



T.C.
TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
MEKATRONİK MÜHENDİLİĞİ ANABİLİM DALI
MEKATRONİK MÜHENDİSLİĞİ DOKTORA PROGRAMI

DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK EEG
İŞARETLERİNDEN UYKU APNE SENDROMU TESPİTİ VE
SINIFLANDIRILMASI

DOKTORA TEZİ

Kübra TANCI

Danışman: Prof. Dr. Mahmut HEKİM

TOKAT- 2024

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre, Prof. Dr. Mahmut HEKİM danışmanlığında hazırlamış olduğum “Derin öğrenme yöntemleri kullanılarak EEG işaretlerinden uyku apne sendromu tespiti ve sınıflandırılması” adlı Doktora tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

12/01/2024

Kübra TANCI

TEŞEKKÜR

Bu çalışmanın her aşamasında bilgi ve önerileriyle beni yönlendiren, akademik tecrübelerini örnek aldığım danışman hocam sayın Prof. Dr. Mahmut HEKİM 'e,

Tez izleme komitemde bulunarak çalışmalarımı kıymetli fikirleriyle yönlendiren hocalarım Doç. Dr. Cem EMEKSİZ ve Doç. Dr. Levent GÖRKEM 'e, bölüm başkanımız Doç. Dr. Zafer DOĞAN başta olmak üzere tüm bölüm hocalarıma,

Bu süreçte bana sabır ve fedakârlık göstererek yardımcı olan sevgili eşim Raşit Sait TANCI 'ya, oğullarıma ve aileme sonsuz teşekkürlerimi sunarım.

Kübra TANCI
Ocak, 2024

ÖZET

DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK EEG İŞARETLERİNDEN UYKU APNE SENDROMU TESPİTİ VE SINIFLANDIRILMASI

Kübra TANCI

Doktora Tezi

Mekatronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Mahmut HEKİM

Ocak 2024, xvii + 56 sayfa

Bu çalışmada, derin öğrenme yöntemleri kullanarak Elektroensefalografi (EEG) işaretlerinden uyku apne sendromunun tespit ve sınıflandırılmasına odaklanılmaktadır. Polisomnografi (PSG) kayıtlarından alınan EEG işaretlerine tüm deneylerde kullanılmak üzere örnekleme, filtreleme, pencereleme, normalizasyon ve frekans altbandlarına ayrıştırma uygulanmıştır. Elde edilen EEG işaretlerinin altbandlarına temel istatistiksel parametreler uygulanarak öznitelik çıkarma işlemi gerçekleştirilmiştir. Bu öznitelikler çok katmanlı algılayıcı sinir ağı (MLPNN) modeline giriş olarak uygulanarak uyku apne sendromu sınıflandırması yapılmıştır. Normalizasyonun ve frekans altbandlarına ayrıştırmanın etkisini değerlendirmek için ham EEG işaretleri ve normalizeli işaretler aynı MLPNN modeli ile tekrar sınıflandırılmıştır. Normalizasyonun sınıflandırma başarısında ciddi bir artış sağlamadığından normalizeli işaretler, frekans altbandlarına ayrıştırılarak öznitelik çıkarma işlemi tekrarlanmış ve aynı MLPNN modeli ile sınıflandırılmıştır. Normalize edilerek frekans altbandlarına ayrıştırma, sınıflandırma başarısını önemli derecede artırmıştır. Diğer bir çalışmada, EEG işaretlerinin spektrogramlarının entropisi MLPNN modeline giriş olarak uygulanmıştır. Her sınıfta başarı artışı gözlemlenmiş fakat şiddetli apne sınıfının başarı oranının en yüksek olduğu görülmüştür. Başka bir deneyde, MLPNN dışında literatürde sıklıkla kullanılan derin öğrenme modellerinden evrimsel sinir ağı (CNN) modeli kullanılmıştır. İki ayrı deneysel çalışma olarak, EEG işaretlerinin ham görüntüleri ve spektrogramları bu modele giriş olarak uygulanmış ve uyku apne sendromu sınıflandırması yapılmıştır. Ön işlem ve öznitelik çıkarımı gerektirmeyen bu sınıflandırma modelinde, spektrogramlarla yapılan deney sonucunda başarı oranı daha yüksek bulunmuştur. Çalışmanın son deneyi olarak, YOLOv5 ve YOLOv8 modelleri ile de uyku apne sendromu sınıflandırması yapılmıştır. Bu sınıflandırmalar için pencerelenen EEG işaretlerinin spektrogramları kullanılmıştır.

İşlem hızının yüksek olması, katman ve parametre sayısının az olması ve yüksek sınıflandırma başarısı vermesi nedeniyle YOLOv8 modelinin performansı, YOLOv5 modeline göre daha yüksek çıkmıştır.

