüsüyle kirlenmiş sağ ve sol motor hareket hayali EEG sinyallerindeki EOG gürültüleri, adaptif filtreler ve geleneksel filtrelerden Chebyshev I, Chebyshev II ve Eliptik filtreler ile temizlenmiştir. İlgili sınıfa ait EEG sinyalleri, geleneksel filtreler ile motor hareket hayali bilgisinin tahmin edildiği frekans bantlarına filtrelenmiştir. Daha sonra CSP metodu ile çıkarılan öznelik vektörleri Destek Vektör Makinaları, Naive Bayes, k-NN ve Lineer Diskriminant Analizi sınıflandırıcılarının girişlerine uygulanarak yapılan filtreleme işlemlerinin sınıflandırma performanslarına etkisi analiz edilip çıkarımlar yapılmıştır. Bu şekilde geleneksel bant geçiren filtreler ile adaptif filtrelerin motor hareket hayali sinyallerinin sınıflandırılmasına ait etkileri de karşılaştırılmıştır.

Tez 5 bölüme ayrılmıştır. Bu bölümler sırasıyla Giriş, Materyal, Metot, Bulgular ve Tartışma, Sonuç ve Öneriler başlıklarını kapsar. 1. Bölümde, çalışma ile ilgili kısa bir bilgi, sinyal ölçüm yöntemleri, nöro-fizyolojik sinyal türleri ve temel bir BBA senaryosunun yapısı anlatılmıştır. 2. bölümde, çalışmada kullanılan ve Graz Üniversitesi tarafından sunulan BBA IV yarışmasının 2a veri seti detayları ile anlatılmıştır. 3. bölüm, çalışmada kullanılan filtreler, ortak uzamsal örüntüler metodu ve sınıflandırıcılar hakkında teorik bilgileri içermektedir. 4. bölümde çalışmada elde edilen bulgular tablolar ile karşılaştırmalı olarak sunulmuştur. 5. bölümde, yapılan çalışmanın pozitif yönleri ve geliştirilmesi gereken yönleri gelecek projeksiyonu ile birlikte ele alınmıştır.

1.1 Sinyal Ölçüm Yöntemleri

Beyin sinyallerinin komutlara dönüşebilmesi için bu mümkün olduğunca doğru ve güvenilir bir şekilde elde edilmesi gerekir. Bu amaçla bir çok sinyal edinim yöntemi geliştirilmiştir. Bu teknikler elektriksel, manyetik, invazif, non-invazif gibi geniş bir çerçevede ele alınabilir. Sinyaller elde edilirken kalite, kullanım kolaylığı, maliyet, kişiye


verdiği zarar vs. faktörler göz önünde bulundurulur. Amaç ve uygulamaya bağlı olarak da ilgili yöntem dikkate alınabilir. Bu kısımda bahsi geçen yöntemler genel hatlarıyla açıklanacaktır.

1.1.1 İnvazif ve Non-invasif

İnvazif prosedürde, Electroencephalography (EEG) veya beyindeki lokal potansiyeller elde edilirken elektrotlar beyindeki korteks tabakasına temas eder. Bu durum, dokuların enfeksiyonu ve tahribi gibi bazı dezavantajları da beraberinde getirir. Aynı zamanda cerrahi işlem gerektirdiğinden maliyeti de yüksektir. Fakat elde edilen sinyal kalitesi oldukça yüksek ve gürültüden arınmış bir şekilde elde edilir. Risk faktörlerinden dolayı bu prosedür yaygın değildir. Non-invasif prosedürün uygulanması kolay ve maliyeti ucuzdur. Bununla birlikte non-invasif ile elde edilen sinyal yüksek miktarda gürültü içerir. Bu gürültülerin sinyal işleme teknikleri ile orijinal sinyallerden arındırılması gerekir.(Snyder ve Shen 2017)

1.1.2 Electroencephalography (EEG)

Electroencephalography (EEG), en çok kullanılan elektriksel tekniklerden biridir. İlk olarak 1970 yılında epileptik nöbetleri gözlemlemek için kullanılmıştır.(Snyder ve Shen 2017) EEG verileri Şekil 1.1’de gösterildiği gibi uluslararası 10-20 elektrot konumlandırma sistemine sahiptir.



EEG sinyalleri yüksek sinyal-gürültü oranına(SNR) sahip olduğu için ve de sinyal için idealdir. Fakat düşük çözünürlüğe sahiptir. Beyin sinyallerinin genliği kafatası yüzeyinde yüzlerce mikro-volt seviyesindedir. Göz hareketleri, göz kırpması, kalp, solunum veya kas gürültülerinden etkilenir. Yüksek kaliteli EEG sistemleri, beyin dalgalarının genliklerini yükseltirken bahsi geçen gürültüleri de minimize edecek karakteristiklerde olması gerekir. Bu gürültüleri azaltmak için yapılan en önemli yöntemlerden biri, birleşim empedansını düşürmek için elektrotların ucuna iletken jel sürmektir. Sonraki aşamada güç kablolarının gürültüleri ve istenmeyen frekansları minimize edilir. Son aşamada, istenmeyen gürültüler sinyal işleme teknikleri ile temizlenir.

1.1.3 Magnetoencephalography (MEG)

Magnetoencephalography, korteksteki nöronların elektrik akımlarından ortaya çıkan manyetik alanı ölçmeye dayalı non-invasif bir tekniktir. Manyetik sinyallerin genlikleri çok düşük olduğundan dünyanın doğal manyetik alanlarından izole edilmiş bir MEG odası mecburiyeti vardır. Bu yüzden daha maliyetli ve EEG kadar pratik yöntem değildir. (Snyder ve Shen 2017)

1.1.4 Electrocorticography (ECoG)

Electrocorticography, kafatasının altında bulunan korteks kısmından elektrotlar ile sinyal alınması işlemidir. Cerrahi işlem gerektirdiğinden invazif bir yöntemdir. Sinyaller korteks kısmından alındığından sinyaller temiz ve sinyal-gürültü-oranı(SNR) yüksek olduğundan veri kalitesi non-invasif yöntemlere göre yüksektir denilebilir. Bu yöntemle alınan veriler temiz ve kaliteli olduğundan non-invasif yöntemlere göre daha az sinyal işleme yöntemleri gerektirir ve sonuçlar daha doğru ve güvenilirdir. Fakat girişimsel bir işlem olduğundan enfeksiyon, kortekse olası bir zarar gibi bazı riskleri de beraberinde getirir.

1.1.5 Near-infrared spectrophotometry (NIRS)ve Functional Magnetic Resonance Imaging (fMRI)

Bu yöntemlerin ikisi de beyin anormalliklerinden kaynaklı vücutta oksijen parametrelerini gözlemleyen yöntemlerdir. fMRI pratik olmayan, yüksek zamansal çözünürlüklü çıktı veren, pahalı bir yöntemdir. NIRS ise EEG ile birlikte değerlendirilebilen pratik ve düşük maliyetli bir yöntemdir. Fakat fMRI yöntemine göre

daha düşük performans sağlar. Çizelge 1.1’de Sinyal edinim yöntemlerinin avantaj ve dezavantajları listelenmiştir.

Çizelge 1.1. Sinyal edinim yöntemlerinin avantajları ve dezavantajları

Yöntem	Sinyal Edinim Türü	Avantajları	Dezavantajları
EEG	Kafatası yüzeyinden elektriksel	• Yüksek zamansal çözünürlük • Non-invasif • Düşük maliyet • Kolay kullanım	• Düşük mekânsal çözünürlük • Durağan olmayan(non-stationary) sinyal • Gürültüye duyarlı
MEG	Elektriksel aktivitelerden manyetik alan ölçümü	• Yüksek frekans aralığı • Yüksek zamansal-mekansal çözünürlük	• Kullanımı pratik değil • Yüksek Maliyet
ECoC	Korteks kısmından girişimsel yöntemler ile	• SNR oranı yüksek • Daha az önışleme gereksinimi • Yüksek performans	• Invasif • Enfeksiyon veya zarar riski
fMRI	Hemodinamik	• Yüksek zamansal-mekansal çözünürlük	• Yüksek Maliyet • Veri ediniminde gecikme(Delay in data acquisition)
NIRS	Hemodinamik	• Yüksek mekansal(spatial) çözünürlük • Düşük maliyet • Taşınabilir • Kolay kullanım	• Düşük zamansal çözünürlük • Düşük Performans

1.2 Nörofizyolojik Sinyal Türleri

Olay Bazlı Potansiyeller(ERPs) ve Beyin Frekans Salınımları(Oscillatory Brain Activity) olmak üzere iki çeşit nörofizyolojik sinyal vardır.


Olay bazlı potansiyellerde, beyin sinyallerinde reaksiyona neden olabilecek bir uyaran(görsel, işitsel vs.) beyin sinyallerinde bir değişime neden olur. Bu değişim ERPs diye isimlendirilir. Herhangi bir mental olay(yalan söyleme, sağ el motor hayali vs.) beyin sinyallerinde anormal salınımlara neden olabiliyor. Bu durum da Beyinsel Aktivitelerin Salınımları diye nitelendiriliyor. (Akıncı 2010)

1.2.1 Olay Bazlı Potansiyeller(ERPs)

Popüler olan Olay Bazlı Potansiyeller P300 ve Steady-State Visual Evoked Potential(SSVEP) olarak iki sınıfta incelenebilir.

1.2.1.1 P300

P300 belirli bir uyaran sunulduktan 300 ms sonra EEG verilerinde meydana gelen pozitif pik reaksiyonlarıdır. Tipik bir P300 sinyali Şekil 1.2’de gösterilmiştir.




Şekil 1.2. Bir uyarana verilen p300 sinyali

Şekil 1.2’de görüldüğü gibi hedef uyaran(target stimulus) EEG sinyalinde pozitif bir pik reaksiyonuna neden olmuş. Bu tarz reaksiyonlar kişiye özgü değildir. Her denekte benzer bir reaksiyona neden olurlar. Dolayısıyla geniş bir eğitime ihtiyaç duymadan kolayca sınıflandırılabilirler.

1.2.1.2 Steady-State Visual Evoked Potential(SSVEP)

SSVEP beynin görsel uyaranlara karşı belirli frekanslarda tepkileridir. Mesela, retina 3.5-75 Hz arasındaki görsel uyaranlar ile tahrik edilirken beyin de aynı frekans aralığında elektriksel aktivite sergiliyor.(Baverina F ve ark 2003) Şekil 1.3'te 7.5-13 Hz aralığında sunulan bir görsel uyaranın aynı anda EEG sinyallerinde meydana gelen frekans değişimleri yansıtılmıştır.(Cecotti H. ve Rivet B. 2011)




Şekil 1.3. 7.5-13 Hz aralığında sunulan görsel uyaranla birlikte EEG sinyallerinde meydana gelen frekans değişimleri

1.2.2 Beyin Frekans Dalgaları(Oscillatory Brain Activity)

Beyindeki frekans salınımları, EEG'si alınacak şahsın hayal durumu, uyanıklığı, hastalığı, konsantrasyonu vs. durumlarına göre değişkenlik gösterebilir. Bu salınımlar beynin belli bir bölgesinde, delta- δ , beta- β , teta- θ , alfa- α , gama- γ ve, mu- μ rhytm olmak üzere birkaç grupta incelenebilir.

Gün boyunca kişinin çalışma, odaklanma, uyku vs. durumlarına göre bu sayılan 5 beyin dalgası aynı anda etkinlik gösterebilir. Fakat içinde bulunulan vaziyete göre muhtemelen bir beyin dalgası dominant vaziyettedir. Tipik beyin dalgalarının EEG kayıtları Şekil 1.4'de gösterildiği gibidir.



Şekil 1.4. Beyin dalgalarının EEG kayıtları(iMotions 2016)

1.2.2.1 Delta-δ Dalgaları

Delta beyin dalgaları 0.5-4 Hz frekans aralığında etkinlik gösterirler. Düşük frekanslı fakat bilinen beyin dalgaları arasında en yüksek gürültüye sahiptirler. Genelde rüyasız uyku ve yüksek meditasyon durumlarında baskındırlar. İyileşme ve hücre yenilenmesi için bu duruma ihtiyaç vardır. Günün önemli bir zaman dilimini derin ve uzun uykuyla geçiren bebeklerin EEG kayıtlarında, delta dalgalarının baskın olduğu gözlenmiştir. 11-14 yaşlar grupları ile yapılan çalışmalarda delta dalgalarının aktivitesi bebekliğe oranla %25 düştüğü raporlanmıştır. Kırklı yaşların ortalarında en yüksek düşüş oranına sahiptir. Yetmiş beş yaşından sonra delta dalgalarının etkinliği neredeyse gözlemlenemez seviyeye gelir.(Heather S. 2015)

1.2.2.2 Teta- θ Dalgaları

Teta dalgaları 4-8 Hz frekans aralığında salınım etkinliğine sahiptir. Teta dalgaları en çok uyku ve meditasyon durumlarında baskındır. Teta frekansının baskın olduğu durumlarda şahıs daha çok dış dünyadan soyutlanmış, iç dünyasına odaklanmıştır. Teta frekansının etkinliği aynı zamanda üzülmeye, karabasan, korku, derin düşünceler ve aniden doğan düşünceler ile de ilişkilidir.

1.2.2.3 Alfa- α Dalgaları

Alfa dalgaları 8-13 Hz frekans aralığında salınım gösterirler. Çoğunlukla beynin oksipital lobu tarafından üretilirler. “Kişinin içinde bulunduğu an” ile çok yakın ilişkilidir. Beynin dinlenme durumunda baskındır. Yapılan çalışmalarda gözler-kapalı, dinlenme pozisyonunda veya uyuşukluk durumlarında artış, gözler-açık ve dış dünya ile meşguliyet durumlarında düşüşler gözlenmiştir.

1.2.2.4 Beta- β Dalgaları

Beta dalgaları 13-38 Hz frekans aralıklarında salınım gösterirler. Özellikle yüksek aktivite, teyakkuz, problem çözme, yargılama, karar verme vs. süreçlerde baskındır. Daha önce bahsi geçen beyin dalgalarına oranla daha geniş frekans spektrumuna sahip olduğu için 3 gruba ayrılır.

Düşük Beta(13-15 Hz) – Aktif düşünme

Orta Beta(15-22 Hz) – Yüksek uğraş durumları

Yüksek Beta(22-38) – Çok kompleks düşünceler, yeni tecrübelerin entegrasyonu, yüksek endişe ve heyecan. Beta dalgaları aynı zamanda uğraşan ve iyi odaklanmış bir beynin karakteristiğini yansıtır.

Dış dünyada cereyan eden olayları deneyimleme esnasında baskındırlar. Aynı zamanda aktif egzersiz esnasında da etkindirler.

1.2.2.5 Gama- γ Dalgaları

Gama dalgaları(38-90 Hz) en yüksek frekansa sahip beyin dalgalarıdır. Duygu ve düşüncelerin harmanlanması için önemlidir. Aşk, fedakarlık, şefkat vs. yüksek duyguların yaşandığı duygu durumlarında yüksek etkinlik gösterirler. Gama dalgaları aynı zamanda şizofreni, panik atak gibi vakalarla da ilişkilidir.(Heather S. 2015)

1.2.2.6 Mu- μ Ritmi


7-14 ve 15-25 Hz bandında salınım gösterir. Yüksek oranda kasların aktif çalışması, yürüme hareketi gibi şahsın motor duyularıyla ilgilidir. Mu Ritmi aynı zamanda hayali motor hareketleriyle de yakından ilişkilidir. Tipik olarak C3, C4, Cz gibi orta elektrot lokasyonlarından kaydedilirler(Marshall P.J. ve Meltzoff A.N. 2011).

Motor hayali ilgili yapılan çalışmalarda mu ve beta bantlarındaki aktiviteler gözlenmiştir. Yapılan çalışmalarda Mu ve Beta dalgalarındaki uzamsal, spektral veya mekânsal değişimler sinyal işleme yöntemleri ile analiz edilerek ilgili motor hayalinin(sağ, sol, yukarı, aşağı vs.) sınıflandırılmasına yönelik yoğun uğraşlar dikkat çekmektedir. Aynı frekans bandındaki alpha frekans bandından farklı olarak göz açma veya kapama hareketlerinden minimal düzeyde etkilenirler ve kasıtlı motor hareket hayalinin icrası esnasında salınım gösterirler. (Aleksandrov A.A ve Tugin S.M. 2012)

1.3 Temel Bir BBA Senaryosu

Giriş kısmında bahsedildiği gibi BBA, hareket veya ses yeteneğinden mahrum insanlar için alternatifler sunar. Beyin sinyalleri ile iletişim sağlanır. Bilindiği gibi beyin

istemli veya istemsiz bütün hareketlerin merkezi durumundadır. Beynin istemli bütün kompleks hareketlerini çözmek mümkün değildir. Fakat bazı teknikler geliştirilerek beynin istemli komutlarını anlamlandırmak mümkün olabiliyor. Beyin sinyallerinin anlamlandırılıp, muhtelif teknikler ile komutlara dönüştürülmesi bazı alanlarda kullanılabilir. Bu bağlamda kaliteli EEG verileri edinimi önem arz eder. Bu aşamadan sonra toplanan verilerden sinyal işleme teknikleri ile özellik çıkarımları ve özellik seçimleri yapılır. Son aşamada ise çeşitli sınıflandırma algoritmaları kullanılarak komut sınıfı belirlenir. Şekil 1.5'te bahsedilen sistemin temel bileşenleri şematize edilmiştir.



