

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

DOKTORA TEZİ

**DERİN ÖĞRENME TABANLI BİYOMEDİKAL KARAR DESTEK
SİSTEMLERİNİN OLUŞTURULMASI**

Harun ÇİĞ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**ŞANLIURFA
2023**

İÇİNDEKİLER

Sayfa No

ÖZET	i
ABSTRACT.....	ii
TEŞEKKÜR.....	iii
ŞEKİLLER DİZİNİ	iv
ÇİZELGELER DİZİNİ	v
SİMGELER DİZİNİ	vi
1. GİRİŞ	1
1.1. Biyomedikal Sinyaller	5
1.1.1. Elektrokardiyografi	5
1.1.2. Elektroansefalografi	7
1.1.3. Elektrokülografi	10
1.1.4. Elektrokortikografi (ECOG).....	10
1.2. Biyomedikal Görüntüler	11
1.3. DDGUP tabanlı Beyin Bilgisayar Arayüzü Sistemleri	14
2. ÖNCEKİ ÇALIŞMALAR.....	16
3. MATERYAL ve YÖNTEM.....	28
3.1. Materyal	28
3.1.1. Biyomedikal sinyaller için kullanılan veri toplama cihazları	29
3.1.1.1. OpenBCI ganglion	29
3.1.1.2. Emotiv EPOC+	33
3.1.2. Biyomedikal sinyaller için veri seti oluşturma	34
3.1.2.1. EEG veri seti oluşturma	34
3.1.2.1.2. Veri toplama.....	35
3.1.2.2. EOG veri seti oluşturma.....	36
3.1.3. Biyomedikal görüntüler göğüs röntgeni veri seti	37
3.2. Yöntem.....	38
3.2.1. Biyomedikal sinyal analizi	39
3.2.1.1. Veri ön işleme	39
3.2.1.2. Veri artırma	48
3.2.1.3. Makine öğrenmesi ve derin öğrenme	50
3.2.2. Biyomedikal görüntülerin analizi ve kullanılan algoritmalar	61
3.2.2.1. Çok amaçlı guguk kuşu arama algoritması	62
3.2.2.2. Çok amaçlı guguk arama ile kontrast artışı	65
3.2.2.3. Evrişimli sinir ağları.....	69
4. ARAŞTIRMA BULGULARI ve TARTIŞMA	73
4.1. Biyomedikal Sinyal ve Görüntü Analizlerinin Değerlendirilmesi	73
4.1.1. Biyomedikal EEG sinyalleri ile insan duygularının tanınması	73
4.1.2. Biyomedikal EOG sinyalleri ile yön tespiti.....	78
4.1.3. Derin öğrenme tabanlı röntgen görüntü analizi ile hastalık tespiti	80
4.1.3.1. Değerlendirme metrikleri	81
4.1.3.2. Kullanılan KSA mimari tasarımı	82
4.1.3.3. DeneySEL sonuçlar	84
5. SONUÇLAR ve ÖNERİLER.....	90
KAYNAKLAR	92
ÖZGEÇMİŞ	107

ÖZET

Doktora Tezi

DERİN ÖĞRENME TABANLI BİYOMEDİKAL KARAR DESTEK SİSTEMLERİNİN OLUŞTURULMASI

Harun ÇİĞ

**Harran Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalı**

**Danışman: Prof. Dr. Mehmet Tahir GÜLLÜOĞLU
Yıl: 2023, Sayfa: 107**

Bu tez, derin öğrenme ve gelişmiş görüntü işleme tekniklerinin biyomedikal sinyal ve görüntü analizindeki etkin uygulamalarını farklı çalışmalar üzerinde detaylı bir şekilde incelemektedir. Tezin biyolojik sinyaller ile ilgili bölümünde EOG, EEG ve EKG gibi biyomedikal sinyaller incelenmiştir. EOG ve EEG sinyal verilerinin bilgisayar ortamına kaydedilmesi için iki farklı cihaz kullanılmıştır. Bu iki cihazdan biri 14 kanallı EMOTIV EPOC+ diğeri ise OPENBCI Ganglion biyosensing sinyal kayıt kartıdır. İlk çalışma, müzik dinlerken duygusal durumun belirlenmesi için EEG sinyallerinin kullanılması konusuna odaklanmaktadır. İlgili çalışmada, AlexNet ve VGG16 gibi önceden eğitilmiş derin öğrenme modelleri kullanılmış ve bu modellerin, insan duygusal durumlarının tanınması problemini çözmedeki potansiyelini gözler önüne sermiştir. En iyi sınıflandırma sonucu %73.28 doğrulukla VGG16 kullanılarak ve Beta frekans bandı spektrogramları üzerinde elde edilmiştir. Bu bulgular, müzik verisi ile hazırlanan EEG veri setlerinin ve mevcut veri setlerinin, insan duygusal durumlarının tanınması probleminde farklı derin ağ modelleri ile kullanılmasını teşvik etmektedir. İkinci çalışma, COVID-19 hastalığının erken tespitine yöneliktir. Gelişmiş bir görüntü iyileştirme teknolojisi olan ÇAGKAA-KSAHE ile X-ışını görüntülerinin kontrastı artırılmış ve bu geliştirilmiş veri, Konvolüsyonel sinir ağları ile sınıflandırılmıştır. Çalışma sonuçları, sunulan yöntemin COVID-19, normal ve pnömoni durumlarını sınıflandırmada yüksek doğruluk oranlarına sahip olduğunu göstermektedir. Bu tez, EEG sinyalleri üzerinden duygu tanıma ve X-ışını görüntü analizi yoluyla COVID-19 tespiti gibi çeşitli uygulama alanlarında derin öğrenme ve görüntü işleme tekniklerinin kullanımının önemli değeri ve uygulanabilirliği hakkında dikkat çekici bilgiler sunmaktadır.

ANAHTAR KELİMELER: Derin Öğrenme, Duygu Tanıma, Hastalık Tespiti, Görüntü İşleme

ABSTRACT

PhD Thesis

ESTABLISHMENT OF BIOMEDICAL DECISION SUPPORT SYSTEMS THROUGH DEEP LEARNING TECHNIQUES

Harun Çiğ

**Harran University
Graduate School of Natural and Applied Sciences
Department of Electrical Electronics Engineering**

**Supervisor : Prof Mehmet Tahir GÜLLÜOĞLU
Year: 2023 , Page: 107**

This thesis provides a comprehensive examination of the effective applications of deep learning models and advanced image processing techniques in biomedical signal and image analysis through two distinctive studies. The section dedicated to biological signals in the thesis focused on the examination of biomedical signals such as EOG, EEG, and EKG. To record the EOG and EEG signal data in a computerized environment, two distinct devices were employed. One of these devices is the 14-channel EMOTIV EPOC+, while the other is the OPENBCI Ganglion biosensing signal recording board. The first study focuses on determining the emotional state while listening to music using electroencephalography (EEG) signals. Here, pre-trained deep learning models such as AlexNet and VGG16 are deployed, revealing their potential in solving the problem of recognizing human emotional states. The highest classification result is achieved at a 73.28% accuracy using VGG16 and Beta frequency band spectrograms. These findings advocate the usage of EEG datasets prepared with music data and existing datasets with different deep network models in the problem of human emotional state recognition. The second study is geared towards the early detection of the COVID-19 disease. The contrast of X-ray images is enhanced with an advanced image enhancement technology, MOCS-CLAHE, and this enhanced data is classified with convolutional neural networks. The study results show high accuracy rates of the method in classifying COVID-19, normal, and pneumonia cases. This thesis presents compelling insights into the significant value and applicability of using deep learning models and image processing techniques in various application areas such as emotion recognition over EEG signals and COVID-19 detection through X-ray image analysis.

KEY WORDS: Deep Learning, Emotion Recognition, Disease Detection, Image Processing

TEŞEKKÜR

Tez çalışmalarım boyunca desteklerini esirgemeyen danışmanım Prof. Dr. Mehmet Tahir GÜLLÜOĞLU hocama, Prof. Dr. Davut HANBAY hocama, Dr. Öğr. Üyesi. Kerim KARADAĞ hocama ve ayrıca tüm eğitim hayatım boyunca maddi ve manevi yanımda olan sevgili aileme çok teşekkür ederim.

Bölüm başkanım Doç. Dr. İbrahim Berkan AYDİLEK, Dr. Öğr. Üyesi Mehmet Bilal ER ve Öğretim Görevlisi Umut KURAN hocalarıma ve birlikte çalıştığım tüm çalışma arkadaşlarıma her türlü destek ve motivasyonları için kalpten teşekkürlerimi sunmak istiyorum.



ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1.1. EKG verisinde tekrarlayan P, QRS, T dalgası	7
Şekil 1.2. Beş saniyelik EEG verilerinin 14 kanalda gösterimi	8
Şekil 1.3. EOG grafiği	10
Şekil 1.4. ECoG sinyal edinimi	11
Şekil 1.5. Biyomedikal görüntüleme teknikleri	12
Şekil 1.6. PETCT ile görüntüleme	14
Şekil 1.7. DDGUP tabanlı BBA	15
Şekil 2.1. Circumplex modeli	23
Şekil 3.1. OpenBCI Ganglion kart	30
Şekil 3.2. Ganglion PCB katmanları	31
Şekil 3.3. Ganglion kartı devresi	32
Şekil 3.4. EMOTIV EPOC+ EEG veri okuma cihazı	34
Şekil 3.5. Örnek göğüs röntgen verisi; (a) COVID-19, (b) Pnömoni, (c) Normal	38
Şekil 3.6. Çerçeveleme	40
Şekil 3.7. Hamming pencereleme	41
Şekil 3.8. EEG sinyalinin çerçevesi ve hamming ile sinyalin pencerelenmesi	42
Şekil 3.9. Bir EEG sinyalinin çözünürlük seviyeleri ve dalgacık katsayıları	45
Şekil 3.10. Sürekli dalgacık dönüşümü ile EEG sinyallerinin görselleştirilmesi	46
Şekil 3.11. EEG verisi ve güç spektrogramı	48
Şekil 3.12. Yapay sinir ağları	51
Şekil 3.13. Çok katmanlı ileri beslemeli ağlar	52
Şekil 3.14. DVM çekirdek fonksiyonlarının veri setleri arasında karşılaştırılması	54
Şekil 3.15. K- en yakın komşu algoritması ile sınıflandırma	55
Şekil 3.16. Rastgele orman	58
Şekil 3.17. EOG sinyal analizinde KKA kullanımı	59
Şekil 3.18. EEG sinyalleri ile duygu analizi için önerilen yöntem	61
Şekil 3.19. ÇAGKAA akış diyagramı	64
Şekil 3.20. Örnek göğüs röntgen görüntüleri	67
Şekil 3.21. X-ray görüntüleri ile hastalık tespiti için önerilen yöntemin gösterimi	68
Şekil 3.22. Maksimum havuzlama işleminin gösterimi	71
Şekil 3.23. Önceden eğitilmiş ağların gösterimi; (a) AlexNet, (b) Vgg16	72
Şekil 4.1. Eğitim prosesi	74
Şekil 4.2. X-ışını görüntüleri: (a) COVID-19, (b) Pnömoni, (c) Normal	81
Şekil 4.3. İki modelin karmaşıklık matrisi	86
Şekil 4.4. Eğitim ve doğrulama verilerinde doğruluk ve kayıp grafikleri	87

ÇİZELGELER DİZİNİ

Sayfa No

Çizelge 1.1. EEG sinyal bant frekans değerleri	9
Çizelge 3.1. Kullanılan veri seti.....	37
Çizelge 3.2. Veri artırma algoritması.....	49
Çizelge 4.1. Alfa bandı veri kümesinde AlexNet için sınıflandırma sonuçları	75
Çizelge 4.2. Beta bandı veri kümesinde AlexNet için sınıflandırma sonuçları.....	76
Çizelge 4.3. Alfa bandı veri kümesinde VGG16 için sınıflandırma sonuçları	76
Çizelge 4.4. VGG16 ve beta bandı için sınıflandırma sonuçları	77
Çizelge 4.5. Diğer yaklaşımlarla performans karşılaştırması.....	78
Çizelge 4.6. EOG veri seti KKA sonuçları	79
Çizelge 4.7. Karmaşıklık matrisi.....	82
Çizelge 4.8. Tasarlanmış KSA mimarisi.....	83
Çizelge 4.9. Görüntü iyileştirme olmadan KSA'den alınan sonuçlar.	85
Çizelge 4.10. ÇAGKAA ile KSAHE uygulandıktan sonra KSA ile elde edilen sonuçlar	85
Çizelge 4.11. Radyografi veri setini kullanan diğer çalışmalarla performans karşılaştırması ..	87

SİMGELER ve KISALTMALAR DİZİNİ

ADD	Ayrık Dalga Dönüşümü
AE	Ayrık Entropi
AHE	Adaptif Histogram Eşitleme
BBA	Beyin Bilgisayar Arayüzü
BDE	Bluetooth Düşük Enerji
BG	Bant Gücü
ÇAGKAA	Çok Amaçlı Guguk Kuşu Arama Algoritması
ÇKA	Çok Katmanlı Algılayıcı
DD	Dalgacık Dönüşümü
DDGUP	Durağan Durum Görsel Uyarılmış Potansiyeller
DVM	Destek Vektör Makinesi
EEG	Elektroensefalografi
EKG	Elektrokardiyografi
EOG	Elektrookülografi
FD	Fourier dönüşümü
GSY	Güç Spektral Yoğunluk
GVT	Gürültü Varyansı Tahmini
HFD	Hızlı Fourier Dönüşümü
HP	Hamming penceresi
KKA	Kanonik Korelasyon Analizi
KSA	Konvolüsyonel Sinir Ağı
KSAHE	Kontrast Sınırlı Adaptif Histogram Eşitleme
MR	Manyetik Rezonans
OYF	Olasılık Yoğunluk Fonksiyonunu
ReLU	Düzeltilici Doğrusal Birimler
RF	Relief Özellik Seçimi Algoritması
sDÇET	Standartlaştırılmış Düşük Çözünürlüklü Elektromanyetik Tomografi

1. GİRİŞ

Biyomedikal sinyaller, insan vücudunun çeşitli fizyolojik işlevlerinin elektriksel gösterimleri olarak kabul edilmektedirler (Akay, 1994). Elektroensefalografi (EEG), elektrokardiyografi (EKG), Elektrookülografi (EOG), Elektromiyografi (EMG) gibi biyomedikal sinyaller hastaların sağlık durumlarını ve potansiyel bozuklukları tespit etmek için önemli bilgiler sunmaktadır. Günümüzde derin öğrenme ve makine öğrenmesi tekniklerinin gelişmesi, bu sinyallerin analizinde ve yorumlanmasında önemli ilerlemeler kaydetmeye yardımcı olmuştur (Schirrmester ve ark., 2017; Shrestha ve Mahmood, 2019).

Gelişmiş biyomedikal veri okuma cihazlarının yanı sıra makine öğrenmesi tekniklerinin gelişmesiyle birlikte, insan zihinsel ve biyolojik sağlık durumlarının izlenmesi alanında büyük ilerlemeler kaydedilmiştir. Yorgunluk, duygusal durum, bilişsel yük gibi insanların zihinsel durumlarını belirlemeye yönelik araştırmalarda bu izleme teknikleri sıkça kullanılmaktadır (Arico ve ark., 2017; Gao ve ark., 2019; Mehta ve Parasuraman, 2013).

Bunun yanı sıra, EKG, EOG ve EMG gibi biyolojik sinyallerin izlenmesi, insanların sağlık durumlarının doğru takip edilebilmesi için izleme teknikleri arasında önemli bir yere sahiptir (Boda ve ark., 2021; Fatourehchi ve ark., 2007). Bu bağlamda, kalp atış hızı kas sinyalleri ve göz sinyalleri gibi biyolojik ölçüm verileri, insanların bilişsel ve sağlık durumlarının değerlendirilmesinde kritik role sahiptir. Bu biyolojik sinyallerin detaylı analizi ve değerlendirilmesi, insan yaşamını doğrudan veya dolaylı olarak etkileyebilecek durumların veya insan sağlığına yönelik potansiyel risklerin daha kapsamlı bir perspektiften anlaşılmasını ve yorumlanmasını sağlamaktadır (Cui ve ark., 2014). Bilişsel kontrolle yönlendirilen kas hareketlerinden izlenen biyomedikal sinyaller, hastalık tespitinden elektronik cihaz kontrolüne kadar birçok farklı alanda kullanılmaktadır (Kiguchi ve Hayashi, 2012). Özellikle insan-robot

etkileşimi ve pasif beyin-bilgisayar arayüzü gibi alanlarda bu tekniklerin kullanımı yaygınlaşmıştır (Zhou ve ark., 2022).

Birçok hastalığın tanısı, teşhisi veya belirtilerinin erken ve doğru tespit edilmesi, tedavi ve hayati riskleri azaltma adına oldukça önemlidir (Cho ve ark., 2021). Bu bağlamda biyomedikal sinyallerin ve görüntülerin analiz sonuçlarının incelenmesi ve iyileştirilmesi de önem arz etmektedir. Yaygın olarak kullanılan fizyolojik sinyaller kabaca EEG, EKG, EMG ve EOG gibi birkaç kategoriye ayrılabilir. Bu fizyolojik sinyalleri kullanan teknikler, vücuttaki belirli fonksiyonları veya faaliyetleri ölçmek ve kaydetmek için kullanılır. Bu biyomedikal sinyal görüntüleme teknikleri arasında EEG, elektrotlar aracılığıyla saçlı deriden elde edilen ve beyin elektriksel aktivitesini yansıtan zayıf elektrik sinyallerini ölçer ve beyin elektriksel aktivitesini biyomedikal sinyaller olarak kaydeder. EEG, genellikle denekler arasında değişkenlik gösteren ve gürültü içeren sinyallerdir. Bu nedenle, EEG'de sağlam özelliklerin belirlenmesi ve analiz edilmesi hala bir zorluktur (Zhou ve ark., 2022).

İnsan beyni, yaklaşık 85 ile 100 milyar aralığında nöron hücresinden oluşan karmaşık bir ağ yapısına sahiptir. Bu nöronlar arasındaki bağlantılar, çeşitli olaylar ve uyarılarla birlikte farklı duygusal deneyimlerin oluşmasını sağlar. Beyindeki nöral bağlantılar, belirli bir nöronun uyarılmasına bağlı olarak güçlü veya zayıf olabilir (Jokanović ve Jokanović, 2021). Duygusal deneyimlerin oluşması sürecinde farklı olaylar, belirli nöronların etkinleşmesine ve bağlantıların oluşmasına neden olur. Örneğin, bir kişi güzel bir müzik parçası dinlediğinde, belirli nöronlar uyarılır ve müziğin keyifli bir deneyim haline gelmesini sağlayan nöral bağlantılar güçlenir. Aynı şekilde, bir kişinin karşılaştığı bir tehlike durumunda, farklı nöronlar aktive olur ve savunma mekanizmalarının devreye girmesini sağlayan bağlantılar güçlenir. Bu nöral bağlantılar, belirli bir duygusal deneyimin tekrarlanması veya benzer bir durumla karşılaşılması durumunda güçlenebilir veya değişebilir. Öğrenme ve deneyimler, nöral ağın yapılarını şekillendirebilir ve duygusal tepkilerin oluşmasında etkili olan bağlantıların güçlenmesini sağlayabilir (Zeng, 2018).

Son yıllarda yapılan araştırmalar, çeşitli uyarıcıların, özellikle müzik gibi kulak yoluyla dinlenen veya görsel nesneler gibi gözle algılanan faktörlerin, EEG sinyalleri üzerinde uyarıcı etkilere sahip olduğunu ortaya koymuştur (Camilleri ve ark., 2022; Cig ve Tuysuz, 2018). Bu faktörler, bir insan beyin aktivitesinde belirgin değişikliklere yol açabilir ve buna bağlı olarak duygusal ve zihinsel durumlarını etkileyebilir. Örneğin, müzik dinlemek, beyin aktivitesindeki ritim ve frekans değişikliklerini tetikleyebilir ve dinleyicide duygusal tepkiler uyandırabilir (Er ve ark., 2021). Aynı şekilde, gözle algılanan görsel uyaranlar da beyin aktivitesini etkileyebilir ve duygu durumunu değiştirebilir.

Bu bağlamda EEG sinyallerinin analizi, çevresel faktörlerden etkilenen beyin aktivitesini anlamak için önemli bir araçtır. EEG verileri, duygusal ve zihinsel durumlarla ilişkili anlamlı bilgileri ortaya çıkarmak için analiz edilebilir. Örneğin, müzik dinleme deneyleri, belirli müzik türlerinin beyin aktivitesindeki değişiklikleri ve duygusal tepkileri tetikleyebileceğini göstermiştir (Er ve ark., 2021). Aynı şekilde, görsel uyaranların beyin aktivitesindeki etkileri de incelenebilir ve duygusal tepkilerle ilişkilendirilebilir. Bu tür analizler, insanların duygusal ve zihinsel durumlarını daha iyi anlamak, beyin aktivitesini çevresel faktörlerle ilişkilendirmek ve buna bağlı olarak sağlık, güvenlik, eğitim gibi farklı alanlarda uygulamalar geliştirmek için değerli bir araç sunmaktadır. Özellikle insan-robot etkileşimi, pasif beyin-bilgisayar arayüzü, insan-bilgisayar etkileşimi gibi alanlarda EEG analizi, kullanıcıların duygusal durumlarını ve bilişsel yüklerini izlemek ve anlamak için yaygın olarak kullanılmaktadır (Camilleri ve ark., 2022).

Biyomedikal sinyal görüntüleme tekniklerinden bir diğeri olan EKG, kalbin elektriksel aktivitesinin incelenmesi için öncelikle tercih edilen bir araçtır ve çeşitli kardiyak aritmilerin tanısında hayati öneme sahiptir (Seidel ve ark., 2021). EKG'nin operasyonel süreci, vücut yüzeyinde -özellikle göğüs, boyun, kollar gibi bölgelerde- elektrotların yerleştirilmesi ile kalp tarafından üretilen elektriksel sinyallerin kaydedilmesini içerir (Sahoo ve ark., 2020). Elektrokardiyogram kayıtları, P dalgası, QRS kompleksi, T dalgası gibi çeşitli dalga formlarını barındırır. EKG, belirlenmiş bir süre boyunca kalbin elektriksel aktivitesini sürekli olarak belgeler, böylece kalp kası

elektiriksel işleyişinin ayrıntılı bir analizini sağlar (Belkadi ve Daamouche, 2021). EKG sinyalleri kalp hastalıklarının klinik teşhisinde hayati bir öneme sahiptir. Belirli bir zaman içerisinde kaydedilen EKG sinyalleri, çok sayıda aritmiyi ve kalp hastalıklarını keşfetmek için kullanılabilir.

Kalp, beyin hastalıkları ve sinirsel hastalıklar gibi birçok hastalığın tedavisinde, teşhis sürecinin uzunluğu ve aksaması nedeniyle gecikmeler yaşanabilir. Biyomedikal görüntüler ve biyolojik sinyaller kullanılarak, bir insanın genel sağlık durumu hakkında hızlı ve değerli bilgiler elde edilebilir. Ayrıca, bu veriler hastalığın şiddeti ve evresi hakkında önemli teşhis bilgileri sağlar. EEG, EKG, EOG gibi hastadan elde edilen biyomedikal sinyaller ve biyomedikal görüntüler kullanılarak beyin, kalp, göz, kas, akciğer, sinir sistemi hastalıkları gibi bir dizi rahatsızlığın erken belirtileri tahmin edilebilir ve bu durumlar teşhis edilebilir. Bu yaklaşım, hastalıkların daha erken ve daha doğru bir şekilde belirlenmesini sağlayarak, tedavinin gecikmesini önlemek adına hayati bir öneme sahiptir (Ertuğrul ve ark., 2021; Luongo ve ark., 2021).

Biyomedikal görüntüleme teknikleri, özellikle X-ışını, ultrason ve manyetik rezonans (MR) görüntüleme teknikleri, hastalıkların teşhisi ve tanısı için yüksek derecede önem taşır (S. Wang ve ark., 2020). Bu veriler, görüntü işleme metodolojileri, yapay zeka ve derin öğrenme tekniklerinin kullanımıyla analiz edilerek hastalıkların doğru ve etkin bir şekilde teşhis ve tespit edilmesi sağlanır (Wu ve ark., 2021). Bu teknolojik araçlar, özellikle karmaşık ve süreklilik gerektiren hastalık durumlarında, hızlı ve doğru teşhis koyma potansiyeliyle sağlık sektörünün önemli bir parçası haline gelmiştir. Son zamanlarda bir hastanın belirli bir virüs ile enfekte olup olmadığını belirlemek için kan ve fiziksel tahlillerin yanı sıra, radyografi görüntüleri üzerinde yapay zekâ ve makine öğrenme yöntemleri de kullanılmaya başlanmıştır (Hertel ve Benlamri, 2021).

Bu tez çalışmasında, hem “deneklerden fizyolojik olarak elde edilen biyomedikal sinyaller” hem de “hastalara ait biyomedikal görüntüler” derin öğrenme ve makine öğrenmesi teknikleri ile analiz edilmiştir. Akciğer göğüs röntgen görüntüleri üzerinde, enfekte olmuş durumların sınıflandırılmasında biyomedikal

görüntüler kullanılmıştır. Sınıflandırma işlemi için Konvolüsyonel Sinir Ağları (KSA), Kontrast Sınırlı Adaptif Histogram Eşitleme Algoritması (KSAHE) ve Çok Amaçlı Guguk Kuşu Arama Algoritması (ÇAGKAA)'nın bir arada kullanımı önerilmiştir.

Çalışmanın bir diğer bölümünde biyomedikal sinyallerin analizi için, farklı müzikler dinletilen bir grup denekten EEG verileri toplanmıştır. Bu deneklerin duygu durumlarını doğru bir şekilde belirlemek amacıyla bir EEG tabanlı duygu tanıma modeli geliştirilmiş ve derin öğrenme tabanlı yeni bir duygu tanıma metodu önerilmiştir. Farklı türden müzik parçaları deneklere dinletilmiş ve beyinde oluşan elektriksel dalgalar mutlu, üzgün, rahat ve gergin duygusal durumlarını tanımlamak için kullanılmıştır. EEG sinyalleri çeşitli kanallardan toplanmış ve elde edilen sinyallerin spektrogramları çıkarılmıştır. Spektrogramlar, önceden eğitilmiş AlexNet ve VGG16 derin ağ modellerine giriş olarak verilmiş ve transfer öğrenme süreci uygulanmıştır.

1.1. Biyomedikal Sinyaller

Biyomedikal sinyaller, insan vücudunun çeşitli fizyolojik işlevlerinin elektriksel ifadeleri olup, farklı uygulama ve araştırma alanları için önemli bilgiler sunarlar. Bu bölümde, fizyolojik bağlamda kişiden elde edilen biyomedikal sinyaller ile bu sinyallerin farklı kullanım alanlarına odaklanılacaktır.

1.1.1. Elektrokardiyografi


Elektrokardiyogram, belirlenmiş bir süre boyunca kalp kaslarının elektriksel aktivitelerini kaydeden ve ölçümleyen standart bir muayenedir (Seidel ve ark., 2021). Bir EKG, kalp hücre aktivitelerinin oluşturduğu karmaşık potansiyel değişikliklerin vektörel toplamının kaydedilmesiyle elde edilir (M. Zhu ve ark., 2021). Elektrofizyolojik sinyaller; insan sinir sistemlerinin doku ve organların aktivitelerini ve işlevlerini kontrol etmesi için önemlidir. İnsan vücudunun fizyolojik aktivitesi, uyarılabilir hücrelerde sürekli olarak elektrik potansiyeli değişiklikleri üretir. Vücuttaki uyarılabilir hücreler sürekli olarak elektrik sinyallerini iletir ve insan vücudunun tüm iç alanında sürekli değişen bir elektrik alanı oluşturur (Plonsey ve

Barr, n.d.; Xu ve ark., 2020). Bu nedenle, insan vücudunun çeşitli doku ve organlarından elektrofizyolojik sinyaller elde edilebilir (Goldberger ve ark., 2008; Yetisen ve ark., 2018).

Elektrotlar, her kardiyomiyositin elektrik vektörünün sentezlenmiş vektörlerini toplayarak kalpten veya deriden EKG dalga formunu elde edebilirler (M. Zhu ve ark., 2021). EKG'nin genliği genellikle 10 μ V ile 4 μ V aralığında değişkenlik gösterir. Amerikan Kalp Derneği ve Amerikan Kardiyoloji Koleji tarafından belirlenen standart EKG frekans alım aralığı 0,05 Hz -150 Hz'dir ve sinyalin esas enerjisi 0,05 Hz ile 40 Hz arasında yoğunlaştırılmıştır (Goldberger ve ark., 2008). Buna ek olarak, kardiyomiyositlerin hücre dışı aksiyon potansiyellerinden (AP) kaynaklanan sinyal özellikleri, entegre sonucun EKG olarak yansmasıyla birlikte, kardiyoloji açısından da önemlidir (Bailey ve ark., 1990; Kligfield ve ark., 2007). Bu türdeki bir sinyal, mikroelektrotların hücreye takılmasıyla toplanır ve bu, kalbin temel fizyolojik işlevini yansıtabilir.

Bir EKG sinyali veya bir kardiyak döngü, Şekil 1.1.'de gösterildiği gibi; P dalgası, QRS kompleksi ve T dalgası olarak adlandırılan bir dizi tekrarlayan dalgadan oluşur.

Şekil 1.1.'de PhysioNet MIT-BIH Arrhythmia veri setinde bulunan 200. Deneğe ait EKG verisinde kalp atışları tespit edilmiş ve ilk 3 kalp atım grafiği çizdirilmiştir.




