

**MAKİNE ÖĞRENMESİ YÖNTEMLERİ KULLANILARAK EEG
VERİSİNDEN ZİHİNSEL DİKKAT DURUMU TESPİTİ**

YÜKSEK LİSANS TEZİ

MURAT KAYA

**MERSİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLGİSAYAR MÜHENDİSLİĞİ
ANABİLİM DALI**

**MERSİN
AĞUSTOS - 2019**

**MAKİNE ÖĞRENMESİ YÖNTEMLERİ KULLANILARAK EEG
VERİSİNDEN ZİHİNSEL DİKKAT DURUMU TESPİTİ**

YÜKSEK LİSANS TEZİ

MURAT KAYA

**MERSİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLGİSAYAR MÜHENDİSLİĞİ
ANABİLİM DALI**

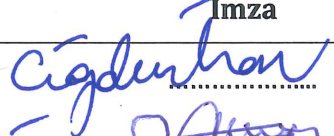


Danışman

**Dr. Öğr. Üyesi Çiğdem İnan ACI
Doç Dr. Yuriy MİSHCHENKO**


**MERSİN
AĞUSTOS - 2019**

ONAY

Murat KAYA tarafından Dr. Öğr. Üyesi Çiğdem ACI danışmanlığında hazırlanan "Makine Öğrenmesi Yöntemleri Kullanılarak EEG Verisinden Zihinsel Dikkat Durumu Tespiti" başlıklı çalışma aşağıda imzaları bulunan jüri üyeleri tarafından 02/08/2019 tarihinde yapılan Tez Savunma Sınavı sonucunda oy birliği/çokluğu ile Yüksek Lisans tezi olarak kabul edilmiştir.

Görevi	Ünvanı, Adı ve Soyadı	İmza
Başkan	Dr. Öğr. Üyesi Çiğdem ACI	
Üye	Prof. Dr. Zeki YETGİN	
Üye	Dr. Öğr. Üyesi Ahmet AYDIN	

Yukarıdaki Jüri kararı Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 23.08/2019 tarih ve 2019.35/1279 sayılı kararıyla onaylanmıştır.



Bu tezde kullanılan özgün bilgiler, şekil, tablo ve fotoğraflardan kaynak göstermeden alıntı yapmak 5846 sayılı Fikir ve Sanat Eserleri Kanunu hükümlerine tabidir.

ETİK BEYAN

Mersin Üniversitesi Lisansüstü Eğitim-Öğretim Yönetmeliğinde belirtilen kurallara uygun olarak hazırladığım bu tez çalışmada,

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
 - Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlâk kurallarına uygun olarak sunduğumu,
 - Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
 - Atıfta bulunduğum eserlerin tümünü kaynak olarak kullandığımı,
 - Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
 - Bu tezin herhangi bir bölümünü Mersin Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı,
 - Tezin tüm telif haklarını Mersin Üniversitesi'ne devrettiğimi
- beyan ederim.

ETHICAL DECLARATION

This thesis is prepared in accordance with the rules specified in Mersin University Graduate Education Regulation and I declare to comply with the following conditions:

- I have obtained all the information and the documents of the thesis in accordance with the academic rules.
- I presented all the visual, auditory and written informations and results in accordance with scientific ethics.
- I refer in accordance with the norms of scientific works about the case of exploitation of others' works.
- I used all of the referred works as the references.
- I did not do any tampering in the used data.
- I did not present any part of this thesis as an another thesis at Mersin University or another university.
- I transfer all copyrights of this thesis to the Mersin University.

02/02/2019

İmza / Signature



Öğrenci Adı ve Soyadı / Student Name and Surname

Murat KAYA

ÖZET

ZİHİNSEL DİKKAT DURUMLARINI MAKİNE ÖĞRENME YÖNTEMLERİ KULLANARAK EEG TABANLI PASİF BİR BBA İLE AYIRT ETMEK

Teknolojideki son gelişmeler insan katılımcıların rolünün pasif gözlemlere indirildiği yeni çalışma ortamları yaratmaktadır. Bu tür ortamlar, verimlilik ve yaşam tarzında yeni sınırlar açarken aynı zamanda pasif kontrol görevleri sırasında bireylerin odaklanma ve konsantrasyonlarını sürdürmemeleriyle ilgili tehlikeler de yaratmaktadır. Bu çalışmada, elektroensefalografik (EEG) beyin aktivitesi görüntüleme ve makine öğrenimi veri analizi yöntemlerini kullanarak bireylerin zihinsel dikkat durumlarını (odaklanmış, dalgın ve uyuklu) izlemeye yönelik pasif bir beyin-bilgisayar arayüzü geliştirilmiştir. Tasarlanan, EEG tabanlı Destek Vektör Makinesi (DVM) algoritması, K En Yakın Komşu ve Adaptif Ağ Tabanlı Bulanık Mantık Çıkarım algoritmalarıyla karşılaştırıldı. Beş katılımcıdan 25 saat EEG verisi toplamak için klasik bir EEG başlığı değiştirildi. 1-5 Hz ve 10-15 Hz frekans bantlarında meydana gelen frontal ve parietal loblarda EEG aktivitesindeki değişikliklerin, bireylerin dikkat durumundaki değişikliklerle ilişkili olduğu saptandı. DVM tabanlı zihinsel durum algılayıcı sürekli performans görevi versiyonunu kullanarak deneysel ortamda bu tür değişiklikleri, bireylerin dikkat durumunu %96.70 (en iyi) ve %91.72 (ortalama) doğrulukla belirlemiştir. Bulgular, EEG beyin aktivite verileri aracılığıyla bireylerin durumunu izlemek için gelecekteki sistemlerin tasarımında yol gösterici olacaktır.

Anahtar Kelimeler: EEG, BBA, zihinsel durum tespiti, uyku tespiti, destek vektör makinesi, pasif kontrol görevi.

Danışman: Dr. Öğr. Üyesi Çiğdem İnan AÇI, Mersin Üniversitesi, Bilgisayar Mühendisliği Anabilim Dalı, Mersin.

İkinci Danışman: Doç. Dr. Yuriy Mishchenko, İzmir Ekonomi Üniversitesi, Biyomedikal Mühendisliği Anabilim Dalı, İzmir.

ABSTRACT

DETERMINATION OF MENTAL ATTENTION STATE WITH EEG BASED BCI USING MACHINE LEARNING METHODS

Recent advances in technology bring about novel operating environments where the role of human participants is reduced to passive observation. While opening new frontiers in productivity and lifestyle, such environments also create hazards related to the inability of human individuals to maintain focus and concentration during passive control tasks. A passive brain-computer interface for monitoring mental attention states of human individuals (focused, unfocused, and drowsy) by using electroencephalographic (EEG) brain activity imaging and machine learning data analysis methods is developed in this work. An EEG data processing pipeline and a machine learning mental state detection algorithm using the Support Vector Machine (DVM) method were designed and compared with k-Nearest Neighbor and Adaptive Neuro-Fuzzy System methods. To collect 25 hours of EEG data from 5 participants, a classic EEG headset was modified. We found that the changes in EEG activity in frontal and parietal lobes occurring at 1-5 Hz and 10-15 Hz frequency bands were associated with the changes in individuals' attention state. We demonstrated the ability to use such changes to identify individuals' attention state with 96.70% (best) and 91.72% (avg.) accuracy in experimental settings using a version of continuous performance task with DVM-based mental state detector. The findings help guide the design of future systems for monitoring the state of human individuals by means of EEG brain activity data.

Keywords: EEG, BCI, mental state detection, drowsiness detection, support vector machine, passive control task.

Advisor: Asst. Prof. Dr. Çiğdem İnan Acı, Computer Engineering, University of Mersin, Mersin.

Co-Advisor: Assoc. Prof. Dr. Yuriy Mishchenko, Biomedical Engineering, University of İzmir Economics, İzmir.

TEŐEKKÜR

Bu alıőmadaki tm deneyler, Toros niversitesi (Mersin, Trkiye) Mhendislik Fakltesi đrencileri arasından seilen sađlıklı gnll katılımcılarla gerekleőtirildi. Tm katılımcılar, Mersin niversitesi'nin etik ilkelerine uygun olarak deneylerin ama ve prosedrleriyle ilgili talimatları aldıktan sonra onay formunu imzalamıőlardır.

Bu alıőma, Mersin niversitesi Bilimsel Araőtırma Projeleri Blm tarafından desteklenmektedir (Proje Kodu: 2018-3-TP2-3064). alıőmaya katkılarından dolayı Dr. đr. yesi iđdem İnan Acı ve Do. Dr. Yuriy Mishchenko'a teőekkrlerimi sunarım.

Tez sunumunda yer alan deđerli jri yeleri; Prof. Dr. Zeki Yetgin ve Dr. đr. yesi Ahmet Aydın'a katılımlarından dolayı teőekkrlerimi sunarım.



İÇİNDEKİLER

	Sayfa
İÇ KAPAK	i
ONAY	ii
ETİK BEYAN	iii
ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
TABLolar DİZİNİ	viii
ŞEKİLLER DİZİNİ	ix
KISALTMALAR ve SİMGELER	x
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMALARI	1
2.1. Çalışmanın Motivasyonu	7
3. MATERYAL ve YÖNTEM	8
3.1. Deneyin Yapılışı	8
3.2. EEG Başlık Modifikasyonu	11
3.3. Veri İşleme ve Öznitelik Çıkarımı	12
3.4. Zihinsel Durum Tespiti	15
3.5. Sınıflandırıcılar	15
3.5.1. Destek Vektör Makineleri (DVM)	16
3.5.2. K En Yakın Komşu (kNN)	16
3.5.3 Adaptive Neuro-Fuzzy System (ANFIS)	17
3.5. DVM Sınıflandırıcılarının Tasarımı	18
3.6. Performans Değerlendirmesi	19
4. BULGULAR ve TARTIŞMA	21
5. SONUÇLAR ve ÖNERİLER	30
KAYNAKLAR	33
ÖZGEÇMİŞ	35

TABLolar DİZİNİ

	Sayfa
Tablo 1. İnsanın dikkat durumunu öngörmeye önceki çalışmaların karşılaştırılması	7
Tablo 2. Örnek Veri	12
Tablo 3. Kullanılan SVMtrain Parametreleri	19
Tablo 4. Hedef zihinsel durum değişkenine sahip ICC (Sınıf İçi Korelasyon)'ye dayanan en önemli 25 özelliğin istatistiksel özellikleri	25
Tablo 5. DVM ile tek bir katılımcıya özgü model için dikkat durumunun doğruluk sonuçları yedi elektrot kullanarak	25
Tablo 6. DVM ile tüm katılımcılar için ortak model için dikkat durumunun doğruluk sonuçları yedi elektrot kullanarak	25
Tablo 7. Tek katılımcıya özel model için Makine Öğrenimi yöntemlerinin ortalama beş kat çapraz doğrulama sonuçlarının karşılaştırılması	26

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1. Bu çalışmada kullanılan sanal pasif kontrol görevine dayalı sürekli performans görevi organizasyonu	10
Şekil 2. Modifiye edilmiş EEG başlık	11
Şekil 3. Zihinsel dikkat durumu algılayıcısının blok şeması	13
Şekil 4. Öznitelik çıkarma adımının blok şeması	15
Şekil 5. DVM çalışma prensibi	16
Şekil 6. kNN çalışma prensibi	17
Şekil 7. ANFIS çalışma prensibi	17
Şekil 8. Odaklanmış (A), dalgın (B) ve uyuklama (C) zihinsel durumları için DVM ağırlık vektörlerine bir örnek	21
Şekil 9. DVM tabanlı sınıflandırıcı eğitim bölümünden önceki örnek bir EEG verisi	22
Şekil 10. EEG elektrotlarından gelen EEG sinyal spektrogramlarının örnekleri: S1 katılımcısı için Fz (A), Pz (B) ve S2 katılımcısı için Fz (C) değerleri	23
Şekil 11. Eğitim / test hataları ve ortalama doğruluk sonuçları, katılımcıya özel model için EEG veri setinde kullanılan EEG elektrotlarının sayısı ile karşılaştırılmıştır	26
Şekil 12. Özellik örnekleri ve S1 katılımcısı için temel istatistiksel özellikleri	31
Şekil 13. S1 katılımcısı ve elektrot Pz için farklı tespit edilen zihinsel durumlarla ilişkili EEG kayıtlarına örnekler: (A) 'odaklanmış' (B) 'dalgın' (C) 'uykulu'	32

KISALTMALAR ve SİMGELER

Kısaltma/Simge	Tanım
ANFIS	Adaptive Neuro Fuzzy Inference System (Uyarlamalı sinirsel bulanık çıkarım sistemi)
BBA	Beyin Bilgisayar Arayüzleri
DFT	Discrete Fourier Transform (Ayrık Fourier dönüşümü)
Diğ	Diğerleri
DVM	Destek Vektör Makinesi
EEG	Elektroensefalografi
ICC	Sınıf İçi Korelasyon
kNN	K nearest neighborhood (K en yakın komşu)
Ort	Ortalama
SAM	Self-Assessment Manikin
STFT	Short Time Fourier Transform (Kısa zaman Fourier dönüşümü)
TEI	Task Engagement Index
WPT	Wavelet Packet Transform

1. GİRİŞ

Otomasyon ve robotlardaki son gelişmeler, insan katılımcıların rolünün giderek daha fazla pasif gözlemlere indirildiği yeni çalışma ortamları yaratmaktadır. Bu tür çalışma ortamları verimlilik ve yaşam tarzı iyileştirmeleri için radikal bir şekilde yeni alanlar açarken, aynı zamanda insan operatörlerinin pasif kontrol görevlerinde yoğunlaşmayı sürdürememesiyle ilgili yeni tehlikeler de yaratmaktadır. Bu gibi durumlarda insan bireylerin durumunu izlemek için en iyi yaklaşımlardan birinin Beyin-bilgisayar arayüzleri (BBA) olması beklenebilir. Günümüzde kullanılan ticari metotlarda göz ve kullanıcı hareketlerinin izlenmesi hareketsiz durumlarda ya da gözlük kullanıldığında yalancı veriler üretmektedir. BBA beyindeki elektriksel aktivitenin direk izlenmesine olanak sağladığından yalancı veriler olmaksızın çalışacak bir durum tespit sistemine olanak sağlayacaktır. Bu çalışmada makine öğrenmesine dayalı BBA tabanlı zihinsel durum tespit sistemi önerilmiştir. Destek vektör makineleri (DVM) kullanılan bu sistem 3 ana zihinsel durumu ele almaktadır. Bunlar aktif, dalgın ve uykulu durumlardır. Literatürde zihinsel durumun tespitinin önemi sadece uyku durumu olarak ele alınmaktadır. Dalgınlık literatürde çalışılmamış bir durum olmakla birlikte uyku durumundan önce geliştiği için tespiti kullanıcıların uyarılması için fırsat tanımaktadır. Önerilecek yöntem sözü edilen 3 durumu %96.70 (en iyi) ve %91.72 (ortalama) doğrulukla belirlemiştir ve gelecekte durum tespit sisteminin farklı alanlarında kullanılabilecek esnek bir tasarıma sahiptir.