Şekil 1.5. Örnek bir BBA sisteminin temel bileşenler

Temel bir BBA sisteminde sinyal edinimi konusu önceki başlıklarda ele alınmıştı. Bu aşamadan sonra uygulama çıktısına kadar olan süreçler/senaryo ile ilgili temel düzeyde bilgiler verilecek.

1.3.1 Özellik Çıkarımı

Özellik çıkarımı, ham sinyalden ilgili sınıfa ait bilgilerin çıkarılması için gereken bir yöntemdir. Bunun için ham EEG sinyalleri zamansal, spektral ve uzamsal bazda analiz edilir. Çıkarılan bu bilgilerin uygulamaya yönelik olması gerekir. Mesela bazı

durumlarda spektral özelliklerin çıkarılması mantıklı iken, p300 için yapılan çalışmalarda zamansal özelliklerin çıkarılması mantıklı olabiliyor. Uzamsal özelliklerin çıkarılması neredeyse bütün uygulamalar için kullanılabilir.

1.3.2 Özellik Seçimi

Özellik seçimi, temelde sınıflandırmanın kolay bir şekilde yapılabilmesi için ham bir sinyalin yeni bir yapıya dönüştürülmesidir. Başka bir deyişle, sınıflandırma için ayırt edici özellikleri zarar vermeden ya da mümkün olduğunca az bir zararla, giriş sinyalinden gereksiz bilgilerin çıkarılmasıdır diyebiliriz. Bu durum özellikle yüksek boyutlu veriler için gerekli bir işlemdir. Bu işlem ile birlikte boyut düşürülerek işlenebilecek daha basit bir model elde edilir. Sonuç olarak hem sınıflandırma hızı hem de doğruluk oranı arttırılır.

1.3.3 Sınıflandırma

Seçilen özellikler bir sınıflandırıcının girişine uygulanır. İlk etapta etiketlenmiş eğitim verileri ile bir sınıflandırma modeli oluşturulur. Sonra etiketlenmemiş test verileri bu model ile sınıflandırmaya tabi tutulduktan sonra çıktı verir. Sınıflandırma algoritmaları lineer veya non-lineer seçilebilir. Motor hayali ile yapılan çalışmalarda, lineer algoritmaların daha başarılı olduklarına dair raporlar mevcuttur.(Akıncı B. 2010)



2. KAYNAK ÖZETLERİ

Kaynak özetleri yapılmadan önce, yapılacak çalışmanın bileşenleri tespit edildi. Motor hareket hayali verilerinin sınıflandırılması ile ilgili en etkili yöntemlerden biri olan CSP teknikleri, gürültülü EEG'den EOG'yi arındırma teknikleri, adaptif filtreler vs. üzerinde duruldu. Ayrıca “Bu teknikler hangi sınıflandırma algoritması ile en yüksek sonuçları verir?” sorusu da dikkate alınarak motor hareket hayalinin sınıflandırılması ile ilgili en etkili sınıflandırıcılar araştırıldı ve yapılan çalışma, araştırılan kaynak özetleri üzerine bina edildi.

Ramoser H. ve ark.(2000), çalışmalarında, ipucu bazlı sağ ve sol el motor hayali hareketlerini sınıflandırmak için yaptıkları BBA çalışmasında çok kanallı EEG sinyalleri için uzamsal bir filtre geliştirmişlerdir. Bu uzamsal filtre ile aktif olan korteks alanını tespit etmişlerdir. Bu çalışmada 20-27 yaş aralığında ve sağ elini kullanan üç kadın, denek olarak kullanılmıştır. Ekranın ortasında bulunan ok işaretinin yönüne göre deneklerden sağ veya sol el motor hayalini gerçekleştirmeleri istenmiştir. Toplamda 20 sağ ve 20 sol el olmak üzere 40 deneme icra edilmiştir. EEG kayıtları alınırken electrooculogram(EOG) ve electromyogram(EMG) kayıtları da kaydedilmiştir. Veri ön işleme işlemlerinde kayıtlardan gürültü tespiti yapılmış ve bandpass filtresi kullanılarak gürültüden arındırılmıştır. Özellik çıkarma kısmında Ortak Uzamsal Örüntüler(CSP) kullanılmış ve çıkarılan özellikler lineer sınıflandırıcının girişine uygulanmıştır. En yüksek sınıflandırma performansları üç denekte sırasıyla %90.8, %92.7 ve %99.7'e kadar ulaşmıştır. Önerilen metodun yüksek doğruluk oranı ve işlem kolaylığı sağlaması, ileri dönem EEG bazlı BBA çalışmaları adına umut vadetmektedir.

P.He ve ark.(2004), yapmış oldukları çalışmada, EEG sinyallerine karışan, göz hareketlerinden kaynaklanan EOG(Electrooculogram) gürültülerini temizlemek için geleneksel regresyon bazlı temizleme yöntemleri yerine adaptif filtre ile gürültü gidermeyi önermişlerdir. Yapılan çalışmada ayrı ayrı kaydedilen dikey göz hareketleri(VEOG) ve yatay göz hareketleri(HEOG), adaptif filtrenin iki referanslı girişine uygulanmıştır. Online uygulamalar esas alındığından diğer adaptif filtrelerle oranla hızı daha yüksek olan recursive least-squares(RLS) metodu tercih edilmiştir. Sunulan bu metodun kalibrasyon gerektirmediği ve zamandan tasarruf sağladığı anlaşılmıştır. Ayrıca önerilen metodun değişen şartlara adapte olmasından ötürü, uzun

periyotlu ölçümlerde hata payı yükselen regresyon bazlı tekniklere göre daha avantajlı olduğu vurgulanmıştır.

Kai Keng Ang ve ark(2008), çalışmalarında, Graz Üniversitesi tarafından yapılan yarışmanın BCI III-IVa veri setini kullanarak EEG sinyallerinden elde edilen sağ el ve sol ayak motor hayali hareketlerini sınıflandırmışlardır. Beş denekten 280 deneme olacak şekilde veri toplanmıştır. Önerilen çalışmada, deneğe özel frekans verileri için bir algoritma(FBCSP) geliştirilmiştir. Bu algoritma ile farklı frekans bantlarındaki verilerden CSP ile otomatik özellik seçimi yapılmıştır. CSP ile çıkarılan öznelik vektörleri SVM, Naive Bayes Parzen, k-NN ve LDA gibi lineer sınıflandırıcıların girişine uygulanmıştır. Yapılan test karşılaştırmalarında, SBCSP algoritmasıyla yapılan çalışmanın doğruluk oranı %89, geleneksel CSP ile yapılan çalışmanın doğruluk oranı %86 çıkmasına karşın önerilen metodun doğruluk oranı %90 gibi yüksek bir orana erişmiştir. Çoğu deneğin EEG sinyallerindeki ayırt edici özellikleri, farklı frekans bantlarına yayılarak değişkenlik gösterdiğinden, şahsa özel ayırt edici özellikleri tespit eden yeni bir algoritmanın geliştirilmesi, yapılan çalışmanın özgün ve güçlü yönlerini yansıtır.

P. Senthil Kumar ve ark.(2009), RLS(Recursive Least Square) adaptif filtre algoritması ve Wavelet Dönüşümü algoritmalarını kullanarak EEG sinyallerini EOG gürültülerinden arındırmak için hybrid bir yaklaşım sunmuşlardır. Çalışmada, MIT-BIH polysomnography Database-Physiobank tarafından sağlanan EEG ve EOG verileri kullanılmıştır. 10-20 sistemli evrensel EEG kanallarından EOG gürültüleri baskın olan FP₁,FP₂, F₇ ve F₈ kanalları çalışmaya dahil edilmiştir. Önerilen metodun amacı, sinyalin önemli frekans bileşenlerine zarar vermeden, sinyal doğasında meydana gelen ani değişimlerinden(EOG, ECG vs.) kaynaklı gürültüleri, filtre katsayılarını dinamik olarak değiştiren RLS algoritması ile temizlemektir. Önerilen metotta, ilk etapta hem EEG hem de EOG sinyallerine Symlet 3 dalgacık fonksiyonu uygulanmıştır. Detay alt bandında elde edilen EOG verileri referans olarak adaptif filtrenin girişine uygulanmış ve yine detay bandından elde edilen kirlenmiş EEG sinyalinden çıkarılarak sinyal temizlenmiştir. Bu aşamadan sonra sinyal wavelet(wavelet reconstruction) ile tekrardan yapılandırılmıştır. Temizlenen EEG'nin spektral bileşenlerinin korunduğu, çizdirilen güç spektrumu ve frekans korrelasyon grafiklerinden anlaşılmaktadır.

LI Ming-Ai ve ark(2009), çalışmalarında, geleneksel CSP yöntemini modifiye

ederek sınıflandırma performansı daha yüksek bir yöntem sunmuşlardır. 140 denemeyi kapsayan ve Graz Üniversitesi BCI merkezinden elde ettikleri veri setini kullanmışlardır. Bu denemelerden 70'i hayali sağ el hareketini, 70'i hayali sol el motor hareketi kaydını içermektedir. C3, C4 ve Cz kanallarından elde edilen EEG verileri 128 Hz'lik örnekleme frekansına sahiptir. Bu veriler bandpass filtresi kullanılarak, 8-30 Hz frekans aralığını kapsayacak şekilde filtrelenmiştir. CSP'de veri ön işleme yapılırken 2 ya da daha fazla eigen vektör seçimi yapılır ve özellik vektörünü seçmek için varyans operasyonları icra edilir. Çok kanallı EEG sinyallerine bu metod uygulanırken seçilen eigen vektörlerin tekrarlanma durumundan kaynaklı sınıflandırma performanslarında düşüş gözlenir. Bu çalışmada, bahsi geçen problemten kaçınmak için CSP yöntemi modifiye edilmiştir. Bu bağlamda en iyi eigen vektörün en büyük eigen değeri seçilerek tekrarlayan eigen değerlerinden kaçınılarak sınıflandırma performansı yükseltilmiştir. Çalışmada, Sınıflandırıcı olarak doğrusal SVM kullanılmıştır. Veri setine geleneksel CSP uygulanarak elde edilen ortalama doğruluk oranı %81,4 olmasına karşın yeni geliştirilen metodun performansı, ortalama %92,1 gibi yüksek bir orana yükselmiştir.

Fabien Lotte ve Cuntai Guan(2010), çalışmalarında, BBA yarışmalarında en popüler metotlardan biri olan genel ortak uzamsal örüntüler(CSP) algoritmasını geliştirerek regülerize edilmiş dört yeni CSP algoritması sunmuşlardır. Klasik CSP algoritmasının gücü ve yaygın kullanımı bilinmesine rağmen gürültü ve aşırı uyum(overfitting) duyarlı olduğu da bilinmektedir. Önerilen bu dört algoritma bu hassasiyetlerden kaynaklı problemleri minimize etmektedir. BCI yarışmalarında kullanılan, BCI III(3a ve 4a) ve BCI IV(4a) veri setleri ile yapılan analizlerde yeni sunulan algoritmalarından RCSP, geleneksel CSP yöntemine kıyasla yaklaşık olarak %10 daha yüksek medyan sınıflandırıcı performansına erişmiştir. Bu yönleriyle ilgili çalışma, BBA çalışmaları için yeni ve güçlü bir uzamsal filtre yaklaşımı sunmaktadır.

Berna Akıncı ve Nevzat Güneri(2010), yapmış oldukları çalışmada, çevrimiçi ipucu-bazlı sağ ve sol el motor hayallerini sınıflandırmaya yönelik bir BBA sistemi geliştirmişlerdir. ODTU laboratuvarında 10 kanallı EEG cihazından kayıtlar alınmıştır. Çalışmada her bir denekten, ekranda beliren ok yönlerine göre ilgili yönün sağ veya sol elin hareket düşüncesi istenmiştir. Sunulan ipucunun görüntülenmesi sonlandıktan hemen sonra sınıflandırma algoritmasının 3 saniye içinde ekrana çıktı vermesi istenmiştir. Distinctive Sensitive Learning Vektor Quantization(DSLVQ) yöntemi ile çıkarılan

öznitelik vektörleri Destek Vektör Makinalarının(DVM) girişine uygulanarak sınıflandırma yapılmıştır. Önerilen yöntem ile sınıflandırma performansı %97,56'lık doğruluk oranına ulaşılmıştır. Sistemin dezavantajı, tek denek üzerinde test edilmesidir. İleri çalışmaların, kişi-bazlı olacak şekilde optimize edilmesi düşünülmektedir.

Neethu Robinson ve Cuntai Guan(2011), yapmış oldukları çalışmada, el hareketinin yönünü tespit eden wavelet tabanlı CSP(common spatial pattern) algoritmasını sunmuşlardır. Önerilen çalışmada, her bir deneme için ekranın ortasında beliren nesneyi deneklerden kuzey, güney, doğu ve batı yönlerinden birine hayali bir şekilde götürmeleri istenmiştir. Sağ elini kullanan iki denneğin sol korteksinden alınan 12 kanallı kayıttan C3 kanalını içeren kayıt kullanılmıştır. Özellik çıkarımı kısmında sinyal daubechies dalgacığı ile alt frekans bantlarına ayrılmıştır. Alt frekans bantlarına ayrılan sinyalden elde edilen detay ve yaklaşımlar katsayıları tekrardan yapılandırılmıştır.(reconstruction process) Tekrardan yapılandırılan sinyal CSP tekniği ile filtrelenmiş ve çıkarılan öznitelik vektörleri LDA(Linear Discriminant Analysis) sınıflandırıcının girişine uygulanmıştır. Sınıflandırıcının çıkışında birinci denek için ortalama %90,25, ikinci denek için ortalama %87.85 yüksek doğruluk oranı elde edilmiştir. Yüksek doğruluk oranı ile literatüre sunulan bu metot, EEG sinyallerinin çoklu-yön bilgilerini sakladığını teyit ediyor.

Kais Belwafi ve ark.(2014), yapmış oldukları çalışmada, motor hayali el hareketlerinin sınıflandırılması ile ilgili yeni bir filtreleme tekniği geliştirmişlerdir. Geliştirilen filtre, kişi-bazlı frekans varyasyonuna uyum sağlayacak şekilde tasarlanmıştır. Sunulan metodun amacı, sağ ve sol el motor hayalinin kontrolü için geliştirilen bir cihazın, hali hazırda sunulan metotlarda gösterdiği doğruluk performansını artırma üzerinedir. Graz üniversitesi tarafından sunulan, BCI yarışması IV(1 veri seti) ve BCI yarışması III(2 veri seti) veri seti olarak kullanılmıştır. Motor hayali üzerine etkisi olduğu düşünülen C3 ve C4 kanalları değerlendirilmiştir. Özellik çıkarma kısmı öncesinde, mu ve Beta bantlarındaki motor hayalinin etkin olduğu frekans bilgilerine zarar vermeyen özel bir filtre geliştirilmiştir. Bilgiler ilgili filtreden geçirildikten sonra CSP türlerinden CSP, SRCSP, CCSP1 ve DLCSPauto gibi algoritmalara tabi tutularak öznitelik vektörleri çıkarılmıştır. Çıkarılan öznitelik vektörleri, Linear Discriminant Analysis(LDA), destek vektör makinaları(DVM), yapay sinir ağları(YSA), saklı markov modelleri(HMM), Mahalanobis Distance(MD) sınıflandırma algoritmalarının girişlerine

uygulanarak sonuçlar elde edilmiştir. Çıkarılan sonuçlar veri seti IIIa'da %100, IIa'da %91,66 ve IVa'da %50 gibi yüksek kappa değerlerine ulaşmıştır. Kontrol sistemi üzerinde çalışan yeni algoritmada, sistem, eğitim aşaması için ilk etapta 1,19 saniyelik sürede tepki verse de eğitim aşamasından sonraki her bir deneme için yaklaşık 0,02 saniyelik hızlı tepkiler göstermiştir. Bu yönüyle, geliştirilen sistemin yüksek doğruluk performansına dayalı, tepki süresi düşük ve hızlı bir sistem olduğu vurgulanabilir.