Anahtar Kelimeler: EEG, uyku apnesi, spektrogram, entropi, MLPNN, derin öğrenme, YOLO.



ABSTRACT

DETECTION AND CLASSIFICATION OF SLEEP APNEA SYNDROME FROM EEG SIGNALS USING DEEP LEARNING METHODS

Kübra TANCI

PhD Thesis

Department of Mechatronics Engineering

Advisor: Prof. Dr. Mahmut HEKİM

January 2024, xvii + 56 pages

This study is focused on the detection and classification of sleep apnea syndrome from Electroencephalography (EEG) signals using deep learning methods. Sampling, filtering, windowing, normalization and frequency subbanding were processed on EEG signals from Polysomnography (PSG) recordings for using in all experiments. Feature extraction was performed by applying basic statistical parameters to the subbands of the obtained EEG signals. These features were applied as input to a multilayer perceptron neural network (MLPNN) model for sleep apnea syndrome classification. To evaluate the effect of normalization and frequency subband segmentation, the raw EEG signals and normalized signals were reclassified by using the same MLPNN model. The normalization results in less significant increase in classification success, so the normalized signals were segmented into frequency subbands, the feature extraction process was repeated and classified by using the same MLPNN model. Normalization and frequency subband segmentation significantly improved the classification success. In another experiment the entropy of spectrograms were applied as input to the MLPNN model. In each class, an increase in success was observed, but the success rate of the severe apnea class was the highest. In another experiment, a convolutional neural network (CNN) model, one of the deep learning models frequently used in the literature, was used in addition to MLPNN. In two different experimental studies, images and spectrograms of EEG signals were applied as input to this model and sleep apnea syndrome classification was performed. In this classification model which does not require preprocessing and feature extraction, the success rate was higher as a result of the experiment with spectrograms. As the last experiment of the study, sleep apnea syndrome classification was performed by using YOLOv5 and YOLOv8 models. For these classifications, spectrograms of windowed EEG signals were used. The performance of

the YOLOv8 model was higher than the YOLOv5 model because of its high processing speed, less number of layers and parameters and high classification success.

Keywords: EEG, sleep apnea, spectrogram, entropy, MLPNN, deep learning, YOLO.



İÇİNDEKİLER

Sayfa

TEŞEKKÜR.....	iii
ÖZET	iv
ABSTRACT.....	vi
İÇİNDEKİLER	viii
ŞEKİLLER LİSTESİ	x
TABLolar LİSTESİ.....	xii
SİMGE VE KISALTMALAR	xiv
1. GİRİŞ.....	1
2. KURAMSAL TEMELLER.....	3
2.1. Uyku Apne Sendromu	3
2.1.1 Obsrükatif uyku apnesi (OSA)	3
2.1.2. Santral uyku apnesi (CSA)	4
2.1.3. Mikst uyku apnesi (MSA).....	4
2.2. Polisomnografi (PSG).....	5
2.3. Elektroansefalogram (EEG) İşaretleri	7
2.4. Sınıflandırma Yöntemleri	7
2.4.1. Çok katmanlı algılayıcı sinir ağı (MLPNN)	7
2.4.2. Evrişimsel sinir ağı (CNN)	9
2.4.3. You only look once (YOLO)	11
3. LİTERATÜR ÖZETLERİ.....	15
4. MATERYAL ve YÖNTEM	19
4.1. Veri Seti.....	19
4.2. Önışleme	20

4.1.1. Örnekleme.....	20
4.1.2.Filtreleme	20
4.1.3.Pencereleme	21
4.1.5. Frekans altbandlarına ayırıştırma.....	22
4.3. Spektrogram	24
4.4. Öznitelik Çıkarımı	25
4.5. Sınıflandırma	26
4.6. Performans değerlendirme metrikleri.....	27
5. BULGULAR VE TARTIŞMA.....	29
5.3. MLPNN modeli kullanılarak gerçekleştirilen sınıflandırmalar.....	29
5.4. CNN modeli kullanılarak gerçekleştirilen sınıflandırmalar	41
5.5. YOLO modeli kullanılarak gerçekleştirilen sınıflandırmalar.....	43
6. SONUÇ ve ÖNERİLER	51
7. KAYNAKLAR.....	52