Şekil 1.1. EKG verisinde tekrarlayan P, QRS, T dalgası

EKG sinyal işlemenin kritik unsurlarından biri, QRS kompleksinin incelenmesidir. Bu kompleks içinde, R dalgası en belirgin özellikte olup bu onun tespitini daha kolay kılar. R dalgasının pik noktasının belirlenmesi, düzensiz kalp ritimlerinin teşhisinden kalp hızı değişkenliğinin saptanmasına kadar bir dizi EKG uygulamasında önemli bir rol üstlenir (Kathirvel ve ark., 2011; Rabbani ve ark., 2011).

1.1.2. Elektroansefalografi

EEG, beyindeki sistematik nöral aktivitelerin neden olduğu, zamanla değişen potansiyellerin ölçümüdür (Geng ve ark., 2011). Nörobilimde, beyin mekanizmalarının daha iyi anlaşılmasını sağlamak ve çeşitli nörolojik patolojiler için biyobelirteçler belirlemek amacıyla EEG ve nörogörüntüleme teknikleri yaygın olarak kullanılmaktadır (Tulay ve ark., 2018). EEG sinyalleri, beyin aktivitelerinin durumunu güvenilir bir şekilde belirlemek için kullanılabilir (Porcaro ve ark., 2023). EEG Özellikle beynin yüzeyinde sinyal yoğunluğunun belirgin olarak gözlemlendiği epilepsi gibi beyin fonksiyon bozukluklarının değerlendirilmesinde önemli bir araçtır. Beyinde meydana gelen elektriksel aktivitelerin ölçümü ile elde edilen EEG sinyalleri kullanılarak hastalık tespitinin yanı sıra duygusal durum tespiti de yapılmaktadır.

Şekil 1.2.'de bir kişinin 14 kanaldan kaydedilen beyin sinyalleri ve göz kırpmalarının beyin sinyali üzerinde oluşturduğu bozulmalar gösterilmiştir.



Şekil 1.2. Beş saniyelik EEG verilerinin 14 kanalda gösterimi

İnsan duygularının anlaşılması, insan-bilgisayar etkileşimine önemli bir katkı sağlamaktadır (Fragopanagos ve Taylor, 2005). Son on yıllık süreçte ses, görsel davranış ve fizyolojik sinyallerden duyguları tanıma üzerine önemli çalışmalar yapılmıştır (H. Hou ve ark., 2020; H.-R. Hou ve ark., 2018; Meng ve ark., 2015). Duygusal yanıtlar genellikle öznel ve çoğu zaman kullanıcının sözlü ve sözsüz

davranışlarından ve fizyolojik sinyaller kullanılarak belirlenir. Ancak uyarının duygusal deneyimde önemli bir rol oynadığı düşünülmektedir (Ledoux, 1989). Duygu tanıma süreçlerinde, EEG sinyalleri üzerinden elde edilen duygusal yanıtların belirlenmesi, hem eğitim hem de test aşamalarında kullanılabilecek potansiyel bir yöntem sunmaktadır (S. Wang ve ark., 2015). Bu, gözlenebilir veri olarak kabul edilebilir ve duygu tanıma sistemlerinin geliştirilmesi ve mükemmelleştirilmesi için büyük bir önem taşır.

Çizelge 1.1. EEG sinyal bant frekans değerleri (Bonanni ve ark., 2008)


Bant İsmi	Frekans Aralığı (Hz)
Delta (δ)	0.5-3.5
Teta (θ)	4-7
Alfa-I(α -I)	8-9
Alfa-II(α -II)	10-12
Beta-I(β -I)	13-17
Beta-II(β -II)	18-30
Gamma-I (γ -I)	31-40
Gamma-II (γ -II)	41-50

EEG sinyalleri farklı frekans bantlarında farklı bilgiler barındırmaktadır. Bu sinyallerin belirli frekans bantlarının ekstraksiyonu için çok sayıda teknik önerilmiştir. Ortak uzamsal desenler üzerine yapılan çalışmalarda (Das ve ark., 2016; Meng ve ark., 2015), frekans bantlarının içerdiği ortak bilgi kullanılarak belirli frekans bantlarının tanımlanmasına yönelik stratejiler geliştirilmiştir. Bu süreçte, frekans bandı enerjisinin değerlendirilmesi için Fisher Oranı yöntemi kullanılmıştır (Ang ve ark., 2008).

Geleneksel Güç Spektral Yoğunluğu (GSY) temelli EEG sinyal sınıflandırma yaklaşımında, EEG frekans spektrumu, biyolojik ritimlere dayalı olarak beş alt banda ayrılır. Çizelge 1.1.'de EEG sinyallerinin farklı frekans bantlarındaki değerleri verilmiştir.

1.1.3. Elektrookülografi

Göz hareketlerinin analizi için kullanılan ilk yöntemlerden biri olarak kabul edilen Elektrookülografi, insan gözünün kornea ve retinası arasındaki elektriksel potansiyelin ölçümünü gerçekleştiren bir tekniktir (Ameri ve ark., 2018; Belkhiria ve ark., 2022). EOG, çeşitli insan-bilgisayar etkileşimi araştırma alanlarında önemli bir araç olarak kullanılmaktadır. Bir kişinin göz kırpması esnasında kaydedilen göz sinyallerinin grafik üzerinde gösterimi Şekil 1.3'te verilmiştir.




Şekil 1.3. EOG grafiği

1.1.4. Elektrokortikografi (ECoG)

Elektrokortikografi (ECoG), elektrotların beyin yüzeyine cerrahi olarak yerleştirilmesiyle beyin korteksinin elektriksel aktivitesinin ölçümünü ve kaydedilmesini sağlayan bir tekniktir (Boran ve ark., 2019). Bu teknik, yüksek temporal ve spatial çözünürlük sunar ve geniş bir frekans aralığını kapsar. EEG'ye kıyasla daha detaylı beyin aktivitesi bilgisi sağlar. ECoG tekniğinde elektrotların doğrudan beyin korteksine yerleştirilmesi gerektiğinden, genellikle EEG gibi non-invaziv yöntemlerin yeterli bilgi sağlayamadığı durumlarda ECoG kullanılır. Bununla birlikte, invaziv doğası ve uygulanması gereken karmaşık tıbbi prosedürleri nedeniyle, kullanımı genellikle ciddi nörolojik durumların tedavisinde veya spesifik araştırma uygulamaları

ile sınırlıdır (Hill ve ark., 2006; T. Yang ve ark., 2014). ECoG sinyallerinin edinimi ve bilgisayar ortamında gösterimi Şekil 1.4'te verilmiştir.




Şekil 1.4. ECoG sinyal edinimi

1.2. Biyomedikal Görüntüler

Biyomedikal görüntüler, tıbbi ve biyolojik araştırmalarda kullanılan çeşitli görüntüleme teknikleriyle elde edilen görüntülerdir. Bu görüntüler, genellikle vücuttaki organları, dokuları veya biyolojik süreçleri görsel olarak gözlemlemek, teşhis koymak, tedavi planlamak ve araştırmalar yapmak için kullanılmaktadır (Maddumapatabendi ve ark., 2008). Bazı yaygın biyomedikal görüntüleme teknikleri ve bu tekniklerle elde edilen görüntülerin örnekleri (bakınız Şekil 1.5.) aşağıda verilmiştir.

Radyografi (X-ışını) Görüntüleme: X-ışını görüntüleme tekniği, vücut içerisine bakabilmenin en eski ve en yaygın yollarından biridir (Hertel ve Benlamri, 2021). Şekil 1.5.'te görüldüğü gibi X-ışınları, vücutta farklı dokuların farklı yoğunluklarda olduğu gerçeğine dayanarak çalışır. Yumuşak dokular X-ışınlarını çoğunlukla geçirirken, daha yoğun dokular (örneğin kemikler) bu ışınları emer veya bloke eder. Bu farklı yoğunluklar nedeniyle, X-ışınları farklı dokulardan geçerken bir film veya dijital sensör üzerinde farklı gri tonlar oluşturur (Udupa, 1994). Yani, vücuttan geçen X-ışınları bir görüntü oluşturur ve bu da radyologların anatomiye ve

olası anormallikleri incelemesini sağlar. X-ışını görüntüleme teknikleri genellikle kemik kırıkları, akciğer enfeksiyonları, diş problemlerinin görüntülenmesi gibi durumlarda kullanılır (Nasiri ve Hasani, 2022).



Şekil 1.5. Biyomedikal görüntüleme teknikleri (Tehrani, 2020)

Bilgisayarlı Tomografi (BT): Beyin, göğüs, karın gibi iç organların kesitsel görüntülerini elde etmek için kullanılır. BT anatomiye yüksek uzamsal çözünürlükle tasvir etmek için iyi bir kapasiteye sahiptir (Santos ve Ledesma-Carbayo, 2006). Geleneksel radyografi, üç boyutlu anatomiye iki boyutlu bir forma indirirken detayları gizleyebilir, yalnızca yüksek kontrastlı farklılıkları belirleyebilir ve ayrıca yüksek radyasyon dozu gerektirir. Bu kısıtlamaları aşmak amacıyla BT, yapıların üst


üste binmesini engelleyerek hastanın vücudunun kesitsel görüntülerini oluşturmak için tasarlanmış bir teknolojidir. Çeşitli organlar ve dokular arasında önemli bir kontrast sağlar, böylece radyologların hastalıkların veya anormalliklerin doğasını, konumunu ve genişliğini canlı organizmada anlayabilmesi için hızlı ve ağrısız bir şekilde belirlemesine olanak tanır (D. Lu ve ark., 2006).

Manyetik Rezonans Görüntüleme: Beyin, omurilik, eklem ve iç organların - yumuşak dokuların- detaylı görüntülerini elde etmek için manyetik alan ve radyo dalgalarını kullanır. MR görüntüleri ameliyatı yapılacak yapıların ameliyat öncesi 3 boyutlu görüntülenmesi için değerli bilgiler sunar (Sun ve ark., 2016). Bu komplikasyon riskini en aza indirir ve operasyon maliyetini azaltır (Marsh, 2001).

Ultrasonografi: Gebelik takibi, karın organlarının incelenmesi, kalp ve damar hastalıklarının teşhisi gibi iç anatomik yapıların dinamik görüntülerini elde etmek için birçok alanda kullanılan ultrasonografi, yüksek frekanslı (ultrasonik) ses dalgalarıyla çalışan bir görüntüleme tekniğidir. Fiziksel prensibi denizaltı sonarına çok benzer. Ultrasonik dalgaların frekansı insan işitme kapasitesinin üzerindedir (yani 20 KHz'in üzerinde). Teşhis amacıyla normalde 1MHz ve 10MHz arasındaki frekanslar kullanılır. Yüksek frekanslı ses dalgalarını üretmek için piezoelektrik kristale dayalı bir elektronik osilatör kullanılır (Evans, 2000; Ferrero ve ark., 2006).

Pozitron Emisyon Tomografisi (PET): Pozitron Emisyon Tomografisi (PET), radyoaktif madde enjeksiyonu yardımıyla metabolik aktiviteyi görüntüleyen ve kanser taraması, beyin aktivitesinin haritalandırılması, kalp-damar hastalıklarının değerlendirilmesi gibi çeşitli alanlarda kullanılan bir tanısal görüntüleme tekniğidir. PET' in insan vücut hücrelerinin metabolik aktivitesini ölçme kabiliyeti, nükleer tıbbın tekniklerini bilgisayarlı görüntü rekonstrüksiyonu ile birleştirebilme özelliği, PET'i, vücuttaki temel biyokimyasal ve biyolojik aktivitenin invaziv olmayan görüntülerini oluşturma kapasitesine sahip kılar. Bu durum PET'in, hastalığın tanı ve tedavisinin yanı sıra hasta yönetiminde de önemli bir rol oynamasını sağlar. PET görüntüleme teknolojisi, diğer geleneksel görüntüleme yöntemleriyle tespit edilemeyecek patolojik değişiklikleri erken aşamada gösterme, tümörleri belirleme ve evreleme yeteneğine

sahiptir (Kontaxakis, 2006). PETCT ile vücudun belirli bölgelerinin görüntülenmesi Şekil 1.6’da verilmiştir.




Şekil 1.6. PETCT ile görüntüleme

1.3. DDGUP tabanlı Beyin Bilgisayar Arayüzü Sistemleri

Beyin-Bilgisayar Arayüzü (BBA) teknolojisi, beyinden gelen aktivite sinyallerini makine kodlarına dönüştürerek beynin çevreyle doğrudan bir iletişim kurmasını sağlar (Wolpaw ve ark., 2002). Bu teknoloji, günlük hayatta çeşitli uygulamalarda kullanılmaktadır. EEG tabanlı BBA, hem engellilere hem de sağlıklı bireylere cihaz kontrolü ve robot kontrolü gibi yeni iletişim seçenekleri sunar. Bu

çeşitlilik, BBA teknolojisinin olağanüstü esnekliğini ve potansiyelini göstermektedir. Özellikle Durağan Durum Görsel Uyarılmış Potansiyel (DDGUP)'in entegre edildiği EEG tabanlı BBA sistemleri, geniş çaplı uygulamalarda kullanılmaktadır. Bu uygulamalar, bilgisayar imleci kontrolü ve ekran menü seçimleri gibi basit görevlerden, sanal klavyeler ve tekerlekli sandalye gibi karmaşık donanım kontrollerine kadar uzanmaktadır (Astaras ve ark., 2013; Brunner ve ark., 2015; Lin ve ark., 2014; Y. Wang ve ark., 2011).



Şekil 1.7. DDGUP tabanlı BBA

DDGUP tabanlı- BBA sistemleri, görsel uyarıların yarattığı beyin yanıtlarını kullanarak deneğin niyetini sadece EEG sinyalleri kullanarak belirleme kabiliyetine sahiptir (Müllerputz ve ark., 2005). DDGUP tabanlı BBA sistemleri, yüksek bilgi transfer hızları ve düşük yanlış pozitif oranları ile dikkat çekmektedir (Shao ve ark., 2020). DDGUP yanıtları, genellikle LED dizilimi, bilgisayar ekranı veya sanal gerçeklik başlığı gibi görsel uyarılarla uyarılan bir bireyin EEG'sinde tespit edilir (Camilleri ve ark., 2022). Bu tip bir BBA sistemi, özellikle felçli hastaların daha bağımsız yaşamalarını destekleme gibi önemli uygulamalara olanak tanıyabilir (Cig ve Tuysuz, 2018). DDGUP tabanlı BBA uygulama örneği Şekil 1.7.'de görsel olarak verilmiştir.

2. ÖNCEKİ ÇALIŞMALAR

Gelişmiş teknolojik uygulamalar ve yaşam kalitesinin artırılması yönündeki çabalar, biyomedikal sinyal analizi ve derin öğrenme tekniklerinin hızla gelişmesine yol açmıştır. Bu bölüm, duygu tanıma, hastalık tespiti ve DDGUP tabanlı BBA sistemlerine odaklanarak, bu alanda yapılan önceki çalışmaları ve literatürü kapsamlı bir şekilde ele almaktadır. Bu çerçevede, biyomedikal sinyallerin ve görüntülerin analizinde kullanılan tekniklerin detaylı bir incelemesi sunularak, mevcut bilgi birikiminin derinleşmesine ve bu alanın gelecekteki gelişmelerini şekillendirecek temel konulara ışık tutması beklenmektedir. Bu bölümün amacı, mevcut literatürdeki bulguları ve uygulamaları analiz ederek, yapılan çalışmanın özgün katkılarını daha belirgin bir şekilde ortaya koymaktır.

Beyin, insan organizmasının merkezi düzenleyici birimidir. Beyin çeşitli bilişsel süreçlerin yanı sıra duygusal yanıtların düzenlenmesinde de kritik roller üstlenir. Bu merkezi organ, duygusal durumların yorumlanması ve duygusal tepkilerin tetiklenmesi konusunda belirli beyin bölgelerinin etkinliğiyle öne çıkar. Elde edilen çok sayıda sinyalin sürekli olarak işlenmesiyle beyin, vücut ve dış çevreden gelen sinyalleri birleştirerek yaşamsal faaliyetlerin doğru bir şekilde yürütülmesini sağlar (Abhang ve ark., 2016b)

Duygular, insanların günlük yaşamlarında temel bir rol oynarlar çünkü insanların rasyonel karar verme süreçlerinde, algılamalarında, insanlar arası etkileşimlerinde ve zekalarında önemli bir yerleri vardır (Alarcao ve Fonseca, 2019). Duygular genellikle olumlu veya olumsuz şekillerde ifade edilir. Olumlu duygular arasında mutluluk, heyecan ve neşe yer alırken olumsuz duygular arasında ise üzüntü, öfke ve korku bulunmaktadır (Abhang ve ark., 2016a) . Robert Plutchik'e göre, herhangi bir duygu altı temel duygudan birine dayanır. Mutluluk, üzüntü, öfke, iğrenme, korku ve şaşkınlık çoğu araştırmacı tarafından ana veya temel duygular olarak kabul edilir ve arketip duygular olarak bilinir (Plutchik ve ark., 1989)

Katılımcıların gözlem esnasındaki temel reaksiyonlarının daha derinlemesine kavranmasına yardımcı olacak olan fizyolojik sinyaller, hem merkezi hem de otonom sinir sistemlerinden elde edilen çoklu kanal kayıtlarını temsil etmektedir (Alarcao ve Fonseca, 2019).

Beynin yarım küreleri arasındaki alfa gücünde gözlemlenen değişiklikler ve asimetri, duygularla ilgilidir. Beynin sağ frontal aktivasyonu, geri çekilme uyarıları ile korku ya da tiksinti gibi olumsuz duygularla ilişkili olduğu; beynin sol ön aktivasyonu ise bir yaklaşma uyarısıyla veya neşe, mutluluk gibi olumlu duygularla ilişkili olduğu gözlemlenmiştir (Balconi ve Mazza, 2009; Chanel ve ark., 2009; Jatupaiboon ve ark., 2013; Liu ve ark., 2011). Böylece, asimetrik frontal EEG aktivitesi valanstaki değişiklikleri yansıtabilir.

Beta bantları ayrıca değerlik ile de ilişkilidir (Jatupaiboon ve ark., 2013). Değerlik tanıma ve uyarılma tanıma konularında yapılan çalışmalar, farklı beyin bölgelerindeki asimetrik aktivitelerin incelenmesini içermektedir. Değerlik tanıma durumunda, prefrontal ve parietal bölgelerdeki alfa bandında asimetri ile temporal bölgedeki gama bandında asimetri gözlemlenmiştir. Diğer yandan, uyarılma tanıma durumunda ise, prefrontal bölgede alfa bandında asimetri ve temporal bölgede gama bandında asimetri gözlemlenmiştir (Huang ve ark., 2012).

Gama bandındaki değişiklikler, mutluluk ve üzüntü duygularıyla ilişkilidir ve temporal lobunun farklı taraflarında alfa dalga aktivitesinde azalma gözlemlenmiştir (sol için üzüntü, sağ için mutluluk) (M. Li ve Lu, 2009). Son olarak ERP bileşenlerinin kısa (N100 ve P100) ile orta (N200 ve P200) gecikmelerinin değerlendirmeye ilişkili olduğu, orta ile uzun (P300 ve SCP) gecikmelerin ise uyarılmayla ilişkili olduğu gözlemlenmiştir (M. Kim ve ark., 2013).

Zhu ve arkadaşlarının yaptığı çalışmada; duygular uyarıldığında, kadınlar arasında daha benzer EEG desenlerinin olduğu, erkeklerde ise EEG desenleri arasında daha fazla bireysel farklılığın olduğu gözlemlenmiştir (J. Zhu ve ark., 2015).

Bir uyarana maruz bırakılan bir kişinin uyarılma anında kaydedilen elektriksel potansiyel sinyaline uyarılmış potansiyel denir. İşitsel Uyarılmış Potansiyeller (AEP), Görsel Uyarılmış Potansiyeller (VEP) ve Somatosensor Uyarılmış Potansiyeller (SsEP) olmak üzere üç farklı uyarılmış potansiyel bulunmaktadır. Bu türler, kullanılan uyartım metoduna göre farklılık gösterir (Walsh ve ark., 2005). AEP, bir kulaklık aracılığıyla sunulan tıklama veya ton uyarını ile uyartılır. VEP bir ışığın belirli frekans aralığında yanıp sönmesi ile veya bir monitörde belli frekanslarda salınım yapan bir şekil tarafından uyartılır (Kemp, 2002). Durağan Durum Görsel Uyarılmış Potansiyeller, görsel sistemin hızlı ve tekrarlayan bir şekilde belirli frekans aralığında yanıp sönen bir ışığa veya dönen bir model gibi tekrarlayan bir görsel uyarana verdiği yanıtı ifade eder (Vialatte ve ark., 2010). SsEP, yani Somatosensory Evoked Potentials, periferik bir sinirin elektriksel uyarılması sonucu beyinde oluşan yanıtların kaydedilmesi ve analiz edilmesi için kullanılan bir nörofizyolojik testtir (Vialatte ve ark., 2010).

Shahabi ve arkadaşları tarafından yapılan çalışmada Çok Değişkenli Otoregresyon Modeli (MVAR) ve DTF analizi kullanılarak, katılımcıların dikkatlice dinlediği farklı müzik parçalarına karşı beyinlerinde meydana gelen elektriksel aktiviteler gözlemlenmiş ve kortikal bölgelerin bağlantı analizi aracılığıyla müziğe karşı beyinde oluşan duygusal yanıt incelenmiştir (Shahabi ve Moghimi, 2016). MVAR modeli, beyindeki farklı bölgelerden gelen sinyallerin birbirleriyle nasıl etkileşime girdiğini anlamak için kullanılmıştır. Katılımcılar neşeli müzik parçalarına maruz kaldıklarında, frontal ve frontal-parietal bölgeler arasındaki bağlantıların arttığı gözlemlenmiştir. Algılanan değerlik açısından davranışsal sonuçların frontal hemisferler arası bağlantı ile pozitif bir ilişki ve frontal-dış bağlantı ile negatif bir ilişki gösterdiği gözlemlenmiştir. Bağlantı matrislerinden hesaplanan özellikler kullanılarak neşeli ve nötr, neşeli ve melankolik, tanıdık ve tanıdık olmayan müzik parçaları dinletilen deneklerin EEG verileri sırasıyla $93,7 \pm 1,06$, $80,43 \pm 1,74$ ve $83,04 \pm 1,47$ doğruluk oranları ile sınıflandırılmıştır. Sınıflandırma için Destek Vektör Makinesi (DVM) kullanılmış ve 8 katlı çapraz doğrulama ile doğruluk oranları saptanmıştır. Araştırmacılar, bir müziği algılamak ve bu müziğe duygusal bir yanıt vermenin beyinde birçok farklı bölgenin birlikte çalışmasını gerektirdiğini

belirtmişlerdir (Shahabi ve Moghimi, 2016). Bu bulgular ışığında, müzik dinlerken beyinde hangi bölgelerin aktif olduğunu ve bu aktivitenin kişinin duygusal yanıtıyla nasıl ilişkili olduğunu otomatik olarak tespit eden invazif olmayan bir değerlendirme aracı öne sürmüştür (Shahabi ve Moghimi, 2016).

Banerjee ve ekibi tarafından yapılan bir çalışmada, Hint Klasik Müziği'nin Ragashroyi adlı bir alt türü üzerinde durulmuştur (Banerjee ve ark., 2021). Bu çalışmada, iki farklı sanatçıdan (bir kadın ve bir erkek), neşe ve hüznün gibi zıt duyguları ifade eden Ragashroyi parçalarını hem sözlerle hem de sözsüz olarak (humming -bir melodi veya ritmi belirtmek için kullanılan, ağız kapalıyken yapılan sözsüz bir seslendirme-) seslendirmeleri istenmiştir. Ses kayıtlarının akustik analizinde, dalga biçimlerinin karmaşıklığını ve öz-benzerliğini ölçmek için Detrended Dalgalanma Analizi (DDA) adı verilen bir teknik kullanılmıştır. Bu ölçümler, müziğin sözlerinin ve melodisinin sesin zaman içindeki yapısal özelliklerine olan etkisini belirlemek için yapılmıştır. Son olarak, çalışma hem Bengali dili bilen hem de bilmeyen dinleyicilerin, sözleri anlayıp anlamamalarının müzikten aldıkları duygusal etkiyi nasıl değiştirdiğini değerlendirmiştir. Müzikal uyarıcılar durdurulduktan ve denekler dinlenme durumunda olduktan bir süre sonra alfa karmaşıklığının devam ettiği gözlemlenmiştir (Banerjee ve ark., 2021). Bu çalışma, müzikal ifadenin hem akustik hem de psikolojik boyutlarını birleştiren bir yaklaşım sunmaktadır.

Banerjee ve arkadaşlarının yaptığı başka bir çalışmada, Hindistan müziğinin normal rahatlama koşulları sırasında beyin aktivitesi üzerindeki etkisini EEG kullanarak analiz etmeyi amaçlamaktadır (Banerjee ve ark., 2016). Çalışmalarında, özel bir müzik eğitimi olmayan on erkek katılımcının Hindustani müzik dinlerken frontal loblarındaki EEG sinyalleri kaydedilmiştir. İki zıt duyguyu ifade eden romantik ve hüzünlü müzik parçaları kullanılmış ve analizler alpha, theta ve gamma beyin ritimlerinin frekansları üzerinde yoğunlaşmıştır. Araştırmada, romantik ve hüzünlü duyguları içeren Hindustani müziği dinlerken tüm katılımcılarda alfa frekans bandında uyarılmış aktivitelerin arttığı gözlemlenmiştir. Müzik uyarıcısı kaldırıldığında, alfa beyin ritimlerinden belirgin bir uyarılma etkinliğinin bir süre devam ettiği, yani eski durumun bir belleği olan Histeresis döngüsünü gösterdiği görülmüştür. Bu, DDA

ölçeklendirme analiz tekniği kullanılarak doğrulanmıştır. Çalışma, Hindustani müziğindeki zıt duyguları içeren müzik parçalarını dinlerken beyin aktivitesindeki değişimlere dair yeni veriler sunmaktadır (Banerjee ve ark., 2016). Bu sonuçlar, müziğin hafıza üzerindeki etkisinin daha iyi anlaşılmasına yönelik gelecekteki araştırmalar için değerli bir temel oluşturmaktadır.

Goshvarpour ve arkadaşları tarafından gerçekleştirilen çalışmada, farklı duygusal müzik videolarının izlenmesi sırasında erkekler ve kadınlar arasında alınan EEG kayıtları üzerinde duygusal yanıtların incelenmesi amaçlanmıştır (Goshvarpour ve Goshvarpour, 2019). Bu kapsamlı araştırma, 15 erkek ve 15 kadın katılımcı olmak üzere toplamda 30 katılımcı hüznü, depresif ve neşeli müzik videolarına maruz bırakılarak kaydedilen çok kanallı EEG sinyallerinin detaylı bir analizini içermektedir. Analiz sürecinde, yedi farklı EEG frekans bandı üzerinde ortalama Fourier çapraz spektral matrisler kullanılarak dikkatli bir değerlendirme yapılmıştır. Bu değerlendirme sonucunda, duygusal tepkilerin ortaya çıkmasında etkin rol oynayan beyin bölgeleri belirlenmiştir. Bu belirlemelerde, standartlaştırılmış düşük çözünürlüklü elektromanyetik tomografi (sDÇET) tekniği kullanılmıştır. Cinsiyet temelli farklılıkların değerlendirmesi ise, sDÇET kaynak güçleri üzerinden gerçekleştirilen bağımsız örneklem t-testi ile yapılmıştır. Elde edilen sonuçlar, tüm EEG frekans bantları boyunca ortalama EEG gücünün erkeklerle karşılaştırıldığında kadınlarda belirgin şekilde daha yüksek olduğunu göstermiştir. Ayrıca EEG frekans bantları üzerindeki mekansal dağılımın erkekler ve kadınlar arasında farklılık gösterdiği ve bu farkın özellikle olumsuz duygusal uyaranlarla daha belirginleştiği ortaya çıkmıştır. Bu bulguların ışığında, erkeklerin ve kadınların duygusal müzik videolarına verdiği yanıtın, beyin ağlarının farklı şekillerde çalıştığını gösterdiği sonucuna varılmıştır (Goshvarpour ve Goshvarpour, 2019).

Bhatti ve arkadaşlarının gerçekleştirdiği bir araştırmada, müziğin insan duyguları üzerindeki etkisi ve farklı yaş gruplarının müziğe olan duyarlılıkları incelenmiştir. Araştırmaya üç farklı yaş grubundan (15-25, 26-35 ve 36-50 yaş) oluşan otuz erkek ve kadın katılımcı dahil edilmiştir (Bhatti ve ark., 2016). Katılımcılardan gürültüsüz bir ortamda, elektronik, rap, metal, rock ve hiphop türlerinden bir dakikalık ses parçalarını dinlemeleri istenmiştir. Duygusal durumları hakkında kişisel raporlama


da dahil olmak üzere, her müzik türünün dinlenmesi sonrasında duygusal durumları değerlendirilmiştir. EEG sinyalleri kullanılarak duygusal tepkiler kaydedilmiş ve bu sinyallerden çıkarılan zaman, frekans ve dalgacık (wavelet) alanlarındaki özellikler insan duygularını sınıflandırmak için kullanılmıştır. Bu sınıflandırma sürecinde, Bhatti ve arkadaşları farklı duygusal durumları belirlemek için Çok Katmanlı Algılayıcı (ÇKA) kullanmışlardır. Kısa süreli Fourier dönüşümü ve Hamming penceresi (HP) kullanılarak zaman ve frekans alanı özellikleri çıkarılmıştır. Güç Spektral Yoğunluk (GSY) ve Bant Gücü (BG), frekans alanından elde edilen özellikler olarak hesaplanmıştır. Araştırma sonuçları, ÇKA'nın beyin sinyallerinin hibrit özelliklerini kullanarak sesli müzik parçalarına yanıt olarak insan duygularını tanıma konusunda başarılı bir doğruluk oranı sağladığını göstermiştir. Ayrıca katılımcılarda rock ve rap türlerinin sırasıyla mutluluk ve üzüntü duygularını tetiklediği gözlemlenmiştir. Bu bulgular, duygusal yanıtın yaş grubuna bağlı olarak değişkenlik gösterdiğini ve özellikle 26-35 yaş grubunun kendileri tarafından bildirilen duygularla uyumlu olan en yüksek duygu tanıma doğruluk oranını gösterdiğini ortaya koymaktadır (Bhatti ve ark., 2016).