Önder Aydemir(2016), CSP tekniği ile öznitelik vektörleri çıkarılan EEG sinyallerinin sınıflandırma performanslarını yükseltmek için EEG sinyallerindeki en iyi zaman aralığını seçecek bir algoritma geliştirmiştir. BBA çalışmalarında karşılaşılan zorluklardan biri olan kişiye özgü öznitelik vektörlerini seçme hususuna bir alternatif sunmuştur. Çalışmada yaşları sırasıyla 24, 24 ve 28 olan üç erkek, denek olarak kullanılmıştır. Sırasıyla A, B ve C notasyonlarıyla belirtilen deneklerden, ekranın ortasında duran kursoru, motor hayali ile ekranın sağ, sol, yukarı ve aşağı kısmında beliren bir hedefe doğru hareket ettirmeleri istenmiştir. İki oturum şeklinde yapılan veri alma işleminin ilk(148 deneme) oturumu eğitim, ikinci oturumu(152 deneme) test için kullanılmıştır. Veriler The Brain Quick EEG system(Micromed, Italy) 18 kanallı EEG cihazından elde edilmiştir. EMG ve EOG'den kaynaklı gürültülerden kaçınmak için bu bölgelere yakın olan FP₁,FP₂, O₁ ve O₂ kanalları çalışmaya dahil edilmemiştir. Çalışmada en iyi zaman penceresini seçebilmek için motor hayali yapılan 8 saniyelik zaman dilimi içerisinde, 0.2 saniyelik(0-0.2 sn aralığı) bir zaman dilimi seçilmiştir. Bu işlem için 10 katlı çapraz-doğrulama(10-FCV) işlemi gerçekleştirilmiştir. Sonrasında 0.2'lik pencere aynı sinyal içerisinde 0.2 saniye(0.2-0.4 sn aralığı) kaydırılarak yine 10 katlı çapraz-doğrulamaya tabi tutulur. Bu durum 8. saniyenin sonuna kadar kaydırılarak 10 katlı çapraz-doğrulama sonucunda sınıflandırma performansını en iyi şekilde yansıtan öznitelik vektörünün seçilmesi sağlanmıştır. İlgili metot ile gerçekleştirilen denemelerin ve 8 saniyelik denemenin bütün zaman diliminin hesaba katılması ile ilgili sonuçlar tablolara yansıtılmıştır. Ortalama doğruluk oranları ve ortalama kappa metrik değerleri tablolara yansıtılarak karşılaştırılmıştır. İlgili metodun bütün görev türlerindeki ortalama başarı performansı, bütün zaman diliminin(8 saniye) hesaba katılmasıyla elde edilen sonuçlardan yaklaşık olarak %50 daha yüksek olduğu gözlenmiştir. Sonuç olarak önerilen metodun, hem işlem maliyeti hem de sınıflandırma performansı açısından geleneksel yöntemlere göre daha iyi sonuçlar verdiği kanıtlanmıştır.

Bu çalışmada, yukarıda özetleri çıkarılan makalelerden alınan bilgilere göre bir yol haritası çizilmiştir. Adaptif RLS filtreleri, bandpass filtreler ve CSP tekniğini yaptığımız çalışmada kullandık. Graz Üniversitesi tarafından sunulan 4. BBA yarışmasının 2a veri seti materyal olarak kullanılmıştır. 9 denek üzerinden alınan EEG verileri, bandpass ve adaptif RLS filtreleri ile ayrı ayrı EOG'den arındırılmıştır. Arındırılan sinyallere ayrı ayrı CSP algoritması uygulanmıştır. CSP algoritmasından elde edilen 4 öznitelik vektörü LDA, SVM, Naive Bayes ve k-NN sınıflandırma algoritmalarının girişlerine uygulanarak sonuçlar kappa skor, doğruluk, kesinlik, f-skor, duyarlılık, kesinlik gibi performans kriterlerine göre değerlendirilerek çıkarımlar yapılmıştır.

3. MATERYAL VE METOT


3.1 Materyal

Kullanılan veri seti 2008 de Graz Üniversitesi tarafından sağlanan yarışmada(BCI Competition 2008) kullanılan veri setlerinden biridir. Çizelge 3.1’de dosya isimleri verilen ve Dataset IIa olarak adı geçen veri seti, 9 farklı denekten alınan EEG verilerini kapsamaktadır. Her bir denek sandalyeye oturur vaziyette ve ekrandan 1 m göz uzaklıkta bulunacak şekilde konumlandırılmıştır. Her bir denek için 2 oturum gerçekleştirilmiştir. Her bir oturum 6 süreçten oluşmaktadır. Her bir süreç 48 denemeden oluşmaktadır. Her bir oturum için toplamda 288 deneme mevcuttur. Sağ el hareket hayali, sol el hareket hayali, ayak hareket hayali ve dil hareket hayali olmak üzere veri seti 4 sınıfı kapsamaktadır.(University of Graz 2008) Oturum dosyaları ve isimleri Çizelge 3.1’de belirtilmiştir.

Çizelge 3.1 Oturum Dosyaları


ID	Eğitim Verileri	Test Verileri
1	A01T.gdf	A01E.gdf
2	A02T.gdf	A02E.gdf
3	A03T.gdf	A03E.gdf
4	A04T.gdf	A04E.gdf
5	A05T.gdf	A05E.gdf
6	A06T.gdf	A06E.gdf
7	A07T.gdf	A07E.gdf
8	A08T.gdf	A08E.gdf
9	A09T.gdf	A09E.gdf

Her bir denemenin başında($t = 0$ s), deneğin hazırlanması için siyah ekranda bir (+) işareti belirir. Denek ekranda (+) işaretiyle eşzamanlı bir bip sesi duyar. 2 saniye sonra 1.25 saniye sürecek şekilde ilgili sınıfın imleç hareketini(sağ, sol, yukarı ve aşağı) belirten bir ok deneğe gösterilir. Bu imleç hareketleri sırasıyla sağ el hareket hayali, sol el hareket hayali, ayak hareket hayali ve dil hareket hayali sınıflarına aittir. Bu ok işareti deneğin motor hareket hayali için hazırlanması gerektiğini belirten bir işarettir. İlgili ok işareti ekrandan kaybolana kadar($t = 6$ sn) deneğin ilgili motor hareket hayalini gerçekleştirmesi istenir. Ekranın tekrardan siyah olmasıyla denekten yaklaşık 2 saniyelik bir ara vermesi istenir. Yarışmada sunulan paradigma Şekil 3.1’de gösterilmiştir.




Şekil 3.1. Örnek bir denemenin zamana bağlı olaylar silsilesi(University of Graz 2008)

EEG verileri Şekil 3.2’de gösterilen elektrot lokasyonlarından 250 Hz örnekleme frekansı ile kaydedilmiştir. Veriler, 22 EEG ve 3 EOG kanalından kaydedilirken 0.5 Hz ve 100 Hz spektral aralığı kapsayacak şekilde bandpass filtreden geçirilmiştir. Buna ek olarak şebeke frekansını baskılamak için 50 Hz’lik Notch filtresi kullanılmıştır. Fz elektrot lokasyonu, referans elektrotu olarak kullanılmıştır.



Şekil 3.2. 22 kanallı elektrot lokasyonları

EOG kanallarından Şekil 3.3’te gösterildiği gibi 3 monopolar elektrot ile kayıtlar alınmıştır.



Şekil 3.3. 3 Monopolar EOG kanalının elektrod montajı

Her bir oturumda yaklaşık EOG'nin EEG'ye etkisi gözlenmek üzere 5 dakikalık muhtelif EOG kayıtları alınmıştır. Bu kayıtlar 3 kısma ayrılabilir. Bu 3 kısımdan son kısım olan gürültü kısmı da 15 saniyelik bloklar halinde 4 kısma ayrılır;

1. 2 dakika gözler açık durumu(Ekranda beliren + işaretine bakarak)
2. 1 dakika gözler kapalı durumu
3. 1 dakika çeşitli göz hareketleri

Teknik problemlerden ötürü A04T oturumunda yukarıda sayılan durumlardan sadece çeşitli göz hareketleri durumu mevcuttur.



Şekil 3.4. EOG kayıt sırası

Yapmış olduğum çalışmada, deneklerin kayıtlarından sağ ve sol el imleç hareketlerini içeren denemeler çekilmiştir. Dolayısıyla yapılan çalışma, sağ el motor hayali ve sol el motor hayalini kapsamaktadır.

3.2 Metot


Şu an bir çok alanda faydalı şekilde kullanılan EEG sinyallerinin en büyük dezavantajlarından biri göz hareketlerinden kaynaklı gürültülerden etkilenmesidir. Özellikle 10-20 sistemli elektrot kanallarından gözlere yakın bölge F_1 , F_2 , FP_1 ve FP_2 kanalları, göz hareketlerinden kaynaklı gürültülerden çok fazla etkilenirler. EOG gürültülerini ortadan kaldırmak için yaygın olarak kullanılan regresyon bazlı teknikler, birçok önileme, prosedür ve de kalibrasyon işlemi gibi dezavantajlara sahiptir. Aynı zamanda bu işlemler ciddi zaman israfına neden olur. Bu bağlamda EOG gürültülerini gidermek için kullanım kolaylığı, stabilite ve hızlı kavuşma gibi özellikleri içerisinde barındıran adaptif bir algoritmaya ihtiyaç vardır. Adaptif filtre algoritmalarından Recursive Least Square(RLS) algoritması, bu koşulları sağladığı için çalışmada RLS yöntemi kullanılmıştır.

3.2.1 Veri Temizleme ve Motor Hareket Hayali Frekans Bandı

3.2.1.1 RLS Adaptif Filtresi

RLS yönteminde, Lineer Regresyondaki gibi cost fonksiyonu kullanılır. MSE(Mean Squared Error) kademeli olarak azaltma esasına dayanır. Least Mean Square(LMS)'den farklı olarak rasgelelik yoktur. Çözümüne hızlı ulaşan bir algoritmadır. Bu yönüyle online işlemlerde de kullanılabilir.

Şekil 3.5'te gürültü gideren ve 1 referans girişine sahip RLS filtresinin blok diyagramı verilmiştir.



Şekil 3.5. RLS filtresinin blok diagramı

Yukarıdaki modelde, $s(n)$ EOG sinyali ile kirlenmiş gürültülü sinyali temsil eder. $x(n)$ saf EEG sinyalinin ve $z(n)$ gürültü bileşenini (yatay göz hareketi gürültüsü) temsil eder.

$r_h(n)$ referans girişi, bir şekilde $z(n)$ ile korelasyona sahip yatay göz hareketi gürültü sinyalidir(HEOG). $h_h(m)$, M'inci dereceden adaptif FIR filtresinin dürtü yanıtını temsil eder.

Adaptif filtrenin çıkışı, $e(n)$ şu şekilde ifade edilir;

$$e(n) = s(n) + r_h(n) \quad (3.1)$$

$$= x(n) + [z(n) - r_h(n)]$$

$$r_h(n) = \sum_{m=1}^M h_h(m) r_h(n+1-m) \quad (3.2)$$

x 'in durağan rasgele sinyal olduğu ve z ve r_h korelasyonunun olmadığı varsayımlarda, e^2 şu şekilde hesap edilir.

$$E[e^2] = E[(x + z + r_h)^2] \quad (3.3)$$

$$E[x^2] = E[(z + r_h)^2]$$

Gürültü giderici filtrenin amacı, filtre katsayılarını $h_h(m)$ ayarlayarak $e(n)$ çıkış sinyalini mümkün olduğunca $x(n)$ 'e yaklaştırmaktır. İstatistiksel olarak, hatanın yani $E[(z - r_h)^2]$ ifadesinin minimize edilmesiyle mümkündür.

$E[x^2]$ filtre katsayılarından etkilenmez. $E[(z - r_h)^2]$ minimize edilmesi $E[e^2]$ ifadesinin minimize edilmesi demektir.

Filtre katsayılarının bu tarzda ayarlanması RLS algoritması ile yapılır. Yukarıdaki formül herhangi bir t_n zaman dilimi için örneklenmiş bir sinyal için tekrardan düzenlendiğinde, t_n zaman dilimindeki her bir örnek $s(i)$, $r_h(i)$ ve $e(i)$ için $i = 1, 2, 3, 4, 5 \dots, n$ durumlarına göre $e(n)$ minimize edilir.

$$\begin{aligned} \varepsilon(n) &= \sum_{i=M}^n \lambda^{n-i} e^2(i) \\ &= e^2(n) + \lambda e^2(n-1) + \dots + \lambda^{n-M} e^2(M) \end{aligned} \quad (3.4)$$

Yukarıdaki eşitlikte $0 < \lambda < 1$ unutma faktörü olarak adlandırılır ve her bir örnek için;

$$e(i) = s(i) - \sum_{m=1}^M h_h(m) r_h(i + 1 - m) \quad (3.5)$$

eşitliği elde edilir.

Yinelenen senaryoda, istatistiksel bütün verileri elde etmek mümkün değildir. Bundan dolayı $E[e^2]$ yerine $\varepsilon(n)$ minimize edilecek. Buna ek olarak, unutma faktörü(λ) dikkate alınarak, algoritmanın tam durağan olmayan-rastgele işlemlere de uygulanabilirliği sağlanıyor.

Filtre katsayıları, $h_h(m)$, $m = 1, 2, 3, 4, 5 \dots, M$ için $e(n)$ 'i minimize eden denklemler aşağıda gösterildiği gibidir;

$$\begin{aligned} \frac{\partial \varepsilon(n)}{\partial h_h(m)} &= 2 \sum_{i=M}^n \lambda^{n-1} e(i) \frac{\partial \varepsilon(i)}{\partial h_h(m)} \\ &= -2 \sum_{i=M}^n \lambda^{n-1} e(i) r_h(i + 1 - m) = 0 \end{aligned} \quad (3.6)$$

$m = 1, 2, 3, 4, 5 \dots, M$ için $e(i)$ yerine konulduğunda aşağıdaki matris formu elde edilir.

$$H = [R(n)^{-1}] \cdot P(n) \quad (3.7)$$

Yukarıdaki eşitlikte $R(n)$, $(M \times M)$ kare matris, H ve $P(n)$ M boyutlu kolon vektörleridir.

$$R(n)(j, k) = \sum_{i=M}^n \lambda^{n-1} r_h(i + 1 - m) r_h(i + 1 - k) = 0 \quad (3.8)$$

$$P(n)(j) = \sum_{i=M}^n \lambda^{n-1} s(i) r_h(i + 1 - j) = 0 \quad (3.9)$$

$$H = [h_h(1) h_h(2) \dots h_h(M)]^T \quad (3.10)$$

Filtre katsayılarının doğrudan denklem (3,7) kullanılarak çözülmesi yüksek işlem maliyeti gerektirir. RLS algoritması kullanılarak aşağıdaki denklemler ile işlem maliyeti önemli ölçüde azaltılır;

$$R(n) = \lambda R(n-1) + r(n)r(n)^T \quad (3.11)$$

$$P(n) = \lambda P(n-1) + s(n)r(n) \quad (3.12)$$

$$r(n) = [r_h(n)r_h(n-1) \dots r_h(n+1-M)]^T \quad (3.13)$$

Denklem (3.11)'deki matrisin tersi kullanılarak aşağıdaki yinelemeli ilişki elde edilir.

$$[R(n)]^{-1} = \lambda^{-1}R(n-1)^{-1} - \lambda^{-1}K(n)r(n)^T [R(n-1)]^{-1} \quad (3.14)$$

Yukarıdaki denklemden $K(n)$ yalnız bırakılırsa;

$$K(n) = \frac{[R(n-1)]^{-1}r(n)}{\lambda + r(n)^T [R(n-1)]^{-1}r(n)} \quad (3.15)$$

eşitliği elde edilir.

