

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**





KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde

Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : / /

Tezin Savunma Tarihi : / /

Tez Danışmanı :

Trabzon

ÖNSÖZ

Bu tez çalışmasında elektroensefalografi (EEG) işaretleri kullanılarak bilişsel yorgunluğun tespiti çalışmaları paylaşılmıştır.

Son yıllarda gelişen dünyada fiziksel iş yükü gerektiren işler azalırken zihinsel iş yükü gerektiren işler artış göstermektedir. Bu çalışmada yüksek zihinsel iş yükü gerektiren işlerin sonucunda ortaya çıkan bilişsel yorgunluğun tespit edilmesi amaçlanmıştır. Bu doğrultuda insanların zihinsel faaliyetlerindeki bilişsel yorgunluk izlerini tespit edebilmek amacıyla Wisconsin Kart Eşleme Testi (WKET) esas alınarak yapılan deneyler esnasında kaydedilen EEG işaretleri kullanılarak hızlı ve doğru şekilde sınıflandırma konusu işlenmiştir. Ayrıca ses sinyalleri üzerinde etkili olan bazı katsayıların EEG sinyalleri üzerindeki etkileri incelenmiştir. Bu konuda literatüre katkı sağlamanın yanı sıra bilişsel yorgunluğun tespiti için farklı yaklaşımlarında denenebileceği konusunda alt yapı oluşturulmak istenmiştir.

Yüksek lisans öğrenimim süresince desteğini hiçbir zaman esirgemeyen, bilgi ve birikimiyle tez çalışmamın tüm aşamalarında yanımda olan ve bana yol gösteren tez danışmanım Doç. Dr. Önder AYDEMİR'e ve yine tez çalışmam süresindeki desteklerinden ötürü Amir NASER'e, Mengü DEMİR'e, Arş. Gör. Ebru ERGÜN'e teşekkürü borç bilir ve şükranlarımı sunarım.

Hem çalışma hayatımda hem de öğrenim hayatımda yanımda olan, aldığım kararları sonuna kadar destekleyen eşim Tayyip EKİM'e ve aileme sonsuz teşekkürlerimi sunarım.

Ayşe EKİM

Trabzon 2021

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “Bilişsel Yorgunluğun EEG İşaretleri ile Sınıflandırılması” başlıklı bu çalışmayı baştan sona kadar danışmanım Doç. Dr. Önder AYDEMİR’in sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 18/08/2021



Ayşe EKİM

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ŞEKİLLER DİZİNİ	X
TABLolar DİZİNİ.....	XII
SEMBOLLER DİZİNİ	XIII
1. GENEL BİLGİLER.....	1
1.1. Giriş	1
1.2. İnsan Beyni	2
1.3. Elektroensefalografinin Kısa Tarihi	4
1.4. EEG'nin Nörofizyolojik Temelleri	5
1.4.1 EEG Sinyallerinin Özellikleri.....	7
1.4.2. EEG Kayıt Standartları.....	9
1.5. Literatür Araştırması.....	10
1.5.1. Öznel Değerlendirme Ölçekleri.....	10
1.5.2. Performans Ölçümleri.....	13
1.5.3. Fizyolojik Yöntemler.....	15
1.5.3.1. Göz Hareketleri.....	15
1.5.3.2. Solunum.....	16
1.5.3.3. Kan Basıncı	17
1.5.3.4. Elektro Kardiyak Aktivite	18
1.5.3.5. Elektroensefalogram.....	20
2. YAPILAN ÇALIŞMALAR.....	24

2.1.	CogBeacon Veri Kümesi	24
2.1.1.	MUSE EEG Cihazı	24
2.1.2.	Wisconsin Kart Eşleme Testi	25
2.1.3.	Veri Toplama Süreci.....	26
2.1.4.	Veri Seti Oluşturma	29
2.2.	EEG Sinyali Özellik Çıkarma Yöntemleri	31
2.2.1.	Mel Frekans Kepstral Katsayıları	33
2.2.2.	Gammatone Kepstral Katsayıları.....	35
2.2.3.	Doğrusal Tahmin Katsayıları	35
2.2.4.	Doğrusal Tahmin Kepstral Katsayıları	36
2.2.5.	Yansıma Katsayıları	37
2.2.6.	LOG Alanı Oranları.....	38
2.2.7.	LOG Filtre Bankası Enerjileri	38
2.2.8.	Spektral Alt Bant Sentroidleri	39
2.2.9.	Çizgi Spektral Frekansları	39
2.2.10.	Güç Spektrumu	40
2.2.11.	Algısal Doğrusal Tahmin Katsayıları	41
2.2.12.	Spektra-Algısal Doğrusal Tahmin Yöntemi	43
2.3.	Öznitelik Çıkarma Yöntemleri	43
2.4.	Sınıflandırma Yöntemleri	45
2.4.1.	k-En Yakın Komşu	45
2.4.2.	Destek Vektör Makinesi	46
2.4.3.	Saf Bayes Sınıflandırıcı	48
2.4.4.	Karar Ağacı.....	50
2.4.4.1.	ID3 Algoritması.....	51
2.4.4.2.	C4.5 Algoritması	51

2.4.4.3.	Sınıflandırma ve Regresyon Ağacı.....	51
2.4.4.4	Topluluk Yöntemleri	51
2.4.5.	Diskriminant Analizi	52
2.5.	Sınıflandırıcı Değerlendirmesi İçin Çokgen Alan Metriği.....	53
3.	BULGULAR.....	56
3.1.	Mel Frekans Kepstral Katsayısı ile Elde Edilen Bulgular	56
3.2.	Gammatone Kepstral Katsayısı ile Elde Edilen Bulgular	58
3.3.	Doğrusal Tahmin Katsayısı ile Elde Edilen Bulgular	60
3.4.	Doğrusal Tahmin Kepstral Katsayısı ile Elde Edilen Bulgular	62
3.5.	Yansıma Katsayısı ile Elde Edilen Bulgular.....	64
3.6.	LOG Alanı Oranları ile Elde Edilen Bulgular	66
3.7.	LOG Filtre Bankası Enerjileri ile Elde Edilen Bulgular.....	68
3.8.	Spektral Alt Bant Sentroidleri ile Elde Edilen Bulgular.....	70
3.9.	Çizgi Spektral Frekansları ile Elde Edilen Bulgular	72
3.10.	Güç Spektrumu ile Elde Edilen Bulgular	74
3.11.	Algısal Doğrusal Tahmin Katsayısı ile Elde Edilen Bulgular	76
3.12.	Spertra-Algısal Doğrusal Tahmin Katsayısı ile Elde Edilen Bulgular	78
4.	TARTIŞMA VE SONUÇLAR.....	81
5.	ÖNERİLER	85
6.	KAYNAKLAR.....	86
	ÖZGEÇMİŞ	

Yüksek Lisans Tezi

ÖZET

BİLİŞSEL YORGUNLUĞUN EEG İŞARETLERİ İLE SINIFLANDIRILMASI

Ayşe EKİM

Karadeniz Teknik Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik- Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Önder AYDEMİR

2021, 109 Sayfa

Bilişsel yorgunluk, beyinin aşırı aktivitesinden kaynaklanır. Uzun süreli konsantrasyon, yüksek risk altında stresli çalışma ve uykusuzluk gibi diğer faktörlerden de kaynaklanabilir. Bilişsel yorgunluk üretkenliğin azalmasına ve güvenlik risklerinin artmasına yol açar. Bu tez çalışmasında bilişsel yorgunluk öznel verilere bağlı kalmadan hızlı ve doğru bir şekilde tespit edilmek istenmiştir. Bunun için CogBeacon veri seti kullanılmıştır. Bu veri seti 19 kadın ve erkek katılımcıdan iki oturumda gerçekleştirilen 76 bilişsel görev esnasında, 4 elektrotlu MUSE EEG cihazı yardımıyla toplanmıştır. Toplanan ham EEG rast gele ayrılmıştır. Genelde ses sinyallerinin analizinde kullanılan 12 farklı katsayının hesabı yapılarak sınıflandırma işlemi yapılmıştır. Öznitelik olarak OK, LD, OMD, DOMD1, DOMD2 ve GOMD denenmiştir. En iyi sonuçlar MFKK ve GTKK hesaplandıktan sonra k-EYK ve DVM algoritmalarıyla yapılan sınıflandırma işlemleri sonucu elde edilmiştir. MFKK hesaplandıktan sonra yapılan sınıflandırmada k-EYK sınıflandırma doğruluğu %78.72, DVM sınıflandırma doğruluğu %78.43, aynı şekilde GTKK hesaplandıktan sonra yapılan sınıflandırmada k-EYK sınıflandırma doğruluğu %78.08, DVM sınıflandırma doğruluğu %76.61 olarak hesaplanmıştır.

Anahtar Kelimeler: Bilişsel Yorgunluk, Elektroensefalografi (EEG), Mel Frekans Kepstral Katsayısı (MFKK), Gammatone Kepstral Katsayısı (GTKK)

Master Thesis

SUMMARY

CLASSIFICATION OF COGNITIVE FATIGUE WITH EEG SIGNS

Ayşe EKİM

Karadeniz Technical University

The Graduate School of Natural and Applied Sciences

Electrical and Electronics Engineering Graduate Program

Supervisor: Assoc. Prof. Dr. Önder AYDEMİR

2021, 109 Pages

Cognitive fatigue is caused by excessive activity of the brain. It can be caused by other factors such as prolonged, high-risk stress work and insomnia. Cognitive fatigue leads to decreased productivity and increased safety risks. In this thesis, it was aimed to determine cognitive fatigue quickly and accurately without depending on subjective data. For this, CogBeacon data set was used. This dataset was renewed from 19 female and male participants, including 76 cognitive tasks in two sessions, with a 4-electrode MUSE EEG headset. The raw EEG collected was randomly assigned. The classification process was made by calculating the 12 different coefficients generally used in the analysis of audio signals. Root mean square, log detector, mean absolute value, modified mean absolute value 1, modified mean absolute value 2 and enhanced mean absolute value have been tested as attributes. The best results were obtained as a result of the classification processes made with KNN and SVM algorithms after calculating MFCC and GTCC. In the classification made after the calculation of the MFCC, the classification accuracy with KNN is 78.72% and SVM classification accuracy as 78.43%. In the classification made after the calculation of GTCC, KNN classification accuracy was calculated as 78.08% and SVM classification accuracy as 76.61%.

Key Words: Cognitive Fatigue, Electroencephalography (EEG), Mel Frequency Cepstral Coefficient (MFCC), Gammatone Cepstral Coefficient (GTCC)

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. 1. İnsan beyninin genel görüntüsü.....	2
Şekil 1. 2. Sinir hücresi yapısı.....	3
Şekil 1. 3. Sinapsın yapısı.....	4
Şekil 1. 4. Hans Berger'in yaptığı ilk EEG kaydı.....	5
Şekil 1. 5. EEG sinyal örneği.....	7
Şekil 1. 6. EEG sinyallerinin delta, teta, alfa ve beta frekans bantları.....	8
Şekil 1. 7. Uluslararası 10-20 elektrot sistemine göre elektrotların yerleştirilmesi.....	9
Şekil 1. 8. Kalp döngüsü.....	18
Şekil 2. 1. Wisconsin Kart Eşleme Testi görseli.....	25
Şekil 2. 2. Her deneğin seçiminden sonra sistem tarafından sağlanan geri bildirim.....	26
Şekil 2. 3. Veri toplama deney düzeni.....	27
Şekil 2. 4. WKET uygulaması.....	28
Şekil 2. 5. MUSE EEG kulaklık.....	30
Şekil 2. 6. Birinci kişiye ait yorgun değil EEG verisi.....	32
Şekil 2. 7. Birinci kişiye ait yorgun EEG verisi.....	32
Şekil 2. 8. Mel Frekansı Kepstral Katsayısı hesaplama adımları.....	33
Şekil 2. 9. Hamming Penceresi.....	34
Şekil 2. 10. Gammatone Kepstral Katsayısı hesaplama adımları.....	35
Şekil 2. 11. Doğrusal Tahmin Katsayısı hesaplama adımları.....	36
Şekil 2. 12. Doğrusal Tahmin Kepstral Katsayısı hesaplama adımları.....	37
Şekil 2. 13. Log Filtre Bankası Enerjisi hesaplama adımları.....	39
Şekil 2. 14. Algısal Doğrusal Tahmin Katsayısı işlem blok şeması.....	41
Şekil 2. 15. Algısal Doğrusal Tahmin Katsayıları hesaplama adımları.....	42
Şekil 2. 16. k-EYK sınıflandırma mimarisi.....	46
Şekil 2. 17. DVM sınıflandırma örneği.....	47
Şekil 2. 18. Karar Ağacı sınıflandırıcı mimarisi.....	50
Şekil 2. 19. Çokgen Alan Metriği.....	54
Şekil 3. 1. MFKK'ye dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA.....	57
Şekil 3. 2. . GTKK'ye dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA.....	59

Şekil 3. 3.	DTK'ye dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA.....	61
Şekil 3. 4.	DTKK'ye dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA.....	63
Şekil 3. 5.	YK'ye dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA.....	65
Şekil 3. 6.	LAO'ya dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA.....	67
Şekil 3. 7.	LFBE'ye dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA.....	69
Şekil 3. 8.	SABS'ye dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA.....	71
Şekil 3. 9.	ÇSF'ye dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA.....	73
Şekil 3. 10.	GS'ye dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA.....	75
Şekil 3. 11.	ADTK'ye dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA.....	77
Şekil 3. 12.	SADTK'ye dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA.....	79

TABLolar DİZİNİ

Sayfa No

Tablo 2. 1.	CogBeacon veri kümesine dâhil edilen toplam WKET görevi sayısı.....	28
Tablo 2. 2.	Kişilere göre verilerin sınıflara dağılımı.....	31
Tablo 2. 3.	Karar ağaçları oluşturmak için üç yöntem.....	51
Tablo 2. 4.	İki sınıflı bir problem için kafa karışıklığı matrisi.....	55
Tablo 3. 1.	MFKK'ye dayalı sınıflandırıcı ve SPD sonuçları.....	57
Tablo 3. 2.	Deney sonuçları.....	58
Tablo 3. 3.	GTKK'ye dayalı sınıflandırıcı ve SPD sonuçları.....	59
Tablo 3. 4.	Deney sonuçları.....	60
Tablo 3. 5.	DTK'ye dayalı sınıflandırıcı ve SPD sonuçları.....	61
Tablo 3. 6.	Deney sonuçları.....	62
Tablo 3. 7.	DTKK'ye dayalı sınıflandırıcı ve SPD sonuçları.....	63
Tablo 3. 8.	Deney sonuçları.....	64
Tablo 3. 9.	YK'ye dayalı sınıflandırıcı ve SPD sonuçları.....	64
Tablo 3. 10.	Deney sonuçları.....	66
Tablo 3. 11.	LAO'ya dayalı sınıflandırıcı ve SPD sonuçları.....	67
Tablo 3. 12.	Deney sonuçları.....	68
Tablo 3. 13.	LFBE'ye dayalı sınıflandırıcı ve SPD sonuçları.....	69
Tablo 3. 14.	Deney sonuçları.....	70
Tablo 3. 15.	SABS'ye dayalı sınıflandırıcı ve SPD sonuçları.....	71
Tablo 3. 16.	Deney sonuçları.....	72
Tablo 3. 17.	ÇSF'ye dayalı sınıflandırıcı ve SPD sonuçları.....	73
Tablo 3. 18.	Deney sonuçları.....	74
Tablo 3. 19.	GS'ye dayalı sınıflandırıcı ve SPD sonuçları.....	75
Tablo 3. 20.	Deney sonuçları.....	76
Tablo 3. 21.	ADTK'ye dayalı sınıflandırıcı ve SPD sonuçları.....	77
Tablo 3. 22.	Deney sonuçları.....	78
Tablo 3. 23.	SADTK'ye dayalı sınıflandırıcı ve SPD sonuçları.....	79
Tablo 3. 24.	Deney sonuçları.....	80
Tablo 4. 1.	Katsayılara dayalı sınıflandırıcı sonuçları.....	82
Tablo 4. 2.	CogBeacon veri seti kullanılarak yapılan çalışmalar.....	83

SEMBOLLER DİZİNİ

ADT	Algısal Doğrusal Tahmin
ÇAM	Çokgen Alan Metriği
D	Duyarlılık
DA	Diskriminant Analizi
DOMD1	Değiştirilmiş ortalama Mutlak Değer 1
DOMD2	Değiştirilmiş Ortalama Mutlak Değer 2
DTK	Doğrusal Tahmin Katsayısı
DTKK	Doğrusal Tahmin Kepstral Katsayıları
DVM	Destek Vektör Makinesi
EAA	Eğri Altındaki Alan
EEG	Elektroensefalografi
EKG	Elektrokardiyografi
FÖ	F ölçümü
GOMD	Geliştirilmiş Ortalama Mutlak Değer
GTKK	Gammatone Kepstral Katsayısı
HFD	Hızlı Fourier Dönüşümü
Hz	Hertz
Jİ	Jaccard İndeksi
K	Kappa
K ⁺	Potasyum iyonu
KA	Karar Ağacı
k-EYK	k-En Yakın Komşu
LAO	Log Alan Oranı
LD	Log Dedektörü
LFBE	Log Filtre Bankası Enerjisi
MFKK	Mel Frekansı Kepstral Katsayıları
mV	Milivolt
Na ⁺	Sodyum iyonu

OK	Ortalama Karekök
OMD	Ortalama Mutlak Deęer
Ö	Özgüllük
RTF	Radyal Temel Fonksiyonu
SABS	Spektral Alt Bant Sentroidi
SADT	Spektra-Algısal Doğrusal Tahmini
SD	Sınıflandırma Doğruluęu
SPD	Sınıflandırıcı Performans Deęerlendirmesi
WKET	Wisconsin Kart Eşleştirme Testi
YK	Yansıtma Katsayısı
α	Alfa
β	Beta
θ	teta
μV	Mikrovolt

1. GENEL BİLGİLER

1.1. Giriş

Beynin retiküler aktivasyon sisteminin zihinsel yorgunluk algısını düzenlediği düşünülmektedir. Zihinsel yorgunluk, optimum bilişsel performansı sürdürmek için geçici yetersizliktir. Herhangi bir bilişsel aktivite sırasında, yorgunluğun başlaması yavaş yavaş başlar ve bireyin bilişsel yeteneğini tam olarak kullanmasını engeller. Zihinsel yorgunluk, sınırlı kaynakların özdenetim kapasitesinin tükendiğinde ortaya çıkan azalmış dikkat olarak kendini gösterebilir [1]. Fiziksel yorgunluktan farklı olsa da fiziksel yorgunlukla ilişkili olan bilişsel yorgunluk, sağlık, ulaşım güvenliği ve benzeri birçok gerçek dünya uygulamasında bulunan yaygın bir semptomdur. Endüstriyel işlerde genellikle tespit edilemeyen ve tedavi edilmeyen “görünmez” bir güvenlik riski olarak kabul edilir. İş sırasında verilen kararların bozulmasına ve beraberinde farklı sonuçlara neden olabilir. Örneğin, bir okul otobüsü sürücüsü yorgun olduğu için dur işaretini kaçırırsa veya geçen bir çantadaki silahı tanımayan bir havaalanı güvenlik görevlisi hatta yanlış ilacı veren bir hemşire veya doktor düşünüldüğünde ciddi sorunlar ortaya çıkabilir [2].

Bugüne kadar, bilişsel yorgunluğu tahmin etmek için birçok yöntem önerilmiştir. Yapılan birçok çalışmada davranışsal indeksler, reaksiyon süresi, hata oranı, sübjektif ölçekler gibi öznel ölçümler kullanılmıştır. Bununla birlikte, davranışsal indekslerin veya öznel yöntemlerin bazı sınırlamaları vardır, örneğin, bilişsel yorgunluğun aniden dalgalanmalarını tespit edemezler ve sonuçlar deneklerin duygularından etkilenebilir. Ergonomik araştırmalarda son zamanlarda görülen bir eğilim, bilişsel yorgunluk durumunu değerlendirmek için daha objektif önlemler seçmektir. Bu yaklaşımlar, bilişsel yorgunluk durumlarını tespit etme aracı olarak elektrookülogram, solunum sinyalleri, kalp atım hızı, deri elektrik potansiyeli ve özellikle elektroensefalografi (EEG) aktiviteleri gibi insanların fizyolojik değişikliklerini ölçmeye odaklanır. Bir bireyin bilişsel yorgunluk durumunu tanımlamak için çok sayıda fizyolojik gösterge mevcut olmasına rağmen, EEG sinyallerinin en umut verici, öngörücü ve güvenilir olduğu gösterilmiştir [3].


EEG, onlarca yıldır beyin fonksiyonlarını araştırmak için bir araç olarak kullanılmıştır. Çeşitli bilişsel dikkatle ilgili çalışmalar hem frontal-orta hat hem de parietal-orta hattın

odaklanmış dikkat ve duygusal bilgi işleme ile ilişkili olduğunu ortaya koymuştur. Dahası, araştırmacılar frontal teta gücünün artmasının bilişsel görev karmaşıklığı ve odaklanmış dikkat ile ilişkili olduğunu, azalmış parietal alfa gücünün ise bilişsel ve görsel motor görevde artan bilgi işlemeyle ilişkili olduğunu bulmuşlardır [1].

Bu tez çalışmasında bilişsel yorgunluğun tespiti için EEG verileri kullanılmıştır. Veri analizinde genellikle ses sinyallerinin analizinde kullanılan katsayılar hesaplanmış daha sonra öznitelik çıkarma işlemi gerçekleştirilmiştir. Sınıflandırma işlemleri yapılarak sonuçlar elde edilmiştir.

1.2. İnsan Beyni

Merkezi sinir sisteminin en önemli kısmı olan beyin, birçok işlevi eş zamanlı olarak gerçekleştirebilen bir organımızdır. Yaklaşık bir trilyon hücreden oluşur. Bunlar sinir hücreleri ve glial hücreleri olmak üzere iki türdür [4]. İnsan beyni, sinirler ve omurilik sayesinde merkezî sinir sistemini kontrol eder, çevresel sinir sistemini yönetir ve hemen hemen insanın tüm işlevlerini düzenler.



Şekil 1. 1. İnsan beyninin genel görüntüsü

Frontal (Ön) Lob: Üst düzey işlevlerin gerçekleştiği bölümdür. Vücut hareketleri, konsantrasyon, planlama, problem çözme, geri bildirim düzenleme ve görevlere sistematik bakabilme gibi işlevleri vardır.

Parietal (Yan) Lop: Duyu nöronlarından gelen çeşitli his ve sinyallerin birleştirilip yorumlanmasından sorumludur. Aynı zamanda dış çevredeki objelerin birbirleri arasındaki veya kendi aralarındaki ilişkilendirmeyi de yapar.

Temporal (Şakak) Lobu: Temporal lob beynin yan taraflarında kulaklarımızın arkasındaki bölgedir. Çok sayıda farklı işlevi olan beyin bölgesine sahiptir. Görsel bilgi işleme süreçlerinin bazı yönleri, şakak lopları tarafından gerçekleştirilir. Özellikle sol şakak lobu çok kişiseldir.

Oksipital (Arka Baş) Lob: Beynin arka tarafından yer alan oksipital lob beynin görsel bilgiyi işleme merkezidir. Büyük bir bölümünü görme korteksi oluşturur. Dışarıdan gelen ışık gözde elektriksel sinyallere dönüştürülür ve optik sinirler vasıtasıyla birincil görme korteksinde işlenir.


Beyincik: Duyu organlarından gelen bilgiyi hareketle ilişkilendirme yapar. Denge ve koordinasyon merkezidir [5, 6].

Nöronlar: Sinir sistemi ve beyin fonksiyonlarının en önemli yapıtaşını nöronlar oluşturur. Bir nöron, soma, dendrit ve akson adı verilen üç ana kısımdan oluşur.

Soma: Çekirdek ve çekirdekçiği içinde bulunduran esas hücre kısmıdır.


Dendrit: Soma içerisinden çıkan çok sayıda dallanmalardır. Yapısı bakımından bir ağacın dallarını andırır. Dendritlerin görevi diğer nöronlardan gelen uyarıları nöron gövdesine iletmektir.

Akson: Gövdeden çıkan sitoplazmik uzantı kısmıdır. Her nöronda bir tane bulunur. Akson, sinir hücresinden gelen işaretleri çevreye taşımakla görevli olup, böylece sinir hücresini diğer sinir hücreleri veya bir kas hücresi ya da bir salgı bezi gibi iş yapan hücrelerle bağlar.



Şekil 1. 2. Sinir hücresi yapısı

Sinir hücreleri aynı zamanda birbirleri ile ilişkidir. Bu ilişki, sinirsel işlevin temelini oluşturan bilgi akışını sağlar. Sinir hücreleri arasındaki bilgi geçiş noktalarına sinaps adı verilir. Uyarıların bir nöronun başka bir nörona geçişi bu yapılar sayesinde gerçekleşir. Sinaps boşluğundan uyarıların (impuls) iletimi aracı maddeler veya mediyatörler denilen maddeler sayesinde gerçekleşir. Sinapslarda presinaptik tarafa ulaşan aksiyon potansiyeli, bu uçtan kimyasal bir mediyatör salınmasına yol açar. Bu mediyatör postsinaptik taraftaki reseptörlerle etkileşerek, bazı iyon kanallarını aktive eder ve postsinaptik zarda elektriksel potansiyel değişikliğine yol açar. Kısacası, sinir hücreleri kendi aralarında bağlantılar kurarak, elektrik devrelerine benzer yollarla iletişimi sağlayıp, beyin işlevlerinin ortaya çıkmasını sağlayan ana elemanlardır. Bu sırada ortaya çıkan elektriksel aktiviteleri kaydetme görevi ise EEG cihazları ile yapılmaktadır [7].



Şekil 1. 3. Sinapsın yapısı


1.3. Elektroensefalografinin Kısa Tarihi

Beyindeki elektrik akımlarının varlığı, 1875 yılında bir İngiliz Doktor Richard Caton tarafından keşfedildi. Caton, kedilerin ve tavşanların açıkta kalan beyinleri üzerinde çalıştı, elektrik akımlarını bir galvanometre aracılığıyla ölçtü ve aynasından yansıyan bir ışık demetini yakındaki bir duvara yerleştirdiği bir ölçeğe yansıttı. Sonuçlar, elektrotlar dış yüzeyin iki noktasına veya bir elektrot gri madde ve diğeri de kafatasının yüzeyine

yerleştirildiğinde çarpandan farklı yönlerde zayıf akımların geçtiğini gösterdi. Bu gözlem, elektroensefalografik aktivitenin bir keşfi olarak kabul edilebilir [5].

Adolf Beck, tavşanların ve köpeklerin beyinlerinin doğal aktivitesini araştırdı. Beyin elektrik aktivitesinin ritmik salınımlarını ilk keşfeden oydu. Ayrıca, gözler ışıkla uyarıldığında bu salınımların ortadan kaybolduğunu gözlemledi; bu, alfa blokajının ilk keşfiydi. Daha sonra iş arkadaşı Napoleon Cybulski, elektroensefalogramı fotografik ek ile bir galvanometre uygulayarak grafiksel form ve köpekte epileptik EEG aktivitesini elektrik uyarımı ile ortaya çıkaran ve ilk gözlemleyen oldu [8].

Hans Berger, 1929'da ilk elektroensefalogramı insan kafa derisinin yüzeyinden kaydetti [8]. 1924'te beynin insan kafa derisinde ölçülen elektriksel aktivitesini yükseltmek için sıradan radyo ekipmanını kullandı. Beyinde oluşan zayıf elektrik akımlarının kafatasını açmadan kaydedilebileceğini ve bir kâğıt şeridi üzerinde grafiksel olarak gösterilebileceğini açıkladı. Gözlemlediği aktivite uyku, anestezi, oksijen eksikliği ve epilepsi gibi bazı sinir hastalıklarında beynin fonksiyonel durumuna göre değişti. Berger, elektroensefalografinin mevcut uygulamalarının çoğunun temellerini attı. Ayrıca insanlarda beyin elektrik potansiyellerini tanımlarken ilk olarak elektroensefalogram kelimesini kullandı [9].



Şekil 1. 4. Hans Berger'in yaptığı ilk EEG kaydı

1.4. EEG'nin Nörofizyolojik Temelleri

Canlı bir hücrelerinin hücre içi negatif yüklüdür ve hücre zarının dinlenme potansiyeli yaklaşık -80 mV'dir. Hücre zarı boyunca potansiyellerin farkı, katyonların yoğunluğunun farkından gelir. Potansiyel fark, metabolik süreçlerle enerji kullanılarak potasyum (K^+) iyonlarının hücrenin içine ve sodyum (Na^+) iyonlarının hücre dışına aktif taşınmasıyla sağlanır [8].

Nöronların elektriksel aktivitesi, aksiyon potansiyellerinin ve postsinaptik potansiyellerin oluşumu ile kendini gösterir. Membranın elektriksel uyarımı bir eşiği aştığında aksiyon potansiyelleri ortaya çıkar. Postsinaptik potansiyeller, eşik altı olaylardır. Aksiyon potansiyellerinin oluşumu, Na^+ iyonları için hızlı geçirgenlik artışı ile bağlantılıdır.

Hücredeki akışları, hücre içindeki potansiyelin hızlı bir şekilde artmasına ve nöronun iç kutuplarının negatiften pozitifte değişmesine neden olur. Daha sonra K^+ iyonlarına karşı membran geçirgenliğinin artması ve Na^+ iyonları için geçirgenliğin azalması, hücrenin içini çevreleyen ortama göre tekrar negatif hale getirir. Bu şekilde, karakteristik sivri uçlu şeklin aksiyon potansiyeli yaratılır. "Ya hep ya hiç" kuralına uyar: eşik üstü uyarılar için, sabit büyüklükte bir darbe üretilir; eşik altı uyarılma için nöron ateşlenmez [8].

Tablo 1. 1. Bilinen ve kullanılan bazı gerilim değerleri

Sinir hücresi ateşlemesi	10 mili volt
Tek bir pil (AAA veya AA)	1.5 volt
Otomobil	12 volt
Ev elektriği	220 volt
Sanayi elektriği	380 volt
Yüksek voltaj	35-150 kilovolt
Yıldırım çakması	100 megavolt


Nöronların elektriksel aktivitesi, hücre içi ve hücre dışı boşluklarda hücre zarı boyunca akımlar oluşturur ve yaklaşık olarak bir dipole uyan bir elektrik alanı üretir. Bu elektrik alanının makroskobik gözlemi, paralel olarak yönlendirilmiş çok sayıda dipolün elektriksel aktivitesinin uyumunu gerektirir. EEG, eşzamanlı olarak üretilen postsinaptik potansiyellerin toplamından gelir. Geri besleme döngüleri ile birbirine bağlanan uyarıcı ve önleyici nöronlardan oluşan ağların ortak özelliklerinin EEG ritimlerinin oluşturulmasında önemli bir rol oynadığı genel olarak kabul edilmektedir. Salınımın sıklığı, iç zar özelliklerine, bireysel nöronların zar potansiyeline ve sinaptik etkileşimlerin gücüne bağlıdır [8].

Geçmişte, bilgi işlemede EEG'nin rolü tam olarak tanınmamıştı. Bununla birlikte, bir nöron popülasyonundaki beta aralığındaki tutarlı salınımların, görsel sistemin özellik bağlamasında temel mekanizma olabileceğine dair güçlü kanıtlar mevcuttur. Bu şekilde, algısal süreçlere boyun eğen benzer dinamik işlevsel duruma sahip nöronsal gruplar oluşturulabilir. Alfa ve teta aralığındaki senkronize salınımlı EEG aktivitesinin rolünün, ağ üzerinden bilgi akışına bir geçit mekanizması olarak hizmet etmek olduğu da kabul

edilmiştir. Salınım aktivitesi patlamaları, beyin seçilen nöronal ağlardaki durum değişikliklerini düzenleyebileceği ve bilgi yolunu değiştirebileceği bir mekanizma oluşturabilir [8].