Zhang ve arkadaşları yaptıkları bir çalışmada, EEG tabanlı duygu tanıma yöntemlerinin karmaşıklığını azaltmayı hedefleyen bir özellik çıkarımına odaklanmışlardır (Zhang ve ark., 2016). Çalışmanın temel önerisi, EEG sinyallerinin özgün mod fonksiyonlarına (IMFs) ayrıştırılması ve bu ayrıştırma sonucunda örnek entropinin hesaplanması için Deneysel Mod Ayrıştırma (EMD) yönteminin kullanılmasıdır. Bu metot, ilk dört IMF'yi kullanarak örnek entropileri hesaplar ve özellik vektörlerini oluşturur. Bu vektörler, eğitim ve test aşamaları için DVM sınıflandırıcısına verilir. Katılımcıların müzik videolarını izlerken duygusal yanıtını analiz etmek için oluşturulan DEAP veri tabanı kullanılmıştır. Veri tabanında bulunan her bir katılımcı 40 adet bir dakikalık müzik videosu izlemiş ve her bir video sonrası dinlediği müzikli videoların duygusal yanıtını belirlemek için kendi değerlendirmesini yapmıştır. Yapılan bu deneylerde, EEG sinyallerini ayrıştırmak için EMD kullanılmış ve SampEn kullanarak özellikler hesaplanmıştır. Ağırlıklı DVM kullanılan deneylerde, dört ikili sınıflandırma görevi oluşturulmuş, sınıflandırma performansını

değerlendirmek için 10 katlı çapraz doğrulama kullanılmış ve %94.98 doğruluk oranı elde edilmiştir (Zhang ve ark., 2016).

Puneeth ve arkadaşları DEAP veri seti üzerinde EEG sinyallerini kullanarak duygusal durumları belirlemeye yönelik yaptıkları bir çalışmada, zaman, frekans ve dakgacık domainlerinden özellikler çıkarılmış ve bu özellikler üzerinde istatistiksel ölçümler kullanılmıştır (Apparasu ve Sreeja, 2022). Bu çalışmada, valans ve uyarılma durumları dört duyguya (öfke, sevinç, üzüntü ve haz) ayrılmıştır. Seçilen EEG kanallarından çıkarılan özellikler, iki boyutlu ve bir boyutlu KSA'ya girdi olarak verilmiştir. Kullanılan bu modeller, tahmin edilmesi gereken duygulara uygun olarak eğitilmiş, özellikle haz duygusu için %81 gibi bir doğruluk oranı elde edilmiştir (Apparasu ve Sreeja, 2022).

Duygu durumlarının sınıflandırılması ile ilgili incelenen çalışmaların çoğunda, Circumplex modeli sıklıkla başvurulmuş bir yaklaşımdır. Bu model, duygusal yanıtların kapsamlı ve açık bir biçimde ifade edilmesini sağlar. Şekil 2.1.'de belirtildiği gibi, Circumplex modeli; düşük uyarılma seviyelerine ve negatif valansa sahip sinyalleri olan bir kişinin muhtemelen daha üzgün olduğunu, yüksek uyarılma seviyelerine ve pozitif valansa sahip sinyalleri olan bir kişinin ise genellikle sinirli veya gergin olma eğiliminde olduğunu gösterir (Mohammadpour ve ark., 2017). Bu modelin altında yatan mantık, EEG tabanlı sinyal sınıflandırma yöntemlerinin ve duygu tanıma modelinin doğruluğunu artırmasında önemli bir rol oynamasıdır.



Şekil 2.1. Circumplex modeli

Tezin fizyolojik sinyaller ile ilgili bölümünde yapılan çalışmada, veri seti oluşturma esnasında iki boyutlu Circumplex modeli kullanılmıştır. Bu model, valans ve uyarılma kavramlarına dayanarak duygusal durumları çizgisel bir düzen içinde temsil eder. Duygusal durumların sürekliliğini ve karşılıklı bağımlılıklarını vurgulayan bu model, duyguları ayrıştırmaktan ziyade ilişkilendirmeye odaklanır. Modelin iki eksenini oluşturan valans ve uyarılma, duygusal durumların özünü oluşturan iki temel bileşendir. Yatay eksen, duygusal valansı (mutluluk ve üzüntü gibi duygusal yükleri) temsil ederken dikey eksen uyarılma seviyesini (yüksek veya düşük enerji hali) temsil eder. Bu model, duygusal durumların göreceli ilişkilerini kapsamlı bir şekilde yansıtabilme özelliği sayesinde tercih edilmiştir.

Bu çalışmanın başlıca katkıları aşağıdaki gibidir:

- Farklı türde Müzik parçalarını dinlerken kaydedilen EEG sinyal verileri bilgisayar ortamına kaydedilmiştir. Kaydedilen EEG sinyal verileri ile insan duygu durumunu yansıtan 4 sınıflı yeni ve özgün bir veri seti oluşturulmuştur. Bu yeni veri seti, müzik dinleyen kişilerin beyin sinyalleri üzerinde meydana gelen duygusal aktivitelerinin kapsamlı bir şekilde analiz edilmesine olanak sağlamaktadır.

- EEG sinyallerini kullanarak insan duygularını tanıma sorununa yönelik yeni bir yöntem önerilmiştir. Bu yöntem, duygu tanıma teknikleri literatürüne katkıda bulunarak, EEG sinyallerinden duygusal durumların daha doğru ve hassas bir şekilde çıkarılabilmesine yardımcı olmaktadır.

- Müzik dinlerken insanların hissettiği duyguların, EEG kayıtlarından elde edilen spektrogramlar ile analiz edilebileceği gösterilmiştir. Bu, müzik ve duygular arasındaki karmaşık etkileşimin daha iyi anlaşılmasına yardımcı olabilir.

- Önceden eğitilmiş derin öğrenme modellerinin insan duygu tanıma sorunu için kullanılabileceği gösterilmiştir. Bu bulgu, karmaşık beyin sinyallerini analiz ederken derin öğrenme tekniklerinin potansiyelini vurgulamaktadır.

- Transfer öğrenmenin, insan duygularını tanıma problemi üzerindeki etkili gücü gösterilmiştir. Bu, özellikle büyük ve karmaşık veri setlerini işleme kapasitesi ve genellenebilirlik becerisi ile transfer öğrenmenin duygu tanıma alanında önemli bir araç olduğunu belirtir.

Önceki Çalışmalar başlığı altında, biyomedikal sinyal analizi üzerine yapılan çalışmalar sunulmuştur. Bu bölüm, biyomedikal görüntüleme konusundaki çalışmaları içerecek şekilde genişletilecektir.

Sharma ve arkadaşları çalışmalarında, pnömoni tespitine yönelik bir KSA modeli önermişlerdir. Bu çalışmada, normal ve pnömonili göğüs X-ışını görüntülerinden oluşan bir veri seti kullanılmıştır. Gönderilen X-ışını görüntülerini tanımak ve sınıflandırmak için KSA tabanlı model kullanılmıştır. İlk adımda, her görüntü 64x32 piksel boyutuna getirilmiş ve daha sonra eğitim ile doğrulama veri setlerine ayrıştırılmış ve görüntüler çeşitli işleme katmanlarına (convolution, havuzlama, ve flattening) tabi tutulmuştur. En son aşamada, işlenen görüntüler çıktı

sınıfına yönlendirilmiş ve bu görüntünün sınıfının (pnömonili veya sağlıklı) tahmin edilmesini sağlamıştır. Modelin eğitiminde, RMSprop ve Adam olmak üzere iki farklı optimizasyon tekniği kullanılmış ve modelin %98'e kadar bir doğruluk oranı sağladığı belirtilmiştir (Sharma ve ark., 2022).

Chandra ve arkadaşları çalışmalarında, pnömoniyi tespit etmek için bir makine öğrenmesi tekniği kullanmışlardır. Öncelikle akciğer bölgeleri X-ışınından bölümlenmiş, daha sonra bu bölgelerden sekiz istatistiksel özellik çıkartılmış ve bu özellikler Rastgele Orman (RO), lojistik regresyon, ÇKA tekniği gibi çeşitli sınıflandırma algoritmaları ile sınıflandırılmıştır. Bu model, 412 görüntü üzerinde değerlendirilmiş ve elde edilen doğruluk yaklaşık %95 olarak tespit edilmiştir (Chandra ve Verma, 2019).

Benzer şekilde, Kuo ve arkadaşları pnömoninin tespiti ve sınıflandırılması için çeşitli özellikler çıkarmışlardır. Çıkarılan özellikler karar ağacı, DVM ve lojistik regresyon gibi çeşitli sınıflandırma modellerine uygulanmıştır. Karar ağacını kullanarak elde edilen maksimum doğruluk %94,5 olarak belirlenmiştir (Kuo ve ark., 2019).

Luo ve arkadaşları çalışmalarında, düşük dozlu X-ışını görüntülerindeki gürültüyü azaltmak için Ultra-Yoğun Gürültü Azaltma Ağı (UYGAA) temelli bir KSA çerçevesi oluşturmuşlardır. Bu UYGAA tabanlı KSA çerçevesi, çoklu-yol sınır birimlerini yoğun bir şekilde birbirine bağlayarak özellik çıkarımını optimize etmektedir. Ek olarak bu ekibin klinik uygulamaları genişletme çabaları doğrultusunda, X-ışını eğitim örneklerinde Poisson gürültüsünün normal bir dağılım göstermesi için eğitim süreci düzenlenmiştir. Bu optimizasyon, düşük dozlu X-ışını görüntülerinde daha yüksek bir sinyal-gürültü oranı elde etmeye yardımcı olmuştur ve bu da düşük dozlu görüntülerin klinik ortamlarda daha geniş bir kullanımını sağlamıştır. Bu bulgular, kalp kateter laboratuvarında X-ışını görüntü gürültüsünün azaltılması konusunda ilerlemeyi mümkün kılmıştır (Luo ve ark., 2021).

Sahin bir çalışmada X-ışını görüntülerini kullanarak COVID-19'u belirlemek ve hastaları COVID-19 pozitif veya negatif olarak ayırt etmek için bir KSA modeli

tasarlamıştır. Bu model, Keras kütüphanesinin sıralı modelini temel alır. Bu sıralı model evrişimli ve maksimum havuzlama katmanlarını içerir. Bu evrişim ve havuzlama katmanlarından oluşan KSA modeli bir X-ışını görüntü veri seti üzerinde eğitilmiştir. Bu çalışmada, MobileNetv2, ResNet50 gibi farklı ağ mimarileri de göz önüne alınmıştır. Sahin'in önerdiği KSA modeli ile test doğruluğu %96.71 ve F1 skoru %91.89 olarak belirlenmiştir (Sahin, 2022).

Bu araştırmalar, COVID-19'un otomatik teşhisinde, X-ışını görüntüleri üzerinde derin öğrenme algoritmalarının önemli bir rol oynayabileceğini ortaya koymaktadır. Model, tanı kitlerinin ve uzman sağlık personelinin yetersiz olduğu uzak bölgelerde, RT-PCR testine alternatif veya destekleyici bir sistem olarak değerlendirilebilir.

Çok sayıda araştırmacı, COVID-19 enfekte hastaları göğüs X-ışını görüntüleri üzerinden belirlemeye yönelik teknikler geliştirmiştir. Bu tez çalışmasında, sınıflandırma doğruluğunu optimize etmek için, öncelikli olarak orijinal görüntülerin kontrastı ÇAGKAA algoritması ve KSAHE tekniği aracılığıyla geliştirilmiştir. Kontrastı geliştirilmiş bu görüntüler, sonrasında KSA modelimize giriş olarak verilmiştir.

Bu tez çalışmasının biyomedikal görüntü analizi bölümünde sunulan temel katkılar aşağıda özetlenmiştir:

Orijinal görüntülerin genel kontrastını iyileştirmek adına, KSAHE'nin optimal parametrelerini bulmak için ÇAGKAA algoritması kullanılmıştır. KSAHE ve ÇAGKAA'un KSA ile entegre edildiği hibrit bir sistem, enfekte akciğer X-ışını görüntülerini daha doğru sınıflandırmak için etkin bir şekilde kullanılabileceğini göstermiştir. Deneylerimizin sağladığı etkin sonuçlar, önerdiğimiz metodun COVID-19 kitlerine alternatif olarak sağlıklı vakaları ve pnömoni vakalarını COVID-19 vakalarından ayırt etmek için kullanılabileceğini ortaya koymuştur.

Çalışmamızın geri kalanı aşağıdaki bölümlerden oluşmaktadır:

Materyal ve yöntemler bölümü (bölüm 3), araştırma bulguları ve tartışma bölümü (bölüm 4) ve sonuçlar ve öneriler bölümü (bölüm 5) bulunmaktadır. Bölüm 3'te, yöntemimiz ayrıntılı olarak açıklanmaktadır. Önerdiğimiz yöntemler, Bölüm 4'te bulunan deneysel sonuçlara göre, konu bağlamında kullanılan son tekniklerle karşılaştırılmaktadır. Bölüm 5'te ise sonuç ve öneriler kısmına yer verilmektedir.



3. MATERYAL ve YÖNTEM

Biyomedikal görüntü ve sinyal analizinin geniş ve karmaşık uygulama alanlarına sahip olduğu bilinmektedir. Bu çalışmada, söz konusu analizlerin gerçekleştirilmesi için kullanılan teknikler ve materyaller ayrıntılı olarak incelenmiştir. Bu detaylı inceleme, biyomedikal verilerin görüntü ve sinyal analizlerini öne çıkarırken kullanılan algoritmik hesaplamalar ve yöntemlerin de geniş uygulama potansiyelini göstermektedir.

Yapay zeka ve derin öğrenme tekniklerinin biyomedikal sinyal ve görüntü analizlerinde uygulanan yöntemlerle birleştirildiği bu çalışmada, spesifik metodolojik yaklaşımlar ayrıntılarıyla birlikte ele alınmıştır. Burada biyomedikal X-ışını görüntüleri üzerinde Konvolüsyonel Sinir Ağları ve Kontrast Sınırlı Adaptif Histogram Eşitleme Algoritması ile Çok Amaçlı Guguk Kuşu Arama Algoritmasının entegrasyonu ve biyomedikal sinyalleri üzerinde ise sinyal işleme yöntemleri, makine öğrenmesi ve derin öğrenme yöntemlerinin kullanımı detaylı bir şekilde incelenmiştir.

Dolayısıyla bu bölüm biyomedikal görüntü ve sinyal işleme tekniklerinin uygulanması bu tekniklerin yönetilmesi ve etkili bir şekilde nasıl kullanılması gerektiğini ayrıntılı bir şekilde ele almaktadır.

3.1. Materyal


Bu tez çalışmasında, biyomedikal sinyaller ve görüntüler temel veri kaynakları olarak kullanılmıştır. Bu veriler, makine öğrenmesi ve yapay zekâ tekniklerinin uygulandığı iki farklı analiz ve sınıflandırma probleminin çözümünde kullanılmıştır. Biyomedikal sinyaller, ‘EMOTIV EPOC+’ ve ‘OPENBCI Ganglion Kartı’ cihazları aracılığıyla toplanan EEG ve EOG verilerini içerirken; biyomedikal görüntüler, COVID-19 hastalık tanısı için kullanılan X-ışını -röntgen- görüntülerinden oluşmaktadır. Her bir veri türü, ayrı ve özgün bir analiz ve sınıflandırma sürecine tabi tutulmuştur.

3.1.1. Biyomedikal sinyaller için kullanılan veri toplama cihazları

3.1.1.1. OpenBCI ganglion


OpenBCI Ganglion kartı, açık kaynak kodlu, taşınabilir ve nispeten düşük maliyetli bir biyopotansiyel ölçüm cihazıdır (Ricogarcia ve ark., 2022). Özellikle BBA uygulamalarında kullanılan bu cihaz, EEG, EKG, EMG, EOG gibi sinyalleri ölçebilir ve birçok farklı platformda ve farklı uzantılarda ham verileri kaydedebilmektedir. Ganglion, dört yüksek kaliteli biyopotansiyel kanala sahiptir ve Bluetooth Düşük Enerji (BDE) üzerinden kablosuz veri iletimi yapabilir (Samson ve ark., 2018)

Bu cihazın en önemli özelliklerinden biri, 3.3V ila 6V DC batarya ile çalışabilmesi ve düşük enerji tüketimine sahip olmasıdır. Bununla birlikte, Ganglion kartının Simblee BDE Radio modülü ve MCP3912 Analog Ön Uç gibi bileşenlere sahip olması, daha doğru ve daha hassas ölçümler yapılabilmesini sağlamaktadır (Korovesis ve ark., 2019). Bu, cihazın biyomedikal sinyalleri toplarken verimliliğini ve güvenilirliğini artırır. Cihazın bir diğer önemli özelliği ise, herhangi bir frekansın 0.3 Hz altında kesilmesidir. Bu, özellikle düşük frekanslı aktivitelerin araştırılmasında önemli olabilir. Bunun yanı sıra Ganglion cihazı, LIS2DH 3 eksenli ivmeölçer gibi ek özelliklerle donatılmıştır, bu da cihazın hareketle ilgili verileri de toplamasına olanak sağlamaktadır (Ganglion, 2018; Samson ve ark., 2018)




Şekil 3.1. OpenBCI Ganglion kart

OpenBCI Ganglion kartının kablosuz yapısı, taşınabilirliği ve kullanıcı dostu arayüzü, kullanıcıların kendi deneylerini tasarlamasına, uygulamasına ve analiz etmesine olanak sağlar. Ayrıca açık kaynak kodlu olması, kullanıcıların Ganglion kartının yazılım ve donanımını kendi ihtiyaçlarına göre özelleştirebilmesini sağlamaktadır.



Şekil 3.2. Ganglion PCB katmanları

OpenBCI tarafından üretilen OpenBCI Ganglion kartı ile birlikte çalışmada kullanılması için yeniden basılan Ganglion kartının ön ve arka yüzleri Şekil 3.1.'de gösterilmiştir. Şekil 3.3.'te Ganglion Kartı PCB katmanları ve Şekil 3.2.'de Ganglion kartı devresi gösterilmiştir. Yeniden üretilen kart Şekil 3.3.'te verilen katmanlardan ve Şekil 3.2.'de verilen Ganglion kart devresinden yararlanarak tasarlanmıştır (Ganglion, 2018).




Şekil 3.3. Ganglion kartı devresi

Bu tez çalışmasında OpenBCI Ganglion cihazı, katılımcıların EOG ve EEG sinyallerini toplamak ve analiz etmek için kullanılmıştır. Bu veriler, göz hareketlerinin sınıflandırılmasında önemli bir rol oynamıştır. Ganglion kartın topladığı EOG verileri, göz hareketlerinin doğru ve etkili bir şekilde sınıflandırılması için gerekli ham veri setini sağlamıştır.

3.1.1.2. Emotiv EPOC+

Beyin dalgalarını ölçen ve analiz eden bir dizi EEG cihazı ve yazılım platformu sunan EMOTIV cihazları, beyin aktivitesini ölçme ve analiz etme konusunda geniş bir uygulama yelpazesine sahiptir. Bu özelliği cihazı nörobilim araştırmaları, kullanıcı deneyimi tasarımı, duygu analizi gibi çeşitli alanlarda kullanılabilir hale getirmiştir.

Bu çalışmada kullanılan EMOTIV EPOC+ cihazı, EEG sinyallerini toplamak için kullanılan taşınabilir ve kablosuz bir cihazdır. Şekil 3.4.'te gösterilen bu cihaz, genellikle beyin aktivitesini kaydetmek ve analiz etmek için kullanılmaktadır (Carter, 2012). Bu EEG kaydedici, kullanımı kolay bir tasarım ile yüksek kaliteli beyin verilerine hızlı ve profesyonel erişim sağlar. Bu cihaz, referans elektrotları hariç olmak üzere toplam 12 kanala sahip olup, 300 saniyeye kadar kayıt alabilmektedir. Bu cihaz, saniyede 128 örnekleme frekansı ile veri alabilir. EEG sinyalleri, beyinde oluşan elektriksel aktiviteyi ölçen bir tekniktir ve genellikle insanların duygusal durumlarını, dikkat düzeylerini ve diğer bilişsel işlevlerini incelemek için kullanılır (Kabir ve ark., 2016). Bu cihaz, veri toplama ve analiz için özelleştirilebilir bir platform sunar ve bu veriler, daha sonra çeşitli uygulamalar için kullanılabilir (Wójcik ve ark., 2015).



Şekil 3.4. EMOTIV EPOC+ EEG veri okuma cihazı

EMOTIV EPOC+ cihazı, bu çalışmada katılımcıların duygusal durumlarını ve beyin dalgalarını kaydetmek için kullanılmıştır. Çalışmada, katılımcılara farklı türde müzikler dinletilmiş ve bu sırada beyin dalgaları EMOTIV EPOC+ cihazı ile kaydedilmiştir. Elde edilen bu veriler, daha sonra beyin dalgaları ve duygusal durum arasındaki ilişkiyi analiz etmek için kullanılmıştır.

3.1.2. Biyomedikal sinyaller için veri seti oluşturma

Bu tez çalışmasında kullanılan veri seti, EMOTIV EPOC+ ve OpenBCI Ganglion cihazı kullanılarak toplanan EEG ve EOG sinyallerinden oluşmaktadır.

3.1.2.1. EEG veri seti oluşturma

Toplanan EEG verileri, müzik dinleyen 9 katılımcıdan elde edilmiştir. Her katılımcıya duygusal durumlarını farklı şekillerde etkileyebilecek çeşitli türlerde müzikler dinletilmiştir. Bu esnada EEG sinyalleri, EMOTIV EPOC+ cihazı aracılığıyla kaydedilmiştir.

3.1.2.1.1. Katılımcılar ve uyarıcı materyaller

Bu çalışma, Türk musikisine ait müzik türlerinin çeşitliliğini ve geniş yelpazesini kullanarak EEG tabanlı duygu tanıma deneyine bir uyarıcı olarak Türk müzik parçalarını eklemiştir. Müzik türlerinin seçimi, bu çalışma için oldukça

önemlidir. Türk müziğinden bilinmeyen ve temel olmayan türlerin seçilmesi, katılımcıların duygusal olarak harekete geçmesini zorlaştırabilir. Dolayısıyla, bu çalışmada, temel Türk müzik türleri olarak kabul edilebilecek ve oldukça popüler olan Türk Sanat ve Türk Halk müziklerinin yanı sıra Türk Pop ve Türk Caz Müzik türleri de kullanılmıştır.

Deney için kullanılan 16 adet ses parçası, MP3 formatında ve 320 kbps örnekleme hızına sahip olup, EEG tabanlı duygu tanıma deneyi için dış uyarıcı olarak kullanılmıştır.

Çalışmaya Türkiye'nin doğu ve batı kültürlerinden 20-25 yaşları arasında toplam dokuz katılımcı gönüllü olarak katılmıştır. Katılımcıların beşi erkek, dördü kadındır. Türkiye'nin Doğu kültüründen katılımcılar genellikle Türk Halk ve Türk Sanat müziği türlerini dinlediklerini belirtirken, Türkiye'nin batı kültüründen katılımcılar genellikle Türk Pop, Türk Sanat ve Türk Caz müziği dinlediklerini belirtmişlerdir.

Katılımcılar, müziğe hobi olarak ilgi gösteren ve dijital ortamda farklı müzik dinleme alışkanlıkları olan bireylerdir. Ayrıca, katılımcılar herhangi bir mental ve ruh sağlığı problemi, depresyon ve anksiyete bozukluğu veya işitme kaybı olmayan bireylerdir. Deney öncesinde, katılımcılara çalışmanın kapsamı ve prosedürü hakkında bilgi verilmiş ve her katılımcıdan yazılı onay alınmıştır.

3.1.2.1.2. Veri toplama

Bu tez çalışmasında, katılımcılardan EEG sinyalleri almak için EMOTIV EPOC+ başlıklı cihaz kullanılmıştır. Bu cihaz, beyin verilerine hızlı ve profesyonel bir erişim sağlar ve duygu tanıma gibi farklı alanlarda yaygın olarak kullanılır. EEG verileri, Bluetooth bağlantısı aracılığıyla Matlab üzerinde hazırlanan bir yazılım kullanılarak bilgisayar ortamında kaydedilmiştir.

Tüm EEG kayıtları, gürültüsüz ve normal gündüz ışığına sahip bir ortamda alınmıştır. Cihazdaki elektrotlar, uluslararası 10-20 sistemi doğrultusunda beyin bölgelerine yerleştirilmiştir ve bu bölgelerden EEG kayıtları alınmıştır. Aynı deney koşullarını sağlamak adına, her bir katılımcıya aynı sırayla 30 saniyelik 16 müzik

parçası dinletilmiştir. Bu müzik türleri Türk Sanat ve Türk Halk müzikleri ile Türk Pop ve Türk Jazz müzikleridir. Her türden dört müzik parçası katılımcılara dinletilmiş ve her parçadan sonra 30 saniyelik bir sessizlik ve dinlenme süresi sağlanmıştır.

Müzikler katılımcılara dinletilirken EEG kayıtları alınmış ve her bir müzik parçasının sonunda hissedilen duyguya göre EEG kaydı etiketlenmiştir. Manuel olarak etiketlenen bu duygu etiketleri, duygu tanıma süreci ve sınıflandırıcıların eğitimi için kullanılmıştır.

Toplamda 144 kayıt alınmış olmasına rağmen, kayıt sürecinde bazı veriler etkili bir şekilde alınamadığı için, 15 kayıt değerlendirmeye alınmamış ve bu nedenle duygu tanıma, totalde 129 EEG sinyal veri kaydı içeren bir veri seti üzerinden gerçekleştirilmiştir. Bu süreç boyunca kullanılan müzik parçaları ve bu parçaların sahiplik bilgileri ek materyaller bölümünde paylaşılmıştır.

3.1.2.2. EOG veri seti oluşturma

Bu tez çalışmasında, OpenBCI Ganglion cihazı kullanılarak göz hareketlerine dayalı bir veri seti oluşturulmuştur. Bu veri seti, bir ekranın kontrol edilmesi için geliştirilmiştir. Ekranın orta noktası, gözün referans bakış konumu olarak belirlenmiştir. Elde edilen veriler belirlenen 4 farklı göz hareketini temsil etmektedir. Bu hareketler:

Hareket1: Gözlerin aşağıya bakışı, ekranın merkezi referans alınarak bakışlar aşağıya doğru yönlendirilir.

Hareket2: Gözlerin yukarıya bakışı, ekranın merkezi referans alınarak bakışlar yukarıya doğru yönlendirilir.

Hareket3: Gözlerin Sağa bakışı, ekranın merkezi referans alınarak bakışlar sağa doğru yönlendirilir.

Hareket4: Gözlerin sola bakışı, ekranın merkezi referans alınarak bakışlar sola doğru yönlendirilir.

Bu hareketler, kullanıcının göz hareketleriyle ekranı kontrol etmesine olanak sağlamaktadır ve belirli bir ekrandaki lokasyon veya işlemi temsil edebilmektedir.

EOG verileri, toplamda altı erkek katılımcıdan alınmıştır. Her katılımcıdan dört farklı yöne bakmaları istenmiştir ve bu dört farklı bakış yönü dört farklı veri sınıfını oluşturmuştur. Katılımcılardan her bakış yönünü 10 kez tekrarlamaları ve her tekrardan sonra 10 saniye dinlenmeleri talep edilmiştir. Bu durumda her bir bakış yönü için 60 veri noktası (10 tekrar * 6 katılımcı) ve toplamda 240 veri noktası (10 tekrar * 4 bakış yönü * 6 katılımcı) elde edilmiştir. Her bir bakış hareketi, 2 saniye süresince kaydedilmiştir.


3.1.3. Biyomedikal görüntüler göğüs röntgeni veri seti

Çalışmanın biyomedikal görüntü analizi bölümünde, yaygın olarak tercih edilen ve bu bağlamda referans olarak kabul edilen bir açık erişimli veri setinden faydalanılmıştır. Kullanılan bu veri seti, ‘COVID-19 Radyografi’ olarak adlandırılmıştır ve Kaggle veritabanı aracılığıyla toplanmıştır (M. Chowdhury ve ark., 2020; Rahman ve ark., 2021). Çizelge 3.1.’de veri seti hakkında daha fazla bilgi sunulmuştur.

Çizelge 3.1. Kullanılan veri seti

Veri Seti Adı	COVID-19	Normal	Pnömoni
COVID-19 Radyografi veri seti (M. Chowdhury ve ark., 2020; Rahman ve ark., 2021)	1143	1341	1345

COVID-19 Radyografi veri seti, COVID-19, normal ve pnömoni olmak üzere üç sınıftan oluşmaktadır. Toplam görüntülerin 1143’ü COVID-19 sınıfına, 1341’i normal sınıfına ve 1345’i pnömoni sınıfına aittir. Her sınıftan örnek göğüs röntgeni görüntüleri Şekil 3.5.’te sunulmuştur.



Şekil 3.5. Örnek göğüs röntgen verisi; (a) COVID-19, (b) Pnömoni, (c) Normal

Bu veri setinin kullanılması COVID-19, normal ve pnömoni durumlarının doğru bir şekilde sınıflandırılmasına olanak sağlar. Bu nedenle veri seti, bu tez çalışmasının kapsamı ve hedefleri ile uyumludur. Bu çeşitli sınıfların dahil edilmesi, modelin daha geniş bir veri yelpazesi üzerinde doğru tahminler yapabilmesi için gereklidir.