Denklem (3.15) kullanılarak, Denklem (14) ve (12) denklem (7)'de yerine konulursa filtre katsayılarını güncelleyen aşağıdaki denklem elde edilir;

$$H(n) = H(n-1) + K(n)e\left(\frac{n}{n-1}\right) \quad (3.16)$$

Yukarıdaki denklemde n zaman diliminde filtre katsayıları $H(n) = [R(n)]^{-1}.P(n-1)$ ifadesiyle ve $(n-1)$ zaman aralığında filtre katsayıları $H(n-1) = [R(n-1)]^{-1}.P(n-1)$ şeklinde ifade edilir. Sonuç olarak aşağıdaki hata fonksiyonu elde edilir.

$$e\left(\frac{n}{n-1}\right) = s(n) - r(n)^T H(n-1)$$

3.2.2 Common Spatial Patterns(CSP)

Motor hayali çalışmalarında, öznitelik vektörü çıkarma hususunda en yaygın kullanılan metot, ortak uzamsal örüntüler(CSP) metodudur.(Grosse ve ark. 2008) CSP metodu, bir sınıfın varyansını maksimuma çıkarırken aynı anda diğer sınıfın varyansını minimize eden bir algoritmadır.(Aydemir Ö. 2016)

EEG sinyalinin normalize edilmiş uzamsal kovaryans matrisi aşağıdaki şekilde hesaplanır;

$$M = \frac{DD^T}{\text{trace}(DD^T)} \quad (3.17)$$

D , bir denemenin $C \times S$ (C , kanal sayısı ve S örnek sayısı) matrisini belirtir. trace , DD^T diagonal elemanların toplamını temsil eder. Uzamsal kovaryans matrisi her bir sınıfın denemesinin ortalaması ile hesaplanır. Ortaya çıkan iki sınıflı matris toplanır ve aşağıdaki kompozit kovaryans matrisi M_C elde edilir.

$$M_C = M_1 + M_2 \quad (3.18)$$

M_C , eigen vektörleri ve eigen değerlerini içerecek şekilde aşağıdaki gibi tekrardan düzenlenebilir.

$$M_C = E_c \lambda_c E_c^T, \quad (3.19)$$

Yukarıda 3. denklemden E_c matrisin eigen vektörleri ve λ diagonal matrisin eigen değerlerini temsil eder. Varyansları eigen düzleminde birbirine eşitleyen dönüşüm,

$$W = \sqrt{\lambda_c^{-1}} E_c^T \quad (3.20)$$

formülü ile hesaplanır. W , ortalama kovaryans matrislerinin dönüşümünde,

$$K_1 = W M_1 W^T \quad K_2 = W M_2 W^T \quad (3.21)$$

şeklinde kullanılır. K_1 ve K_2 ortak eigen vektörlerini paylaşır ve iki matrisin eigen değerlerinin toplamı her zaman 1'e eşittir.

$$K_1 = U \lambda_1 U^T \quad K_2 = U \lambda_2 U^T \quad (3.22)$$

$$\lambda_1 + \lambda_2 = I$$

Yukarıdaki denklemden I eş matristir. Son olarak projeksiyon matrisinde,

$$P = (U^T W)^T$$

Kolonlar P^{-1} , ortak uzamsal örüntülerdir. Projeksiyon matrisi ile birlikte, her bir denemenin ayrıştırılması,

$$Z = PD \quad (3.23)$$

şeklinde yapılır. Eigen değerlerinin toplamı her zaman 1 olduğundan, Z 'nin ilk ve son satırının varyansı öznitelik çıkarımı için uygundur. Bu çalışmada ilk ve son satırın varyansı öznitelik olarak kullanılacaktır. Varyansa aşağıdaki formülle hesaplanır;

$$V = \frac{\sum (Z_R - \bar{Z}_R)^2}{L - 1} \quad (3.24)$$

Denklem 3.24'de Z_R , Z matrisinin bir satırı ve L ise bu satırın uzunluğudur.

3.2.3 Sınıflandırma Algoritmaları

3.2.3.1 Lineer Diskriminant Analizi(LDA)

1936 yılında Fisher tarafından geliştirilen bir algoritmadır. Basit yapıda olmasına rağmen kompleks problemlerde iyi sonuçlar veren bir sınıflandırma yöntemidir. Fisher, denklem 1'de belirtilen skor fonksiyonunu tanımlamıştır.

$$Z = \beta_1 x_1 + \beta_2 x_2 + \dots \beta_d x_d \quad (3.25)$$

Skor fonksiyonu denklem 3.26'da belirtildiği gibidir;

$$S(\beta) = \frac{\beta^T \mu_1 + \beta^T \mu_2}{\beta^T C \beta} \quad (3.26)$$

$$S(\beta) = \frac{\bar{Z}_1 + \bar{Z}_2}{Var(Z)} \quad (3.27)$$

Model katsayıları;

$$\beta = C^{-1}(\mu_1 - \mu_2) \quad (3.28)$$

Toplanmış Kovaryans Matrisi;

$$C = \frac{1}{n_1 + n_2} (n_1 C_1 + n_2 C_2) \quad (3.29)$$

Yukarıdaki denklemlerde;

β : Lineer model katsayıları

C_1 ve C_2 : Kovaryans matrisleri

μ_1 ve μ_2 : Ortalama vektörler

En iyi diskriminantı elde etmek için Mahalanobis mesafesini elde etmek gerekiyor. Mahalanobis mesafesinin 3'ten küçük olması, yapılacak sınıflandırmanın yanlış olma ihtimalinin küçük olması anlamına gelir.

$$\Delta^2 = B^T (\mu_1 - \mu_2) \quad (3.30)$$

Δ : İki sınıf arasındaki Mahalanobis farkı...

Bu aşamadan sonra, eğer denklem 3.31'deki şart sağlanırsa, yeni gelen öznitelik sınıflandırılabilir.

$$B^T \left(x - \left(\frac{\mu_1 + \mu_2}{2} \right) \right) > \log \left(p \left(\frac{c_1}{c_2} \right) \right) \quad (3.31)$$

3.2.3.2 Naive Bayes(NB)

Sınıflandırma problemlerine olasılıkla çözüm getiren bir sınıflandırma algoritmasıdır. Önceden sınıflandırdığı verilerin olasılıklarına göre yeni gelen test verisini değerlendirerek sınıflandırır.

Her biri m tane özellik barındıran n adet sınıf olduğu düşünölsün. Bu sınıflardan her hangi birine dahil olan veri grubu farz edölsin. Sınıfı belli olmayan bir Y verisi için bütün sınıflara ait olma ihtimalleri hesaplanır. Çıkan en yüksek ihtimal hesabına göre o verinin sınıfı tespit edilir.

$$P(S_i|Y) = \frac{P(Y|S_i)*P(S_i)}{P(Y)} \quad (3.32)$$

$P(S_i|Y)$: Y durumu gerçekleştiğinde, S_i olayının gerçekleşme ihtimali

$P(Y|S_i)$: S_i durumu gerçekleştiğinde, Y olayının gerçekleşme ihtimali


$P(Y)$, $P(S_i)$: Y ve S_i olaylarının önsel olasılıklarıdır. Veriler bağımsız değerlendirildiğinden ve aynı öneme sahip olduğundan her bir $P(Y)$ değeri, her gelen veri için aynı olur. Bundan dolayı denklem 3.33’de olduğu gibi modifiye edilebilir.

$$P(S_i|Y) = P(Y|S_i) * P(S_i) \quad (3.33)$$

Denklem 3.33’te elde edilen sonuç ile test verisinin en yakın olduğu sınıf tespit edilir.

3.2.3.3 K En Yakın Komşu Algoritması(KNN)

KNN algoritmasında bir verinin bir kümeye en yakın durumu esas alınır. Önceden sınıflandırılmış bir veri setine, bir test verisi katıldığı zaman, bu test verisinin gruplanmış k tane veriye uzaklığı analiz edilir. Sınıflandırılmaya çalışılan veri için $k = 4$ ise, en yakın 4 komşu dikkate alınır. Temsili sınıflandırma Şekil 3.6’da göstermiştir.




Şekil 3.6. KNN algoritması, temsili sınıflandırma

KNN algoritması uzaklık hesaplamalarında birkaç yöntem mevcuttur. Bunlar, Minkowski, Eclidean, Hamming ve Manhattan metotlarıdır. Bu çalışmada, Eclidean denklemi(3.34) kullanılmıştır.

$$d(x, y) = \sqrt{\sum_{i=1}^n (X_i - Y_i)^2} \quad (3.34)$$

3.2.3.4 Destek Vektör Makinaları(DVM)

Aynı zamanda Support Vektor Machines(SVM) olarak bu algoritma, binari ve çoklu veri setleri için kullanılabilir. Sınıf üyelerinden her birine, en fazla olan uzaklığı olan doğruyu sınır olarak tercih eder.(Largest Margin). Largest Margin(en yüksek tolerans) prensibi, sınıflandırmayı en güvenli şekilde yapmak içindir. Kernel fonksiyonları kullanılarak lineer olarak tam olarak ayrılamayan, kompleks sınıf üyeleri ayrılabilir.(Non Linear SVM)



Şekil 3.7. SVM maximum tolerans temsili gösterimi(Haltuf 2014)

Şekil 3.7’de iki sınıflı(binary) veri setinin, 2 boyutlu vektör uzayında, maksimum tolerans düzlemi ile sınıflandırıldığı görülmektedir. Bu düzlemdeki her bir nokta aşağıdaki denklem ile ifade edilebilir.

$$D = \{(X_i, C_i) | X_i \in R^P, C_i \in \{-1, 1\}\}_{i=1}^n \quad (3.35)$$

Denklem 3.35’deki gösterimin bir aşırı düzlem(hyperplane) üzerinde olduğu düşünülürse, her bir nokta denklem 3.36’daki gibi ifade edilebilir.

$$wx - b = 0 \quad (3.36)$$

Denklem 3.36’da w, aşırı düzleme dik olan vektörü, x, bu noktanın değişken parametresi ve b ise uzaklığa göre kayma oranıdır denilebilir. Denklem 3.36’de, b/|w| oranı iki veri grubu arasındaki mesafe farkını verir. Bu mesafe denklemine göre, Şekil 3.6’da gösterilen aşırı düzleme göre elde edilen 2 doğru denklemi, denklem 3.37 ve 3.38’de ifade edilmiştir.

$$wx - b = -1 \quad (3.37)$$

$$wx - b = 1 \quad (3.38)$$

Denklem 3.37 ve denklem 3.38, doğruların kaydırılmasıyla elde edilen en yüksek değerlerin elde edilmesinin bir sonucudur.

3.2.4 Performans Kriterleri

Çizelge 3.2’de gösterilen örnek konfüzyon matrisinde, A ile gösterilen değer sol el sınıfı doğru tahmin sayısını, D ile gösterilen değer sağ el sınıfı doğru tahmin sayısını gösterir. Bununla birlikte C ile gösterilen değer gerçekte sağ el sınıfına aitken sol el sınıfı olarak sınıflandırılan yanlış tahmin sayısını gösterir. Yine B ile gösterilen değer gerçekte sol el sınıfına aitken sağ el sınıfı olarak sınıflandırılan yanlış tahmin sayısını gösterir. Yapılan çalışmada her bir sınıflandırıcıya ait veriler bu şekilde temsil edilecektir.

Çizelge 3.2 Örnek Konfüzyon Matrisi

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	A(TP)	B(FN)
	Sağ	C(FP)	D(TN)

Çizelge 3.2’de gösterilen konfüzyon matrisi üzerinden performans kriterleri hesaplanmıştır.

3.2.4.1 Kappa Skor

Sınıflandırmada daha gerçekçi başarımlar elde etme amacıyla Cohen tarafından 1960 yılında sunulan kappa skor hem çoklu hem de 2 sınıflı uygulamalarda sıkça kullanılmaktadır. Kappa skor, doğruluk oranının “şans eseri ortaya çıkma olasılığı” hesaba katılarak yapılır.

$$ACC = \frac{A + D}{A + B + C + D} \quad (3.39)$$

$$K = \frac{(ACC - p_e)}{(1 - p_e)} \quad (3.40)$$

$$p_e = \frac{(A + C) * (A + B) * (B + D) * (C + D)}{N} \quad (3.41)$$

N = Deneme Sayısı

K = Kappa Skor

p_e = ACC’nin şans eseri ortaya çıkma ihtimali

ACC = Doğruluk oranı

K = 1 : iki sınıf birbiriyle tamamen uyuşmaktadır.

K = 0 : iki sınıf için uyuşma şans ile belirlenmiştir ve diğer durumlarda hiçbir uyuşma yoktur.

Kesinlik, Duyarlılık, F-Skor gibi diğer performans değerlendirme kriterleri de aşağıda gösterilmiştir.

TP = True Pozitif oranı

FP = False Pozitif oranı

FN = False Negatif oranı

TN = True Negatif oranı

$$Kesinlik = \frac{TP}{TP + FP} \quad (3.42)$$

$$Duyarlılık = \frac{TP}{TP + FN} \quad (3.43)$$

Recall = Duyarlılık

$$Özgüllük = \frac{TN}{TN + FP} \quad (3.44)$$

$$F\ Skor = \frac{2 * kesinlik * duyarlılık}{kesinlik + duyarlılık} \quad (3.45)$$

Kappa skor ile ilgili Landis, J. R., & Koch, G. G. 1977’de yazmış oldukları makalede aşağıdaki çıkarımlarda bulunmuşlardır.

Çizelge 3.2. Landis ve Koch’un kappa skor çıkarımları(Landis ve Koch, 1977)


Kappa	Çıkarım
<0	İki sınıf arasında hiç uyuşma yok
0.0 – 0.20	İki sınıf arasında önemsiz derecede uyuşma var
0.21 – 0.40	İki sınıf arasında orta derecede uyuşma var
0.41 – 0.60	İki sınıf arasında ekseriyetle uyuşma var
0.61 – 0.80	İki sınıf arasında önemli derecede uyuşma var
0.81 – 1.00	İki sınıf arasında mükemmele yakın derecede uyuşma var

Bulgular kısmında, sınıflandırma performansları ile ilgili çıkarımlar, daha gerçekçi olması yönüyle daha çok kappa skoruna göre değerlendirilecektir.




4. BULGULAR VE TARTIŞMA

Veriler Şekil 4.1 gösterildiği gibi EEG başlığı ile toplamda 22 kanaldan veri alınmıştır. EEG verileri kafatası bölgesindeki elektrotlardan elde edilirken eş zamanlı olarak, Şekil 4.2’de gösterildiği gibi göz çevrelerine yerleştirilen 3 elektrottan da EOG verileri kaydedilmiştir. Veri seti, EOG verileri birlikte toplamda 25 kanaldan oluşmaktadır. Çalışmamızda bu veriler offline olarak değerlendirilmiştir.




Şekil 4.1. 10-20 evrensel sistemli EEG elektrotları



Şekil 4.2. EOG elektrot montajı


4.1 Yarışmada Kullanılan Deneme Paradigması ve Sinyallerin Güç Spektrumları

Yarışmada Şekil 4.3'te gösterilen paradigma kullanılmıştır. Şekil 4.3'te bir deneme(trial)'nin olaylar silsilesi gösterilmiştir. “Motor Imagery” diye belirtilen 3-6 saniyelik zaman diliminde, kişi sağ ve sol el hareket motor hayalini icra ettiği için bu zaman dilimi çalışmaya dahil edilmiştir.




Şekil 4.3. Bir denemenin olaylar silsilesi ve hesaba katılacak zaman dilimi

Şekil 4.4 ve 4.5'te sınıflandırmaya dahil edilecek sağ ve sol el motor hareket hayali EEG verilerinin C3 kanalı verisi ve bu EEG sinyallerinden temizlenecek EOG sinyallerinin 3 saniyelik örnek kesitleri matlab ortamında zaman domeninde çizdirilmiştir. 3 saniye, 250 Hz ile örneklenmiş frekansın 750-1500 sample(örnek) aralığını kapsıyor.




Şekil 4.4. Örnek sağ el motor hayali EEG ve EOG sinyali




Şekil 4.5. Örnek sol el motor hayali EEG ve EOG sinyali

4. BULGULAR VE TARTIŞMA

Şekil 4.6 ve Şekil 4.7’de, yukarıda, zaman domeninde çizdirilen sinyaller welch psd yöntemiyle frekans domeninde çizdirilmiştir. Bu şekilde sinyallerin güç yoğunluklarının hangi bantlara yayıldığı gözlemlenebilir.



Şekil 4.6. Örnek sağ el motor hareket hayali C3 kanalı verisi ve EOG1 sinyalinin spektral gösterimi




Şekil 4.7. Örnek sol el motor hareket hayali C3 kanalı verisi ve EOG1 sinyalinin spektral gösterimi

Şekil 4.6 ve 4.7’de motor hayali sinyallerinin alfa ve beta bandına yayıldığı gözlemlenebiliyor. EOG sinyalleri farklı durumlarda 1-2 Hz, 2-4 Hz, 4-8 Hz, 8-16 Hz, 16-30 Hz ve az da olsa 30 Hz üstünde spektral değişimler gösterir (Daud, W. B. W., ve Sudirman, R. 2011). EOG sinyallerinin 8-16 Hz spektral özellikler sergilemesi, motor

hayali EEG sinyallerini de etkiler. Çünkü motor hayali sinyallerinde spektral öznitelikler çıkarılırken çoğunlukla 8-30 Hz frekans bandı öznitelik olarak seçilir. Şekil 4.6 ve Şekil 4.7’de eşzamanlı alınan EOG gürültüsünün spektral karakteristiklerinin bazı noktalarda EEG sinyallerini etkilediği gözlemlenebiliyor. Bu noktada veri ön işleme kısmında yapılması gereken iş sınıflandırılabilirken esas ayırt edici bilgiye zarar vermeden gürültü bileşenini ortadan kaldırmaktır. Bunun için regresyon bazlı, bandpass filtreleri, adaptif filtreler vs. çok çeşitli gürültü giderme seçenekleri mevcuttur. Bu çalışmada kullanılan veriler, gerçek zamanlı(real time) veya online olarak kullanılmaya uygun olduğundan ve bu tarzda elde edildiğinden hem bandpass hem de adaptif filtre seçilirken algoritmaların hızlı olması durumlarının göz önünde bulundurulması gerekiyor. Bu noktada adaptive filtre olarak recursive least square(RLS) algoritması seçilmiştir.