2. KAYNAK ARAŞTIRMALARI

BBA'lar beyin ve bilgisayar veya harici cihaz arasında doğrudan bir iletişim kanalı kurar. [1]. BBA'lar, insanlar ile makineler arasında klavye girişi veya konuşma gibi geleneksel etkileşim kanallarını atlayan bilgisayarlar arası yeni bir iletişim paradigması sunmaktadır. Non-invaziv BBA, yani cerrahi müdahale gerektirmeyen sistemler (beyin aktivitesini gözlemek için elektroensefalografi (EEG), manyetoensefalografi veya manyetik rezonans görüntüleme) bireylerin beyin aktivitelerini gözlemek suretiyle doğrudan olmayan yöntemlerin tuzaklarından kaçınarak, onların zihinsel durumunu doğrudan gözleme problemini ele almak için özel bir öneme sahiptir [2]. Bu bağlamda EEG kullanımı, EEG teknolojisinin yerleşik doğası, modern EEG başlıklarının görece kullanım kolaylığının yanı sıra mevcut modern EEG cihazlarının küçük boyutu, uygun maliyeti, taşınabilirliği ve güvenilirliği göz önüne alındığında özel ilgi konusudur [3,4,5].

Geçmişte yapılan çeşitli çalışmalarda, araç sürüşü esnasındaki yorgunluk tespiti konusunda EEG'den yararlanıldığı görülmüştür. Örneğin, Hsieh ve diğ. [6], araç sürücülerinin

yorulma tespiti bağlamında sürücünün EEG sinyallerini kullanarak aracın şerit konumunu tahmin eden bir sistem geliştirmişlerdir. Sözü edilen sistem, özel yapım 2 altın elektrotlu kablosuz bir EEG cihazı kullanılarak gerçekleştirilmiştir. Cihaz, 343 Hz örnekleme oranına sahiptir. Sürücünün uyku durumunu test edebilmek için simülasyona dayalı bir deney ortamı yaratılmış ve katılımcılar 6 hareketli sürüş simülasyonunu sanal bir otoban yolunda sistemi kullanmışlardır. Sanal otobanda toplam 4 yol çizgisi bulunmakta ve 2 çizgi yolun tam ortasında yer alırken diğer iki çizgi yolun sağ ve solunda yer almaktadır. Katılımcıların görevi ise sağ ve sol taraflarda yer alan çizgilerin tam ortasında arabayı sabit 100 km/sa hız ile 45 dakika boyunca kullanmaktır. Simülasyondaki aracı bu çizgiler arasında tutmak devamlı bir dikkat ve kontrol gerektirmektedir. Katılımcı çizgilerin dışarısına çıktığında durum sürücü hatası olarak kabul edilir. Deneyler kişilerin yorgun olduğu akşamüzeri saatlerde gerçekleştirilmiş ve katılımcılar 2, gerekli halde 3 kere deneye katılmıştır. Deney sonucunda toplanan EEG verileri 343 Hz'den öncelikle 64 Hz değerine düşürülmüştür. Bu ham EEG verileri Kısa - Zaman Hızlı Fourier Dönüşümünden geçirildikten sonra normalize edilmiş ve lineer regresyon modeline gönderilmiştir. Sözü edilen algoritmanın performansı Matlab kullanılarak test edilmiştir. Test, elde edilen gerçek sürücü uyku hataları ile algoritmanın tahmini olan sürücü uyku hataları üst üste getirilerek gerçekleştirilmiştir.

Yeo ve diğ. [7], Destek vektör makinesine (DVM) dayalı sınıflandırıcıların EEG tabanlı uyku tespit sistemlerindeki başarısını değerlendirmiş ve farklı beyin dalgalarının uyku ile bağlantısını araştırmıştır. Çalışmada Medtronic PL-Winsor EEG cihazı kullanılmıştır. Cihaz 256 Hz örnekleme oranına sahip ve 32 elektrotludur. Sözü edilen çalışmaya 20 katılımcı eşlik etmiş ve deneyler katılımcıların uykulu durumlarından faydalanabilmek adına akşamüstü gerçekleştirilmiştir. Deney prosedürü katılımcılara 1 saat boyunca oldukça boş otoban resimleri gösterilmesini ve araç motor sesi dinletilmesini içermektedir. Deney esnasında katılımcılara 10/20 düzeninde EEG yerleşimi yapılmış, kalp atışlarından kaynaklı gürültüleri tespit edebilmek adına nabız ölçer yerleştirilmiş ve manuel olarak sınıflandırma işlemine veri elde edebilmek için göz hareketlerini takip eden elektrotlar da yerleştirilmiştir. Deney sonucunda elde edilen ham EEG verisinden kalp atışları ve katılımcıların hareketlerine dayalı istenmeyen gürültüler görsel olarak incelenerek ayrılmıştır. Gürültülerden arındırılan EEG verisi Matlab kullanılarak 0.1-25 Hz değerlerinde özelleştirilmiş bir bant geçişi filtresinden geçirilmiştir. Mevcut EEG verisi manuel olarak 2 EEG eğitilmiş araştırmacı tarafından manuel olarak sınıflandırılmıştır. Manuel sınıflandırma işleminde göz kırpma zamanı 0.3-0.4 saniye aralığında ve EEG aktivitesi beta dalgalarında ise uyarılmış, göz kırpma zamanı 0.5 saniyeden fazla ve EEG aktivitesi alfa dalgalarında ise uyuklama olarak kabul edilmiştir. DVM kullanılarak otomatik bir sınıflandırma yapmak için Hızlı Fourier Dönüşümü ve Hann Penceresi kullanılarak öznel çıkartımı uygulanmıştır. Otomatik sınıflandırmanın sonucu manuel sınıflandırma ile

karşılaştırılmış ve örtüştüğü tespit edilmiştir. Bu çalışma, araç sürücülerinin uyarılmış ve uykulu halleri ile EEG beta ve alfa ritimlerdeki değişiklikler arasında bir bağlantı olduğunu bildirmiştir. Daha sonra, araç sürücülerinin yorulma başlangıcını otomatik olarak tespit etmek, böyle bir sistemi simüle etmek ve gerçek sürüş koşullarında test etmek için bir sistem önermişlerdir.

Mardi ve diğ. [8], yukarıdaki deneylerde olduğu gibi aktiflik ve uyku durumlarını ele almış ve bu iki durum arasındaki EEG aktivitesi farkını ortaya koymuşlardır. Çalışmayı gerçekleştirebilmek için taşınabilir bir EEG cihazı kullanılmıştır. Bu cihaz, 24 kanallı ve 128 Hz örneklem oranına sahiptir. Sözü edilen EEG farklılıklarını ortaya koyabilmek için bir deney prosedürü hazırlanmıştır. Deneyde engelli bir yol içeren simülasyon kullanılmıştır. Bu simülasyona 20 saat boyunca uyumamış 10 katılımcı dâhil edilmiş, 45 dakika boyunca simülasyonda araç kullanmışlardır. Deney esnasında yapılan engellere takılma ve kazalar hata olarak kabul edilmiştir. Çalışmada aktif ve uyku durumunun farkını ortaya koyabilmek adına EEG sinyallerine Higuchi ve Petrosian Fraktal Boyut hesapları uygulanarak öznitelik çıkarımı yapılmış, bu verilere ise iki uçlu t-testi uygulanarak ayırım gerçekleştirilmiştir. Uykulu ve aktif durum arasında %95 oranında oldukça yüksek bir farklılık olduğu, bu sayede EEG-BBA ile dikkat durum testlerini uygulamanın oldukça güçlü sonuçlar vereceğini ortaya koymuşlardır.

Simon ve diğ. [9], EEG aktivitesindeki alfa millerinin yorgunlukla ilişkisini açıklamışlardır. Alfa milleri, alfa güç yoğunluğunun 500 Ms dar bantta patlama göstererek artmasıdır. Çalışmada 1000 Hz örneklem oranına sahip 128 elektrotlu BrainAmp EEG cihazı kullanılmıştır. Araştırma için tasarlanan deney gerçek bir araba sürüşü içermekte ve 55 katılımcıya sahiptir. Katılımcılar 430-480 km boyunca öğle saatlerinde başlayan normal trafik koşullarında araç sürüşü gerçekleştirmişlerdir. Araç sürüşü esnasında EEG kaydı alınmış, katılımcıların yüzleri termal kamerayla görüntülenerek uykuya dair veriler toplanmıştır. 55 katılımcıdan 10'u yorgunluk nedeniyle testi bırakmış ve sadece bu 10 katılımcının verisi çalışmada kullanılmıştır. Alfa millerini tespit edebilmek için EEG dalgalarına kısa zaman Fourier dönüşümü uygulanmış ve tespit için bir algoritma öne sürülmüştür. Öne sürülen algoritmanın çalışabilirliğini kontrol etmek adına araştırmacılar sentetik EEG verisi yaratmışlardır. Sözü edilen algoritmanın sentetik veride başarılı olması üzerine gerçek verilere uygulanmış ve sonuç olarak EEG sinyallerindeki alfa millerinin parametrelerindeki değişikliklerin sürücü yorgunluğunun artmasıyla ilişkili olabileceğini göstermişlerdir.

Hashemi ve diğ. [10], araç sürücülerinin uyuşukluğunun başladığını tespit etmek için bir sistem ortaya koymuşlardır: Görsel olarak uyarılmış potansiyeli elde edebilmek için katılımcılara parlayan ışık kaynağı gösterilmiştir. Parlayan veya patlayan bir ışık kaynağını görmek görsel korteks üzerinde farklı bir EEG dalgası oluşturmaktadır. Araştırmacılar, sürücünün gözünün açık ya da kapalı olduğunu anlamak için sözü edilen EEG dalgasını

kullanmıştır. Uyku durumu tespitinde farklı ve sınıflandırması kolay olan bir sebep arandığı söylenebilir. Diğer araştırmalardan farklı olarak uyku ya da dalgınlıkla birebir alakalı olmayan bu araştırmanın gözlerin kapalı olup olmadığına odaklanmış olmasıdır. Tasarlanan deneyde katılımcılar bir simülasyon kullanmıştır. Katılımcılarda Görsel Olarak Uyarılmış Potansiyel EEG yaratabilmek için karşılıklarına ara ara parlayan ışık kaynağı yerleştirilmiştir. Elde edilen EEG dalgalarına kısa zaman Fourier dönüşümü uygulanarak öznelik çıkarımı yapılmış ve DVM ile sınıflandırılmıştır. Sınıflandırma sonucu olarak kapalı ve açık gözler %97 farkla ayrılabilmiştir.

Birkaç çalışma, EEG BBA'nın araba sürüşünden farklı ortamlarda deneklerin zihinsel durumlarının keşfedilmesine yönelik uygulamalarını bildirmiştir: Borghini ve diğ. [11], uçak pilotları veya araç sürücüleri gibi farklı koşullar altında zihinsel iş yükü ve EEG sinyalleri arasındaki korelasyonu incelemiştir. Arico ve diğ. [12], hava trafik kontrolörlerinin zihinsel iş yükünün değerlendirilmesi için pasif bir EEG BBA geliştirmiştir. Myrden ve Chau'nun bir çalışması [2], zihinsel aritmetik, anagram çözümü ve kısa süreli hafıza hatırlama da dahil olmak üzere zihinsel iş yükü görevleri sırasında yorgunluk, gerginlik ve dikkat durumlarındaki değişiklikleri tespit etmek için pasif bir EEG BBA tanımlamıştır.

İnsanların zihinsel durumlarını EEG kayıtlarını kullanarak belirleme çalışmalarının ürettiği veriler, araştırmacıları bu veri kümelerini ve makine öğrenme yöntemlerini kullanarak zihinsel durumu tahmin etmeye yönlendirmiştir: Li ve diğ. [13], Self-Assessment Manikin (SAM) kullanarak k-En Yakın Komşu (kNN) sınıflandırıcısı ile üç dikkat seviyesi sınıflandırmışlardır. Deneklere üstlenmeleri gereken çeşitli zihinsel görevler verilmiş ve bir dizi dikkat sınıflandırması kullanarak görevler sırasında dikkat düzeyleri hakkında rapor vermeleri istenmiştir. Ortalama doğruluk oranının, yedi seans EEG eğitiminden sonra %57.03'e ulaştığı gösterilmiştir.

Ke ve diğ. [14], tüm deneklere üç farklı dikkat seviyesinde (örneğin dikkat, dikkatsiz ve dinlenme) görevlerini yerine getirme talimatı verilen iki deney gerçekleştirmiştir. Daha sonra, istatistiksel analizler ve DVM ile sınıflandırma yapılmıştır. İki deney için üç dikkat seviyesinin tanınmasında sırasıyla %76.19 ve %85.24 doğruluk değerleri olan sonuçlar elde etmişlerdir.

Wang ve diğ. [15] DVM kullanarak, sürücülerin dikkatini ve operatörlerin ikili (çoklu) görev koşullarına katılımlarına odaklanmalarını takip etmek ve önlemek için bir karşı yöntem geliştirmişlerdir. Sistem, katılımcıların sırasıyla matematik ve sürüş görevlerinde dikkat odağını tespit etmede %84.6 ± 5.8 ve %86.2 ± 5.4 sınıflandırma doğruluğu sağlamıştır. Yapılan başka bir çalışmada [16] dikkat ve dikkatsizlik durumları, dalgacık filtresi ve DVM kullanarak ayrılmıştır. Dört denekle deney yapılmış ve %77-83 oranında bir doğruluk elde edilmiştir.

Bu çalışmada zihinsel durum tespiti ve izlenmesi problemini incelemek için, pasif gözlem görevi sırasında katılımcıların zihinsel durumlarını karakterize eden özgün bir EEG veri kümesi toplanmıştır. Zihinsel durumlarındaki değişiklikleri tespit etmek için DVM tabanlı bir

yöntem önerilmiştir. DVM detektörü, istenilen zihinsel durumdayken denekler için toplanan EEG verisi örnekleri üzerinde eğitilmiştir. Makine öğrenimi DVM sınıflandırıcıları topluluğu, algılamayı çoklu duruma özgü sınıflandırıcı çıkışlarının XOR toplaması yoluyla uygulamak için kullanılmıştır. Geliştirilen detektörün sadece EEG sinyalleri kullanarak odaklanmış, dalgın ve uyuklama ile ilgili zihinsel dikkat durumlarını ayırt ettiği gösterilmiştir.