3.2. Yöntem

Bu bölümde, biyomedikal sinyal ve görüntülerinin analiz ve sınıflandırılmasını gerçekleştirmek için kullanılan yöntemler detaylı bir şekilde açıklanmaktadır.

3.2.1. Biyomedikal sinyal analizi

3.2.1.1. Veri ön işleme


Bu alt bölümde, toplanan EEG sinyallerinin analize hazır hale getirilmesi sürecini, bir dizi ön işlem adımı aracılığıyla ele alacağız. Bu süreç genel olarak aşağıdaki adımları içerir:

3.2.1.1.1. Sinyal filtreleme

İnsan beyin aktivitesini incelemek için 0 Hz - 50 Hz bandı kullanılır. EEG sinyallerinin kalitesi ve gürültüsüz olması, özellik çıkarımı ve sınıflandırma için önemlidir. Bu nedenle gürültüyü azaltmak için 1.0 Hz ile 50 Hz arasında bir bant geçişine sahip bir filtre kullanılır.

3.2.1.1.2. Çerçeveleme

Filtreden geçirilen sinyallerden spektrogram çıkarabilmek için, sinyal belirli bir uzunluktaki çerçevelere ayrılır. Çerçeve uzunluğu 20 ila 40 ms arasında değişir ancak yaygın değer 25ms'tir (Haggag ve ark., 2015). Bu çalışmada, EEG sinyalleri 25 ms uzunluğunda çerçevelere bölünmüştür. Ayrıca, Şekil 3.6.'da gösterildiği gibi her bir çerçeve, önceki çerçevenin bir kısmını kapsar. Bu işlem çerçeveler arası geçişin düzgün olmasını sağlamak içindir (Atal, 1976).




Şekil 3.6. Çerçeveleme

Çerçeveler arasında örtüşmenin olmaması, iki ardışık çerçeveyi izlerken veya o çerçevedeki sinyalleri işlerken, çerçeveler arasındaki özellik değişikliği kesintiye veya sıçramaya neden olacağı bilinmektedir (Atal, 1976). Ayrıca komşu çerçevelerin parametre değerleri arasındaki fark da daha yüksek olur. Bu sebeple çerçeveler birbiri ile örtüşmektedir. Bu tez çalışmasının biyomedikal sinyaller ile ilgili bölümünde, çerçevelerin birbirini kapsama oranı çerçevenin %50'si olarak belirlenmiştir.

3.2.1.1.3. Pencereleme

Sinyal üzerine çerçeveleme uygulandıktan sonra, pencereleme uygulanmıştır. Bu, her çerçevenin başında ve sonunda oluşan süreksizliği önlemek amacıyla yapılmıştır.




Şekil 3.7. Hamming pencereleme

Bu çalışmada, pencerelemede yaygın olarak kullanılan ‘Hamming penceresi’ kullanılmıştır. Şekil 3.7.’de gösterilen ‘Hamming Pencereleme’ sayesinde sinyalin merkezi bölgesi daha belirgin hale gelmiştir. Uçlar sıfıra yaklaştırılır ve HP ile sinyalin son bölgelerinde istenmeyen radyasyonlar en aza indirilir (Gupta ve ark., 2013). Aynı zamanda sinyali Fourier dönüşümü için uygun hale getiren Hamming fonksiyonudur. Hamming fonksiyonunun çalışma mantığı, HP ile çerçevelenen ses sinyalinin çarpılmasıdır, sonuçta pencereleme sinyali elde edilir. Hamming penceresi formülü Denklem 3.1’de verilmiştir (Gupta ve ark., 2013). α bir optimizasyon parametresi ve N pencere uzunluğudur. Çerçvelendikten ve HP uygulandıktan sonraki sinyallerin dalga formları Şekil 3.8.’de verilmiştir.

$$w[n] = \alpha - (1 - \alpha) * \cos\left(2 * \pi * \frac{n}{N}\right) \quad (3.1)$$

$$n: 0, 1, 2 \dots N - 1$$



Şekil 3.8. EEG sinyalinin çerçevenmesi ve hamming ile sinyalin pencerenmesi

3.2.1.1.4. Fourier dönüşümü

Hamming pencereleme işleminden sonra sinyale Fourier dönüşümü uygulanır. Sinyal verilerinde dönüşüm bir sinyalin başka parametrelerle temsil edilmesi olarak düşünülebilir. Fourier dönüşümü, zaman alanında olan bir sinyalin frekans alanına geçişini sağlar. Bu çalışmada, Hızlı Fourier Dönüşümü (HFD) kullanılmıştır. Sinyal işleme alanında Fourier dönüşümü sinyal içindeki bilgilere erişmek için önemli bir dönüşüm yöntemi olarak kabul edilir (M. Li ve Chen, 2021). Frekans, genlik ve faz bileşenlerinden meydana gelen sinyaller Kosinüs ve sinüs fonksiyonlarının toplamı olarak ifade edilebilir. Her bir çerçeve içerisindeki sinyal HFD ile zaman domaininden frekans domainine geçirilir.

Bir fonksiyonun sürekli zaman Fourier Dönüşümü genellikle Denklem 3.2'ye göre hesaplanır: $F(\omega)$ frekans-domainindeki sinyali, $f(t)$ zaman-domainindeki orijinal sinyali temsil eder. j sembolü, matematikte hayali birim (i 'nin eşdeğeri) olarak kullanılır ve $\sqrt{-1}$ 'in değerini alır. ω frekansı temsil eder. Orijinal sinyal ve integral işareti, verilen sınırlar arasında belirtilen fonksiyonun integralini (yani alanını) almayı temsil eder. Bu formül, her frekansta (ω), sinyalin ne kadar büyük bir bileşeni olduğunu hesaplar. Böylece bir sinyalin frekans-domainindeki gösterimi elde edilir.

Denklem 3.3' te ise sürekli zamanlı Fourier dönüşümünün ağırlıklı hareketli pencere versiyonu gösterilmiştir. Bu denklem genellikle zaman-frekans analizi için kullanılır. Denklem'de verilen $x[m]$: İncelenen sinyal veya veri serisi, $w[n-m]$: Bir pencere fonksiyonu (genellikle Gauss, Hamming, Hanning vb. gibi), $e^{(-j\omega n)}$: Euler formülünün frekans domaini bölümü ($j = \sqrt{-1}$, ω frekansı ve n zamandır) olarak ifade edilir (Ersoy, 2006).

$$F(\omega) = \int f(t) * e^{-j\omega t} dt \quad (3.2)$$

$$X(n, \omega) = \sum_{m=-\infty}^{\infty} x[m]w[n-m]e^{-j\omega n} \quad (3.3)$$

HFD, Fourier dönüşümünün daha verimli bir algoritmasıdır. HFD, genellikle bir sinyalin frekans-domainine dönüştürülmesi için kullanılır ve bunu Fourier dönüşümünün matematiksel kompleksliğini azaltan özel bir algoritma kullanarak yapar. Denklem 3.4'te belirtilen formülde, $X(k)$ frekans domainindeki sinyali, $x(n)$ ise zaman domainindeki orijinal sinyali temsil eder. 'e' sembolü, Euler sayısını (yaklaşık olarak 2.71828) ifade eder (Ersoy, 2006). 'N', sinyalin toplam örnek sayısını belirtir. 'n' ve 'k', zaman ve frekans indislerini sırasıyla temsil eder.

$$X(k) = \sum_{n=0}^{N-1} x(n) * e^{-\frac{j2\pi nk}{N}} \quad (3.4)$$

Bu formül, her frekansta (k), sinyalin ne kadar büyük bir bileşeni olduğunu hesaplar. Böylece, bir sinyalin frekans-domainindeki gösterimini elde ederiz. Yine de pratikte, bu matematiksel ifadenin kullanımı, genellikle daha karmaşık HFD algoritmaları kullanılarak gerçekleştirilir. Bu algoritmalar, Fourier dönüşümünün matematiksel karmaşıklığını azaltır ve böylece daha büyük veri setlerinde kullanımı daha hızlı ve verimli hale getirir (M. Li ve Chen, 2021).

3.2.1.1.5. Dalgacık dönüşümü


Dalgacık Dönüşümü (DD), çok ölçekli bir çalışma prensibine dayanan Fourier dönüşümünün bir genişlemesidir (Hubbard, 1998). DD, durağan olmayan sinyallerle ilgili problemleri ele alır ve sinyaller içinde hem frekans hem de zaman hakkında bilgi sağlar. DD'nin avantajı, düşük frekanslarda geniş ve yüksek frekanslarda dar olan değişken pencere boyutudur (Bremer ve ark., 2006). Bu nedenle DD tüm frekans aralıklarında optimal zaman-frekans çözünürlüğüne yol açar. Sürekli DD'de, sonlu enerjiye sahip belirli bir sinyal, sürekli bir frekans bandı ailesine yansıtılır (Hubbard, 1998).

$$W(a, b) = \int f(t) * \psi^*((t - b)/a) dt \quad (3.5)$$

Denklem 3.5'de verilen Sürekli Dalgacık Dönüşümü formülünde;


$W(a, b)$ Dalgacık dönüşümünü, $f(t)$ analiz edilmekte olan sinyali temsil eder. ψ^* kompleks konjugatını ve $\psi(t)$ dalgacık fonksiyonunu temsil eder. a ve b ölçek ve yer değiştirme parametreleridir (Hubbard, 1998).

Şekil 3.9.'da orijinal EEG sinyaline DD uygulanmış ve farklı çözünürlük seviyelerinde sinyal elde edilmiştir. Bu grafik, EEG sinyalinin frekans bileşenlerini farklı seviyelerde ayrıştırarak bilgi sağlar.



Şekil 3.9. Bir EEG sinyalinin çözünürlük seviyeleri ve dalgacık katsayıları

DD, bir sinyali, frekans bandının sürekli bir ailesine yansıtan bir işlemi temsil eder (T. Wang ve ark., 2021). Yani dalgacık dönüşümü bir sinyalin farklı frekans bantlarındaki bileşenlerini ayırmak için kullanılır. Söz konusu sinyal, bu frekans bantlarına ‘yansıtılır’, yani, sinyalin bu frekanslardaki enerjisi ölçülür. İki boyutlu bir sinyalin dalgacık dönüşümü, yinelemeli filtreleme ve alt örnekleme işlemlerini içerir. Resim, iki boyutlu bir matris olarak düşünülebilir ve dalgacık dönüşümünün her seviyesinde, resim sinyali orijinal boyutun $\frac{1}{4}$ ’üne sahip dört alt frekans bandına ayrılır (C. Wang ve ark., 2023). Bu bandlar, karşılık gelen frekans bantlarının dalgacık katsayılarını içerir.



Şekil 3.10. Sürekli dalgacık dönüşümü ile EEG sinyallerinin görselleştirilmesi

Şekil 3.10.'da bir Elektroensefalografi (EEG) sinyalinin Sürekli Dalgacık Dönüşümünü görselleştirilmiştir. X-ekseni, sinyalin zaman veya örneklerini temsil eder. Bu, sinyaldeki aktivitenin zamanla nasıl değiştiğini gözlemlememizi sağlar. Y-ekseni ise frekansları ifade eder. Ölçeklerin geniş bir aralığa yayılması, dalgacık dönüşümünün frekanslarının düşükten yükseğe çeşitli özellikleri yakalayabilmesini mümkün kılar.

Renkler, belirli bir zaman ve frekanstaki dalgacık katsayılarının büyüklüğünü gösterir. Renkler genellikle 'ısı haritası' tarzında sunulur, daha koyu renkler düşük değerlere, daha açık veya daha parlak renkler ise yüksek değerlere karşılık gelir. Bu durum, belirli bir zaman noktasında hangi frekans bileşenlerinin baskın olduğunu görselleştirmemizi sağlar.

Özellikle EEG sinyalleri söz konusu olduğunda, belirli frekans bantları (delta, theta, alfa, beta, gamma vb.) belirli beyin durumları veya aktiviteleri ile ilişkilendirilir. Bu çerçevede, çıktıyı yorumlarken belirli frekans bölgelerindeki parlaklık değişimlerini veya desenleri aramak önemli olabilir. Bu değişimler, belirli bir zaman noktasında belirli bir beyin aktivitesinin yüksek olabileceğini gösterebilir. Bu şekilde


çıktı, beyin aktivitesinin zaman ve frekans boyutlarının birleşik bir görünümünü sağlar.

3.2.1.1.6. Güç spektrogramının çıkarılması

Son aşamada, Fourier dönüşümü uygulanan sinyallerin güç spektrogramları çıkarılır. Spektrogram, genellikle bir sinyalin zaman içindeki frekans içeriğini görsel olarak temsil etmek için kullanılan bir grafikdir. Her bir noktada, sinyalin belirli bir frekansta ne kadar enerjiye sahip olduğunu gösterir. Bu, özellikle sinyalin zaman içinde nasıl değiştiğini analiz etmek için önemlidir. Örnek sinyalin güç spektrogram grafiği Şekil 3.11’de verilmiştir. Güç spektrogramı, spektrogramın bir çeşidi olarak düşünülebilir. Ancak güç spektrogramı, sinyalin belirli bir frekansta ne kadar ‘gücü’ olduğunu gösterir, yani enerjiyi göstermemektedir. Buradaki ‘güç’, genellikle sinyalin belirli bir frekansta ne kadar ‘gürültülü’ olduğunu ifade eder.

Güç spektrogramının çıkarılması, genellikle bir sinyalin güç spektrogramını hesaplamak için kullanılan bir prosedürdür. Bu işlem genellikle aşağıdaki adımları içerir: Sinyalin her bir bölümüne (genellikle ‘pencereler’ olarak adlandırılır) bir Fourier Dönüşümü (FD) uygulanır. Bu, sinyalin frekans-domainindeki gösterimini verir. Her bir pencerenin Fourier Dönüşümünün karesi alınır. Bu, sinyalin belirli bir frekansta ne kadar güçlü olduğunu gösteren bir değer verir. Bu değerler, zamanın bir fonksiyonu olarak grafik üzerinde çizilir. Bu, sinyalin zaman içindeki güç dağılımını göstermektedir (Dantona ve ark., 2011; Rahim Abdullah ve ark., 2015).

Bu prosedür, bir sinyalin zaman içindeki frekans karakteristiklerini daha ayrıntılı olarak anlamamızı sağlar. Ayrıca sinyal işleme ve makine öğrenmesi gibi alanlarda, özellikle sinyal sınıflandırma ve tanıma gibi uygulamalarda önemli bir rol oynar.



Şekil 3.11. EEG verisi ve güç spektrogramı

Fourier dönüşümü genellikle bir pencere fonksiyonu uygulandıktan sonra sinyale uygulanır. Bu, sinyalin belirli bir zaman dilimindeki frekans içeriğini analiz etmek için yapılır. Bu pencere fonksiyonu genellikle bir Hanning, Hamming, veya Blackman penceresi olabilir ve sinyalin tamamına uygulanmaz, sadece belirli bir zaman dilimine uygulanır. Sinyal bu pencere ile çarpılır ve sonrasında FD uygulanır. Sonrasında bu sonucun karesi alınır. Denklem 3.6'da bir güç spektrogramının nasıl hesaplandığı matematiksel olarak ifade edilmiştir. Bu denklemde: $x(\tau)$ orijinal sinyali temsil eder. $w(t - \tau)$ pencere fonksiyonudur. $e^{-j2\pi f\tau}$ Fourier dönüşümünün temel işlemidir. $X(t, f)$ sinyalin t zamanında f frekansındaki gücünü temsil eder. Bu işlemler sinyalin tüm zaman dilimleri için tekrarlanır ve bu şekilde zaman-frekans grafiği, yani spektrogram oluşturulmuş olur (H. Jopri ve ark., 2018).

$$X(t, f) = \left| \int x(\tau)w(t - \tau)e^{-j2\pi f\tau}d\tau \right|^2 \quad (3.6)$$

3.2.1.2. Veri artırma

Derin öğrenme çoğu durumda iyi bir sınıflandırma performans oranı elde etmek ve eğitim verileri ile test verileri arasında olan hata farkını minimize etmek için geniş

bir eğitim verisi setine ihtiyaç duyar (J. Li ve ark., 2021). Orijinal veri büyüklüğünün sınırlı olduğu durumlarda, sorunu aşmak için veri artırma süreci gereklidir. Veri artırma işlemlerinden biri, eğitim veri setinde bulunan verilere bir dizi deformasyon işlemi uygulayarak ek eğitim veri örneklerinin oluşturulmasıdır (Su ve ark., 2021). Veri artırmanın temel ilkesi, etiketli verilere uygulanan deformasyonlar nedeniyle yeni verilerin etiketlerinin değişmemesidir (Salamon ve Bello, 2017).

Görüntüyü farklı açılarda döndürme işlemi, yataydan dikeye çevirme işlemi, görüntüye gürültü ekleme işlemi ve renk manipülasyonu uygulama işlemleri gibi birçok veri artırma tekniği mevcuttur.

Çizelge 3.2. Veri artırma algoritması

Girdi: *sf* : Spectrogram Dosyası

rr: rastgele döndürme

sh: kırpma,

cs: renk kaydırma, *sv*: kaydırma değeri

gf: Gauss filtresi, *gfv*: Gauss filtre değeri

sp: tuz ve biber, *spv*: tuz ve biber filtre değeri

Algoritma:

```

1:      Giriş parametrelerini başlatın ve atayın (sf, rr, sh, cs, sv, gf, gfv, sp, spv)
2:      sf = klasor_okur ( 'klasoradi/'+dosyaadı ');
3:      for i:= 1 to length (sf) do
4:          data = Spektrogram Dosyasını Oku (sf.Name);
5:          rr = döndür (data);
6:          sh = kırp (data);
7:          cs = renk_kaydırma (data,sv);
8:          gf = gürültü (data, 'gaussian', gfv);
9:          sp = gürültü (data, tuz & biber, spv);
10:         Yeni spektrogram dosyası ( 'döndürülmüş.jpg', rr);
11:         Yeni spektrogram dosyası ( 'kırpılmış.jpg', sh);
12:         Yeni spektrogram dosyası ( 'renk_kaydırma.jpg', cs);
13:         Yeni spektrogram dosyası ( 'gürültü_gaussian.jpg', gf);
14:         Yeni spektrogram dosyası ( 'gürültü_tuz_ve_biber.jpg', sp);
      end for (döngüyü sonlandır)

```

Bu çalışmada, veri artırma işlemi için 5 farklı teknik uygulanmıştır. Bunlar arasında rastgele döndürme, kayma, renk kaydırma, Gaussian filtre ve Tuz & Biber gürültüsü bulunmaktadır. Veri setindeki orijinal örneğin dahil edilmesiyle, veri setimizin boyutu artırılmıştır. Çizelge 3.2’de, veri artırma algoritmasının sözde kodu verilmiştir.

3.2.1.3. Makine öğrenmesi ve derin öğrenme


Bu başlık altında başlığı altında, evrensel bilgi çıkarımı ve karar verme yeteneği sağlamak için kullanılan güçlü ve çok yönlü yapay zekâ yöntemlerini açıklanmıştır.

Yapay Sinir Ağları

Yapay Sinir Ağları (YSA), yapay zekânın önemli bir bileşenidir ve birçok nöronu içeren, insan beyninden esinlenerek tasarlanmış matematiksel bir modeldir (L. Wang ve He, 2010). Bu nöronlar genellikle ağ yapısında kullanılır ve her bir nöron bağlantısı, belirli bir değeri temsil eden ve ağ üzerinden aktarılan sinyalle çarpılan bir ağırlıkla ilişkilidir (Niebur ve Germond, 1991; Q. Yang ve ark., 2017).

YSA, önceden herhangi bir bilgi olmaksızın, giriş ve çıkış verileri arasındaki doğrusal olmayan ilişkileri tanımlayabilme kabiliyetine sahiptir. Eğitim sürecinin ardından, YSA’nın işlem hızı oldukça yüksektir, çünkü bu sistem yalnızca bir dizi basit ve birbirine bağlı işlem birimini içerir.

Bir nöronun çıktısı, genellikle literatürde doğrusal ya da tanjant sigmoid gibi çeşitli şekillerde bulunan bir aktivasyon fonksiyonu ile belirlenir. YSA, model tanıma, genelleştirme ve interpolasyon yeteneklerine sahiptir, böylece eğitilmiş bir ağa bilinmeyen yeni bir girdi verildiğinde, ağın uygun bir çıktı üretme kapasitesi vardır. Bu nedenle, deterministik hata ve sistem modellerine ihtiyaç duymazlar, sadece simüle edilmiş eğitim verileri gereklidir (Niebur ve Germond, 1991)



Şekil 3.12. Yapay sinir ağı

$$y(t+1) = a \left(\sum_{j=1}^n w_{ij} x_j(t) - \theta_i \right) \quad (3.7)$$


$$f_i \Delta net_i = \sum_{j=1}^n w_{ij} x_j - \theta_i$$

Denklem 3.7’de x nöronun n giriş parametresini; w_i ve x_j , her giriş için ağırlıkları; θ_i bias değerini ve $a(i)$ ise aktivasyon fonksiyonunu ifade eder.

Şekil 3.12’de yapısal formu gösterilen YSA modeli; lineer olmayan sistemlerin modellemesinde kullanılabilmesi nedeniyle veri madenciliği, tıbbi tanı uygulamaları gibi çeşitli alanlarda kullanılmaktadır (G. Yang, 2013).

Şekil 3.13’de gösterilen çok katmanlı yapay sinir ağı, genellikle en az bir giriş katmanı, bir ya da daha fazla gizli katman ve en az bir çıkış katmanı içerir. Bir YSA modelinde, düğümler arasındaki bağlantılar en önemli faktörlerdendir. Ağ topolojisi, her katmandaki belirli sayıda nöronun diğer katmanlardaki nöronlarla bağlanmasıyla oluşturulur.

ÇKA yapay sinir ağı modelinin ileri beslemeli bir türüdür. Standart ÇKA modeli giriş katmanı, gizli katman ve çıktı katmanı olmak üzere üç kategoriden oluşan bir nöron grubunu içerir. Her nöron belirli bir katmanda bulunur ve ayarlanan katmandaki tüm nöronlarla bağlantıları vardır (Hewahi ve Abu Hamra, 2017).



Şekil 3.13. Çok katmanlı ileri beslemeli ağlar

Optimal performansı sağlamak adına, problem durumuna uygun bir sinir ağı modelinin belirlenmesi önemlidir. Uygun bir eğitim algoritmasının yanı sıra, katman sayısı ve her katmandaki birim sayısı da dikkatlice belirlenmelidir. Eğitim algoritması ağda oluşan tahmin hatasını minimize edecek şekilde ağırlık ve bias değerlerini bulmak için kullanılır. N adet örnekle temsil edilen bir eğitim seti için (x_i, y_i) , $x_i \in \mathbb{R}^d$, $y_i \in \mathbb{R}^d$ nin olduğu durumlar, N adet gizli düğüm ve çıktı fonksiyonu şeklinde aşağıda Denklem 3.8 ile ifade edilmiştir.

$$ay_i = \sum_{i=1}^M \beta_i g(\omega_i x_j + b_i) \quad 1 \leq j \leq N \quad (3.8)$$

Destek Vektör Makineleri

Destek Vektör Makineleri, sınıflandırma ve regresyon analizlerinde kullanılan etkin bir makine öğrenme yöntemidir, lineer ve çekirdek fonksiyonlarının kullanımını içermektedir. Şekil 3.14'te, DVM'nin çeşitli çekirdek fonksiyonlarına (linear, poly, rbf, sigmoid) dayalı performansı gösterilmektedir. Algoritmanın çekirdeği, veri gruplarının arasında optimal bir ayırım sınırlaması çizer, bu sınırın konumlandırılması, ilgili veri gruplarındaki üyelerden maksimum uzaklıkta olacak şekilde gerçekleştirilir.


Özü itibariyle DVM, bu sınırlamanın en optimal şekilde nasıl çizileceğini belirleyen bir modelleme teknolojisidir (Alpaydin, 2021).

$$L(x) = \text{sign}((\sum[y_i * \alpha_i * K(x_i, x)] + b))$$

$$K(X_i, X_j) = \left\{ \begin{array}{ll} X_i, X_j & \text{Lineer} \\ (\gamma X_i \cdot X_j + C)^d & \text{Polinomal} \\ \exp(-\gamma |X_i - X_j|^2) & \text{Radyal Fonksiyon} \\ \tanh(\gamma X_i \cdot X_j + C) & \text{Sigmoid} \end{array} \right\} \quad (3.9)$$

Denklem 3.9.'da DVM' nin temel formülü verilmiştir. Bu formülde:

$L(x)$ tahmini sınıfı belirtir (1 veya -1). $\text{sign}()$ işareti işlevi, pozitif sayılar için 1, negatif sayılar için -1 döndürür. y_i gerçek sınıfı belirtir ve α_i Lagrange çarpanlarıdır. $K(x)$ bir çekirdek fonksiyonudur (örneğin, doğrusal, RBF, sigmoid, vs.). X_i örnek veri noktalarıdır ve x test veri noktasıdır, b ise bias değeridir (C. Wang ve ark., 2019). Önemli olan nokta, α_i değerlerinin, DVM'nin eğitim aşamasında öğrenilmiş olan ve sadece destek vektörlerine karşılık gelen $y_i * x_i$ çiftleri için sıfırdan farklı olmasıdır. Diğer bir deyişle, sadece veri setindeki birkaç nokta (destek vektörleri), sınıflandırma kararını belirler. Bu, DVM'nin 'destek vektör' adını nereden aldığını açıklar.




Şekil 3.14. DVM çekirdek fonksiyonlarının veri setleri arasında karşılaştırılması

İlk veri seti, birbirine dokunmayan iki yarı daire şeklinde verilerden oluşmaktadır. Bu noktada, lineer çekirdekli DVM'nin karmaşık yapıyı tam anlamıyla modelleyemediği görülürken, diğer çekirdeklerin (poly, rbf, sigmoid) bu eğri veri yapısını etkili bir şekilde modelleyebildiği görülmektedir. En yüksek performansı sergileyen çekirdek ise rbf olmuştur. İkinci veri seti, iç içe iki halka şeklinde verilerden oluşmaktadır. Yine lineer çekirdek bu veri yapısını modellemekte yetersiz kalırken, poly, rbf ve sigmoid çekirdekler verileri başarılı bir şekilde ayırmıştır. Rbf çekirdeği, bu dairesel yapıdaki veri setinde de en iyi performansı sergileyen çekirdek olmuştur. Üçüncü veri seti ise, iki grup halinde doğrusal olarak ayrılabilir verilerden oluşmaktadır. Bu durumda, tüm çekirdekler, veri setini başarıyla modellemiştir. Ancak, en basit ve en doğrudan çözümü lineer çekirdek sağlamıştır. Bu bağlamda

grafiğin geneline bakıldığı zaman farklı çekirdek fonksiyonlarının veri setinin yapısına ve özelliklerine bağlı olarak farklı performanslar sergileyebileceği görülmektedir. Bu durum, model oluştururken çekirdek seçiminin, algoritmanın genel performansı üzerinde önemli bir etkiye sahip olduğunu göstermektedir.

K- En Yakın Komşu

K-en yakın komşu (K-EYK) algoritmaları, büyük ölçekli bir veri kümesi içerisinde bir sorgu örneği ile en yüksek benzerliği gösteren veri alt kümesinin belirlenmesini hedefler. Bu algoritmalar, boyut indirgeme, model sınıflandırma ve görüntü alımı gibi çok çeşitli uygulamaların temelini oluşturmaktadır (Jegou ve ark., 2011; Zhang ve ark., 2017). Şekil 3.15.'te belirtildiği üzere, bu algoritmayı kullanarak bir veri noktasını sınıflandırmak için, sorgu noktasına en yakın olan k eğitim noktası belirlenir. Sınıflandırma, komşuların oyları ile belirlenir ve belirlenecek sınıf, en yakın komşular içerisinde en yakın olan sınıfa atanır.



Şekil 3.15. K- en yakın komşu algoritması ile sınıflandırma

K-EYK algoritması, denetimli öğrenme algoritması sınıfında yer almaktadır. Algoritma uygulaması, belirli bir boyutta özellik vektörünün eğitim seti olarak tanımlanması ve gözlemlenen sınıf etiketleri ile ilişkilendirilmesi ile başlar (C. Li ve ark., 2012). Bu algoritma ile bir öznitelik vektörünün bir ya da daha fazla en yakın k komşulukta bulunan vektör elemanlarına dayalı sınıflandırma işlemi gerçekleştirilir.

Karar Ağacı (KA)

Karar ağaçları, çok çeşitli sınıflandırma ve regresyon problemleri için kullanılabilen gözetimli bir öğrenme algoritmasıdır (Friedl ve Brodley, 1997) . Temelde karar ağaçları, özniteliklere dayalı bir dizi karar kuralına bağlı olarak, öğrenme problemini daha basit alt-problemlere böler. Bu, hiyerarşik bir ağaç yapısı biçiminde modellenir ve burada her iç düğüm bir öznitelik kararına, her dal kararın bir sonucuna ve her yaprak düğümü bir tahmine karşılık gelmektedir (Fayyad ve Irani, 1992).

Karar ağacı algoritmaları, karmaşık veri kümelerini anlaşılır ve yorumlanabilir bir şekilde modellemeye yardımcı olur. Her karar düğümü, belirli bir özelliğin değerini basit bir mantıksal deneme ile test eder. Bu özellik, modelin çıktılarını anlaşılır koşullu ifadelerle sunar. Bu nedenle karar ağacı algoritmaları, modelin sonuçlarının net bir şekilde anlaşılması ve yorumlanması gereken tıbbi tanımlar ve kredi puanlama gibi durumlarda sıklıkla kullanılmaktadır (Friedl ve Brodley, 1997).