1.4.1 EEG Sinyallerinin Özellikleri


EEG sinyalleri, farklı frekans aralıklarına sahip olan dalgaların üst üste binmesi ile oluşur. Periyodik olmayan fakat ritmik olan, 0.5 Hz'den başlayan ve 100 Hz'i aşan frekans aralığında, genlikleri ise 10 μ V ile 200 μ V arasında kaydedilebilen ve ham EEG kaydına filtreleme uygulanarak ayrı ayrı tespit edilebilen dalgalardır [6]. Aşağıdaki ritimler EEG'de ayırt edilmiştir: delta (0,5–4 Hz), teta (4-8 Hz), alfa (8-13 Hz), beta (13–30 Hz) ve gama (+30 Hz). Gama bileşenlerinin kafa derisi elektrotları ile kaydedilmesi zordur ve frekansları 45 Hz'yi geçmez; ECoG bileşenlerinde, 100 Hz'e kadar veya daha yüksek, kaydedilebilir. Farklı ritimlerin EEG'ye katkısı, deneğin yaşına ve davranışsal durumuna, özellikle de uyanıklık düzeyine bağlıdır. EEG özelliklerinde önemli nesnelere arası farklılıklar da mevcuttur. EEG örneği, nöro-patolojik koşullar, metabolik bozukluklar ve ilaç etkisinden etkilenir [8].



Şekil 1. 5. EEG sinyal örneği

Tablo 1. 2. EEG'nin Temel Ritimleri

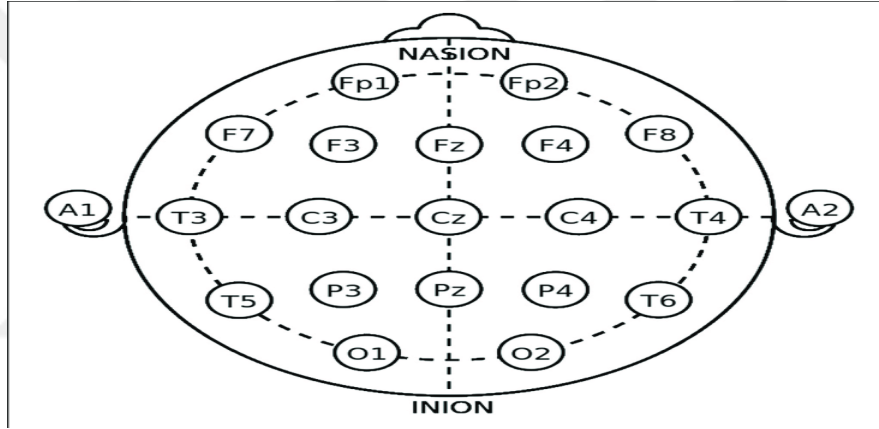
	Frekans (Hz)	
DELTA	0.5-4	Derin uyku sırasında kaydedilen EEG'lerde baskın bir özelliktir. Bu aşamada, delta dalgaları genellikle büyük genliklere (75–200 mV) sahiptir ve kafa derisinin her yerinde güçlü bir uyum gösterir.
TETA	4-8	Yetişkin insanlarda nadiren görülür. İnsanlarda, teta bandındaki aktivite duygusal veya bazı bilişsel durumlarda ortaya çıkabilir; patolojinin neden olduğu alfa ritimlerinin yavaşlamasıyla da bağlantılı olabilir.
ALFA	8-13	Uyanıklık sırasında baskındır ve en çok başın arka bölgelerinde belirgindir. En iyi gözler kapalıyken ve rahat bir durumda olduğunda gözlemlenirler. Dikkatle ve zihinsel çabayla engellenir veya zayıflatılır.
BETA	13-30	Çeşitli hayvan ve insan çalışmalarında gösterildiği gibi, artan uyanıklık ve odaklanmış dikkat durumları için karakteristiktir.
GAMA	+30	Bilgi işlemeye ve istemli hareketlerin başlamasıyla bağlantılıdır. Genel olarak, en yavaş kortikal ritimlerin boş beyinle ilgili olduğu ve en hızlı bilgi işlemeye ilgili olduğu özetlenebilir.



Şekil 1. 6. EEG sinyallerinin delta, teta, alfa ve beta frekans bantları

1.4.2. EEG Kayıt Standartları

EEG genellikle kafa derisine yerleştirilen elektrotlar aracılığıyla kaydedilir. 1958'de Uluslararası Elektroensefalografi ve Klinik Nörofizyoloji Federasyonu, elektrot yerleştirme için 10-20 elektrot yerleştirme sistemi adı verilen standardizasyonu kabul eder. Bu sistem, kafa derisine elektrotların fiziksel yerleşimini ve atamalarını standartlaştırır. Baş, beynin tüm bölgelerini yeterli derecede kapsayacak şekilde kafatası yerlerinden orantılı olarak bölünür. Etiketler 10-20, elektrotlar için noktaların seçildiği kulaklar ve burun arasındaki yüzde cinsinden orantılı mesafeyi belirtir. Elektrot yerleşimleri, komşu beyin bölgelerine göre etiketlenir: F (ön), C (merkezi), T (temporal), P (arka) ve O (oksipital) [9].



Şekil 1. 7. Uluslararası 10-20 elektrot sistemine göre elektrotların yerleştirilmesi

Tomografiden de bilindiği gibi farklı beyin bölgeleri, beynin farklı işlevleriyle ilişkili olabilir. Her kafa derisi elektrotu belirli beyin merkezlerinin yakınında bulunur, örneğin F7, rasyonel merkezlere, Fz motivasyon merkezlerine, F8 ise duygusal dürtülerin kaynaklarına yakın konumdadır. C3, C4 ve Cz konumlarının etrafındaki korteks, duyuşal ve motor işlevlerle ilgilenir. P3, P4 ve Pz yakınlarındaki yerler, algılama ve farklılaşma aktivitesine katkıda bulunur. T3 ve T4'e yakın duygusal işlemciler bulunurken, T5 ve T6'ya yakın belirli hafıza işlevleri gerçekleşir. Birincil görsel alanlar O1 ve O2'nin altında bulunabilir. Bununla birlikte, kafatasının homojen olmayan özelliklerinden, korteks kaynaklarının farklı yöneliminden, kaynaklar arasındaki tutarlılıklardan kaynaklanan sınırlamalar nedeniyle aktif kaynakların kesin konumu hala açık bir problem olduğundan kafa derisi elektrotları korteksin belirli alanlarını yansıtmayabilir [9].

1.5. Literatür Araştırması

İnsan hatası, bilgi eksikliği, iletişim eksikliği, dikkat eksikliği, aşırı stres, bilişsel yorgunluk ve çevresel faktörler gibi bazı uygunsuzlukların neden olduğu istenmeyen davranışlar olarak tanımlanabilir. Bilişsel durumu izlemek, bu hataları azaltmak için yararlı bir araçtır. Bu nedenle bilişsel yük ile ilgili pek çok çalışma çeşitli araştırma alanlarında yürütülmektedir.

Bilişsel yük teorisine göre iki kişi aynı görevi aynı koşullarda, aynı anda ve aynı başarı seviyesinde tamamlayabilir. Bununla birlikte, her iki insanın da aynı düzeyde bilişsel yükü sahip olduğunu garanti etmez. Kişisel nitelikler, özellikler, bilişsel yük ve bilişsel durum gibi birçok farklı faktöre bağlıdır. Bilişsel yorgunluk seviyesini tanımlamak önemli olsa da, ölçülebilecek belirli ölçütler yoktur. Literatürdeki bilişsel yükü ölçmek için kullanılan mevcut yöntemler, bilişsel yükü tahmin etmek için bazı etkili göstergeler vermeye çalışmaktadır [10].

Bilişsel yükü ölçme yöntemleri üç başlık altında toplanabilir: öz değerlendirme veya öznel değerlendirme ölçümleri; performans ölçümleri ve fizyolojik ölçümler. Öznel değerlendirme, ilgili görevleri tamamlayan kişilerin öz değerlendirmelerine dayanır. Performans ölçümleri, görev tamamlama süresi ve görev tamamlama başarısıyla ilgilidir. Bu yöntemler genellikle iki görevi aynı anda tamamlamayı gerektiren ikincil görev uygulamalarını içerir. Fizyolojik yöntemler ise otonom sinir sistemi ve beyin aktivitelerinden bazı endikasyonlar izlenerek belirlenir. Göz bebeği tepkileri, kalp atış hızı değişkenliği ve beyin aktiviteleri bilişsel yükü tahmin etmek için kullanılan en yaygın göstergelerden bazılarıdır. Bilişsel durumu izleyerek bilişsel yükü tahmin etmek için beyin aktivitelerine dayalı çalışmalarda EEG sistemleri tercih edilmektedir [10].

1.5.1. Öznel Değerlendirme Ölçekleri

Öznel yöntemler kullanımı kolay, düşük maliyetli ve basit nicel sonuçlar sağlarlar. Öznel yöntemlerde kullanılan derecelendirme ölçekleri, genellikle sıralı yanıt kategorileri dizisinden oluşur. Ölçeklerdeki etiketler; uyarılar ve tepkiler arasındaki uygunluğu tanımlar. Bununla birlikte, herhangi bir iş yükü ölçeğindeki değerler ile fiziksel dünyadaki ölçülebilir olaylar arasında doğrudan bir ilişki yoktur. Öznel ölçümler yüksek öznel

geçerliliğine sahip olmalarına rağmen, yorumlanmaları ve performansı tahmin etme yetenekleri belirsizdir [10].

Öznel görüşleri toplamak için çeşitli teknikler mevcuttur. Bunlar, psikometrik olarak tanımlanmış derecelendirme ölçeklerini, iki veya çoktan seçmeli yanıtları olan yapılandırılmış anketleri, açık uçlu anketleri, yapılandırılmış görüşmeleri ve yapılandırılmamış görüşmeleri içerir [11].

VACP yöntemi, iş yükünün üç farklı bileşenini ele almaktadır; duyuşsal, bilişsel ve psikomotor. Duyuşsal bileşen, bir deneğin katılması gereken görsel, işitsel veya kinestetik uyaranların karmaşıklığını ifade eder; bilişsel bileşen, deneğin gerektirdiği bilgi işleme düzeyini ifade eder; psikomotor bileşeni, deneğin davranışsal tepkilerinin karmaşıklığını ifade eder. Görev ağı modellemesiyle birleştirildiğinde tahmini iş yükü değerlendirmesi için kullanılabilen basit, tanısal bir iş yükü ölçüm aracı için eski bir tekniktir. Denekler, görev taleplerini her biri standartlaştırılmış, kategorik bir listeye göre değerlendirirler. Sistem tasarımında doğrulama eksikliğine ve sıralı verilerin uygunsuz bir şekilde toplanmasına itirazlar yapılmasına rağmen, sistemlerin kullanıcıları nerede aşırı yükleyebileceğini belirlemek için yararlı olduğu kanıtlanmıştır [12, 13].

İş Yükü Dizini yazılım aracı, sistem tasarımcılarının mürettebat istasyonunun fiziksel düzenini, otomasyonun belirli mürettebata uygulanmasını içerir ve kararların iş yükü sonuçlarını göz önünde bulundurmasına olanak tanır. İş yükü hesaplamalarındaki birden çok kaynak arasındaki görüş ayrılığından dolayı geliştirilmiştir [14].

Öznel İş Yükü Değerlendirme Tekniđi, operasyonel olarak kullanımı kolay ve görev performansı ile ilişkili çalışmalar hakkında yüksek kalitede hassas bilgi veren bir derecelendirme ölçeđi tekniđidir [15]. Öznel İş Yükü Değerlendirme Tekniđi üç alt ölçekten oluşmaktadır: zaman yükü, zihinsel çaba yükü ve psikolojik stres yükü. Her boyut, üç puanlık bir derecelendirme ölçeđi ile temsil edilir (1 = Düşük, 2 = orta ve 3 = yüksek). Üç ölçeđin her birinin üç seviyesinin 27 olası kombinasyonu, deneklerin bir deneyden önce en düşükten en yükseğe doğru sıralanması için ayrı kartlarda sunulur. Bu sıralamalar, aralık özelliklerine sahip 100 puanlık, tek boyutlu bir ölçek oluşturmak için kullanılır. Sıralama süreci, zaman alıcı olmasına rağmen, bir aralık ölçeđi sağladığından ve iş yükü tanımındaki bireysel farklılıkları dikkate aldığından değerlidir. Sınırlı sayıda boyut ve aralık ölçek değerleri, Öznel İş Yükü Değerlendirme Tekniđi'ni operasyonel ortamlarda kullanım için cazip kılar. Fakat izin verilen bu sınırlı derecelendirme aralığı aynı zamanda ölçeđin hassasiyetini de azaltır [16].

Cooper-Harper Handling nitelikleri derecelendirme ölçeği geliştirilen en eski ölçeklerden biridir. Hava taşıtı kullanım niteliklerinin öznel değerlendirmelerini elde etmek için geliştirilmiş olmasına rağmen, aynı zamanda iş yükünü de etkileyen faktörlerin çoğuna da duyarlı olduğu görülmüştür. Denekler, her biri iki veya üç alternatif arasından bir dizi karar verir. Her karar, deneği başka bir seçime veya 1-10 arasında değişen son bir sayısal derecelendirmeye yönlendirilirler [16].

Modifiye Cooper-Harper ölçeği, laboratuvar, simüle uçuş ve ordu saha testlerinde test edilmiştir. Ölçeğin simüle edilmiş uçuşta iş yükü değişikliklerine duyarlı olduğu gözlemlenirken, diğer ortamlarda daha az yararlı olduğu kanıtlanmıştır [16].

NASA-TLX, altı alt ölçek derecelendirmesinin ağırlıklı ortalamasına dayalı bir genel iş yükü tahmini sağlar. [17]. NASA-TLX, askeri ve sivil helikopterler, genel havacılık, nakliye ve askeri jet simülatörleri ve yer tabanlı sistemlerde başarıyla kullanılmıştır. Değerlendiriciler arası değişkenlik, diğer derecelendirme ölçeklerine göre daha düşüktür [16].

Çoklu Kaynak Anketi, belirli kaynaklar üzerindeki yükü tanımlayarak yüksek doğruluk sağlamayı amaçlayan, öznel iş yükü değerlendirmesi için kolayca yönetilen 17 maddelik bir ölçüdür. Boles ve Adair, Çoklu Kaynak Anketi aracılığıyla iş yükünün nedenini değerlendirmeye çalışmışlar ve bu yöntemin diğer öznel yöntemlerle iyi ilişkili olduğunu öne sürmüşlerdir. Çoklu Kaynak Anketi'nin daha iyi bir yöntem mi yoksa pratik bir iş yükü ölçüm tekniği mi olduğu henüz belli değildir [18].

Derecelendirme Ölçeği Zihinsel Çaba Ölçeği, deneklerin görevi yerine getirmek için ne kadar çaba harcamaları gerektiğini belirtmelerini gerektiren tek boyutlu bir derecelendirme ölçeğidir. Denekler, yanıtlarını 0-150 ölçeğine sahip dikey bir çizgide işaretler ve "hiç çaba sarf etmeme" ile "çok çaba gösterme" arasında değişen sözel değerlere göre değerlendirirler [19].

Bedford ölçeği, orijinal olarak pilot iş yükünün değerlendirilmesi için geliştirilmiş, öznel iş yükünün tek boyutlu bir derecelendirme ölçeğidir. 'Yedek zihinsel kapasiteyi' ele alır ve 1-10 arası bir derecelendirme üreten hiyerarşik bir karar ağacını temsil eder [20].

Savunma Araştırma Ajansı İş Yükü Ölçeği, dört ölçek içeren doğrulanmış çok boyutlu bir iş yükü değerlendirme tekniğidir. Deneklerden girdi talebi, merkez talebi, çıktı talebi ve zaman baskısı gibi görev taleplerine ilişkin algılarını derecelendirmelerini ister. Bu ölçekler, geniş bir performans ve iş yükü verilerinden istatistiksel olarak türetilen dört iş yükü faktörüne karşılık gelir [19]. Savunma Araştırma Ajansı İş Yükü Ölçeği, tek görevleri

değerlendirmek veya birden çok eşzamanlı görevle ilgili deneyimleri değerlendirmek için kullanılabilir [21].

Bilgi İşleme modeli, zaman ve işlenecek bilgilerle ilgilidir. İş yükünü görev yürütmenin gözlemlenebilir yönleriyle ilişkilendirdiğini iddia eden birkaç yöntemden biridir. Bu durumda zaman baskısı, bireysel yetenekleri ve görev taleplerini ölçülebilir bir miktar olarak yansıtır. Bilgi İşleme modeli iş yükünün kendisini ölçmez, ancak iş yükünün zaman baskısına eşit olduğunu ve hata oranlarının yalnızca zaman baskısına bağlı ilişkiler olduğunu varsayar. Bilgi İşleme modeli tek boyutlu bir ölçek olarak kabul edilebilmesine rağmen, genellikle iş yüküyle ilişkili diğer faktörleri dikkate alır ve bu faktörleri, ya yürütme süresini artırarak ya da miktarı azaltarak zaman baskısını hafifletmek için kullanır. Bilgi İşleme modeli, bilginin işlendiği insan bilişsel sisteminde her yerde geçerlidir [21, 22].

Derecelendirme ölçekleri genellikle sıralı yanıt kategorileri dizisinden oluşur. Ölçeklerdeki etiketler, uyaranlar ve tepkiler arasındaki uygunluğu tanımlar. Bununla birlikte, herhangi bir iş yükü ölçeğindeki değerler ile fiziksel dünyadaki belirli, ölçülebilir olaylar arasında doğrudan bir ilişki yoktur [16].

İş yükü tamamen nesnel görev talepleriyle tanımlanmadığından, aynı görev gereksinimleri ile karşı karşıya olan farklı bireylerin deneyimleri oldukça farklı olabilir. Ek olarak, insanlar bir derecelendirme verirken farklı değişkenleri dikkate alabilir (çünkü kişisel iş yükü tanımları değişir) ve farklı öznel önyargılar ifade edebilir [16].

Bu tür nicel öznel tekniklerin tekrarlına bilirliliği ve geçerliliği bazen belirsizdir. Derecelendirmelerin sıralı niteliği nadiren sorgulanırken, görünürde kesin bir sonuç olmaksızın çok tartışılan bir konu olmuştur [23].

1.5.2. Performans Ölçümleri

Bilişsel yorgunluk ve performans açıkça ilişkili olsa da, bu ilişkinin doğası basit değildir. Operatörler iş yükünü ve performansını birbirlerine karşı değiştirebilirler. Görev talepleri zamanla değiştikçe, operatörler çabalarını artırabilirler veya azaltabilirler. Görev talepleri çok olduğunda kritik görevlerde performansı düşürmemek için daha az önemli görevleri erteleyebilir ya da düşük iş yükü gerektiren bazı görevleri planlandıktan önce tamamlayabilirler. Bu nedenle, iş yükü ile performans arasındaki ilişki, operatörlerin benimsediği stratejilere ve daha iyi performans elde etmek için ek çaba göstermesinin yanı sıra göreve bağlıdır [16].

Birincil görev ölçü türlerine göre doğruluk, hız ve miktar olmak üzere üç performans ölçüsü sınıfı vardır. Doğruluk; hedef değere kıyasla kontrol hatasını, hız; saniye veya saniyenin kesirleri cinsinden ölçülen yanıt süresini, miktar; belirli bir süre içinde kaç görev veya görev ögesinin doğru şekilde tamamlandığını ifade eder. Doğruluk, operatörün davranışının ve sistemin birleşik çıktısını yansıtırken, hız operatör çabasını doğrudan ölçer. İş yükü değerlendirmesi amacıyla daha fazla hata, daha uzun yanıt süreleri, daha yüksek kontrol hatası ve tamamlanamayan görevler, artan iş yükünün kanıtı olarak alınır [16].

Cain'e göre, iş yükünün performans ölçüleri birincil görev ölçüleri ve ikincil görev ölçüleri olarak sınıflandırılabilir. Çoğu araştırmada, hizmet içi performans genelleştirilmesi çalışmanın merkezinde yer aldığından, birincil görevin performansı her zaman ilgi çekici olmuştur. İkincil görev yöntemlerinde, ikincil görevin performansının kendisinin pratik önemi olmayabilir ve yalnızca operatörün yükünü ölçmeye hizmet eder [21].

Kalsbeek'e göre, performans ölçümleri, zihinsel kapasitenin ölçülmesinden oluşan geleneksel yol ve tercih edilmesi gereken ana görevin basit, tekrarlayan bir görev olduğu deneylerde kullanılabilir. Örneğin, bir ikili görevde ikincil görev, performansı belirlemede bir stres koşulu olarak kabul edilebilir [24].

Rouse, performans ölçülerini kısa süreli ve uzun süreli ölçüler olarak sınıflandırmıştır. Burada kısa süreli performans mutlak iş yükünü yansıtmamaktadır. Bunu sonucu, belirli bir kontrol ve izleme görevinde, merkezi görevdeki kısa süreli performansın dikkat dağıtımı ile ilişkili olmadığını gösteren Enstrom ve Rouse'un çalışmasıyla desteklenmektedir [25, 26].

Colle ve Reid, ikincil görev performans ölçütlerinin kavramsal ve teorik ilgi olmasına rağmen özellikle operasyonel değerlendirmelerde, öznel ölçülerden daha az pratik olduğunu belirtmektedirler. Bu yüzden hassas ikincil görev önlemlerinin geliştirilmesi gerektiğini belirtmişlerdir [27].

Hart ve Wickens, birincil görev ölçümlerinin iş yükü değerlendirmesinde önemli olduğunu düşünmektedirler. Buna rağmen operatör başarısından ziyade sistemin neler başarabileceğinin bir ölçüsü olduğunu belirtmektedirler. Ayrıca iş yükü ile birincil görev performansı arasında bir ayrışmanın olduğunu belirtmektedirler [16].

Genel olarak yapılan çalışmalar incelendiğinde operasyonel performans ölçütlerinin gerekçelendirilmesi kolay olsa da, genellikle bilimsel titizlikten yoksundur. Bu yüzden sonuçların yorumlanmasını güçleştirir. Kontrolsüz ve bilinmeyen faktörler, denemelerde amaçlanan sonuçlara ulaşamamıza neden olabilir. Laboratuvarda yapılan çalışmalar deneysel kontrol sağlamasına rağmen operasyonel görev esnasındaki çevresel faktörlerden

yoksundur. Deneysel ve operasyonel deęerlendirmenin bir kombinasyonu genellikle en iyi yaklaşımdır. Bununla birlikte, görev performans ölçüleri, birçok tekrarlı yapıcı simülasyonlarda deęerlendirilebilen dięer operatör-durum faktörlerine dayalı tahmin modellerini varsaymak için anahtardır. Sanal simülasyonlar tipik olarak birkaç replikasyonla sınırlıdır ve bu nedenle orantılı olarak daha az koşulu dikkate alabilir [21].

1.5.3. Fizyolojik Yöntemler

1.5.3.1. Göz Hareketleri

Göz ölçümlerin kullanımı son yıllarda artmıştır ve bunun nedeni ölçüm kolaylığı ve aparat erişilebilirliğinin artması olmuştur. Ölçümler arasında göz kırpma hızı, göz kırpma süresi, göz kırpma gecikmesi ve göz bebeęi boyutu bulunur. Göz bebeęi çapı iki ile sekiz milimetre arasında deęişebilir. Göz bebeęi çapı kasılan ve genişleyen bir grup kas tarafından kontrol edilir. Bu yeteneğin temel işlevi, çeşitli koşullarda görmeye izin vermek, daha karanlık koşullarda göz bebeęinin çapını arttırmak ve ayrıca gözün odağı deęiştirmesini sağlamaktır [28].

Causse ve dięerleri yaptıkları çalışma ile ortalama göz bebeęi çapı deęişikliğinin, planlama ve yüksek görsel dikkat içeren bir karşılaştırma görevi sırasında, yüksek seviyelerde sözel çalışma belleęi gerektiren mantıksal bir karşılaştırma görevine kıyasla daha yüksek olduğunu ve katılımcının yaptığı hatalara duyarlı olduğunu görmüşlerdir [29]. Gao ve arkadaşları ise göz bebeęi çapı deęişikliğinin bir nükleer enerji santrali simülasyonu sırasında hata oranıyla yüksek düzeyde ilişkili olduğunu göstermişler ve bunun da bilişsel iş yükündeki bir artışı yansıtabileceęi sonucuna varmışlardır [30]. Recarte ve Nunes, gerçek bir sürüş görevi sırasında göz bebeęi çapında önemli farklılıklara yol açtığı görmüşlerdir [31]. Bununla birlikte, göz bebeęi çapındaki azalma ortam aydınlatmasındaki bir deęişikliğin sonucu olabileceğinden, göz bebeęi çapı ölçülerine dikkat edilmelidir [32].

Ryu ve Myung göz kırpma aralığının deneklerin izleme görevi için zihinsel çabalarını tahmin etmek için kullanılabileceğini, ancak aritmetik görev için kullanılamayacağını tespit etmişlerdir [33]. Veltman, simüle edilmiş uçuşla karşılaştırıldığında gerçek uçuş sırasında göz kırpma frekansında büyük bir artış gözlemlenmiştir. Bu, ortamdaki farklı görsel uyaranlar veya farklı ışık yoğunluğu gibi çeşitli nedenlerden dolayı olmuş olabilir. Ancak hem gerçek hem de simüle uçuş için göz kırpma süresinin azaldığı ve genliğin arttığı sonucuna varmıştır

[34]. Veltman ve Gaillard yaptıkları bir başka çalışmada katılımcıların yüksek görsel iş yüküne maruz kaldıklarında göz kırpma sıklığının ve süresinin azaldığı gösterilmiştir. Bu nedenle inceleme altındaki görev görsel olduğunda zihinsel iş yükünün bir ölçüsü olarak kullanılabilirliğini öngörmüşlerdir [35]. Brookings artan görsel talebin, bir hava trafik kontrol görevi sırasında olduğu gibi daha düşük göz kırpma oranları sağladığı gösterilmiştir [36]. Wilson, gerçek uçuşun görsel olarak zorlu bölümleri sırasında göz kırpma oranlarının azaldığını gözlemlemiştir [37].

Bilişsel iş yükü hakkında göz hareketlerinin ölçümleri zihinsel taleplere duyarlı olmakla birlikte, diğer faktörlere de duyarlıdır; özellikle yorgunluğa duyarlıdır. Ölçümler genellikle küçük hareketleri algılayabilen sabit bir sensör gerektirir, sahada ve hatta bazen vücut hareket ederken sensörün kafa üzerindeki hareketi nedeniyle laboratuvar da bile doğru ölçüm yapması zor bir durumdur [10].

1.5.3.2. Solunum

Solunum ölçümleri hız, hava akışı, hacim veya solunum gazı analizini içerir. Zihinsel iş yükünün ölçülmesi için solunum hızının ölçümü, solunum ölçümlerinde en yararlı olanıdır [38]. Solunum hızının elektrofizyolojik yöntemlerle ölçülmesi kolaydır, ancak göğüs etrafına bir kayış yerleştirilerek ve kayış gerginliğindeki artışı ve azalmayı izleyerek nefes hızını ölçmek için de gerilim ölçümleri kullanılabilir. Hava akışı veya gaz analizi ölçümleri, burun ve ağız üzerine bir maske yerleştirilerek yapılabilir [28].

Simüle edilmiş hava trafik kontrolü sırasında zorluk arttıkça solunum hızının daha yüksek olduğu [36], Backs ve diğerleri tarafından da gözlemlenen bir bulgu olarak bulunmuştur [39]. Solunum hızının, üç hava trafik kontrol senaryosu sırasında gerçek koşuldan kayda değer ölçüde daha yüksek olduğunu ve iş yükü koşullarında önemli ölçüde farklılık gösterdiğini bulmuşlardır. Ek olarak, Brookings ve arkadaşları görev daha zor hale geldikçe ve solunum hızı arttıkça göz kırpma hızında bir düşüş gözlemlemiştir [36]. Ayrıca Brookings ve arkadaşları, hava trafik kontrol görevi sırasında kalp atış hızı ve solunum hızında ilişkili herhangi bir değişiklik gözlemlememişler, ancak görev zorluğu arttıkça solunum hızı daha yükseldiğini fark etmişlerdir [36]. Backs ve arkadaşları görevin zorluğu arttıkça metabolik hızın arttığını bulmuşlar, ancak aynı zamanda daha kötü performans gösterenlerde metabolik hızın daha yüksek olduğunu saptamışlardır [39].

Stres ve iş yükü arttıkça solunum hızının arttığı ve solunum hacminin azaldığı görülürken, bu ölçü büyük ölçüde fiziksel aktiviteye bağlıdır [40]. Bu nedenle, çaba gerektiren görevler bu tür analizlere uygun değildir. Maskelerin ağız ve buruna takılmasını gerektiren gaz analizi yöntemleri, uygulanan ortamlarda yararlı değildir ve birincil görev performansını etkileyebilir. Bir istisna, çalışmalarını sırasında sıklıkla oksijen maskesi takan askeri pilotlar olabilir, bu nedenle bu durumda hava akışını ve solunum gazlarını ölçmek birincil görevi engellemez. Solunum ölçümleriyle ilgili başka bir husus, konuşmanın gerekli olduğu zamandır. Konuşma üretimi solunum modellerini kesintiye uğratabilir ve modifiye ederek zihinsel iş yükü ile ilgisi olmayan solunum hızında değişikliklere yol açabilir [38, 41, 42]. Solunum ölçümlerinin birkaçı çok az müdahaleyle ölçülebilir. Stres ve zihinsel iş yükü arttıkça solunum hacmi azalırken solunum hızının arttığı gözlemlenmiştir, ancak solunum hızı ve hacmi fiziksel aktiviteye de büyük ölçüde bağlı olduğundan dolayı operatör durumu hakkında yararlı bilgiler sağlarken, tek başına uygun bir iş yükü ölçüsü olmadığı anlaşılmaktadır [28].

1.5.3.3. Kan Basıncı

Kan basıncı, vücutta dolaşan kanın kan damarlarının duvarlarına uyguladığı basıncın bir ölçüsüdür. Kan basıncı genellikle kalp kasının kasılıp gevşemesi sırasında uygulanan basınç olarak ifade edilir. Veltman ve Gaillard, kan basıncındaki bir artışı, artan görev yükü ile ilişkilendirmişler ve çalışma ile dinlenme süreleri arasında farklı olduğunu göstermişlerdir. Deneyimli pilotlar ile simüle edilmiş bir uçuş görevi sırasında kan basıncı değişkenliğinin, uçuş bölümleri arasında önemli ölçüde farklılık gösterdiği saptamışlardır [35]. Bununla birlikte, Hwang ve arkadaşları bir nükleer izleme görevi giderek karmaşık hale geldiğinde, kan basıncının arttığını saptamışlardır [43]. Finsen ve arkadaşları ise kontrollü deneysel koşullar altında, bir bilgisayar görevine bellek yükünü içeren ikincil görevlerin eklenmesinin kan basıncını önemli ölçüde artırdığını gözlemlemişlerdir [44]. Causse ve arkadaşları yaptıkları çalışma ile yüksek düzeyde sözel çalışma belleği gerektiren mantıksal bir muhakeme görevi ile planlama ve yüksek görsel dikkat içeren akıl yürütme görevini karşılaştırmışlar ve sözel çalışma belleği gerektiren görev sırasında kan basıncının yükseldiği sonucuna varmışlardır.

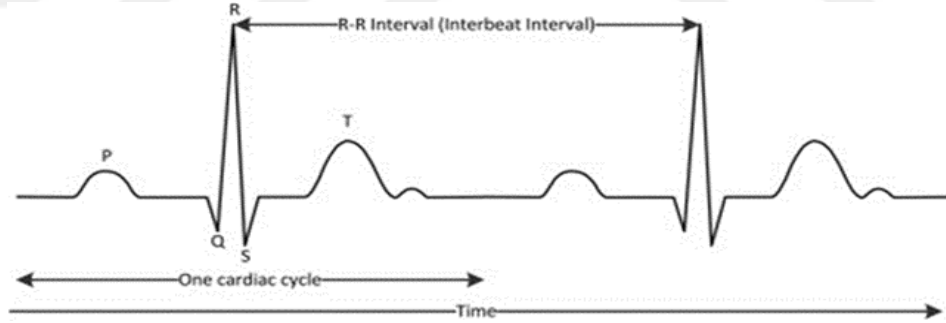
Bernardi ve arkadaşları kendiliğinden nefes alma durumuyla karşılaştırıldığında, sessiz okumaya karşı yüksek sesle okumanın kan basıncında bir artışa neden olduğunu

görmüşlerdir. Bu artış, hem sessiz hem de yüksek sesle zihinsel bir aritmetik görev sırasında önemli olmuştur [41]. Boutcher siyah-beyaz ve sözel olmayan Stroop görevine göre geleneksel Stroop görevi (sözel) sırasında ortalama arter basıncının daha yüksek olduğu gözlemlenmiştir [45]. Bu durum kalp atış hızı değişkenliğinin orta frekansta nefes alıp verme ve buna bağlı olarak kan basıncıyla ilgili konuşma üretiminden etkilenmesi ile tutarlıdır.