ŞEKİLLER LİSTESİ

Sayfa

Şekil 2.1 OSA test grafiği	3
Şekil 2.2 CSA test grafiği	4
Şekil 2.3 MSA test grafiği	5
Şekil 2.4 Örnek bir PSG kaydı.....	5
Şekil 2.5 Elektrotların konumu	6
Şekil 2.6 10-20 elektrot sisteminin üstten ve yandan yerleşimi	7
Şekil 2.7 MLPNN mimarisi	8
Şekil 2.8 CNN'in genel mimarisi	9
Şekil 2.9 Evrişim işlemi.....	9
Şekil 2.10 Maksimum havuzlama örneği	10
Şekil 2.11 YOLO sinir ağı mimarisi.....	11
Şekil 2.12 YOLOv5 mimarisi.....	12
Şekil 2.13 YOLOv8 mimarisi.....	13
Şekil 4.1 Örnek EEG işaretleri	19
Şekil 4.2 IIR Butterworth BpF gösterimi	20
Şekil 4.3 Filtreli EEG işaretleri.....	21
Şekil 4.4 Normalizeli EEG işaretleri	22
Şekil 4.5 Frekans altbandlarına ayrıştırılmış EEG işareti.....	23
Şekil 4.6 EEG işaretleri ve spektrogramları (a) hafif (b) orta (c) şiddetli (d) sağlıklı....	24
Şekil 5.1 Deney 1'e ait ROC analizi.....	30
Şekil 5.2 Deney 2'ye ait ROC analizi.....	32
Şekil 5.3 Deney 3-a'ya ait ROC analizi.....	34
Şekil 5.4 Deney 3-b'ye ait ROC analizi	36
Şekil 5.5 Deney 3-c'ye ait ROC analizi.....	38

Şekil 5.6 Deney 3’e ait Acc değerleri	38
Şekil 5.7 Deney 4’e ait ROC analizi.....	41
Şekil 5.8 YOLOv5 ve YOLOv8 modellerine ait eğitim ve test kayıpları	44
Şekil 5.9 Deney 6-a’ya ait ROC analizi.....	46
Şekil 5.10 Deney 6-b’ye ait ROC analizi	47



TABLolar LİSTESİ

Sayfa

Tablo 2.1 OSA tipleri.....	4
Tablo 2.2 Sınıflandırma fonksiyonları.....	11
Tablo 4.1 EEG işaretlerinin sınıf, AHI ve süre bilgileri.....	19
Tablo 4.2 EEG frekans altbandları	23
Tablo 4.3 Kullanılan istatistiksel parametreler	25
Tablo 4.4 İkili sınıflandırma için karışıklık matrisi	28
Tablo 5.1 Deney1'e ait karışıklık matrisleri	29
Tablo 5.2 Deney 1'e ait geçerlik sonuçları	30
Tablo 5.3 Deney 2'ye ait karışıklık matrisi ve geçerlik sonuçları	31
Tablo 5.4 Deney 3-a'ya ait karışıklık matrisleri ve geçerlik ölçütleri	33
Tablo 5.5 Deney 3-b'ye ait karışıklık matrisleri ve geçerlik ölçütleri.....	35
Tablo 5.6 Deney 3-c'ye ait karışıklık matrisleri ve geçerlik ölçütleri	37
Tablo 5.7 Deney 4'e ait karışıklık matrisleri ve geçerlik ölçütleri	39
Tablo 5.8 Deney 5-a'ya ait sınıflandırma sonuçları	42
Tablo 5.9 Deney 5-b'ye ait sınıflandırma sonuçları	42
Tablo 5.10 Deney 6'ya ait eğitim sonuçları.....	43
Tablo 5.11 Deney 6-a'ya ait sınıflandırma sonuçlar.....	45
Tablo 5.12 Deney 6-a'ya ait karışıklık matrisleri	45
Tablo 5.13 Deney 6-b'ye ait sınıflandırma sonuçları	46
Tablo 5.14 Deney 6-b'ye ait karışıklık matrisleri.....	47
Tablo 5.15 Deney 1'e ait Acc değerleri	48
Tablo 5.16 Deney 2'ye ait Acc değerleri	48
Tablo 5.17 Deney 3'e ait Acc değerleri	48
Tablo 5.18 Deney 4'e ait Acc değerleri	49

Tablo 5.19 Deney 5'e ait Acc deęerleri.....	49
Tablo 5.20 Deney 6'ya ait Acc deęerleri.....	49



SİMGE VE KISALTMALAR

Simgeler	Açıklama
f_L	alt kesim frekansı
f_H	üst kesim frekansı
f_0	merkez frekansı
x_i	girdi değeri
σ^2	varyans
μV	mikrovolt
f	frekans
w	açısal hız
p_i	normalize enerji
k	penceredeki örnek sayısı
μ	standart sapma
$x[n]$	ayrık işaret
$X(k)$	ayrık işaretin Fourier dönüşümü
$x(t)$	sürekli işaret
$X(w)$	sürekli işaretin Fourier dönüşümü

Kısaltmalar	Açıklama
PSG	Polisomnografi
EEG	Elektrosefalografi
AHI	Apne-hipoapne indeksi
ANN	Yapay sinir ağı
DWT	Ayrık dalgacık dönüşümü
MUSIC	Çoklu işaret sınıflandırma