Tablo 1, zihinsel dikkat durumlarını kronolojik olarak saptama konusundaki önceki çalışmaların sonuçlarını özetlemektedir.

Liu ve diğ. [17], öğrencilerin ders esnasında dikkatlerini kaybedip etmediğine yoğunlaşmışlardır. Yapılan çalışmada, dikkatli ve dikkatsiz olmak üzere iki durum incelenmiş, durum tespiti yapabilmek ve veri toplayabilmek için yapılan deneye 24 katılımcı eşlik etmiştir. Ortalama yaşları 25 olan katılımcılar 12 kadın ve 12 erkek olarak ayrıldı. Bu ayrımın amacı kadın ve erkek arasındaki dikkat farklılıklarını gözlemleyebilmektir. Katılımcılar, deney esnasında standart olarak öğrenimlerinde gördükleri İngilizce dersine ait materyalleri kullanmışlar, belirli İngilizce diyalogları dinleyerek kendilerine verilen soruları cevaplayıp dikkat durumlarını kendileri değerlendirmişlerdir. Deney, klasik bir öğrenme ortamını simüle etmeyi amaçlamaktadır. Katılımcılardan deney esnasında MindSet marka bir EEG cihazı ile veri toplanmıştır. Bu cihaz kafa üzerinde frontal lob kısmına 1 elektrot (Fp1) yerleştiren taşınabilir kablosuz bir cihazdır. Cihaz 512 Hz örneklem oranına sahiptir. Toplanan EEG verileri Hızlı Fourier Transform kullanılarak öznelik çıkarım işlemine tabi tutulmuş olup sınıflandırıcı olarak DVM kullanılan çalışmada başarı oranı en iyi %76.82 olarak elde edilmiştir.

Lee ve diğ. [18], sürücülerin uyku durumlarını 6 farklı durum olarak ele alan ve bunları sınıflandıran bir sistem önermiştir. Çalışmada 100 Hz örneklem oranına sahip bir EEG cihazı kullanılmıştır. Çalışmada 8 elektrotlu olduğu belirtilen cihazın, çalışmada paylaşılan bir figür üzerinde 2 elektrotlu olduğu belirtilmektedir. 20 katılımcının eşlik ettiği deney prosedürü 4 saat kullanılacak bir simülasyondan oluşmaktadır. Simülasyon araç sürüşü içermekte ve her katılımcı 2 gün olmak üzere toplam 8 saatlik bir EEG verisine sahiptir. Katılımcılardan EEG verisinin yanı sıra solunum verisi de toplanmıştır. Solunum verisi kişilerin oksijen seviyesine göre uyku durumları ile ilgili bilgi edinmek için toplanmıştır. Toplanan EEG verileri 0.1 Hz ve 40 Hz aralığında Butterworth filtre ile filtrelenmiştir. Filtrelenen veri Wavelet Packet Transform (WPT) kullanılarak öznelik çıkarım işlemine tabi tutulmuştur. Araştırmacılar sınıflandırıcı olarak DVM tercih etmiştir. EEG kaydı, öznelik çıkarımı ve DVM tabanlı sınıflandırıcı bir cep telefonu üzerinde çalıştırılmıştır. Uyanık, uyuklamaya yakın, uyuklama, aşırı uyuklama, uyku, derin uyku olmak üzere literatürde tam tanımlarının yer almadığı 6 durum sınıflandırması için yapılan bu sistem %98.60 oranında bir doğruluk vaat etmektedir.

Nuamah ve Seong [19], 2018 yılında Task Engagement Index (TEI) olarak adlandırılan bir metot ile durum sınıflandırmasında diğer çalışmalardan oldukça farklı bir çalışma

önermişlerdir. TEI EEG güç bantlarını kullanan bir orandır ve çalışmada "TEI = (beta/(alfa + teta))" olarak ifade edilmiştir. Bu denklemden elde edilen değerler ile kişilerin yürütmekte oldukları görevle bilişsel olarak ne kadar bağlantılı olduğunu tespit etmeyi amaçladılar. Bu amaçlarını gerçekleştirebilmek için hazır bir EEG veri kümesi kullanmışlardır. Kullanılan veri kümesinde 5 farklı görev yer almaktadır bu görevler; matematiksel çarpma, mektup yazma, geometrik şekil döndürme, görsel sayı sayma olarak belirtilmiştir. Görevlerin ortak özellikleri, katılımcıların görev esnasında hareket etmeden, sesli düşünmeden gerçekleştirilmiş olmasıdır. Sözü edilen EEG veri kümesine araştırmacılar TEI oranını uygulamış ve elde edilen sonucu 6 adet DVM sınıflandırıcıyı beslemek için kullanmışlardır. 6 adet DVM yukarıda sözü edilen 5 durumu sınıflandırmak için kullanılmıştır. Sınıflandırma sonucu olarak %93.33 oranında bir başarı elde edilmiştir. Sonuç olarak TEI oranı ile insanların bilişsel iş yükü altındaki durumlarının sınıflandırmasında başarılı bir metot olabileceğini öne sürülmüştür. TEI BBA sınıflandırmalarında çok fazla kullanılan bir metot olmadığından literatürde konu hakkında fazla bilgi yer almamaktadır. Sözü edilen çalışma diğer durum sınıflandırma çalışmalarından oldukça farklıdır.

Tablo 1'de görüldüğü gibi, çalışmamız önceki çalışmalardan daha iyi sonuçlara sahiptir. Yakın sonuçlar veren çalışmalar analiz edildiğinde, EEG sinyalini destekleyen ekstra veriler kullanıldığı veya sadece iki durum kullanılarak zihinsel durumların sınıflandırıldığı görülmüştür.

Tablo 1. Zihinsel dikkat durumunun öngörülmesi hakkında yapılan önceki çalışmaların karşılaştırılması.

Kaynak	Veriseti	Metot	Zihinsel Durum Tahmini	Doğruluk (%)
[13]	EEG	KNN	3 farklı dikkat durumu	57.00
[17]	EEG	DVM	2 durum (dikkatli ya da dikkatsiz)	76.82
[18]	EEG ve solunum verisi	DVM	6 durum (uyanık, uyuklamaya yakın, uyuklama, aşırı uyuklama, uyku, derin uyku)	98.60
[14]	EEG	DVM	3 durum (dikkatli, dikkatsiz ve dinlenme)	76.19 -85.24
[15]	EEG	DVM	2 durum (araç kullanımı ve matematik görevi)	84.6±5.8- 86.2±5.4
[16]	EEG	DVM	2 durum (aktif ya da aktif değil)	77.00-83.00
[2]	EEG	DVM	3 durum (uyku, uyku geçişi, dikkatli)	71.6-84.8
[3]	EEG	DVM	2 durum (aktif ya da aktif değil)	92.80
[19]	EEG Task engagement index	DVM	2 durum (aktif ya da aktif değil)	93.33 ± 8.16
[20]	Sadece EEG	DVM	3 durum (odaklanmış, dalgın, uykulu)	96.70 (iyi) 91.72 (ort.)

2.1. Çalışmanın Motivasyonu

Bu çalışmada, uykuda ya da pasif kalması gerekirken aynı zamanda sürekli olarak önemli bir konsantrasyon ve dikkat seviyesini korumak zorunda kalan bireylerde zihinsel durum değişikliklerini algılama problemini araştırılmıştır. Böyle bir senaryonun bir örneği otomatik süreçlerin veya sistemlerin denetlenmesi olabilir, başka bir örneği, robotik araçların veya insansız uçakların kontrol edilmesi veya robotların güvenlik izlenmesi olabilir. Yine bir başka örnek, uçak pilotlarının, uçağın otopilot kontrolünde iken uzun süreli izlenmesi olabilir. Tüm bu durumlarda, sorumlu kişilerden işlemlerin müdahalesiz denetimi istenirken, aynı zamanda ilgili kişilerin uyanık olmaları ve hızlı bir şekilde tepki vermeleri gerekmekte ve bunları yapabilmeleri beklenmektedir.

Bu çalışma ile EEG verilerinden dalgın ve odaklanmış dikkat ile kopuk ve uykulu gibi saf zihinsel durumları tespit etmenin mümkün olduğunu göstermeyi amaçladık ve böyle bir görevi çözmek için makine öğrenmeye dayalı bir sistem geliştirmeye çalıştık. Daha önceki çalışmalar, EEG sinyallerini desteklemek için ekstra veriler (örneğin; görev katılımı endeksi veya solunum

verileri) kullanmış veya yüksek doğruluk elde etmek için tespit edilen zihinsel durumların sayısını iki ile sınırlandırmıştır. Devamlı performans görevleri versiyonunda sadece EEG verilerini kullanarak %96.70 (en iyi) ve %91.72 (ortalama) doğrulukla deneysel olarak ilgili/ odaklanmış, dalgın ve uykulu zihinsel durumlarının farklılaşmasını saptamaya çalıştık. Deneklerin bu çalışmada kullanılan durum tespiti yaklaşımı genel olarak kabul edilir ve bu nedenle gelecekte hastanelerde hasta izleme durumları gibi farklı ortamların yanı sıra modern otomatik ve robotik sistemlerin emniyet mekanizmalarını geliştirmeye yardım etmek gibi farklı ortamların geliştirilmesi ile ilgili olarak kolayca genelleştirilebilir.

Her ne kadar makale, iyi yerleşmiş sinyal işleme ve veri analizi tekniklerinden faydalansa da, beynin faaliyetinin zihinsel durumlarını - dışsal olarak açık biçimde tezahür etmeyen "saf" zihinsel durumlar dahil olmak üzere - tanımlamak için bu tür tekniklerin uygulanması konusunun yeni olduğunun altını çiziyoruz. Pasif olarak dalgın durumun belirlenmesi, kontrol / pasif denetim süreçleriyle yüksek derecede ilgilidir ve bilindiği kadarıyla literatürdeki ilk çalışmadır. Benzer şekilde, pasif deneklerin dikkat durumlarının belirlenmesi de literatürdeki bu türden ilk çalışmadır - önceki çalışmalar o düzeneğin doğası gereği sürekli aktif olan araç sürücülerinin ve benzer operatörlerin durumlarını izlemeye odaklanmış çalışmalardır. Bu tür ortamlar kalıcı olarak pasif olan deneklerin uyusukluğunu veya ayrılmasını tanımlamaktan oldukça farklıdır. Bu problemi burada çözmek için kullanılan genel bir yaklaşım, yani deneklerin özdeşleşmiş zihinsel durumları ve makine öğrenimi için elde edilen EEG veri örneklerini kullanmak oldukça geneldir ve saf zihinsel durumlar da dahil olmak üzere diğer zihinsel durumların araştırılmasına uygulanabilir olması aynı zamanda literatürde yeni bir bakış açısıdır.

3. MATERYAL ve YÖNTEM

3.1. Deneyin Yapılışı

Bu çalışmada, düşük yoğunluklu kontrol görevi yapan beş katılımcıdan toplanan toplam 25 saatlik EEG kayıtlarını içeren orijinal bir veri kümesi kullanılmıştır. Görev, "Microsoft Tren Simülatörü" programını kullanarak bilgisayar simülasyonlu bir treni kontrol etmekten ibarettir. Her bir deney, yukarıda belirtilen bilgisayar simülasyon programında öncelikli olarak özelliiksiz bir rota boyunca 35 ila 55 dakika boyunca bir treni kontrol eden katılımcılardan oluşmaktadır.

Bu çalışmada incelenen üç zihinsel durum, odaklanmış ancak pasif dikkat, dalgın (odaklanmamış veya kopuk ancak uyanık durum) ve uyuklama halini içermektedir. İlk "odaklanmış" durumun, odak ve konsantrasyonu korurken treni pasif biçimde denetlemesine karşılık geldiği anlaşılmıştır. Bu durumda aktif katılım belirtilmemiştir. Aslında, görevin büyük

kısmı, katılımcılar tarafından seyahate aktif müdahale içermemekte, bununla birlikte, sürekli konsantrasyon ve odaklanma gerektirmektedir.

İkinci durum, katılımcıların açıkça uyuklamadığı, ancak ekrandaki gelişmelere dikkat etmekten ve uyanık olmaktan uzak, kopuk ama uyanık, dalgın denetim durumudur. Bu durumun fark edilmesi halinde tespit edilmesi ve uyarılması gereken tehlikeli bir durum olarak yorumlanabilir. Öte yandan, böyle bir durum herhangi bir dış takip ile açıkça gösterilemeyebilir, tespit edilmesi zor olabilir. Böyle bir durumu “saf” olarak adlandırabiliriz, çünkü net bir dış belirti olmaksızın zihinsel olarak gerçekleştirilir. Bu tür durumların ayrımcılığına yönelik metodoloji bu çalışmanın ana amaçları arasındadır.

Üçüncü durum, açıkça uyuklama durumudur. Giriş bölümünde açıklandığı gibi, uyuklama daha önce alfa-bant EEG aktivitesinin artması ile ilişkilidir ve EEG verileri ile tespiti literatürde hali hazırda tartışılmıştır. Aynı zamanda uyuklama, örneğin bir göz kapağını takip eden videoda veya kalp atış hızı izlemesi gibi EEG dışı araçlarla da algılanabilir.

Yukarıda belirtilen üç zihinsel durumun tespit edilmesi bağlamında katılımcılar, her bir deneyin başında aldıkları deney denetçisinin talimatlarını izleyerek, bu durumları simüle etmişlerdir. Katılımcılar, simüle edilmiş bir yolcu trenini 35-55 dakikalık bir süre için temelde özelliksiz bir rota üzerinden kontrol etmiştir. Spesifik olarak, her deneyin ilk 10 dakikasında, katılımcılar simülatörün kontrollerine yakından dikkat ederek ve ekrandaki gelişmeleri ayrıntılı olarak takip ederek simüle edilmiş trene odaklanmış ve trenin kontrolü ile ilgilenmiştir. Denemelerin ikinci 10 dakikasında, katılımcılar simülatörü izlemeyi bıraktı ve odaklanmamaya başladı. Katılımcılar bu süre zarfında herhangi bir kontrol girişi sağlamamış ve bilgisayar ekranındaki gelişmelere dikkat etmeyi bırakmışlardı; ancak, gözlerini kapatmalarına veya uyuklamalarına izin verilmedi. Son olarak, deneylerin üçüncü 10 dakikasında, katılımcıların serbestçe rahatlamalarına, gözlerini kapatmalarına ve istedikleri gibi uyuklamalarına izin verildi (Şekil 1).



Şekil 1. Bu çalışmada kullanılan sanal pasif kontrol görevine dayalı sürekli performans görevi organizasyonu.