Yapılan çalışmalara bakıldığında kan basıncının zihinsel taleple ilişkili olduğu görülmektedir, ancak çok hassas görünmüyor ve fiziksel aktivite, stres, uyku, sindirim ve konuşmadan bile büyük ölçüde etkilenmektedir. Kolayca ve sıklıkla ölçülmesine rağmen, kan basıncı zihinsel iş yükünün ölçümünde sağlıklı sonuçlar sağlamamaktadır.

1.5.3.4. Elektro Kardiyak Aktivite

Elektrokardiyografi (EKG) teknikleri, bir dizi sensör kullanarak kalbin elektriksel aktivitesini ölçer. Kalpten gelen elektrik sinyali Şekil 1.8’de gösterilmektedir. Klinik amaçlar için on iki sensöre kadar kullanılabilir. Tüketici uygulamaları için iki sensör yeterli olabilir.



Şekil 1. 8. Kalp döngüsü

Bu tekrarlayan elektrik sinyali, vücuda kan pompalamak için gerekli olan kalbin polarizasyonunu ve depolarizasyonunu temsil eder. Tek bir kardiyak döngünün unsurları P-Q-R-S-T olarak adlandırılır. Bu dalga ile ilişkili farklı önlemler, zihinsel iş yükü hakkında fikir veren kardiyak aktiviteyi karakterize etmek için kullanılabilir [28].

EKG teknikleri kullanılarak ölçülen kardiyak aktivite, zihinsel iş yükünün en yaygın kullanılan fizyolojik ölçüsüdür. Kalp atış hızı artan görev talepleri ile artar [32]. Sosnowski ve arkadaşları, bir dizi öğenin mantıksal olarak tamamlanmasını gerektiren görevlere kıyasla, problem çözmeyi gerektiren görevler sırasında kalp atış hızında daha büyük bir artış

olduğunu görmüşler [46]. Veltman ve Gaillard, simüle edilmiş bir uçuş görevi sırasında bir görev daha zor hale geldikçe normal aralıklarda sistematik bir düşüş gözlemlemişler. Görev zorluğu değişmezken diğer kardiyovasküler ölçümler görevler arasında farklılaşmıştır [47]. Bacs hava trafik kontrolünde deneyimi olmayan katılımcılar ile yaptığı çalışma da; düşük görev yükü senaryosuna kıyasla yüksek görev yükü simüle edilmiş hava trafik kontrol senaryosu sırasında daha yüksek kalp atış hızı gözlemlemiştir [39].

Frekans alanında, Veltman ve Gaillard orta frekans bandının zihinsel iş yükündeki değişikliklere en duyarlı olduğunu ve bu bant içindeki güçte bir azalmanın zihinsel iş yükündeki artışı yansıttığını belirtmişlerdir [47]. Tattersall ve Hockey bir izleme görevi sırasında; stajyer uçuş mühendislerini simüle edilmiş bir uçuş sırasında hataları tespit ederken ve düzeltirken gözlemlemiştir. Uçuşun problem çözme unsurları sırasında orta frekans bandındaki kalp atış hızı değişkenliğinin bastırıldığını bulmuşlardır [48]. Fallahi ve arkadaşları ise kalkış ve iniş aşamalarında yüksek kalp atış hızı tespit etmişler ve bir trafik izleme görevi sırasında koşullar düşük trafik yoğunluğundan yüksek trafik yoğunluğuna geçtiğinde kalp atış hızı değişkenliği etkilenmiştir [49].

Yüksek frekans bandı ve orta frekans bantları solunumdan etkilenir [35] ve bu, Gao ve arkadaşları tarafından, karmaşık bir görev sırasında kalp atış hızı değişkenliğinin arttığı bulgusunun olası bir açıklaması olarak gösterilmiştir [30]. Görevler sırasında derin, yavaş nefes alma, yüksek banttaki kalp atış hızı değişkenliğini artırabilir [47]. Veltman ayrıca, solunum aktivitesine atfedilen zamanla grafiğe çizildiğinde kalp hızı değişkenliğinde dalgalanmalar gözlemiştir ve solunum frekansı azaldığında ve genlik arttığında orta frekans varyasyonunda artışlar olduğunu göstermiştir [34]. Zihinsel aritmetik bir görev sırasında, konuşma olduğunda değişkenlik artmış ve nefes alma hızı azalmış [41], konuşma olmadığında ise tersine dönen bir etki olmuştur. Miyake, bu etkiyi denemek ve en aza indirmek için, katılımcılara bilişsel görevler sırasında nefeslerini sesli bir tonla senkronize etmeleri talimatını vermiştir [50].

Nickel ve Nachreiner, kalp hızı değişkenliğini karakterize etmek için kullanılan orta frekans bileşeninin, zihinsel iş yükünü değerlendirmek için yeterli hassasiyetten ve teşhisten yoksun olduğu sonucuna varmışlardır. Orta frekans bileşeninin, sadece çalışma seviyeleri ile dinlenme seviyeleri arasında ayırım yapmak için uygun olduğunu veya kalp atış hızı değişkenliğine yansımaları için görevler arasında büyük farklılıklar olması gerektiğini belirtmişlerdir [47, 51]. Ryu ve Myung yaptıkları çalışma ile orta frekans bandındaki kalp

atış hızı değişkenliğinin, izleme görevinin zorluğu ile ilişkili olduğunu bulmuşlar, ancak ikincil bir zihinsel aritmetik görev eklendiğinde hassas olmadığını fark etmişlerdir [33].

Orta frekans bandının genel olarak görev zorluğuna en duyarlı olduğu görülmüştür. Bununla birlikte, orta frekans bandı, düşük ve orta seviyelerdeki görev talepleri arasında ayırım yapar, ancak yüksek seviyelerde arasında ayırım yapmaz [32]. Orta frekans bandındaki kalp atış hızı değişkenliğinin performanstaki farklılıkları veya algılanan görev zorluğunu yansıttığı görülmemiştir [51]. Orta ve yüksek banttaki kalp atış hızı değişkenliği de segmentler arasında farklılık göstermiştir [35]. Wilson, gerçek uçuş için kalp atış hızının, kalp atış hızı değişkenliğinden daha hassas olduğu sonucuna varmıştır [37] ve Veltman, bir uçuş çalışması sırasında kalp atış hızı değişkenliğinin gerçek ve simüle uçuş arasında farklı olmadığını bulmuştur [34].

Kardiyovasküler ölçümler için önemli kullanım konuları, alan ve ölçüm uzunluğudur. Zaman alanı ölçümlerini kullanırken, tüm kayıtların aynı uzunlukta olması gerekir. Ek olarak, kardiyoloji görev gücü, kayıt uzunluğunun örnekleme oranının 10 katı olmasını tavsiye eder. Örnekleme hızı önemlidir ve 250–500 MHz aralığı önerilir. Frekans alanında, kalp atış hızı değişkenliğinin varyansı, kayıt uzunluğu ile orantılı olarak artar. Bu nedenle, spektral bileşenlerin kısa ve uzun vadeli analizleri her zaman ayırt edilmelidir. Ek olarak, kullanılan frekanslar açısından farklı çalışmalarda değişkenlik vardır. Bu farklılıklar, çalışmaların doğrudan karşılaştırılmasını daha zor hale getirir [52].

1.5.3.5. Elektroensefalogram

Bilişsel yükü nesnel ve sürekli olarak ölçme ihtiyacı, öznel ölçülere alternatif yöntemlerin araştırılmasını teşvik etmiştir. Nesnel ölçümlerle ilgili olarak araştırmacılar, bilişsel yükü yansıtan fizyolojik aktivitelerdeki değişiklikleri tespit etmek fizyolojik bir yöntem bulmak istemişlerdir. Böyle bir fizyolojik yöntem, salınımlı beyin aktivitesini EEG yoluyla ölçmektir [63–66]. Kapsamlı bir araştırma grubu, bilişsel sinirbilim alanındaki biliş ve dikkat mekanizmalarını araştırmak için beyin salınımlarının işlevsel önemini göstermiştir [63, 67, 68]. Dahası, EEG ekipmanındaki teknolojik gelişmeler ve EEG veri analizlerini kolaylaştırmak için program ve yazılımın mevcudiyeti, gerçeğe dayalı öğrenme bağlamlarında bilişsel işlemenin sinirsel ilişkilerini inceleme potansiyelini genişletmiştir [69]. Bilişsel yükün bir ölçüsü olarak, EEG'nin birçok avantajı vardır. Birincisi, katılımcıların hareketsiz kalmasını gerektiren ve bu nedenle öğrenme senaryolarında

kullanımlarını sınırlayan diğer nörogörüntüleme tekniklerinden farklı olarak EEG, bir bireyin beyindeki elektriksel aktiviteyi noninvaziv olarak toplayabilir [64, 65]. İkincisi, bilişsel yükün göz bebeği genişleme ölçüsü ile karşılaştırıldığında EEG, göz bebeği boyutunu etkileyecek olan ortamdaki değişikliklere daha az duyarlıdır [54]. Ayrıca, EEG, beyin elektrik aktivitesindeki değişiklikleri milisaniye ölçeğinde yansıtmasına olanak tanıyan yüksek zamansal çözünürlük sağlayan bir bilişsel yük ölçüsü olarak çalışabilir [55]. Bu avantajlar EEG'yi bilişsel yorgunluğun umut verici bir ölçüsü haline getirmektedir. Bütün bu konular ele alındığında EEG verileri ile oldukça fazla çalışma yapılmış, çok farklı analizler denenmiş ve yeni teknikler önerilmiştir.

Tuncer ve arkadaşları sürücülerde bilişsel yorgunluğun tespiti için bir şema önermişlerdir. Önerilen şema, ön işleme, özellik oluşturma, bilgilendirici özellik seçimi ve sığ sınıflandırıcı aşamaları ile sınıflandırmayı içermektedir. Ön işlemede, ayırık kosinüs dönüşümü ve hızlı Fourier dönüşümü birlikte kullanılmıştır. Ayrıca, dinamik merkez tabanlı ikili desen ve çok eşikli üçlü desen, yeni bir özellik oluşturma ağı oluşturmak için birlikte kullanılmıştır. Özellik seçim aşamasında, üç katmanlı bir hibrit özellik seçme yöntemi sunmuşlar ve önerilen yöntemin gücünü göstermek için sınıflandırma aşamasında kıyaslama sınıflandırıcılar kullanmışlardır. Deneylerde, önerilen çerçeve ile EEG sinyallerini kullanarak yorgunluk tespiti için % 97.29 sınıflandırma doğruluğuna ulaşmışlardır [53]. Bhardwaj ve arkadaşları ise makine öğrenimi ve derin öğrenme algoritmalarını kullanarak yorgunlukla ilgili yol kazalarının oranını azaltabilen, oldukça hassas, EEG tabanlı bir sürücü yorgunluğu sınıflandırma sistemi önermişlerdir. Sonuçlar, teta, alfa, beta ve deltanın göreceli gücünün, sürücü yorgunluğu ile önemli bir korelasyon gösterdiğini göstermiştir. Seçilen özellikler, sürücü yorgunluğu alanında iyi bilinen 20 sınıflandırıcı kullanılarak eğitilmiş ve değerlendirilmiştir. Deep Autoencoder ve k-EYK algoritmaları ile sırasıyla % 99.7 ve % 99.6 doğruluk elde etmişler [54]. Chai ve arkadaşları ise bu konuda 43 sağlıklı katılımcıdan sürücü yorgunluğunu sınıflandırmak için iki sınıflı bir EEG tabanlı sınıflandırma sunmuşlardır. Sistem, kaynak ayırma için entropi oranına bağlı minimizasyon analizi, özellik çıkarımı için otoregresif modelleme ve sınıflandırma algoritması için Bayesian sinir ağı ile bağımsız bileşen kullanmışlardır. Sınıflandırma sonuçları % 89.7'lik bir duyarlılık, % 86.8'lik bir özgüllük ve % 88.2'lik bir doğruluk göstermiştir [55]

Setiawan ve arkadaşları yaptıkları çalışma ile EEG ölçümü sırasında yorgunluk durumunu provoke etmedeki zorluk nedeniyle, zihinsel yorgunluğu tespit etmek için iki deneysel tasarım önermişlerdir. İlk tasarımda fiziksel indüksiyon (Fİ) ve 2. tasarım zihinsel

indüksiyon (Zİ) kullanmışlardır. EEG sinyallerini 20 sağlıklı katılımcıdan, 14 kanallı kablosuz EEG kulaklık ile toplamışlar. Her katılımcıdan Trail, Span, Stroop ve aritmetik dâhil olmak üzere bir bilgisayar oyunu biçiminde dört tür bilişsel test gerçekleştirmesini istemişlerdir. Yorgunluk durumunun öznel ölçümünü, İsveç Mesleki Yorgunluk Envanteri anketleri kullanılarak ölçmüşlerdir. Sınıflandırma işleminde ise İlişki Vektör Makinesi yaklaşımını kullanmışlardır. Sonuçlara göre, tüm bilişsel testler, indüksiyon öncesine göre indüksiyon sonrası ortalama yanıt süresi değerini artırmış ve düzeltme skorunu sonucuna ulaşımlardır. Başka bir sonuç, en iyi zihinsel yorgunluk tespitinin fiziksel indüksiyondan ziyade zihinsel indüksiyonla elde edildiğini tespit etmişlerdir. Sınıflandırma sonuçları % 93.7 (Zİ) ve % 92.6 (Fİ) doğruluk elde etmişlerdir [56].

Dehais ve arkadaşları zihinsel yorgunluk ve zihinsel aşırı yükün elektrofizyolojik ilişkilerini sırasıyla 32 kanallı kuru bir EEG sistemi ile ölçmek için gerçek uçuş koşulları altında iki deney gerçekleştirmişlerdir. Zihinsel yorgunluğun ortaya çıkmasının daha yüksek teta ve alfa bandı gücü ile ilişkili olduğunu ortaya koymuşlardır. Zihinsel yorgunluğu ve aşırı yük durumlarını tespit etmek için tek bir deneme sınıflandırması yapmışlardır. Sınıflandırma doğruluğu, zihinsel yorgunluğa karşı yorgunluk ve zihinsel aşırı yük ile düşük-yüksek yük arasındaki farkı ayırt etmede sırasıyla % 76.9 ve % 89.1'e ulaşmışlardır [57].

Myrden ve Chau zihinsel durumdaki değişiklikleri tek bir deneme temelinde izlemek için EEG kullanan pasif bir beyin-bilgisayar ara yüzünün fizibilitesini araştırmışlardır. On bir sağlıklı yetişkin bireyden bir dizi zorlu zihinsel görev tamamlamalarını istemişler ve 15 lokasyondan kortikal aktiviteyi kaydetmişlerdir. EEG sinyal özelliklerinde fazlalığı hesaba katmak için bir özellik kümeleme algoritması kullanarak, kendi kendine bildirilen yorgunluk, hayal kırıklığı ve dikkat seviyelerindeki değişiklikleri sırasıyla % 74.8 ± 9.1 , % 71.6 ± 5.6 ve % 84.8 ± 7.4 doğrulukla sınıflandırmışlardır [58].

Chai ve arkadaşları EEG tabanlı bir sınıflandırma sisteminin, zorlu bilgisayar görevlerinden kaynaklanan bilişsel yorgunluğu tespit etmek için bir araç olarak kullanabileceğini öne sürmüşlerdir. Yaptıkları çalışmada bilişsel olarak zorlu görevler sırasında bilişsel yorgunluğun sınıflandırılmasında en iyi özellik çıkarıcıyı bulmak için güç spektral yoğunluğu ve üç alternatif özellik çıkarma yöntemini araştırmışlardır. Karşılaştırılan bu yöntemler güç spektral entropisi, dalgacık ve otoregresiftir. Bu çalışmada sınıflandırıcı olarak Bayes sinir ağı kullanmışlardır. Sonuçlar, güç spektral yoğunluğu ve güç spektral entropisi yöntemlerinin kullanımının her bilgisayar görevi için ortalama % 60 doğruluk sağladığını göstermiştir. Bu bulgu, ortalama doğruluğu % 61 olan dalgacık yöntemi

kullanılarak biraz iyileştirmişlerdir. Otoregresif yöntemi, bu çalışmada AX-sürekli performans testinde % 75.95, psikomotor uyanıklık testinde % 75.23 ve Stroop'ta % 76.02 doğrulukla güç spektral yoğunluğu, güç spektral entropisi ve dalgacık ile karşılaştırıldığında en iyi özellik çıkarıcı olduğunu tespit etmişlerdir [59].

Dimitrakopoulos ve arkadaşları daha doğru sürekli yorgunluk seviyesi tahmini sağlamak için regresyon rastgele orman modeli kullanmışlardır. Çok bantlı güç özellikleri, bir saatlik simüle edilmiş sürüş görevinden kaydedilen EEG verilerinden çıkarmışlar daha sonra yorgunlukla ilgili yaygın ayırt edici özellikleri elde etmek için denekler arası regresyon gerçekleştirilmişlerdir. Tatmin edici bir tahmin doğruluğu elde etmişler ve eşzamanlı olarak gerekli elektrotları en aza indirerek 3 elektrotlu bir set kullanmayı önermişlerdir [60].

Qu EEG sinyallerinin özelliklerini ayırt etmek için karışık sinyalleri doğrudan analiz etmenin doğru olmadığını düşündüğü için karışık konuşma sinyallerinin kör kaynak ayırma fikrinden yola çıkarak EEG bağımsız bileşenler özelliklerine dayalı bir zihinsel iş yükü sınıflandırma yöntemi önermiştir. Bu yöntemde, saf sinyaller elde etmek için bağımsız bileşen analizi kullanılır. Bağımsız bileşenlerin enerji özellikleri, zihinsel iş yükünü sınıflandırmak için doğrudan çıkarılır, çünkü bu yöntem, özellik çıkarma için doğrudan bağımsız bileşenlerin enerji özelliklerini kullanır. Mevcut çözümle karşılaştırıldığında, önerilen yöntem ile daha iyi sınıflandırma sonuçları elde edildiği görülmüştür [61].

Veri setini kullandığımız Papakostas ise bilişsel yorgunluğun tespiti için 6 kadın ve 13 erkekten oluşan 19 katılımcıya Wisconsin Kart Eşleme Testi ve bu testin değiştirilmiş versiyonunu uygulayarak 76 oturumdan oluşan bilişsel görev gerçekleştirmelerini istemiştir. Görev sırasında EEG sinyallerini kaydetmiştir. Kaydettiği bu EEG'ler ile ortalama değer, standart sapma, maksimum değer, minimum değer, spektral sentroid ve spektral rollof parametrelerini kullanarak öznitelik çıkarma işlemi yapmıştır. 10 kat çapraz doğrulama yapılarak verileri belirlenmiştir. DVM algoritması ile sınıflandırma yapmış ve ortalama % 67'lik bir doğruluk elde etmiştir [2]. Ekim ve arkadaşları aynı veri seti (CogBeacon) ile yaptıkları çalışmada ham EEG'ler rastgele ayırarak öznitelik çıkarma işlemi yapılmıştır. Sınıflandırma işleminde DVM ve k-EYK algoritmaları kullanılmıştır. Öznitelik olarak klasik EEG öznitelik çıkarma teknikleri olan Katz ve Higuchi Fraktal Boyut, standart sapma, medyan, varyans ve kovaryans denenmiştir. DVM ile sınıflandırılma yapıldığında test ortalaması %83.14 elde edilmiştir. k-EYK ile sınıflandırma yapıldığında test ortalaması %83.34 elde edilmiştir [62].

2. YAPILAN ÇALIŞMALAR


2.1. CogBeacon Veri Kümesi

Çalışmamızda zihinsel faaliyetlerde bilişsel yorgunluğun tespiti için kaydedilmiş olan CogBeacon veri seti kullanılmıştır. Veri seti 4 elektrotlu MUSE EEG cihazı yardımı ile kaydedilmiştir. Bu veri seti deneysel psikoloji alanında önemli bir yere sahip olan Wisconsin Kart Eşleme Testi (WKET) ilkelerini temel almaktadır. Bahsi geçen bu ilkeler 6'sı kadın 13'ü erkek olmak üzere 19 sağlıklı katılımcı üzerinde denenmiş 76 bilişsel görevden oluşmaktadır. Kullandığımız veri seti çevrim içi olarak bulunabilir (https://github.com/MikeMpapa/CogBeacon-MultiModal_Dataset_for_Cognitive_Fatigue).

2.1.1. MUSE EEG Cihazı

Elektroensefalogram kulaklıklarının artan kalitesi ve uygun fiyatı, tıbbi sınıf cihazların pratik olmadığı durumlarda bu cihazları çekici kılmaktadır. Bu sayede bilişsel durumları tahmin etmek ve izlemek, daha önce EEG izleme için elverişli olmayan görevler için mümkün kılmaktadır [63].

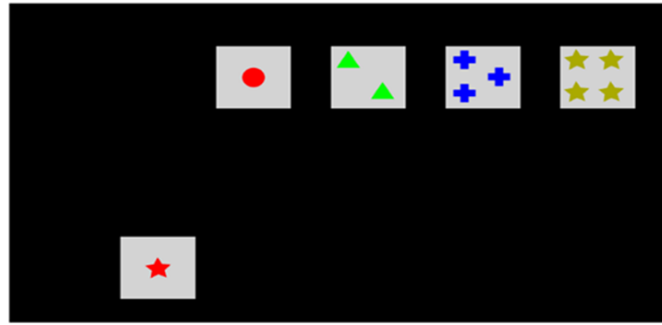
MUSE, dünya çapında sinirbilim araştırmacıları tarafından yaygın olarak kullanılan bir EEG cihazıdır. Giyilebilir bir cihaz olan MUSE EEG cihazının ham EEG aktivasyonu 220 Hz örnekleme hızındadır. İki tane prefrontal lobun üzerinde ve ikisi kulakların arkasında olmak üzere dört elektrota sahiptir. Cihaza gömülü dijital sinyal işleme üniteleri sayesinde EEG frekans bantlarından çıkarılan bilgiler ve özellikler, yani gama 32–100 Hz (γ), beta 13–32 Hz (β), alfa 8-13 Hz (α), teta 4–8 Hz (θ) ve delta 0,5–4 Hz (δ) 10 Hz'lik bir örnekleme oranında kaydedilebilir [64].



Şekil 2. 1 MUSE EEG cihazı

2.1.2. Wisconsin Kart Eşleme Testi


Wisconsin Kart Eşleme Testi (WKET), deneğin sembollerinin rengine, miktarına ve şekillerine göre farklı kartları eşleştirmesini gerektirir ve genellikle EEG bilişsel çalışmalarında uygulanır [65].



Şekil 2. 1. Wisconsin Kart Eşleme Testi görseli

WKET, üç kategoriye göre farklılık gösteren dört kart destesinden oluşur: renkler (kırmızı, yeşil sarı ve mavi), şekiller (üçgen, yıldız, çarpı ve daire) ve sembol sayısı (1'den 4'e kadar). Ekranın altında bir kart görüldüğünde, bu kart üç kategoriden birini izleyen dört desteden biriyle eşleştirmelidir. Denek, kullanılan kategoriye göre kartla eşleşen desteye dokunmalıdır. Her cevaptan sonra deneğe geri bildirim ('doğru' veya 'yanlış') verilir. Denek

kategoriyi (örneğin sembol, renk veya sayı) keşfettiğinde, 10 doğru kart eşleşmesinden sonra meydana gelen değişime kadar onu takip etmelidir. Kullanımdaki kategori değiştiğinde, denek her zaman öncekinden farklı olan yeni kategoriyi keşfetmelidir [66].



Şekil 2. 2. Her deneğin seçiminden sonra sistem tarafından sağlanan geri bildirim

WKET' de dikkate alınan performans ölçüleri şu şekildedir: tamamlanmış kategoriler, kalıcı hatalar ve kalıcı olmayan hatalar. Tamamlanan kategorilerin sayısı, deneğin 'doğru' geribildirim on katı geri bildirim aldığı kategori sayısını gösterir. Kalıcı hatalar, denek kural değişikliğinden önce kullanılan kategoriye göre cevap vermeye devam ettiğinde ortaya çıkar. Kalıcı olmayan hatalar iki tür hata kümesidir: verimli ve dikkat dağıtıcı. Verimli hatalar, denek 10 doğru kart eşleşmesinden sonra ilk önce olumsuz bir geri bildirim aldığı anda yeni bir kategori keşfetme stratejisiyle ilgilidir. Dikkat dağıtıcı hatalar, denek kullanımdaki kategoriyi keşfettikten sonra yanlış bir şekilde bir kart seçtiğinde ortaya çıkar [65].

2.1.3. Veri Toplama Süreci

Kullandığımız veri seti 19 ile 33 yaşları arasındaki 19 sağlıklı katılımcıdan oluşmaktadır. Toplamda 6 kadın ve 13 erkek katılımcıdan veri toplanmıştır. Bir deneyin toplam süresi, genellikle 25-30 dakika arasında değişmektedir. Deneyde kullanılan WKET testini katılımcılar daha önce denememiştir. Bu süre boyunca, aşağıdaki adımları anlamak ve tamamlamak için her kullanıcının dikkatli olması gerekmektedir [2].

Adım 1: Araştırmacı tarafından açıklanan orijinal WKET görevinin talimatları anlatılmıştır (~ 5 dakika).

Adım 2: Orijinal WKET uygulaması gerçekleştirilmiştir (~ 4 ila 7 dakika).

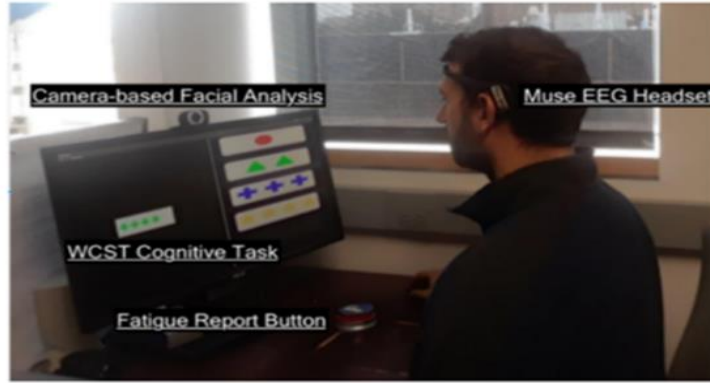
Adım 3: Öznel yorgunluğu bildirmek için görev tamamlandıktan sonra bir anket yanıtlandırılmıştır (~ 2 dakika).

Adım 4: Araştırmacılar tarafından değiştirilmiş WKET (V1 veya V2) görevinin talimatları anlatılmıştır (~ 3 dakika).

Adım 5: WKET' nin değiştirilmiş sürümünün gerçekleştirilmesi istenmiştir (~ 7 ila 9 dakika).

Adım 6: Deneyin tamamlanmasından sonra öznel yorgunluğu bildirmek için bir anket yanıtlandırılmıştır (~ 2 dakika).

Deney sırasında katılımcılara dinlenme süresi verilmemiştir yani her bir adım bir önceki bittikten hemen sonra başlamıştır.




Şekil 2. 3. Veri toplama deney düzeni

Veri toplama süreci iki oturumdan oluşmaktadır. Katılımcılar her iki oturuma da katılmak zorundadır ve oturumlar farklı günlerde gerçekleştirilmiştir. Her iki oturum da iki ana bölümden oluşmaktadır. Her iki oturumda da aynı olan ilk bölümde, katılımcılardan orijinal WKET' de açıklanan aynı kural ve yönergeleri izleyen bilişsel oyunu oynamaları istenmiştir. Deneyin birinci bölüm, her turda 4 uyarıcı kart ile toplam 60 turdan oluşmaktadır ve eşleştirme kuralı her 6 saniyede bir değişmektedir. İlk bölümün tamamlanmasından hemen sonra gerçekleşen ikinci bölüm, değiştirilmiş sürümlerden biri olan V1 veya V2'yi oynatılmaktadır. İki oturum arasındaki temel fark, görevin ikinci kısmındadır. İlk oturumun ikinci bölümünde, kullanıcılardan WKET' nin V1 sürümünü oynamaları, ikinci oturumda ise V2 oynamaları istenmiştir [2].

Tablo 2. 1. CogBeacon veri kümesine dâhil edilen toplam WKET görevi sayısı.

	Kişi	Bölüm	Bilişsel Görev
Orijinal WKET	19	2	38
V1-WKET	19	1	19
V2-WKET	19	1	19
Toplam			76

Kullanıcıları yormak için, kullanıcı katılımı ve dikkatine göre genel karmaşıklığı ve oyun taleplerini artırmayı amaçlayan orijinal görevin iki alternatif versiyonunu geliştirilmiştir. İlk sürümde (V1), test sadece iki olası seçenek sunarak başlar (orijinal görev tarafından sağlanan standart dört seçeneğe karşı). Test ilerledikçe, olası seçenek sayısı, toplam beş olası seçeneğe ulaşıncaya kadar kademeli olarak bir artmaktadır. İkinci sürümde (V2), olası seçimlerin sayısı, karar kuralı değiştiğinde rastgele değişir. V1'de olduğu gibi, V2 için minimum seçenek sayısı iki ve maksimum seçenek sayısı beştir. Her iki değiştirilmiş sürümde de toplam tur sayısı orijinal WKET' ye kıyasla neredeyse iki katına çıkmıştır (60 tur olan orijinal WKET: V1' de 120, V2' de 128 tura çıkmıştır). Karar kuralı daha sık değişmiştir (orijinal WKET' deki her 6 saniyede bir değişen kural V1 ve V2' de 4 saniyede bir değişmiştir.) ve maksimum yanıt süresi 2 saniye azalmıştır. İkinci bölüm olarak V1 ve V2' testlerinin uygulanmasının amacı kullanıcıyı daha önce yaşadıklarına benzer ancak aynı olmayan bir olaya maruz bırakarak kullanıcının uyum sağlayabilmesi için dikkat etmesi istenmiştir [2].



Şekil 2. 4. WKET uygulaması

Bilişsel yorgunluğun oluşmasından sorumlu tek faktör olarak görev süresinin düşünülmemesi gerekmektedir. Değiştirilmiş sürümler (V1-V2), görevin parametrelerini değiştirerek zihinsel çabayı artırmak için tasarlanmıştır bundan dolayı bilişsel yorgunluğu artırmada önemli bir rol oynamaktadır. WKET gibi tekrarlayan ve monoton görevler, uyarılma düzeylerini düşürme ve bilişsel yorgunluğu başlatma eğilimindedir. CogBeacon verisi bilişsel yorgunluk oluşumunu gerçek zamanlı olarak gözlemlemek için bir araç görevi görmektedir [2].

Her test sırasında, katılımcılardan önlerine yerleştirilen bir düğmeye basarak, göreve ayak uydurmakta zorlandıkları zaman bildirmeleri istenmiştir. Bir oyun sırasında herhangi bir zamanda katılımcılar istedikleri kadar düğmeye basabilmektedirler. Katılımcın düğmeye basması kullanıcının test tarafından bunalmış hissettiğinin bir göstergesi olarak kabul edebilir ve dikkatini verememesi, can sıkıntısı, doğru karar kuralını hatırlama veya çözüme zorluğunun bir sonucu olabileceği anlamına gelmektedir. Katılımcının öznel görüşü potansiyel olarak görev performansını etkileyebilmektedir. Kullanıcının düğmeye basması (yukarıda belirtilen tüm nedenler / koşullar) bilişsel yorgunluğun göstergeleri olarak kabul edilmiştir [2].

Yapılan deneyin katılımcılara bilişsel yorgunluk indükleyebildiğini doğrulamak için, oturumun tamamlanmasından sonra bir anket doldurmalarını istenmiştir. Verdikleri yanıtlara göre, deneye başlamadan hemen önce hissettiklerine kıyasla sürecin sonunda daha yorgun olduklarını bildirmişlerdir. Ayrıca çoğu katılımcı, oyunun değiştirilmiş sürümlerinin sunduğu değişen sayıdaki seçeneğe uyum sağlamak için daha fazla çaba sarf etmeleri gerektiğini öne sürmüşlerdir [2].