4.2 Çalışmanın Akış Diyagramı

Şekil 4.8’de mevcut çalışmanın akış diyagramı verilmiştir. gdf formatında bir bütün halinde olan veri setinin ilk etapta sağ ve sol trial(deneme) epoch’ları ayıklandı. 4 sınıflı ve 288 deneme olan veri seti, matlab ortamında belli proseslerden geçirilerek 2 sınıflı(sağ ve sol el) ve dolayısıyla 144 deneme haline getirildi. Bu şekilde bir eğitim veya test verisi, 144 denemeden oluşmaktadır. Her bir denemenin içerisinde 22 EEG kanalı ve 3 EOG kanalı mevcuttur. Veri ön işleme kısmının ikinci aşamasında her bir deneğe ait her bir denemenin 22 kanalı ayrı ayrı bandpass ve adaptif filtrelerinden geçirildi. Motor hayali verilerinin bulunduğu spektral aralık 8-30 Hz olduğundan veriler, bandpass filtreleri ile 8-30 Hz frekans aralığına filtrelendi. Bu şekilde EOG’dan kaynaklı yüksek frekans bileşenleri de toplamda 22 kanallı her bir EEG denemesinden temizlendi. Adaptif filtre ile temizleme aşamasında EOG1 kanalı(23. Kanal), adaptif filtrenin referans girişine, gürültülü her bir EEG denemesinin 22 kanalı, adaptif filtrenin birincil girişine(Primary Input) sırayla uygulandı. Adaptif filtrenin çıkışında her bir EEG denemesinin 22 kanalı EOG’dan arındırılmış oldu. Temizlenmiş deneme verileri ayrı ayrı CSP metoduna tabi tutuldu. Bu şekilde her bir denemenin 22 kanalı CSP algoritmasına giriş olarak uygulandı. CSP algoritmasının çıkışında her bir denemeden 4 öznitelik vektörü elde edildi. CSP ile çıkarılan bu 4 öznitelik vektörü, Naive Bayes, SVM, k-NN ve LDA sınıflandırıcılarının girişlerine uygulandı. Konfüzyon matrisleri elde edilen verilerin her bir sınıflandırıcı ile ilgili accuracy, kappa, sensitivity, specificity, f-score gibi performans değerleri elde edildi.



Şekil 4.8. Çalışmanın akış diyagramı

Bandpass ve adaptif filtreler kullanılarak elde edilen verilere CSP metodu uygulandıktan sonra elde edilen sınıflandırma sonuçları bundan sonraki aşamada tablolar ile gösterilecektir. İlk etapta 9 deneye ait veriler chebyshev 1 filtresi filtreledikten sonra sonuçlar tablolara yansıtıldı. Sonrasında her bir denek sırasıyla chebyshev 2, elliptic ve RLS adaptif filtresiyle filtreledikten sonra sonuçlar tablolara yansıtıldı.

4.3 Chebyshev Tip 1 İle Filtrelenen 9 Deneğin Verilerinin, SVM, LDA, Naive Bayes ve KNN Algoritmalarına Göre Başarı Performansları

Çalışmanın bu bölümünde, 9 deneğin her bir denemesinin her bir kanalı, chebyshev tip 1 filtresi kullanılarak ayrı ayrı temizlenmiştir. Passband frekans değerleri 10-20 Hz aralığına ayarlanmıştır. Veriler temizlendikten sonra 751x22x144 boyutlarında bir matris elde edilmiştir. Bu çok boyutlu matriste, 751, 3 saniyenin örnek sayısını, 22, kanal sayısını, 144, deneme sayısını temsil edecek şekilde oluşturulmuştur. Bu aşamadan sonra her bir denemenin 22 kanal bilgisi CSP algoritmasına giriş olarak verilmiştir. CSP algoritmasının çıkışında, 144x4 boyutlarında bir öznitelik vektörü elde edilmiştir. Yani 144 deneme sayısını, 4 öznitelik vektörünü temsil edecek şekilde bir çıkış elde edilmiştir. Bu öznitelik vektörleri ayrı ayrı SVM, LDA, Naive Bayes ve KNN sınıflandırma algoritmalarının girişlerine uygulanarak kappa, accuracy, precision, sensitivity, F-Score, specificity gibi performans kriterlerine göre başarımlar elde edilmiştir. Her bir

deneğin konfüzyon matrisi sınıflandırıcılara göre ayrıca tablolar ile gösterilmiştir. 9. denemenin sonunda, 9 deneğin ortalama başarımlarını performansları sınıflandırıcı bazında ayrıca tablanmıştır. Bu şekilde, chebyshev tip 1 filtresinin sınıflandırıcılar bazında en yüksek ortalama performans değerleri tablo ile yansıtılmıştır.

1. Denek- Chebyshev 1

Sınıflandırma performansları, konfüzyon matrisleri üzerinden hesaplanır. Çizelge 4.1'e sağ ve sol olmak üzere 2 sınıflı örnek bir konfüzyon matrisi modeli verilmiştir. Çizelge 4.1'de A ile gösterilen değer sol el sınıfı doğru tahmin sayısını, D ile gösterilen değer sağ el sınıfı doğru tahmin sayısını gösterir. Bununla birlikte C ile gösterilen değer gerçekte sağ el sınıfına aitken sol el sınıfı olarak sınıflandırılan yanlış tahmin sayısını gösterir. Yine B ile gösterilen değer gerçekte sol el sınıfına aitken sağ el sınıfı olarak sınıflandırılan yanlış tahmin sayısını gösterir. Yapılan çalışmada her bir sınıflandırıcıya ait veriler bu şekilde temsil edilecektir.

Çizelge 4.1 Örnek Konfüzyon Matrisi

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	A	B
	Sağ	C	D

Aşağıdaki gösterilen konfüzyon matrisleri 1. Deneğin SVM, LDA, NB ve k-NN sınıflandırma algoritmaları ile ilgili bilgi vermektedir.

4. BULGULAR VE TARTIŞMA

Konfuzyon M.(SVM)				Konfuzyon M.(LDA)			
GERÇEK		TAHMİN		GERÇEK		TAHMİN	
		Sol	Sağ			Sol	Sağ
	Sol	62	10		Sol	67	5
GERÇEK	Sağ	36	36	GERÇEK	Sağ	41	31

Konfuzyon M.(NB)				Konfuzyon M.(k-NN)			
GERÇEK		TAHMİN		GERÇEK		TAHMİN	
		Sol	Sağ			Sol	Sağ
	Sol	56	16		Sol	40	32
GERÇEK	Sağ	41	31	GERÇEK	Sağ	44	28

Çizelge 4.2 Denek-1, Chebyshev type 1 ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,47	0,60	0,67	0,68
Duyarlılık(Sensitivity)	0,55	0,77	0,98	0,93
Özgüllük(Specificity)	0,38	0,43	0,36	0,38
Kesinlik(Precision)	0,47	0,57	0,61	0,62
Duyarlılık (Recall)	0,55	0,77	0,98	0,93
F-Skor(F-Measure)	0,51	0,66	0,75	0,74
Kappa Skor(Kappa Skor Metric)	-0,05	0,20	0.34	0.36

Chebyshev 1 filtresi ile Denek 1 üzerinden elde edilen sonuçlar Çizelge 4.2’de gösterilmiştir. En yüksek performansı LDA sınıflandırıcısı 0.68 doğruluk oranı ve 0.36’lık kappa skor ile göstermiştir. Bunun haricindeki performans kriterleri de Çizelge 4.2’de gösterilmiştir.

Bu aşamadan sonra, chebyshev 1 filtresi ile denek 1 için benimsenin gösterim tarzı, her bir denek için yansıtılacaktır.

2. Denek- Chebyshev 1

Konfuzyon M.(SVM)				Konfuzyon M.(LDA)			
GERÇEK		TAHMİN		GERÇEK		TAHMİN	
		Sol	Sağ			Sol	Sağ
	Sol	47	25		Sol	53	19
GERÇEK	Sağ	34	38	GERÇEK	Sağ	37	35

Konfuzyon M.(NB)				Konfuzyon M.(k-NN)			
GERÇEK		TAHMİN		GERÇEK		TAHMİN	
		Sol	Sağ			Sol	Sağ
	Sol	51	21		Sol	51	21
GERÇEK	Sağ	36	36	GERÇEK	Sağ	41	31

Çizelge 4.3 Denek-2, Chebyshev type 1 ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,56	0,60	0,59	0,61
Duyarlılık(Sensitivity)	0,71	0,70	0,65	0,73
Özgüllük(Specificity)	0,43	0,5	0,52	0,43
Kesinlik(Precision)	0,55	0,58	0,58	0,58
Duyarlılık (Recall)	0,70	0,70	0,65	0,73
F-Skor(F-Measure)	0,62	0,64	0,61	0,65
Kappa Skor(Kappa Skor Metric)	0,13	0,20	0,18	0.22

4. BULGULAR VE TARTIŞMA

Chebyshev 1 filtresi ile denek 2 üzerinden elde edilen sonuçlar Çizelge 4.3’de gösterilmiştir. Çizelge 3.2’deki kappa skor durumlarına göre, LDA’nın gösterdiği performans ile iki sınıf arasında orta derecede bir uyuma olduğu gözlenmektedir.

3. Denek- Chebyshev 1

Konfuzyon M.(SVM)				Konfuzyon M.(LDA)			
GERÇEK		TAHMİN		GERÇEK		TAHMİN	
		Sol	Sağ			Sol	Sağ
	Sol	72	0		Sol	72	0
GERÇEK	Sağ	4	68	GERÇEK	Sağ	4	68

Konfuzyon M.(NB)				Konfuzyon M.(k-NN)			
GERÇEK		TAHMİN		GERÇEK		TAHMİN	
		Sol	Sağ			Sol	Sağ
	Sol	72	0		Sol	72	0
GERÇEK	Sağ	7	65	GERÇEK	Sağ	6	66

Chebyshev 1 filtresi ile denek 3 üzerinden elde edilen sonuçlar Çizelge 4.4’de gösterilmiştir. Çizelge 3.2’deki kappa skor durumlarına göre iki sınıf arasında mükemmele yakın derecede bir uyuma olduğu gözlenmektedir.

Çizelge 4.4 Denek-3, Chebshev type 1 ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,95	0,95	0,97	0,97
Duyarlılık(Sensitivity)	1	1	1	1
Özgüllük(Specificity)	0,92	0,90	0,94	0,94
Kesinlik(Precision)	0,92	0,91	0,94	0,94
Duyarlılık (Recall)	1	1	1	1
F-Skor(F-Measure)	0,96	0,95	0,97	0,97
Kappa Skor(Kappa Skor Metric)	0,92	0,91	0.94	0.94

4. Denek- Chebyshev 1

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	52	20
	Sağ	41	31

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	47	25
	Sağ	38	34

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	70	2
	Sağ	72	0

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	64	8
	Sağ	62	10

Chebyshev 1 filtresi ile denek 4 üzerinden elde edilen sonuçlar Çizelge 4.5’de gösterilmiştir. Çizelge 3.2’deki kappa skor durumlarına göre, bütün sınıflandırma algoritmalarının performanslarında iki sınıf arasında önemsiz derecede bir uyuşma olduğu gözlenmektedir.

Çizelge 4.5 Denek-4, Chebshev type 1 ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,51	0,48	0,58	0,56
Duyarlılık(Sensitivity)	0,88	0,97	0,72	0,65
Özgüllük(Specificity)	0,13	0	0,43	0,13
Kesinlik(Precision)	0,50	0,49	0,55	0,55
Duyarlılık (Recall)	0,88	0,97	0,72	0,65
F-Skor(F-Measure)	0,64	0,65	0,63	0,59
Kappa Skor(Kappa Skor Metric)	0,02	-0,02	0.15	0.13

5. Denek - Chebyshev 1

Konfuzyon M.(SVM)				Konfuzyon M.(LDA)			
GERÇEK	TAHMİN			GERÇEK	TAHMİN		
		Sol	Sağ			Sol	Sağ
	Sol	69	3		Sol	68	4
	Sağ	65	7		Sağ	59	13

Konfuzyon M.(NB)				Konfuzyon M.(k-NN)			
GERÇEK	TAHMİN			GERÇEK	TAHMİN		
		Sol	Sağ			Sol	Sağ
	Sol	52	20		Sol	27	45
	Sağ	41	31		Sağ	35	37

Chebyshev 1 filtresi ile denek 5 üzerinden elde edilen sonuçlar Çizelge 4.6’da gösterilmiştir. Çizelge 3.2’deki kappa skor durumlarına göre, bütün sınıflandırma algoritmalarının performanslarında yine iki sınıf arasında önemsiz derecede bir uyuma olduğu gözlenmektedir.

Çizelge 4.6 Denek-5, Chebshev type 1 ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,44	0,58	0,53	0,56
Duyarlılık(Sensitivity)	0,38	0,72	0,95	0,94
Özgüllük(Specificity)	0,51	0,43	0,09	0,51
Kesinlik(Precision)	0,43	0,56	0,51	0,53
Duyarlılık (Recall)	0,38	0,72	0,95	0,94
F-Skor(F-Measure)	0,40	0,63	0,66	0,68
Kappa Skor(Kappa Skor Metric)	-0,11	0,15	0.06	0.13

6. Denek - Chebyshev 1

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	6	66
	Sağ	4	68

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	3	69
	Sağ	3	69

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	52	20
	Sağ	43	29

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	37	35
	Sağ	33	39

Chebyshev 1 filtresi ile denek 6 üzerinden elde edilen sonuçlar Çizelge 4.7’de gösterilmiştir. Çizelge 3.2’deki kappa skor durumlarına göre, bütün sınıflandırma algoritmalarının performanslarında iki sınıf arasında önemsiz derecede bir uyuma olduğu gözlenmektedir. Başka bir deyişle iki sınıf için uyuma sadece şans ile belirlenmiştir.

Çizelge 4.7 Denek-6, Chebshev type 1 ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,52	0,57	0,51	0,5
Duyarlılık(Sensitivity)	0,51	0,72	0,08	0,04
Özgüllük(Specificity)	0,54	0,40	0,94	0,54
Kesinlik(Precision)	0,52	0,55	0,6	0,5
Duyarlılık (Recall)	0,51	0,72	0,08	0,04
F-Skor(F-Measure)	0,52	0,62	0,15	0,08
Kappa Skor(Kappa Skor Metric)	0,06	0,13	0.03	0

7. Denek - Chebyshev 1

Konfuzyon M.(SVM)				Konfuzyon M.(LDA)			
GERÇEK	TAHMİN			GERÇEK	TAHMİN		
		Sol	Sağ			Sol	Sağ
Sol	44	28		Sol	42	30	
Sağ	23	49		Sağ	23	49	

Konfuzyon M.(NB)				Konfuzyon M.(k-NN)			
GERÇEK	TAHMİN			GERÇEK	TAHMİN		
		Sol	Sağ			Sol	Sağ
Sol	40	32		Sol	37	35	
Sağ	23	49		Sağ	28	44	

Chebyshev 1 filtresi ile denek 7 üzerinden elde edilen sonuçlar Çizelge 4.8’de gösterilmiştir. Çizelge 3.2’deki kappa skor durumlarına göre, SVM ve LDA ve NB sınıflandırma algoritmalarının performanslarında iki sınıf arasında orta derecede bir uyuşma olduğu gözlenmektedir.

Çizelge 4.8 Denek-7, Chebshev type 1 ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,56	0,61	0,64	0,63
Duyarlılık(Sensitivity)	0,51	0,55	0,61	0,58
Özgüllük(Specificity)	0,61	0,68	0,68	0,61
Kesinlik(Precision)	0,56	0,63	0,65	0,64
Duyarlılık (Recall)	0,51	0,55	0,61	0,58
F-Skor(F-Measure)	0,54	0,59	0,63	0,61
Kappa Skor(Kappa Skor Metric)	0,13	0,23	0.29	0,26

8. Denek - Chebyshev 1

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	60	12
	Sağ	4	68

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	68	4
	Sağ	8	64

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	68	4
	Sağ	7	65

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	65	7
	Sağ	9	63

Chebyshev 1 filtresi ile denek 8 üzerinden elde edilen sonuçlar Çizelge 4.9’da gösterilmiştir. Çizelge 3.2’deki kappa skor durumlarına göre, LDA ve NB algoritmalarının performanslarında iki sınıf arasında mükemmele yakın derecede bir uyuşma olduğu gözlenmektedir.