TEO	Teager enerji operatörü
SVM	Destek vektör makinesi
OSAS	Obstrüktif uyku apne sendromu
KNN	k en yakın komşu sınıflandırma
CNN	Evrişimsel sinir ağı
LSTM	Uzun-kısa süreli bellek
UWB	Ultra ağırlık bandı
MILBP	Çok kanallı bilgi yerel ikili modeli
OSA	Obstrüktif uyku apnesi
HI	Hipoapne indeksi
AI	Apne indeksi
CSA	Santral uyku apnesi
MSA	Merkezi uyku apnesi
EKG	Elektrokardiyografi
EMG	Elektromiyografi
EOG	Elektrookulografi
Hz	Hertz
IIR	Sonsuz impulslu yanıt
BpF	Band geçiren filtre
FT	Fourier dönüşümü
DFT	Ayrık Fourier dönüşümü
STFT	Kısa zamanlı Fourier dönüşümü
FFT	Hızlı Fourier dönüşümü
Acc	Toplam doğru sınıflandırma
TP	Doğru pozitif
TN	Doğru negatif
FP	Yanlış pozitif
FN	Yanlış negatif
ROC	Alıcı işlem karakteristiği
MLPNN	Çok katmanlı algılayıcı sinir ağı
YOLO	You only look once
CSP	Çapraz aşama kısım ağı

SPP	Uzaysal piramit havuzlama
Conv	Konvolüsyon
Concat	Birleştirme
SiLU	Sigmoid ağırlıklı doğrusal birim
CloU	Kapalı döngü çıkış birimi
K	Basıklık
S	Çarpıklık
ME	Ortalama enerji
LE	Log enerji entropisi
SE	Shannon entropisi

1. GİRİŞ

Uyku apne sendromu, uykuda yaşanan bir sağlık sorunu olup uyku esnasında solunumun 10 saniyeden 1 dakikaya kadar durması durumudur ve bu olay gece boyunca 5 defaya kadar yaşanabilmektedir. Uyku esnasında hava akımının %50 oranında düşmesine hipoapne denilmektedir (Çiçek, 2021). Uyku apnesi yaş, cinsiyet ve kilodan bağımsız olarak, boğazdaki dokuların büyük olması, dolaşım ve sinir sistemindeki bazı bozukluklar, alkol ve sigara tüketimi gibi durumlarda artış gösterebilir. Uyku esnasında meydana gelen ve sebebi açıklanamayan ani ölümler uyku apnesi sonucu gelişebilmektedir.

Uyku apne sendromunun doğru tespit edilmesi tedavi sürecinin verimliliği bakımından önemlidir. Tanısı, gece boyunca uyku laboratuvarlarında hastalardan alınan kayıtlarla konulabilmektedir. Elde edilen verilerle uyku apnesinin türü, sıklığı ve seviyesi hakkında yorum yapılabilmektedir. Uyku apne sendromunu tespit süresi zaman alıcı olduğundan, bu çalışmada daha pratik ve verimli bir yöntem önerilmektedir. Elektroansefalogram (EEG) işaretleri kullanılarak uyku apne sendromu tespit ve sınıflandırılması üzerinde durulmuştur.

Bu çalışmada, uyku apne sendromu tespit ve sınıflandırmasında sıklıkla kullanılan ve başarı oranı yüksek olan EEG işaretleri tercih edilmiştir. Çalışmada kullanılan EEG işaretleri bilimsel araştırmalara açık olan Pysionet veri tabanından alınmıştır (PhysioBank ATM (physionet.org)). Uyku apne teşhisi hekimler tarafından konulmuş, farklı apne-hipoapne indeks (AHI) değerlerine sahip hastalara ait işaretler uyku apne sendromu sınıflandırması için kullanılmıştır. Vücudun birçok yerine elektrot takılarak alınan Polisomnografi (PSG) kayıtları yerine sadece kafatası üzerine yerleştirilen elektrotlarla EEG ölçümleri yapılarak uyku apne sendromu teşhisi yapılabilirliğinin araştırması olarak bu çalışma yapılmıştır. Kullanılan sınıflandırma yöntemleri, daha önce örneğine rastlanılmış fakat uyku apne sendromu tespit ve sınıflandırmasında kullanılmamış yöntemlerdir. Uyku apne sendromu tespit ve sınıflandırma çalışmalarında spektrogram tabanlı entropini kullanılması ve spektrogramların derin öğrenme modelleriyle sınıflandırılması ilk defa bu çalışmada kullanılmaktadır.