Yukarıda bahsedildiği gibi, genel veri toplama sürecinin ve orijinal görevdeki değişikliklerin gerçekten de katılımcılar için bilişsel çaba açısından zorlu bir ortam yaratılabildiğini göstermektedir. Bu bulgular, testi gerçekleştirirken kullanıcılar tarafından gerçek zamanlı olarak sağlanan öznel raporlarla uyumludur.

2.1.4. Veri Seti Oluşturma

Kullandığımız veri seti EEG sinyalleri 2'si prefrontal lob üzerinden, 2'si kulak arkasından olmak üzere 4 farklı noktadan alınmıştır. Toplamda 6888 veri kaydedilmiştir. Kaydedilen bu veriler kullanıcıların deney esnasında düğmeye basması ile ilişkilendirilen tüm veriler yorgun olarak sınıflandırılmış ve 2160 veriden oluşmaktadır. Düğmeye basma

ile ilişkilendirilmeyen veriler yorgun değil olarak sınıflandırılmış ve 4728 veriden oluşmaktadır. Kaydedilen tüm bu veriler 220 Hz' de örneklenmiştir. Veri kaydetme uzunluğu cevap verme süresi temel alınarak yapılmıştır. Bundan dolayı verilerin uzunluğu birbirinden farklıdır.



Şekil 2. 5. MUSE EEG kulaklık

EEG verileri 76 deney yapılarak toplanmıştır ve her oturumun verileri ayrı bir klasörde saklanmıştır. Bu klasör "user_ <userID> _ <StimuliType> _ <GameMode>" olarak adlandırılmıştır. "User_ID tek bir tamsayı ise ve oyun modu "m" harfiyle karakterize edilmişse, bu, verilerin değiştirilmiş WKET sürümü olan V1 kullanılarak kaydedildiği anlamına gelir. User_ID'den sonra "b" harfi gelirse ve oyun modu "m" olarak tanımlanırsa, bu klasörün WKET'nin değiştirilmiş V2 sürümü kullanılarak kaydedilen verileri içerdiği anlamına gelir. Son olarak, oyun modu "o" harfiyle karakterize edilmişse bu veri toplamının orijinal WKET kurallarının kaydedildiği anlamına gelir [2].

Veriler deneyin birinci günü toplandıysa, "user_0_v_o" klasör adı, kimliği 0 olan kullanıcıya ait klasör görsel uyarılar ve verilerin orijinal WKET kullanılarak toplandığını göstermektedir. Aynı şekilde "user_0_v_m" klasör adı, birinci oturumda kimliği 0 olan kullanıcıya ait klasör görsel uyarılar ve verilerin WKET görevinin değiştirilmiş bir sürümü V1 kullanılarak toplandığını göstermektedir. Veriler deneyin ikinci günü toplandıysa "user_0b_v_o" klasör adı, kimliği 0 olan kullanıcıya ait klasör görsel uyarılar ve verilerin orijinal WKET kullanılarak toplandığını göstermektedir. "user_0b_v_m" klasör adı, kimliği 0 olan kullanıcıya ait klasör görsel uyarılar ve verilerin WKET görevinin değiştirilmiş bir sürümü V2 kullanılarak toplandığını göstermektedir [2].

Aşağıdaki Tablo2.2.'de veri toplama süreci boyunca toplanan EEG verilerinin kişilere göre sınıflara dağılımı verilmiştir. Bir kişiden yaklaşık 368 veri toplanmıştır. Düğmeye bir kez basıldıktan sonraki veriler yorgun sınıfına dâhil edilmiştir. Örneğin birinci kişi orijinal WKET'si sırasında 28. sorudan sonra düğmeye basmıştır ve 29-60 arası yorgun sınıfına dâhil edilmiştir.


Tablo 2. 2. Kişilere göre verilerin sınıflara dağılımı

Kişi No	Yorgun Değil				Yorgun			
	WKET	V1	WKET	V2	WKET	V1	WKET	V2
1	1-28	1-26	1-19	1-34	29-60	27-120	20-60	35-128
2	1-60	1-54	1-52	1-11	-	55-120	53-60	12-128
3	1-60	1-35	1-60	1-3	-	36-80	-	4-128
4	1-45	1-20	1-29	1-30	46-60	21-120	30-60	31-128
5	1-58	1-80	1-40	1-24	59-60	81-120	-	25-128
6	1-60	1-120	1-60	1-128	-	-	-	-
7	1-60	1-12	1-40	1-63	-	13-120	-	64-128
8	1-60	1-120	1-60	1-128	-	-	-	-
9	1-60	1-120	1-60	1-128	-	-	-	-
10	1-60	1-72	1-58	1-83	-	73-120	59-60	84-128
11	1-60	1-47	1-60	1-128	-	48-120	-	-
12	1-60	1-55	1-60	1-46	-	56-120	-	47-128
13	1-60	1-120	1-60	1-38	-	-	-	39-104
14	1-60	1-120	1-56	1-63	-	-	57-60	64-128
15	1-60	1-4	1-60	1-22	-	5-120	-	23-128
16	1-60	1-120	1-60	1-128	-	-	-	-
17	1-60	1-76	1-60	1-103	-	77-120	-	104-128
18	1-60	1-120	1-60	1-104	-	-	-	105-128
19	1-60	1-35	1-39	1-24	-	36-120	40-60	25-128
Toplam	1091	1356	993	1288	49	884	107	1120
Genel Toplam	4728				2160			


2.2. EEG Sinyali Özellik Çıkarma Yöntemleri

Mevcut zihinsel iş yükü sınıflandırma yöntemleri, karışık EEG sinyalleri ile yapılmaktadır. EEG elektrotları tarafından kaydedilen EEG sinyalleri bir grup karmaşık beyin sinyali olduğu için çok kaynaklı karışık konuşma sinyallerine benzerler [61]. Bu nedenle EEG sinyallerinin özelliklerini ayırt etmek için ses sinyallerinde özellik çıkarma

yönteminde kullanılan aşağıda ayrıntılı bir şekilde bahsedilen katsayıları hesaplandı. Daha sonra hesaplanan bu katsayılara öznitelik çıkarma işlemi uygulayarak sınıflandırma yöntemlerini denendi.



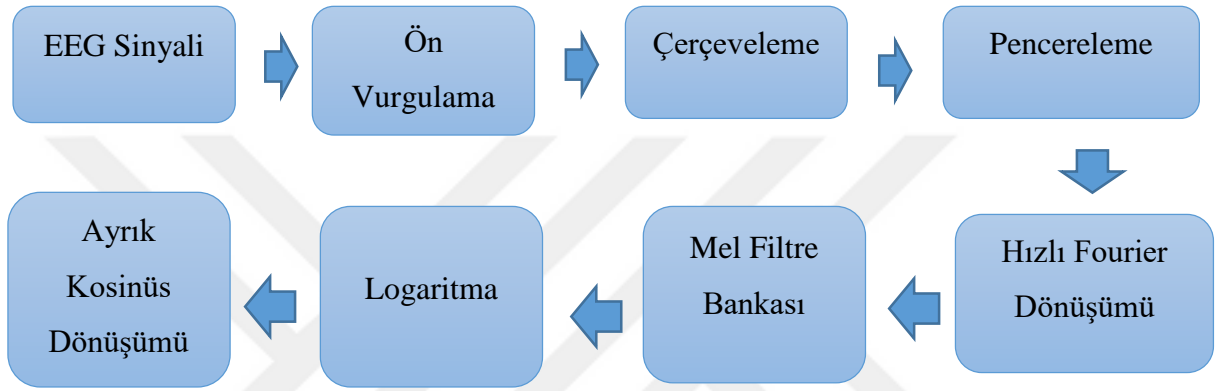
Şekil 2. 6. Birinci kişiye ait yorgun değil EEG verisi



Şekil 2. 7. Birinci kişiye ait yorgun EEG verisi

2.2.1. Mel Frekans Kepstral Katsayıları

Mel Frekans Kepstral Katsayıları (MFKK), daha çok konuşma tanımada kullanılan özniteliklerden biridir. Seslerin ve elektrofizyolojik sinyal arasında belirli benzerlikler vardır. Bu nedenle, her iki durumda da kullanılan özellik çıkarma yöntemleri benzer sinyal işleme özelliklerine dayanmaktadır [67]. MFKK öznitelik çıkarımının basamakları Şekil 2.8’de gösterilmiştir.



Şekil 2. 8. Mel Frekans Kepstral Katsayısı hesaplama adımları

Ön Vurgulama: Hızlı Fourier dönüşümü uygulandığında ortaya çıkabilecek sayısal sorunları önlemek ve sinyal-gürültü oranını iyileştirmek için kullanılır [68]. X sinyaline uygulanan ön vurgu eşitlik (1)’deki gibidir:

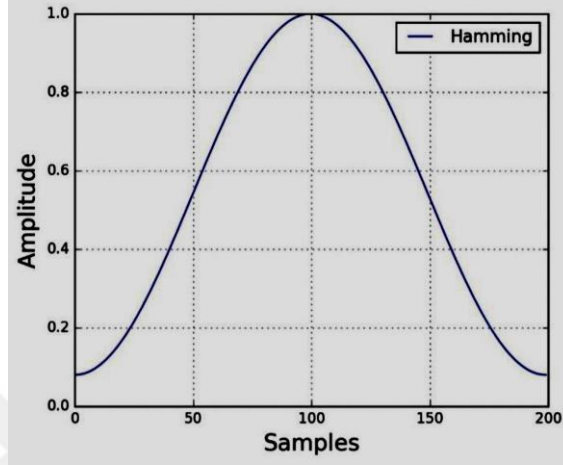
$$y(t) = x(t) - 0.95 x(t - 1) \quad (1)$$

Çerçeveleme: Ön vurgulamadan sonra, sinyali kısa süreli çerçevelere bölmek için kullanılır. Zamanla sinyaldeki frekansların değişmesi nedeniyle kullanılır. Çerçeve uzunluğu ardışık kareler arasında% 50 örtüşme ile 20ms-40ms arasındadır [68].

Pencereleme: Sinyalin orta bölgelerini güçlendirirken kenar bölgelerini zayıflatma işlemidir. Pencereleme işleminde Hamming, Hanning, Dikdörtgen, Barlett, Kasier ve Blackman yöntemleri kullanılır. Burada Hamming kullanılmıştır. Hamming penceresinin uygulanmasının nedeni, FFT’ nin sinyalin sabit olduğu varsayımını önlemek ve spektral sızıntıyı azaltmaktır [68]. EEG sinyalini çerçeveledikten sonra, her çerçeveye uygulanan pencereleme işlemi aşağıdaki gibi:

$$wn = 0.54 - 0.46\cos(2\pi n/N - 1) \quad (2)$$

Burada, $0 \leq n \leq N - 1$, N , şekil 2.9'da gösterildiği gibi pencere uzunluğudur.



Şekil 2. 9. Hamming Penceresi

Hızlı Fourier Dönüşümü: Bu aşamada, N örnekli her çerçevenin zaman bölgesinden, frekans bölgesine çevrilmesi için Hızlı Fourier Dönüşümü (HFD) uygulanır. Genellikle N , 256 veya 512'dir [68]. Her çerçeveden HFD' yi çıkardıktan sonra, güç spektrumu aşağıdaki gibi hesaplanacaktır: x_i , x sinyalinin i 'inci çerçevesidir.

$$P = \frac{|HFD(x_i)|^2}{N} \quad (3)$$

Filtre bankları: Filtre bankası son adımdır ve tipik olarak 40 filtreye mel-ölçeği üzerinde üçgen filtreler uygulanarak hesaplanır [68]. Frekans ve mel-ölçeği arasındaki dönüşüm şu şekilde yapılabilir:

$$m = 2595 \log_{10}(1 + f/700) \quad (4)$$

$$f = 700(10^{m/2595} - 1) \quad (5)$$

Logaritma: Üçgen filtre çıktıları $Y(i)$, $i = 0, 1, 2, \dots, M$ logaritma kullanılarak sıkıştırılır. Burada M , filtre bankasındaki filtre sayısına eşittir [69].

Ayrık Kosinüs Dönüşümü: HFD ile geçilen frekans alanından zaman alanına geri dönmek için ayrık kosinüs dönüşümü yapılır. Bu işlem sonrasında elde edilen katsayılar mel frekans kepstral katsayıları adı verilir [70].

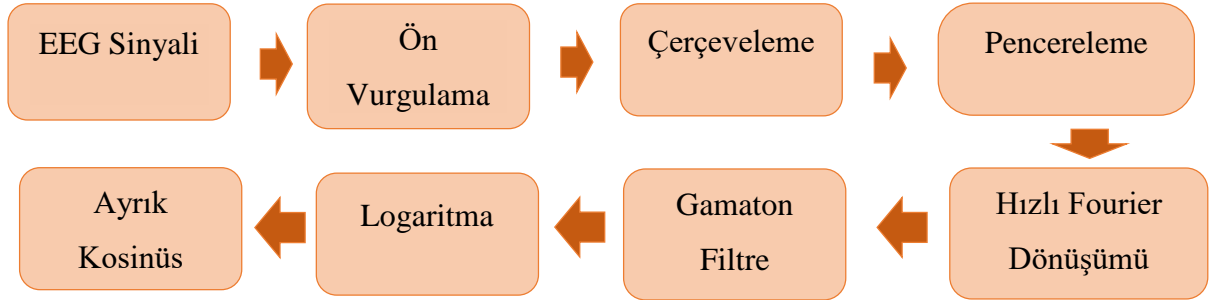
2.2.2. Gammatone Kepstral Katsayıları

Gammatone Kepstral Katsayıları (GTKK) gamaton filtre bankalarına dayalıdır, bu filtre bankları. GTKK' lerin ekstraksiyon süreci, mel filtre bankasının gamaton filtre bankası ile değiştirilmesinin dışında MFKK' lerin ekstraksiyon sürecine benzer [71].

Gammatone filtre bankası parametreleri hesaplaması eşitlikteki gibi hesaplanır:

$$G_i(k) = k^{n-1} e^{-2\pi B_i k} \cos(2\pi f_i + \varphi_i) u(k), \quad i \in [1, Q] \quad (6)$$


Eşitlik (6)'daki n filtre sırası B_i filtre zayıflama katsayısı, f_i merkez frekansı ve Q filtre bankasındaki filtre sayısıdır [72].



Şekil 2. 10. Gammatone Kepstral Katsayısı hesaplama adımları

2.2.3. Doğrusal Tahmin Katsayıları

Doğrusal Tahmin Katsayıları (DTK), EEG sinyallerini sıkıştırmak için kullanılır. Hem zaman alanında (bitişik örnekler korelasyonu) hem de frekans alanında (rezonans yapısına karşılık gelen tüm kutuplu spektrum) iyi bir sezgisel yorumlamaya sahiptir [73].



Şekil 2. 11. Doğrusal Tahmin Katsayısı hesaplama adımları

Oto Korelasyon Analizi: Pencereleme yapılan sinyalin her bir çerçevesine oto korelasyon analizi uygulanır. Burada p DTK analizinin derecesini ifade eder. Oto korelasyon eşitlik (7)' de verildiği gibi hesaplanır.

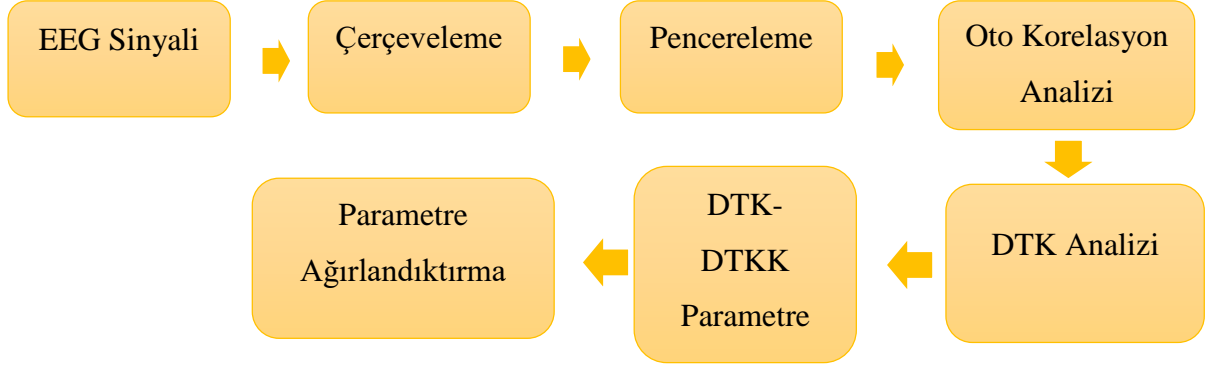
$$r_l(m) = \sum_{n=0}^{N-1-m} \hat{x}_l(n) \hat{x}_l(n+m), \quad m = 0, 1, \dots, p \quad (7)$$

DTK Analizi: Bir sonraki adım, $p + 1$ oto korelasyonlarının önbellek çerçevesini bir "DTK parametresine" dönüştüren DTK analizidir. Otokorelasyon katsayılarından bir DTK parametresine (DTK otokorelasyon metodu için) dönüştürmek için kullanılan metod, Durbin metodu olarak bilinir. Durbin algoritmasındaki amaç doğrusal tahmin filtresi katsayıları a_1, a_2, \dots, a_p ile ilgili tahmin hata değişikliğinin yinelemeli olarak bulunmasıdır. DTK analizine geçişte otokorelasyon analizinin yerine kovaryans analizi yapılabilir, fakat genellikle otokorelasyon analizi kullanılır [74].

2.2.4. Doğrusal Tahmin Kepstral Katsayıları

Doğrusal Tahmin Kepstral Katsayıları (DTKK) hesaplanması işlemi temel olarak DTK katsayılarının Fourier dönüşümü ile kepsral katsayılara dönüştürülmesidir. Bundan dolayı bu yöntemde ilk olarak DTK katsayılarının elde edilmesi gereklidir. Ardından diğer işlemlerin yapılır.

DTKK yöntemi Şekil 2.12. da görüldüğü gibi çerçeveleme, pencereleme, oto korelasyon analizi, DTK analizi, DTK-DTKK parametre dönüştürme, parametre ağırlıklandırma aşamalarından oluşmaktadır [75].



Şekil 2. 12.Doğrusal Tahmin Kepstral Katsayısı hesaplama adımları

DTK-DTKK Parametre Dönüşümü: Bu aşamada DTK katsayıları, eşitlik kullanarak kepsral katsayılarına dönüştürülür. Log büyüklük spektrumunun Fourier dönüşümü temsilinin katsayıları olan kepsral katsayılarının, parazit tanıma için DTK katsayılarından, yansıma katsayılarından veya log alan oranından daha sağlam, güvenilir bir özellik kümesi olduğu gösterilmiştir.

$$c_1 = a_1 \quad (8)$$

$$c_n = a_n + \sum_{k=1}^{n-1} \left(1 - \frac{k}{n}\right) a_k c_{n-k} \quad , 1 < n \leq p \quad (9)$$

Parametre ağırlıklandırma: DTK-DTKK Parametre Dönüşümü yapıldıktan sonra düşük sıralı kepsral katsayıların genel spektral eğime duyarlılığı ve yüksek sıralı kepsral katsayıların gürültüye (ve diğer gürültü benzeri değişkenlik biçimlerine) duyarlılığı nedeniyle, standart hale gelmiştir. Bu hassasiyetleri en aza indirmek için kepsral katsayıları inceltmiş bir pencere ile ağırlıklandırma tekniği uygulanmıştır. Ağırlıklandırma fonksiyonu kepsral uzayda bir bant geçiren filtre ile uygulanmaktadır [74].

2.2.5. Yansıma Katsayıları

DTK alternatif olarak, Yansıma Katsayısı (YK), birleştirilmiş tüplerin fiziksel modelinde her bir ekleme yansıtılan enerjinin ölçüsü olarak gösterilebilir. Otokorelasyon yönteminde DTK'leri hesaplarken YK'ler bir ara çözüm olarak ortaya çıkar. Levinson-

Durbin yinelemeli prosedürü $\{i \in \mathbb{Z}: i \geq 0, i \leq p\}$, DTK'lerden YK hesaplamak için uygulanabilir [76].

$$k_i = \frac{R_i - \sum_{k=1}^i a_{i-1}(k)R(i-1)}{E_{i-1}} \quad (10)$$

$$a_k(i) = a_k(i-1) - k_i a_{i-k}(i-1) \quad (11)$$

Sınır koşulları;

$$a_i(i) = k_i, \quad a_k = a_k(p) \quad (12)$$

2.2.6. LOG Alanı Oranları

Log Alan Oranı (LAO) katsayıları, doğrusal tahmin katsayılarından (DTK) türetilir. LAO katsayıları ile DTK arasındaki ilişki şöyledir:

$$LAO = \log\left(\frac{A_i}{A_{i+1}}\right) = \log\left(\frac{1+a_i}{1-a_i}\right), \quad A_{p+1} = 1 \quad (13)$$

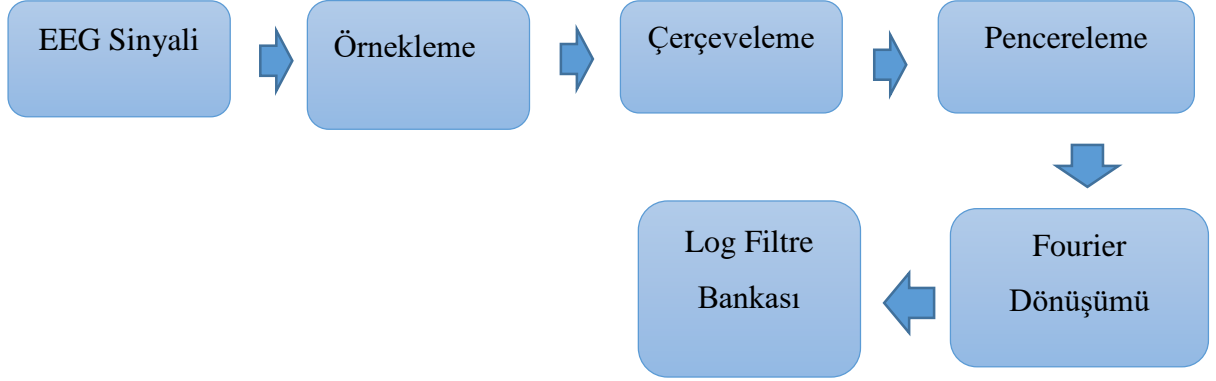
Burada a_i , aşağıdaki şekillerde bulunabilen i 'inci parcor katsayılarıdır:

$$a = a_i^{(i)}, \quad 1 \leq i \leq p \quad (14)$$

Buradaki $a_i^{(i)}$, DTK modeli tarafından hesaplanan i 'inci DTK' dir [77].

2.2.7. LOG Filtre Bankası Enerjileri

Log filtre bankası enerjisini (LFBE) hesaplamak için, giriş sinyali örneklenir ve çerçeveleme işlemi yapılır. Daha sonra, güç spektrumu üretmek için bir hamming penceresi ve Fourier dönüşümü uygulanır. Son olarak, log filtre bank uygulanır [78].



Şekil 2. 13. Log Filtre Bankası Enerjisi hesaplama adımları

2.2.8. Spektral Alt Bant Sentroidleri

Spektral alt bant sentroidleri (SABS) merkezlerini hesaplamak için, frekans bandı sabit sayıda alt bantlara bölünür ve sinyalinin güç spektrumunu kullanarak her bir alt bant için ağırlık merkezi hesaplanır.

Frekans bandının $[0, F_s / 2]$ M alt bantlarına bölünür, burada F_s örnekleme frekansıdır. M'inci alt bantın alt ve üst kenarları sırasıyla l_m ve h_m ve filtre şekli $W_m(f)$ 'dir. M'inci alt bant spektral merkez C_m 'yi şu şekilde hesaplarız:

$$C_m = \frac{\int_{l_m}^{h_m} f W_m(f) P^\gamma(f) df}{\int_{l_m}^{h_m} W_m(f) P^\gamma(f) df} \quad (15)$$

Burada $P(f)$ güç spektrumu ve γ güç spektrumunun dinamik aralığını kontrol eden sabittir [79].

2.2.9. Çizgi Spektral Frekansları

Çizgi Spektrumu Frekans gösterimi ilk olarak Itakura tarafından alternatif bir doğrusal tahmin parametrik gösterimi olarak önerildi [80]. Çizgi spektrum frekans gösterimi, sınırlı bir aralık, parametrelerin sıralı bir sıralaması ve filtre kararlılığının basit bir kontrolü dâhil olmak üzere bir dizi özelliğe sahiptir; Ek olarak, çizgi spektrumu frekans gösterimi bir frekans alanı temsilidir ve bu nedenle insan algılama sisteminin belirli özelliklerinden yararlanmak için kullanılabilir [81].

Çizgi spektrum frekanslarını tanımlamak için, ters filtre polinomu $A(z)$ iki polinom oluşturmak için kullanılır:

$$A(z) = 1 + a_1 z^{-1} + \dots + a_M z^{-M} \quad (16)$$

Burada M , $A(z)$ 'nin sırasıdır ve a_i doğrusal tahmin katsayılarıdır.

$$P(z) = A(z) + z^{-(M+1)} A(z^{-1}) \quad (17)$$

$$Q(z) = (z) - z^{-(M+1)} A(z^{-1}) \quad (18)$$

$P(z)$ ve $Q(z)$ polinomlarının köklerine çizgi spektrum frekansları denir. Polinomlar $P(z)$ ve $Q(z)$ aşağıdaki iki özelliğe sahiptir:

- 1) $P(z)$ ve $Q(z)$ 'nin tüm sıfırları bir birim çember üzerindedir;
- 2) $P(z)$ ve $Q(z)$ sıfırları iç içe geçmiştir yani çizgi spektrum frekansları artan sıradadır [81].

2.2.10. Güç Spektrumu

Fourier dönüşümü, bir sinyalde hangi frekansların var olduğunu tanımlar, ancak bunları zaman içinde yerelleştirmez. Bunu hesaba katmak için, her çerçevede hangi frekansların var olduğuna dair bir fikir edinmek için sinyal çerçevelerine ayrık fourier dönüşümü uygulanır. Bu yöntemde frekans-zaman eksenini için bir çözünürlük değiş tokuşu vardır. Pencereleme gerekli zaman çözünürlüğü için yeterince küçük olması gerekir, ancak frekansın güç spektrumunun gösterimini engelleyecek kadar olmamalıdır [82]. Bir zaman sinyali için Kısa Süreli Fourier Dönüşümü denklem (19) ile verilir:

$$H(n, k) = \sum_{n=1}^N h(n) w(n) e^{\frac{-j2\pi kn}{N}} \quad (19)$$

Burada $w(n)$, hamming penceresi ve ayrık fourier dönüşümü şu şekilde tanımlanır:

$$H(k) = \sum_{n=1}^N h(n) e^{\frac{-j2\pi kn}{N}}, \quad 0 \leq k \leq N \quad (20)$$

Eşitlik (20) yer alan $h(n)$ sinyalin zaman domeni, N örnek pencere uzunluğunu ve k ayırık fourier dönüşümü uzunluğunu ifade etmektedir.


Bir sonraki adım, her kare için enerjiyi bulmaktır. Bu, Kısa Süreli Fourier Dönüşümünün çıktısını güç spektrumunun zaman-frekans alanına eşleyerek bulunur.

$$S(n, k) = |H(n, k)|^2 \quad (21)$$

Bir çerçeve için güç spektrumunu hesaplamak, periodogram olarak bilinen $N/2 + 1$ uzunluğunda bir özellik vektörünü döndürür. Periodogramın bir araya getirilmesi, sinyalin spektrogramı olan $N \times (N/2 + 1)$ boyutunda bir matris oluşturur [82].

2.2.11. Algısal Doğrusal Tahmin Katsayıları

Hermansky tarafından geliştirilen Algısal Doğrusal Tahmin (ADT) katsayıları şu kavramlara dayanır: kritik bant çözünürlük eğrileri, eşit ses yüksekliği eğrisi ve kübik kök olarak bilinen yoğunluk-ses şiddeti güç yasası ilişkisine.



Şekil 2. 14. Algısal Doğrusal Tahmin Katsayısı işlem blok şeması

ADT'nin hesaplamasının ayrıntılı adımları şekil 2.15'te gösterilmiştir [83].

Sinyal Hamming penceresi tarafından ağırlıklandırılır. Pencerenin tipik uzunluğu yaklaşık 20 ms'dir. N , pencerenin uzunluğudur.

$$W(n) = 0.54 + 0.46 \cos[2\pi n / (N - 1)] \quad (22)$$

Ayrık Fourier dönüşümü, pencereli sinyal bölümünü frekans alanına dönüştürür. Tipik olarak, hızlı Fourier dönüşümü burada kullanılır. Pencereli sinyalin güç spektrumu şu şekilde hesaplanır [84].

$$P(\omega) = Re(S(\omega)^2) + Im(S(\omega)^2) \quad (23)$$

Kritik Bant Analizi: $P(\omega)$ Spektrumu, frekans eksenini ω boyunca, Bark frekansı Ω 'ye bükülür,

$$\Omega(\omega) = 6 \ln \left\{ \frac{\omega}{1200\pi} + \left[\left(\frac{\omega}{1200\pi} \right)^2 + 1 \right]^{0.50} \right\} \quad (24)$$

Burada ω rad / s cinsinden açısal frekanstır. Ortaya çıkan çarpık güç spektrumu daha sonra simüle edilmiş kritik bandın maskeleme eğrisi $\psi(\Omega)$ güç spektrumu ile birleştirilir.

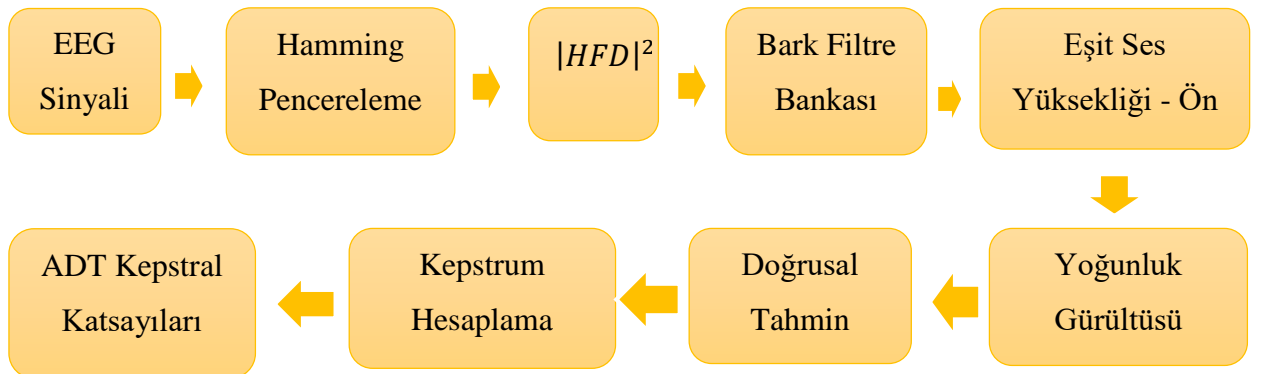
Eşit Yükseklikte Ön Vurgu: Denklem (25)'in asimptotları 0 ile 400 Hz arasında 12 dB / oct, 400 ile 1200 Hz arasında 0 dB / oct, 1200 ile 3100 Hz arasında 6 dB / oct ve 0 dB / oct 3100 ile Nyquist frekansı arasında bir filtrenin transfer fonksiyonunu temsil eder [84].

$$E(\omega) = [(\omega^2 + 56.8 \times 10^6)\omega^4] / [(\omega^2 + 6.3 \times 10^6)^2 \times (\omega^2 + 0.38 \times 10^9)] \quad (25)$$

Sonuç olarak ilk (0 Bark) ve son (Nyquist frekansı) örneklerinin değerleri, en yakın komşularının değerlerine eşit yapılır.