Ek olarak karar ağaçları veri özniteliklerinin önemini belirleme yeteneğine sahiptir. Bir öznitelik ne kadar çok sayıda karar düğümünde kullanılırsa ve bu düğümler ne kadar yüksek seviyede olursa, o öznitelik genel tahminin belirlenmesinde o kadar önemli hale gelmektedir (Quinlan, 1986).

Karar ağacı algoritmalarından bazıları;

ID3: Bu algoritma, ‘bilgi kazancı’ kriterine dayanarak karar ağacını büyütür. Her düğümde, her özellik için bilgi kazancı hesaplanır ve en yüksek bilgi kazancına sahip olan özellik seçilir (Jin ve ark., 2009).

C4.5: ID3’ün geliştirilmiş bir sürümüdür. Bu algoritma, ‘kazanç oranı’ adı verilen bir kriter kullanır. Bu kriter bilgi kazancının özniteliklerin potansiyel olarak yüksek değer sayısından kaynaklanan önyargısını azaltmaya yardımcı olur. Bu bir öznitelik değerlerini bölme işlemine dayanır ve böylece daha dengeli bir ağaç yapısı oluşturmaya yardımcı olur (Sahoo ve ark., 2020).

CART (Sınıflandırma ve Regresyon Ağacı): Bu algoritma hem sınıflandırma hem de regresyon problemleri için kullanılabilir. CART, ‘Gini Saflık Ölçütü’ ya da ‘Bilgi Kazancı’ gibi bir dizi farklı ölçüt kullanabilir ve genellikle ikili ağaçlar oluşturmaktadır (Cleophas ve Zwinderman, 2021; Matthews, 2014).

CHAID (Chi- Kare Otomatik Etkileşim Tespiti): Bu algoritma, Chi-kare testini kullanarak özellik seçimi yapar ve birden fazla çocuğu olan düğümler oluşturabilir (Atieh ve ark., 2018).

M5: Bu algoritma, regresyon ağaçları oluşturmak için kullanılır. Her düğümde, özellikler arasındaki ilişkiyi temsil etmek için bir regresyon modeli oluşturulur (Marfo ve ark., 2021).

Koşullu Çıkarım Ağaçları: Bu algoritma, ağaç yapısını belirlemek için istatistiksel testler kullanır ve bu da biasın azaltılmasına yardımcı olur (Levshina, 2020).


Rastgele Ormanlar

RO metodolojisi, hem sınıflandırma hem de tahmin etme amacıyla kullanılan parametrik olmayan bir gözetimli yöntemdir (Breiman, 2001). Söz konusu yöntem, Şekil 3.16.’da gösterildiği gibi çoklu karar ağaçlarının bir kombinasyonunu temel alır ve her ağaç, girdi verilerine en sık rastlanan sınıfı atama konusunda bağımsız bir oy kullanır (Costache ve ark., 2020). Dolayısıyla ağaçların çoğunluk oyu, sınıf tahminini belirler.

RO modellerinde, modelin çeşitlilik ve gücünü artırmak için, orijinal eğitim veri setinden farklı alt gruplar seçilir ve bu alt gruplar üzerinde ayrı ayrı karar ağaçları oluşturulur (Breiman, 1996). Bu yaklaşımın sonucunda, daha yüksek bir sınıflandırıcı stabilitesi elde edilir. Bir ağaç için eğitimde kullanılmayan veri alt kümeleri ‘out-of-bag’ olarak adlandırılır (Breiman, 2001). Bu alt kümeler, performansı ve doğruluğu değerlendirmek ve genelleştirme hatasının önyargısız bir tahminini hesaplamak için kullanılır.

Modeldeki ağaç sayısının artırılması, genelleştirme hatasının yakınsamasına ve RO ile verilerin aşırı uyumunun önlenmesine yol açar. RO modeli oluşturmak için, sınıflar arası ölçütlerin çeşitliliğini maksimize etmek amacıyla uygun bir özellik seçim ölçütüne ihtiyaç vardır. Her düğümdeki özellikleri seçme konusunda en sık kullanılan yöntemler arasında kazanç oranı, Gini İndeksi ve Chi-Kare bulunur (Mohajane ve ark., 2021).

Ağaçlar oluşturulurken her düğüm, özelliklerin rastgele seçilmiş bir alt kümesini kullanır. Bu yaklaşım, her ağacın performansını azaltabilirken ağaçlar arasındaki benzerliği düşürür. Sonuç olarak, bu durum modelin genelleme kabiliyetini artırır ve toplam hatayı düşürür (Breiman, 2001).




Şekil 3.16. Rastgele orman

Ek olarak RO, büyük veri kümelerinde etkin bir şekilde çalışabilme yeteneğine sahiptir. Kapsamlı miktarda girdi özelliğini işleyebilir, modelleme için kullanılan özelliklerin önemine dair tahminlerde bulunabilir, eksik verileri doldurabilir ve durum çiftleri arasındaki yakınlıkları hesaplayarak aykırı değerleri tespit edebilir. Ayrıca RO, aykırı değerlere ve gürültüye karşı oldukça dayanıklıdır (Rodriguez-Galiano ve ark., 2012).

Kanonik Korelasyon Analizi

Kanonik Korelasyon Analizi (KKA), istatistik ve çok değişkenli veri analizinde kullanılan bir tekniktir (Miao ve ark., 2022). KKA, iki çok boyutlu değişken set arasındaki genel korelasyonu belirlemek için kullanılan bir istatistiksel analiz metodudur (Somers ve Bertrand, 2016).




Şekil 3.17. EOG sinyal analizinde KKA kullanımı

KKA'nın temel amacı, iki değişken set arasında lineer bir ilişki bulmaktır. Bu ilişki, değişken setler arasındaki korelasyonları maksimize eden bir dizi katsayı ile belirlenmektedir (Bin ve ark., 2009). KKA, bu katsayıları belirlemek için genellikle bir optimizasyon problemi çözmektedir. Şekil 3.17.'de KKA'nın EOG sinyal analizinde kullanımına ilişkin bir örnek verilmiştir. X, göz kası hareketinin izlenimi ile elde edilen EOG sinyalleridir. Y_f , X ile aynı uzunluğa sahip olan referans sinyalleri kümesine karşılık gelmektedir. P_k ise $f_1, f_2, \dots, f_k$ olan referans sinyallerinin frekansı ile elde edilen KKA katsayılarıdır.

Derin Öğrenme

Derin öğrenme, çok katmanlı hesaplama modelleri aracılığıyla verinin çok seviyeli soyutlamalarını öğrenmeye olanak sağlayan gelişmiş bir yapay zeka formudur (LeCun ve ark., 2015). Derin öğrenme, verinin yüksek boyutlu yapısını keşfetme konusunda son derece etkili olmuştur. Bu yöntem, genellikle geniş veri setlerindeki karmaşık yapıları keşfetmek için geri yayılım algoritmasını kullanır (Ma ve ark., 2015).

Son yıllarda derin öğrenme, büyük veri kümelerinin analizinde, otomatik sürüşte, tıbbi görüntü analizinde, otomatik dil çevirisinde ve benzeri uygulama alanlarında önemli atılımlar yapmıştır (LeCun ve ark., 2015). Aynı zamanda, derin öğrenme, makine öğrenmesinin başarısız olduğu yerlerde çözümler üretmek için de genellikle uygulanır. Derin öğrenme, doğal veriyi ham haliyle işleme yeteneği ve otomatik özellik çıkarımı ile klasik makine öğrenme tekniklerini aşarak, çoklu alanlarda başarılı uygulamalara yol açmıştır (Ciodaro ve ark., 2012). Ayrıca, çok boyutlu veri yapılarını anlama ve bu bilgiyi geniş bir uygulama yelpazesinde kullanma yeteneği ile yapay zeka alanında önemli bir dönüm noktası olmuştur (LeCun ve ark., 2015). Çalışmada önerilen yöntem Şekil 3.18.'de gösterilmiştir.



Şekil 3.18. EEG sinyalleri ile duygu analizi için önerilen yöntem

Bu çalışmada derin öğrenmeye dayalı kullanılan bazı derin öğrenme modelleri ve algoritmaları, ‘biyomedikal görüntülerin analizi ve kullanılan algoritmalar’ başlığı altında ayrıntılı olarak incelenmiştir.

3.2.2. Biyomedikal görüntülerin analizi ve kullanılan algoritmalar

Biyomedikal görüntülerin analizi hem tıbbi teşhis hem de tedavi seçeneklerinin belirlenmesi için hayati bir öneme sahiptir. Bu bölümde, COVID-19 Radyografi veri setinde yer alan röntgen görüntülerinin iyileştirilmesi ve sınıflandırılması için kullanılan algoritmalar ile derin öğrenme teknikleri ele alınacaktır. Göğüs röntgen görüntülerinin kalitesinin artırılması ve denetimli modellerin doğruluk oranlarının yükseltilmesi hayati bir öneme sahiptir (Ghosh ve Ghosh, 2022; Siracusano ve ark., 2020).

Bu tez çalışmasında göğüs röntgen görüntülerindeki hastalıkların daha yüksek doğruluk oranıyla sınıflandırılmasını sağlamak amacıyla çok hedefli arama stratejisi olan ÇAGKAA (X.-S. Yang ve Deb, 2013) temelli KSAHE (Pizer ve ark., 1987) ile birlikte KSA kullanılmıştır.

3.2.2.1. Çok amaçlı guguk kuşu arama algoritması

ÇAGKAA, guguk kuşlarının hareketlerinden ve klasik guguk arama (CS) algoritması (X.-S. Yang ve Deb, 2009) etkisi altında oluşturulan çok amaçlı metaheuristik bir optimizasyon yöntemidir. Çözümlere ait pozisyonlar, gugukların yumurtaları olarak temsil edilir ve CS gibi, ÇAGKAA gugukların pozisyonlarını belirlemek için Lévy uçuşlarını kullanır. Gugukların uygunluk skorları, önceden belirlenmiş bir uygunluk fonksiyonu (yani hedef fonksiyon) kullanılarak değerlendirilir. Bu fonksiyon, problem tipine göre seçilir. Çok amaçlı bir algoritma olan ÇAGKAA için, birden çok uygunluk fonksiyonu belirlenebilir. Bu sayede, birden çok çözüm elde edilir ve bu çözümler bir Pareto frontunda yer alır. Pareto frontu, birbirini domine etmeyen bir dizi çözümden oluşur. Yani, bu durumu daha somut bir şekilde ifade edersek, eğer iki çözüm vektörümüz v ve t varsa ve bu çözüm vektörleri farklı hedeflerin değerlerini temsil ediyorsa, v 'nin Pareto-optimal olması için, t 'nin hiçbir hedefi (veya bileşeni), v 'nin karşılık gelen hedefinden (veya bileşeninden) daha iyi olmamalıdır. Ayrıca, v 'nin en az bir hedefi (veya bileşeni), t 'nin karşılık gelen hedefinden (veya bileşeninden) daha iyi olmalıdır. Bu nedenle, bir optimizasyon probleminin Pareto frontu Denklem 3.10'da olduğu gibi verilebilir, burada s çözüm ve S çözüm setidir. CS algoritmasının çok amaçlı versiyonunda, her guguk K yerine bir yumurta bırakır.

$$PF = \{s \in S \mid \exists s' \in S: s' < s\} \quad 3.10$$

Guguklar parazitik bir şekilde davranır. Bu yüzden, bir istilacı guguk, kendi yumurtasını başka bir kuşun yuvasına bırakır, çünkü algoritma yavru parazitizmini taklit eder. Ev sahibi guguk kuşu, bir istilacı gugukun yumurtalarının farkına varabilir ve bu olasılık 'pa' ile belirlenir. Eğer ev sahibi guguk farkına varırsa yumurtayı

yuvaadan atabilir veya tamamen yeni bir yuva oluşturmak için bir Lévy uçuşu gerçekleştirebilir.

$$L(s, \gamma, \mu) = \begin{cases} \sqrt{\frac{\gamma}{2\pi}} \exp\left[-\frac{\gamma}{2(s-\mu)}\right] \frac{1}{(s-\mu)^{3/2}} & \text{if } 0 < \mu < s < \infty, \\ 0 & \text{if } s \leq 0 \end{cases} \quad (3.11)$$


Basit bir Lévy dağılımı formülü Denklem 3.11' de verilmiştir. Denklemde, μ minimum adım parametresidir, γ ölçek parametresidir. $s \rightarrow \infty$ olduğunda, Denklem 3.12 elde edilir.

$$L(s, \gamma, \mu) = \sqrt{\frac{\gamma}{2\pi}} \frac{1}{s^{3/2}} \quad (3.12)$$

Lévy uçuşunu kullanan kuşlar, Denklem 3.13 ile pozisyonlarını günceller.

$$x_i^{(t+1)} = x_i^{(t)} + \alpha \oplus L(\lambda) \quad (3.13)$$

Denklem 3.13'te, $x_i^{(t+1)}$ bir sonraki yineleme için çözümdür, $x_i^{(t)}$ mevcut yinelemedeki çözümdür, α 0'dan büyük olması gereken bir ölçekleme faktörüdür, $\oplus$ sembolü eleman düzeyinde çarpma operatörünü temsil eder. $L(\lambda)$ ise, $1 < \lambda < 3$ olacak şekilde λ 'nın Lévy dağılımını temsil eder. Lévy dağılımı, bir rassal (veya stochastic) sürecin bir türünü ifade eder ve ÇAGKAA algoritmasında, çözümün yeni pozisyonunun belirlenmesinde kullanılır. ÇAGKAA'nın akış diyagramı Şekil 3.19.'da gösterilmiştir. Denklemler (3.10)-(3.13) için, (X.-S. Yang ve Deb, 2013)'ye bakılabilir.



Şekil 3.19. ÇAGKAA akış diyagramı

3.2.2.2. Çok amaçlı guguk arama ile kontrast artışı

Kontrast Sınırlı Uyarlamalı Histogram Eşitleme (Pizer ve ark., 1987), genel histogram eşitleme (Gonzalez ve ark., 2009) uygulamak yerine, görüntüleri ayrı bağlamsal bölgelere bölen ve bu bölgeleri bağımsız olarak eşitleyen, Adaptif Histogram Eşitleme (AHE)'nin sınırlamalarının üstesinden gelmek için tasarlanmış yerel bir kontrast iyileştirme tekniğidir. KSAHE, Klip Limiti (KL) ve Blok Boyutu (BB) olmak üzere iki parametreye izin verir. KL, her bağlamsal bölgenin histogramını önceden belirlenmiş bir limite kadar kırpma işlemi gerçekleştirir, bu şekilde KSAHE istenmeyen gürültünün ve aşırı iyileştirmenin önüne geçer. Ayrıca, BB parametresi, M ve N olmak üzere iki alt parametre içerir. Burada M, x-eksenindeki bağlamsal bölgelerin sayısıdır ve N, y-eksenindeki bağlamsal bölgelerin sayısıdır. Her bağlamsal bölgenin iyileştirilmesinden sonra, bağımsız olarak eşitlenen bu bölgeler, sınırlarındaki tutarsızlıkları gidermek amacıyla çift doğrusal interpolasyon kullanılarak birleştirilir.

Görsel kaliteyi artırmak amacıyla KSAHE parametrelerini optimize etmek için ÇAGKAA seçilmiştir. Bu amaçla uygunluk fonksiyonları olarak iki kalite metriği kullanılmıştır. Çıktı görüntüleri, her iterasyonda KSAHE parametrelerini ÇAGKAA kullanarak optimize eder ve çıktılar bu iki metrikle değerlendirilir. Kullanılan ilk uygunluk fonksiyonu, bir görüntüdeki detay seviyesini belirten Ayırık Entropi (AE)'dir (Patel ve ark., 2013). Ayırık entropi, bir görüntüdeki detay seviyesini gösterir. Daha fazla detaya sahip olan görüntülerin AE değerleri daha yüksektir. Görüntüdeki detay seviyesi, derin ağların özellikleri çıkarmak için önemli olduğundan, AE, çıktı görüntülerini değerlendirmek için uygun fonksiyonlardan biridir. AE, Denklem 3.14'da verildiği gibi ifade edilmektedir.

$$AE = - \sum_{i=1}^n P(x_i) \log_2 P(x_i) \quad (3.14)$$

Denklem 3.14'da, $P(x_i)$ görüntünün i gri seviyesinin Olasılık Yoğunluk Fonksiyonunu (OYF) ve n gri seviyelerinin sayısını temsil eder. Sonuç

görüntülerindeki gürültüyü önlemek için hızlı bir Gürültü Varyans Tahmini (GVT) yöntemi kullanılır, çünkü sonuçtaki gürültü, derin ağ modeli için yanlış pozitif ve yanlış negatif kararlarına neden olabilir (Immerkær, 1996). GVT'nin ayrı versiyonu Denklem 3.15'te verilmiştir.

$$\sigma_n = \sqrt{\frac{\pi}{2}} \frac{1}{6(W-2)(H-2)} \sum_I |I(x,y) * N| \quad (3.15)$$

Denklem 3.15'te, I görüntüyü, W görüntünün genişliğini, H görüntünün yüksekliğini, N gürültü tahmin operatörünü, x ve y sırasıyla x-eksenindeki ve y-eksenindeki mekansal koordinatları temsil eder. Görülebileceği gibi, görüntü I, gürültü tahmini operatörü N ile evrişimlidir ve sonuçlanan evrişimli görüntüdeki tüm piksellerin toplamı hesaplanır. Kenarlar gürültü tahminine, duyarsız olmalıdır, bu nedenle, bir görüntünün Laplacian'ının yaklaştığı iki maske farkı alınarak gürültü tahmini operatörü N sağlanır. Bu, Denklem 3.18 ile belirlenir. N'nin hesaplanması için L1 ve L2 kullanılır, bunlar sırasıyla Denklem 3.16 ve Denklem 3.17'te verilmiştir.

$$L_1 = \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix} \quad (3.16)$$

$$L_2 = \frac{1}{2} \begin{bmatrix} 1 & 0 & 1 \\ 0 & -4 & 0 \\ 1 & 0 & 1 \end{bmatrix} \quad (3.17)$$


$$\sigma_n = \sqrt{\frac{\pi}{2}} \frac{1}{6(W-2)(H-2)} \sum_I |I(x,y) * N| \quad (3.18)$$

ÇAGKAA-KSAHE'nin AE'yi maksimize ettiği ve gürültüyü minimize ettiği göz önüne alındığında, AE'yi kullanan uygunluk fonksiyonu, Denklem 3.19'da olduğu gibi verilebilir. Gürültünün minimize edilmesi için, ikinci uygunluk fonksiyonu olarak GVT'nin çarpımsal tersini hesaplamının yeterli olduğu, Denklem 3.20'de verilmiştir. Denklemler 3.14.-3.18. için, Immerkær'ın yapmış olduğu çalışmaya başvurulabilir

(Immerkær, 1996). Örnek X-ışını görüntüleri ve bunların geliştirilmiş sürümleri Şekil 3.20.'de verilmiştir. Bu çalışmada önerilen yöntemin gösterimi,

Şekil 3.21.'de verilmiştir.


Şekil 3.21.'de üst sırada normal röntgen görüntüleri verilmiştir alt sırada ise bunların ÇAGKAA-KSAHE kullanılarak geliştirilmiş versiyonları sunulmuştur.



Şekil 3.20. Örnek göğüs röntgen görüntüleri

$$f_1 = AE \quad (3.19)$$

$$f_2 = 1 / GVT \quad (3.20)$$



Şekil 3.21. X-ray görüntüleri ile hastalık tespiti için önerilen yöntemin gösterimi

3.2.2.3. Evrişimli sinir ağları

Evrişimli sinir ağları, ileri beslemeli ve çok katmanlı bir sinir ağı mimarisine sahip olup, görsel obje algılama ve görüntü analizi gibi görevlerde yoğun bir şekilde kullanılmaktadır. KSA'ların çalışma prensibi, insan beyninin içerisinde bulunan bir dizi nöronun birbiriyle etkileşimini taklit eder. Bu nöronların bağlantı desenleri, görsel korteks'teki organizasyon yapısına oldukça benzer bir yapı gösterir (Fu ve Aldrich, 2019). KSA'lar, görüntü tanıma ve sınıflandırma sorunlarında yüksek performans gösteren etkin sinir ağı mimarileri olarak kabul edilmiştir. KSA'ların temel yapısı, genellikle evrişim, havuzlama ve tam bağlı katmanlardan oluşan matematiksel bileşenlerden meydana gelir. Bu bileşenler, KSA'ların karmaşık görsel bilgiyi işlemesini ve etkili bir şekilde çözümlemesini sağlar (Gülcü ve Kuş, 2019).

Evrişim ve havuzlama katmanları özellik çıkarmaktan, tam bağlı katmanlar çıkarılan özellikleri son çıktıya sınıflandırma için göndermekten sorumludur. Evrişimler, sinir ağının bir görüntüdeki sayısal piksel değerlerini yorumlaması için gereklidir. Bu yüzden, evrişimli katmanın amacı, orijinal görüntüyü sayısal değerlere dönüştürmektir, böylece sinir ağı görüntüyü doğru bir şekilde yorumlayabilir ve desenleri doğru bir şekilde çıkarabilir (Masci ve ark., 2012). Evrişim katmanında, filtreler giriş görüntüsü üzerinden geçer. Önceden eğitilmiş mimariler, çoğunlukla evrişim katmanları ve tamamen bağlı katmanlardan oluşur. Evrişim katmanında belirli bir yükseklik ve genişliğe sahip filtreler, giriş görüntüsü üzerinde ayarlanan kaydırma adımları ile soldan sağa doğru dolaşır. Evrişim işlemi için gerekli formül Denklem 3.21'de verilmiştir. Bu denklemde M özellik haritasını temsil ederken, w evrişim çekirdeğini ifade eder. I orijinal görüntüyü belirtir ve m ile n , I görüntüsü için mekansal koordinatlara ve i ve j çekirdek için kullanılan koordinatlara karşılık gelir.

$$M(I,i,j)=(I*w)(I,i,j)=\sum_m \sum_n I(m,n)w(I-m,j-n) \quad (3.21)$$

Evrişimli katmanda gerçekleştirilen işlemlerin ardından, bir KSA'da genellikle doğrusal olmayan bir katman veya aktivasyon katmanı kullanılır. Aktivasyon için


Düzeltici Doğrusal Birimler (ReLU) kullanılır. Bu işlem, her evrişim katmanından sonra uygulanır. Evrişim sonunda, giriş verilerinde oluşan negatif değerler sıfıra çekilir. ReLU'nun kullanım amacı, derin ağı doğrusal olmayan bir yapıya getirmektir. Ayrıca bu katmanın ana amacı, lineer hesaplamalar yapan bir sistemi, lineer olmayan bir hale getirmektir. RELU, kendisine verilen tüm giriş değerlerini Denklem 3.22'de bulunan fonksiyonunu kullanarak hesaplar. Esasen, bu katmanda, tüm negatif giriş değerleri 0 ile değiştirilir. Sonuç olarak, bu katman ağı ve modelin doğrusal olmayan özelliklerini artırırken, evrişim katmanından çıkarılan özellikler bozulmaz. RELU formülü Denklem 3.22'de verilmiştir.

$$\text{ReLU}(x) = \max(x, 0) \quad (3.22)$$

Evrişimli ve RELU katmanlardan alt örneklendirilmiş özellikler oluşturma işlemi sona erdiğinde, elde edilen özellikler tam bağlı katmana verilir. Burada her giriş bir çıktıya bağlanır ayrıca her nöronun öğrenilebilir bir ağırlık değeri vardır (ER, 2020). Son tam bağlı katman genellikle aynı sayıda çıktı düğümüne ve sınıfa sahiptir. Bu son katmanda sınıflandırma işlemi yapılır. Bu son katman içerisinde farklı sınıflandırıcılar kullanmak mümkün olsa da çoğu zaman Softmax tercih edilen sınıflandırıcı olmuştur. Softmax formülü Denklem 3.23'te verilmiştir, burada e, üstel fonksiyonu, x_i ve x_k giriş vektörünün elemanlarını temsil eder. Softmax aktivasyon fonksiyonu, nöronların çıktı değerlerini 0 ile 1 aralığında düzenler.

$$\text{Softmax}(x_i) = \frac{e^{x_i}}{\sum_{k=1}^N e^{x_k}} \quad (3.23)$$

Ayrıca CNN'de, her evrişim ve ReLU işleminin ardından havuzlama işlemi uygulanır. Havuzlama, bir sonraki evrişim katmanına gönderilecek giriş görüntüsünün genişlik ve yükseklik açısından boyutunu azaltma işlemidir (Ghosh ve Ghosh, 2022). Havuzlamanın ana hedefi, parametre sayısını azaltmak ve genel hesaplama maliyetini düşürmektir. Havuzlama katmanı, her özellik haritasından bağımsız çalışır. Tüm havuzlama yöntemleri arasında, en yaygın olanı genellikle maksimum havuzlamadır (Masci ve ark., 2012). Bir maksimum havuzlama örneği Şekil 3.22.'de gösterilmiştir.



Şekil 3.22. Maksimum havuzlama işleminin gösterimi


3.2.2.3.1. Transfer öğrenme

Derin sinir ağları, görüntü tanıma problemleri için oldukça verimli çözümler üretir (Shahnaz ve ark., 2016). Ancak derin sinir ağlarını tasarlamak ve etkili bir şekilde eğitmek için büyük miktarda veri ve yüksek düzeyde hesaplama kaynağı gereklidir. Bu sorunu çözmek için sunulan yaklaşımlardan biri transfer öğrenmedir. Transfer öğrenme işlemi, bir problem türüne ait eğitim sırasında kazanılan bilginin, diğer problem türlerini eğitmek için kullanıldığı bir makine öğrenme tekniğidir. Yeterli etiketli veri olmadığı durumlarda, derin sinir ağı eğitiminde transfer öğrenme çok etkili bir yöntemdir. Daha önce tanımlanmış ağıdaki parametreleri başlangıç değerleri olarak kullanmak ve büyük görüntülerden öğrenilen özellikleri kullanmak, sınıflandırma başarısını artırmada etkilidir (S. Lu ve ark., 2019). Kendi veri setlerimizi bu önceden eğitilmiş mimarilerle sınıflandırmak istediğimizde, transfer öğrenme farklı modellerde uygulanabilir. Daha önce eğitilmiş ağların sonundaki bağlantıları değiştirebilir ve bu ağları kendi veri setimizle yeniden eğitebiliriz veya bu önceden eğitilmiş derin ağları özellik çıkarıcı olarak kullanabiliriz.

3.2.2.3.2. AlexNet ve VGG16

AlexNet, 2012 yılında ImageNet geniş ölçekli görsel tanıma yarışmasında en yüksek başarı elde eden evrişimli sinir ağı olarak bilinmektedir (Krizhevsky ve ark.,

2017). Bu mimari model, 1.2 milyon görüntüden oluşan ve 1000 yaygın objeyi içeren ImageNet veritabanı üzerinde daha önce eğitilmiş ve 1000 görüntüyü ayırabilen bir ağ yapısına sahiptir (Russakovsky ve ark., 2015). Mevcut çıktı katmanının yerine, ele alınan sınıflandırma problemleri ile ilgili uygun bir katman koyarak bu ağı özellik çıkarıcı olarak kullanmak mümkündür. AlexNet mimarisi temel olarak 5 evrişimli katman ve 3 tam bağlı katmandan oluşur. Örnek AlexNet mimarisi Şekil 3.23.(a)'da gösterilmiştir. Önceden eğitilmiş VGG16 derin ağ mimarisi, Simonyan ve Zisserman tarafından ILSVRC 2014 yarışmasında geliştirilmiştir. Temel olarak 13 evrişimden oluşan 3 tamamen bağlı katman içeren bir derin ağıdır. Maxpool, Tamamen bağlı katman, ReLU katmanı, Dropout katmanı ve Softmax katmanı ile birlikte toplamda 41 katman bulunmaktadır. Giriş katmanındaki görüntü 224x224x3 boyutlarındadır. Son katman sınıflandırma katmanıdır. AlexNet'te olduğu gibi, boyutunu azaltmak için bazı evrişim katmanlarını takiben Max-havuzlama uygulanır (J. Kim ve ark., 2016). Tipik Vgg16 mimarisi Şekil 3.23.(b)'de verilmiştir.



Şekil 3.23. Önceden eğitilmiş ağların gösterimi; (a) AlexNet, (b) Vgg16

4. ARASTIRMA BULGULARI ve TARTISMA

Bu bölüm, araştırmamızın temel bulgularını sunmaktadır. Bu çalışmada, derin öğrenme tabanlı biyomedikal karar destek sistemlerinin oluşturulması için biyomedikal sinyallerin ve biyomedikal görüntülerin analizi olmak üzere iki ana unsura odaklanılmıştır. Her iki bölümde, hem önceden belirlenmiş metodolojilerin uygulanması ve elde edilen sonuçların analiz edilmesi, hem de bulguların geniş bir perspektifte değerlendirilmesi ve tartışılması sunulacaktır. Bu kapsamlı değerlendirme, kullanılan tekniklerin biyomedikal araştırma ve uygulamalarda etkin bir şekilde nasıl kullanılabileceğini ve potansiyel olarak gelecekteki biyomedikal karar destek sistemleri araştırmaları için yol göstermeyi amaçlamaktadır. Yapılan analizler ve tartışmalar, derin öğrenme tabanlı biyomedikal teknolojilere yönelik karar destek sistemlerinde bir bilgi tabanı oluşturmayı ve bu alanda ilerleyen diğer araştırmacılara yardımcı olmayı amaçlamaktadır.


4.1. Biyomedikal Sinyal ve Görüntü Analizlerinin Değerlendirilmesi

Bu alt bölümde, uygulanan metodolojilerin sonuçları incelenmiş ve bulgular ayrıntılı olarak analiz edilmiştir.