Bu tez altı bölümden oluşmaktadır. Birinci bölüm “Giriş” bölümüdür ve uyku apne sendromu hakkında genel bilgiler verilerek tez içeriğinden bahsedilmiştir. İkinci bölüm “Kuramsal Temeller” bölümüdür. Bu bölümde uyku apne sendromunun genel tanımı, çeşitleri açıklanarak teşhis yöntemi olan PSG’den bahsedilmiştir. PSG kayıtlarında yer alan ve uyku apne sendromu teşhisinde en başarılı sonuçların alındığı EEG işaretleri hakkında genel bilgiler verilmiştir. Üçüncü bölüm ‘Literatür Özetleri’ bölümüdür. Bu bölümde uyku apne sendromuyla ilgili yapılmış olan çalışmalardan, EEG işaretinin uyku apne sendromu tespit ve sınıflandırmasına olan katkılarından bahsedilmiştir. Dördüncü bölüm olan “Materyal ve Yöntem” bölümünde ise çalışmada kullanılan EEG işaretleri, işaret işlemede kullanılan ön işlemler ve sınıflandırma yöntemleri hakkında bilgiler verilmiştir. Beşinci bölüm “Bulgular ve Tartışma” bölümünde ise yapılan tüm deneysel çalışmalara ait çizelge, sonuç, grafik bilgileri verilerek başarı oranları detaylı şekilde yorumlanmıştır. Son bölüm olan “Sonuç” bölümünde ise çalışmanın kazanımlarından bahsedilerek çıkarımlar yapılmıştır.


2. KURAMSAL TEMELLER

2.1. Uyku Apne Sendromu

Apne kelimesi Yunanca kökenli olup ‘soluksuz kalmak’ anlamına gelmektedir. Uyku esnasında 10 saniye ile 1 dakika arası soluksuz kalma durumu uyku apne sendromu olarak tanımlanmaktadır. Genel olarak her yaşta ve cinsiyette görülebilen, tedavi gerektiren bir sağlık sorunudur (Karamustafaoğlu, 2014). Uyku apne sendromu meydana geliş şekillerine göre üç türe ayrılmaktadır (Papila ve ark., 2005).

2.1.1 Obsrükatif uyku apnesi (OSA)

Obstrüktif uyku apnesi, üst solunum yollarında özellikle gırtlakta doku sarkması nedeniyle uyku esnasında solunum yolunun tıkanmasına bağlı olarak ortaya çıkmaktadır. En sık karşılaşılan uyku apne çeşididir (Karamustafaoğlu, 2014). Oksijen bu durumda beyine az gidecektir ve beyin, oksijen sağlamak amacıyla kişiyi uyandırmak isteyecektir. OSA olan kişilerin derin uykuya geçmesi mümkün değildir. Bir OSA hastasına ait test grafiği Şekil 2.1’de verilmektedir.



Şekil 2.1 OSA test grafiği

Şekil 2.1’de görüldüğü gibi mavi şeritte sınırlı göğüs ve karın hareketlerinin olduğu durumda solunum da durmaktadır. OSA tipleri AHI değerlerine göre belirlenmektedir. Solunumun %50’nin altına düştüğü ve oksijen doymunluęunda %3 azalma olduğu durumlara hipoapne denmektedir. Uyku süresince meydana gelen apnelerin saatlik ortalaması apne indeksi (AI) olarak adlandırılır. Hipoapne indeksi (HI) ise uyku esnasında oluşan hipoapnelerin saatlik ortalamasıdır. AHI ise uyku boyunca meydana gelen toplam apne ve hipoapnelerin oranıdır (Çiçek, 2021). AHI değerlerine göre OSA tipleri Tablo 2.1’de verilmektedir.

Tablo 2.1 OSA tipleri

Sınıf	AHI değeri
Sağlıklı	5'den küçük
Hafif	5-15 arası
Orta	15-30 arası
Şiddetli	30'dan fazla

Tablo 2.1'de görüldüğü gibi AHI değeri 5'den küçük olan bireyler sağlıklı sınıfındadır. 5-15 arası hafif apneli, 15-30 arası orta apneli ve 30'dan büyük ise şiddetli apne sınıfında kabul edilmektedir.

2.1.2. Santral uyku apnesi (CSA)

Santral (merkezi) uyku apnesi, en nadir olarak görülen apne çeşididir. Beynin solunum sağlayan kaslara yeterince oksijen gönderemediği durumlarda ortaya çıkar. Kandaki oksijen miktarı giderek azaldığından sık sık uyanma durumu görülür. Genellikle yeni doğmuş bebeklerde ve kalp rahatsızlığı olan kişilerde görülür (Aydoğan, 2023). Şekil 2.2'de CSA durumunda elde edilen test kayıtları verilmektedir (Öter, 2016).




Şekil 2.2 CSA test grafiği

Şekil 2.2'de görüldüğü gibi hava akışında kesilme gerçekleşmiştir fakat küçük titreşimlerle hasta soluk almaya çalışmaktadır. Nefes alma olayı sinirsel olarak mümkün olmadığından hasta apneye girmiş durumdadır.