Tren kontrol simülasyon deneylerinin özel ayarları, yukarıda belirtilen tren simülatör programında "Acela Express" modern lokomotifi ve "Amtrak-Philadelphia" rotasının 40 dakikalık bir bölümünü kullanmayı içermektedir. Simülasyonlar için seçilen rotanın segmenti düz ve özelliksizdi, böylece katılımcılar daha yüksek bir katılım seviyesinin gerekli olduğu rotanın ilk ve son beş dakikalık bölümleri haricinde simülasyonlar sırasında az sayıda kontrol girdisi sağlamak zorunda kaldı. Katılımcılara, tüm deneylerde simüle edilen trenin hızını sabit ve 40 mph'de tutmaları talimatı verilmiştir. Kontroller, (sürüş hızını kontrol eden) gaz kelebeği ayarından ve (hızlı bir yavaşlama sağlamak için) fren uygulamasından oluşuyordu. Kontroller standart bir bilgisayar klavyesindeki tuşlarla gerçekleştirildi.

Her katılımcı günde en fazla bir deney yaparak yedi deneye katılmıştır. İlk iki deney alışkanlık için kullanılmış ve son beş deney veri toplamak için kullanılmıştır. Tüm deneyler, katılımcıların deneme aşamasının üçüncü yani uykulu durumuna girmelerini kolaylaştırmak için akşam 19:00-23:00 saatleri arasında gerçekleştirilmiştir. Katılımcılar, deneyin denetçisi tarafından izlendi ve deneylerin yukarıda belirtilen yapıya uyduğundan ve hareket etme veya konuşma gibi önemli bir aksaklık yaşanmadığından emin olmak için bir videoya kaydedildi. Dalgın durumu kontrol edebilmek için C# tabanlı bir reaksiyon zamanlayıcısı geliştirildi. Sözü edilen program 120 saniye aralıkta rastgele zamanlarda katılımcılara "bip" sesi göndermekteydi. Katılımcılar her "bip" sesini duyduğunda klavyeden "L" tuşuna bastılar. sesin gönderildiği an ve katılımcının "L" tuşuna bastığı an zaman olarak bir metin dosyasında tutuldu. Kişiler dalgın oldukları esnada "bip" sesine ya hiç ya da geç cevap verebildiler. Bu program dalgınlığın ölçülmesinde dışsal bir ölçü olarak kullanıldı.

Deneylerin ham verileri Kaggle web sitesinde araştırmacılar için mevcut olmakla birlikte [21] gerçek veriden bir bölüm Tablo 2'de gösterilmiştir.

3.2. EEG Başlık Modifikasyonu

EEG verileri, değiştirilmiş bir Epoc EEG cihazı ve klasik ıslak elektrotları kullanılarak elde edilmiştir. Epoc cihazı, 128 Hz örnekleme hızında 12 kanal gerçek zamanlı EEG verisi, 0.51 μ V gerilim çözünürlüğü ve 0.2-43Hz arasında bir bant genişliği sağlayan ve kablosuz bir Bluetooth bağlantısı aracılığıyla veri toplama bilgisayarına bağlanan taşınabilir bir EEG toplama cihazıdır [22]. Emotiv EEG cihazının başlık kısmı, elektrotların kafa derisinin ön ve parietal loblarının üzerine yerleştirilmesine izin verecek şekilde değiştirilirken (Şekil 2), orijinal Epoc başlık yalnızca sert plastik örümcek ağı kapak formatı içindeki ön ve oksipital alanlar üzerinde elektrot kapsamına izin vermektedir. Bu nedenle, bu çalışmada kullanılan elektrotların konumları, standart 10-20 sisteminde F3-Fz-F4-C3-Cz-C4-T3-T4-T5-T6-Pz idi. EEG cihazında dört elektrot (burada T3, T4, T5 ve T6 konumlarıyla tanımlanır) akım sağlamak ve EEG referansını belirlemek için kullanılmış, veri toplamak için kullanılamamıştır. Yedi elektrottan elde edilen veriler F3, F4, Fz, C3, C4, Cz ve Pz ile tanımlanmıştır. Ham EEG verileri, Epoc yazılımının araştırma lisansında yer alan veri toplama API'si ile birlikte teslim edilen eeglogger.m örnek programa dayalı olarak geliştirilen, özel bir Matlab kodu kullanılarak Epoc cihazından elde edilmiştir. Islak elektrotların direnci, deneylerin başında ve sonunda kontrol edilmiştir. Elektrotların direnci deney sonunda istenen seviyede değilse, deney tekrarlanmıştır.



Şekil 2. Modifiye edilmiş EEG başlık

Tablo 2. Örnek veri

Cnt,	Intp.	Kanal F3	Kanal FZ	Kanal T3	Kanal F4	Kanal C3	Kanal CZ	Kanal C4	Kanal T4	Kanal PZ	X	Y
80	0	4020.51	4915.90	4036.92	4328.72	4285.13	4035.90	4250.77	4304.62	4102.56	1570	1719
81	0	4021.03	4913.85	4039.49	4329.23	4283.59	4035.90	4250.26	4304.62	4107.18	1569	1720
82	0	4016.41	4909.23	4038.97	4327.69	4277.95	4035.38	4250.26	4304.62	4106.67	1568	1721
83	0	4009.23	4907.69	4036.41	4325.64	4270.77	4028.21	4246.15	4304.62	4105.64	1569	1719
84	0	4003.08	4905.64	4036.41	4326.15	4264.10	4017.44	4245.13	4304.62	4107.18	1568	1722
85	0	3994.36	4902.56	4036.41	4323.59	4255.38	4010.26	4243.59	4304.62	4106.67	1569	1721
86	0	3988.21	4904.10	4034.87	4322.05	4248.72	4006.15	4236.41	4304.62	4106.15	1567	1721
87	0	3988.72	4903.08	4035.38	4324.62	4252.31	4003.08	4234.36	4304.62	4107.69	1568	1722
88	0	3991.28	4902.05	4034.36	4327.18	4258.46	4002.56	4238.46	4304.62	4106.15	1567	1721
89	0	3991.79	4903.08	4034.36	4326.67	4261.03	4000.00	4236.92	4304.62	4101.03	1566	1721
90	0	3991.28	4898.97	4034.36	4325.64	4260.00	3994.87	4232.31	4304.62	4097.44	1566	1720
91	0	3990.77	4893.33	4034.87	4325.64	4255.90	3991.79	4234.36	4304.62	4093.85	1565	1719
92	0	3988.72	4893.85	4035.38	4324.10	4254.87	3991.79	4233.85	4304.62	4090.26	1564	1717
93	0	3988.21	4895.38	4034.36	4322.05	4257.44	3992.31	4230.77	4304.62	4090.77	1563	1717
94	0	3994.36	4894.36	4034.36	4325.64	4261.03	3994.36	4234.87	4304.62	4092.82	1562	1715

Cnt=Örnek Sayacı.

Intp.=Verilerin enterpolasyonlu olup olmadığını belirtir.

X = Jiroskop X-ekseni.

Y = Jiroskop Y-ekseni.

3.3. Veri İşleme ve Öznitelik Çıkarımı

Deneklerin zihinsel dikkat durumlarını, zaman-frekans alanında temsil edilen EEG sinyallerine dayanarak tespit etmek için bir algoritma geliştirilmiştir. EEG sinyallerine dayanarak deneklerin zihinsel dikkat durumlarını tespit etmenin genel blok şeması, Şekil 3'te gösterilmiştir. Öznitelik çıkarımı aşamasında, kısa süreli Fourier dönüşümü (STFT) ve Blackman penceresini kullanarak her bir EEG kanalında ki EEG sinyallerinin spektrogramları hesaplandı [23,24]. Kısaca, STFT, küçük bir zaman aralığı boyunca (1)'de tanımlanan EEG sinyal frekans spektrumundaki gücün zamana bağlı (geçici lokalize) bir dağılımını kodlar,

$$X_{STFT}(t, \omega) = \sum_{t'=-\infty}^{\infty} x(t')w(t' - t)e^{-j\omega t'} \quad (1)$$

Burada, $x(t)$ zaman alanındaki tek bir EEG kanalındaki EEG sinyalleridir, $w(t)$ sadece küçük bir komşulukta sıfırdan farklı olan “pencereleme” işlevidir $t' = t$ ve EEG sinyallerinin lokalizasyonunu küçük bir t' civarında zaman aralığında $t' = t$ dayatır. Spektrogram, STFT genliklerinin karesi olarak tanımlanır $S(t, \omega) = |X_{STFT}(t, \omega)|^2$ ve EEG sinyallerinin frekans bileşimini, belirli bir zaman noktasının yakınında nicelleştirir.



Şekil 3. Zihinsel dikkat durumu algılayıcısının blok şeması.

Ham EEG verileri değiştirilmiş Epoc Emotiv başlıktan yedi kanalda $f_s = 128$ Hz örnekleme frekansında elde edilmiştir. STFT hesaplaması her kanal için ayrı olarak yapılmıştır. STFT $\Delta T = 15$ EEG sinyallerinin ikinci fragmanları ve $m = 1024$ hızlı ayrık Fourier dönüşümü (DFT) kullanılarak hesaplandı. EEG sinyalini her bir parçanın her iki ucunda gittikçe azaltmak için Blackman pencereleme fonksiyonu kullanılmıştır. Blackman pencereleme fonksiyonu (2) ile tanımlanmıştır.

$$w(\hat{t}) = \begin{cases} 0.42 - 0.5 \cos \frac{2\pi\hat{t}}{M-1} + 0.08 \cos \frac{4\pi\hat{t}}{M-1}, & 0 \leq \hat{t} < M \\ 0, & otherwise \end{cases} \quad (2)$$

M , penceredeki toplam zaman noktalarının sayısıdır ($M = F_s \cdot \Delta T = 1920$) ve $\hat{t} = 0, 1, \dots, M-1$, pencerenin içinde ayrık bir zaman dizinidir. STFT daha sonra her giriş EEG kanalı içinde bir saniye aralıklarla $X_{STFT}(t, \omega)$ zamana göre değişen bir DFT genliği üreten bir saniyelik bir zaman adımında hesaplanmıştır.

Her bir EEG kanalında STFT'nin hesaplanmasından sonra, EEG sinyalinin zamana bağlı güç spektrumunu (yani, spektrogram) oluşturmak için DFT genliklerinin mutlak kareleri $S(t, \omega)$ yukarıda anlatıldığı gibi her kanalda hesaplandı. DFT'de kullanılan $m = 1024$ puan olması nedeniyle, elde edilen spektrum, EEG sinyalindeki güç dağılımını karakterize etti. $m/2 + 1 = 513$ frekans $\omega_k = kF_s/m = 0.125k$ Hz, k 0 ila $m/2 = 512$ arasında değişmiştir. Bunlar daha sonra ortalama kullanılarak 0.5 Hz frekans bantları olarak kutulandı (frequency bin), böylece 0 ila 64 Hz arasındaki her 0.5 Hz frekans kutusundaki ortalama spektral güç ölçülmüştür. Frekans aralığı daha sonra 0-18 Hz ile sınırlandırılmıştır, böylece yalnızca 36 frekans, $\Omega_k = k \cdot 0.5$ Hz, $k = 1, \dots, 16$, veri kümesinde tutulmuştur. Sabit bileşen $\Omega = 0$ Hz olarak verilmiştir. Son olarak,

kutulanmış ve frekans sınırlı spektrogramlar $S(t, \Omega)$ 15 saniyelik çalışan bir ortalama kullanılarak geçici olarak yumuşatılmıştır.

Her kanal için üretilen yukarıdaki hesaplama, her kanal için $S(t, \Omega)$ EEG sinyalinin $\Omega_k = k \cdot 0.5$ Hz, frekanslarında $k= 1, \dots, 36$, bir saniye aralıklarla zamana bağlı güç spektrumlarını yumuşatmış, son özellik vektörü daha sonra her zaman noktasında güç değerlerini t desibel formuna dönüştürerek ve tüm yedi giriş EEG kanalından spektrumları tek bir ortak özellik vektöründe (3) birleştirilerek oluşturulmuştur;

$$\bar{f}(t) = (10 \log_{10} S_c(t, \Omega), c = 1, \dots, 7, \Omega = k \cdot 0.5 \text{ Hz}, k = 1, \dots, 36), \quad (3)$$

Burada c , EEG giriş kanallarını belirtmektedir.

Öznelik çıkarma işleminin önemli bir parametresi, STFT'nin pencereleme işlevinin geçici süresi $w(t)$ ve zamansal yumuşatma genişliğidir. Daha büyük bir pencere ve daha geniş bir zamansal düzleştirici, elde edilen güç spektrumunda daha yüksek seviyede bir pürüzsüzlük sağlar, böylece zamansal çözünürlükten ödün verir ve akış aşağısındaki olası herhangi bir detektörün tepkisini keserken daha iyi bir gürültü bastırması sunar. Daha küçük bir pencere ve daha kısa düzleştirici, STFT genliklerinde daha fazla gürültü pahasına daha yüksek bir zamansal hassasiyet ve yanıt verir.

Hem Blackman penceresi hem de geçici koşu filtresi için 1, 5, 15, 30 ve 60 saniyelik aralıkları dikkate alarak, bu parametrelerin farklı seçimleri denenmiş ve 1 ve 5 saniye aralıklarının EEG değişikliklerine hızlı bir tepki verdiği görülmüştür. 30 ve 60 saniyelik aralıklar, daha yüksek derecede bir gürültü bastırma sağlamış ancak aynı zamanda EEG sinyallerinde herhangi bir değişiklik spektrumda görünmeden veya detektörü etkilemeden önce 30 ila 60 saniyelik bir gecikmeye neden olmuştur. Pencere boyutu ve ortalama çalışma için 15 saniyelik aralık seçiminin yukarıdaki iki etki arasında iyi bir uzlaşma sağladığını ve bu nedenle bu çalışmada benimsenebileceğini gözlemledik. Öznelik çıkarma adımının akış şeması Şekil 4'te gösterilmiştir.



Şekil 4. Öznitelik çıkarma adımının blok şeması.

3.4. Zihinsel Durum Tespiti

En Küçük Kareler DVM makine öğrenme yaklaşımı kullanılarak zihinsel durum detektörü geliştirildi [25]. Bir DVM detektörü geliştirmek için, öncelikle zamanla değişen EEG sinyalinin spektrumları bir özellik vektörüne yeniden düzenlenmiştir. Bunun için tüm giriş EEG kanallarından her zaman noktası için hesaplanan güç spektrumları birleştirilmiş, böylece EEG sinyalinin gücünün tüm EEG kanalları üzerindeki dağılımı ve 0.5 Hz adımda 0 ila 18 Hz arasındaki frekansları karakterize eden 252 boyutunda bir vektör üretilerek yapılmıştır. Bundan sonra, her bir zihinsel durumu ayrı ayrı tespit etmek için bir DVM sınıflandırıcısı eğitilmiştir. Eğitim verileri, EEG spektral verilerinden rastgele zaman noktalarında seçilen belirli sayıda özellik vektöründen oluşmaktadır. DVM iki durumlu bir sınıflandırıcısı olduğundan, ikiden fazla zihinsel durumun ayırt edilmesi için birden fazla DVM sınıflandırıcısının birleştirilmesi gerekir. Spesifik olarak, ilk DVM sınıflandırıcısı, EEG verilerinde “odaklanmış” durumun diğerlerine karşı oluşumunu tespit etmek için; “Dalgın” durumun diğerlerine karşı oluşumunu tespit etmek içinse ikinci bir DVM sınıflandırıcısı eğitilmiştir.