4.1.1. Biyomedikal EEG sinyalleri ile insan duygularının tanınması

Bu tez çalışmasının ilgili bölümünde, yeni bir veriyi sınıflandırılmak amacıyla önceden eğitilmiş derin öğrenme modellerinin uygulanmasını içeren transfer öğrenme yaklaşımı kullanılmıştır. Bu bağlamda, AlexNet ve VGG16 modeli incelenmiştir. AlexNet, VGG16 ve önceden eğitilmiş KSA mimarileri, EEG spektrogram görüntülerini 4 farklı kategoride sınıflandırmak için kullanılmıştır (Er ve ark., 2021). Önceden eğitilmiş ağların son üç katmanı, 1000 sınıf için yapılandırılmıştır. Bu üç katmanda, yeni sınıflandırma problemi için ince ayarlama yapılmıştır. Orijinal modelin son üç katmanı dışındaki diğer parametreler korunmuş ve başlangıç değerleri olarak kullanılmıştır. Son üç katman, tamamen bağlı bir katman, bir Softmax katmanı ve bir sınıflandırma çıktı katmanı ile değiştirilmiştir ve katmanlar yeni sınıflandırma

görevine aktarılmıştır. Tamamen bağlı katman, yeni verideki sınıf sayısı ile aynı boyutta ayarlanmıştır. Veriler, Alpha ve Beta gibi farklı frekans bandında ayrı ayrı değerlendirilmiştir. Modelin performansını ölçmek için, verilerin %70'i ilk deneyde eğitim için ve %30'u test için kullanılırken, ikinci deneyde %80'i eğitim için ve %20'si test için kullanılmıştır. Eğitim sürecinin ilerleyişi, Şekil 4.1.'de sunulmuştur.



Şekil 4.1. Eğitim prosesi

Önerilen yöntem, i5 2.71 GHz işlemci, 8GB bellek ve NVIDIA GT 730 4GB GPU donanım yeteneklerine sahip bir bilgisayarda uygulanmıştır. Uygulama için gereken yazılım kodları matlab2018a kullanılarak hazırlanmıştır. AlexNet ağı, 227x3 boyutunda giriş resimleri gerektirirken, VGG16 ağı 224x3 boyutunda giriş resimleri gerektirir. Veri kümesindeki tüm resimler otomatik olarak yeniden boyutlandırılır. Öğrenme hızı, epoch numarası ve minibatch boyutu, KSA performansını doğrudan etkileyen önemli hiper-parametrelerdir. Her iki ağda da minibatch boyutu 64 olarak ayarlanmış, maksimum epoch sayısı 32 ve öğrenme hızı $1e-4$ olarak belirlenmiştir. Ayrıca, ağın performansını ölçmek için 5 katmanlı çapraz doğrulama uygulanmıştır. Çizelge 4.1.'de, EEG verisinin alfa frekans bandındaki spektrogram görüntüleri ile AlexNet kullanılarak elde edilen sınıflandırma sonuçları verilmiştir. Veri kümesi sırasıyla %70 ve %30 eğitim ve test için ayarlandığında, en iyi sınıflandırma sonucu

mutlu sınıfından %69.13 olarak elde edilmiştir. Veri kümesi eğitim ve test için sırasıyla %80 ve %20 olarak ayarlanmış ve önceki işlem adımları aynı şekilde uygulanmıştır. Bu işlem sonucunda, en iyi sınıflandırma sonucu yine mutlu sınıfından %70.25 olarak elde edilmiştir. Veri kümesi %80 eğitim ve %20 test verisi olarak ayarlandığında daha yüksek bir başarı oranı gözlemlenmiştir.

Çizelge 4.1. Alfa bandı veri kümesinde AlexNet için sınıflandırma sonuçları

Model	Frekans Bandı	Eğitim-Test	Sınıflar	Doğruluk %					
				Kat - 1	Kat - 2	Kat - 3	Kat - 4	Kat - 5	Ort.%
AlexNet	Alpha	70% - 30%	Gergin	63.42	61.74	62.61	66.51	64.22	63.70
			Mutlu	71.24	69.37	70.33	68.15	66.56	69.13
			Rahat	66.12	64.31	68.54	64.14	64.17	65.45
			Üzgün	68.46	67.16	66.29	68.42	69.20	67.90
AlexNet	Alpha	80% - 20%	Gergin	65.73	66.32	64.77	66.83	65.43	65.81
			Mutlu	70.34	69.34	71.42	69.81	70.35	70.25
			Rahat	68.36	64.61	69.39	64.24	65.82	66.48
			Üzgün	70.11	68.10	65.58	69.86	70.27	63.70

Çizelge 4.2’de, EEG verisinin beta frekans bandındaki spektrogram görüntüleri ile AlexNet kullanılarak elde edilen sınıflandırma sonuçları verilmiştir. Veri kümesi sırasıyla %70 ve %30 eğitim ve test için ayarlandığında, en iyi sınıflandırma sonucu üzgün sınıfından %71.07 olarak elde edilmiştir. Veri kümesi eğitim ve test için sırasıyla %80 ve %20 olarak ayarlandığında, en iyi sınıflandırma sonucu mutlu sınıfından %71.57 olarak elde edilmiştir. Veri kümesi %80 eğitim ve %20 test verisi olarak ayarlandığında, başarı oranının arttığı gözlemlenmiştir. Çizelge 4.1. ile sonuçlar karşılaştırıldığında; beta bandında analiz edilen verilerin, alfa bandında incelenen veriler ile yakın sonuçlar verdiği gözlenirken, beta bandında analiz edilen verinin daha yüksek doğruluk oranı sağladığı görülmüştür.

Çizelge 4.2. Beta bandı veri kümesinde AlexNet için sınıflandırma sonuçları

Model	Frekans Bandı	Eğitim-Test	Sınıflar	Doğruluk %					Ort. %
				Kat - 1	Kat - 2	Kat - 3	Kat - 4	Kat - 5	
AlexNet	Beta	70% - 30%	Gergin	61.22	64.53	63.44	68.63	67.73	65.11
			Mutlu	70.15	69.81	72.31	72.36	70.43	71.01
			Rahat	68.56	66.36	67.76	69.18	68.25	68.02
			Üzgün	71.27	70.48	69.77	72.19	71.66	71.07
AlexNet	Beta	80% - 20%	Gergin	63.64	68.41	69.12	67.43	69.15	67.55
			Mutlu	72.22	70.12	73.12	70.62	71.79	71.57
			Rahat	69.27	69.19	69.47	70.27	70.37	69.71
			Üzgün	73.40	70.14	69.68	71.82	70.23	65.11

Çizelge 4.3.'te, EEG verisinin alfa frekans bandındaki spektrogram görüntüleri ile VGG16 kullanılarak elde edilen sınıflandırma sonuçları verilmiştir. Veri kümesi sırasıyla %70 ve %30 eğitim ve test için ayarlanmıştır. En iyi sınıflandırma sonucu mutlu ve üzgün sınıfından %71.66 olarak elde edilmiştir. Veri kümesi eğitim ve test için sırasıyla %80 ve %20 olarak ayarlanmış ve önceki işlem adımları aynı şekilde uygulanmıştır. Bu işlem sonucunda, en iyi sınıflandırma sonucu mutlu sınıfından %72.29 olarak elde edilmiştir. Veri kümesinin %80 eğitim ve %20 test verisi olarak ayarlanması sonucunda (70% -30% ile karşılaştırıldığında), daha yüksek bir başarı oranı gözlemlenmiştir.

Çizelge 4.3. Alfa bandı veri kümesinde VGG16 için sınıflandırma sonuçları

Model	Frekans Bandı	Eğitim-Test	Sınıflar	Doğruluk %					Ort. %
				Kat - 1	Kat - 2	Kat - 3	Kat - 4	Kat - 5	
VGG16	Alpha	70% - 30%	Gergin	73.23	71.34	70.00	70.00	71.57	71,22
			Mutlu	70.45	71.15	72.77	70.63	73.32	71,66
			Rahat	70.36	70.38	72.62	73.46	71.51	71,66
			Üzgün	73.02	73.03	70.01	70.07	71.00	71,42
VGG16	Alpha	80% - 20%	Gergin	71.61	71.45	72.77	71.68	73.84	72,27
			Mutlu	72.39	71.86	71.88	71.42	73.92	72,29
			Rahat	71.05	73.28	73.74	70.93	71.65	72,13
			Üzgün	71.39	72.52	73.40	73.57	72.34	71,22

Çizelge 4.4.'te, EEG verisinin beta frekans bandındaki spektrogram görüntüleri ile VGG16 kullanılarak elde edilen sınıflandırma sonuçları verilmiştir. Veri kümesi sırasıyla %70 ve %30 eğitim ve test için ayarlandığında, en iyi sınıflandırma sonucu gergin sınıftan %72.01 olarak elde edilmiştir. Veri kümesi eğitim ve test için sırasıyla %80 ve %20 olarak ayarlandığında, en iyi sınıflandırma sonucu gergin sınıftan %73.28 olarak elde edilmiştir. Veri kümesi %80 eğitim ve %20 test verisi olarak ayarlandığında, başarı oranının arttığı gözlemlenmiştir. Çizelge 4.3. ile sonuçlar karşılaştırıldığında, beta bandında analiz edilen verinin, alfa bandında analiz edilen veriden daha yüksek doğruluk oranı sağladığı görülmektedir. Ayrıca EEG verisinin sınıflandırılması için kullanılan derin ağlarda, VGG16'nın AlexNet'e kıyasla daha yüksek bir doğruluk aralığı sağladığı gözlemlenmiştir.

Çizelge 4.4. VGG16 ve beta bandı için sınıflandırma sonuçları

Model	Frekans Bandı	Eğitim-Test	Sınıflar	Doğruluk %					
				Kat - 1	Kat - 2	Kat - 3	Kat - 4	Kat - 5	Ort. %
VGG16	Beta	70% - 30%	Gergin	73.32	71.25	71.24	71.74	72.53	72.01
			Mutlu	70.00	70.00	70.63	71.46	70.83	70.58
			Rahat	71.34	70.52	70.84	72.22	72.26	71.43
			Üzgün	71.46	72.65	72.47	70.78	70.22	71.56
VGG16	Beta	80% - 20%	Gergin	73.21	75.57	71.39	72.62	73.61	73.28
			Mutlu	70.61	73.88	72.33	71.72	73.87	72.48
			Rahat	71.24	73.31	73.32	70.51	73.46	72.36
			Üzgün	71.72	72.85	71.66	73.59	72.58	72.01

Bu çalışmada önerilen yöntemin performansını daha iyi değerlendirebilmek için, çalışmada kullanılan yöntem ile literatürde kullanılan diğer yöntemler karşılaştırılmıştır. Çizelge 4.5., insan duygularının sınıflandırılmasında beyin sinyallerini kullanan önemli çalışmaları özetlemektedir. Bu çalışmalarda gerçekleştirilen duygu sınıflandırma işlemlerinde, elektrot sayısı, uyarıcılar ve sınıflandırıcı tipleri genellikle dikkate alınmaktadır.

Çizelge 4.5. Diğer yaklaşımlarla performans karşılaştırması

Yaklaşımlar	Duygu Sayısı	Doğruluk %
(Bhatti ve ark., 2016)	4	78.11
(Koelstra ve ark., 2010)	4	57.70
(Chanel ve ark., 2011)	3	63.00
(Jirayucharoensak ve ark., 2014)	3	49.52
Önerilen Yöntem	4	74.00

Çizelge 4.5.'te görüldüğü gibi, çalışmada kullanılan yöntemin literatürde kullanılan diğer üç yönteme kıyasla daha iyi performans gösterdiği gözlemlenmiştir. Bu bilgiler ışığında, önerilen mimarinin EEG ile insan duygularının tanınması ve belirlenmesinde etkili bir şekilde kullanılabileceği görülmektedir (Er ve ark., 2021).

4.1.2. Biyomedikal EOG sinyalleri ile yön tespiti

Bu çalışmada, göz hareketlerine dayalı bir BBA yöntemi geliştirilmiştir. OpenBCI Ganglion cihazı ile toplanan elektrookülografi (EOG) verileri, kullanıcıların belirli bir ekrandaki noktalara bakarak ekrandaki nesneleri kontrol etmelerine imkân sağlamaktadır. Çalışma, dört farklı göz hareketinin (yukarı, aşağı, sağ ve sol) algılanması ve bu hareketlerin bir ekranın veya cihazın kontrol edilebilmesine olanak sağlaması üzerine odaklanılmıştır. Altı farklı katılımcıdan elde edilen veriler, her bir göz hareketi için 60 veri noktası (toplamda 240 veri noktası) oluşturacak şekilde toplanmıştır.

Göz, korneada pozitif kutbu ve retinada negatif kutbu olan bir elektriksel potansiyel alan olarak modellenenir. Bu alanın stabil korneo-retinal potansiyel farkı varsayıldığında, göz sabit bir elektriksel potansiyel alanın kaynağı olduğunu gösterir (Bulling ve ark., 2011). EOG sinyalleri ise bu elektriksel potansiyel alanından ölçülen sinyallerdir. Göz merkez pozisyonundan periferiye doğru hareket ettiğinde, retina bir elektroda yaklaşırken kornea karşı elektroya yaklaşır. Bu dipol yönelimindeki değişim elektriksel potansiyel alanında bir değişikliğe neden olur ve böylece ölçülen EOG sinyal genliği değişir. Bu değişikliklerin analizi ile göz hareketleri takip edilebilir.

Gözün iki tarafına yerleştirilen iki çift cilt elektrodu ve alından ek bir referans elektrodu kullanarak, yatay ve dikey olmak üzere iki hareket bileşenine karşılık gelen temel iki sinyal bileşeni (EOG_h ve EOG_v) belirlenebilir. EOG genellikle 5 ila 20µV/derece arasında sinyal genlikleri ve 0 ila 30 Hz arasında temel frekans içeriği gösterir (Abdel-Samei ve ark., 2021).

Veri ön işleme sürecinde, kaydedilen EOG verileri, çoğunlukla düşük frekanslarda yer alır. Bu yüzden 0.1 ve 30 Hz arasında bir bandpass filtresi uygulanmıştır. Ayrıca, bu frekans filtresi, EOG verilerinde istenmeyen yüksek frekanslı gürültülerin ve düşük frekanslı eğilimlerin etkisini azaltmaktadır. Sonraki adımda, KKA kullanılarak eğitim veri setine dayalı bir sınıflandırıcı oluşturulmuştur. Veri setindeki her göz hareketi, önceden belirlenen bir etiketle ilişkilendirilmiştir. Ardından, her bir etiketin belirli bir göz hareketi ile ne kadar ilişkili olduğunu belirlemek için KKA uygulanmıştır.

Çizelge 4.6. EOG veri seti KKA sonuçları


Göz Hareketi	Toplam Örnek	Doğru Tahmin	Yanlış Tahmin	Başarı Oranı
Aşağı Bakış	60	48	12	80%
Yukarı Bakış	60	50	10	83.33%
Sağa Bakış	60	51	9	85%
Sola Bakış	60	46	14	76.67%
Toplam / Ortalama	240	195	45	81.25%

KKA kullanılarak, göz hareketlerini belirlemek için bir sınıflandırıcı oluşturulmuştur. Bu teknik genellikle iki değişken arasındaki ilişkiyi belirlemek için kullanılmıştır. Her bir EOG sinyali karşılık gelen bir göz hareketiyle eşleştirilmiştir. Bu eşleştirmeler, veri setindeki her göz hareketi için önceden belirlenmiş bir etiket ile ilişkilendirilmiştir. KKA, her bir etiketin belirli bir yöne bakan göz hareketiyle ne kadar doğru ilişkilendirildiğinin belirlenmesini sağlamıştır. Elde edilen sonuçlar Çizelge 4.6.'da özetlenmiştir.

4.1.3. Derin öğrenme tabanlı röntgen görüntü analizi ile hastalık tespiti

Bu çalışmada, bu alandaki yaygın kabul görmüş bir açık erişim veri seti kullanılmıştır. Bu veri seti, COVID-19 Radyografi olarak adlandırılmış ve bilgi paylaşım platformu olan Kaggle üzerindeki veri tabanından derlenmiştir (M. Chowdhury ve ark., 2020; Rahman ve ark., 2021).

COVID-19 Radyografi veri seti, COVID-19, normal ve pnömoni olmak üzere üç ayrı kategoriye ayrılmıştır. Bu kategorilerden COVID-19 sınıfına 1143, normal sınıfına 1341 ve pnömoni sınıfına 1345 görüntü dahil edilmiştir. Her bir kategorideki temsilci göğüs röntgeni görüntüleri, Şekil 4.2’de sunulmuştur. Bu görüntüler, ilgili sınıfların özelliklerini ve farklılıklarını vurgulamaktadır.



Şekil 4.2. X-ışını görüntüleri: (a) COVID-19, (b) Pnömoni, (c) Normal.

4.1.3.1. Değerlendirme metrikleri

Çalışmada kullanılan yöntemin performansını değerlendirmek için doğruluk, kesinlik ve duyarlılık hesaplanmıştır. Çizelge 4.7.'de karmaşıklık matrisi verilmiştir. Burada tahminler Pozitif (P) veya Negatif (N) olarak ve doğruluk değerleri Doğru (T) veya Yanlış (F) olarak temsil edilmektedir. Bu performans metriklerinin formülleri Denklem 4.1'de verilmiştir. Bu metrikler, modelimizin performansının kapsamlı ve objektif bir şekilde değerlendirilmesini sağlamaktadır.

Çizelge 4.7. Karmaşıklık matrisi

	Gerçek Değerler	
	1	0
Tahmin edilen	1 TP	FP
	0 FN	TN

TP: Doğru pozitif sayısı (gerçek pozitifleri doğru şekilde tahmin edilen örnekler)

TN: Doğru negatif sayısı (gerçek negatifleri doğru şekilde tahmin edilen örnekler)

FP: Yanlış pozitif sayısı (gerçek negatifleri yanlış şekilde pozitif olarak tahmin edilen örnekler)

FN: Yanlış negatif sayısı (gerçek pozitifleri yanlış şekilde negatif olarak tahmin edilen örnekler)

$$\begin{aligned}
 \text{Doğruluk} &= \frac{|TP| + |TN|}{|TP| + |FP| + |FN| + |TN|} & \text{Kesinlik} &= \frac{|TP|}{|TP| + |FP|} \\
 \text{F1Skor} &= 2 * \frac{(\text{Kesinlik} * \text{Duyarlılık})}{(\text{Kesinlik} + \text{Duyarlılık})} & \text{Duyarlılık} &= \frac{|TP|}{|TP| + |FN|}
 \end{aligned}
 \tag{4.1}$$

Denklem 4.1’de verilen F1 puanı kesinlik ve duyarlılığın harmonik ortalamasına eşittir (Canibey ve Seveli, 2022).

4.1.3.2. Kullanılan KSA mimari tasarımı

Tez çalışmasında biyomedikal X-Ray görüntüleri üzerinde kullanılan KSA mimarisi, bir dizi dikkatlice seçilmiş katmanlardan oluşmaktadır. Kullanılan bu mimari bir giriş katmanı, iki konvolüsyon katmanı, iki havuzlama katmanı, iki tam bağlantılı katman ve nihayetinde bir çıkış katmanı olmak üzere toplamda sekiz katmana ev sahipliği yapar.

Konvolüsyon katmanları, modelin öznitelik çıkarımını gerçekleştirdiği yerdir. İlk konvolüsyon katmanı, 128 konvolüsyon filtresine sahipken, ikinci katmanda bu sayı 64'e düşer. Bu filtreler, giriş özelliklerinin boyutlarını küçültürken, verinin özünü ve anlamlı bilgilerini koruma görevini görür.

Aktivasyon işlemlerinde, ReLU fonksiyonu kullanılmıştır. Bu fonksiyon, modelin girdiler üzerinde lineer olmayan işlemler yapabilmesini sağlar ve bu sayede karmaşık özellikleri başarılı bir şekilde öğrenir. Her konvolüsyon ve ReLU işlemi sonrasında, model boyut indirgeme ve aşırı öğrenmeyi önleme amacıyla 2x1 boyutunda bir maksimum havuzlama işlemi gerçekleştirir.

Çizelge 4.8. Tasarlanmış KSA mimarisi

Sıra No	Katman Adı	Açıklama	Özellikler
1	Giriş	Giriş Vektörü	-
2	'conv1'	Konvolüsyon	12x12 boyutunda 128 konvolüsyon filtresi
3	'relu1'	ReLU	-
4	'pool1'	Maksimum havuzlama	2x1 havuzlama
5	'conv2'	Konvolüsyon	6x6 boyutunda 64 konvolüsyon filtresi
6	'relu2'	ReLU	-
7	'pool2'	Maksimum havuzlama	2x1 havuzlama
8	'fc1'	Tam Bağlı Katman	2048 nöron
9	'relu3'	ReLU	-
10	'drop1'	Dropout	50% dropout
11	'fc2'	Tam Bağlı Katman	2048 nöron
12	Çıkış	Softmax	3 sınıf

Daha detaylı bir bakış açısıyla, mimarimizin özenle seçilmiş bu bileşenlerinin ayrıntıları Çizelge 4.8.'de sunulmuştur. KSA mimarisi, performansını ve genelleştirme yeteneğini optimize etmek için bu şekilde kurgulanmıştır. Sonuçta, bu tasarım kullanılan mimarinin karmaşık girdilerden anlamlı özellikleri etkili bir şekilde öğrenmesini ve doğru çıktıları üretmesini sağlar.

4.1.3.3. Deneysel sonuçlar

Bu bölümde, önerilen yöntemimize dayalı deneylerden elde edilen sonuçlar anlatılmaktadır. Önerilen model, 5.0 GHz hızında çalışan bir Intel Core i7 işlemciye, 32GB belleğe ve RTX 3050 OC 8 GB GPU donanımına sahip bir bilgisayarda MATLAB 2020b kullanılarak geliştirilmiştir. 10 katlı çapraz doğrulama tekniği kullanılarak, göğüs röntgeni görüntüleri rastgele olarak eğitim ve test seti olarak bölünmüştür. Çalışmada ağ, farklı hiperparametreler kullanılarak, mini-küme boyutu ve öğrenme oranı ayarlanarak eğitilmiştir. Mini-küme boyutları 32, 64, 128 olarak seçilmiş, öğrenme oranları ise 0.1, 0.01 ve 0.001 olarak belirlenmiştir. Epoch aralığı 25 olarak seçilmiştir.

Çizelge 4.9.'da, görüntü iyileştirmesi olmadan KSA için sonuçlar şu şekilde özetlenebilir;

Mini-küme boyutunun 32 olduğu durumda; öğrenme oranı 0.1 olarak ayarlandığında, elde edilen en yüksek doğruluk ve hassasiyet sonuçları sırasıyla %96.57 ve %96.17'dir. Mini-küme boyutunu aynı tutarken, öğrenme oranını 0.01'e değiştirerek, en yüksek duyarlılık %96.93 oranıyla elde edilmiştir.

İkinci aşamada, mini-küme boyutu 64 olduğunda; öğrenme oranı 0.1 ile en yüksek doğruluk, hassasiyet ve duyarlılık sonuçları sırasıyla %96.74, %96.65 ve %96.78 olarak elde edilmiştir.

Son aşamada, mini-küme boyutu 128 olduğunda; öğrenme oranı 0.01. Ayrıca elde edilen en yüksek doğruluk ve hassasiyet sırasıyla %96.52 ve %96.66'dır ve öğrenme oranı 0.1 olarak ayarlandığında, en yüksek duyarlılık %97.15 oranıyla elde edilmiştir.

Çizelge 4.9. Görüntü iyileştirme olmadan KSA'den alınan sonuçlar.

Model	Batch-Size	Öğrenme Oranı	Doğruluk %	Kesinlik %	Duyarlılık%
KSA	32	0.1	96.57	96.17	95.43
		0.01	95.16	95.69	96.93
		0.001	95.51	95.06	96.32
	64	0.1	95.24	96.36	95.31
		0.01	96.74	96.65	96.78
		0.001	95.78	96.01	96.04
	128	0.1	95.83	95.03	97.15
		0.01	96.52	96.66	95.25
		0.001	96.54	96.59	95.83

Çok amaçlı guguk kuşu arama algoritması ile kontrast iyileştirme uygulandıktan sonra KSA ile elde edilen sonuçlar Çizelge 4.10.'da gösterilmiştir. Bu Çizelge aşağıdaki gibi özetlenebilir;

Batch-Size boyutu 32 olarak seçildiğinde ve öğrenme oranı 0.001 olarak belirlendiğinde, elde edilen en yüksek doğruluk ve hassasiyet oranları sırasıyla %98.41 ve %97.59 olarak hesaplanmıştır. Aynı Batch-Size boyutu 32 kullanılırken, öğrenme oranını 0.01 olarak güncellendiğinde, en yüksek duyarlılık oranının %98.99 olduğu gözlemlenmiştir.


İkinci aşamada, Batch-Size boyutu 64 olarak ayarlandığında ve öğrenme oranı 0.001 olarak seçildiğinde, en yüksek doğruluk oranı %99.16 olarak elde edilmiştir. Öğrenme oranı 0.001 kullanıldığında, elde edilen en yüksek hassasiyet ve en yüksek duyarlılık oranları ise sırasıyla %98.85 ve %98.51 olarak belirlenmiştir.

Çizelge 4.10. ÇAGKAA ile KSAHE uygulandıktan sonra KSA ile elde edilen sonuçlar

Model	Batch-Size	Öğrenme Oranı	Doğruluk %	Kesinlik %	Duyarlılık%
KSA (guguk arama algoritması ile)	32	0.1	97.53	99.09	98.84
		0.01	98.41	97.59	98.99
		0.001	99.05	99.20	98.08
	64	0.1	98.86	98.82	97.71
		0.01	99.16	98.54	98.04
		0.001	97.37	98.85	98.51
	128	0.1	98.16	98.48	98.34
		0.01	97.44	97.68	98.78
		0.001	99.12	98.64	97.39


Son olarak, Batch-Size boyutu 128 seçildiğinde ve öğrenme oranı 0.001 olarak ayarlandığında, en yüksek doğruluk ve hassasiyet oranları sırasıyla %99.12, %98.64 olduğu gözlemlenmiştir. Öğrenme oranı 0.01 olarak güncellendiğinde ise, en yüksek duyarlılık oranı %98.78 olarak elde edilmiştir.

Karmaşıklık matrisi Şekil 4.3'te verilmiştir. Bu, ağlardan alınan en yüksek doğruluk oranını göstermektedir.



Şekil 4.3. İki modelin karmaşıklık matrisi

Eğitim ve test döngülerinde bulunan en iyi sonuçların doğruluk ve kayıp eğrileri Şekil 4.4.'te gösterilmiştir. Bu görseller, modelin performansının detaylı bir analizini sunmaktadır. Bu sayede grafik modelin doğruluğunun ve hatalarının daha iyi anlaşılmasına olanak sağlamaktadır.



Şekil 4.4. Eğitim ve doğrulama verilerinde doğruluk ve kayıp grafikleri

Hastalık sınıflandırması için önerilen yöntemin mevcut modellerle objektif bir performans karşılaştırması yapılmıştır. COVID-19 radyografi veri setini kullanan önemli çalışmaların bir özeti Çizelge 4.11.'de sunulmuştur (Er ve ark., 2021). Diğer veri setlerini kullanan ve COVID-19 tespiti için kullanılan çalışmaları özetlemektedir.

Çizelge 4.11. Radyografi veri setini kullanan diğer çalışmalarla performans karşılaştırması

Yazar	Yaklaşım	Doğruluk (%)
(M. E. H. Chowdhury ve ark., 2020)	DenseNet201 with image augmentation	97.94
(Aslan ve ark., 2021)	ALexNet & LSTM	98.70
(Turkoglu, 2021)	COVIDetectionNet with Relief	99.18
(Arifin ve ark., 2021)	MobileNet	87.5
(Ilma Progga ve ark., 2020)	VGG-16 with histogram equalization	98.75
(N. Chowdhury ve ark., 2020)	PDCOVIDNet	96.58
Mevcut Çalışma	ÇAGKAA-KSAHE Görüntü İyileştirme ile KSA Modeli	99.12

Chowdhury ve arkadaşlarının yapmış olduğu bir çalışmada, kullanılan veri setindeki görüntülere DenseNet201 ile veri artırma işlemi uygulanmıştır. Ardından iyileştirme yapılan görüntüler üzerinde transfer öğrenme ile ön eğitilmiş derin ağlar kullanılmıştır. Bu işlemler sonucunda hastalık sınıflandırma işleminde %97.94 başarı doğruluk oranı elde edilmiştir (M. Chowdhury ve ark., 2020).

Aslan ve arkadaşları çalışmalarında iki derin öğrenme modeli kullanmışlardır. İlk kullanılan modelde, transfer öğrenme tekniğiyle AlexNet'i ve ikinci olarak kullanılan modelde ise AlexNet ve LSTM'yi hibrit olarak kullanmışlardır. Hibrit yöntemin uygulanmasıyla %98.70 sınıflandırma oranı gibi daha iyi bir sonuç elde etmişlerdir (Aslan ve ark., 2021).

Turkoglu yapmış olduğu bir çalışmada COVIDetectioNet modelini kullanmıştır. Bu modelde, özellikler önceden eğitilmiş AlexNet mimarisinin evrişimli ve tam bağlantılı katmanlarından elde edilmiştir. Ayrıca, en etkili özellikler ReliefF özellik seçim algoritması (RF) kullanılarak belirlenmiş ve sınıflandırma başarısı %99.18 elde edilmiştir (Turkoglu, 2021).

Arifin ve arkadaşlarının yapmış olduğu çalışmada, derin öğrenme temelli MobileNet kullanılmış ve sınıflandırma işlemi sonucunda %87.5 doğruluk başarı oranı elde edilmiştir (Arifin ve ark., 2021).

Progga ve arkadaşları yapmış oldukları çalışmada önerdikleri modelde VGG-16, VGG-19 ve MobilNetV2 ağlarını kullanmışlardır. Veri setindeki çeşitlilik histogram eşitleme ile artırılmıştır ve VGG-16 öğrenme modeli kullanılarak %98.75 başarı oranı elde edilmiştir (Ilma Progga ve ark., 2020).