Yoğunluk Gürültüsü: Tüm kutuplu modellemeden önceki son işlem, kübik kök genlik sıkıştırmasıdır [84].

$$S(\omega) = (E(\omega))^{0.33} \quad (26)$$



Şekil 2. 15. Algısal Doğrusal Tahmin Katsayıları hesaplama adımları

2.2.12. Spektra-Algısal Doğrusal Tahmin Yöntemi

Spektra-algısal doğrusal tahmin (SADT) yöntemi, algısal doğrusal tahminin (ADT) bir uzantısıdır ve ADT'den tek farkı, her alt banda bir bant geçiş filtresinin eklenmesidir. SADT'de yer alan süreç, kritik güç spektrumunun ADT'deki gibi hesaplanmasını ve ardından sıkıştırılmalı statik doğrusal olmayan dönüşümü içerir. Daha sonra, dönüştürülmüş her spektral bileşenin zaman yörüngesi, bir bant geçiş filtresine girdilerdir. Bir sonraki adımda, süzölmüş konuşma, insan işitme sistemini taklit etmek için genişleyen statik doğrusal olmayan dönüşüm kullanılarak dönüştürülür, ardından eşit ses şiddeti eğrisi ayarı ve yoğunluk-yüksek güç yasası uygulaması izlenir. Son olarak, SADT katsayıları, bir önceki aşamanın çıktısında ters Fourier dönüşümü, doğrusal tahmin analizi ve sepstral analizi gerçekleştirilerek ardışık olarak hesaplanır [85].

2.3. Öznitelik Çıkarma Yöntemleri

Öznitelik çıkarımı işlemi yapılarak büyük bir veri kümesini açıklamak için kaynak miktarını azaltmış oluruz. Karmaşık bir veri üzerinde analiz yapılırken ortaya çıkan ana problemlerden biri de kullanılan değişken sayısının artmasıdır. Çok fazla değişken içeren analizler genellikle büyük bir bellek alanına ve işlemci gücüne gereksinim duyar, ayrıca sınıflandırma algoritmalarının eğitim kümesine aşırı uymasına sebep olarak tahmin performansını aşağı çeker. Öznitelik çıkarımı, değişkenlerin kombinasyonlarını oluşturmak suretiyle bu sorunları aşmayı ve veriyi yeterli bir doğrulukla açıklayabilir olmayı sağlayan yöntemleri tanımlayan genel bir terimdir.

Çıkarılacak öznitelikler EEG verisini tanımlamada kullanılabilir ancak bu durum özniteliklerin sınıflandırma aşamasında yüksek doğruluk vereceği anlamına gelmez. Dolayısıyla yüksek oranda sınıflandırma doğruluğu için EEG verisini yaklaşık olarak özetleyebilecek öznitelik vektörü bulmak çok önemli bir aşamadır.

Bu çalışmada öznitelik olarak Ortalama karekök (OK), log dedektörü (LD), ortalama mutlak değer (OMD), değiştirilmiş ortalama mutlak değer 1 (DOMD1), değiştirilmiş ortalama mutlak değer 2 (DOMD2) ve geliştirilmiş ortalama mutlak değer (GOMD) kullanıldı. Veri uzunlukları birbirinden farklı olduğu için seçilen özniteliklerin uzunluktan bağımsız olmasına dikkat edilmiştir.

Otalama Karekök: Değişen miktarların büyüklüğünün ölçülmesinde kullanılan istatistik bir ölçüttür. Matematiksel olarak eşitlik (27) 'deki gibi hesaplanır. Burada x dalgacık katsayısı ve L katsayı uzunluğunu ifade eder [86].

$$OK = \sqrt{\frac{1}{L} \sum_{i=1}^L (x_i)^2} \quad (27)$$

Log Detektörü: Doğrusal olmayan detektör olarak tanımlanır ve LD özelliği eşitlik (28)'deki gibi tanımlanır. Burada x dalgacık katsayısı ve L katsayı uzunluğudur. Uygulanan kuvveti tahmin etmede iyi olan bir özelliktir [87].

$$LD = \exp\left(\frac{1}{L} \sum_{i=1}^L \log(|x_i|)\right) \quad (28)$$

Ortalama Mutlak Değer: Sinyalin mutlak değerinin toplamının ortalaması olarak tanımlanır. Burada x dalgacık katsayısı ve L katsayı uzunluğudur [87].

$$OMD = \frac{1}{L} \sum_{i=1}^L |x_i| \quad (29)$$

Değiştirilmiş Ortalama Mutlak Değer 1: Ağırlık penceresi işlevini atayan ODM özelliğinin bir uzantısıdır [87].

$$ODM1 = \frac{1}{L} \sum_{x=i}^L w_i |x_i| \quad (30)$$

$$w_i = \begin{cases} 1 & 0,25L \leq i \leq 0,75L \\ 0,5 & \text{diğer} \end{cases} \quad (31)$$

Değiştirilmiş Ortalama Mutlak Değer 2: Sürekli ağırlık penceresi işlevini atayan OMD özelliğinin başka bir uzantısıdır [87].

$$ODM2 = \frac{1}{L} \sum_{x=i}^L w_i |x_i| \quad (32)$$

$$w_i = \begin{cases} 1 & 0,25L \leq i \leq 0,75L \\ \frac{4i}{L} & i < 0,25L \\ \frac{4(i-L)}{L} & \text{diğer} \end{cases} \quad (33)$$

Geliştirilmiş Ortalama Mutlak Değer: Denklem (34)' te görülebileceği gibi, p parametresi, örneğin sinyal içindeki etkisini tanımlamak için kullanılır. GOMD'de, bölgelerin% 20 ila% 80'i için daha fazla sayıda p kullanılır. Çünkü orta bölgedeki bilgi içeriği güçlendirilerek daha değerli bilgiler elde edilebilir. Bu şekilde özelliklerin kalitesi iyileştirilebilir. Burada x dalgacık katsayısı ve L katsayının uzunluğudur [87].

$$EMAV = \frac{1}{L} \sum_{i=1}^L |(x_i)^p| \quad (34)$$

$$p = \begin{cases} 0,75 & i \geq 0,2L \text{ ve } i \leq 0,8L \\ 0,50 & \text{diğer} \end{cases} \quad (35)$$


2.4. Sınıflandırma Yöntemleri

2.4.1. k-En Yakın Komşu

k-en yakın komşu (k-EYK) algoritması, denetimli bir makine öğrenimi algoritması uygulaması en basit ve kolay olanlardan biridir. k faktörü, sınıf sınırlarının belirlenmesinde çok önemlidir. Sınırlar, k değerlerinin artmasıyla düzgün hale gelir. Eğitim hata oranı ve doğrulama hata oranı, k değerlerine erişmek için kullanılan iki parametredir [88]. k-EYK algoritması, yürütmesini iki adımda tamamlar, ilk olarak en yakın komşuların sayısını bulur ve ikincisi, birinci adımı kullanarak veri noktasını belirli bir sınıfa sınıflandırır. Komşuyu bulmak için, denklem 36'da verildiği gibi öklid mesafesi gibi mesafe ölçütleri kullanır.

$$\text{öklid}(x, y) = \sqrt{\sum_i (x_i - y_i)^2} \quad (36)$$

Eğitim setinden en yakın k örneğini seçer, ardından belirsizliği önlemek için k'nin tek sayı olması gereken sınıflarının çoğunluk oyunu alır. Şekil 2.16 k-EYK sınıflandırıcısının mimarisini göstermektedir [89].



Şekil 2. 16. k-EYK sınıflandırma mimarisi

Sınıf 1 ve sınıf 2 olmak üzere 2 sınıf vardır. Sarı kare işaretleri sınıf 1'i, yeşil daireler sınıfı 2'yi ve mor yıldız test verisini temsil etmektedir. Seçilen k 3'tür ve en yakın 3 komşu arasından hangi sınıfa ait veriler daha fazla ise test verisi o sınıfa dâhil edilir. Böylece, yeni test verisi 1. sınıfa atanır.

MATLAB'daki "fitcknn" fonksiyonu, k-EYK sınıflandırıcısını modellemek için kullanılmıştır. Öğrenilen sınıflandırma kuralı daha sonra bir dizi standartlaştırılmış test veri noktası için yanıtları tahmin etmek için predict' te kullanılır. Mesafe ölçütü olarak 'öklid' yöntemi kullanılmış ve bu sınıflandırma yönteminde komşu sayısı değeri 5 olarak seçilmiştir. Yorgun ve yorgun değil olarak iki sınıf tanımlanmıştır. Bu fonksiyon herhangi bir y değeri veya herhangi bir ağırlık eksikse, fitcknn bu değerleri y 'den, ağırlıklardan ve ilgili x satırlarını verilerden kaldırır. Yazılım, ağırlıkları toplamı 1 olacak şekilde yeniden normalleştirir. Tahmin edicileri ('Standartlaştır', 1) veya standartlaştırılmış Öklid mesafesini bir ölçek olmadan standartlaştırmayı belirtirseniz, fitcknn ortalamayı ve standart sapmayı hesaplamadan önce tek tek kestiricilerden eksik gözlemleri kaldırır. Başka bir deyişle, yazılım, her bir kestiricide 'omitnan' seçeneği ile ortalama ve std'yi uygular [90].

2.4.2. Destek Vektör Makinesi

Destek vektör makinesi (DVM), klasik iki sınıflandırma sorunu için tasarlanmıştır ve küçük örnekleri, doğrusal olmayan ve yüksek boyutlu veri sınıflandırma problemlerini çözmede benzersiz avantajlara sahiptir. DVM' nin temel ilkesi, örnekleri doğrusal olmayan

dönüşümle yüksek boyutlu bir özellik uzayına eşlemek ve düşük boyutlu uzayda karşılık gelen doğrusal olmayan problemi çözmek için optimal bir hiper düzlem oluşturmaktır. Örneğin bir set varsayarsak $\{(x_i, y_i) \mid i = 1, 2, \dots, n\}$, x_i , i ' inci giriş özelliği vektörü ve y_i , x_i ' nin kategori etiketidir [91]. Hiper düzlem fonksiyonu şu şekilde modellenir:


$$\omega \cdot x + b = 0 \quad (37)$$

Burada b ve w sırasıyla sapma parametresi ve ağırlık vektörüdür. Nokta \cdot iç çarpımı gösterir. İkili bir sınıflandırma sorunu için, numuneleri doğru bir şekilde tanımlamak için, tüm numunelerin kısıtlamaya uyması gerekir, yani:

$$\omega \cdot x + b \begin{cases} > 1 & \text{için } y_i = 1 \\ < -1 & \text{için } y_i = -1 \end{cases} \quad (38)$$

Maksimum sınıflandırma aralığı $2/\|\omega\|^2$ ' dir ve $\|\omega\|^2$ ' yi en aza indirerek elde edilebilir. Boşluk terimi ξ ve ceza faktörü C 'yi Denklem (38) 'e getirerek, DVM' nin doğrusal bölünmezlik problemi aşağıdaki kısıtlanmış optimizasyon sorununa dönüştürülür.

$$\min f = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \xi_i, \quad y_i(\omega \cdot x_i + b) \geq 1 - \xi_i, \quad i = 1, 2, \dots, n \quad (39)$$



Şekil 2. 17. DVM sınıflandırma örneği

Yüksek boyutlu uzayda örnek vektörlerin hesaplanması, çekirdek fonksiyonu tarafından iç çarpıma dönüştürülür. Bir çekirdek işlevi, örneklerin özellik uzayına eşlenmesini belirlediğinden, çekirdek işlevinin seçimi DVM sınıflandırması için çok anlamlıdır. Radyal temel fonksiyonunun (RTF) mükemmel özelliği nedeniyle, model tanımlamasının kullanımında her zaman DVM' nin çekirdek fonksiyonu olarak görevlendirilir ve şu şekilde açıklanır:

$$K(x_i x_j) = \phi(x_i) \cdot \phi(x_j) = \exp(-g \|x_i - x_j\|^2) \quad (40)$$

Buradaki g , çekirdek parametresini temsil eder.

Denklem (39)'u çözmek için Lagrange fonksiyonu, bu tür ikinci dereceden programlama problemini karşılık gelen ikili probleme dönüştürmek için geliştirildi:

$$\max L = \sum_{i=1}^n \mu_i - \frac{1}{2} \sum_{i,j} \mu_i \mu_j y_i y_j K(x_i x_j), \sum_{i,j} \mu_i \mu_j = 0, \mu_i \geq 0, i = 1, 2, \dots, n \quad (41)$$

μ_i , Lagrange çarpanıdır. Son olarak, Denklem (41) 'i çözerek, RTF fonksiyonu ile doğrusal sınıflandırma karar fonksiyonu şu şekilde verilir:

$$f(x) = \text{sgn}(\sum_{i=1}^n \mu_i K(x_i, x) + b) \quad (42)$$

Çalışmada MATLAB'daki "fitsvm" fonksiyonu DVM' yi modellemek için kullanılmıştır. Öğrenilen sınıflandırma kuralı daha sonra bir dizi standartlaştırılmış test veri noktası için yanıtları tahmin etmek için predict' te kullanılır.

2.4.3. Saf Bayes Sınıflandırıcı

Saf Bayes sınıflandırıcı (SBS), Bayes teoreminin güçlü (naif) bağımsızlık varsayımları ile uygulanmasına dayanan basit bir olasılık sınıflandırıcısı olarak yaygın bir şekilde tanınmaktadır.

Bir SBS, diğer özelliklerin varlığına veya yokluğuna bakılmaksızın, giriş özelliklerinin her birinin olasılığa bağımsız olarak katkıda bulunduğunu düşünür. Saf tasarımlarına ve görünüşte aşırı basitleştirilmiş varsayımlarına rağmen, çeşitli karmaşık gerçek dünya durumlarında oldukça iyi çalışırlar [92].

Bazı olasılık modelleri türleri için, SBS' ler denetimli bir öğrenme ortamında çok verimli bir şekilde eğitilebilir. Birçok pratik uygulamada, SBS için parametre tahmini, maksimum olabilirlik yöntemini kullanır.

Bir SBS için olasılık modeli, x_1 'den x_n 'ye kadar çeşitli özellik değişkenleri için koşullu, az sayıda sonuç veya sınıf içeren, bağımlı bir sınıf değişkeni C üzerinde koşullu bir modeldir:

$$p(C|x_1, x_2, \dots, x_n) \quad (42)$$

Bununla birlikte, bir özellik çok sayıda değer alabiliyorsa veya özellik sayısı n çok büyükse, böyle bir modeli olasılık tablolarına dayandırmak mümkün değildir. Bu nedenle modeli daha uygulanabilir hale getirmek için yeniden formüle edilir:

$$p(C|x_1, x_2, \dots, x_n) = \frac{p(C)p(x_1, x_2, \dots, x_n|C)}{p(x_1, x_2, \dots, x_n)} \quad (43)$$

Bayes analizde, son sınıflandırma, Bayes kuralı olarak adlandırılan kuralı kullanarak bir arka olasılık oluşturmak için her iki bilgi kaynağının önceki ve olasılık birleştirilmesiyle üretilir [92].

Uygulamada, payda C 'ye bağlı olmadığından ve paydanın etkin bir şekilde sabit olması için x_i özelliklerinin değerleri verildiğinden, sadece bu kesrin payına ilgi vardır. Bu nedenle, sadece aşağıdakilerin değerini maksimize etmemiz gerekiyor:

$$p(C)p(x_1, x_2, \dots, x_n|C) \quad (44)$$

C kategorisi verildiğinde, x_i ' nin her bir özelliğın diğer x_j ($i \neq j$) özelliklerinden koşullu olarak bağımsız olduğunu varsayılırsa C :

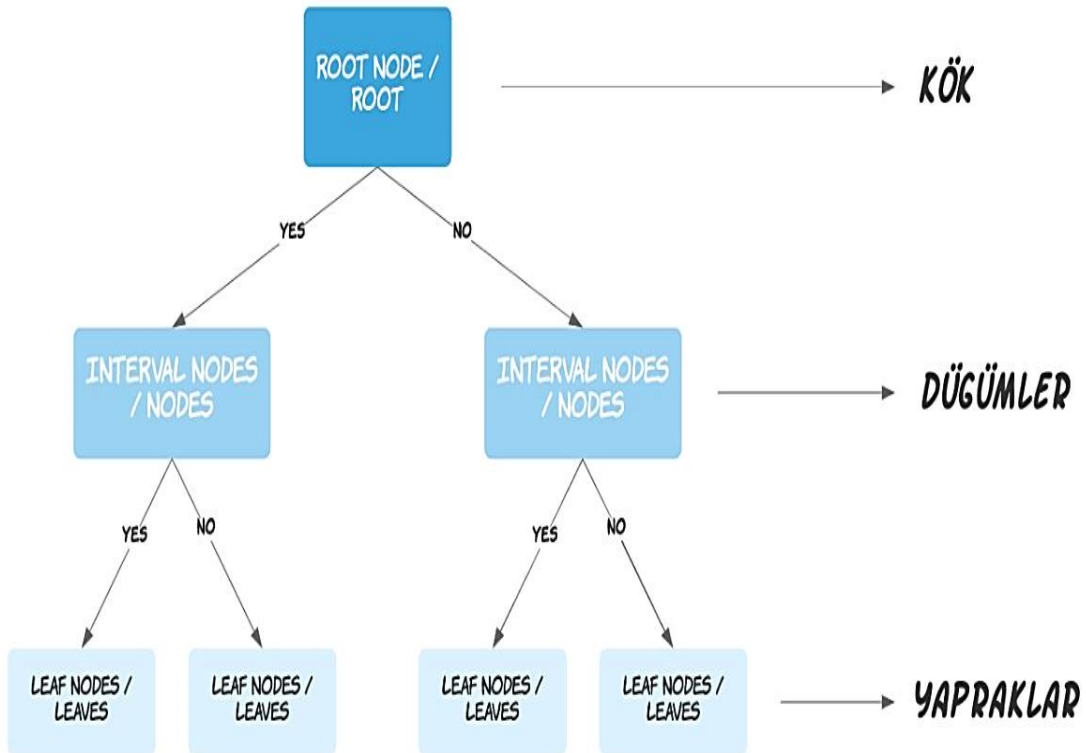
$$p(x_1, x_2, \dots, x_n|C) = \prod_{i=1}^n p(x_i|C) \quad (45)$$

Burada olasılık $p(x_1|C), \dots, p(x_n|C)$ eğitim örneği kullanılarak tahmin edilebilir.

Bu hesaplamalar sayesinde, her sınıfa ait bir örneklemin son olasılıklarını elde edebiliriz. Çalışmada MATLAB' daki "fitcnb" fonksiyonu SBS' yi modellemek için kullanılmıştır. Öğrenilen sınıflandırma kuralı daha sonra yanıtları tahmin etmek için PREDICT' te kullanılır.

2.4.4. Karar Ağacı

Karar ağacı (KA), ağaç benzeri bir yapıdır. Her düğüm, öznelik üzerindeki bir testi temsil eder, her dal sonucunu belirtir ve her yaprak düğüm bir sınıf etiketini belirtir. Kök düğümden yaprak düğüme giden yol, bir sınıflandırma kuralı olarak görülebilir. Bir KA için öğrenme yönteminin amacı, girdi nitelikleri temelinde bir hedef sınıf etiketinin değerini tahmin eden bir KA modeli oluşturmaktır [92].



Şekil 2. 18. Karar Ağacı sınıflandırıcı mimarisi

2.4.4.1. ID3 Algoritması

ID3 algoritması, kök düğüm olarak orijinal S kümesi ile başlar. S kümesindeki tüm kullanılmayan öznitelikleri yineler ve bu özneliğin entropisini veya bilgi kazancını hesaplar. Daha sonra en küçük entropiye veya bilgi kazancına sahip özneliği seçer. S kümesi, verilerin alt kümelerini oluşturmak için seçilen özneliğe bölünür. ID3, yalnızca seçilmemiş öznitelikleri dikkate alarak her alt kümede yinelenmeye devam eder [92].

2.4.4.2. C4.5 Algoritması

C4.5, ID3 algoritmasının bir uzantısıdır. C4.5, her düğümde, örnekleri bir sınıfta veya diğerinde zenginleştirilmiş alt kümelere en etkili şekilde ayıran özelliği seçer. Bilgi kazancı, bölme kriteri olarak seçilebilir. En büyük normalleştirilmiş bilgi kazancına sahip özellik, algoritmanın yararlı olduğunu kanıtlamak için test edilir. Daha sonra C4.5 daha küçük alt listelerde tekrarlanır [92].

2.4.4.3. Sınıflandırma ve Regresyon Ağacı

Sınıflandırma ve regresyon ağacı, bir karar ağacı için parametrik olmayan bir öğrenme tekniğidir. Yanıt değişkenininin kategorik veya sayısal olmasına bağlı olarak hem bir sınıflandırma ağacı hem de bir regresyon ağacı oluşturabilir.

Başlangıçta sınıflandırma ve regresyon ağacı, örnekleri bağımlı değişkenlere göre farklılaştırmak için en iyi bölünmeyi elde etmek için kuralları seçer. Bu işlem, sınıflandırma ve regresyon ağacı daha fazla kazanç algılayana kadar veya önceden tanımlanmış bazı sonlandırma kriteri karşılanana kadar her küçük düğüme yinelenmeli olarak uygulanır [92].

2.4.4.4 Topluluk Yöntemleri

Topluluk yöntemleri genellikle, örneğin rastgele orman, gradyan ağaç artırma ve torbalama ağacı gibi bir karar ağaçları koleksiyonu oluşturmak için kullanılır. Tablo 2.2, bunların uygulama yöntemlerini göstermektedir [92]. Tez çalışmasında KA sınıflandırıcısını modellemek için “fitctree” fonksiyonu kullanılmıştır.

Tablo 2. 3. Karar ağaçları oluşturmak için üç yöntem

Adı	Yöntem
Rastgele Orman	Sınıflandırma oranını iyileştirmek için bir dizi karar ağacı kullanır
Gradyan Ağaç Artırma	Hem regresyon tipi hem de sınıflandırma tipi problemler için kullanılabilir.
Torbalama Ağacı	Bu erken bir topluluk yöntemidir, eğitim verilerini değiştirerek tekrar tekrar yeniden örnekleyerek birden çok ağaç inşa eder ve bir fikir birliği için çoğunluk oyu verir.

2.4.5. Diskriminant Analizi

Diskriminant analizi (DA), belirleyici değişkenlerin ayırt edici fonksiyonlarının parametrelerini tahmin etmek için eğitim verilerini kullanan iyi bilinen bir istatistiksel sınıflandırma tekniğidir. Ayırt edici fonksiyonlar, çeşitli sınıflar arasındaki tahmin uzayındaki sınırları belirler. Ortaya çıkan sınıflandırıcı, öngörücü verilere dayalı olarak sınıflar arasında cevabın kategorik seviyeleri göre ayırım yapar [93].

Sınıflandırıcı, c kararları veya ayırt edici işlevler ile ($\{f_1, f_2, \dots, f_c\}$) temsil edilir; burada c ; sınıf sayısını temsil eder. Karar işlevleri, sınıflar ve bölge arasındaki karar sınırlarını belirlemek için kullanılır. Bu nedenle, ayırt edici fonksiyonlar, c farklı diskriminant fonksiyonlarının karşılaştırılmasına dayalı olarak bilinmeyen modelin (x) sınıf etiketini belirlemek için kullanılır ve maksimum puanın sınıf etiketini bilinmeyen örneğe atar. Denklemde (46) gösterildiği gibi; ω_i bölgesinde, i . Diskriminant fonksiyonu (f_i), diğer tüm ayırt edici fonksiyonlara kıyasla maksimum değere sahip olacaktır. Herhangi iki ayırt edici fonksiyonun değerleri eşitse ($f_i(x) = f_j(x)$), bilinmeyen desen (x) iki sınıf arasındaki sınırdadır [94].

$$f_i(x) > f_j(x), \quad i, j = 1, 2, \dots, c, \quad i \neq j \quad (46)$$

Farklı sınıfları farklı bölgelere ayırmak ve karar sınırlarını oluşturmak için ayırt edici işlevler kullanılır. Başka bir deyişle, her karar sınırı (S_{ij}) iki farklı bölgeyi, yani iki sınıf ω_i ve ω_j ' yi ayırır ve f_i ve f_j olmak üzere iki ayırt edici fonksiyondan oluşur. Diyelim ki, iki

sınıfımız var (ω_1) ve (ω_2), bu nedenle iki farklı ayırıcı fonksiyon (f_1 ve f_2) var ve karar sınırı aşağıdaki gibi hesaplanır [94].

$$S_{12} = f_1(x) - f_2(x) \quad (47)$$


Bilinmeyen bir desen x 'in karar bölgesi veya sınıf etiketi denklem 48'deki gibi hesaplanır.

$$\text{sgn}(S_{12}(x)) = \text{sgn}(f_1(x) - f_2(x)) = \begin{cases} \text{Sınıf1} & \text{için } S_{12} \geq 0 \\ \text{Tanımsız} & \text{için } S_{12} = 0 \\ \text{Sınıf2} & \text{için } S_{12} < 0 \end{cases} \quad (48)$$

MATLAB' da diskriminant analiz modelini modellemek için 'fitdiscr' fonksiyonu kullanılır.

2.5. Sınıflandırıcı Değerlendirmesi İçin Çokgen Alan Metriği

Sınıflandırıcı performans değerlendirme (SPD), örüntü tanıma için zorlu bir görevdir. Örüntü tanıma alanında en popüler ölçü olan sınıflandırma doğruluğu (SD), sınıfların eşit sayıda örneğe sahip olması durumunda iyi çalışsa da, sınıfların farklı sayıda örneğe sahip olması durumunda her bir sınıfın tanıma performansını değerlendirmede başarısız olur. Bu sorunun üstesinden gelmek için, araştırmacılar SD hariç duyarlılık (D), özgüllük (Ö), eğri altındaki alan (EAA), Jaccard indeksi (Jİ), Kappa (K) ve F-ölçümü (FÖ) gibi çeşitli ölçütler geliştirmişlerdir. Sınıflandırıcıların performansını değerlendirmek için birçok değerlendirme ölçütü vermek, büyük tabloları mümkün kılar. Ek olarak, sınıflandırıcıları birbirleriyle karşılaştırırken, bir sınıflandırıcı bir metrikte daha başarılı olabilir, diğer ölçütler için düşük performans gösterebilir. Bu nedenle, bu tür durumlar, sonuçları izlemeyi ve sınıflandırıcıları karşılaştırmayı zorlaştırır. Bu çalışmada, bir sınıflandırıcının performansının çokgen alan metriği (ÇAM) olarak adlandırılan tek bir metrikle değerlendirilmesine izin veren istikrarlı ve derin bir bilgi kriteri olan metrik kullanılmıştır. Böylelikle sınıflandırıcıların performansını, çeşitli ölçütlere ihtiyaç duyulmadan kolayca değerlendirdik [95].



Şekil 2. 19. Çokgen Alan Metriği

ÇAM, Şekil 'te gösterildiği gibi, SD, D, Ö, EAA, Jİ ve FÖ noktalarının düzenli bir altıgende oluşturduğu çokgen alanı kullanılarak hesaplanır. Normal altıgenin 6'dan oluştuğuna dikkat edilmelidir. Eşkenar üçgenlerin her iki kenarın uzunluğu 1'e eşittir. Yani $|OA| = |OB| = |OC| = |OD| = |OE| = |OF| = 1$ 'dir. Dolayısıyla altıgenin alanı 2,59807'ye eşittir. $|OA|$, $|OB|$, $|OC|$, $|OD|$, $|OE|$ ve $|OF|$ uzunlukları sırasıyla SD, D, Ö, EAA, Jİ ve FÖ değerlerini temsil eder. ÇAM, aşağıdaki formül kullanılarak hesaplanır:

$$\text{ÇAM} = \frac{\text{ÇA}}{0,259807} \quad (49)$$

Burada ÇA, oluşan çokgenin alanıdır. ÇAM'ı $[0, 1]$ aralığına normalleştirmek için ÇA değeri 2.59807'ye bölünmektedir [95].

Tablo 2.3'te, negatif ve pozitif sınıf etiketleri olan iki sınıflı bir problem için bir karışıklık matrisini göstermektedir.

Tablo 2. 4. İki sınıflı bir problem için kafa karışıklığı matrisi

		Tahmin Edilen Etiket	
		Pozitif	Negatif
Gerçek Etiket	Pozitif	Doğru Pozitif (DP)	Yanlış Negatif (YN)
	Negatif	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Bu tabloda DP, DN, YP ve YN sırasıyla doğru tahmin edilen pozitif örnek sayısı, doğru tahmin edilen negatif örnek sayısı, yanlış tahmin edilen pozitif örnek sayısı ve yanlış tahmin edilen negatif örnek sayısı olarak tanımlanmıştır. Araştırmacılar, SD, D, Ö, Jİ, EAA ve FÖ dâhil olmak üzere sınıflandırma performansını değerlendirmek için yaygın olarak kullanılan metriklerin matematiksel ifadeleri sırasıyla şu verilmiştir:

$$SD = \frac{DP+DN}{DP+DN+YP+YN} \quad (50)$$

$$D = \frac{DP}{DP+YN} \quad (51)$$

$$\ddot{O} = \frac{DY}{DY+YP} \quad (52)$$

$$J\dot{I} = \frac{DP}{DP+YP+YN} \quad (53)$$

$$EAA = \int_0^1 f(x)dx \quad (54)$$

$$F\ddot{O} = \frac{2DP}{2DP+YP+YN} \quad (55)$$

3. BULGULAR

Bu tez çalışmasında Cogbeacon veri seti kullanılmıştır. Bu veri setinde 19 kişiden toplanmış 6888 EEG verisi bulunmaktadır. Bu verilerden 2160 tanesi yorgun 4728 tanesi yorgun değil olarak sınıflandırılmıştır. Kullandığımız bu verilerden 6. 8. 9. ve 16. kişilere ait veriler sadece yorgun değil sınıfında yer aldığı için daha sağlıklı karşılaştırma yapabilmek adına çıkarılmıştır. Ayrıca toplanan veri uzunlukları birbirinden farklı oldukları için 440 Hz ile 1600 Hz arasındaki veriler dikkate alınmıştır. Tüm bu eleme işlemleri yapıldıktan sonra 2143 tanesi yorgun ve 3219 tanesi yorgun değil olmak üzere 5362 veri üzerinde çalışılmıştır.

EEG sinyalleri bir grup karışık beyin sinyali olduğu için çok kaynaklı konuşma sinyalleri ile benzerlik gösterirler [61]. Bu nedenle çalışmamızda genelde kullanım alanları incelendiğinde konuşma sinyallerinde kullanılan 2.2. bölümünde ayrıntılı olarak anlattığımız bazı frekans alanı katsayıları hesaplandıktan sonra 2.3. bölümde yer alan öznitelik çıkarma yöntemleri yapılmıştır. Sınıflandırma işlemi için 2.4. bölümde bahsedilen sınıflandırma algoritmaları kullanılmıştır.

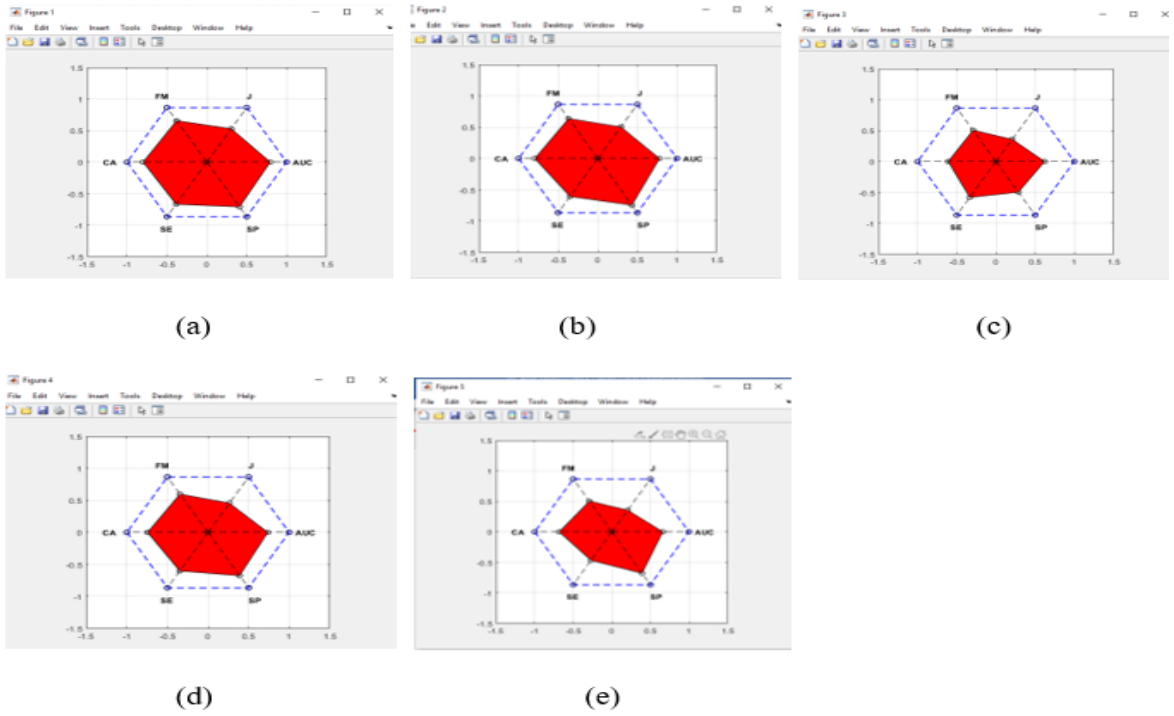
3.1. Mel Frekans Kepstral Katsayısı ile Elde Edilen Bulgular

MFKK hesaplandıktan sonra öznitelik çıkarma işlemi gerçekleştirilmiş daha sonra veriler %50 eğitim ve %50 test olarak ayrılmıştır ve sınıflandırma işlemleri gerçekleştirilmiştir. Sınıflandırıcı performansını değerlendirmek için her sınıflandırma işleminin ardından SPD işlemi uygulanmıştır. Toplanan tüm sonuçlar aşağıdaki tabloda mevcuttur ayrıca sınıflandırma performansı ekran görüntüleri de aşağıda yer almaktadır.