3.5. Sınıflandırıcılar

Çalışmada öne sürülen makine öğrenmesine dayalı DVM sınıflandırıcısının, bu görevde kullanılma nedeni diğer sınıflandırma metodlarından daha yüksek başarı elde etmesidir. Çalışmada tercih edilen DVM, k en yakın komşu (kNN) ve Adaptive Neuro-Fuzzy System (ANFIS) metodları ile karşılaştırılmıştır.

3.5.1 Destek Vektör Makineleri (DVM)

Sınıflandırma görevlerinde kullanılan bilinen bir yöntemdir. Bir düzlemde bulunan iki grup arasında çizilen bir sınır ile sınıflandırma işlemi gerçekleştirilebilir. Bu sınırın çizileceği yer iki grubun üyelerine en uzak noktadır. DVM bu sınırın nasıl çizileceğini belirler [25].

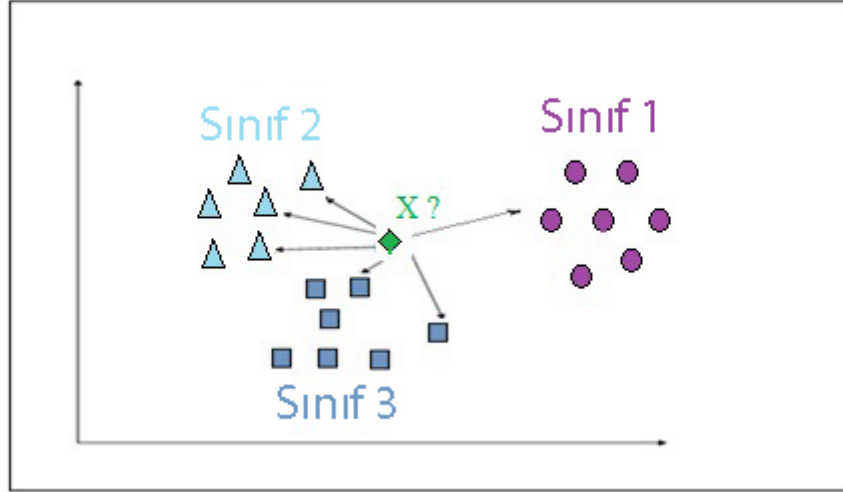
Sınırın çizilebilmesi için iki gruba en yakın olacak şekilde iki paralel çizgi çizilir. Bu çizgiler birbirlerine yaklaştırılarak ortak sınır çizgisi belirlenir. Şekil 5'te DVM çalışma prensibi gösterilmiştir.



Şekil 5. DVM çalışma prensibi.

3.5.2 K En Yakın Komşu (kNN)


K En Yakın Komşu algoritması, düzleme yeni eklenen sınıflandırılmamış veriyi, düzlemde yer alan ve sınıflandırılmış verilere yakınlığına göre daha önceden belirlenmiş sınıflardan birine atayarak çalışır [26,27,28]. Bu işlem Şekil 6'da gösterilmiştir. Her veri için uzaklık hesaplama işlemleri tekrar ettiği için büyük verilerde kullanılması uygun olmamaktadır.



Şekil 6. kNN çalışma prensibi.

3.5.3 Adaptive Neuro-Fuzzy System (ANFIS)

ANFIS bir tür yapay sinir ağıdır. Hem sinir ağlarını hem de bulanık mantık ilkelerini bütünleştirir ve ikisinin de faydalarından yararlanabilir [29,30,31]. Bu durum ANFIS için hibrit bir algoritma olduğunun göstergesidir. Sonuç çıkarma sistemi, doğrusal olmayan fonksiyonları yaklaşık olarak öğrenme yeteneğine sahip olan bir dizi bulanık IF-THEN kuralına karşılık gelir. ANFIS'i daha verimli kullanabilmek için genetik algoritmalarından elde edilen en iyi parametreler kullanılabilir. Şekil 7'de ANFIS algoritmasının çalışma prensibi gösterilmiştir.



Şekil 7. ANFIS çalışma prensibi.

Yukarıdaki modelde 1. Katmanda yer alan A_i ve B_i sözel değerleri ifade etmektedir. A_i ve B_i bir üyelik fonksiyonu ile üyelik derecesini alarak katmandan çıkarlar. 2. Katmana gelindiğinde girdiler çarpılarak bir düğümden çıkarlar. 3. Katmanda, ateşleme gücü değerleri toplam ateşleme gücüne oranlanarak bir normalizasyon işlemi gerçekleştirilir. 4. Katmandan sonra TakagiSugeno-Kang modeli çalıştırılır. 5. ve son katmana gelindiğinde toplam çıktı değeri elde edilir.

3.6. DVM Sınıflandırıcılarının Tasarımı

DVM sınıflandırıcıları, *SVMtrain* Matlab İstatistik Araç Kutusu'nun işlevi kullanılarak eğitilmiştir. Ayar parametreleri, varsayılan değerleri olarak kullanılmıştır. Varsayılan metot parametresi "en küçük kareler" (LS) ile değiştirilmiştir. Kullanılan değerler tablo 3'te gösterilmiştir. *Otomatik ölçeklendirme* parametresi (eğitim verilerinin ortalamasını ve varyansını sırasıyla sıfıra ve bire düşürerek) etkinleştirildi ve *kutu kısıtlaması* (DVM'deki yanlış sınıflandırmaların maliyeti) 1 olarak ayarlandı. Doğrusal çekirdek işlevi ve "en küçük kareler" yöntemi, bu çalışmada yer alan eğitim verilerinin büyüklüğünden kaynaklanan DVM optimizasyon problemini çözmek için kullanıldı.

DVM, geçici olarak yerel EEG sinyalini, W ağırlıklı bir vektörle karakterize eden bir özellik vektörünün doğrusal bir kıvrımının sonucuna dayanmaktadır. $y = \sum_i W_i f_i$, spektral güç özelliklerini f_i temsil eder ve i bu özellikleri ve buna karşılık gelen ağırlıkları sıralayan dizini temsil eder W_i . Her bir zaman noktasının özellik vektörü, ya +1 (mevcut) olarak $y \geq b$ belirli bir eşğin üstünde ise b veya -1 olarak (yoksa) sınıflandırıldığında, bireysel ağırlıkların işareti ve büyüklüğü W_i detektörün karar sürecine her özelliğin katkısı ve önemi hakkında bilgi verir. Özellik vektörünün inşası ile $\bar{f}(t)$, ağırlıklar W_i belirli zihinsel durumların ayrımcılığına katkıda bulunan frekansları ve elektrotları, her ikisi de $W_i > 0$ olduğunda pozitif anlamda ve $W_i < 0$ olduğunda negatif anlamda olduğunu gösterir.

Ağırlık vektörlerinin tipik bir örneğini gösteren bir çizim W , katılımcı S1 için F3, F4 ve Fz'nin en belirgin üç EEG kanalı üzerinden Şekil 5'te verilmiştir. Buradan görülebileceği gibi, DVM ağırlık vektörlerinin incelenmesi, 1-5 Hz frekans aralığında yüksek EEG gücünün, detektör tarafından "odaklanmış" durumun varlığının pozitif bir kanıtı olarak değerlendirilirken, 10-15 Hz frekans aralığı "uyuklama" durumunun bir göstergesi olarak alındığını belirtir. Bu gözlemler, Bölüm 3'teki sonuçların yanı sıra literatürdeki uyuklama ve uyanık zihinsel durumların EEG işaretine ilişkin bulgular ile de uyumludur. "Dalgın" veya ilgisiz zihinsel durumun göstergesi, EEG gücündeki hem 1-5 Hz hem de 10-15 Hz frekansındaki azalmadır (Şekil 5B). Bu, ilgisiz zihinsel durumdaki EEG spektrumunun öğrenilmesine tekabül eder.

Sonuç olarak, EEG verilerindeki “odaklanmış”, “dalgın” ve “uyuklama” durumlarını sınıflandırmak için 3 DVM sınıflandırıcısı geliştirilmiştir. Sınıflandırıcıların çıktıları, son tespitleri üretmek için bir XOR toplaması kullanılarak birleştirilmiştir. Herhangi bir sınıflandırıcı, diğer sınıflandırıcılar “-1” ile (yok) cevap verdiğinde, belirli bir zaman noktasında “+1” ile (mevcut) yanıt verdiyse, böyle bir zaman noktası yanıt veren sınıflandırıcının etiketine göre kategorilere ayrılır. İki veya daha fazla sınıflandırıcı “+1” ile yanıt verirse veya tüm sınıflandırıcılar “-1” ile yanıt verdiyse, böyle bir zaman noktası “sınıflandırılmamış” olarak kategorize edilir ve bir hata haline gelir

Tablo 3. Kullanılan SVMtrain parametreleri

Parametre	Varsayılan	Kullanılan
"autoscale"	true	true
"boxconstraint"	1	1
"kernelcachelimit"	5000	5000
"kernel_function"	linear	linear
"kktviolationlevel"	0	0
"method"	SMO	LS
"mlp_params"	[1 -1]	[1 -1]

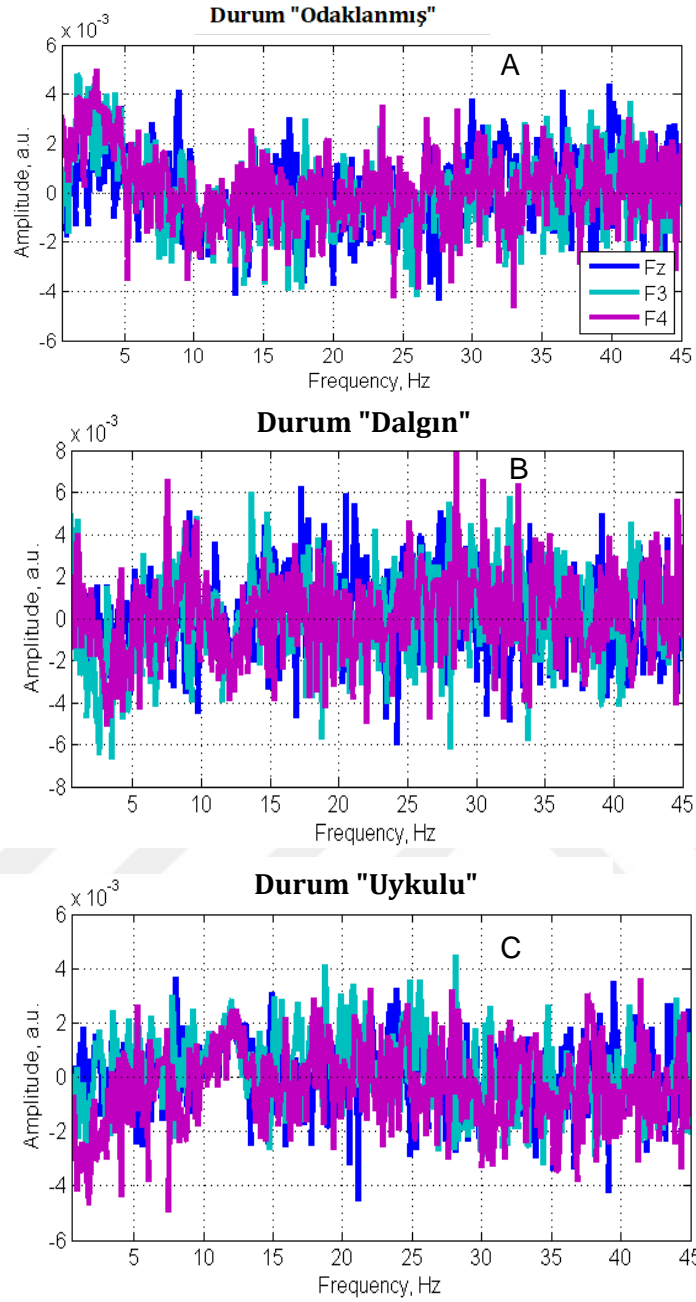
3.6. Performans Değerlendirmesi

DVM tabanlı zihinsel durum detektörünün performansı, rastgele uzatma çapraz doğrulama kullanılarak değerlendirilir. Çapraz doğrulama, makine öğreniminde sınıflandırma ve regresyon modellerinin doğruluğunu değerlendirmek için standart bir yaklaşımdır. Çapraz doğrulamada, mevcut verilerin bir alt kümesi eğitimden çıkarılır, böylece makine öğrenim modeli bu verileri göremez veya gizli veri kümesinde yer alan bilgilerin bilgisine sahip olamaz. Eğitim bittikten sonra, hangi makine öğrenme algoritmasını kullanırsanız kullanın, nihai modelin performansının tarafsız bir tahmini onu geri çekilen onay veri kümesine uygulayarak ve oradaki modelin doğruluğunu değerlendirerek elde edilir. Rastgele yayılma çapraz doğrulamada, eğitimden önce rastgele seçilen veri noktalarının belirli bir yüzdesi seçilir ve geri çekilir. Ardından son detektörün doğruluğunun değerlendirilmesinde kullanılır.

Burada, iki değerlendirme modeli (kişiyek(katılımcıya) özel ve katılımcıların ortak verileri) değerlendirildi: Kişiyek özel modelde, zihinsel durum detektörü, yalnızca o katılımcı için toplanan verilere dayanarak her katılımcı için ayrı ayrı eğitildi. O bireyin tüm deneylerinden elde edilen EEG verilerinin rastgele zaman noktalarının %80'i, DVM durum sınıflandırıcılarının

eđitimi için kullanılmıřtır. Üretilen bireysel detektörün dođruluđu daha sonra eđitimde kullanılmayan tüm denemelerin verilerinin kalan %20'sinde deđerlendirilmiřtir. Burada, her katılımcının eđitim verileri genellikle aynı deneđin farklı denemelerinden rastgele toplanan 6000 veri noktasından oluřmaktadır. Sırasıyla, son detektörün performansının deđerlendirilmesinde 1500 veri noktası kullanılmıřtır. Bu yaklařımda, her katılımcı için farklı bir zihinsel durum detektörü eđitilmiřtir.