Chowdhury ve arkadaşlarının yapmış olduğu başka bir çalışmada, PDCOVIDNet adlı derin öğrenme tabanlı bir model kullanılmıştır. Bu öğrenme modeli ile %96.58 doğruluk oranı elde edilmiştir (N. Chowdhury ve ark., 2020).

Çizelge 4.11.'de sunulan çalışmalara göre, önerilen sistemimiz, ÇAGKAA-KSAHE görüntü iyileştirme ve bir KSA modeli kullanarak %99.12 doğruluk oranı ile ikinci en yüksek doğruluk oranını elde etmiştir. Bu sonuç, ÇAGKAA-KSAHE'nin görüntü iyileştirme kapasitesini ve modelin COVID-19 ile enfekte olmuş hastalığı tanıma yeteneğini pozitif bir şekilde etkileyebildiğini göstermektedir(Çiğ ve ark., 2023). Ancak, unutulmamalıdır ki bu modeller belirli bir veri setinde eğitilmiş olup, performansları farklı veri setleri veya gerçek dünya senaryolarına genişletildiğinde değişiklik gösterebilir.

Göğüs kafesi röntgen görüntülerinde görüntülenen enfekte hastalık tespitinde derin öğrenme modellerinin kullanımı genel olarak etkileyici sonuçlar göstermiştir ve birçok çalışmada yüksek doğruluk oranları rapor edilmiştir. Bu tür modellerin potansiyeli, COVID-19 gibi enfekte vakaların hızlı ve doğru bir şekilde teşhis ve tespit etmede tıbbi profesyonellere destek olmaktır. Ancak, bu modellerin geniş çapta kabul görmesi ve uygulanabilmesi için güvenilirliklerinin ve geliştirilebilirliklerinin daha kapsamlı araştırmalarla doğrulanması gereklidir.

Yüksek doğruluk oranlarına rağmen, bu modellerin kullanımı ile ilgili bazı sınırlılıklar da vardır. En büyük engellerden biri, modellerin geliştirilebilirliğini olumsuz etkileyebilecek büyük ve çeşitli COVID-19 veri setlerinin mevcut olmamasıdır. Ayrıca, model performansları, görüntü kalitesi, görüntüleme ekipmanı varyasyonları ve popülasyondaki COVID-19 yaygınlığı gibi faktörlerden etkilenebilir. Bu nedenle, bu modellerin güvenilirlik ve geliştirilebilirlik açısından daha sağlam olabilmesi için geniş ve çeşitli veri setlerinin toplanması ve düzenlenmesi önemlidir.

Derin öğrenme modelleri, X-ışını ve BT tarama görüntülerini kullanarak COVID-19'u tespit etmede önemli bir potansiyel göstermiştir. Bu tabloda listelenen modellerin elde ettiği yüksek doğruluk oranlarına rağmen, sınırlamalarını ve daha fazla araştırma gerekliliğini dikkate almak esastır.

5. SONUÇLAR ve ÖNERİLER

Bu tez çalışması, biyomedikal sinyal ve görüntü analizinde derin öğrenme modellerinin ve görüntü işleme tekniklerinin kullanımını incelerken, bu teknolojilerin etkinliği ve potansiyeli ile ilgili önemli bulgular sunmaktadır. Çalışmanın iki ana odak noktası bulunmaktadır: EEG sinyalleri üzerinden duygu tanıma ve biyomedikal X-ray görüntüleri kullanılarak enfekte hastalık tespiti.

Çalışmanın biyomedikal sinyaller ile ilgili bölümünde, müzik dinleme esnasında EEG sinyalleri üzerinde meydana gelen elektriksel aktiviteler ölçülünerek duygu tanıma için bir yöntem geliştirilmiştir. Özgün bir deney tasarımına dayanan bu çalışmada, çeşitli müzik türlerinden seçilen şarkıları dinleyen 9 kişinin EEG sinyalleri bilgisayara kaydedilmiştir. Bu özel durum, kendi veri setimizi oluşturma fırsatı vermiştir ve bu da çalışmanın özgünlüğünü artırmıştır. Kaydedilen EEG sinyalleri üzerinden spektrogram görüntüleri oluşturulmuş ve bu görüntüler üzerinde önceden eğitilmiş derin ağlar AlexNet ve VGG16 kullanılarak duygu tanıma işlemi gerçekleştirilmiştir. Bu deneyin sonucunda, Beta frekans bandı spektrogramları ile VGG16'nın kombinasyonu %73.28'lik en yüksek sınıflandırma sonucunu vermiştir. Bu sonuçlar, önceden eğitilmiş derin öğrenme modellerinin duygu tanıma konusunda etkin bir araç olabileceğini göstermiştir.

Çalışmanın ikinci faslında, COVID-19 ile enfekte hastalığın göğüs röntgen görüntüleri üzerinden hızlı ve doğru bir şekilde tespit edilmesine odaklanmıştır. Bu çalışmada, X-ışını görüntülerinin kontrastını artırmak ve KSA'ların en doğru sınıflandırmayı yapabilmesi için optimal parametre değerlerini belirlemek amacıyla ÇAGKAA-KSAHE kullanılmıştır. Deneyler, yöntemimizin COVID-19, normal ve pnömoni olgularını sınıflandırmada yüksek doğruluk oranlarına sahip olduğunu göstermiştir. Üstelik, deneyler sonucunda elde edilen %99.16 doğruluk oranı, %99.20 hassasiyet oranı ve %98.99 duyarlılık oranı, literatürde kullanılan diğer yöntemlere kıyasla oldukça başarılıdır.

Özetle, bu tez, EEG sinyalleri üzerinden duygu tanıma ve enfekte hastalık tespiti için X-ışını görüntü analizi gibi çeşitli alanlarda derin öğrenme ve görüntü işleme tekniklerinin etkinliği ve potansiyelini vurgulamaktadır. Hem özgün veri setinin oluşturulması hem de geliştirilen yöntemlerin yüksek doğruluk oranları, biyomedikal sinyal ve görüntü analizinde derin öğrenme modellerinin ve görüntü işleme tekniklerinin uygulanabilirliğini ve değerini artırmaktadır. Ancak, bu teknolojilerin geniş çapta uygulanabilirliği ve güvenilirliğini sağlamak için daha geniş ve çeşitli veri setlerinin toplanması ile derin öğrenme modellerinin geliştirilmesi gerekmektedir. Ayrıca, farklı optimizasyon algoritmalarının kombinasyonunu içeren hibrit optimizasyon tekniklerinin COVID-19 teşhisinde kullanılması, gelecekteki araştırmalar için potansiyel bir yol olarak görülmektedir. Bu iki çalışma, gelecekteki araştırmalara yön vermek için değerli bir temel oluştururken, aynı zamanda bu teknolojilerin daha geniş bir yelpazede uygulanmasının yolunu açabilir.

KAYNAKLAR

- ABDEL-SAMEI, A.-G. A., EL-SAMIE, F. E. A., BRISHA, A. M., and ALI, A. S., 2021. Control of Robot Arm Based on EOG Signals. In 2021 9th International Japan-Africa Conference on Electronics, Communications, and Computations (JAC-ECC). IEEE. <https://doi.org/10.1109/jac-ecc54461.2021.9691437>
- ABHANG, P. A., GAWALI, B. W., and MEHROTRA, S. C., 2016a. Chapter 1 - Introduction to Emotion, Electroencephalography, and Speech Processing. Introduction to EEG- and Speech-Based Emotion Recognition (pp. 1–17). Academic Press. <https://doi.org/10.1016/B978-0-12-804490-2.00001-4>
- ABHANG, P. A., GAWALI, B. W., and MEHROTRA, S. C., 2016b. Chapter 3 - Technical Aspects of Brain Rhythms and Speech Parameters. Introduction to EEG- and Speech-Based Emotion Recognition (pp. 51–79). Academic Press. <https://doi.org/10.1016/B978-0-12-804490-2.00003-8>
- AKAY, M., 1994. PREFACE. In Biomedical Signal Processing (pp. 13–14). Elsevier. <https://doi.org/10.1016/b978-0-12-047145-4.50004-3>
- ALARCAO, S. M., and FONSECA, M. J., 2019. Emotions Recognition Using EEG Signals: A Survey. IEEE Transactions on Affective Computing, 10(3), 374–393. <https://doi.org/10.1109/taffc.2017.2714671>
- ALPAYDIN, E., 2021. Machine Learning. The MIT Press. <https://doi.org/10.7551/mitpress/13811.001.0001>
- AMERI, S. K., KIM, M., KUANG, I. A., TOPCU, U., AKINWANDE, D., LU, N., PERERA, W. K., and ALSHIEKH, M., 2018. Imperceptible electrooculography graphene sensor system for human – robot interface. Npj 2D Materials and Applications, May, 1–7. <https://doi.org/10.1038/s41699-018-0064-4>
- ANG, K. K., CHIN, Z. Y., ZHANG, H., and GUAN, C., 2008. Filter Bank Common Spatial Pattern (FBCSP) in Brain-Computer Interface. In 2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence). IEEE. <https://doi.org/10.1109/ijcnn.2008.4634130>
- APPARASU, P. Y. K., and SREEJA, S. R., 2022. Emotion Recognition from Brain Signals While Subjected to Music Videos. In Intelligent Human Computer Interaction (pp. 772–782). Springer International Publishing. https://doi.org/10.1007/978-3-030-98404-5_68
- ARICO, P., BORGHINI, G., DI FLUMERI, G., SCIARAFFA, N., COLOSIMO, A., and BABILONI, F., 2017. Passive BCI in Operational Environments: Insights, Recent Advances, and Future Trends. IEEE Transactions on Biomedical Engineering, 64(7), 1431–1436. <https://doi.org/10.1109/tbme.2017.2694856>
- ARIFIN, F., ARTANTO, H., NURHASANAH, and GUNAWAN, T. S., 2021. Fast COVID-19 Detection of Chest X-Ray Images Using Single Shot Detection MobileNet Convolutional Neural Networks. Journal of Southwest Jiaotong University, 56(2), 235–248. <https://doi.org/10.35741/issn.0258-2724.56.2.19>
- ASLAN, M. F., UNLERSEN, M. F., SABANCI, K., and DURDU, A., 2021. CNN-based transfer learning-BiLSTM network: A novel approach for COVID-19 infection detection. Applied Soft Computing, 98, 106912. <https://doi.org/10.1016/j.asoc.2020.106912>

- ASTARAS, A., MOUSTAKAS, N., ATHANASIOU, A., and GOGOUSSIS, A., 2013. Towards Brain-Computer Interface Control of a 6-Degree-of-Freedom Robotic Arm Using Dry EEG Electrodes. *Advances in Human-Computer Interaction*, 2013, 1–6. <https://doi.org/10.1155/2013/641074>
- ATAL, B. S., 1976. Automatic recognition of speakers from their voices. *Proceedings of the IEEE*, 64(4), 460–475. <https://doi.org/10.1109/proc.1976.10155>
- ATIEH, M., PANG, J. K., LIAN, K., and WONG, S., 2018. PD099: Predicting peri-implant disease: chi-squared automatic interaction detection (CHAID) decision tree analysis of risk indicators. *Journal of Clinical Periodontology* 76, 45, 76–76. https://doi.org/10.1111/jcpe.101_12914
- BAILEY, J. J., BERSON, A. S., GARSON, A., HORAN, L. G., MACFARLANE, P. W., MORTARA, D. W., and ZYWIETZ, C., 1990. Recommendations for standardization and specifications in automated electrocardiography: bandwidth and digital signal processing. A report for health professionals by an ad hoc writing group of the Committee on Electrocardiography and Cardiac Electrophysi. *Circulation*, 81(2), 730–739. <https://doi.org/10.1161/01.cir.81.2.730>
- BALCONI, M., and MAZZA, G., 2009. Brain oscillations and BIS/BAS (behavioral inhibition/activation system) effects on processing masked emotional cues. *International Journal of Psychophysiology*, 74(2), 158–165. <https://doi.org/10.1016/j.ijpsycho.2009.08.006>
- BANERJEE, A., SANYAL, S., GAYEN, P., ROY, S., PATNAIK, P., and GHOSH, D., 2021. An acoustical and psychological study on contribution of lyrics in raga-based happy and sad Indian music. *Journal of Physics: Conference Series*, 1896(1), 12017. <https://doi.org/10.1088/1742-6596/1896/1/012017>
- BANERJEE, A., SANYAL, S., PATRANABIS, A., BANERJEE, K., GUHATHAKURTA, T., SENGUPTA, R., GHOSH, D., and GHOSE, P., 2016. Study on Brain Dynamics by Non Linear Analysis of Music Induced EEG Signals. *Physica A: Statistical Mechanics and Its Applications*, 444, 110–120. <https://doi.org/10.1016/j.physa.2015.10.030>
- BELKADI, M. A., and DAAMOUCH, A., 2021. A robust QRS detection approach using stationary wavelet transform. *Multimedia Tools and Applications*. <https://doi.org/10.1007/s11042-020-10500-9>
- BELKHIRIA, C., BOUDIR, A., HURTER, C., and PEYSAKHOVICH, V., 2022. EOG-Based Human–Computer Interface: 2000–2020 Review. 1–19.
- BHATTI, A. M., MAJID, M., ANWAR, S. M., and KHAN, B., 2016. Human emotion recognition and analysis in response to audio music using brain signals. *Computers in Human Behavior*, 65, 267–275. <https://doi.org/10.1016/j.chb.2016.08.029>
- BIN, G., GAO, X., YAN, Z., HONG, B., and GAO, S., 2009. An online multi-channel SSVEP-based brain–computer interface using a canonical correlation analysis method. *Journal of Neural Engineering*, 6(4), 46002. <https://doi.org/10.1088/1741-2560/6/4/046002>
- BODA, S., MAHADEVAPPA, M., and DUTTA, P. K., 2021. A hybrid method for removal of power line interference and baseline wander in ECG signals using EMD and EWT. *Biomedical Signal Processing and Control*, 67(April 2020), 102466. <https://doi.org/10.1016/j.bspc.2021.102466>

- BONANNI, L., THOMAS, A., TIRABOSCHI, P., PERFETTI, B., VARANESE, S., and ONOFRJ, M., 2008. EEG comparisons in early Alzheimer's disease, dementia with Lewy bodies and Parkinson's disease with dementia patients with a 2-year follow-up. *Brain*, 131(3), 690–705. <https://doi.org/10.1093/brain/awm322>
- BORAN, E., RAMANTANI, G., KRAYENBUHL, N., SCHREIBER, M., KONIG, K., FEDELE, T., and SARNTHEIN, J., 2019. Clinical Neurophysiology High-density ECoG improves the detection of high frequency oscillations that predict seizure outcome. *Clinical Neurophysiology*, 130(10), 1882–1888. <https://doi.org/10.1016/j.clinph.2019.07.008>
- BREIMAN, L., 1996. Bagging predictors. *Machine Learning*, 24(2), 123–140. <https://doi.org/10.1007/BF00058655>
- BREIMAN, L., 2001. Random Forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- BREMER, J. C., COIFMAN, R. R., MAGGIONI, M., and SZLAM, A. D., 2006. Diffusion wavelet packets. *Applied and Computational Harmonic Analysis*, 21(1), 95–112. <https://doi.org/10.1016/j.acha.2006.04.005>
- BRUNNER, C., BIRBAUMER, N., BLANKERTZ, B., GUGER, C., KUBLER, A., MATTIA, D., MILLÁN, J. DEL R., MIRALLES, F., NIJHOLT, A., OPISSO, E., RAMSEY, N., SALOMON, P., and MULLER-PUTZ, G. R., 2015. BNCI Horizon 2020: towards a roadmap for the BCI community. *Brain-Computer Interfaces*, 2(1), 1–10. <https://doi.org/10.1080/2326263x.2015.1008956>
- BULLING, A., WARD, J. A., GELLERSEN, H., and TROSTER, G., 2011. Eye Movement Analysis for Activity Recognition Using Electrooculography. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 33(4), 741–753. <https://doi.org/10.1109/tpami.2010.86>
- CAMILLERI, T., MANGION, J., and CAMILLERI, K., 2022. Exploiting EEG-extracted Eye Movements for a Hybrid SSVEP Home Automation System. In *Proceedings of the 15th International Joint Conference on Biomedical Engineering Systems and Technologies*. SCITEPRESS - Science and Technology Publications. <https://doi.org/10.5220/0010783800003123>
- CANIBEY, S. T., and SEVLI, O., 2022. Determining the Income Distribution Levels of Individuals with Machine Learning Techniques. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 5(2), 753–766. <https://doi.org/10.47495/okufbed.1039815>
- CARTER, J., 2012. Improving the performance of GIS/spatial analysts though novel applications of the Emotiv EPOC EEG headset [Michigan Technological University]. <https://doi.org/10.37099/mtu.dc.etsds/570>
- CHANDRA, T. B., and VERMA, K., 2019. Pneumonia Detection on Chest X-Ray Using Machine Learning Paradigm. In *Proceedings of 3rd International Conference on Computer Vision and Image Processing* (pp. 21–33). Springer Singapore. https://doi.org/10.1007/978-981-32-9088-4_3
- CHANEL, G., KIERKELS, J. J. M., SOLEYMANI, M., and PUN, T., 2009. Short-term emotion assessment in a recall paradigm. *International Journal of Human-Computer Studies*, 67(8), 607–627. <https://doi.org/10.1016/j.ijhcs.2009.03.005>
- CHANEL, G., REBETEZ, C., BÉTRANCOURT, M., and PUN, T., 2011. Emotion Assessment From Physiological Signals for Adaptation of Game Difficulty. *IEEE*

- Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans, 41(6), 1052–1063. <https://doi.org/10.1109/tsmca.2011.2116000>
- CHO, J., LEE, B., KWON, J. M., LEE, Y., PARK, H., OH, B. H., JEON, K. H., PARK, J., and KIM, K. H., 2021. Artificial Intelligence Algorithm for Screening Heart Failure with Reduced Ejection Fraction Using Electrocardiography. *ASAIIO Journal*, 314–321. <https://doi.org/10.1097/MAT.0000000000001218>
- CHOWDHURY, M., RAHMAN, T., KHANDAKAR, A., MAZHAR, R., KADIR, M. A., MAHBUB, Z. BIN, ISLAM, K. R., KHAN, M. S., IQBAL, A., EMADI, N. AL, REAZ, M. B. I., and ISLAM, M. T., 2020. Can AI Help in Screening Viral and COVID-19 Pneumonia *IEEE Access*, 8, 132665–132676. <https://doi.org/10.1109/access.2020.3010287>
- CHOWDHURY, N., RAHMAN, M., and KABIR, M. A., 2020. PDCOVIDNet: A Parallel-Dilated Convolutional Neural Network Architecture for Detecting COVID-19 from Chest X-Ray Images. *Open Engineering Inc.* <https://doi.org/10.31224/osf.io/myp6c>
- CIG, H., GÜLLÜOĞLU, M. T., ER, M. B., KURAN, U., and KURAN, E. C., 2023. Enhanced Disease Detection Using Contrast Limited Adaptive Histogram Equalization and Multi-Objective Cuckoo Search in Deep Learning. *Traitement Du Signal*, 40(3), 915–925. <https://doi.org/10.18280/ts.400308>
- CIG, H., and TUYSUZ, M. F., 2018. Impact of age, sex and hair type on SSVEP-based EEG signals analysis. In *2018 26th Signal Processing and Communications Applications Conference (SIU)*. IEEE. <https://doi.org/10.1109/siu.2018.8404638>
- CIODARO, T., DEVA, D., DE SEIXAS, J. M., and DAMAZIO, D., 2012. Online particle detection with Neural Networks based on topological calorimetry information. *Journal of Physics: Conference Series*, 368, 12030. <https://doi.org/10.1088/1742-6596/368/1/012030>
- MATTHEWS, J., 2014. Classification And Regression Trees(CART). In *Encyclopedia of Environmental Change (Vols 1–3)*. SAGE Publications, Ltd. <https://doi.org/10.4135/9781446247501.n662>
- CLEOPHAS, T. J., and ZWINDERMAN, A. H., 2021. Regression Trees. In *Regression Analysis in Medical Research* (pp. 383–391). Springer International Publishing. https://doi.org/10.1007/978-3-030-61394-5_22
- COSTACHE, R., HONG, H., and PHAM, Q. B., 2020. Comparative assessment of the flash-flood potential within small mountain catchments using bivariate statistics and their novel hybrid integration with machine learning models. *Science of The Total Environment*, 711, 134514. <https://doi.org/10.1016/j.scitotenv.2019.134514>
- CUI, L., XUE, B., and ZHOU, F., 2014. Atmospheric turbulence MTF for infrared optical waves' propagation through marine atmospheric turbulence. *Infrared Physics and Technology*, 65, 24–29. <https://doi.org/10.1016/j.infrared.2014.03.004>
- DANTONA, G., MUSCAS, C., and SULIS, S., 2011. Localization of Nonlinear Loads in Electric Systems Through Harmonic Source Estimation. *IEEE Transactions on Instrumentation and Measurement*, 60(10), 3423–3430. <https://doi.org/10.1109/tim.2011.2126830>
- DAS, A. K., SURESH, S., and SUNDARARAJAN, N., 2016. A discriminative subject-specific spatio-spectral filter selection approach for EEG based motor-

- imagery task classification. *Expert Systems with Applications*, 64, 375–384. <https://doi.org/10.1016/j.eswa.2016.08.007>
- SAHIN, M. E., 2022. Deep learning-based approach for detecting COVID-19 in chest X-rays. *Biomedical Signal Processing and Control*, 78, 103977. <https://doi.org/10.1016/j.bspc.2022.103977>
- ER, M. B., 2020. Akciğer Seslerinin Derin Öğrenme İle Sınıflandırılması. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 8(4), 830–844. <https://doi.org/10.29109/gujsc.758325>
- ER, M. B., CIG, H., and AYDILEK, I. B., 2021. A new approach to recognition of human emotions using brain signals and music stimuli. *Applied Acoustics*, 175, 107840. <https://doi.org/10.1016/j.apacoust.2020.107840>
- ERSOY, O. K., 2006. Appendix C: The Discrete-Time Fourier Transform, The Discrete Fourier Transform and The Fast Fourier Transform. In *Diffraction, Fourier Optics and Imaging*. <https://doi.org/10.1002/9780470085004.app3>
- ERTUĞRUL, Ö. F., ACAR, E., ALDEMİR, E., and ÖZTEKİN, A., 2021. Automatic diagnosis of cardiovascular disorders by sub images of the ECG signal using multi-feature extraction methods and randomized neural network. *Biomedical Signal Processing and Control*, 64(July 2020). <https://doi.org/10.1016/j.bspc.2020.102260>
- EVANS, D. H., 2000. Doppler signal analysis. *Ultrasound in Medicine and Biology*, 26, S13–S15. [https://doi.org/10.1016/s0301-5629\(00\)00153-8](https://doi.org/10.1016/s0301-5629(00)00153-8)
- FATOURECHI, M., BASHASHATI, A., WARD, R. K., and BIRCH, G. E., 2007. EMG and EOG artifacts in brain computer interface systems: A survey. *Clinical Neurophysiology*, 118(3), 480–494. <https://doi.org/10.1016/j.clinph.2006.10.019>
- FAYYAD, U. M., and IRANI, K. B., 1992. On the handling of continuous-valued attributes in decision tree generation. *Machine Learning*, 8(1), 87–102. <https://doi.org/10.1007/bf00994007>
- FERRERO, J. M., FERRERO, Á., TRÉNOR, B., MONTILLA, F., SAIZ, J., and RODRÍGUEZ, B., 2006. Ischemia. In *Wiley Encyclopedia of Biomedical Engineering*. John Wiley and Sons, Inc. <https://doi.org/10.1002/9780471740360.ebs0661>
- FRAGOPANAGOS, N., and TAYLOR, J. G., 2005. Emotion recognition in human–computer interaction. *Neural Networks*, 18(4), 389–405. <https://doi.org/10.1016/j.neunet.2005.03.006>
- FRIEDL, M. A., and BRODLEY, C. E., 1997. Decision tree classification of land cover from remotely sensed data. *Remote Sensing of Environment*, 61(3), 399–409. [https://doi.org/10.1016/s0034-4257\(97\)00049-7](https://doi.org/10.1016/s0034-4257(97)00049-7)
- FU, Y., and ALDRICH, C., 2019. Flotation froth image recognition with convolutional neural networks. *Minerals Engineering*, 132, 183–190. <https://doi.org/10.1016/j.mineng.2018.12.011>
- GANGLION, T., 2018. Erişim Tarihi: 21.06.2023. Ganglion Specs. <https://docs.openbci.com/Ganglion/GanglionSpecs/#>
- GAO, Z., WANG, X., YANG, Y., MU, C., CAI, Q., DANG, W., and ZUO, S., 2019. EEG-Based Spatio–Temporal Convolutional Neural Network for Driver Fatigue Evaluation. *IEEE Transactions on Neural Networks and Learning Systems*, 30(9), 2755–2763. <https://doi.org/10.1109/tnnls.2018.2886414>

- GENG, S., ZHOU, W., YUAN, Q., CAI, D., and ZENG, Y., 2011. EEG non-linear feature extraction using correlation dimension and Hurst exponent. *Neurological Research*, 33(9), 908–912. <https://doi.org/10.1179/1743132811Y.0000000041>
- GHOSH, S. K., and GHOSH, A., 2022. ENResNet: A novel residual neural network for chest X-ray enhancement based COVID-19 detection. *Biomedical Signal Processing and Control*, 72, 103286. <https://doi.org/10.1016/j.bspc.2021.103286>
- GOLDBERGER, J. J., CAIN, M. E., HOHNLOSER, S. H., KADISH, A. H., KNIGHT, B. P., LAUER, M. S., MARON, B. J., PAGE, R. L., PASSMAN, R. S., SISCOVICK, D., STEVENSON, W. G., and ZIPES, D. P., 2008. American Heart Association/American College of Cardiology Foundation/Heart Rhythm Society Scientific Statement on Noninvasive Risk Stratification Techniques for Identifying Patients at Risk for Sudden Cardiac Death. *Heart Rhythm*, 5(10), e1–e21. <https://doi.org/10.1016/j.hrthm.2008.05.031>
- GONZALEZ, R. C., WOODS, R. E., and MASTERS, B. R., 2009. Digital Image Processing, Third Edition. *Journal of Biomedical Optics*, 14(2), 29901. <https://doi.org/10.1117/1.3115362>
- GOSHVARPOUR, A., and GOSHVARPOUR, A., 2019. EEG spectral powers and source localization in depressing, sad, and fun music videos focusing on gender differences. *Cognitive Neurodynamics*, 13(2), 161–173. <https://doi.org/10.1007/s11571-018-9516-y>
- GÜLCÜ, A., and KUŞ, Z., 2019. Konvolüsyonel Sinir Ağlarında Hiper-Parametre Optimizasyonu Yöntemlerinin İncelenmesi. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 7(2), 503–522. <https://doi.org/10.29109/gujsc.514483>
- GUPTA, S., JAAFAR, J., WAN AHMAD, W. F., and BANSAL, A., 2013. Feature Extraction Using Mfcc. *Signal & Image Processing: An International Journal*, 4(4), 101–108. <https://doi.org/10.5121/sipij.2013.4408>
- H. JOPRI, M., R. ABDULLAH, A., MANAP, M., SUTIKNO, T., and AB GHANI, M. R., 2018. An Identification of Multiple Harmonic Sources in a Distribution System by Using Spectrogram. *Bulletin of Electrical Engineering and Informatics*, 7(2), 244–256. <https://doi.org/10.11591/eei.v7i2.1188>
- HAGGAG, S., MOHAMED, S., BHATTI, A., HAGGAG, H., and NAHAVANDI, S., 2015. Noise level classification for EEG using Hidden Markov Models. In 2015 10th System of Systems Engineering Conference (SoSE). IEEE. <https://doi.org/10.1109/sysose.2015.7151974>
- HERTEL, R., and BENLAMRI, R., 2021. COV-SNET: A deep learning model for X-ray-based COVID-19 classification. *Informatics in Medicine Unlocked*, 24, 100620. <https://doi.org/10.1016/j.imu.2021.100620>
- HEWAHI, N. M., and ABU HAMRA, E., 2017. A Hybrid Approach Based on Genetic Algorithm and Particle Swarm Optimization to Improve Neural Network Classification. *Journal of Information Technology Research*, 10(3), 48–68. <https://doi.org/10.4018/jitr.2017070104>
- HILL, N. J., LAL, T. N., SCHRODER, M., HINTERBERGER, T., WIDMAN, G., ELGER, C. E., SCHOLKOPF, B., and BIRBAUMER, N., 2006. Classifying Event-Related Desynchronization in EEG, ECoG and MEG Signals. In *Lecture Notes in Computer Science* (pp. 404–413). Springer Berlin Heidelberg. https://doi.org/10.1007/11861898_41