Çizelge 4.9 Denek-8, Chebshev type 1 ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,89	0,92	0,89	0,92
Duyarlılık(Sensitivity)	0,90	0,94	0,83	0,94
Özgüllük(Specificity)	0,88	0,90	0,94	0,88
Kesinlik(Precision)	0,88	0,90	0,94	0,89
Duyarlılık (Recall)	0,90	0,94	0,83	0,94
F-Skor(F-Measure)	0,89	0,93	0,88	0,92
Kappa Skor(Kappa Skor Metric)	0,78	0,85	0,78	0,83

9. Denek - Chebyshev 1

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	43	29
	Sağ	10	62

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	40	32
	Sağ	7	65

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	39	33
	Sağ	6	66

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	35	37
	Sağ	12	60

Chebyshev 1 filtresi ile denek 9 üzerinden elde edilen sonuçlar Çizelge 4.10'da gösterilmiştir. Çizelge 3.2'deki kappa skor durumlarına göre, NB, SVM ve LDA sınıflandırma algoritmalarının performanslarında iki sınıf arasında ekseriyetle bir uyuma olduğu gözlenmektedir.

Çizelge 4.10 Denek-9, Chebshev type 1 ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,65	0,73	0,73	0,73
Duyarlılık(Sensitivity)	0,49	0,54	0,60	0,56
Özgüllük(Specificity)	0,83	0,91	0,86	0,83
Kesinlik(Precision)	0,74	0,87	0,81	0,85
Duyarlılık (Recall)	0,48	0,54	0,59	0,55
F-Skor(F-Measure)	0,59	0,67	0,68	0,67
Kappa Skor(Kappa Skor Metric)	0,32	0,46	0,46	0,46

Chebyshev 1 filtresi ile bütün denekler üzerinden elde edilen ortalama sonuçlar Çizelge 4.11’de gösterilmiştir. Çizelge 3.2’deki kappa skor durumlarına göre, bütün sınıflandırma algoritmalarının performanslarında, iki sınıf arasında orta derecede bir uyuma olduğu gözlenmektedir.

Çizelge 4.11 Chebshev type 1 ile elde edilen başarı performansları ortalamaları

	k-NN(ort)	NB(ort)	SVM(ort)	LDA(ort)
Doğruluk(Accuracy)	0,62	0,67	0,68	0,69
Kappa Skor(Kappa Skor Metric)	0,24	0,35	0,36	0,37

Ayrıca, Chebyshev 1 filtresi kullanılarak yapılan sınıflandırma işlemlerinde, SVM ve LDA gibi sınıflandırıcıların NB ve k-NN tarzı non-lineer sınıflandırıcılara oranla daha başarılı olduğu görülüyor. Genel anlamda, CSP metodu kullanılarak çıkarılan özneliklerin sınıflandırılmasında lineer sınıflandırıcılar daha yüksek performans göstermektedir.

Yukarıda, Chebyshev 1 filtresi kullanılarak yapılan kappa skor analizlerinin benzerleri Chebyshev 2, Eliptik ve RLS Adaptif filtresi için de yapılabilir.

4.4 Chebyshev Tip 2 İle Filtrelenen 9 Deneğin Verilerinin, SVM, LDA, Naive Bayes ve KNN Algoritmalarına Göre Başarı Performansları

Çalışmanın bu bölümünde, 9 deneğin her bir denemesinin her bir kanalı, chebyshev tip 2 filtresi kullanılarak ayrı ayrı temizlenmiştir. Passband frekans değerleri 10-20 Hz aralığına ayarlanmıştır. Veriler temizlendikten sonra 751x22x144 boyutlarında bir matris elde edilmiştir. Bu çok boyutlu matriste, 751, 3 saniyenin örnek sayısını, 22, kanal sayısını, 144, deneme sayısını temsil edecek şekilde oluşturulmuştur. Bu aşamadan sonra her bir denemenin 22 kanal bilgisi CSP algoritmasına giriş olarak verilmiştir. CSP algoritmasının çıkışında, 144x4 boyutlarında bir öznelik vektörü elde edilmiştir. Yani 144 deneme sayısını, 4 öznelik vektörünü temsil edecek şekilde bir çıkış elde edilmiştir. Bu öznelik vektörleri ayrı ayrı SVM, LDA, Naive Bayes ve KNN sınıflandırma algoritmalarının girişlerine uygulanarak kappa, accuracy, precision, sensitivity, F-Score, specificity gibi performans kriterlerine göre başarımlar elde edilmiştir. Her bir deneğin konfüzyon matrisi sınıflandırıcılara göre ayrıca tablolar ile gösterilmiştir. 9. denemenin sonunda, 9 deneğin ortalama başarımlarını sınıflandırıcı bazında

ayrıca tablolanmıştır. Bu şekilde, chebyshev tip 2 filtresinin sınıflandırıcılar bazında en yüksek ortalama performans değerleri tablo ile yansıtılmıştır.

1. Denek - Chebyshev Tip 2

Konfuzyon M.(SVM)				Konfuzyon M.(LDA)			
GERÇEK	TAHMİN			GERÇEK	TAHMİN		
		Sol	Sağ			Sol	Sağ
	Sol	47	25		Sol	48	24
	Sağ	7	65		Sağ	7	65

Konfuzyon M.(NB)				Konfuzyon M.(k-NN)			
GERÇEK	TAHMİN			GERÇEK	TAHMİN		
		Sol	Sağ			Sol	Sağ
	Sol	58	14		Sol	48	24
	Sağ	15	57		Sağ	12	60

Çizelge 4.12 Denek-1, Chebshev Type II ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,75	0,80	0,78	0,78
Duyarlılık(Sensitivity)	0,67	0,81	0,65	0,66
Özgüllük(Specificity)	0,83	0,79	0,90	0,83
Kesinlik(Precision)	0,80	0,79	0,87	0,87
Duyarlılık (Recall)	0,67	0,80	0,65	0,67
F-Skor(F-Measure)	0,72	0,80	0,74	0,76
Kappa Skor(Kappa Skor Metric)	0,50	0,60	0,56	0,57

2. Denek - Chebyshev Tip 2

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	35	37
	Sağ	24	48

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	40	32
	Sağ	24	48

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	33	39
	Sağ	25	47

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	38	34
	Sağ	38	34

Çizelge 4.13 Denek-2, Chebshev Type II ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,50	0,55	0,58	0,61
Duyarlılık(Sensitivity)	0,52	0,46	0,47	0,56
Özgüllük(Specificity)	0,47	0,65	0,67	0,47
Kesinlik(Precision)	0,50	0,57	0,59	0,63
Duyarlılık (Recall)	0,52	0,46	0,49	0,56
F-Skor(F-Measure)	0,51	0,50	0,53	0,59
Kappa Skor(Kappa Skor Metric)	0	0,11	0.15	0,22

3. Denek - Chebyshev Tip 2

Konfuzyon M.(SVM)				Konfuzyon M.(LDA)			
GERÇEK	TAHMİN			GERÇEK	TAHMİN		
		Sol	Sağ			Sol	Sağ
	Sol	72	0		Sol	71	1
	Sağ	9	63		Sağ	9	63

Konfuzyon M.(NB)				Konfuzyon M.(k-NN)			
GERÇEK	TAHMİN			GERÇEK	TAHMİN		
		Sol	Sağ			Sol	Sağ
	Sol	72	0		Sol	69	3
	Sağ	13	59		Sağ	7	65

Çizelge 4.14 Denek-3, Chebshev Type II ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,93	0,90	0,94	0,93
Duyarlılık(Sensitivity)	0,96	1	1	0,99
Özgüllük(Specificity)	0,90	0,82	0,88	0,90
Kesinlik(Precision)	0,90	0,85	0,89	0,89
Duyarlılık (Recall)	0,95	1	1	0,99
F-Skor(F-Measure)	0,93	0,91	0,94	0,93
Kappa Skor(Kappa Skor Metric)	0.86	0,82	0.88	0,86

4. Denek - Chebyshev Tip 2

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	40	32
	Sağ	26	46

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	47	25
	Sağ	36	36

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	41	31
	Sağ	27	45

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	40	32
	Sağ	33	39

Çizelge 4.15 Denek-4, Chebshev Type II ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,55	0,60	0,60	0,58
Duyarlılık(Sensitivity)	0,56	0,57	0,56	0,66
Özgüllük(Specificity)	0,54	0,63	0,64	0,54
Kesinlik(Precision)	0,54	0,60	0,61	0,57
Duyarlılık (Recall)	0,56	0,57	0,56	0,65
F-Skor(F-Measure)	0,55	0,59	0,58	0,60
Kappa Skor(Kappa Skor Metric)	0.1	0,19	0.19	0,15

5. Denek - Chebyshev Tip 2

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	13	59
	Sağ	3	69

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	14	58
	Sağ	5	67

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	27	45
	Sağ	20	52

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	23	49
	Sağ	18	54

Çizelge 4.16 Denek-5, Chebshev Type II ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,54	0,55	0,57	0,56
Duyarlılık(Sensitivity)	0,32	0,38	0,18	0,19
Özgüllük(Specificity)	0,76	0,72	0,95	0,75
Kesinlik(Precision)	0,56	0,57	0,81	0,73
Duyarlılık (Recall)	0,32	0,38	0,18	0,19
F-Skor(F-Measure)	0,41	0,45	0,29	0,31
Kappa Skor(Kappa Skor Metric)	0.07	0,09	0.14	0,13

6. Denek - Chebyshev Tip 2

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	52	20
	Sağ	46	26

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	51	21
	Sağ	46	26

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	45	27
	Sağ	43	29

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	45	27
	Sağ	43	29

Çizelge 4.17 Denek-6, Chebshev Type II ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,47	0,51	0,54	0,53
Duyarlılık(Sensitivity)	0,63	0,63	0,72	0,70
Özgüllük(Specificity)	0,29	0,40	0,36	0,29
Kesinlik(Precision)	0,47	0,51	0,53	0,52
Duyarlılık (Recall)	0,63	0,63	0,72	0,71
F-Skor(F-Measure)	0,54	0,56	0,61	0,60
Kappa Skor(Kappa Skor Metric)	-0.07	0,02	0.08	0,07

7. Denek - Chebyshev Tip 2

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	64	8
	Sağ	41	31

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	58	14
	Sağ	27	45

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	59	13
	Sağ	28	44

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	53	19
	Sağ	27	45

Çizelge 4.18 Denek-7, Chebshev Type II ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,68	0,72	0,66	0,72
Duyarlılık(Sensitivity)	0,74	0,82	0,89	0,81
Özgüllük(Specificity)	0,63	0,61	0,43	0,63
Kesinlik(Precision)	0,66	0,67	0,60	0,68
Duyarlılık (Recall)	0,73	0,82	0,88	0,80
F-Skor(F-Measure)	0,69	0,74	0,72	0,74
Kappa Skor(Kappa Skor Metric)	0.36	0,43	0.32	0,43

8. Denek - Chebyshev Tip 2

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	66	6
	Sağ	3	69

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	62	10
	Sağ	3	69

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	62	10
	Sağ	3	69

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	65	7
	Sağ	3	69

Çizelge 4.19 Denek-8, Chebshev Type II ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,93	0,90	0,94	0,90
Duyarlılık(Sensitivity)	0,90	0,86	0,92	0,86
Özgüllük(Specificity)	0,95	0,96	0,96	0,96
Kesinlik(Precision)	0,95	0,95	0,96	0,96
Duyarlılık (Recall)	0,90	0,86	0,92	0,86
F-Skor(F-Measure)	0,92	0,90	0,94	0,91
Kappa Skor(Kappa Skor Metric)	0.86	0,82	0.88	0,82

9. Denek - Chebyshev Tip 2

Konfuzyon M.(SVM)				Konfuzyon M.(LDA)			
GERÇEK	TAHMİN			GERÇEK	TAHMİN		
		Sol	Sağ			Sol	Sağ
Sol	62	10		Sol	65	7	
Sağ	19	53		Sağ	23	49	

Konfuzyon M.(NB)				Konfuzyon M.(k-NN)			
GERÇEK	TAHMİN			GERÇEK	TAHMİN		
		Sol	Sağ			Sol	Sağ
Sol	67	5		Sol	51	21	
Sağ	25	47		Sağ	28	44	

Çizelge 4.20 Denek-9, Chebshev Type II ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,65	0,79	0,80	0,79
Duyarlılık(Sensitivity)	0,70	0,93	0,86	0,90
Özgüllük(Specificity)	0,61	0,65	0,74	0,61
Kesinlik(Precision)	0,64	0,72	0,77	0,74
Duyarlılık (Recall)	0,70	0,93	0,86	0,90
F-Skor(F-Measure)	0,68	0,82	0,81	0,81
Kappa Skor(Kappa Skor Metric)	0.32	0,58	0.60	0,58

Çizelge 4.21 Chebshev type 2 ile elde edilen başarı performansları ortalamaları

	k-NN(ort)	NB(ort)	SVM(ort)	LDA(ort)
Doğruluk(Accuracy)	0,67	0,68	0,72	0,71
Kappa Skor(Kappa Skor Metric)	0,38	0,40	0.43	0,42

Chebyshev 2 filtresi ile bütün denekler üzerinden elde edilen ortalama sonuçlar Çizelge 4.21’de gösterilmiştir. Çizelge 3.2’deki kappa skor durumlarına göre, bütün

sınıflandırma algoritmalarının performanslarında, iki sınıf arasında ekseriyetle bir uyuma olduğu gözlenmektedir. Ayrıca yine lineer sınıflandırıcıların performanslarının k-NN ve NB gibi sınıflandırma algoritmalarına göre daha yüksek olduğu gözlenmiştir.

4.5 Eliptik Filtre İle Filtrelenen 9 Deneğin Verilerinin, SVM, LDA, Naive Bayes ve KNN Algoritmalarına Göre Başarı Performansları

Çalışmanın bu bölümünde, 9 deneğin her bir denemesinin her bir kanalı, eliptik filtresi kullanılarak ayrı ayrı temizlenmiştir. Passband frekans değerleri 10-20 Hz aralığına ayarlanmıştır. Veriler temizlendikten sonra 751x22x144 boyutlarında bir matris elde edilmiştir. Bu çok boyutlu matriste, 751, 3 saniyenin örnek sayısını, 22, kanal sayısını, 144, deneme sayısını temsil edecek şekilde oluşturulmuştur. Bu aşamadan sonra her bir denemenin 22 kanal bilgisi CSP algoritmasına giriş olarak verilmiştir. CSP algoritmasının çıkışında, 144x4 boyutlarında bir öznitelik vektörü elde edilmiştir. Yani 144 deneme sayısını, 4 öznitelik vektörünü temsil edecek şekilde bir çıkış elde edilmiştir. Bu öznitelik vektörleri ayrı ayrı SVM, LDA, Naive Bayes ve KNN sınıflandırma algoritmalarının girişlerine uygulanarak kappa, accuracy, precision, sensitivity, F-Score, specificity gibi performans kriterlerine göre başarımlar sonuçları elde edilmiştir. Her bir deneğin konfüzyon matrisi sınıflandırıcılara göre ayrıca tablolar ile gösterilmiştir. 9. denemenin sonunda, 9 deneğin ortalama başarımlar performansları sınıflandırıcı bazında ayrıca tablolandırılmıştır. Bu şekilde, eliptik filtresinin sınıflandırıcılar bazında en yüksek ortalama performans değerleri tablo ile yansıtılmıştır.