Tablo 3. 1. MFKK'ye dayalı sınıflandırıcı ve SPD sonuçları

Sınıflandırıcı	k-EYK	DVM	SMS	KA	DA
Doğruluk	79.8583	79.3734	61.0593	74.4125	68.2208
ÇAM	0.57	0.55	0.33	0.48	0.37
SD	0.80	0.79	0.61	0.74	0.68
D	0.77	0.70	0.67	0.69	0.54
Ö	0.82	0.86	0.57	0.78	0.78
EAA	0.79	0.78	0.62	0.74	0.66
K	0.61	0.58	0.41	0.53	0.41
FÖ	0.76	0.73	0.58	0.69	0.58

Tablo 3.1'de görüldüğü üzere en iyi sınıflandırma doğruluğu %79.8583 ile k-EYK sınıflandırıcısından elde edilmiştir. ÇAM değerlerine bakıldığında da en iyi değerler k-EYK sınıflandırıcısına aittir. K-EYK'den sonra en iyi doğruluk %79.3734 ile DVM sınıflandırıcısından elde edilmiştir. Üçüncü sırada %74.4125 ile KA sınıflandırıcısı gelmektedir. Diğer sınıflandırıcıların SBS ve DA doğruluk değerlerine bakıldığında iyi sonuçlar vermediği ve ÇAM değerine bakıldığında SPD iyi olmadığı görülmektedir.



Şekil 3. 1. MFKK'ye dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA

Sınıflandırıcıların doğruluk değerleri ve sınıflandırıcı performansları tek tek hesaplandıktan sonra yapılan tüm aşamalar 100 kez tekrarlanmış ve ortalama sınıflandırıcı başarıları (OSB) ile standart sapma hesaplanmıştır.

Tablo 3. 2. Deney sonuçları

Sınıflandırıcılar	Ortalama Sınıflandırıcı Başarısı	Standart sapma
k-EYK	78.7240	0.6777
DVM	78.4301	0.6325
SBS	60.1070	0.7319
KA	74.5457	1.0000
DA	69.3253	0.5788

Tablo 3.2’de görüldüğü üzere k-EYK algoritması için OSB %78.7240 standart sapması 0.6777 olarak hesaplanmıştır. En iyi sınıflandırma başarısı k-EYK algoritmasına aittir. DVM algoritmasının OSB’si %78.4301 standart sapması 0.6325 olarak hesaplanmıştır. SBS algoritmasının OSB’si %60.1070 ve standart sapması 0.7319’dır. KA sınıflandırıcısı için OSB %74.5457 ve standart sapma 1.0000 olarak hesaplanmıştır. Son olarak DA sınıflandırıcısının OSB’si %69.3253 ve standart sapması 0.5788 olarak hesaplanmıştır. Tabloda yer alan değerlerden de anlaşıldığı üzere en iyi sonuçlar k-EYK algoritmasından ve DVM algoritmasından elde edilmiştir.

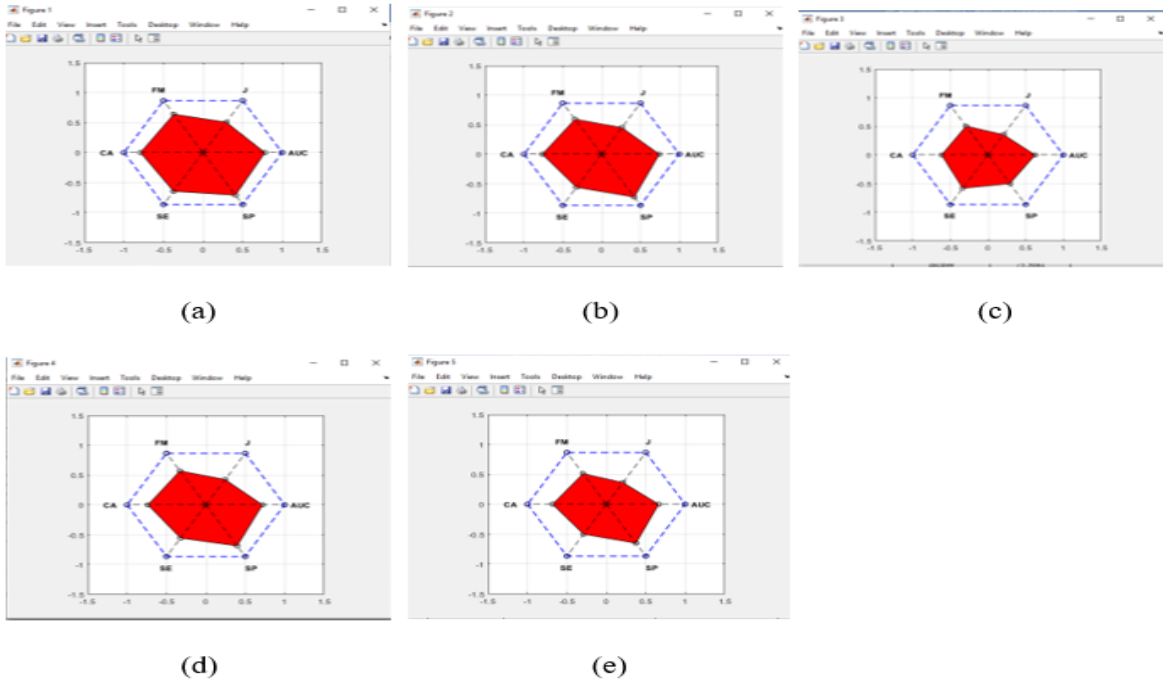
3.2. Gammatone Kepstral Katsayısı ile Elde Edilen Bulgular

GTKK hesaplandıktan sonra öznelik çıkarma işlemi gerçekleştirilmiş daha sonra veriler %50 eğitim ve %50 test olarak ayrılmıştır ve sınıflandırma işlemleri gerçekleştirilmiştir. Sınıflandırıcı performansını değerlendirmek için her sınıflandırma işleminin ardından SPD işlemi uygulanmıştır. Toplanan tüm sonuçlar aşağıdaki tabloda mevcuttur ayrıca sınıflandırma performansı ekran görüntüleri de aşağıda yer almaktadır.

Tablo 3. 3. GTKK'ye dayalı sınıflandırıcı ve SPD sonuçları

Sınıflandırıcı	k-EYK	DVM	SBS	KA	DA
Doğruluk	78.9258	76.1656	61.5069	73.3681	68.1089
ÇAM	0.55	0.49	0.34	0.45	0.37
SD	0.79	0.76	0.62	0.73	0.68
D	0.74	0.65	0.67	0.64	0.58
Ö	0.82	0.84	0.58	0.79	0.75
EAA	0.78	0.74	0.62	0.72	0.66
K	0.58	0.52	0.41	0.49	0.42
FÖ	0.74	0.68	0.58	0.66	0.59

Tablo 3.3'te görüldüğü üzere en iyi sınıflandırma doğruluğu %78.9258 ile k-EYK sınıflandırıcısından elde edilmiştir. ÇAM değerlerine bakıldığında da en iyi değerler k-EYK sınıflandırıcısına aittir. K-EYK'den sonra en iyi doğruluk %76.1656 ile DVM sınıflandırıcısından elde edilmiştir. Üçüncü sırada %73.3681 ile KA sınıflandırıcısı gelmektedir. Diğer sınıflandırıcıların SBS ve DA doğruluk değerlerine bakıldığında iyi sonuçlar vermediği ve ÇAM değerine bakıldığında SPD iyi olmadığı görülmektedir.



Şekil 3. 2. . GTKK'ye dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA

Sınıflandırıcıların doğruluk değerleri ve sınıflandırıcı performansları tek tek hesaplandıktan sonra yapılan tüm aşamalar 100 kez tekrarlanmış ve ortalama sınıflandırıcı başarıları (OSB) ile standart sapma hesaplanmıştır. Hesaplanan bu değerler aşağıdaki tabloda yer almaktadır.

Tablo 3. 4. Deney sonuçları

Sınıflandırıcılar	Ortalama Sınıflandırıcı Başarısı	Standart sapma
k-EYK	78.0854	0.6388
DVM	76.6195	0.6953
SBS	60.8803	0.6400
KA	72.5196	1.0206
DA	67.8971	0.8067

Tablo 3.4'te görüldüğü üzere k-EYK algoritması için OSB %78.0854 standart sapması 0.6388 olarak hesaplanmıştır. En iyi sınıflandırma başarıları k-EYK algoritmasına aittir. DVM algoritmasının OSB'si %76.6195 standart sapması 0.6953 olarak hesaplanmıştır. SBS algoritmasının OSB'si %60.8803 ve standart sapması 0.6400'dir. KA sınıflandırıcısı için OSB %72.5196 ve standart sapma 1.0206 olarak hesaplanmıştır. Son olarak DA sınıflandırıcısının OSB'si %67.8971 ve standart sapması 0.8067 olarak hesaplanmıştır. Tabloda yer alan değerlerden de anlaşıldığı üzere en iyi sonuçlar k-EYK algoritmasından ve DVM algoritmasından elde edilmiştir.

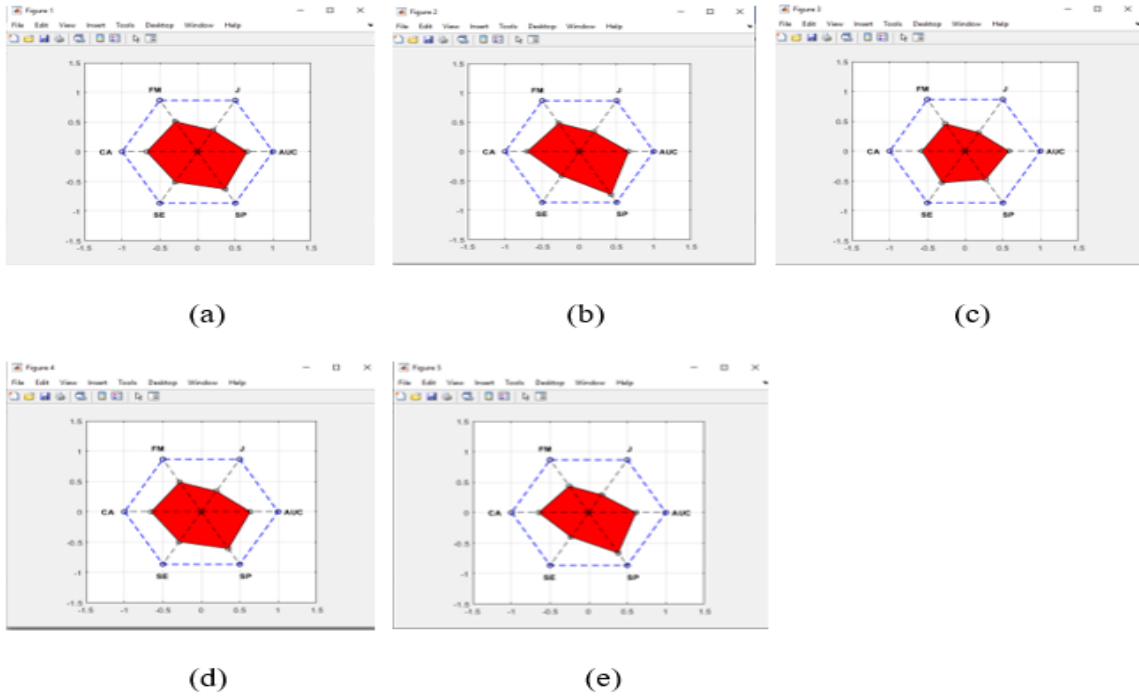
3.3. Doğrusal Tahmin Katsayısı ile Elde Edilen Bulgular

DTK hesaplandıktan sonra öznitelik çıkarma işlemi gerçekleştirilmiş daha sonra veriler %50 eğitim ve %50 test olarak ayrılmıştır ve sınıflandırma işlemleri gerçekleştirilmiştir. Sınıflandırıcı performansını değerlendirmek için her sınıflandırma işleminin ardından SPD işlemi uygulanmıştır. Toplanan tüm sonuçlar aşağıdaki tabloda mevcuttur ayrıca sınıflandırma performansı ekran görüntüleri de aşağıda yer almaktadır.

Tablo 3. 5. DTK'ye dayalı sınıflandırıcı ve SPD sonuçları

Sınıflandırıcı	k-EYK	DVM	SBS	KA	DA
Doğruluk	67.2510	70.1604	57.0310	65.0877	64.4909
ÇAM	0.37	0.36	0.28	0.34	0.30
SD	0.67	0.70	0.57	0.65	0.64
D	0.59	0.48	0.61	0.57	0.46
Ö	0.73	0.85	0.54	0.70	0.76
EAA	0.66	0.66	0.58	0.64	0.61
K	0.41	0.38	0.36	0.39	0.34
FÖ	0.58	0.56	0.53	0.56	0.50

Tablo 3.5'te görüldüğü üzere %67.2510 k-EYK sınıflandırıcısından elde edilmiştir. DVM algoritması ile %70.1604 doğruluk elde edilmiştir. KA sınıflandırıcısı ile %65.0877 doğruluk sağlanmıştır. SBS ve DA sırası ile %57.0310 ve %64.4909 doğruluk elde edilmiştir. Sınıflandırıcı doğrulukları ve SPD göz önüne alındığında DTK kullandığımız veri kümesi için uygun bir metrik değeridir.



Şekil 3. 3. DTK'ye dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA

Sınıflandırıcıların doğruluk değerleri ve sınıflandırıcı performansları tek tek hesaplandıktan sonra yapılan tüm aşamalar 100 kez tekrarlanmış ve ortalama sınıflandırıcı başarıları (OSB) ile standart sapma hesaplanmıştır. Hesaplanan bu değerler aşağıdaki tabloda yer almaktadır.

Tablo 3. 6. Deney sonuçları

Sınıflandırıcılar	Ortalama Sınıflandırıcı Başarısı	Standart sapma
k-EYK	68.6404	0.7434
DVM	69.7452	0.9213
SBS	56.4502	0.6672
KA	65.0966	1.1009
DA	64.0537	0.7724

Tablo 3.6’da görüldüğü üzere k-EYK algoritması için OSB %68.6404 standart sapması 0.7434 olarak hesaplanmıştır. DVM algoritmasının OSB’si 69.7452 standart sapması 0.9213 olarak hesaplanmıştır. SBS algoritmasının OSB’si %56.4502 ve standart sapması 0.6672’dir. KA sınıflandırıcısı için OSB %65.0966 ve standart sapma 1.1009 olarak hesaplanmıştır. Son olarak DA sınıflandırıcısının OSB’si %64.0537 ve standart sapması 0.7724 olarak hesaplanmıştır.

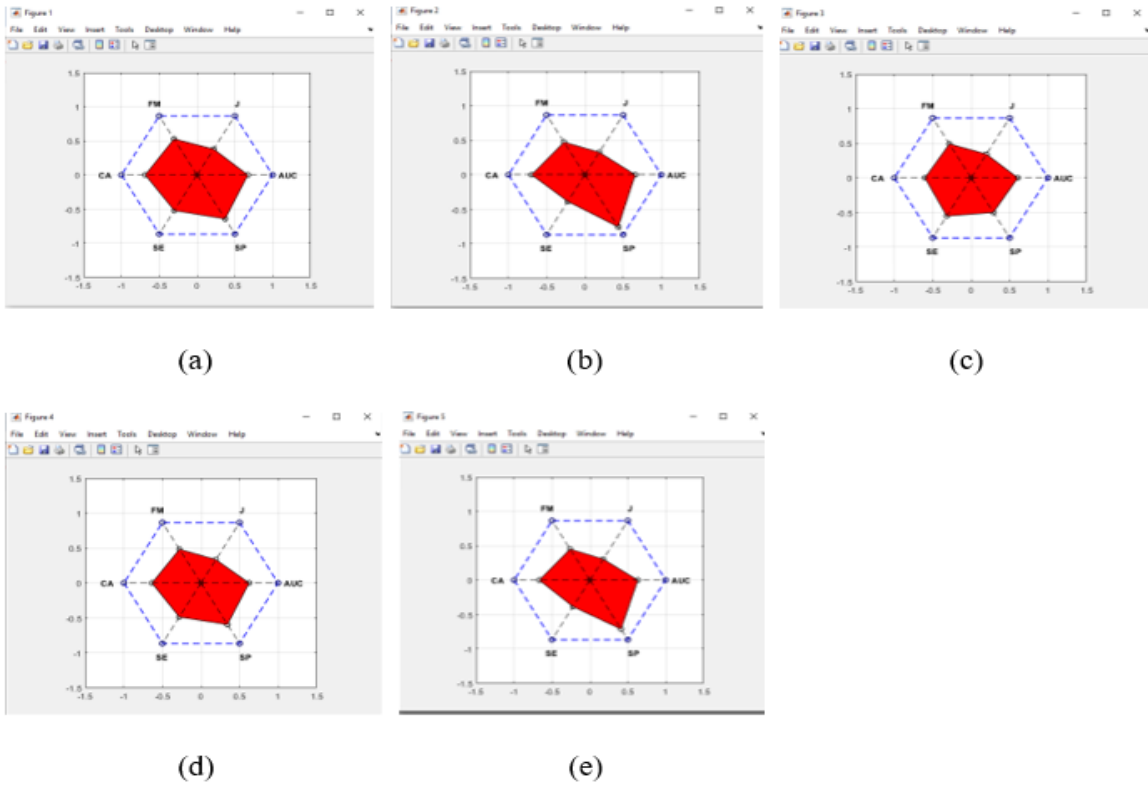
3.4. Doğrusal Tahmin Kepstral Katsayısı ile Elde Edilen Bulgular

DTKK hesaplandıktan sonra öznelik çıkarma işlemi gerçekleştirilmiş daha sonra veriler %50 eğitim ve %50 test olarak ayrılmıştır ve sınıflandırma işlemleri gerçekleştirilmiştir. Sınıflandırıcı performansını değerlendirmek için her sınıflandırma işleminin ardından SPD işlemi uygulanmıştır. Toplanan tüm sonuçlar aşağıdaki tabloda mevcuttur ayrıca sınıflandırma performansı ekran görüntüleri de aşağıda yer almaktadır.

Tablo 3. 7. DTKK'ye dayalı sınıflandırıcı ve SPD sonuçları

Sınıflandırıcı	k-EYK	DVM	SBS	KA	DA
Doğruluk	68.4446	69.5636	60.0522	63.4838	66.6169
ÇAM	0.39	0.35	0.32	0.33	0.32
SD	0.68	0.70	0.60	0.63	0.67
D	0.60	0.45	0.64	0.56	0.44
Ö	0.74	0.87	0.58	0.69	0.82
EAA	0.67	0.66	0.61	0.62	0.63
K	0.44	0.37	0.39	0.39	0.35
FÖ	0.61	0.55	0.57	0.56	0.52

Tablo 3.7'de görüldüğü üzere %68.4446 k-EYK sınıflandırıcısından elde edilmiştir. DVM algoritması ile %69.5636 doğruluk elde edilmiştir. KA sınıflandırıcısı ile %63.4838 doğruluk sağlanmıştır. SBS ve DA sırası ile %60.0522 ve %66.6169 doğruluk elde edilmiştir. Sınıflandırıcı doğrulukları ve SPD göz önüne alındığında DTKK kullandığımız veri kümesi için uygun bir metrik değildir.



Şekil 3. 4. DTKK'ye dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA

Sınıflandırıcıların doğruluk değerleri ve sınıflandırıcı performansları tek tek hesaplandıktan sonra yapılan tüm aşamalar 100 kez tekrarlanmış ve ortalama sınıflandırıcı başarıları (OSB) ile standart sapma hesaplanmıştır. Hesaplanan bu değerler aşağıdaki tabloda yer almaktadır.

Tablo 3. 8. Deney sonuçları

Sınıflandırıcılar	Ortalama Sınıflandırıcı Başarısı	Standart sapma
k-EYK	67.6695	0.6667
DVM	69.7456	1.0035
SBS	59.6755	0.6115
KA	63.5166	1.0365
DA	65.1645	0.8063

Tablo 3.8’de görüldüğü üzere k-EYK algoritması için OSB %67.6695 standart sapması 0.6667 olarak hesaplanmıştır. DVM algoritmasının OSB’si 69.7456 standart sapması 1.0035 olarak hesaplanmıştır. SBS algoritmasının OSB’si %59.6755 ve standart sapması 0.6115’dir. KA sınıflandırıcısı için OSB %63.5166 ve standart sapma 1.0365 olarak hesaplanmıştır. Son olarak DA sınıflandırıcısının OSB’si %65.1645 ve standart sapması 0.8063 olarak hesaplanmıştır.

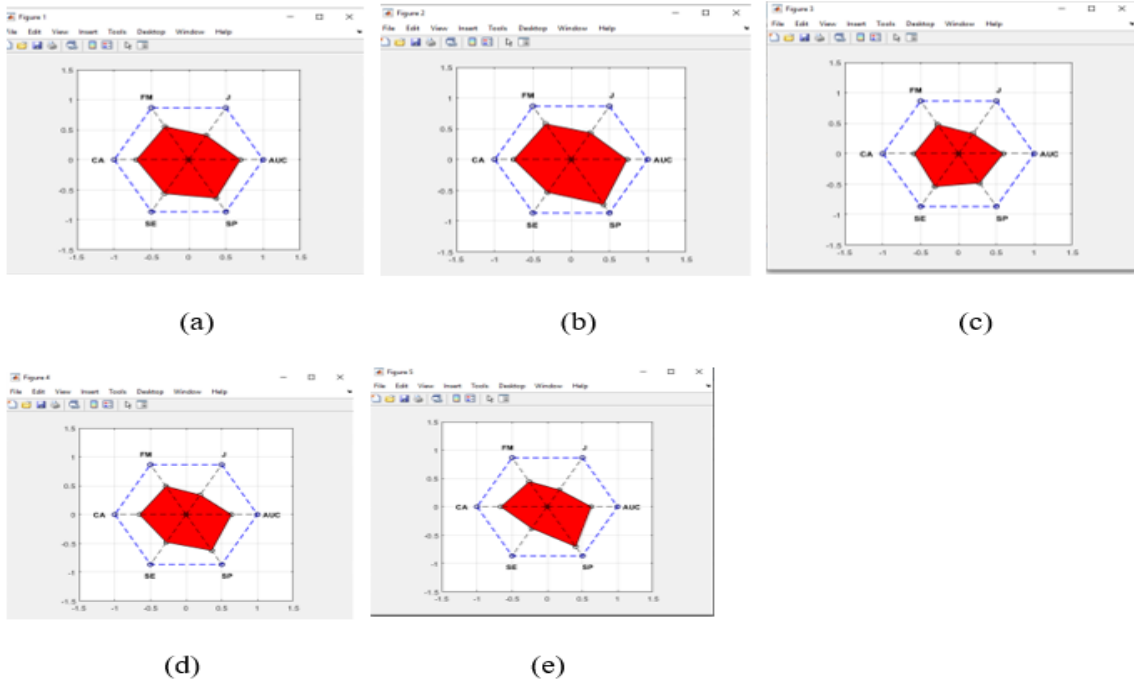
3.5. Yansıma Katsayısı ile Elde Edilen Bulgular

YK hesaplandıktan sonra öznitelik çıkarma işlemi gerçekleştirilmiş daha sonra veriler %50 eğitim ve %50 test olarak ayrılmıştır ve sınıflandırma işlemleri gerçekleştirilmiştir. Sınıflandırıcı performansını değerlendirmek için her sınıflandırma işleminin ardından SPD işlemi uygulanmıştır. Toplanan tüm sonuçlar aşağıdaki tabloda mevcuttur ayrıca sınıflandırma performansı ekran görüntüleri de aşağıda yer almaktadır.

Tablo 3. 9. YK'ye dayalı mıflandırıcı ve SPD sonuçları

Sınıflandırıcı	k-EYK	DVM	SBS	KA	DA
Doğruluk	70.0485	74.8601	58.2618	65.0504	65.8336
ÇAM	0.42	0.46	0.30	0.34	0.31
SD	0.70	0.75	0.58	0.65	0.66
D	0.65	0.61	0.62	0.55	0.44
Ö	0.74	0.84	0.55	0.72	0.81
EAA	0.69	0.73	0.59	0.64	0.62
K	0.47	0.50	0.38	0.39	0.34
FÖ	0.64	0.67	0.55	0.56	0.51

Tablo 3.9'da görüldüğü üzere %70.0485 k-EYK sınıflandırıcısından elde edilmiştir. DVM algoritması ile %74.8601 doğruluk elde edilmiştir. KA sınıflandırıcısı ile %65.0504 doğruluk sağlanmıştır. SBS ve DA sırası ile %58.2618 ve %65.8336 doğruluk elde edilmiştir. Sınıflandırıcı doğrulukları ve SPD göz önüne alındığında DTK kullandığımız veri kümesi için uygun bir metrik değildir.



Şekil 3. 5. YK'ye dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA

Sınıflandırıcıların doğruluk değerleri ve sınıflandırıcı performansları tek tek hesaplandıktan sonra yapılan tüm aşamalar 100 kez tekrarlanmış ve ortalama sınıflandırıcı başarıları (OSB) ile standart sapma hesaplanmıştır. Hesaplanan bu değerler aşağıdaki tabloda yer almaktadır.

Tablo 3. 10. Deney sonuçları

Sınıflandırıcılar	Ortalama Sınıflandırıcı Başarısı	Standart sapma
k-EYK	69.2025	0.7811
DVM	73.2838	0.8132
SBS	59.5878	0.9390
KA	66.1011	1.1420
DA	65.8053	0.7991

Tablo 3.10'da görüldüğü üzere k-EYK algoritması için OSB %69.2025 standart sapması 0.7811 olarak hesaplanmıştır. DVM algoritmasının OSB'si %73.2838 standart sapması 0.8132 olarak hesaplanmıştır. SBS algoritmasının OSB'si 59.5878 ve standart sapması 0.9390'dir. KA sınıflandırıcısı için OSB %66.1011 ve standart sapma 1.1420 olarak hesaplanmıştır. Son olarak DA sınıflandırıcısının OSB'si %65.8053 ve standart sapması 0.7991 olarak hesaplanmıştır.

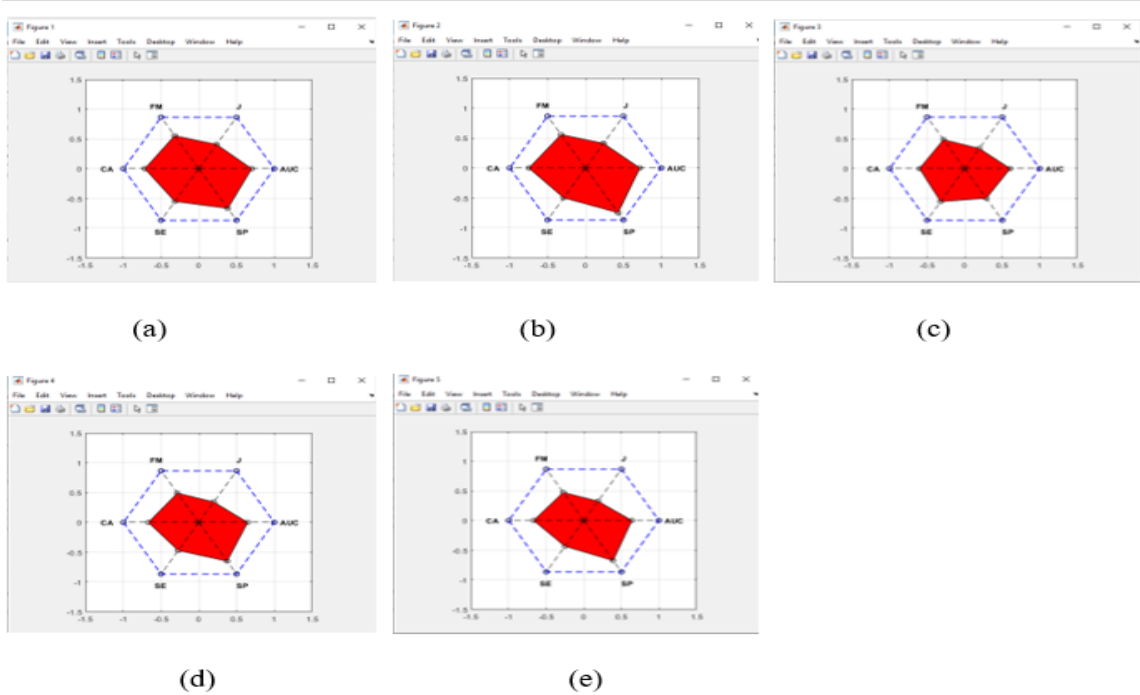
3.6. LOG Alanı Oranları ile Elde Edilen Bulgular

LAO hesaplandıktan sonra öznitelik çıkarma işlemi gerçekleştirilmiş daha sonra veriler %50 eğitim ve %50 test olarak ayrılmıştır ve sınıflandırma işlemleri gerçekleştirilmiştir. Sınıflandırıcı performansını değerlendirmek için her sınıflandırma işleminin ardından SPD işlemi uygulanmıştır. Toplanan tüm sonuçlar aşağıdaki tabloda mevcuttur ayrıca sınıflandırma performansı ekran görüntüleri de aşağıda yer almaktadır.

Tablo 3. 11. LAO'ya dayalı sınıflandırıcı ve SPD sonuçları

Sınıflandırıcı	k-EYK	DVM	SBS	KA	DA
Doğruluk	71.4659	74.5990	60.0149	66.7661	63.7661
ÇAM	0.43	0.44	0.31	0.35	0.34
SD	0.71	0.75	0.60	0.67	0.67
D	0.63	0.57	0.64	0.54	0.50
Ö	0.77	0.86	0.57	0.75	0.78
EAA	0.70	0.72	0.61	0.65	0.64
K	0.47	0.47	0.39	0.40	0.38
FÖ	0.64	0.64	0.56	0.57	0.55

Tablo 3.11'de görüldüğü üzere %71.4659 k-EYK sınıflandırıcısından elde edilmiştir. DVM algoritması ile %74.5990 doğruluk elde edilmiştir. KA sınıflandırıcısı ile %66.7661 doğruluk sağlanmıştır. SBS ve DA sırası ile %60.0149 ve %63.7661 doğruluk elde edilmiştir. Sınıflandırıcı doğrulukları ve SPD göz önüne alındığında DTK kullandığımız veri kümesi için uygun bir metrik değildir.



Şekil 3. 6. LAO'ya dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA

Sınıflandırıcıların doğruluk değerleri ve sınıflandırıcı performansları tek tek hesaplandıktan sonra yapılan tüm aşamalar 100 kez tekrarlanmış ve ortalama sınıflandırıcı başarıları (OSB) ile standart sapma hesaplanmıştır. Hesaplanan bu değerler aşağıdaki tabloda yer almaktadır.