2.1.3. Mikst uyku apnesi (MSA)

Mikst (bileşik) apne, obstrüktif apne ile merkezi apnenin bileşimi olduğundan bu ismi almaktadır. Başlangıçta OSA gibi davranıp uyku boyunca CSA gibi seyreden bir apne çeşididir ve bu apneye ait test kayıtları Şekil 2.3'te verilmektedir (Öter, 2016).




Şekil 2.3 MSA test grafiği

Şekil 2.3'te görüldüğü gibi, OSA gibi başlayan apne sonrasında küçük titreşimlerle nefes almada zorlanmalar yaşanmakta ve CSA gibi davranış göstermektedir.


2.2. Polisomnografi (PSG)

Polisomnografi, uyku apnesi teşhisi yapmak amacıyla uyku laboratuvarlarında gece boyunca hastalardan alınan fiziksel ve fizyolojik aktivitelerin sayısala dönüştürülüp kaydedilmesidir (Akşahin, 2010). PSG ilk olarak EEG işaretlerinden uyku evrelerini tespit eder. Daha sonra solunum kayıtları kullanılarak tıkanma olup olmadığına ve kandaki oksijen miktarına bakılır. Alınan bu bilgiler uyku esnasında kaydedilen vücut pozisyonu, Elektrokardiyografi (EKG), Elektrokülografi (EOG) ve Elektromiyografi (EMG) gibi verilerle birleştirilerek bir sonuç raporu elde edilir. Bir PSG kaydına ait grafik Şekil 2.4'te verilmektedir (Çiçek, 2021).



Şekil 2.4 Örnek bir PSG kaydı

Şekil 2.4'te görüldüğü gibi, bir PSG kaydı EEG, EKG, EOG, EMG, vücut pozisyonu, ağız ve burundaki hava sirkülasyonu, burun hava basıncı, göğüs ve karın hareketleri, oksijen satürasyonu, nabız geçiş süresi, horlama ve solunum sesleri gibi birçok parametre hakkında bilgi vermektedir. Uyku apne sendromu sınıflandırmasında PSG kayıtlarındaki en başarılı sonuç veren parametre EEG olduğundan EEG işaretleri tercih edilmiştir. PSG kayıtları hastanın vücudunun değişik yerlerine elektrotların bağlanmasıyla elde edilir. Elektrotların konumu Şekil 2.5'te verilmektedir (Özol, 2013).



Şekil 2.5 Elektrotların konumu

Şekil 2.5'te görüldüğü gibi elektrotlar kafatası üzerinde yoğunlaşmıştır. Saçlı deride sürtünmeyi azaltmak için uygulamadan önce jel kullanılarak kayıtlar alınır. Merkezi sinir sisteminden uzak bir referans noktası seçilerek kaydedilen elektriksel potansiyeller unipolar kayıt olarak adlandırılırken yakın iki bölge arasındaki elektriksel potansiyel kayıtları da polar kayıt olarak adlandırılır (Akşahin, 2010).


Uyku apne sendromu, tanısı konulduktan sonra tedavisi mümkün olan bir hastalıktır. Uyku apne sendromunun tanısı hekim tarafından uyku laboratuvarlarında alınan PGS kayıtlarına göre konulmaktadır. Gece boyunca vücudun farklı yerlerine elektrotlar takılarak alınan bu kayıtlarda uyku apne-hipoapne durumları, apnenin süresi ve türü hakkında bilgi edinilebilir. Uyku apnesi hastalarının sayısı giderek arttığından ve teşhis için hastaların uyku laboratuvarlarında gece boyunca kalmaları zaman alıcı ve zahmetli

bir işlem olduğundan dolayı bu tezde uyku apne tespitini kolaylaştıracak ve zaman almasını önlemeye yardımcı olması açısından EEG işaretleri kullanılarak uyku apne sendromu tespit ve sınıflandırması amaçlanmıştır.

2.3. Elektroansefalogram (EEG) İşaretleri

EEG işaretleri beyin yüzeyinden elektrotlarla alınan düşük genlikli biyolojik işaretlerdir. Bu işaretlerin düşük genlikli olması insan beyninde saklı olan bilgileri tamamen elde etmeyi zorlaştırmaktadır. Son zamanlarda bilgisayarlarda bu bilgileri işlemek ve analiz etmek kullanışlı hale gelmiş olup epilepsi, şizofreni ve Parkinson gibi birçok hastalığın teşhisinde kolaylık sağlamaktadır (Yörük, 2019).

EEG işaretleri genel olarak 10-20 elektrot yerleşim sistemine göre kaydedilmektedir ve genellikle 8 veya 16 kanallı EEG çekimi kullanılmaktadır. Elektrot yerleşimlerinin yandan ve üstten görünüşleri Şekil 2.6'da verilmektedir (Karamustafaoğlu, 2014).