Katılımcıların ortak verileri modelinde, tüm katılımcılar için ortak olarak tek bir detektör eđitilmiřtir. Tüm katılımcıların ortak EEG kayıtlarından elde edilen verilerin %80'i eđitim için rastgele seçildi. "Karıřık" veya "jenerik" detektörün performansı daha sonra, eđitimde görülmeyen, her bir katılımcının ayrı ayrı verisinin yanı sıra, karıřık verilerin veri kümesine karřı deđerlendirilmiřtir. Buradaki çapraz dođrulama hem tüm katılımcılar için ortaklařa hem de her bir katılımcı için bireysel olarak, hem genel olarak hem de katılımcı bazında genel zihinsel durum detektörünün kusursuzluđunu elde etmek için yapılmıřtır.

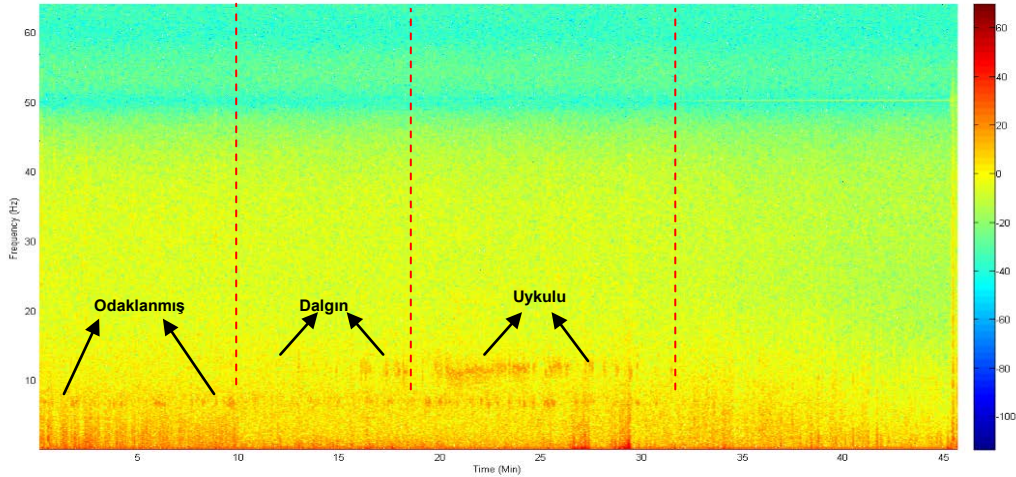


Şekil 8. Odaklanmış (A), dalgın (B) ve uyuklama (C) zihinsel durumları için DVM ağırlık vektörlerine bir örnek.

4. BULGULAR ve TARTIŞMA

Bu çalışmadaki tüm deneyler, öğrenciler arasından seçilen sağlıklı gönüllü katılımcılarla yapılmıştır. Tüm katılımcılar, deneylerin amaç ve prosedürleriyle ilgili talimatları aldıktan sonra bilgilendirilmiş onay formunu imzaladılar.

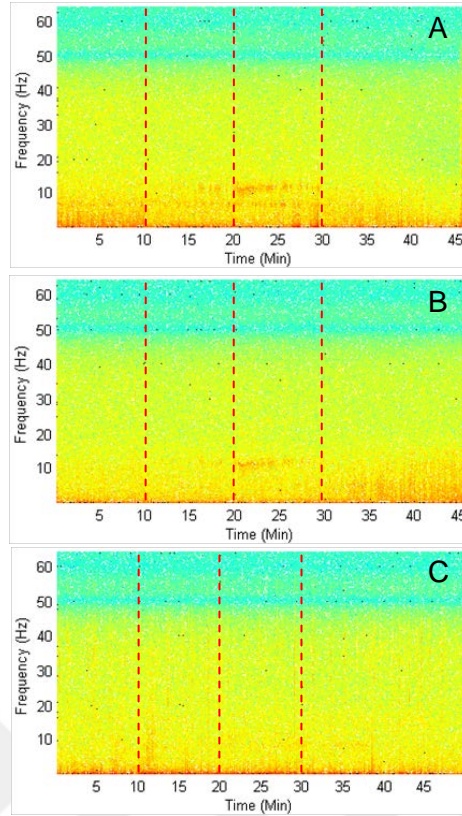
Şekil 6, DVM tabanlı sınıflandırıcı eğitim bölümünden önceki örnek bir EEG verisini göstermektedir. EEG sinyallerinde farklı dikkat durumlarıyla ilişkili farklılıklar spektrogramlarda görülebilir. Kırmızı kesikli çizgiler 0-10 dakika (odaklanmış), 10-20 dakika (dalgın) ve 20-35 dakika (uykulu) zaman aralıklarına karşılık gelen farklı dikkat durumu dönemlerini gösterir.



Şekil 9. DVM tabanlı sınıflandırıcı eğitim bölümünden önceki örnek bir EEG verisi

Toplanan verilerin ön incelemesi, bireylerin dikkat durumlarındaki değişikliklerin, bazı EEG kanallarında belirli frekanslarda değişiklik olarak görünen EEG spektral güç dağılımındaki değişikliklerle ilgili olabileceğini ortaya koymuştur. EEG sinyallerinin elektrotların konumuna göre değişen bileşimi Şekil 7'de görülebilir. Şekilde (A) ve (B) bölümleri, katılımcı S1 için EEG elektrotları Fz (A) ve Pz (B) 'den sürekli performans görevi sırasında toplanan örnek EEG spektrogramlarını göstermektedir. Bölüm (C), Fz elektrotundan katılımcı S2 için toplanan EEG spektrogramını gösterir.

Daha spesifik olarak, odaklanmış ve dalgın dikkat durumlarının, frontal EEG kanalları F3, F4 ve Fz'de 1-10Hz frekans bantlarında arttırılmış veya bastırılmış EEG aktivitesi ile ilişkili olduğu görülmüştür. Uyuklama hali, 10-15 Hz'de EEG sinyallerinde ve EEG kanalları C3, C4, Cz ve Pz'de alfa-bant frekansında sürekli veya aralıklı güç çıkışı olarak gözlenebilir. Bu incelemeyle katılımcıların odaklanmış, dalgın ve uyuklama halleri, çeşitli EEG kanallarındaki sinyalin yerel spektrumuna dayanarak EEG verisinde ayırt edilebilir.



Şekil 10. EEG elektrotlarından gelen EEG sinyal spektrogramlarının örnekleri: katılımcı S1 için Fz (A), Pz (B) ve katılımcı S2 için Fz (C).

Daha sonra, Bölüm 2.5'te açıklandığı gibi, yukarıdaki zihinsel durumların EEG verilerinden tespit edilmesi için DVM tabanlı bir algoritma oluşturulmuştur. Bu tür bir detektördeki spektral güç özelliklerinin incelenmesi yukarıdaki ön gözlemleri desteklemiştir. Özellikle, Tablo 3, zihinsel durum algılayıcısının özelliklerinden bazılarını ve hedef detektör durumlarının bu özelliklerine sahip olan Sınıf İçi Korelasyon Katsayısına (ICC) göre düzenlenen istatistiksel özelliklerini listeler. ICC, sürekli bir tahmin değişkeninin ayrık sonuç değişkeniyle ilişkisinin, basit Pearson korelasyonu ile ilgili ve (4) ile tanımlandığı şekilde istatistiksel bir ölçüttür.

$$ICC = \frac{\text{Grup ortalamasının varyansı}}{\text{Tam varyans}}$$

(4)

Tablo 3, farklı zihinsel dikkat durumlarıyla ilişkili EEG sinyallerinde iki tip farklılığı göstermektedir. 8-13 Hz frekanslarında alfa bandı gücünde, özellikle parietal lob üzerinde (elektrotlar C3, C4, Cz ve Pz) bir artış ve bir alt delta ve teta bandındaki frekanslarda 1-4 Hz, özellikle ön lob üzerinde (elektrotlar F3, F4 ve Fz) bir düşüş göstermektedir.

DVM tabanlı zihinsel durum sınıflandırıcısının performansı (5) tarafından verilen doğruluk ölçüsü oranı bakımından değerlendirilmektedir.

$$\text{Doğruluk} = \frac{\text{Doğru tahminlerin sayısı}}{\text{Tüm tahminlerin sayısı}} \quad (5)$$

Tablo 4 ve Tablo 5, sırasıyla kişiye özgü ve katılımcıların ortak veri modeli için DVM tabanlı zihinsel durum sınıflandırıcısının doğruluğunu göstermektedir. Tablolardan görülebileceği gibi, kişiye özgü modelde tüm katılımcıların zihinsel dikkat durumlarını, %88.60 ile %96.70 arasında değişen bir ortalama doğrulukla ayırt etme durumu başarılıdır. Katılımcıların ortak veri modeli için zihinsel durumların tespiti ise %71.80 ile %78.80 arasında yapılabilmektedir.

DVM bazlı sınıflandırıcıdan elde edilen sonuçların verimliliğini göstermek için, zihinsel dikkat durumları literatürde iyi bilinen diğer iki sınıflandırıcı kullanılarak da sınıflandırıldı ve DVM bazlı sınıflandırıcının en iyi sonuçları ile karşılaştırıldı. DVM'ye ek olarak, kNN, son zamanlarda EEG sınıflandırması için kullanılan yaygın bir yöntemdir [26,27,28]. Tablo 6'da verilen sonuçlara göre, kNN bazlı sınıflandırıcı, tüm metodların en kötü sonucu olan %73.35 ile %83.46 arasında değişen bir ortalama doğruluk vermiştir. kNN ve DVM kadar yaygın olmasa da, Adaptive Neuro-Fuzzy System (ANFIS), EEG sınıflandırma problemlerinde kullanılan bir yöntemdir [29,30,31]. Çalışmamızdaki ANFIS tabanlı sınıflandırıcı, kNN tabanlı ve DVM tabanlı yöntemler arasında bir performans (%78.33 ile %85.41) vermiştir. Sonuçların gösterdiği gibi, DVM tabanlı yöntem zihinsel durum tespiti konusunda en iyi performansı elde etmiştir.

Katılımcıların ortak verileri ile yapılan zihinsel durum detektörünün, kişiye özel bir algılama yaklaşımından açıkça daha faydalı olduğu unutulmamalıdır. Bununla birlikte, ampirik olarak katılımcıların ortak verileri ile yapılan detektörünün, EEG verilerindeki zihinsel dikkat durumlarını çok iyi şekilde sınıflandıramadığını gözlemledik. Buna göre, kişiye özel EEG kod çözümleri için gereklilik, EEG BBA literatüründe de çok daha fazla belirtilmiştir.

Son olarak, her EEG kanalının farklı zihinsel dikkat durumlarını ayırt etmedeki katkısı değerlendirilmiştir. Bu görev için, farklı EEG kanallarının katılımcıların zihinsel durumlarının tespitine katkısını ve önemini belirleyen geriye doğru basamak eleme prosedürü kullanılmıştır. Spesifik olarak, tüm EEG elektrotlarına sahip zihinsel durum detektörü eğitilmiş ve bir elektrot veri kümesinden çıkarılarak, tüm katılımcılar için detektörün ortalama doğruluğunun düşmesi ölçülmüştür. Daha sonra, doğruluktaki en küçük düşüşe sahip olan elektrot veri kümesinden kalıcı olarak çıkarılmıştır. Prosedür daha sonra sadece bir elektrot kalana kadar tekrar edilmiştir. Bu prosedürün sonuçları (örn. eğitim / test hataları ve ortalama doğruluk sonuçları ile EEG elektrotlarının sayısı) Şekil 8'de gösterilmiştir. Şekildeki elektrotların sırası soldan sağa F3-Fz-Cz-F4-Pz-C4-C3'tür, böylece EEG elektrotlarının saflarını azalan bir önem sırasına göre

tanımlar. Şekil 8'de, eğitim ve test hataları MATLAB'in "loss" fonksiyonu kullanılarak hesaplanmıştır.

Tablo 4. Hedef zihinsel durum değişkenine sahip ICC (Sınıf İçi Korelasyon)'ye dayanan en önemli 25 özelliğin istatistiksel özellikleri.

No	Kanal	Frekans (Hz)	Ort.	STD	Ort. Aktif	Ort. Dalgın	Ort. Uykulu	ICC
1	C3	12	7.3701	6.6015	3.0069	2.8568	15.258	0.77489
2	F3	12	7.3351	7.1219	2.6434	2.4826	15.817	0.76973
3	C4	12	7.0274	6.9183	2.5108	2.2899	15.251	0.76694
4	Cz	12	7.1504	6.9895	2.5024	2.4753	15.436	0.76248
5	F4	12	7.7564	6.9367	3.2259	3.0626	15.954	0.75787
6	C3	11.5	7.2411	6.4331	2.6736	3.2756	14.824	0.75544
7	C4	11.5	6.8756	6.5842	2.2998	2.7417	14.616	0.75063
8	F3	11.5	7.1857	6.7928	2.3314	3.0661	15.161	0.74986
9	Pz	12	5.6787	5.9377	2.0338	1.5049	12.627	0.74438
10	Fz	12	6.24	7.2337	1.4592	1.4907	14.709	0.7438
11	F4	11.5	7.5599	6.7017	2.8145	3.5413	15.348	0.73483
12	Cz	11.5	7.0045	6.7105	2.3403	2.8885	14.807	0.73479
13	Fz	11.5	6.1487	7.0016	1.181	2.1192	14.144	0.71065
14	Pz	11.5	5.866	6.0477	1.9401	2.0206	12.772	0.70766
15	C4	12.5	5.9152	6.233	1.9	1.9717	12.988	0.6987
16	F3	12.5	6.3208	6.3337	2.2655	2.2949	13.502	0.69763
17	C3	12.5	6.2436	5.8986	2.4349	2.5351	12.924	0.69603
...
43	F4	3	10.72	3.4544	14.252	9.0921	9.0286	0.50204
44	F4	3.5	9.5554	3.2217	12.813	8.2334	7.8354	0.49144
45	F4	2.5	11.889	3.4799	15.402	10.138	10.323	0.49129
46	F4	4	8.86	3.049	11.921	7.5095	7.3397	0.48387
47	F4	4	8.1726	2.8992	11.054	6.8883	6.7534	0.47408
48	F4	2.5	11.351	3.2627	14.548	9.691	9.9839	0.46457
...