Tablo 3. 12. Deney sonuçları

Sınıflandırıcılar	Ortalama Sınıflandırıcı Başarısı	Standart sapma
k-EYK	71.2827	0.7331
DVM	73.1555	0.9064
SBS	59.6229	0.9674
KA	67.1578	1.0000
DA	66.8855	0.8100

Tablo 3.12’de görüldüğü üzere k-EYK algoritması için OSB %71.2827 standart sapması 0.7331 olarak hesaplanmıştır. DVM algoritmasının OSB’si %73.1555 standart sapması 0.9064 olarak hesaplanmıştır. SBS algoritmasının OSB’si %59.6229 ve standart sapması 0.9674’dir. KA sınıflandırıcısı için OSB %67.1578 ve standart sapma 1.0000 olarak hesaplanmıştır. Son olarak DA sınıflandırıcısının OSB’si %66.8855 ve standart sapması 0.8100 olarak hesaplanmıştır.

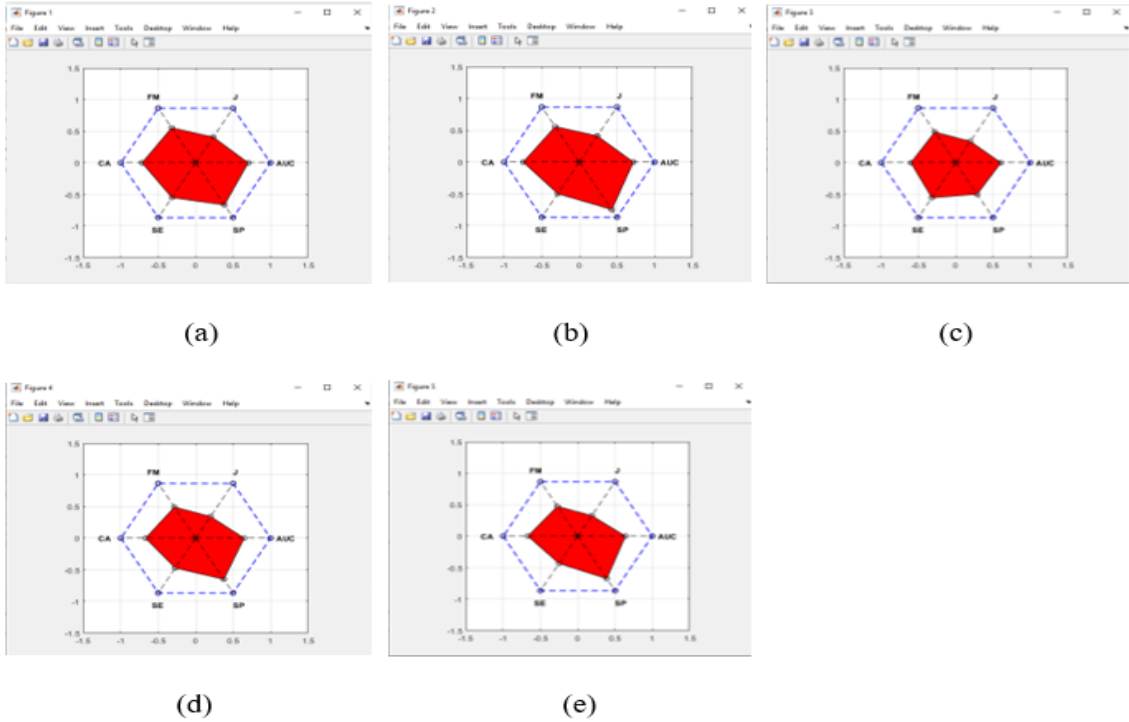
3.7. LOG Filtre Bankası Enerjileri ile Elde Edilen Bulgular

LFBE hesaplandıktan sonra öznitelik çıkarma işlemi gerçekleştirilmiş daha sonra veriler %50 eğitim ve %50 test olarak ayrılmıştır ve sınıflandırma işlemleri gerçekleştirilmiştir. Sınıflandırıcı performansını değerlendirmek için her sınıflandırma işleminin ardından SPD işlemi uygulanmıştır. Toplanan tüm sonuçlar aşağıdaki tabloda mevcuttur ayrıca sınıflandırma performansı ekran görüntüleri de aşağıda yer almaktadır.

Tablo 3. 13. LFBE'ye dayalı sınıflandırıcı ve SPD sonuçları

Sınıflandırıcı	k-EYK	DVM	SBS	KA	DA
Doğruluk	72.9579	66.9526	59.5300	64.9012	66.3931
ÇAM	0.46	0.34	0.33	0.34	0.33
SD	0.73	0.67	0.60	0.65	0.66
D	0.69	0.50	0.73	0.57	0.50
Ö	0.76	0.78	0.51	0.70	0.77
EAA	0.72	0.64	0.62	0.63	0.63
K	0.50	0.37	0.41	0.39	0.37
FÖ	0.66	0.54	0.59	0.56	0.54

Tablo 3.13'te görüldüğü üzere %72.9579 k-EYK sınıflandırıcısından elde edilmiştir. DVM algoritması ile %66.9526 doğruluk elde edilmiştir. KA sınıflandırıcısı ile %64.9012 doğruluk sağlanmıştır. SBS ve DA sırası ile %59.5300 ve %66.3931 doğruluk elde edilmiştir. Sınıflandırıcı doğrulukları ve SPD göz önüne alındığında DTK kullandığımız veri kümesi için uygun bir metrik değildir.



Şekil 3. 7. LFBE'ye dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA

Sınıflandırıcıların doğruluk değerleri ve sınıflandırıcı performansları tek tek hesaplandıktan sonra yapılan tüm aşamalar 100 kez tekrarlanmış ve ortalama sınıflandırıcı başarıları (OSB) ile standart sapma hesaplanmıştır. Hesaplanan bu değerler aşağıdaki tabloda yer almaktadır.

Tablo 3. 14. Deney sonuçları

Sınıflandırıcılar	Ortalama Sınıflandırıcı Başarısı	Standart sapma
k-EYK	73.2902	0.6876
DVM	67.7035	0.7874
SBS	60.3689	0.8082
KA	68.0485	0.9281
DA	65.0705	0.8940

Tablo 3.14'te görüldüğü üzere k-EYK algoritması için OSB %73.2902 standart sapması 0.6876 olarak hesaplanmıştır. DVM algoritmasının OSB'si 67.7035 standart sapması 0.7874 olarak hesaplanmıştır. SBS algoritmasının OSB'si %60.3689 ve standart sapması 0.8082'dir. KA sınıflandırıcısı için OSB %68.0485 ve standart sapma 0.9281 olarak hesaplanmıştır. Son olarak DA sınıflandırıcısının OSB'si %65.0705 ve standart sapması 0.8940 olarak hesaplanmıştır.

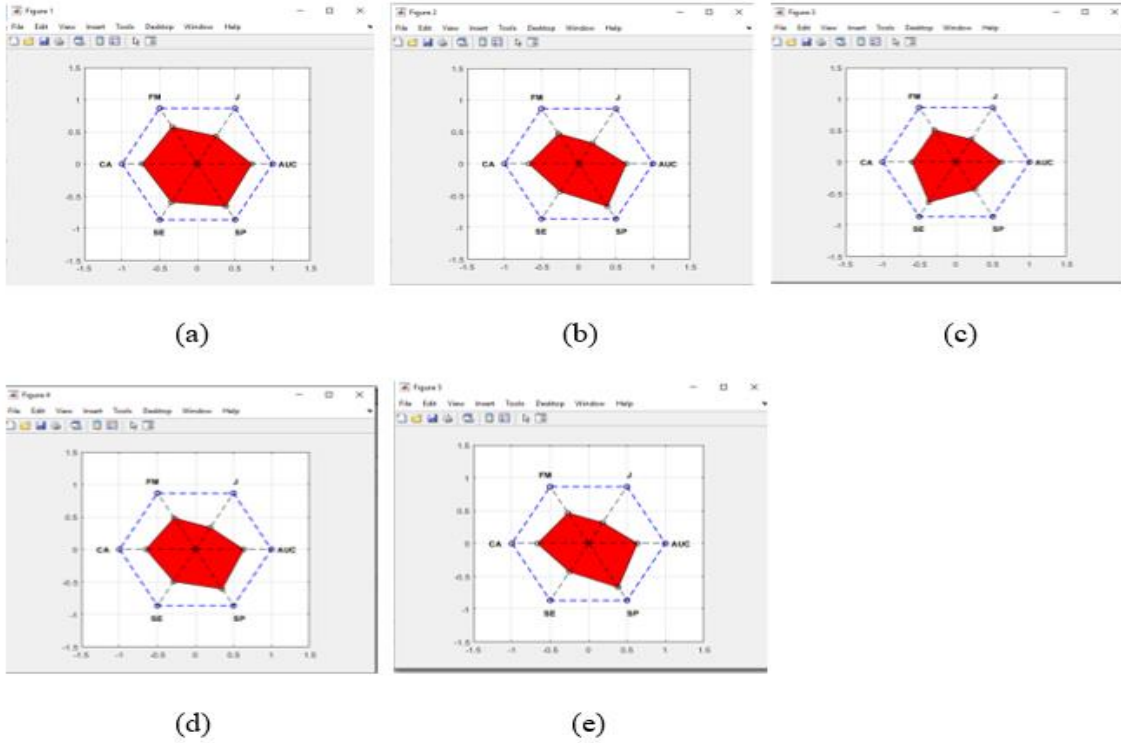
3.8. Spektral Alt Bant Sentroidleri ile Elde Edilen Bulgular

SABS hesaplandıktan sonra öznitelik çıkarma işlemi gerçekleştirilmiş daha sonra veriler %50 eğitim ve %50 test olarak ayrılmıştır ve sınıflandırma işlemleri gerçekleştirilmiştir. Sınıflandırıcı performansını değerlendirmek için her sınıflandırma işleminin ardından SPD işlemi uygulanmıştır. Toplanan tüm sonuçlar aşağıdaki tabloda mevcuttur ayrıca sınıflandırma performansı ekran görüntüleri de aşağıda yer almaktadır.

Tablo 3. 15. SABS'ye dayalı sınıflandırıcı ve SPD sonuçları

Sınıflandırıcı	k-EYK	DVM	SBS	KA	DA
Doğruluk	64.4909	63.7822	59.2689	62.5140	65.7217
ÇAM	0.34	0.30	0.32	0.32	0.34
SD	0.64	0.64	0.59	0.63	0.66
D	0.57	0.45	0.68	0.56	0.54
Ö	0.69	0.76	0.53	0.67	0.73
EAA	0.63	0.61	0.61	0.61	0.64
K	0.39	0.33	0.40	0.37	0.39
FÖ	0.56	0.50	0.57	0.54	0.56

Tablo 3.15'te görüldüğü üzere %64.4909 k-EYK sınıflandırıcısından elde edilmiştir. DVM algoritması ile %63.7822 doğruluk elde edilmiştir. KA sınıflandırıcısı ile %62.5140 doğruluk sağlanmıştır. SBS ve DA sırası ile %59.2689 ve %65.7217 doğruluk elde edilmiştir. Sınıflandırıcı doğrulukları ve SPD göz önüne alındığında DTK kullandığımız veri kümesi için uygun bir metrik değildir.



Şekil 3. 8. SABS'ye dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA

Sınıflandırıcıların doğruluk değerleri ve sınıflandırıcı performansları tek tek hesaplandıktan sonra yapılan tüm aşamalar 100 kez tekrarlanmış ve ortalama sınıflandırıcı başarıları (OSB) ile standart sapma hesaplanmıştır. Hesaplanan bu değerler aşağıdaki tabloda yer almaktadır.

Tablo 3. 16. Deney sonuçları

Sınıflandırıcılar	Ortalama Sınıflandırıcı Başarısı	Standart sapma
k-EYK	63.6434	0.8369
DVM	64.2577	0.7984
SBS	59.8385	0.6648
KA	62.7915	1.0230
DA	64.4054	0.8848

Tablo 3.16’da görüldüğü üzere k-EYK algoritması için OSB %63.6434 standart sapması 0.8369 olarak hesaplanmıştır. DVM algoritmasının OSB’si 64.2577 standart sapması 0.7984 olarak hesaplanmıştır. SBS algoritmasının OSB’si %59.8385 ve standart sapması 0.6648’dir. KA sınıflandırıcısı için OSB %62.7915 ve standart sapma 1.0230 olarak hesaplanmıştır. Son olarak DA sınıflandırıcısının OSB’si %64.4054 ve standart sapması 0.8848 olarak hesaplanmıştır.

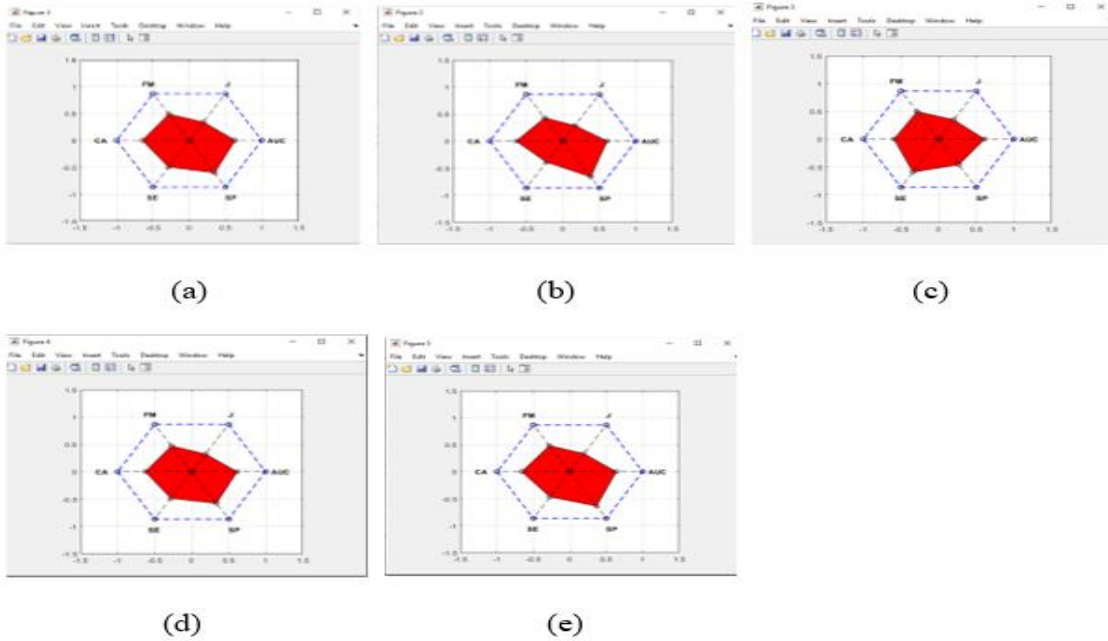
3.9. Çizgi Spektral Frekansları ile Elde Edilen Bulgular

ÇSF hesaplandıktan sonra öznitelik çıkarma işlemi gerçekleştirilmiş daha sonra veriler %50 eğitim ve %50 test olarak ayrılmıştır ve sınıflandırma işlemleri gerçekleştirilmiştir. Sınıflandırıcı performansını değerlendirmek için her sınıflandırma işleminin ardından SPD işlemi uygulanmıştır. Toplanan tüm sonuçlar aşağıdaki tabloda mevcuttur ayrıca sınıflandırma performansı ekran görüntüleri de aşağıda yer almaktadır.

Tablo 3. 17. ÇSF'ye dayalı sınıflandırıcı ve SPD sonuçları

Sınıflandırıcı	k-EYK	DVM	SBS	KA	DA
Doğruluk	60.9101	60.6490	57.4413	61.5815	60.4625
ÇAM	0.29	0.23	0.31	0.30	0.26
SD	0.61	0.61	0.57	0.62	0.60
D	0.50	0.33	0.75	0.51	0.40
Ö	0.68	0.79	0.46	0.68	0.74
EAA	0.59	0.56	0.60	0.60	0.57
K	0.34	0.25	0.42	0.35	0.29
FÖ	0.51	0.41	0.59	0.52	0.45

Tablo 3.17'de görüldüğü üzere %60.9101 k-EYK sınıflandırıcısından elde edilmiştir. DVM algoritması ile %60.6490 doğruluk elde edilmiştir. KA sınıflandırıcısı ile %61.5815 doğruluk sağlanmıştır. SBS ve DA sırası ile %57.4413 ve %60.4625 doğruluk elde edilmiştir. Sınıflandırıcı doğrulukları ve SPD göz önüne alındığında DTK kullandığımız veri kümesi için uygun bir metrik değildir.



Şekil 3. 9. ÇSF'ye dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA

Sınıflandırıcıların doğruluk değerleri ve sınıflandırıcı performansları tek tek hesaplandıktan sonra yapılan tüm aşamalar 100 kez tekrarlanmış ve ortalama sınıflandırıcı başarıları (OSB) ile standart sapma hesaplanmıştır. Hesaplanan bu değerler aşağıdaki tabloda yer almaktadır.

Tablo 3. 18. Deney sonuçları

Sınıflandırıcılar	Ortalama Sınıflandırıcı Başarısı	Standart sapma
k-EYK	60.4543	0.7849
DVM	60.8198	0.7823
SBS	57.9411	0.7462
KA	61.6979	0.9093
DA	60.9392	0.7787

Tablo 3.18’de görüldüğü üzere k-EYK algoritması için OSB %60.4543 standart sapması 0.7849 olarak hesaplanmıştır. DVM algoritmasının OSB’si 60.8198 standart sapması 0.7823 olarak hesaplanmıştır. SBS algoritmasının OSB’si %57.9411 ve standart sapması 0.7462’dir. KA sınıflandırıcısı için OSB %61.6979 ve standart sapma 0.9093 olarak hesaplanmıştır. Son olarak DA sınıflandırıcısının OSB’si %60.9392 ve standart sapması 0.7787 olarak hesaplanmıştır.

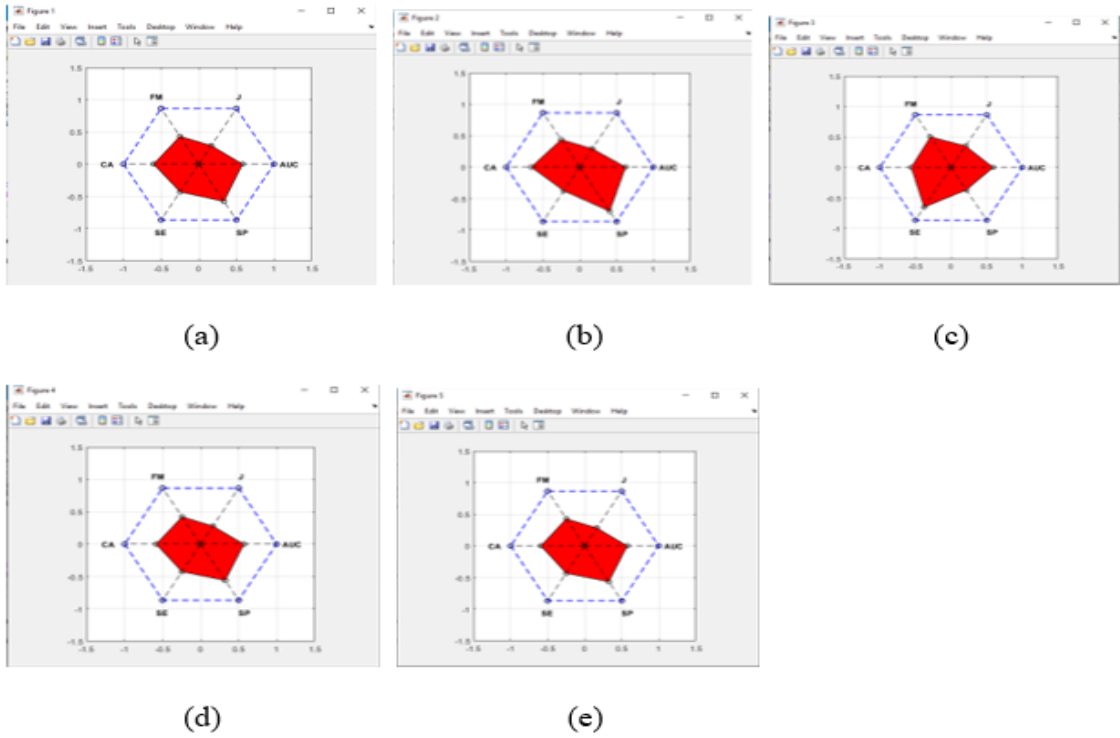
3.10. Güç Spektrumu ile Elde Edilen Bulgular

GS hesaplandıktan sonra öznelik çıkarma işlemi gerçekleştirilmiş daha sonra veriler %50 eğitim ve %50 test olarak ayrılmıştır ve sınıflandırma işlemleri gerçekleştirilmiştir. Sınıflandırıcı performansını değerlendirmek için her sınıflandırma işleminin ardından SPD işlemi uygulanmıştır. Toplanan tüm sonuçlar aşağıdaki tabloda mevcuttur ayrıca sınıflandırma performansı ekran görüntüleri de aşağıda yer almaktadır.

Tablo 3. 19. GS'ye dayalı sınıflandırıcı ve SPD sonuçları

Sınıflandırıcı	k-EYK	DVM	SBS	KA	DA
Doğruluk	59.8284	65.8336	55.7628	58.3364	58.9705
ÇAM	0.28	0.31	0.30	0.27	0.27
SD	0.60	0.66	0.56	0.58	0.59
D	0.50	0.43	0.75	0.49	0.50
Ö	0.67	0.81	0.43	0.65	0.65
EAA	0.58	0.62	0.59	0.57	0.57
K	0.33	0.34	0.41	0.32	0.33
FÖ	0.50	0.50	0.58	0.49	0.49

Tablo 3.19'da görüldüğü üzere %59.8284 k-EYK sınıflandırıcısından elde edilmiştir. DVM algoritması ile %65.8336 doğruluk elde edilmiştir. KA sınıflandırıcısı ile %58.3364 doğruluk sağlanmıştır. SBS ve DA sırası ile %55.7628 ve %58.9705 doğruluk elde edilmiştir. Sınıflandırıcı doğrulukları ve SPD göz önüne alındığında DTK kullandığımız veri kümesi için uygun bir metrik değildir.



Şekil 3. 10. GS'ye dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA

Sınıflandırıcıların doğruluk değerleri ve sınıflandırıcı performansları tek tek hesaplandıktan sonra yapılan tüm aşamalar 100 kez tekrarlanmış ve ortalama sınıflandırıcı başarıları (OSB) ile standart sapma hesaplanmıştır. Hesaplanan bu değerler aşağıdaki tabloda yer almaktadır.

Tablo 3. 20. Deney sonuçları

Sınıflandırıcılar	Ortalama Sınıflandırıcı Başarısı	Standart sapma
k-EYK	59.1291	0.8276
DVM	65.8616	0.9213
SBS	55.8639	1.1579
KA	59.6024	0.9746
DA	58.2395	0.9868

Tablo 3.20’de görüldüğü üzere k-EYK algoritması için OSB %59.1291 standart sapması 0.8276 olarak hesaplanmıştır. DVM algoritmasının OSB’si %65.8616 standart sapması 0.9213 olarak hesaplanmıştır. SBS algoritmasının OSB’si %55.8639 ve standart sapması 1.1579’dir. KA sınıflandırıcısı için OSB %59.6024 ve standart sapma 0.9746 olarak hesaplanmıştır. Son olarak DA sınıflandırıcısının OSB’si %58.2395 ve standart sapması 0.9868 olarak hesaplanmıştır.

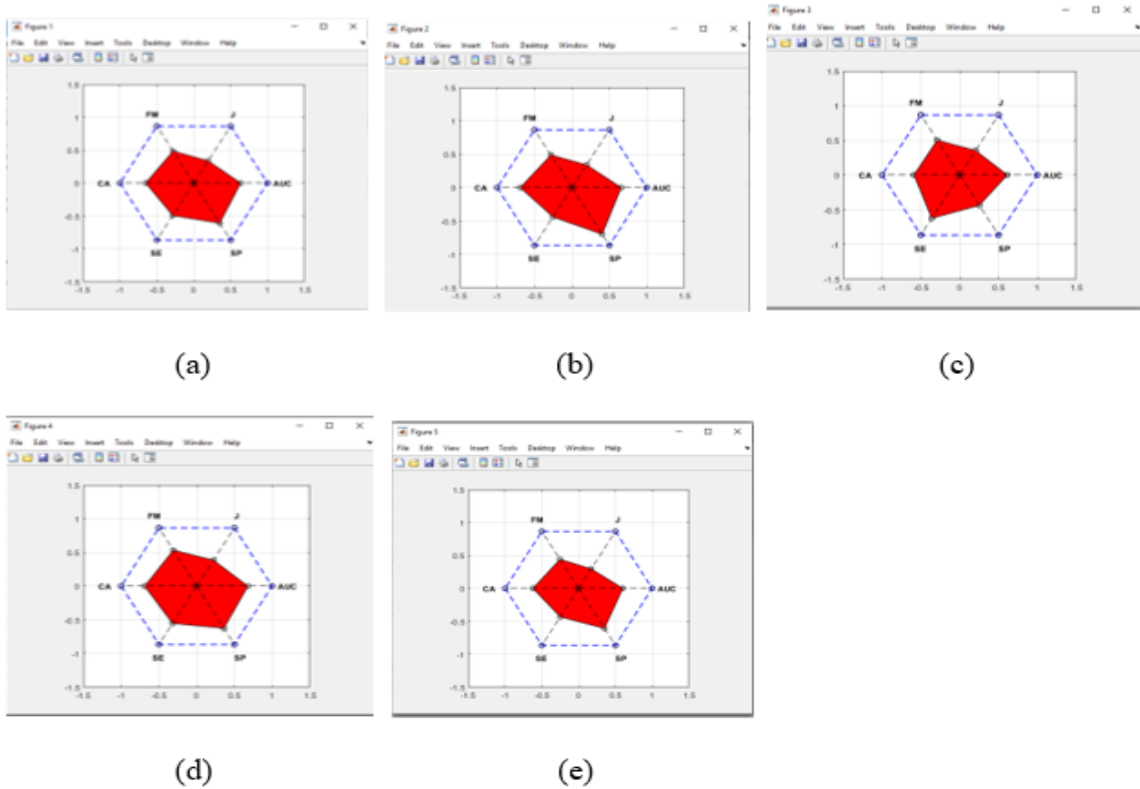
3.11. Algısal Doğrusal Tahmin Katsayısı ile Elde Edilen Bulgular

ADTK hesaplandıktan sonra öznitelik çıkarma işlemi gerçekleştirilmiş daha sonra veriler %50 eğitim ve %50 test olarak ayrılmıştır ve sınıflandırma işlemleri gerçekleştirilmiştir. Sınıflandırıcı performansını değerlendirmek için her sınıflandırma işleminin ardından SPD işlemi uygulanmıştır. Toplanan tüm sonuçlar aşağıdaki tabloda mevcuttur ayrıca sınıflandırma performansı ekran görüntüleri de aşağıda yer almaktadır.

Tablo 3. 21. ADTK'ye dayalı sınıflandırıcı ve SPD sonuçları

Sınıflandırıcı	k-EYK	DVM	SBS	KA	DA
Doğruluk	65.0131	69.0041	58.8586	68.8176	62.1783
ÇAM	0.34	0.36	0.32	0.40	0.30
SD	0.65	0.69	0.59	0.69	0.62
D	0.57	0.51	0.72	0.64	0.50
Ö	0.70	0.81	0.50	0.72	0.70
EAA	0.64	0.66	0.61	0.68	0.60
K	0.39	0.39	0.41	0.44	0.34
FÖ	0.56	0.56	0.58	0.62	0.51

Tablo 3.21'de görüldüğü üzere %65.0131 k-EYK sınıflandırıcısından elde edilmiştir. DVM algoritması ile %69.0041 doğruluk elde edilmiştir. KA sınıflandırıcısı ile %68.8176 doğruluk sağlanmıştır. SBS ve DA sırası ile %58.8586 ve %62.1783 doğruluk elde edilmiştir. Sınıflandırıcı doğrulukları ve SPD göz önüne alındığında DTK kullandığımız veri kümesi için uygun bir metrik değildir.



Şekil 3. 11. ADTK'ye dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA

Sınıflandırıcıların doğruluk değerleri ve sınıflandırıcı performansları tek tek hesaplandıktan sonra yapılan tüm aşamalar 100 kez tekrarlanmış ve ortalama sınıflandırıcı başarıları (OSB) ile standart sapma hesaplanmıştır. Hesaplanan bu değerler aşağıdaki tabloda yer almaktadır.

Tablo 3. 22. Deney sonuçları

Sınıflandırıcılar	Ortalama Sınıflandırıcı Başarısı	Standart sapma
k-EYK	65.4010	0.7274
DVM	68.4920	0.9387
SBS	59.4476	0.7096
KA	68.6975	1.1694
DA	62.5151	0.7944

Tablo 3.22’de görüldüğü üzere k-EYK algoritması için OSB %65.4010 standart sapması 0.7274 olarak hesaplanmıştır. DVM algoritmasının OSB’si 68.4920 standart sapması 0.9387 olarak hesaplanmıştır. SBS algoritmasının OSB’si %59.4476 ve standart sapması 0.7096’dir. KA sınıflandırıcısı için OSB %68.6975 ve standart sapma 1.1694 olarak hesaplanmıştır. Son olarak DA sınıflandırıcısının OSB’si %62.5151 ve standart sapması 0.7944 olarak hesaplanmıştır.

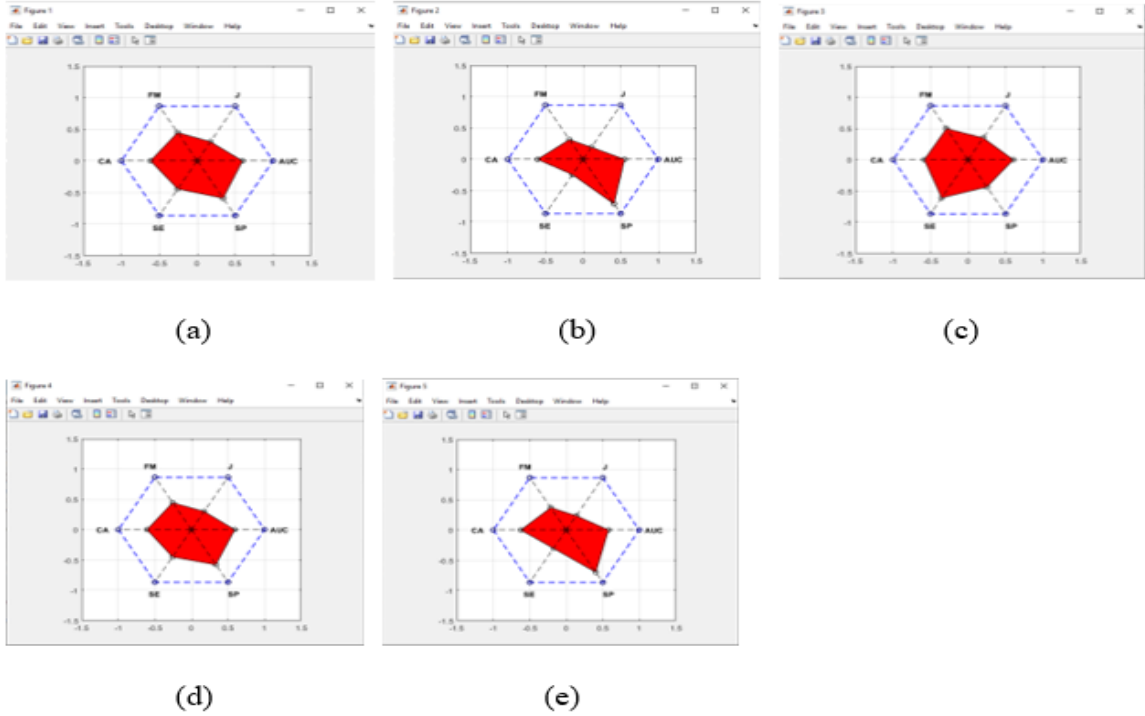
3.12. Spertra-Algısal Doğrusal Tahmin Katsayısı ile Elde Edilen Bulgular

SADTK hesaplandıktan sonra öznitelik çıkarma işlemi gerçekleştirilmiş daha sonra veriler %50 eğitim ve %50 test olarak ayrılmıştır ve sınıflandırma işlemleri gerçekleştirilmiştir. Sınıflandırıcı performansını değerlendirmek için her sınıflandırma işleminin ardından SPD işlemi uygulanmıştır. Toplanan tüm sonuçlar aşağıdaki tabloda mevcuttur ayrıca sınıflandırma performansı ekran görüntüleri de aşağıda yer almaktadır.