Şekil 2.6 10-20 elektrot sisteminin üstten ve yandan yerleşimi

2.4. Sınıflandırma Yöntemleri

2.4.1. Çok katmanlı algılayıcı sinir ağı (MLPNN)

Çok katmanlı algılayıcı sinir ağı yapısal olarak doğrusal olmayan, aktivasyon fonksiyonuna sahip birçok nöronun birleşiminden oluşur. Giriş katman, gizli katman ve çıkış katmanı olarak üç kısımdan oluşan ileri beslemeli bir ağ yapısına sahiptir. Giriş katmanı bilgi girişinin yapıldığı katmandır. Eğitim sırasında hesaplamaların yapıldığı katmanlar kullanıcıya erişim sağlamadığından gizli katman olarak adlandırılır. Giriş katmanından alınan veriler gizli katmanda işlenerek çıkış katmanına iletilir. Gizli katmanda yer alan nöronların sayısı kullanıcı tarafından belirlenebilmektedir. Yanlış ya

da aşırı eğitime sebep olmaması açısından deneme yanılma yoluyla nöron sayısı belirlenebilmektedir (Übeyli,2008). Gerçekleştirilen deneylerde 1 girişli, 10 nörona sahip 1 gizli katmanlı ve 1 çıkışlı bir MLPNN mimarisi kullanılmıştır. Dörtlü sınıflandırma yapılırken ise çıkış sayısı dört olarak başka bir model kullanılmıştır. Şekil 2.7’de genel bir MLPNN modeli verilmektedir.



Şekil 2.7 MLPNN mimarisi


Şekil 2.7’de görüldüğü gibi her bir j nöronu w_{μ} bağlantı ağırlığıyla giriş işaretlerinin çarpımlarının toplamını alarak y_j çıkış fonksiyonunu üretir. Eşitlik 2.1’de verilen f fonksiyonu nörona etki eden işaretlerin ağırlık toplamını çıkışa iletmektedir.

$$y_j = f \left(\sum w_{\mu} x_i \right) \quad (2.1)$$

MLPNN modelinde eğitime ne zaman son verileceğinin çapraz geçerlilik hatası belirler. Hata artmaya başladığı zaman model en iyi çözüme ulaşmış demektir. Aktivasyon fonksiyonu olarak sigmoid ya da hiperbolik tanjant fonksiyonu seçilebilir. Geri yayılım algoritması bir MLPNN modeli için en iyi bilinen eğitim algoritması olmasının yanı sıra yetersiz kapsama hızına sahiptir. Bu sorunun giderilmesi amacıyla Levenberg–Marquardt (LM) geriye yayılım algoritması kullanılmaktadır (Orhan,2010). Bu çalışmada kullanılan MLPNN modeli LM algoritması ile eğitilmiştir.

2.4.2. Evrişimsel sinir ağı (CNN)


Girdi verisini çeşitli katmanlarla işleyen ve bu sayede öznetelikleri otomatik tespit eden bir sinir ağı modelidir. Klasik makine öğrenmesi yöntemlerinde öznetelik hesaplanması zaman alan ve tecrübe gerektiren bir işlemdir. Yerel zaman dilimlerine uygulanan, tekrarlayan filtreler veya çekirdekler içeren karmaşık bir derin öğrenme modelidir (Nazlı,2021). Temel bir CNN mimarisi Şekil 2.8’de verilmektedir.



Şekil 2.8 CNN'in genel mimarisi


- *Girdi katmanı:* Giriş verisinin direk kullanıldığı katmandır. Herhangi bir ön işleme gerek kalmadan veri ham haliyle girdi katmanına verilir. Burada girdi boyutu önem kazanmaktadır. Çok büyük ya da çok küçük boyutlarda seçilen girdiler başarıyı olumsuz yönde etkileyecektir.

- *Evrişim (konvolüsyon) katmanı:* Görseller aslında içerisinde piksellerden oluşan matrisler barındırmaktadır. Evrişim katmanında da orijinal görüntüden daha küçük bir filtre görselin üzerinde gezer ve bazı özellikler yakalamaya çalışır. Yatay ve dikey hareket eden bu filtrenin değerleri bir matriste depolanır. Bu matrise özellik ya da aktivasyon haritası denmektedir (Nasıfoğlu, 2022). Bu işleme ait görsel Şekil 2.9’da verilmektedir.



Şekil 2.9 Evrişim işlemi



- *Havuzlama (pooling) katmanı:* Aktivasyon haritasının boyutunu ve ağ parametrelerinin sayısını azaltmak amacıyla havuzlama yapılmaktadır. İki türlü yapılabilir. Filtrenin kapladığı alandaki en büyük değerler alınıp havuzlama yapılıyorsa maksimum havuzlama, ortalama değerler alınıp havuzlama yapılıyorsa ortalama havuzlama adını almaktadır (Özcan, 2020).