Tablo 5. DVM ile tek bir katılımcıya özgü modeli için dikkat durumunun doğruluk sonuçları (yedi elektrot kullanılarak)

Katılımcı	Deney1	Deney2	Deney3	Deney4	Deney5	Ortalama Deneyler
S1	%98	%99	%93	%95	%97	%96.70
S2	%90	%87	%91	%90	%88	%89.70
S3	%88	%88	%88	%86	%91	%88.60
S4	%91	%95	%92	%96	%92	%93.50
S5	%90	%81	%93	%91	%93	%90.10

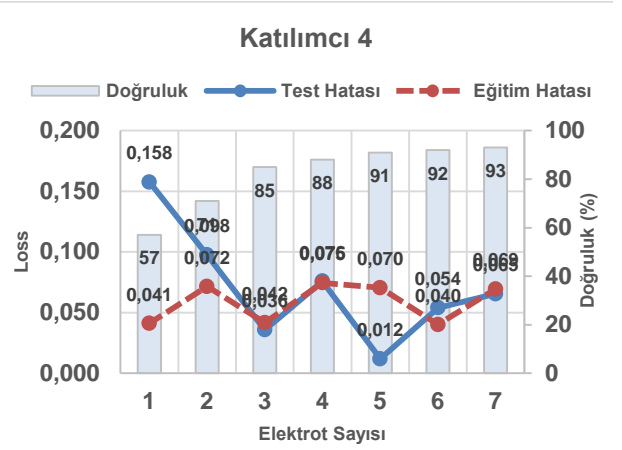


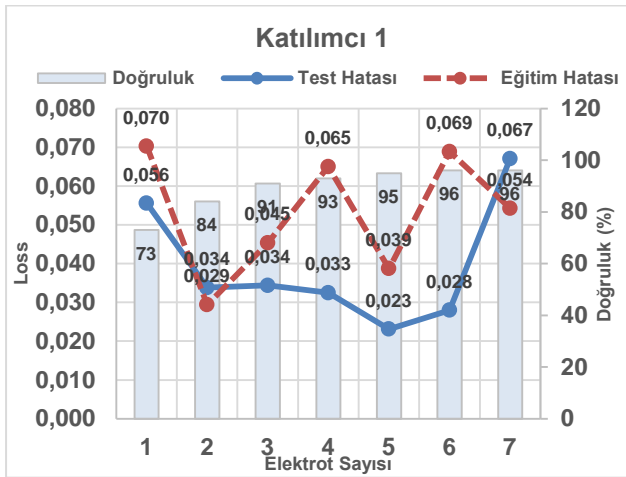
Tablo 6. DVM ile tüm katılımcılar için ortak veri modeli için dikkat durumunun doğruluk sonuçları (yedi elektrot kullanılarak)


Katılımcı	Deney1	Deney2	Deney3	Deney4	Deney5	Ortalama Deneyler
S1	%75	%70	%71	%75	%68	%71.80
S2	%81	%72	%72	%74	%76	%75.00

S3	%82	%68	%76	%77	%72	%75.00
S4	%79	%80	%78	%79	%78	%78.80
S5	%76	%69	%74	%72	%73	%72.20

Tablo 7. Tek katılımcıya özel model için Makine Öğrenimi yöntemlerinin ortalama beş kat çapraz doğrulama sonuçlarının karşılaştırılması.

Method	S1	S2	S3	S4	S5	5 Katılımcının Ortalaması
kNN	%82.46	%76.15	%73.35	%79.88	%76.98	%77.76
ANFIS	%85.41	%81.51	%79.84	%82.67	%78.33	%81.55
DVM	%96.70	%89.70	%88.60	%93.50	%90.10	%91.72





Şekil 11. Eğitim / test hataları ve ortalama doğruluk sonuçları, katılımcıya özel model için EEG veri setinde kullanılan EEG elektrotlarının sayısı ile karşılaştırılır.

Bu çalışmada, EEG verileri kullanılarak katılımcılarda zihinsel durumları tespit etme sorunu araştırılmıştır. EEG verilerini kullanarak dikkat durumlarından uyuklama problemi sorununu ayrı tutmak, geçmişte otomobil sürüşü bağlamında incelenmiştir. Diğer çalışmalardan farklı olarak, bu çalışma pasif gözlem veya denetim görevlerinde bulunanların zihinsel durumlarının ayrımı gerçekleştirmiştir. Görevde aktif katılımın olmaması, bu ortamda önemli farklılıklar getirmiştir. Ayrıca, odaklanmış, uyuklayan ve dalgın olmak üzere 3 farklı zihinsel durum incelenmiştir. Dalgın durum deneklerin açıkça uyumadığı, ancak odaklanma kaybı nedeniyle olaylara cevap verme yeteneğini yitirdiği durumdur ve bu çalışmada ayırt edilebilmiştir. Dalgın durum literatürde çalışılmamıştır, ancak süreç kontrolü için önemli bir risk taşımaktadır ve tespit edilmesi önemli ölçüde daha zordur, çünkü böyle bir “kopuk” zihinsel durum ikincil görsel olarak herhangi başka türlü gözlemlenebilir ipuçları ya da göstergeler yoluyla açık biçimde gösterilemeyebilir. Bu anlamda, ikinci ayırt edici duruma “saf” zihinsel bir durum diyoruz. Bu “saf” zihinsel durumu ayırt etmeye yönelik makalede geliştirilen metodoloji, farklı durum gruplarının ayrımcılığının yanı sıra, farklı durum ve görevlerde denek durumlarını ayırt etmek için daha genel olarak uygulanabilir.

Geçmişte benzer pek çok çalışma, araç sürücülerinin uyuklamasına ve diğer yandan zihinsel iş yükü görevlerinde bulunan bireylerde stresin değerlendirilmesine odaklanmıştır. EEG izlemenin yanı sıra video ve hareket izlemesi gibi başka yöntemler de kullanılmıştır. Önceki çalışmalarında başarılı olmasına rağmen, bu tür yöntemlerin çoğu farklı durumlarda hazır dönüşüme izin vermemektedir. Bireylerin boşta veya pasif kaldığı durumlar, video ve hareket tabanlı uyanıklık izlemesi için özel bir zorluktur. EEG tabanlı pasif BBA, deneklerin zihinsel koşullarını izlemek için kolayca aktarılabilir bir metodoloji sağlayarak bu sorunu çözmek için doğal bir yaklaşım sunar. EEG sinyalleri doğrudan beynin sinirsel aktivitesine bağlanır ve fiziksel, görsel veya fizyolojik ipuçlarına dayalı olanlar gibi diğer durum izleme sistemlerinin

tuzaklarından kaçınarak, farklı zihinsel durumların sinirsel belirtilerini doğrudan izleme fırsatı sunar.

Bu çalışmada, zihinsel durum detektörlerinin denekler için ayrı ayrı eğitilmelerinin önemli olduğunu saptadık. “Genel” bir zihinsel durum detektörünün, katılımcıya özel detektörlerden önemli ölçüde daha kötü performans gösterdiği tespit edildi, yukarıda belirtilen üç zihinsel duruma göre tespit doğruluğunu %20-30 kaybettiği gözlemlendi.

EEG sinyallerinde hangi özelliklerin yukarıdaki zihinsel durumların tanımlanmasına katkıda bulunduğu incelendi. Odaklanmış ve dalgın durumlar arasındaki farkların, en düşük 1 ila 10 Hz arasındaki düşük frekanslı EEG aktivitesinde açıkça ortaya çıktığı gözlemlendi. Yani, odaklanmış veya ilgili durum 1-10 Hz bandında yüksek EEG gücü ile ilişkiliydi. İlgisiz veya dalgın durum, bu frekans bandı üzerindeki ve diğer frekans bantlarındaki EEG spektrumunun boşaltılması ile ilişkilendirildi. Bu değişiklikler en belirgin şekilde ön lob üzerinde ortaya çıktı. Delta bandı EEG aktivitesi ile bireylerin konsantrasyonu arasındaki ilişki geçmişte EEG literatüründe bildirilmiştir. Bununla birlikte, EEG literatürünün zihinsel iş yükü görevleriyle ilişkilendirdiği beta veya teta gibi yüksek frekanslı EEG aktivitesinde önemli değişiklik belirtileri görülmemesi ilginç bulundu. Uyuklama durumu, 10-15Hz'de aralıklı veya sürekli alfa bandının yükselmesiyle kendini gösterdi; alfa EEG dalgaları ve uyuklama arasındaki ilişki ile ilgili literatürdeki bulgularla tutarlıydı.

Farklı EEG elektrotlarının ayırt edici odaklanmış, dalgın ve uyuklayan zihinsel durumlarındaki göreceli önemi sıralandı. Performansın %90'ından fazlasının F3, F4, Fz ve Cz gibi yalnızca 4 EEG elektrotuyla geri kazanılabileceği görüldü. Bu elektrotların üçü ön lobun üzerine yerleştirildi. Ön lobdaki sinirsel aktivite, geleneksel olarak bireyin konsantrasyonu ile ilişkilendirilmiştir. Böylece, ön elektrotlar, zihinsel olarak ilgili olan deneklerle ilgili olmayan denekleri etkili bir şekilde ayırt etti. Parietal lobun alfa dalgalarının gelişimi ile ilişkili olduğu bilinmektedir. Bu nedenle, Cz elektrotunun uyuklamanın başlamasının tespitini kolaylaştırması beklenebilir.

Farklı zihinsel durumların ayrımcılığına bağlı EEG sinyallerinin parametreleri, bu tür zihinsel durum izleme sistemlerinin EEG sinyal toplama alt sistemleri için önemlidir. Sinyalin bant genişliği, çözünürlük ve elektrotlar gibi faktörlerin tümü bu sistemlerin tasarımını ve maliyetini etkiler. Çalışmadaki analiz, üç zihinsel dikkat durumunun başarılı bir şekilde belirlenmesinin, 20 Hz'nin altındaki bir frekans bandına sınırlandırılmış EEG sinyalleri kullanılarak ve F3, F4, Fz, Cz ve muhtemelen Pz konumlarında sadece dört veya beş elektrot kullanılarak yapılabileceğini göstermektedir. Bu, zihinsel dikkat durumlarını izlemek için pasif EEG BBA'ların tasarımının, yukarıdaki şemada nispeten düşük frekanslarda 40-50 Hz ve sadece dört elektrotta sinyal alımı sağlayan donanım ile yapılabileceğini göstermektedir.

EEG tabanlı teknolojilerin pratik uygulamaları için büyük bir komplikasyon, EEG BBA'nın hareket eserlerine ve dış elektromanyetik girişimlere karşı duyarlılığıdır. Bu durum EEG cihazlarının, kolayca etkilenmeleri ve denek hareketlerinden veya yakındaki elektrik ve elektronik cihazlarla çalışmasından dolayı bozulma işaretleri olarak bilinir. Bu etkenler, bireylerin hareketsiz kalma ve kontrollü iç ortamlarda kalma özelliklerinin bu tür problemlerin çoğunu hafiflettiği bu çalışma bağlamında çok daha az etkilidir.

Aynı zamanda, burada kullanılan metodolojinin en önemli avantajlarından biri, hedef durumların doğrudan sinirsel aktivite üzerinde tanımlanmasına dayanmasıdır. Denekler istenilen hedef durumları uygularken öğrenilen sinirsel belirtilerin doğrudan kullanımı, böyle bir yaklaşımı aşmayı, şaşırtmayı veya yanlış yönlendirmeyi zorlaştırır; bu, zihinsel durum tahmini için video veya hareket izleme gibi ikincil belirtiler kullanıldığında önemli bir risktir. Dahası, yaklaşımımız fizyolojik veya görsel belirtiler yoluyla açıkça ortaya çıkmayan zihinsel durumların ya da bizim tabir ettiğimiz gibi "saf" zihinsel durumların tespit edilmesini sağlar. Son olarak, buradaki metodoloji, minimum değişikliklerle çeşitli uygulamaların farklı zihinsel durumlarının tespiti için kolaylıkla genelleştirilebilir ve uygulanabilir.

Daha spesifik olarak, bu çalışmada zihinsel durumları tespit etme yöntemi, belirli bir sürekli dikkat görevi bağlamında incelenmiştir. Aynı zamanda, kullanılan yaklaşım çok geneldir ve bireyler ağırlıklı olarak pasif kaldıkları sürece farklı durumlarda farklı zihinsel durumların tespiti sorununa uygulanabilir. Bu yöntem hastanelerde yatılı, felçli ve hareketsiz hastalara uygulanabilir. Önerilen metodolojinin temel unsurları şunlardır: (i) bu tür durumların kontrollü simülasyonunu kullanarak ilgili zihinsel durumlarla ilişkili EEG verilerinden örnekler elde etmek, (ii) EEG verilerine ve deneğe özel ve zihinsel duruma özgü davranışlara dayalı bu tür durumlar için detektör üretmek amacıyla makina öğrenimi kullanmak; (iii) pasif bir EEG BBA içindeki çoklu makine öğrenme detektörlerinin sonuçlarını XOR veya benzeri birleştirme tekniği ile birleştirmek. Böyle inşa edilmiş makine öğrenme detektörlerinin parametrelerinin analizi, farklı zihinsel durumların EEG sinyallerinin temsili hakkında fikir verebilir.

Farklı zihinsel dikkat durumlarının bu metodoloji bağlamında tanımlanması kendi kendine raporlama yoluyla yapılır. Psikolojik uygulamada öz bildirim uygulaması yaygın olarak kabul edilmektedir. Bu çalışmada, ilgi durumları "odaklanmış: konsantre kalmak, aktif olarak bir işe dikkat etmek", "dalgın: uyanık kalmak, ancak dikkat etmemek veya bir işe tepki vermemek" ve "uyuklamak: gözler kapalı veya açık uykuya dalmak" olarak tanımlanmıştır. Bu nedenle, EEG verileri toplanırken katılımcılara bu hedef durumları uygulamaları talimatı verilmiştir. Denekler, bu durumları, anladıkları gibi belirtilen zaman aralıklarında uygulamışlardır.

Genel olarak, hedef zihinsel durumları tanımlamak için bağımsız olarak kullanılacak objektif önlemler varsa kullanılmalıdır. Bu çalışmada, iki faktör bu tür objektif kontrollerin kullanılmasını engellemiştir. Birincisi, bu çalışmada tanımlanacak olan durumlardan birinin

dalgınlık (ilgisizlik) olduğu düşünülürken, konuyla ilgili herhangi bir aktif araştırmanın bulunmaması bu denemenin belirli bir yöntemi olmadığını göstermektedir. İkincisi, pasif olarak odaklanmış veya gerçekten dalgın hale gelen katılımcılarla ilişkilendirilebilecek net görsel ölçümler veya belirtiler tanımlanamadı. Bu nedenle, bu çalışma bağlamında zihinsel durumları tanımlamanın birincil aracı olarak deneklerin kendini bildirme uygulaması kullanılmıştır.

Öte yandan, EEG sinyallerinin incelenmesi Şekil 9 ve Şekil 10'da gösterilmektedir. Şekil 9'da, sol sütun: karşılık gelen EEG kanalına ve frekansına göre gösterilen ortalamaların (çubuk grafikler) ve farklı özelliklerin standart sapmaları (kırmızı çizgi). Sağ sütun: farklı zihinsel durum dönemlerinde farklı özelliklerin ortalama ve standart sapmaları. Mavi, "odaklanmış" durumdur, turuncu, "dalgın" durumdur ve sarı, "uykulu" durumdur. Hata çubukları, her bir özelliğin grup içi standart sapmalarını gösterir.