- HOU, H., ZHANG, X., and MENG, Q., 2020. Olfactory EEG Signal Classification Using a Trapezoid Difference-Based Electrode Sequence Hashing Approach. *International Journal of Neural Systems*, 30(03), 2050011. <https://doi.org/10.1142/s0129065720500112>
- HOU, H.-R., MENG, Q.-H., ZENG, M., and SUN, B., 2018. Improving Classification of Slow Cortical Potential Signals for BCI Systems With Polynomial Fitting and Voting Support Vector Machine. *IEEE Signal Processing Letters*, 25(2), 283–287. <https://doi.org/10.1109/lsp.2017.2783351>
- HUANG, D., GUAN, C., ANG, K. K., ZHANG, H., and PAN, Y., 2012. Asymmetric Spatial Pattern for EEG-based emotion detection. In *The 2012 International Joint Conference on Neural Networks (IJCNN)*. IEEE. <https://doi.org/10.1109/ijcnn.2012.6252390>
- HUBBARD, B. B., 1998. *The World According to Wavelets*. A K Peters/CRC Press. <https://doi.org/10.1201/9781439864555>
- ILMA PROGGA, N., SHAHADAT HOSSAIN, M., and ANDERSSON, K., 2020. A Deep Transfer Learning Approach to Diagnose Covid-19 using X-ray Images. In *2020 IEEE International Women in Engineering (WIE) Conference on Electrical and Computer Engineering (WIECON-ECE)*. IEEE. <https://doi.org/10.1109/wiecon-ece52138.2020.9398037>
- IMMERKÆR, J., 1996. Fast Noise Variance Estimation. *Computer Vision and Image Understanding*, 64(2), 300–302. <https://doi.org/10.1006/cviu.1996.0060>
- JATUPAIBOON, N., PAN-NGUM, S., and ISRASENA, P., 2013. Emotion classification using minimal EEG channels and frequency bands. In *The 2013 10th International Joint Conference on Computer Science and Software Engineering (JCSSE)*. IEEE. <https://doi.org/10.1109/jcsse.2013.6567313>
- JEGOU, H., DOUZE, M., and SCHMID, C., 2011. Product Quantization for Nearest Neighbor Search. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 33(1), 117–128. <https://doi.org/10.1109/tpami.2010.57>
- JIN, C., DE-LIN, L., and FEN-XIANG, M., 2009. An improved ID3 decision tree algorithm. In *2009 4th International Conference on Computer Science & Education*. IEEE. <https://doi.org/10.1109/iccse.2009.5228509>
- JIRAYUCHAROENSAK, S., PAN-NGUM, S., and ISRASEN, P., 2014. EEG-Based Emotion Recognition Using Deep Learning Network with Principal Component Based Covariate Shift Adaptation. *He Scientific World Journal*, 10 pages. <https://doi.org/http://dx.doi.org/10.1155/2014/627892>
- JOKANOVIĆ, V., and JOKANOVIĆ, B., 2021. Brain-Computer Interface: State-of-Art, Challenges, and the Future. In *Artificial Intelligence* (pp. 203–227). Chapman and Hall/CRC. <https://doi.org/10.1201/9781003140351-21>
- KABIR, E., SIULY, and ZHANG, Y., 2016. Epileptic seizure detection from EEG signals using logistic model trees. *Brain Informatics*, 3(2), 93–100. <https://doi.org/10.1007/s40708-015-0030-2>
- KATHIRVEL, P., SABARIMALAI MANIKANDAN, M., PRASANNA, S. R. M., and SOMAN, K. P., 2011. An Efficient R-peak Detection Based on New Nonlinear Transformation and First-Order Gaussian Differentiator. *Cardiovascular Engineering and Technology*, 2(4), 408–425. <https://doi.org/10.1007/s13239-011-0065-3>

- KEMP, A., 2002. Steady-State Visually Evoked Potential Topography during Processing of Emotional Valence in Healthy Subjects. *NeuroImage*, 17(4), 1684–1692. <https://doi.org/10.1006/nimg.2002.1298>
- KIGUCHI, K., and HAYASHI, Y., 2012. An EMG-Based Control for an Upper-Limb Power-Assist Exoskeleton Robot. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 42(4), 1064–1071. <https://doi.org/10.1109/tsmcb.2012.2185843>
- KIM, J., LEE, J. K., and LEE, K. M., 2016. Accurate Image Super-Resolution Using Very Deep Convolutional Networks. In 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE. <https://doi.org/10.1109/cvpr.2016.182>
- KIM, M., KIM, M., OH, E., and KIM, S.-P., 2013. A review on the computational methods for emotional state estimation from the human EEG. *Computational and Mathematical Methods in Medicine*, 2013, 573734. <https://doi.org/10.1155/2013/573734>
- KLIGFIELD, P., GETTES, L. S., BAILEY, J. J., CHILDERS, R., DEAL, B. J., HANCOCK, E. W., VAN HERPEN, G., KORS, J. A., MACFARLANE, P., MIRVIS, D. M., PAHLM, O., RAUTAHARJU, P., and WAGNER, G. S., 2007. Recommendations for the standardization and interpretation of the electrocardiogram. *Heart Rhythm*, 4(3), 394–412. <https://doi.org/10.1016/j.hrthm.2007.01.027>
- KOELSTRA, S., YAZDANI, A., SOLEYMANI, M., MUHL, C., LEE, J.-S., NIJHOLT, A., PUN, T., EBRAHIMI, T., and PATRAS, I., 2010. Single Trial Classification of EEG and Peripheral Physiological Signals for Recognition of Emotions Induced by Music Videos. In *Brain Informatics* (pp. 89–100). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-15314-3_9
- KONTAXAKIS, G., 2006. Positron Emission Tomography (PET). In *Wiley Encyclopedia of Biomedical Engineering*. John Wiley and Sons, Inc. <https://doi.org/10.1002/9780471740360.ebs0952>
- KOROVESIS, KANDRIS, KOULOURAS, and ALEXANDRIDIS., 2019. Robot Motion Control via an EEG-Based Brain–Computer Interface by Using Neural Networks and Alpha Brainwaves. *Electronics*, 8(12), 1387. <https://doi.org/10.3390/electronics8121387>
- KRIZHEVSKY, A., SUTSKEVER, I., and HINTON, G. E., 2017. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90. <https://doi.org/10.1145/3065386>
- KUO, K. M., TALLEY, P. C., HUANG, C. H., and CHENG, L. C., 2019. Predicting hospital-acquired pneumonia among schizophrenic patients: a machine learning approach. *BMC Medical Informatics and Decision Making*, 19(1), 42. <https://doi.org/10.1186/s12911-019-0792-1>
- LECUN, Y., BENGIO, Y., and HINTON, G., 2015. Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- LEDOUX, J. E., 1989. Cognitive-Emotional Interactions in the Brain. *Cognition and Emotion*, 3(4), 267–289. <https://doi.org/10.1080/02699938908412709>
- LEVSHINA, N., 2020. Conditional Inference Trees and Random Forests. In *A Practical Handbook of Corpus Linguistics* (pp. 611–643). Springer International Publishing. https://doi.org/10.1007/978-3-030-46216-1_25

- LI, C., ZHANG, S., ZHANG, H., PANG, L., LAM, K., HUI, C., and ZHANG, S., 2012. Using the K-Nearest Neighbor Algorithm for the Classification of Lymph Node Metastasis in Gastric Cancer. *Computational and Mathematical Methods in Medicine*, 2012, 1–11. <https://doi.org/10.1155/2012/876545>
- LI, J., WANG, Y., WANG, S., WANG, J., LIU, J., JIN, Q., and SUN, L., 2021. Multiscale Attention Guided Network for COVID-19 Diagnosis Using Chest X-Ray Images. *IEEE Journal of Biomedical and Health Informatics*, 25(5), 1336–1346. <https://doi.org/10.1109/JBHI.2021.3058293>
- LI, M., and CHEN, W., 2021. FFT-based deep feature learning method for EEG classification. *Biomedical Signal Processing and Control*, 66(December 2020), 102492. <https://doi.org/10.1016/j.bspc.2021.102492>
- LI, M., and LU, B.-L., 2009. Emotion classification based on gamma-band EEG. In 2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE. <https://doi.org/10.1109/iembs.2009.5334139>
- LIN, C.-T., LIN, B.-S., LIN, F.-C., and CHANG, C.-J., 2014. Brain Computer Interface-Based Smart Living Environmental Auto-Adjustment Control System in UPnP Home Networking. *IEEE Systems Journal*, 8(2), 363–370. <https://doi.org/10.1109/jsyst.2012.2192756>
- LIU, Y., SOURINA, O., and NGUYEN, M. K., 2011. Real-Time EEG-Based Emotion Recognition and Its Applications. In *Lecture Notes in Computer Science* (pp. 256–277). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-22336-5_13
- LU, D., BAI, E., and WANG, G., 2006. Computed Tomography. In *Wiley Encyclopedia of Biomedical Engineering*. John Wiley & Sons, Inc. <https://doi.org/10.1002/9780471740360.ebs0300>
- LU, S., LU, Z., and ZHANG, Y.-D., 2019. Pathological brain detection based on AlexNet and transfer learning. *Journal of Computational Science*, 30, 41–47. <https://doi.org/10.1016/j.jocs.2018.11.008>
- LUO, Y., MAJOE, S., KUI, J., QI, H., PUSHPARAJAH, K., and RHODE, K., 2021. Ultra-Dense Denoising Network: Application to Cardiac Catheter-Based X-Ray Procedures. *IEEE Transactions on Biomedical Engineering*, 68(9), 2626–2636. <https://doi.org/10.1109/tbme.2020.3041571>
- LUONGO, G., SCHULER, S., LUIK, A., ALMEIDA, T. P., SORIANO, D. C., DOSSEL, O., and LOEWE, A., 2021. Non-Invasive Characterization of Atrial Flutter Mechanisms Using Recurrence Quantification Analysis on the ECG: A Computational Study. *IEEE Transactions on Biomedical Engineering*, 68(3), 914–925. <https://doi.org/10.1109/TBME.2020.2990655>
- MA, J., SHERIDAN, R. P., LIAW, A., DAHL, G. E., and SVETNIK, V., 2015. Deep Neural Nets as a Method for Quantitative Structure–Activity Relationships. *Journal of Chemical Information and Modeling*, 55(2), 263–274. <https://doi.org/10.1021/ci500747n>
- MADDUMAPATABENDI, J. D., KIMOTO, A., and SHIDA, K., 2008. A Novel Biomedical Ultrasonic and Impedance Imaging System.
- MARFO, S. A., ASANTE-OKYERE, S., and ZIGGAH, Y. Y., 2021. A new flowing bottom hole pressure prediction model using M5 prime decision tree approach. *Modeling Earth Systems and Environment*, 8(2), 2065–2073. <https://doi.org/10.1007/s40808-021-01211-7>

- MARSH, A., 2001. In *Medicine Information Technologies In Medicine Volume I: Medical Simulation: Vol. I*.
- MASCI, J., MEIER, U., CIRESAN, D., SCHMIDHUBER, J., and FRICOUT, G., 2012. Steel defect classification with Max-Pooling Convolutional Neural Networks. In *The 2012 International Joint Conference on Neural Networks (IJCNN)*. IEEE. <https://doi.org/10.1109/ijcnn.2012.6252468>
- MEHTA, R. K., and PARASURAMAN, R., 2013. Neuroergonomics: a review of applications to physical and cognitive work. *Frontiers in Human Neuroscience*, 7, 889. <https://doi.org/10.3389/fnhum.2013.00889>
- MENG, J., YAO, L., SHENG, X., ZHANG, D., and ZHU, X., 2015. Simultaneously Optimizing Spatial Spectral Features Based on Mutual Information for EEG Classification. *IEEE Transactions on Biomedical Engineering*, 62(1), 227–240. <https://doi.org/10.1109/tbme.2014.2345458>
- MIAO, M., HU, W., XU, B., ZHANG, J., RODRIGUES, J. J. P. C., and DE ALBUQUERQUE, V. H. C., 2022. Automated CCA-MWF Algorithm for Unsupervised Identification and Removal of EOG Artifacts From EEG. *IEEE Journal of Biomedical and Health Informatics*, 26(8), 3607–3617. <https://doi.org/10.1109/jbhi.2021.3131186>
- MOHAJANE, M., COSTACHE, R., KARIMI, F., BAO PHAM, Q., ESSAHLAOU, A., NGUYEN, H., LANEVE, G., and OUDIA, F., 2021. Application of remote sensing and machine learning algorithms for forest fire mapping in a Mediterranean area. *Ecological Indicators*, 129, 107869. <https://doi.org/10.1016/j.ecolind.2021.107869>
- MOHAMMADPOUR, M., HASHEMI, S. M. R., and HOUSHMAND, N., 2017. Classification of EEG-based emotion for BCI applications. In *2017 Artificial Intelligence and Robotics (IRANOPEN)*. IEEE. <https://doi.org/10.1109/rios.2017.7956455>
- MULLERPUTZ, G. R., SCHERER, R., BRAUNEIS, C., and PFURTSCHELLER, G., 2005. Steady-state visual evoked potential (SSVEP)-based communication: impact of harmonic frequency components. *Journal of Neural Engineering*, 2(4), 123–130. <https://doi.org/10.1088/1741-2560/2/4/008>
- NASIRI, H., and HASANI, S., 2022. Automated detection of COVID-19 cases from chest X-ray images using deep neural network and XGBoost. *Radiography (London, England: 1995)*, 28(3), 732–738. <https://doi.org/10.1016/j.radi.2022.03.011>
- NIEBUR, D., and GERMOND, A. J., 1991. Power flow classification for static security assessment. *Proceedings of the First International Forum on Applications of Neural Networks to Power Systems*, 83–88. <https://doi.org/10.1109/ANN.1991.213502>
- PATEL, O., P. S. MARAVI, Y., and SHARMA, S., 2013. A Comparative Study of Histogram Equalization Based Image Enhancement Techniques for Brightness Preservation and Contrast Enhancement. *Signal & Image Processing: An International Journal*, 4(5), 11–25. <https://doi.org/10.5121/sipij.2013.4502>
- PIZER, S. M., AMBURN, E. P., AUSTIN, J. D., CROMARTIE, R., GESELOWITZ, A., GREER, T., TER HAAR ROMENY, B., ZIMMERMAN, J. B., and ZUIDERVELD, K., 1987. Adaptive histogram equalization and its variations. *Computer Vision, Graphics, and Image Processing*, 39(3), 355–368. [https://doi.org/10.1016/s0734-189x\(87\)80186-x](https://doi.org/10.1016/s0734-189x(87)80186-x)

- PLONSEY, R., & BARR, R. C., 2007. Exercises. In *Bioelectricity* (pp. 391–523). Springer US. https://doi.org/10.1007/978-0-387-48865-3_13
- PLUTCHIK, R., VAN PRAAG, H. M., and CONTE, H. R., 1989. Correlates of suicide and violence risk: III. A two-stage model of countervailing forces. *Psychiatry Research*, 28(2). [https://doi.org/10.1016/0165-1781\(89\)90048-6](https://doi.org/10.1016/0165-1781(89)90048-6)
- PORCARO, C., AVANAKI, K., ARIAS-CARRION, O., and MØRUP, M., 2023. Editorial: Combined EEG in research and diagnostics: Novel perspectives and improvements. *Frontiers in Neuroscience*, 17, 11–13. <https://doi.org/10.3389/fnins.2023.1152394>
- QUINLAN, J. R., 1986. Induction of decision trees. *Machine Learning*, 1(1), 81–106. <https://doi.org/10.1007/bf00116251>
- RabBANI, H., MAHJOOB, MP., FARAHABADI, E., and FARAHABADI, A., 2011. R peak detection in electrocardiogram signal based on an optimal combination of wavelet transform, Hilbert transform, and adaptive thresholding. *Journal of Medical Signals and Sensors*, 1(2), 91. <https://doi.org/10.4103/2228-7477.95292>
- RAHIM ABDULLAH, A., AHMAD, N. H. T. H., ABIDULLAH, N. A., SHAMSUDIN, N. H., and JOPRI, M. H., 2015. Performance Evaluation of Real Power Quality Disturbances Analysis Using S-Transform. *Applied Mechanics and Materials*, 752–753, 1343–1348. <https://doi.org/10.4028/www.scientific.net/amm.752-753.1343>
- RAHMAN, T., KHANDAKAR, A., QIBLAWEY, Y., TAHIR, A., KIRANYAZ, S., ABUL KASHEM, S. BIN, ISLAM, M. T., AL MAADEED, S., ZUGHAIER, S. M., KHAN, M. S., and CHOWDHURY, M. E. H., 2021. Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images. *Computers in Biology and Medicine*, 132, 104319. <https://doi.org/10.1016/j.combiomed.2021.104319>
- RICOGARCIA, O. D., FERNANDEZ FERNANDEZ, J., BECERRA SALDANA, R. A., and WITKOWSKI, O., 2022. Emotion-Driven Interactive Storytelling: Let Me Tell You How to Feel. In *Artificial Intelligence in Music, Sound, Art and Design* (pp. 259–274). Springer International Publishing. https://doi.org/10.1007/978-3-031-03789-4_17
- RODRIGUEZ-GALIANO, V. F., GHIMIRE, B., ROGAN, J., CHICA-OLMO, M., and RIGOL-SANCHEZ, J. P., 2012. An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67, 93–104. <https://doi.org/10.1016/j.isprsjprs.2011.11.002>
- RUSSAKOVSKY, O., DENG, J., SU, H., KRAUSE, J., SATHEESH, S., MA, S., HUANG, Z., KARPATHY, A., KHOSLA, A., BERNSTEIN, M., BERG, A. C., and FEI-FEI, L., 2015. ImageNet Large Scale Visual Recognition Challenge. *International Journal of Computer Vision*, 115(3), 211–252. <https://doi.org/10.1007/s11263-015-0816-y>
- SAHOO, S., SUBUDHI, A., DASH, M., and SABUT, S., 2020. Automatic Classification of Cardiac Arrhythmias Based on Hybrid Features and Decision Tree Algorithm. *International Journal of Automation and Computing*, 17(4), 551–561. <https://doi.org/10.1007/s11633-019-1219-2>
- SALAMON, J., and BELLO, J. P., 2017. Deep Convolutional Neural Networks and Data Augmentation for Environmental Sound Classification. *IEEE Signal Processing Letters*, 24(3), 279–283. <https://doi.org/10.1109/lsp.2017.2657381>

- SAMSON, V. R. R., PRAVEEN KITTI, B., PRADEEP KUMAR, S., SURESH BABU, D., and MONICA, C., 2018. Electroencephalogram-based OpenBCI devices for disabled people. *Lecture Notes in Electrical Engineering*, 434, 229–238. https://doi.org/10.1007/978-981-10-4280-5_24
- SANTOS, A., and LEDESMA-CARBAYO, M. J., 2006. Cardiac Imaging. In *Wiley Encyclopedia of Biomedical Engineering*. John Wiley and Sons, Inc. <https://doi.org/10.1002/9780471740360.ebs0221>
- SCHIRRMESTER, R. T., SPRINGENBERG, J. T., FIEDERER, L. D. J., GLASSTETTER, M., EGGENSBERGER, K., TANGERMANN, M., HUTTER, F., BURGARD, W., and BALL, T., 2017. Deep learning with convolutional neural networks for EEG decoding and visualization. *Human Brain Mapping*, 38(11), 5391–5420. <https://doi.org/10.1002/hbm.23730>
- SEIDEL, H. B., DA ROSA, M. M. E. A., PAIM, G., DA COSTA, E. A. C., ALMEIDA, S. J. M., and BAMPI, S., 2021. Approximate pruned and truncated haar discrete wavelet transform VLSI hardware for energy-efficient ECG signal processing. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 68(5), 1814–1826. <https://doi.org/10.1109/TCSI.2021.3057584>
- SHAHABI, H., and MOGHIMI, S., 2016. Toward automatic detection of brain responses to emotional music through analysis of EEG effective connectivity. *Computers in Human Behavior*, 58, 231–239. <https://doi.org/10.1016/j.chb.2016.01.005>
- SHAHNAZ, C., SHOAIB-BIN-MASUD, and HASAN, S. M. S., 2016. Emotion recognition based on wavelet analysis of Empirical Mode Decomposed EEG signals responsive to music videos. In *2016 IEEE Region 10 Conference (TENCON)*. IEEE. <https://doi.org/10.1109/tencon.2016.7848034>
- SHAO, L., ZHANG, L., BELKACEM, A. N., ZHANG, Y., CHEN, X., LI, J., and LIU, H., 2020. EEG-Controlled Wall-Crawling Cleaning Robot Using SSVEP-Based Brain-Computer Interface. *Journal of Healthcare Engineering*, 2020, 6968713. <https://doi.org/10.1155/2020/6968713>
- SHARMA, S., GUPTA, S., GUPTA, D., RASHID, J., JUNEJA, S., KIM, J., and ELARABAWY, M. M., 2022. Performance Evaluation of the Deep Learning Based Convolutional Neural Network Approach for the Recognition of Chest X-Ray Images. *Frontiers in Oncology*, 12, 932496. <https://doi.org/10.3389/fonc.2022.932496>
- SHRESTHA, A., and MAHMOOD, A., 2019. Review of Deep Learning Algorithms and Architectures. *IEEE Access*, 7, 53040–53065. <https://doi.org/10.1109/access.2019.2912200>
- SIRACUSANO, G., LA CORTE, A., GAETA, M., CICERO, G., CHIAPPINI, M., and FINOCCHIO, G., 2020. Pipeline for Advanced Contrast Enhancement (PACE) of Chest X-ray in Evaluating COVID-19 Patients by Combining Bidimensional Empirical Mode Decomposition and Contrast Limited Adaptive Histogram Equalization (CLAHE). *Sustainability*, 12(20), 8573. <https://doi.org/10.3390/su12208573>
- SOMERS, B., and BERTRAND, A., 2016. Removal of eye blink artifacts in wireless EEG sensor networks using reduced-bandwidth canonical correlation analysis. *Journal of Neural Engineering*, 13(6), 66008. <https://doi.org/10.1088/1741-2560/13/6/066008>

- SU, L., FU, X., and HU, Q., 2021. A convolutional generative adversarial framework for data augmentation based on a robust optimal transport metric. In 2021 IEEE 23rd Int Conf on High Performance Computing & Communications; 7th Int Conf on Data Science & Systems; 19th Int Conf on Smart City; 7th Int Conf on Dependability in Sensor, Cloud & Big Data Systems & Application (HPCC/DSS/SmartCit. IEEE. <https://doi.org/10.1109/hpcc-dss-smartcity-dependsys53884.2021.00178>
- SUN, G., WANG, F., CHEN, X., YU, X., MA, X., ZHOU, D., ZHU, R., and XU, B., 2016. Impact of Virtual and Augmented Reality Based on Intraoperative Magnetic Resonance Imaging and Functional Neuronavigation in Glioma Surgery Involving Eloquent Areas. *World Neurosurgery*, 96, 375–382. <https://doi.org/10.1016/j.wneu.2016.07.107>
- TEHRANI, M., 2020. What's the Difference Between All the Different Head Scans. THE BRAIN INJURY COMMUNITY. <https://doi.org/https://sdbif.org/whats-the-difference-between-all-the-different-head-scans/>
- TULAY, E. E., METIN, B., TARHAN, N., and ARIKAN, M. K., 2018. Multimodal Neuroimaging: Basic Concepts and Classification of Neuropsychiatric Diseases. *Clinical EEG and Neuroscience*, 50(1), 20–33. <https://doi.org/10.1177/1550059418782093>
- TURKOGLU, M., 2021. COVIDetectionNet: COVID-19 diagnosis system based on X-ray images using features selected from pre-learned deep features ensemble. *Applied Intelligence (Dordrecht, Netherlands)*, 51(3), 1213–1226. <https://doi.org/10.1007/s10489-020-01888-w>
- UDUPA, J. K., 1994. Three-dimensional imaging in biomedical computing: principles, algorithms, and systems. In *SPIE Proceedings*. SPIE. <https://doi.org/10.1117/12.185239>
- VIALATTE, F.-B., MAURICE, M., DAUWELS, J., and CICHOCKI, A., 2010. Steady-state visually evoked potentials: Focus on essential paradigms and future perspectives. *Progress in Neurobiology*, 90(4), 418–438. <https://doi.org/10.1016/j.pneurobio.2009.11.005>
- WALSH, P., KANE, N., and BUTLER, S., 2005. The clinical role of evoked potentials. *Journal of Neurology, Neurosurgery, and Psychiatry*, 76 Suppl 2(Suppl 2), ii16–ii22. <https://doi.org/10.1136/jnnp.2005.068130>
- WANG, C., DU, J., CHEN, G., WANG, H., SUN, L., XU, K., LIU, B., and HE, Z., 2019. QAM classification methods by SVM machine learning for improved optical interconnection. *Optics Communications*, 444, 1–8. <https://doi.org/10.1016/j.optcom.2019.03.058>
- WANG, C., SUN, F., XIA, Z., LI, Q., LI, J., HAN, B., and MA, B., 2023. Wavelet-FCWAN: Fast and Covert Watermarking Attack Network in Wavelet Domain. *Journal of Visual Communication and Image Representation*, 103875. <https://doi.org/10.1016/j.jvcir.2023.103875>
- WANG, L., and HE, Y., 2010. A New Web Service Ranking Method Based on QoS Independent Components and ANN. In 2010 International Conference on Computational Intelligence and Software Engineering. IEEE. <https://doi.org/10.1109/wicom.2010.5601461>
- WANG, S., KANG, B., MA, J., ZENG, X., XIAO, M., GUO, J., CAI, M., YANG, J., LI, Y., MENG, X., and XU, B., 2020. A deep learning algorithm using CT images

- to screen for Corona Virus Disease (COVID-19). Cold Spring Harbor Laboratory. <https://doi.org/10.1101/2020.02.14.20023028>
- WANG, S., ZHU, Y., YUE, L., and JI, Q., 2015. Emotion recognition with the help of privileged information. *IEEE Transactions on Autonomous Mental Development*, 7(3), 189–200. <https://doi.org/10.1109/TAMD.2015.2463113>
- WANG, T., LU, C., SUN, Y., YANG, M., LIU, C., and OU, C., 2021. Automatic ECG classification using continuous wavelet transform and convolutional neural network. *Entropy*, 23(1), 1–13. <https://doi.org/10.3390/e23010119>
- WANG, Y., WANG, Y., and JUNG, T.-P., 2011. A cell-phone-based brain–computer interface for communication in daily life. *Journal of Neural Engineering*, 8(2), 25018. <https://doi.org/10.1088/1741-2560/8/2/025018>
- WÓJCIK, G. M., WIERZGAŁA, P., and GAJOS, A., 2015. Evaluation of Emotiv EEG neuroheadset. *Bio-Algorithms and Med-Systems*, 11(4), 211–215. <https://doi.org/10.1515/bams-2015-0026>
- WOLPAW, J. R., BIRBAUMER, N., MCFARLAND, D. J., PFURTSCHELLER, G., and VAUGHAN, T. M., 2002. Brain–computer interfaces for communication and control. *Clinical Neurophysiology*, 113(6), 767–791. [https://doi.org/10.1016/s1388-2457\(02\)00057-3](https://doi.org/10.1016/s1388-2457(02)00057-3)
- WU, X., CHEN, C., ZHONG, M., WANG, J., and SHI, J., 2021. COVID-AL: The diagnosis of COVID-19 with deep active learning. *Medical Image Analysis*, 68, 101913. <https://doi.org/10.1016/j.media.2020.101913>
- XU, C., YANG, Y., and GAO, W., 2020. Skin-interfaced sensors in digital medicine: from materials to applications. *Matter*, 2(6), 1414–1445. <https://doi.org/10.1016/j.matt.2020.03.020>
- YANG, G., 2013. A Novel Method for Mining Association Rules from Continuous Attributes Based on Cultural Immune Algorithm. *Journal of Information and Computational Science*, 10(9), 2845–2853. <https://doi.org/10.12733/jics20102086>
- YANG, Q., LE BLOND, S., AGGARWAL, R., WANG, Y., and LI, J., 2017. New ANN method for multi-terminal HVDC protection relaying. *Electric Power Systems Research*, 148, 192–201. <https://doi.org/10.1016/j.epsr.2017.03.024>
- YANG, T., HAKIMIAN, S., and SCHWARTZ, T. H., 2014. Seminars in Epileptology indications , techniques , and utility in epilepsy surgery. 16(3), 271–279.
- YANG, X.-S., and DEB, S., 2009). Cuckoo Search via Lévy flights. 2009 World Congress on Nature & Biologically Inspired Computing (NaBIC), 210–214. <https://doi.org/10.1109/NABIC.2009.5393690>
- YANG, X.-S., and DEB, S., 2013. Multiobjective cuckoo search for design optimization. *Computers & Operations Research*, 40(6), 1616–1624. <https://doi.org/10.1016/j.cor.2011.09.026>
- YETISEN, A. K., MARTINEZ-HURTADO, J. L., UNAL, B., KHADEMHOSEINI, A., and BUTT, H., 2018. Wearables in Medicine. *Advanced Materials (Deerfield Beach, Fla.)*, 30(33), e1706910–e1706910. <https://doi.org/10.1002/adma.201706910>
- ZENG, H., 2018. Mesoscale connectomics. *Current Opinion in Neurobiology*, 50, 154–162. <https://doi.org/10.1016/j.conb.2018.03.003>
- ZHANG, Y., JI, X., and ZHANG, S., 2016. An approach to EEG-based emotion recognition using combined feature extraction method. *Neuroscience Letters*, 633, 152–157. <https://doi.org/10.1016/j.neulet.2016.09.037>

- ZHANG, Y., XIANG, M., and YANG, B., 2017. Graph regularized nonnegative sparse coding using incoherent dictionary for approximate nearest neighbor search. *Pattern Recognition*, 70, 75–88. <https://doi.org/10.1016/j.patcog.2017.04.030>
- ZHOU, Y., HUANG, S., XU, Z., WANG, P., WU, X., and ZHANG, D., 2022. Cognitive Workload Recognition Using EEG Signals and Machine Learning: A Review. *IEEE Transactions on Cognitive and Developmental Systems*, 14(3), 799–818. <https://doi.org/10.1109/tcds.2021.3090217>
- ZHU, J., ZHENG, W.-L., and LU, B.-L., 2015. Cross-subject and Cross-gender Emotion Classification from EEG. In *IFMBE Proceedings* (pp. 1188–1191). Springer International Publishing. https://doi.org/10.1007/978-3-319-19387-8_288
- ZHU, M., WANG, H., LI, S., LIANG, X., ZHANG, M., DAI, X., and ZHANG, Y., 2021. Flexible Electrodes for In Vivo and In Vitro Electrophysiological Signal Recording. *Advanced Healthcare Materials*, 2100646, 1–21. <https://doi.org/10.1002/adhm.202100646>