Tablo 3. 23. SADTK'ye dayalı sınıflandırıcı ve SPD sonuçları

Sınıflandırıcı	k-EYK	DVM	SBS	KA	DA
Doğruluk	61.3950	60.3879	58.2991	60.7236	62.2529
ÇAM	0.30	0.21	0.31	0.29	0.25
SD	0.61	0.60	0.58	0.61	0.62
D	0.51	0.28	0.70	0.52	0.35
Ö	0.68	0.82	0.50	0.67	0.81
EAA	0.60	0.55	0.60	0.59	0.58
K	0.35	0.22	0.40	0.35	0.27
FÖ	0.52	0.36	0.57	0.51	0.43

Tablo 3.23'te görüldüğü üzere %61.3950 k-EYK sınıflandırıcısından elde edilmiştir. DVM algoritması ile %60.3879 doğruluk elde edilmiştir. KA sınıflandırıcısı ile %60.7236 doğruluk sağlanmıştır. SBS ve DA sırası ile %58.2991 ve %62.2529 doğruluk elde edilmiştir. Sınıflandırıcı doğrulukları ve SPD göz önüne alındığında DTK kullandığımız veri kümesi için uygun bir metrik değildir.



Şekil 3. 12. SADTK'ye dayalı ÇAM grafikleri a)k-EYK b)DVM c)SBS d)KA e)DA

Sınıflandırıcıların doğruluk değerleri ve sınıflandırıcı performansları tek tek hesaplandıktan sonra yapılan tüm aşamalar 100 kez tekrarlanmış ve ortalama sınıflandırıcı başarıları (OSB) ile standart sapma hesaplanmıştır. Hesaplanan bu değerler aşağıdaki tabloda yer almaktadır.

Tablo 3. 24. Deney sonuçları

Sınıflandırıcılar	Ortalama Sınıflandırıcı Başarısı	Standart sapma
k-EYK	61.2462	0.6773
DVM	60.8363	0.7940
SBS	58.6125	0.7485
KA	60.6468	1.0411
DA	61.1153	0.7529

Tablo 3.24'te görüldüğü üzere k-EYK algoritması için OSB %61.2462 standart sapması 0.6773 olarak hesaplanmıştır. DVM algoritmasının OSB'si 60.8363 standart sapması 0.7940 olarak hesaplanmıştır. SBS algoritmasının OSB'si %58.6125 ve standart sapması 0.7485'dir. KA sınıflandırıcısı için OSB %60.6468 ve standart sapma 1.0411 olarak hesaplanmıştır. Son olarak DA sınıflandırıcısının OSB'si %61.1153 ve standart sapması 0.7529 olarak hesaplanmıştır.

4. TARTIŞMA VE SONUÇLAR

Bu tez çalışmasında gelişen dünya ile birlikte değişen çalışma şartlarının da getirdiği sorunlardan biri olan bilişsel yorgunluğun tespiti için çalışmalar yürütülmüştür. Uzun yıllardır bilişsel yorgunluğun tespiti için birçok çalışma yapılmıştır. Bu çalışmalardan bazıları nesnel olmayan yöntemleri içeren anket çalışmalarından oluşmaktadır. Daha sonra nesnel veriler elde edebilmek için fizyolojik ölçümlerden faydalanılmıştır. Bu fizyolojik yöntemlerden biri de EEG sinyalleri ile yapılan çalışmalardır. Bu nedenden dolayı çalışmada EEG sinyallerini içeren Cogbeacon veri seti kullanılmıştır. EEG sinyalleri doğası gereği değişik gösteren sinyaller olduğu için sağlıklı yorumlayabilmek için matematiksel yöntemlerle analiz edilmektedir. Bu tez çalışmasında da EEG sinyalleri üzerinde matematiksel analizler yapılmıştır.

EEG sinyallerinden; daha çok ses sinyallerinin analizinde kullanılan 12 farklı katsayı hesaplanmıştır. Bu katsayıları ile ilgili bilgiler bölüm 2.2. de ayrıntılı olarak anlatılmıştır. Daha sonra katsayı hesaplama işleminden sonra öznitelik çıkarma işlemi uygulanmıştır. Uygulanan öznitelikler de bölüm 2.3. te ayrıntılı olarak anlatılmıştır. Kullanılan verilerin boyutları birbirinden farklı olduğu için özniteliklerin uzunluktan bağımsız olmasına dikkat edilmiştir. Sınıflandırma işlemi içinde beş farklı sınıflandırıcı denenmiştir. Buradaki amaç farklı parametreleri daha iyi karşılaştırabilmek olmuştur. Yapılan çalışmanın sonucunda MFKK ve GTKK katsayıları ve k-EYK ile DVM algoritmaları ile yapılan sınıflandırma işleminden elde edilen ortalama sınıflandırıcı doğrulukları sırası ile %78.724, %78.4301 ve %78.085, %76.6195 veri setini kullandığımız çalışmada alınan sonuçlardan daha iyidir.

Veri setinin toplanma biçimi göz önüne alındığında diğer çalışmalara göre iyi bir sonuç olduğunu söyleyebiliriz. Genelde EEG verileri çok sayıda elektrotlu laboratuvar ortamları için uygun olan cihazlarla toplanmaktadır. Elde ettiğimiz sonuçlar MUSE EEG cihazı gibi kullanımı kolay hazır sensörler ile yapılan ölçümlerden de anlamlı ayrıntıları ayırt edebileceğimizi göstermiştir.

Hesaplanan katsayılara dayalı elde edilen tüm sınıflandırma sonuçları Tablo 4.1’de birlikte verilmiştir.

Tablo 4. 1. Katsayılara dayalı sınıflandırıcı sonuçları

Katsayılar	Sınıflandırma doğruluğu (%)				
	k-EYK	DVM	SBS	KA	DA
MFKK	78.72	78.43	60.10	74.54	69.32
GTKK	78.08	76.61	60.88	72.51	67.89
DTK	68.64	69.74	56.45	65.09	64.05
DTKK	67.66	69.74	59.67	63.51	65.16
YK	69.20	73.28	59.58	66.10	65.80
LAO	71.28	73.15	59.62	67.15	66.88
LFBE	73.29	67.70	60.36	68.04	65.07
SABS	63.64	64.25	59.83	62.79	64.88
ÇSF	60.45	60.81	57.94	61.69	60.93
GS	59.12	65.86	55.86	59.60	58.23
ADTK	65.40	68.49	59.44	68.69	62.51
SADTK	61.24	60.83	58.61	60.64	61.11

Tablo 4.1 de görüldüğü üzere bilişsel yorgunluğun tespiti için EEG sinyallerinin analizinde MFKK ve GTKK katsayıları kullanılabilir. Ayrıca sınıflandırıcı olarak k-EYK ve DVM algoritmaları kullanılmalıdır. Bölüm 3’te bulgulardan bahsederken ayrıntılı bir şekilde sınıflandırma performansı değerlendirmesi sonuçlarına da yer verilmiştir. SPD sonuçlarına bakıldığında en iyi performansın k-EYK ve DVM algoritmasının gösterdiği görülmektedir. Sınıflandırıcılardan bazıları %70’in üzerinde sonuçlar vermiş olsa da SPD çok iyi olmadığı için bu sonuçlar tek başına iyi kabul edilemez. Bundan dolayı kullandığımız sınıflandırıcının performans değerlendirmesinin de ne kadar önemli olduğu anlaşılmaktadır.

CogBeacon veri seti kullanılarak yapılan diğer çalışmaların karşılaştırması aşağıdaki tabloda verilmektedir.

Tablo 4. 2. CogBeacon veri seti kullanılarak yapılan çalışmalar

No	Öznitelikler	Sınıflandırıcılar	Sınıflandırıcı Doğruluğu
1	Ortalama değer	Gauss Dairesel Tabanlı İşlev Çekirdeği, Rastgele Ormanlar, Ekstra Ağaçlar, Gradyan Yükselten DVM'leri denemiştir.	Ortalama % 67 doğruluk elde edilmiştir.
	Standart sapma		
	Maksimum değer		
	Minimum değer		
	Spektral sentroid		
	Spektral rollof		
2	Varyans	DVM sınıflandırıcısı ve k-EYK sınıflandırıcısı denenmiştir.	DVM için ortalama doğruluk % 83.14 k-EYK için ortalama doğruluk % 83.34
	Ortalama değer		
	Kovaryans		
	Standart sapma		
	Katz Fraktal Boyut		
	Higuchi Fraktal Boyut		
3	Ortalama karekök	k-EYK, DVM, SBS, KA, DA	DVM için ortalama doğruluk % 78.43 k-EYK için ortalama doğruluk % 78.72
	Log detektörü		
	Ortalama mutlak değer		
	Değiştirilmiş ortalama mutlak değer 1		
	Değiştirilmiş ortalama mutlak değer 2		
	Geliştirilmiş ortalama mutlak değer		

Tablo 4.2. de yer alan 1. çalışma Papakostas tarafından yapılmıştır. Papakostas yaptığı çalışmada 10 kat çapraz doğrulama yaparak verileri belirlenmiş ortalama % 67 doğruluk elde etmiştir [2]. İkinci sırada yer alan çalışma Ekim ve arkadaşları tarafından yapılmıştır. Veriler rastgele belirlenmiştir ve DVM ile test ortalaması % 83.14 k-EYK ile test ortalaması % 83.34 elde edilmiştir [62]. Tez çalışmasında ses sinyallerinin analizinde kullanılan bazı katsayılar hesaplanmış ve veriler rast gele olarak ayrılmıştır. Daha sonra öznitelik çıkarma işlemleri

gerçekleştirilmiş ve MFKK ve GTKK katsayıları ve k-EYK ile DVM algoritmaları ile yapılan sınıflandırma işleminden elde edilen ortalama sınıflandırıcı doğrulukları sırası ile %78.724, %78.430 ve %78.085, %76.6195 bulunmuştur. Elde edilen bu sonuçlar Papakostas'ın çalışmasında alınan sonuçlardan daha iyi ancak Fraktal Boyut özniteliklerini kullanılarak yapılan Ekim ve arkadaşlarının çalışmasından düşüktür. Tez çalışmasında ulaşılan sonuçlar veri analizlerinde farklı alanlara ait tekniklerin kullanılabilceğidir.



5. ÖNERİLER

Bu çalışmada bilişsel yorgunluğun tespitinde farklı parametreler denenmiş ve bu yönde katkı sağlanmak istenmiştir. Ses sinyallerinin analizinde kullanılan MKKK ve GTKK katsayılarının EEG sinyalinde bilişsel yorgunluğun tespiti için kullanılabileceği görülmüştür. Sınıflandırıcı performans değerlendirmesinin ne kadar önemli olduğuna dikkat çekilmek istenmiştir. Ayrıca farklı boyuttaki verilerin uzunluktan bağımsız uygun öznitelikler seçildiğinde iyi sonuçlar elde edilebileceği görülmüştür.

İlerleyen çalışmalarımızda EEG verileri toplamak için yine kulaklık gibi kullanılan ama teknolojik olarak daha gelişmiş cihazlarla toplanmış veriler kullanılabilir. Öznitelikler değiştirilebilir ya da artırılabilir.

Bu çalışma bilişsel yorgunluğun günlük hayat seyrinde rahatlıkla tespit edilebileceğini göstermiştir. Bilişsel yorgunluğun tespitinin önemli olduğu iş gruplarına entegre edilebilir.

6. KAYNAKLAR

1. Chuckravanen, D., Approximate Entropy as a Measure of Cognitive Fatigue: An EEG Pilot Study, IJETST, (2014) 1036–1042.
2. Papakostas, M., Rajavenkatanarayanan, A. ve Makedon, F., CogBeacon: A Multi-Modal Dataset and Data-Collection Platform for Modeling Cognitive Fatigue, Technologies, 7, 46 (2019).
3. Zhang, C., Zheng, C.X. ve Yu, X.L., Automatic Recognition of Cognitive Fatigue from Physiological Indices by Using Wavelet Packet Transform and Kernel Learning Algorithms, Expert Systems with Applications, 36 (2009) 4664–4671.
4. Avcı, D.E. ve Yağbasan, R., Beyin Yarı Kürelerinin Baskın Olarak Kullanılmasına Yönelik Öğretim Stratejileri, Gazi Eğitim Fakültesi Dergisi, 28, 2 (2008) 1–17.
5. Korkmaz, Ö. ve Mahiroğlu, A., Beyin, Bellek ve Öğrenme, Kastamonu Eğitim Dergisi, 15, 1 (2007) 93–104.
6. Kılıç Ekici, Ö., İnsan Beyninin Yapısı Nasıldır?, <https://bilimgenc.tubitak.gov.tr/makale/insan-beyninin-yapisi-nasildir>, 7 Nisan 2021.
7. <https://saglik.ihya.com/sinir-sistemi/sinir-hucresinin-noronun-yapisi-ve-gorevleri.html>, Sinir Hücresinin (Nöronun) Yapısı ve Görevleri, 7 Nisan 2021.
8. Picton, T.W. ve Mazaheri, A., Electroencephalography (EEG), Encyclopedia of Cognitive Science, (2006).
9. Teplan, M., Fundamentals of EEG, Measurement Science Review, 2, 2 (2002).
10. Ozkan, N.F. ve Kahya, E., An Experiment in Use of Brain Computer Interfaces for Cognitive Researches, International Journal of Intelligence Science 5, (2015) 80-88.
11. Williges, R.C. ve Wierwille, W.W., Behavioral Measures of Aircrew Mental Workload, Human Factors Society, 21, 5 (1979) 49-574.
12. McCracken, J.H. ve Aldrich, T.B., Analysis of Selected LHX Mission Functions, Implications for Operator Workload and System Automation Goals, Anacapa Sciences Inc., (1984), Tech. Note ASI 479-024-84(B).
13. Aldrich, T.B. ve Szabo, S.M., et al., The development and Application of Models to Predict Operator Workload During System Design. Applications of Human Performance Models to System Design. G.R.B. McMillan, D.; Salas, E.; Strub, M.H.; Sutton, R.; van Breda, L. New York, Plenum Press., 2 (1989) 65-80.
14. North, R.A. ve Riley, V.A., W/INDEX: a Predictive Model of Operator Workload, in G. R. McMillan, D. Beevis, E. Salas, M. H. Strub, R. Sutton and L. Van Breda (eds),

- Applications of Human Performance Models to System Design, Defense Research Series, 2, 81-90, New York: Plenum Press, 1989.
15. Reid, G.B., Current Status of the Development of the Subjective Workload Assessment Technique, Proceedings of the Human Factors Society, (1985) 220–223.
 16. Hart, S.G. ve Wickens, C.D., Workload Assessment and Prediction, Van Nostrand Reinhold, (1990) 257–296.
 17. Hart, S. G. ve Staveland, L. E., Development of NASA-TLX (Task Load Index) Results of Empirical and Theoretical Research, In P. A. Hancock and N. Meshkati (Eds.) Human Mental Workload, Amsterdam: North Holland Press, 1988.
 18. Boles, D.B. ve Adair, L.P., Validity of the Multiple Resources Questionnaire (MRQ), submitted to the Human Factors and Ergonomics Society, (2001).
 19. Farmer, P.N. ve E.W., Performance and Workload measurement In Simulation-Based Training, Paper presented at the AMP Symposium on "Selection and Training Advances in Aviation", Held in Prague, Czech Republic, in May 1996, and published in CP-588.
 20. Roscoe, A.H. ve Ellis, G.A., Assessing Pilot Workload, NATO AGARD (Advisory Group for Aerospace Research and Development), 7 rue Ancelle, 92200 Neuilly-sur-Seine, Fr. 84, (1978) 78–82.
 21. Cain, B., A Review of the Mental Workload Literature, Defence research and development Toronto (Canada), 2007.
 22. Hendy, K.C., An Introduction to the IP/PCT Model Implementation in IPME, DRDC Toronto TR 2010-040, (2011).
 23. Annett, J., Subjective Rating Scales: Science or art? Ergonomics, 45 (2002) 966–987.
 24. Kalsbeek, J.W.H., Standards of Acceptable Load in ATC Tasks. Ergonomics, 145 (2007) 641-650.
 25. Rouse, W.B., Approaches to Mental Workload, Mental Workload Its Theory and Measurement, Nevi lie Moray University of Stirling Stirling, Scotland Springer, 1979.
 26. Enstrom, K.D. ve Rouse, W.B., Real-Time Determination of How a Human Has Allocated His Attention Between Control and Monitoring Tasks, IEEE Trans. Syst., 7 (1977) 153–161.
 27. Colle, H.A. ve Reid, G.B., Double Trade-off Curves with Different Cognitive Processing Combinations: Testing the Cancellation Axiom of Mental Workload Measurement Theory, Hum. Factors Ergon. Soc., 41 (1999) 35–50.
 28. Charles, R.L. ve Nixon, J., Measuring mental workload using physiological measures: A systematic review, Appl. Ergon., 74 (2019) 221–232.

29. Causse, M., Senard, J.-M., Demonet, J.F. ve Pastor, J., Monitoring Cognitive and Emotional Processes Through Pupil and Cardiac Response During Dynamic Versus Logical Task, Appl Psychophysiol Biofeedback, 35 (2010) 115–123.
30. Gao, Q., Wang, Y., Song, F., Li, Z. ve Dong, X., Mental workload measurement for emergency operating procedures in digital nuclear power plants, Ergonomics, 56 (2013) 1070–1085
31. Recarte, M.A. ve Nunes, L.M., Mental Workload While Driving : Effects on Visual Search , Discrimination , and Decision Making, J. Exp. Psychol., 9 (2003) 119–137.
32. Rivecourt, M. De, Kuperus, M.N., Post, W.J. ve Mulder, L.J.M., Cardiovascular and Eye Activity Measures as Indices for Momentary Changes in Mental Effort During Simulated Flight. Ergonomics, 51 (2008) 1295–1319.
33. Ryu, K. ve Myung, R., Evaluation of Mental Workload with a Combined Measure Based on Physiological Indices During a Dual Task of Tracking and Mental Arithmetic, Int. J. Ind. Ergon., 35 (2005) 991–1009.
34. Veltman, J.A., A Comparative Study of Psychophysiological Reactions During Simulator and Real Flight, Int. J. Aviat. Psychol., 12 (2002) 33–48.
35. Veltman, J.A. ve Gaillard, A.W.K., Physiological Indices of Workload Flight Task, Biol. Psychol., 42 (1996) 323–342.
36. Brookings, J.B., Wilson, G.F. ve Swain, C.R., Psychophysiological Responses to Changes in Workload During Simulated Air Traffic Control, Biol. Psychol., 42 (1996) 361–377.
37. Wilson, G.F., An Analysis of Mental Workload in Pilots During Flight Using Multiple Psychophysiological Measures, Int. J. Aviat. Psychol., 12 (2002) 3–18.
38. Roscoe, A.H., Assessing Pilot Workload. Why Measure Heart Rate, HRV and Respiration?, Biol. Psychol., 34 (1992) 259–287.
39. Backs, R.W., Ted Navidzadeh, H. ve Xu, X., Cardiorespiratory Indices of Mental Workload During Simulated Air Traffic Control, Proceedings of the XIVth Triennial Congress of the International Ergonomics, (2000) 89–92.
40. Grassmann, M., Vlemincx, E., Von Leupoldt, A., Mittelstädt, J.M. ve Van Den Bergh, O., Respiratory Changes in Response to Cognitive Load: A Systematic Review, Neural Plasticity, 2016.
41. Bernardi, L., Wdowczyk-Szulc, J., Valenti, C., Castoldi, S., Passino, C., Spadacini, G. ve Sleight, P., Effects of Controlled Breathing, Mental Activity and Mental Stress with or without Verbalization on Heart Rate Variability, Journal of the American College of Cardiology, 35 (2000) 1462–1469.
42. Sirevaag, E.J., Kramer, A.F., Wickens, C.D., Reisweber, M., Strayer, D.L. ve Grenell,

- J.F., Assessment of Pilot Performance and Mental Workload in Rotary Wing Aircraft, Ergonomics, 36 (1993) 1121–1140.
43. Hwang, S., Yau, Y., Lin, Y., Chen, J., Huang, T., Yenn, T. ve Hsu, C., Predicting Work Performance in Nuclear Power Plants, Saf. Sci., 46 (2008) 1115–1124.
 44. Finsen, L., Sjøgaard, K., Jensen, C., Borg, V. ve Christensen, H., Muscle Activity and Cardiovascular Response During Computer-Mouse Work with and without Memory Demands, Ergonomics, 44 (2001) 1312–1329.
 45. Boutcher, Y.N. ve Boutcher, S.H., Cardiovascular Response to Stroop: Effect of Verbal Response and Task Difficulty, Biol. Psychol., 73 (2006) 235–241.
 46. Sosnowski, T., Krzywosz-Rynkiewicz, B. ve Roguska, J., Program Running Versus Problem Solving: Mental Task Effect on Tonic Heart Rate, Psychophysiology, 41 (2004) 467–475.
 47. Veltman, J.A. ve Gaillard, A.W.K., Physiological Workload Reactions to Increasing Levels of Task Difficulty, Ergonomics, 41 (1998) 656–669.
 48. Tattersall, A.J. ve Hockey, G.R.J., Level of Operator Control and Changes in Heart Rate Variability During Simulated Flight Maintenance, Hum. Factors., 37 (1995) 682–698.
 49. Fallahi, M., Motamedzade, M., Heidarimoghadam, R. ve Reza, A., Effects of Mental Workload on Physiological and Subjective Responses During Traffic Density Monitoring: A Field Study, Appl. Ergon., 52 (2016) 95–103.
 50. Miyake, S., Multivariate Workload Evaluation Combining Physiological and Subjective Measures, Int. J. Psychophysiol., 40 (2001) 233–238.
 51. Nickel, P. ve Nachreiner, F., Sensitivity and Diagnosticity of the 0.1-Hz Component of Heart Rate Variability as an Indicator of Mental Workload, Hum. Factors., 45 (2003) 575–590.
 52. Guidelines, American, T.N., Heart Rate Variability: Standards of Measurement, Physiological Interpretation, and Clinical Use, Eur. Heart J., 17 (1996) 354–381.
 53. Tuncer, T., Dogan, S., Ertam, F. ve Subasi, A., A Dynamic Center and Multi Threshold Point Based Stable Feature Extraction Network for Driver Fatigue Detection Utilizing EEG Signals, Cogn. Neurodyn, (2020).
 54. Bhardwaj, R., Parameswaran, S. ve Balasubramaniana, V., Performance Comparison of Machine Learning and Deep Learning While Classifying Driver's Cognitive State, 2018 IEEE 13th Int. Conf. Ind. Inf. Syst., 89–93.
 55. Chai, R., Naik, G.R., Nguyen, T.N., Ling, S.H., Tran, Y., Craig, A. ve Nguyen, H.T., Driver Fatigue Classification with Independent Component by Entropy Rate Bound Minimization Analysis in an EEG-Based System, IEEE J. Biomed. Heal.

Informatics,21 (2017) 715–724.

56. Setiawan, A., Wibawa, A.D., Pane, E.S. ve Purnomo, M.H., EEG-based Mental Fatigue Detection Using Cognitive Tests and RVM Classification, 2019 Int. Conf. Artif. Intell. Inf. Technol., (2019) 180–185.
57. Dehais, F., Somon, B. ve Tim Mullen, Callan, D.E., A Neuroergonomics Approach to Measure Pilot's Cognitive Incapacitation in the Real World with EEG, Springer, (2020) 111–117.
58. Myrden, A. ve Chau, T., A Passive EEG-BCI for Single-Trial Detection of Changes in Mental State. IEEE Trans, Neural Syst. Rehabil. Eng., 25 (2017) 345–356.
59. Chai, R., Smith, M. R., Nguyen, T. N., Ling, S. H., Coutts, A. J. ve Nguyen, H. T., Comparing Features Extractors in EEG-based Cognitive Fatigue Detection of Demanding Computer Tasks, Proceedings of the Annual International Conference of the IEE Engineering in Medicine and Biology Society (EMBC), 37 (2015) 7594–7597.
60. Dimitrakopoulos, G.N., Member, S., Kakkos, I., Thakor, N. V, Bezerianos, A., Member, S. ve Sun, Y., A Mental Fatigue Index Based on Regression Using Multiband EEG Features with Application in Simulated Driving, In 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Seogwipo, (2017) 3220–3223.
61. Qu, H., Shan, Y., Liu, Y., Pang, L., Fan, Z., Zhang, J. ve Wanyan, X., Mental Workload Classification Method Based on EEG Independent Component Features, Appl. Sci., 10 (2020) 1 –15.
62. Ekim, A., Aydemir, Ö. ve Demir, M., Bilişsel Yorgunluğun EEG İşaretleri ile Sınıflandırılması, Tıptekno'20, 19-20 Kasım, Online, (2020) 30–33.
63. Bashivan, P., Rish, I. ve Heisig, S., Mental State Recognition via Wearable EEG, (2016).
64. <https://choosemuse.com/>, MUSE EEG Kulaklık, 21 Nisan 2021.
65. Barceló, F., Electrophysiological Evidence of Two Different Types of Error in the Wisconsin Card Sorting Test, Neuroreport, 10 (1999) 1299–1303.
66. Dias, N.S., Ferreira, D., Reis, J., Jacinto, R., Pinho, F., Festa, J., Pereira, M., Afonso, N. ve Santos, N.C., Age Effects on EEG Correlates of the Wisconsin Card Sorting Test, Physiol. Rep., 3 (2015) 1–15.
67. Nava-Vázquez, I.F., de Avila-Armenta, E., Espinoza-Bermúdez, L., Esquivel-Cordero, E., Chora-López, V., Galván-Tejada, J.I., Galván-Tejada, C.E. ve Gamboa-Rosales, H., Implementation of Novel Technologies and CAD Software to the Improve and Reduce of Costs in Orthotics Adaptation, IFMBE Proceedings, (2020) 933-938.

68. Ahmed, M.C. ve Koçer, H.E., Turkish Speech Recognition Using Mel-frequency Cepstral Coefficients (MFCC) and Hidden Markov Model (HMM), VERİ BİLİMİ DERGİSİ, 2 (2019) 39–44.
69. Abdulrahman, M., Gwadabe, T.R., Abdu, F.J. ve Eleyan, A., Gabor Wavelet Transform Based Facial Expression Recognition Using PCA and LBP. *Signal Process, Commun. Appl. Conf.*, (2014) 2265–2268.
70. Peker O., Speech Recognition by Turkish Word. In: *Signal Processing and Communication Application Conference (SIU)*, Zonguldak, Turkey, 2016 1737-1740.
71. Sharma, G., Umapathy, K. ve Krishnan, S., Trends in Audio Signal Feature Extraction Methods, Appl. Acoust., 158 (2020) 107020.
72. Luo, X. ve Feng, Y., An Underwater Acoustic Target Recognition Method Based on Restricted Boltzmann Machine, Sensors (Switzerland), 20 (2020) 1–18.
73. Azmy Gad, M.M., Classification of Mental Tasks Using Support Vector Machine Based on Linear Predictive Coding and New Mother Wavelet Transform, *Proc. - 2015 Int. Conf. Biomed. Eng. Comput. Technol. Sib.*, 2015 156–159.
74. Rabiner, L. ve Juang, B.-H., *Fundamentals of Spech Recognition*, PTR Prentice-Hall, (1993).
75. Karasartova, S., Metinden Bağımsız Konuşmacı Tanıma Sistemlerinin İncelenmesi ve Gerçekleştirilmesi, Yüksek lisans Tezi, Ankara Üniversitesi Fen bilimleri Enstitüsü, 2011.
76. Cooney, C., Folli, R. ve Coyle, D., Mel Frequency Cepstral Coefficients Enhance Imagined Speech Decoding Accuracy from EEG, *29th Irish Signals Syst. Conf. ISSC 2018*, (2018) 1–7.
77. Chow, D. ve Abdulla, W.H., Speaker Identification Based on Log Area Ratio and Gaussian Mixture Models in Narrow-Band Speech, *Trends in Artificial Intelligence*, Springer, (2004) 901–908.
78. Adeel, A., Gogate, M. ve Hussain, A., Contextual Deep Learning-Based Audio-Visual Switching for Speech Enhancement in Real-World Environments, Inf. Fusion., 59 (2020) 163–170.
79. Paliwal, K.K., Spectral Subband Centroids Features for Speech Recognition, *Proceedings of the International Conference Acoustics, Speech and Signal Processing (ICASSP)*, 2, Seattle, (1998) 617–620.
80. Yu, A. ve Wang, H., Effect of Noise on Line Spectrum Frequency and a Robust Speech Recognition Method for the Low Bit-Rate Encoded Speech, *Proc. Int. Conf. on Phonetic Science'99*, (1999).

81. Paliwal, K.K., Paliwal, K.K., Kleijn, W.B. ve Kleijn, W.B., Quantization of LPC Parameters, Speech Coding Synth., (1995) 433–466.
82. Gombos, T., Acoustic Recognition with Deep Learning Experimenting with Data Augmentation and Neural Networks, Master's thesis Department of Physics Faculty of Mathematics and Natural Sciences UNIVERSITY OF OSLO, Spring 2019.
83. Dave, N., Feature Extraction Methods LPC , PLP and MFCC In Speech Recognition, Int. J. Adv. Res. Eng. Technol., 1, 6 (2013) 1–5
84. Hermansky, H., Perceptual Linear Predictive (PLP) Analysis of Speech, J. Acoust. Soc. Am., 87, 4 (1990) 1738–1752.
85. Zulkifly, M.A.A. ve Yahya, N., Relative Spectral-Perceptual Linear Prediction (RASTA-PLP) Speech Signals Analysis Using Singular Value Decomposition (SVD), 2017 IEEE 3rd Int. Symp. Robot. Manuf. Autom. ROMA 2017. 2017-Decem, (2017) 1–5.
86. Kim, K.S., Choi, H.H., Moon, C.S. ve Muna, C.W., Comparison of k -Nearest Neighbor , Quadratic Discriminant and Linear Discriminant Analysis in Classification of Electromyogram Signals Based on the Wrist-Motion Directions, Curr. Appl. Phys. 11, 3 (2011) 740–745.
87. Too, J., Abdullah, A.R. ve Saad, N.M., Classification of Hand Movements based on Discrete Wavelet Transform and Enhanced Feature Extraction, Int J Adv Comput Sci Appl IJACSA, (2019).
88. Krishnan, P. ve Yaacob, S., Drowsiness Detection Using Band Power and log Energy Entropy Features Based on EEG Signals, Int J Innov Technol Explor Eng 8,10 (2019) 830–836.
89. Bablani, A., Edla, D.R. ve Dodia, S., ScienceDirect Classification Classification of EEG EEG Data Data using using k k -Nearest -Nearest Neighbor Neighbor approach approach for for Concealed Information Test Concealed Information Test, Procedia Comput. Sci., 143 (2018) 42–249.
90. https://www.mathworks.com/help/stats/fitcknn.html?s_tid=srchtitle#bt6cr9l-X, fitcknn, 29 Nisan 2021.
91. Fu, W., Shao, K., Tan, J. ve Wang, K., Fault Diagnosis for Rolling Bearings Based on Composite Multiscale Fine-Sorted Dispersion Entropy and SVM with Hybrid Mutation SCA-HHO Algorithm Optimization, IEEE Access., 8 (2020) 13086–13104.
92. Wang, S.H., et al., Classification Methods for Pathological Brain Detection, Pathological Brain Detection, Springer, Singapore, (2018) 119-147.
93. Alkan, A. ve Günay, M., Identification of EMG Signals Using Discriminant Analysis and SVM Classifier, Elsevier, 39 (2012) 44–47.
94. Tharwat, A., Linear vs. Quadratic Discriminant Analysis Classifier: a Tutorial, Int. J.

Appl. Pattern Recognit, 3, 2 (2016) 145–180.

95. Aydemir, O., A New Performance Evaluation Metric for Classifiers: Polygon Area Metric, J. Classif , (2020) 16–26.



ÖZGEÇMİŞ

Liseyi Abdurrahmanpaşa Lisesi'nde tamamladı. 2012 yılında Erciyes Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü'nü kazandı. 2017 yılında lisans eğitimini tamamladı. 2017 yılı güz döneminde KTÜ Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda yüksek lisans eğitimine başladı. Biyomedikal alanda yürütülen çalışmalara ilgi duyan EKİM, iyi derecede İngilizce bilmektedir.

Katıldığı Kongre Ve Toplantılar

1. Tıptekno'20, Medical Technologies Conference (Tıptekno'20), 5-6 Kasım 2020, İzmir