1. Denek - Elliptik

Konfuzyon M.(SVM)				Konfuzyon M.(LDA)			
GERÇEK	TAHMİN			GERÇEK	TAHMİN		
		Sol	Sağ			Sol	Sağ
Sol	65	7		Sol	67	5	
Sağ	39	33		Sağ	46	26	

Konfuzyon M.(NB)				Konfuzyon M.(k-NN)			
GERÇEK	TAHMİN			GERÇEK	TAHMİN		
		Sol	Sağ			Sol	Sağ
Sol	65	7		Sol	63	9	
Sağ	45	27		Sağ	42	30	

Çizelge 4.22 Denek-1, Elliptic filter ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,64	0,64	0,68	0,65
Duyarlılık(Sensitivity)	0,88	0,90	0,90	0,93
Özgüllük(Specificity)	0,42	0,38	0,46	0,41
Kesinlik(Precision)	0,60	0,59	0,63	0,59
Duyarlılık (Recall)	0,88	0,90	0,90	0,93
F-Skor(F-Measure)	0,71	0,71	0,74	0,72
Kappa Skor(Kappa Skor Metric)	0.29	0,27	0.36	0,29

2. Denek - Eliptik

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	57	15
	Sağ	42	30

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	65	7
	Sağ	52	20

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	59	13
	Sağ	53	19

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	46	26
	Sağ	41	31

Çizelge 4.23 Denek-2, Eliptik filter ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,53	0,54	0,60	0,59
Duyarlılık(Sensitivity)	0,63	0,81	0,79	0,90
Özgüllük(Specificity)	0,43	0,26	0,41	0,43
Kesinlik(Precision)	0,52	0,52	0,57	0,55
Duyarlılık (Recall)	0,63	0,82	0,79	0,90
F-Skor(F-Measure)	0,57	0,64	0,66	0,69
Kappa Skor(Kappa Skor Metric)	0.07	0,08	0.21	0,18

3. Denek - Eliptik

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	71	1
	Sağ	0	72

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	72	0
	Sağ	0	72

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	72	0
	Sağ	0	72

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	67	5
	Sağ	3	69

Çizelge 4.24 Denek-3, Elliptic filter ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,94	1	0,99	1
Duyarlılık(Sensitivity)	0,93	1	0,98	1
Özgüllük(Specificity)	0,96	1	1	1
Kesinlik(Precision)	0,93	1	1	1
Duyarlılık (Recall)	0,94	1	0,98	1
F-Skor(F-Measure)	0,94	1	0,99	1
Kappa Skor(Kappa Skor Metric)	0.88	1	0.98	1

4. Denek - Eliptik

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	72	0
	Sağ	71	1

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	70	2
	Sağ	58	14

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	57	15
	Sağ	50	22

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	1	71
	Sağ	3	69

Çizelge 4.25 Denek-4, Elliptic filter ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,48	0.55	0,51	0.58
Duyarlılık(Sensitivity)	0,01	0,79	1	0.97
Özgüllük(Specificity)	0,95	0.30	0.01	0.96
Kesinlik(Precision)	0,25	0.53	0.50	0.54
Duyarlılık (Recall)	0,01	0.79	1	0.97
F-Skor(F-Measure)	0,03	0.63	0,67	0.7
Kappa Skor(Kappa Skor Metric)	-0.02	0.1	0.01	0.16

5. Denek - Elliptik

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	72	0
	Sağ	65	7

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	68	4
	Sağ	60	12

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	63	9
	Sağ	55	17

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	56	16
	Sağ	54	18

Çizelge 4.26 Denek-5, Elliptic filter ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,51	0.55	0,55	0.55
Duyarlılık(Sensitivity)	0,77	0,88	1	0.94
Özgüllük(Specificity)	0,26	0.24	0.1	0.25
Kesinlik(Precision)	0,50	0.53	0.52	0.53
Duyarlılık (Recall)	0,78	0.88	1	0.94
F-Skor(F-Measure)	0,61	0.66	0,69	0.68
Kappa Skor(Kappa Skor Metric)	0.03	0.11	0.11	0.11

6. Denek - Eliptik

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	12	60
	Sağ	8	64

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	14	58
	Sağ	9	63

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	15	57
	Sağ	6	66

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	26	46
	Sağ	31	41

Çizelge 4.27 Denek-6, Elliptic filter ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,46	0.56	0,53	0.54
Duyarlılık(Sensitivity)	0,36	0,20	0,17	0.19
Özgüllük(Specificity)	0,56	0.91	0.89	0.56
Kesinlik(Precision)	0,45	0.71	0.6	0.60
Duyarlılık (Recall)	0,36	0.20	0,16	0.19
F-Skor(F-Measure)	0,40	0.32	0,26	0.29
Kappa Skor(Kappa Skor Metric)	-0.07	0.13	0.05	0.07

7. Denek - Elliptik

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	70	2
	Sağ	46	26

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	71	1
	Sağ	50	22

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	71	1
	Sağ	53	19

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	64	8
	Sağ	52	20

Çizelge 4.28 Denek-7, Elliptic filter ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,58	0.63	0,66	0.64
Duyarlılık(Sensitivity)	0,88	0,98	0,97	0.98
Özgüllük(Specificity)	0,27	0.26	0.36	0.28
Kesinlik(Precision)	0,55	0.57	0.60	0.58
Duyarlılık (Recall)	0,88	0.98	0,97	0.98
F-Skor(F-Measure)	0,68	0.72	0,74	0.73
Kappa Skor(Kappa Skor Metric)	0.16	0.25	0.33	0.29

8. Denek - Eliptik

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	68	4
	Sağ	5	67

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	66	6
	Sağ	4	68

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	70	2
	Sağ	11	61

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	71	1
	Sağ	17	55

Çizelge 4.29 Denek-8, Elliptic filter ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,88	0.91	0,94	0.93
Duyarlılık(Sensitivity)	0,98	0,97	0,94	0.92
Özgüllük(Specificity)	0,76	0.84	0.93	0.76
Kesinlik(Precision)	0,80	0.86	0.93	0.94
Duyarlılık (Recall)	0,98	0.97	0,94	0.91
F-Skor(F-Measure)	0,88	0.92	0,93	0.92
Kappa Skor(Kappa Skor Metric)	0.75	0.82	0.88	0.86

9. Denek - Elliptik

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	28	44
	Sağ	13	59

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	38	34
	Sağ	21	51

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	29	43
	Sağ	14	58

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	32	40
	Sağ	21	51

Çizelge 4.30 Denek-9, Elliptic filter ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,57	0.60	0,60	0.62
Duyarlılık(Sensitivity)	0,44	0,40	0,38	0.53
Özgüllük(Specificity)	0,70	0.80	0.81	0.70
Kesinlik(Precision)	0,60	0.67	0.68	0.64
Duyarlılık (Recall)	0,44	0.40	0,38	0.52
F-Skor(F-Measure)	0,51	0.50	0,49	0.58
Kappa Skor(Kappa Skor Metric)	0.15	0.21	0.21	0.24

Çizelge 4.31 Elliptic filtre ile elde edilen başarı performansları ortalamaları

	k-NN(ort)	NB(ort)	SVM(ort)	LDA(ort)
Doğruluk(Accuracy)	0,62	0,66	0,67	0,68
Kappa Skor(Kappa Skor Metric)	0,24	0,33	0,34	0,36

Elliptik filtresi ile bütün denekler üzerinden elde edilen ortalama sonuçlar Çizelge 4.30’da gösterilmiştir. Çizelge 3.2’deki kappa skor durumlarına göre, bütün sınıflandırma algoritmalarının performanslarında, iki sınıf arasında orta derecede bir uyuma olduğu gözlenmektedir. Diğer filtre sonuçlarında olduğu gibi SVM ve LDA gibi lineer sınıflandırma algoritmalarının performanslarının diğer non-lineer algoritmalarından daha üstün olduğu dikkat çekmektedir.

4.6 Adaptif Filtre İle Filtrelenen 9 Deneğin Verilerinin, SVM, LDA, Naive Bayes ve KNN Algoritmalarına Göre Başarı Performansları

Çalışmanın bu bölümünde, 9 deneğin her bir denemesinin her bir kanalı, adaptif RLS filtresi kullanılarak ayrı ayrı temizlenmiştir. Her bir denemenin 22 kanallık verisi ayrı ayrı adaptif filtrenin birincil girişine, her bir denemenin EOG1 verisi de adaptif filtrenin referans girişine uygulanmıştır. Veriler temizlendikten sonra 751x22x144 boyutlarında bir matris elde edilmiştir. Bu çok boyutlu matriste, 751, 3 saniyenin örnek sayısını, 22, kanal sayısını, 144, deneme sayısını temsil edecek şekilde oluşturulmuştur. Bu aşamadan sonra her bir denemenin 22 kanal bilgisi CSP algoritmasına giriş olarak verilmiştir. CSP algoritmasının çıkışında, 144x4 boyutlarında bir öznitelik vektörü elde edilmiştir. Yani 144 deneme sayısını, 4 öznitelik vektörünü temsil edecek şekilde bir çıkış elde edilmiştir. Bu öznitelik vektörleri ayrı ayrı SVM, LDA, Naive Bayes ve KNN sınıflandırma algoritmalarının girişlerine uygulanarak kappa, accuracy, precision, sensitivity, F-Score, specificity gibi performans kriterlerine göre başarımlar elde edilmiştir. Her bir deneğin konfüzyon matrisi sınıflandırıcılara göre ayrıca tablolar ile gösterilmiştir. 9. denemenin sonunda, 9 deneğin ortalama başarımlarını performansları sınıflandırıcı bazında ayrıca tablolandırılmıştır. Bu şekilde, adaptif RLS filtresinin sınıflandırıcılar bazında en yüksek ortalama performans değerleri tablo ile yansıtılmıştır.

1. Denek - Adaptif RLS

Konfuzyon M.(SVM)				Konfuzyon M.(LDA)			
GERÇEK	TAHMİN			GERÇEK	TAHMİN		
	Sol		Sağ		Sol		Sağ
	Sol	55	17		Sol	50	22
	Sağ	51	21		Sağ	42	30

Konfuzyon M.(NB)				Konfuzyon M.(k-NN)			
GERÇEK	TAHMİN			GERÇEK	TAHMİN		
	Sol		Sağ		Sol		Sağ
	Sol	10	62		Sol	39	33
	Sağ	16	56		Sağ	40	32

Çizelge 4.32 Denek-1, RLS algoritması ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,49	0.45	0,52	0.55
Duyarlılık(Sensitivity)	0,54	0,13	0,76	0.69
Özgüllük(Specificity)	0,44	0.77	0.29	0.44
Kesinlik(Precision)	0,49	0.38	0.51	0.54
Duyarlılık (Recall)	0,54	0.13	0,51	0.69
F-Skor(F-Measure)	0,51	0.20	0,76	0.60
Kappa Skor(Kappa Skor Metric)	-0.01	-0.08	0.05	0.11

2. Denek - Adaptif RLS

Konfuzyon M.(SVM)				Konfuzyon M.(LDA)			
GERÇEK	TAHMİN			GERÇEK	TAHMİN		
		Sol	Sağ			Sol	Sağ
	Sol	12	60		Sol	41	31
	Sağ	8	64		Sağ	27	45

Konfuzyon M.(NB)				Konfuzyon M.(k-NN)			
GERÇEK	TAHMİN			GERÇEK	TAHMİN		
		Sol	Sağ			Sol	Sağ
	Sol	20	52		Sol	15	57
	Sağ	20	52		Sağ	14	58

Çizelge 4.33 Denek-2, RLS algoritması ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,50	0.5	0,52	0.59
Duyarlılık(Sensitivity)	0,20	0,27	0,16	0.56
Özgüllük(Specificity)	0,80	0.72	0.88	0.80
Kesinlik(Precision)	0,51	0.5	0.6	0.60
Duyarlılık (Recall)	0,20	0.27	0,16	0.56
F-Skor(F-Measure)	0,29	0.35	0,26	0.58
Kappa Skor(Kappa Skor Metric)	0.01	0	0.05	0.19

3. Denek - Adaptif RLS

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	66	6
	Sağ	9	63

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	66	6
	Sağ	9	63

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	64	8
	Sağ	13	59

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	65	7
	Sağ	19	53

Çizelge 4.34 Denek-3, RLS algoritması ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,81	0.85	0,89	0.89
Duyarlılık(Sensitivity)	0,90	0,88	0,91	0.91
Özgüllük(Specificity)	0,73	0.81	0.88	0.73
Kesinlik(Precision)	0,77	0.83	0.88	0.88
Duyarlılık (Recall)	0,90	0.88	0,91	0.91
F-Skor(F-Measure)	0,83	0.85	0,89	0.89
Kappa Skor(Kappa Skor Metric)	0.63	0.70	0.79	0.79

4. Denek - Adaptif RLS

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	3	69
	Sağ	2	70

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	4	68
	Sağ	5	67

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	20	52
	Sağ	29	43

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	22	50
	Sağ	22	50

Çizelge 4.35 Denek-4, RLS algoritması ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,5	0.43	0,50	0.49
Duyarlılık(Sensitivity)	0,30	0,27	0,04	0.05
Özgüllük(Specificity)	0,69	0.59	0.97	0.69
Kesinlik(Precision)	0,5	0.40	0.06	0.44
Duyarlılık (Recall)	0,30	0.27	0,04	0.05
F-Skor(F-Measure)	0,37	0.33	0,07	0.09
Kappa Skor(Kappa Skor Metric)	0	-0.12	0.01	-0.01

5. Denek - Adaptif RLS

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	72	0
	Sağ	72	0

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	72	0
	Sağ	72	0

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	72	0
	Sağ	72	0

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	69	3
	Sağ	65	7

Çizelge 4.36 Denek-5, RLS algoritması ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,52	0.5	0.5	0.5
Duyarlılık(Sensitivity)	0,95	1	1	1
Özgüllük(Specificity)	0,09	0	0	0.09
Kesinlik(Precision)	0,51	0.5	0.5	0.5
Duyarlılık (Recall)	0,95	1	1	1
F-Skor(F-Measure)	0,66	0.66	0.66	0.66
Kappa Skor(Kappa Skor Metric)	0.05	0	0	0

6. Denek - Adaptif RLS

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	24	48
	Sağ	33	39

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	23	49
	Sağ	23	49

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	71	1
	Sağ	70	2

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	22	50
	Sağ	21	51

Çizelge 4.37 Denek-6, RLS algoritması ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,50	0.50	0,43	0.5
Duyarlılık(Sensitivity)	0,30	0,98	0,33	0.31
Özgüllük(Specificity)	0,70	0.02	0.54	0.70
Kesinlik(Precision)	0,51	0.50	0.42	0.5
Duyarlılık (Recall)	0,30	0.98	0,33	0.31
F-Skor(F-Measure)	0,38	0.66	0,37	0.38
Kappa Skor(Kappa Skor Metric)	0.01	0.01	-0.1	0

7. Denek - Adaptif RLS

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	72	0
	Sağ	65	7

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	72	0
	Sağ	65	7

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	59	13
	Sağ	43	29

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	54	18
	Sağ	51	21

Çizelge 4.38 Denek-7, RLS algoritması ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,52	0.61	0,54	0.55
Duyarlılık(Sensitivity)	0,75	0,81	1	1
Özgüllük(Specificity)	0,29	0.40	0.09	0.29
Kesinlik(Precision)	0,51	0.57	0.52	0.52
Duyarlılık (Recall)	0,75	0.81	1	1
F-Skor(F-Measure)	0,61	0.67	0,68	0.68
Kappa Skor(Kappa Skor Metric)	0.04	0.22	0.09	0.09

8. Denek - Adaptif RLS

Konfuzyon M.(SVM)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	67	5
	Sağ	3	69

Konfuzyon M.(LDA)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	68	4
	Sağ	4	68

Konfuzyon M.(NB)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	66	6
	Sağ	3	69

Konfuzyon M.(k-NN)

		TAHMİN	
		Sol	Sağ
GERÇEK	Sol	62	10
	Sağ	2	70

Çizelge 4.39 Denek-8, RLS algoritması ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,91	0.93	0,94	0.94
Duyarlılık(Sensitivity)	0,86	0,91	0,93	0.94
Özgüllük(Specificity)	0,97	0.95	0.95	0.97
Kesinlik(Precision)	0,96	0.95	0.95	0.94
Duyarlılık (Recall)	0,86	0.91	0,93	0.94
F-Skor(F-Measure)	0,91	0.93	0,94	0.94
Kappa Skor(Kappa Skor Metric)	0.83	0.88	0.89	0.89

9. Denek - Adaptif RLS

Konfuzyon M.(SVM)				Konfuzyon M.(LDA)			
GERÇEK	TAHMİN			GERÇEK	TAHMİN		
		Sol	Sağ			Sol	Sağ
Sol	67	5		Sol	69	3	
Sağ	26	46		Sağ	34	38	

Konfuzyon M.(NB)				Konfuzyon M.(k-NN)			
GERÇEK	TAHMİN			GERÇEK	TAHMİN		
		Sol	Sağ			Sol	Sağ
Sol	52	20		Sol	51	21	
Sağ	23	49		Sağ	31	41	

Çizelge 4.40 Denek-9, RLS algoritması ile elde edilen başarı performansları

	k-NN	NB	SVM	LDA
Doğruluk(Accuracy)	0,63	0.70	0,78	0.74
Duyarlılık(Sensitivity)	0,70	0,72	0,93	0.95
Özgüllük(Specificity)	0,56	0.68	0.63	0.56
Kesinlik(Precision)	0,62	0.69	0.72	0.66
Duyarlılık (Recall)	0,70	0.72	0,93	0.95
F-Skor(F-Measure)	0,66	0.70	0,81	0.78
Kappa Skor(Kappa Skor Metric)	0.27	0.40	0.56	0.48

Çizelge 4.41 RLS algoritması ile bütün denekler üzerinden elde edilen ortalama başarı performansları

Adaptif filtre	k-NN(ort)	NB(ort)	SVM(ort)	LDA(ort)
Doğruluk(Accuracy)	0,59	0,60	0,62	0,64
Kappa Skor(Kappa Skor Metric)	0,20	0,22	0.29	0,31

Adaptif RLS filtresi ile bütün denekler üzerinden elde edilen ortalama sonuçlar Çizelge 4.40’da gösterilmiştir. Çizelge 3.2’deki kappa skor durumlarına göre LDA ve SVM sınıflandırma algoritmalarının performanslarında, iki sınıf arasında orta derecede bir uyuma olduğu gözlenmektedir. Diğer filtre sonuçlarında olduğu gibi SVM ve LDA gibi lineer sınıflandırma algoritmalarının performanslarının diğer non-lineer algoritmalarından daha üstün olduğu dikkat çekmektedir.