Şekil 9 ve Şekil 10, deneklere üç farklı dikkat durumunu uygulama talimatı verilen 3 zaman diliminde gözlenen EEG sinyallerinin şekli ve özelliklerinde açık, objektif ve ölçülebilir farklılıklar olduğunu göstermektedir. Nesnel farklılıklar, sırasıyla deneklerin kendilerini odaklanmış / konsantre, dalgın / ilgisiz ve uyuklar vaziyette tanımladıkları zaman aralıklarıyla eşleştirilmiştir.

5. SONUÇLAR ve ÖNERİLER


Bu çalışmada bildirilen ilgili veya odaklanmış, dalgın veya kopuk ve uyuklama hallerinin ayrılmasının doğruluğu %96.70 (en iyi) ve %91.72'ye (ortalama) ulaşmıştır ve sürücü güvenliği uygulamaları için kullanılabilir. Bu çalışmada kullanılan DVM tabanlı EEG BBA yaklaşımı, farklı zihinsel durumların tespiti ve çeşitli farklı durumlar da dâhil olmak üzere diğer senaryolar için genelleştirilmiş kullanıma hazır bir makine öğrenme modeline izin verir. Yapılandırılmış zihinsel durum detektörlerinin parametrelerinin analizi, EEG sinyallerinde bu tür durumların temsili konusunda yeni bilgiler sağlayabilir.

Bu çalışmanın genelleştirilmesinin fark yaratacak özelliklerinden biri deneklerin zihinsel durumlarının değerlendirilmesini veya izlenmesini gerektiren klinik uygulamalarda kullanılabilir olmasıdır. Bu klinik uygulamalara örnek olarak anestezinin derinliğini izlemek için kullanılan teknolojilerden biri olan bispektral indeks izlemedir (BIS). BIS, anestezi uzmanlarının hastaların intraoperatif farkındalık insidansını azaltmalarına yardımcı olan bir anestezi indeksi derinliği oluşturmak için EEG sinyallerini izlemeye dayanan tescilli bir teknolojidir. Her ne kadar BIS'nin arkasındaki algoritmalar tescilli olsa ve açıklanmasa da, BIS, zaman alanı, frekans alanı ve yüksek dereceli spektral temsillerde hesaplanan çeşitli EEG parametrelerinin ağırlıklı toplamı olarak hesaplanan ampirik olarak elde edilmiş bir ölçüdür [32]. Böylece, 0 (EEG sessizliğine eşdeğer) ile 100 arasında değişen tek bir değer, beynin EEG

aktivitesine dayanarak genel bir anestezi seviyesini belirtmek için türetilir. Bispektral endeksin inşası bu çalışmada kullanılan yaklaşıma benzerdir ve gelecekte yeni klinik uygulamalar için genişletilebilir.



Şekil 12. Özellik örnekleri ve katılımcı S1 için temel istatistiksel özellikleri.



Şekil 13. Katılımcı S1 ve elektrot Pz için farklı tespit edilen zihinsel durumlarla ilişkili EEG kayıtlarına örnekler: (A) 'odaklanmış' (B) 'dalgın' (C) 'uykulu'

KAYNAKLAR

- [1]. Shangkai, G., Yijun, W., Xiaorong, G., Bo, H. (2014). Visual and Auditory Brain-Computer Interfaces. *IEEE Transactions on Biomedical Engineering*, 61(5), 1436-1447.
- [2]. Myrden, A., Chau, T. (2017). A Passive EEG-BCI for Single-Trial Detection of Changes in Mental State. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25(4), 345-356.
- [3]. Alirezaei, M., Sardouie, S. H. (2017). Detection of Human Attention Using EEG Signals. *2017 24th National and 2nd International Iranian Conference on Biomedical Engineering (ICBME)* içinde (ss. 1-5). IEEE.
- [4]. Aricò, P., Borghini, G., Di Flumeri, G., Colosimo, A., Pozzi, S., Babiloni, F. (2016). A passive brain-computer interface application for the mental workload assessment on professional air traffic controllers during realistic air traffic control tasks. *Progress in Brain Research*, 228, 295-328.
- [5]. Resalat, S. N., Saba, V. (2015). A practical method for driver sleepiness detection by processing the EEG signals stimulated with external flickering light. *Signal, Image and Video Processing*, 9(8), 1751-1757.
- [6]. Hsieh, H.-Y., Liang, S.-F., Ko, L.-W., Lin, M., Lin, C.-T. (2006). Development of a Real-Time Wireless Embedded Brain Signal Acquisition/Processing System and its Application on Driver's Drowsiness Estimation. *IEEE International Conference on Systems, Man and Cybernetics* içinde (ss. 4374-4379). IEEE.
- [7]. Yeo, M. V. M., Li, X., Shen, K., Wilder-Smith, E. P. V. (2009). Can SVM be used for automatic EEG detection of drowsiness during car driving? *Safety Science*, 47(1), 115-124.
- [8]. Mardi, Z., Ashtiani, S. N. M., Mikaili, M. (2011). EEG-based Drowsiness Detection for Safe Driving Using Chaotic Features and Statistical Tests. *Journal of Medical Signals and Sensors*, 1(2), 130-137.
- [9]. Simon, M., Schmidt, E. A., Kincses, W. E., Fritzsche, M., Bruns, A., Aufmuth, C., Schrauf, M. (2011). EEG alpha spindle measures as indicators of driver fatigue under real traffic conditions. *Clinical Neurophysiology*, 122(6), 1168-1178.
- [10]. Hashemi, A., Saba, V., Resalat, S. N. (2014). Real Time Driver's Drowsiness Detection by Processing the EEG Signals Stimulated with External Flickering Light. *Basic and Clinical Neuroscience*, 5(1), 22-27.
- [11]. Borghini, G., Astolfi, L., Vecchiato, G., & Mattia, D. (2014). Measuring neurophysiological signals in aircraft pilots and car drivers for the assessment of mental workload, fatigue and drowsiness. *Neuroscience & Biobehavioral Reviews*, 44, 58-75.
- [12]. Arico, P., Borghini, G., Di Flumeri, G., Sciaraffa, N., Colosimo, A., Babiloni, F. (2017). Passive BCI in Operational Environments: Insights, Recent Advances, and Future Trends. *IEEE Transactions on Biomedical Engineering*, 64(7), 1431-1436.
- [13]. Li, Y., Li, X., Ratcliffe, M., Liu, L., Qi, Y., Liu, Q. (2011). A real-time EEG-based BCI system for attention recognition in ubiquitous environment. *Proceedings of 2011 international workshop on Ubiquitous affective awareness and intelligent interaction - UAAII '11* içinde (ss. 33-40). New York, USA: ACM Press.
- [14]. Ke, Y., Chen, L., Fu, L., Jia, Y., Li, P., Zhao, X., Ming, D. (2014). Visual attention recognition based on nonlinear dynamical parameters of EEG. *Bio-Medical Materials and Engineering*, 24(1), 349-355.
- [15]. Wang, Y.-K., Jung, T.-P., Lin, C.-T. (2015). EEG-Based Attention Tracking During Distracted Driving. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 23(6), 1085-1094.
- [16]. Djamal, E. C., Pangestu, D. P., & Dewi, D. A. (2016). EEG-based recognition of attention state using wavelet and support vector machine. *2016 International Seminar on Intelligent Technology and Its Applications (ISITIA)* içinde (ss. 139-144). IEEE.
- [17]. Liu, N.-H., Chiang, C.-Y., Chu, H.-C. (2013). Recognizing the degree of human attention using EEG signals from mobile sensors. *Sensors (Basel, Switzerland)*, 13(8), 10273-10286.

- [18]. Lee, B.-G., Lee, B.-L., Chung, W.-Y., Lee, B.-G., Lee, B.-L., Chung, W.-Y. (2014). Mobile Healthcare for Automatic Driving Sleep-Onset Detection Using Wavelet-Based EEG and Respiration Signals. *Sensors*, 14(10), 17915–17936.
- [19]. Nuamah, J. K., Seong, Y. (2018). Support vector machine (SVM) classification of cognitive tasks based on electroencephalography (EEG) engagement index. *Brain-Computer Interfaces*, 5(1), 1–12.
- [20]. Acı, Ç. İ., Kaya, M., Mishchenko, Y. (2019). Distinguishing mental attention states of humans via an EEG-based passive BCI using Machine Learning Methods. *Expert Systems with Applications*.
- [21]. Acı, Ç., Kaya, M., Mishchenko, Y. (2019). *Attention State Dataset*. 11 Temmuz 2019 tarihinde <https://www.kaggle.com/inancigdem/eeeg-data-for-mental-attention-state-detection> adresinden erişildi.
- [22]. EPOC+. (2019). *EMOTIV*. 11 Temmuz 2019 tarihinde <https://www.emotiv.com/epoc/> adresinden erişildi.
- [23]. Almeida, L. B. (1994). The fractional Fourier transform and time-frequency representations. *IEEE Transactions on Signal Processing*, 42(11), 3084–3091.
- [24]. Lobos, T., Rezmer, J. (1997). Real-time determination of power system frequency. *IEEE Transactions on Instrumentation and Measurement*, 46(4), 877–881.
- [25]. Suykens, J. A. K., Vandewalle, J. (1999). Least Squares Support Vector Machine Classifiers. *Neural Processing Letters*, 9(3), 293–300.
- [26]. Hu, B., Li, X., Sun, S., Ratcliffe, M. (2018). Attention Recognition in EEG-Based Affective Learning Research Using CFS+KNN Algorithm. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 15(1), 38–45.
- [27]. Ibrahim, S. W., Djemal, R., Alsuwailem, A., Gannouni, S. (2017). Electroencephalography (EEG)-based epileptic seizure prediction using entropy and K-nearest neighbor (KNN). *Communications in Science and Technology*, 2(1), 6–10.
- [28]. Shah, M., Ghosh, R. (2018). Classification and Prediction of Human Cognitive Skills Using EEG Signals. *2018 Fourth International Conference on Biosignals, Images and Instrumentation (ICBSII)* içinde (ss. 206–212). IEEE.
- [29]. Bozkurt, F., Seçkin, A. Ç., Coşkun, A. (2017). Integration of IMU Sensor on Low-Cost EEG and Design of Cursor Control System with ANFIS. *International Journal of Engineering Trends and Technology*, 54, 162–169.
- [30]. Deivasigamani, S., Senthilpari, C., & Yong, W. H. (2016). Classification of focal and nonfocal EEG signals using ANFIS classifier for epilepsy detection. *International Journal of Imaging Systems and Technology*, 26(4), 277–283.
- [31]. Madhusmita, M., Mousumi, B., Narayan, P. D., Kumar, M. S. (2019). A Novel Method for Epileptic EEG Classification Using DWT, MGA, and ANFIS: A Real Time Application to Cardiac Patients with Epilepsy. *Springer, Singapore*. (pp. 525–534).
- [32]. Chalela, R., Gallart, L., Pascual-Guardia, S., Sancho-Muñoz, A., Gea, J., & Orozco-Levi, M. (2018). Bispectral index in hypercapnic encephalopathy associated with COPD exacerbation: a pilot study. *International Journal of Chronic Obstructive Pulmonary Disease*, 13, 2961.

ÖZGEÇMİŞ

Adı ve Soyadı : Murat KAYA

Doğum Tarihi : 12.03.1994

E-mail : ug.murat.kaya@toros.edu.tr

Öğrenim Durumu :

Derece	Bölüm/Program	Üniversite	Yıl
Lisans	Bilgisayar Mühendisliği	Toros Üniversitesi	2012-2017
Yüksek Lisans	Bilgisayar Mühendisliği	Mersin Üniversitesi	2017-2019
Doktora			

Görevler :

Görev Ünvanı	Görev Yeri	Yıl
Yazılımcı	Toros Üniversitesi BBA Lab (ARDEB 1001)	2012
Öğretmen	Küçükler Akademi Kod Atolyesi	2013
Öğretmen	Kavram Ortaokulu	2017
Öğretmen	Boğaziçi Koleji	2018

ESERLER (Makaleler ve Bildiriler)

Makaleler

1. Acı, Ç. İ., Kaya, M., & Mishchenko, Y. (2019). Distinguishing mental attention states of humans via an EEG-based passive BCI using Machine Learning Methods, Expert Systems with Applications, vol. 134, pp. 153-166 (SCI-Exp).
2. Kaya, M., Binli, M. K., Ozbay, E., Yanar, H., & Mishchenko, Y. (2018). A large electroencephalographic motor imagery dataset for electroencephalographic brain computer interfaces. Scientific data, 5.
3. Y.Mishchenko, Y., Kaya, M., Ozbay, E., & Yanar, H. (2018). Developing a Three-to Six-State EEG-Based Brain-Computer Interface for a Virtual Robotic Manipulator Control. IEEE Transactions on Biomedical Engineering, 66(4), 977-987.
4. Mishchenko, Y., Kurat, K., & Cömert, M. Beyin Bilgisayar Arayüzü İçin DVM Makine Öğrenme Yöntemi Kullanılarak EEG Verilerinden Sağ ve Sol El Hareket Düşüncelerinin Tespiti. TÜBAV Bilim Dergisi, 10(3), 1-20.

Bildiriler

1. Kaya, M., Acı, Ç., & Mishchenko, Y. (2018, May). A passive brain-computer interface for monitoring mental attention state. In 2018 26th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.
2. Y. Mishchenko, M.Kaya, H. Yanar, E. Ozbay "Characterization of the key properties of electroencephalographic signal for noninvasive brain machine.computer interface applications." SFN 2016, San Diego, CA, USA, November 12-16 2016
3. M. Kaya, H. Yanar, Y. Mishchenko "Developing computational infrastructure for an EEG-based brain computer interface." 24th IEEE Signal Processing and Communications Applications Conference SIU2016, Zonguldak, Turkey, May 16-19 2016.
4. E. Ozbay, Y. Mishchenko, M. Kaya, H. Yanar "Control of a virtual robotic hand manipulator using a non-invasive EEG-based brain-machine interface", 1st International Mediterranean Science and Engineering Congress IMSEC2016, Adana, Turkey, October 26-28 2016.

5. Y. Mishchenko, M. Kaya "Detecting the attention state of an operator in continuous attention task using EEG-based Brain-Computer Interface." 23rd IEEE Signal Processing and Communications Applications Congress SIU2015, Malatya, Turkey, May 16-19 2015.
6. M. Kaya, Y. Mishchenko "The system for estimating operator's attention state." Mersin University R&D Project Fair 2015, Mersin, Turkey, May 7-8 2015.
7. M. Kaya, Y. Mishchenko, H. Seckin "Methods for direct brain-computer communications using a Brain-Computer Interface." 4th Regional Project Fair of East Mediterranean Universities, Iskenderum, Turkey, April 30 2014.