4.7 Farklı 4 filtre ile elde edilen ortalama sınıflandırma performansları

Çizelge 4.42 4 filtre ile elde edilen ortalama sınıflandırma performansları


Chebshev type 1	k-NN(ort)	NB(ort)	SVM(ort)	LDA(ort)
Doğruluk(Accuracy)	0,62	0,67	0,68	0,69
Kappa Skor(Kappa Skor Metric)	0,24	0,35	0,36	0,37
Chebshev type 2	k-NN(ort)	NB(ort)	SVM(ort)	LDA(ort)
Doğruluk(Accuracy)	0,67	0,68	0,72	0,71
Kappa Skor(Kappa Skor Metric)	0,38	0,40	0,43	0,42
Elliptic filtre	k-NN(ort)	NB(ort)	SVM(ort)	LDA(ort)
Doğruluk(Accuracy)	0,62	0,66	0,67	0,68
Kappa Skor(Kappa Skor Metric)	0,24	0,33	0,34	0,36
Adaptif filtre	k-NN(ort)	NB(ort)	SVM(ort)	LDA(ort)
Doğruluk(Accuracy)	0,59	0,60	0,62	0,64
Kappa Skor(Kappa Skor Metric)	0,20	0,22	0,29	0,31

Çizelge 4.41’de, 9 denek için kullanılan bütün filtrelerin ortalama sınıflandırma performansları gösterilmiştir. Chebyshev II filtresi SVM ile %72 ortalama sınıflandırma performansı ile bütün filtrelere kıyasla en yüksek sonuçlara ulaşmıştır. Chebyshev 1 filtresi en yüksek sınıflandırma performansını, %69 ortalama sınıflandırma performansı ile LDA sınıflandırıcısı ile elde etmiştir. Elliptic filtre %68 ortalama sınıflandırma performansını %68 ile elde etmiştir. Adaptif filtre, %64 ortalama sınıflandırma performansını LDA kombinasyonu ile elde etmiştir. Çizelge 4.40’a bakarak sınıflandırıcı bazında en yüksek performansın lineer sınıflandırıcılara(SVM ve LDA) ait olduğu çıkarımı yapılabilir. Naive Bayes ve k-NN algoritması lineer sınıflandırıcılara göre daha düşük performans göstermiştir. Çizelge 4.40’ta belki de en çok dikkat edilen

noktalardan biri adaptif filtrenin diğer sınıflandırıcılara göre düşük performans sergilemesidir. Bunun önemli nedenlerinden biri motor hareket hayali bilgisinin 7.5-30 Hz arasında olmasıdır. Yüksek performans elde edebilmek için yapılan bant geçiren filtre kalibrasyonlarında en yüksek performans sonuçları, 7.5 Hz ile 21 Hz aralığına kalibre edilen bant geçiren filtrelerden elde edildi. Bu aslında motor hareket hayali bilgisinin 7.5-30 arasında olmasını teyit eder niteliktedir. Şekil 4.9 ve Şekil 4.10'da örnek bir sol el ve sağ el motor hareket hayalinin frekans güç yoğunlukları çizdirilmiştir. Her iki çizelge de de adaptif filtrenin EOG sinyalinin temizlediği görülebiliyor. Fakat adaptif filtrenin 30 Hz üzerindeki frekansları baskılamadığı ve adaptif filtre ile temizlenen sinyalin 30-130 Hz aralığında frekans bileşenlerine sahip olduğu görülüyor. Yapılan bant geçiren filtre kalibrasyonlarından anlaşılabileceği gibi 30 Hz üzerindeki frekans bileşenleri genel anlamda sınıflandırma performansını düşürecek niteliktedir.



Şekil 4.9 Örnek sol el motor hareket hayalinin C3 kanalının frekans gücü yoğunluğu



Şekil 4.10 Örnek sağ el motor hareket hayalinin C3 kanalının frekans gücü yoğunluğu

Çizelge 4.43 En yüksek sınıflandırma performansları kombinasyonları

	Accuracy(%)	Kappa
1. Denek	80 (chebII+LDA)	0.60
2. Denek	61 (chebII + LDA)	0.22
3. Denek	100 (elliptic + LDA)	1
4. Denek	60 (chebII + SVM)	0.19
5. Denek	58 (cheb1 + NB)	0.15
6. Denek	57 (cheb1 + NB)	0.13
7. Denek	72 (chebII + LDA)	0.43
8. Denek	94 (chebII + SVM)	0.88
9. Denek	80 (ChebII+SVM)	0.60

Çizelge 4.44 En yüksek sınıflandırma performansı(Elliptic filtre, 3. Denek)

	k-NN(%)	NB(%)	SVM(%)	LDA(%)
Doğruluk(Accuracy)	94	100	99	100
Duyarlılık(Sensitivity)	93	100	98	100
Özgüllük(Specificity)	96	100	100	100
Kesinlik(Precision)	93	100	100	100
Duyarlılık (Recall)	94	100	98	100
F-Skor(F-Measure)	94	100	99	100
Kappa Skor(Kappa Skor Metric)	88	100	98	100

Çizelge 4.43'te her bir deneğe ait filtre-sınıflandırıcı kombinasyonlarının en yüksek performans değerleri gösterilmiştir. 3. Denek, 10-20 Hz elliptik filtre kalibrasyonu ve LDA sınıflandırıcısıyla %100'lük bir doğruluk oranına yükselmiştir. Ayrıca belirtilen frekans kalibrasyonu ile 3. Denek üzerinde Naive Bayes sınıflandırıcısı da %100'lük doğruluk performansı göstermiştir. 3. Denek ile ilgili elliptik filtre sonuçları Çizelge 4.44'te gösterilmiştir. Bu oranlar, çalışmada yapılan bütün varyasyonlardan en başarılı performanslarıdır.

5. SONUÇ VE ÖNERİLER

Bu çalışma, sağ ve sol motor hareket hayalinin, EEG verileri üzerinde oluşan etkilerini tespit etme amacıyla gerçekleştirilmiştir. Ayrıca, EOG verileri kullanılarak temizlenen adaptif filtreler ve non-adaptif filtreler ile temizlenen EEG verilerinin sınıflandırma sonuçlarına mukayesesi amaçlanmıştır.

Adaptif filtre olarak RLS algoritması ve bant geçiren filtre olarak Chebyshev 1, Chebyshev 2 ve Eliptik filtreleri seçilmiştir. Bu filtrelemelerden elde edilen veriler öznitelik çıkarma yöntemi olan CSP algoritmasına giriş olarak uygulanmıştır. Her bir denemenin 22 kanalı CSP algoritmasına giriş olarak verilmiştir. CSP algoritmasının çıkışında her bir deneme için 4 öznitelik vektörü elde edilmiştir. Elde edilen bu öznitelik vektörleri k-NN, Naive Bayes, SVM ve LDA sınıflandırma algoritmalarının girişine uygulanmıştır. Sınıflandırma sonuçları, Doğruluk(Accuracy), Kappa Skor(Kappa), Duyarlılık(Sensitivity), Kesinlik(Precision), Özgüllük(Specificity), F-Skor(F-Score) performans kriterlerine göre değerlendirilmiştir.

9 deneğin ortalama performansı dikkate alındığında, en yüksek performans ortalamasını, %72'lik doğruluk performansı ve %43'lük kappa skoru ile chebyshev 2+LDA sınıflandırıcısı kombinasyonu gösterdi. Sınıflandırıcı bazında ortalama başarımlarda LDA ve SVM, k-NN ve Naive Bayes'ten daha yüksek performans sergiledi. 3. denek üzerinde eliptik filtre ve LDA kombinasyonu %100 doğruluk oranı ve 1 kappa skoru ile en yüksek başarımları gösterdi. RLS adaptif filtresi ile yapılan sonuçların diğer filtrelerle göre daha düşük olduğu gözlemlendi.

Sonuçlardan da anlaşılacağı üzere, sağ ve sol motor hareket hayalini tespit, non-adaptif filtreler ile yapılan uygulama, adaptif filtre ile yapılan uygulamadan daha iyi sonuçlar vermiştir. Çünkü motor hareket hayali bilgisi frekans aralığının üzerindeki etki aralığı 8-30 Hz olduğu bilinmektedir. Bu aralığın belli olması ve non-adaptif filtre için kesim frekansı bölgesi bilindiği için non-adaptif filtre kullanım imkanı oluşmaktadır. Bu gerekçeden ötürü, yapılan çalışmamızda, non-adaptif filtre ile yapılan uygulama sonuçları, adaptif RLS filtresi uygulama sonuçlarına göre daha iyi sonuçlar vermektedir. Bu sonuçlara göre kesim frekansları belli olmayan gürültüleri gidermede adaptif filtreler önerilebilir.



6. KAYNAKLAR

Akıncı B. 2010. Realization of a cue based motor imagery brain computer interface with its potential application to a wheelchair. Yüksek lisans tezi, Orta Doğu Teknik Üniversitesi Fen Bilimleri Enstitüsü, Ankara. 157

Hameed A. 2012. Real-Time Noise Cancellation Using Adaptive Algorithms. Yüksek lisans tezi, Orta Doğu Teknik Üniversitesi Fen Bilimleri Enstitüsü, Ankara. 84

Snyder S., Shen X.A.. 2017. A Review of Brain Signal Processing Methods. Erisim: [https://pdfs.semanticscholar.org/1ec4/b409df522c36b97ade60323708f09dac8799.pdf]. Erisim Tarihi :9.06.2019

Cecotti, H., & Rivet, B. 2011. Effect of the visual signal structure on steady-state visual evoked potentials detection. In 2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Mayıs 2011, S. 657-660.

Beverina, F., Palmas, G., Silvoni, S., Piccione, F., & Giove, S. 2003. User adaptive BCIs: SSVEP and P300 based interfaces. *PsychNology Journal*, 1(4): 331-354.

IMOTIONS 2016. EEG (Electroencephalography): The Complete Pocket Guide. Erisim: [https://imotions.com/blog/eeg/]. Erisim Tarihi :9.06.2019

HEATHER S. 2015. Brain Waves. Erisim: [http://www.simonheather.co.uk/pages/articles/brain_waves.pdf]. Erisim Tarihi :10.06.2019

Ramoser, H., Muller-Gerking, J., & Pfurtscheller, G. 2000. Optimal spatial filtering of single trial EEG during imagined hand movement. *IEEE transactions on rehabilitation engineering*, 8(4), 441-446.

He, P., Wilson, G., & Russell, C. 2004. Removal of ocular artifacts from electro-encephalogram by adaptive filtering. *Medical and biological engineering and computing*, 42(3), 407-412.

Lotte, F., & Guan, C. 2010. Regularizing common spatial patterns to improve BCI designs: unified theory and new algorithms. *IEEE Transactions on biomedical Engineering*, 58(2), 355-362.

Robinson, N., Vinod, A. P., Guan, C., Ang, K. K., & Peng, T. K. 2011. A Wavelet-CSP method to classify hand movement directions in EEG based BCI system. In 2011 8th International Conference on Information, Communications & Signal Processing, Haziran 2011, S. 1-5

Ang, K. K., Chin, Z. Y., Zhang, H., & Guan, C. 2008. Filter bank common spatial pattern (FBCSP) in brain-computer interface. In 2008 IEEE International Joint Conference on Neural Networks, IEEE World Congress on Computational Intelligence, Haziran 2008 S. 2390-2397.

Mingai, L., Jingyu, L., Dongmei, H., & Jinfu, Y. 2009. An improved CSP algorithm and application in motor imagery recognition. In 2009 Fifth International Conference on Natural Computation, Ağustos 2009, Cilt. 2, S. 114-117.

Akıncı, B., & Genç, N. G. 2010. Online cue-based discrimination of left/right hand movement imagination. In 2010 15th National Biomedical Engineering Meeting, Nisan 2010 S. 1-4

Belwafi, K., Djemal, R., Ghaffari, F., & Romain, O. 2014. An adaptive EEG filtering approach to maximize the classification accuracy in motor imagery. In 2014 IEEE Symposium on Computational Intelligence, Cognitive Algorithms, Mind, and Brain (CCMB), Aralık 2014, S. 121-126.

Kumar, P. S., Arumuganathan, R., Sivakumar, K., & Vimal, C. 2009. An adaptive method to remove ocular artifacts from EEG signals using wavelet transform. *J. Appl. Sci. Res*, 5(7), 711-745.

Aydemir Ö. 2016. Common spatial pattern-based feature extraction from the best time segment of BCI data. *Turkish Journal of Electrical Engineering & Computer Sciences*, 3976 – 3986.

University of Graz 2008. BCI Competition IV. Erisim:[<http://www.bbc.de/competition/iv/#dataset2a>]. Erisim Tarihi :10.06.2019

Grosse-Wentrup, M., & Buss, M. 2008. Multiclass common spatial patterns and information theoretic feature extraction. *IEEE transactions on Biomedical Engineering*, 55(8), 1991-2000.

Marshall, P. J., & Meltzoff, A. N. 2011. Neural mirroring systems: Exploring the EEG mu rhythm in human infancy. *Developmental cognitive neuroscience*, 1(2), 110-123.

Aleksandrov, A. A., & Tugin, S. M. 2012. Changes in the mu rhythm in different types of motor activity and on observation of movements. *Neuroscience and Behavioral Physiology*, 42(3), 302-307.

Landis, J. R., & Koch, G. G. 1977. The measurement of observer agreement for categorical data. *biometrics*, 159-174.

ÖZGEÇMİŞ

Adı Soyadı	: Zeynelabidin SEVGİLİ
Doğum Yeri	: Mardin
Doğum Tarihi	: 08.03.1985
Medeni Hali	: Evli
Yabancı Dil	: İngilizce

Eğitim Durumu (Kurum ve Yıl)

Lise	: Nusaybin Lisesi
Lisans	: Dicle Üniversitesi Elektrik ve Elektronik Müh.
Y. Lisans	: Dicle Üniversitesi – Elektrik ve Elektronik Müh.Anabilim Dalı

Çalıştığı Kurum/Kurumlar ve Yıl

- İnotek bilişim(web yazılım)(2010)
- Eroğlu yazılım(Hastane otomasyon sistemleri(Dicle Üniversitesi Tıp Fakültesi))(2011)
- Kralkızı barajı: Elektrik bakım mühendisi(6 ay), Elektrik İşletme Mühendisi(13 ay)(2012-2014)
- RN ENERJİ GES(Güneş Enerjisi Santrali) Projelendirme ve Danışmanlık(2 sene)(2015-2019)



DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
TEZ İNTİHAL FORMU

ÖĞRENCİ BİLGİLERİ

ADI VE SOYADI	Zeynelabidin SEVGİLİ
ÖĞRENCİ NO	16805006
EĞİTİM – ÖĞRETİM YILI	2018-2019
YARIYIL	☐ Güz ☒ Bahar
ANABİLİM DALI	Elektrik Elektronik Mühendisliği
PROGRAM	Yüksek Lisans
TEZ KONUSU	İmleç Hareketlerine Ait EEG Sinyallerinin Sınıflandırılmasında Adaptif ve Adaptif Olmayan Filtrelerin Uygulamaları

İNTİHAL RAPORU BİLGİLERİ

RAPOR TÜRÜ	Tez Savunma Sınavı Sonrası
SAYFA SAYISI	100
BENZERLİK ORANI	%9
RAPORLAMA TARİHİ	05/08/ 2019

Yukarıda başlığı/konusu gösterilen tez çalışmamın kapak sayfası, giriş, ana bölümler, sonuç ve tartışma kısımlarından oluşan toplam 100 sayfalık kısmına ilişkin, 05/08/2019 tarihinde şahsım tarafından Turnitin.adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan intihal raporuna göre, tezimin benzerlik oranı % 9'dır.

Uygulanan filtrelemeler:

- ☐ Kabul/Onay sayfaları hariç,
☐ Kaynakça hariç
☐ Alıntılar hariç/dâhil
☐ Diğer

Dicle Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Programlarda Tez Çalışması İntihal Raporu Uygulama Esasları'nı inceledim ve bu Uygulama Esasları'nda belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edilmesi durumunda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini saygılarımla arz ederim.

Zeynelabidin SEVGİLİ
05.08.2019

Prof. Dr. Mehmet AKIN
Tez Danışmanı
05.08.2019

Doç. Dr. Bilal GÜMÜŞ
Anabilim Dalı Başkanı
05.08.2019

Formdaki bilgiler bilgisayar ortamında doldurulmalıdır. El yazısı ile doldurulan formlar geçersiz sayılmaktadır.