Şekil 2.10 Maksimum havuzlama örneği

- *Tam bağlantı (fully connected) katmanı:* Giriş verisi sinir ağlarıyla eğitilebilecek özelliklere geldiğinde tam bağlantı katmanına verilir. Burada düğün özellikleri ve ağırlıklar tutularak öğrenme süreci başlamış olmaktadır. İçerdiği parametre sayısı fazla olduğundan yüksek işlem gücü gerektirmektedir. Bundan önceki katmanlarda elde edilen iki boyutlu aktivasyon haritası düzleştirme işlemi ile vektöre dönüştürülür.
- *Sınıflandırma katmanı:* Tam bağlantı katmanından sonra gelen, sınıflandırmanın yapıldığı son katmandır. Sigmoid ve softmax gibi fonksiyonlar kullanılarak olasılık hesaplanır. Bu katmanda çıktı değeri sınıf sayısı kadar olmalıdır. Çıktıda sınıf sayısı kadar olasılık elde edilir ve en yüksek değer hangi sınıf için verilmişse girdi verisi o sınıfa atanır (Nasıfoğlu, 2022). Sigmoid ve softmax fonksiyonlarına ait bilgiler Tablo 2.2’de verilmektedir.

Tablo 2.2 Sınıflandırma fonksiyonları

Sigmoid	$F(z)_i = \frac{1}{1 + e^{-z_i}}$	
Softmax	$F(z)_i = \frac{e^{z_i}}{\sum_{i=1}^K e^{z_i}}$	

z : girdi vektörü


i : girdi vektörünün her bir elemanı

$F(z)$: çıkış olasılığı

K : vektördeki sınıf sayısı

2.4.3. You only look once (YOLO)

YOLO modeli, CNN kullanarak nesne tespiti ve sınıflandırması yapan algoritmaların en popüleridir. Görüntü ve videolardaki nesneleri tek seferde ve hızlı bir şekilde tespit edebilmektedir. Görüntü sadece bir kez ağ içinden geçip görevini tamamladığından “You Only Look Once” adı verilmiştir (Kırca, 2021). YOLO mimarisi girdi görüntüsünü öncelikle belirli bölgelere ayırmakta ve her bölgedeki nesneleri belirleyen güven skoru oluşturmaktadır. Ayırdığı bölgelere ait sınır değerleri ve nesnenin boyutu güven skorunda saklıdır. YOLO sinir ağı mimarisi Şekil 2.11’de verilmektedir.




Şekil 2.11 YOLO sinir ağı mimarisi

Kaydedilen bu özellikler baş kısmında sınıflandırma etiketi olarak kullanılır. Baş katmanında evrişim yapılmakta ve hedef değerlerine göre sınıf tahmin değerleri hesaplanmaktadır (Aydın, 2023).

YOLOv8

YOLOv8 modeli, YOLO ailesine ait nesne tespiti modellerinin en son sürümüdür. YOLOv8, YOLOv5 modelin geliştirilmiş bir versiyonudur ve performansını artırmak için daha gelişmiş özellikler ve optimizasyonlar eklemiştir. YOLOv8 mimarisinin üç ana bileşeni vardır: omurga, boyun ve baş (Resi, 2023). YOLOv8 mimari yapısı Şekil 2.13'te verilmektedir.



Şekil 2.13 YOLOv8 mimarisi

Şekil 2.13'te görüldüğü gibi CSPDarknet53 yapısını temel alan bu mimari, C2f modülü, SPPF katmanı, grup normalizasyonu ve SiLU etkinleştirme gibi yenilikler içermektedir. Ayrıca, nesne varlığı, sınıflandırma ve regresyon görevlerini ayrı ayrı ele alan bir baş modeli bulunmaktadır. YOLOv8 mimarisi, çıktı katmanında sigmoid ve softmax fonksiyonlarını kullanarak nesne varlığı ve sınıf olasılıklarını hesaplamaktadır. Algılama doğruluğunu artırmak amaçlı sınırlayıcı kutu ve sınıflandırma kayıpları için CIOU, DFL ve ikili çapraz entropi yöntemlerini kullanmaktadır (Resi, 2023). Omurga, girdi görüntüsünden özellik çıkarmak için kullanılır. CSPDarknet53, önceki versiyonlara göre modelin parametre sayısını azaltır ve katmanlar arasındaki bilgi akışını artırır. Boyun, omurga tarafından çıkarılan özellikleri birleştirir ve YOLOv8 modelinin farklı ölçeklerde ve en-boy oranlarında nesneleri tespit etmesini sağlar. Baş, girdi görüntüsündeki

nesnelerin konumunu ve sınıfını tahmin eden bir bileşendir ve sınıflandırması zor örnekler için daha yüksek ağırlıklar atayarak modelin performansını etkiler. Yeniden işlem aşamasında, baş tarafından tahmin edilen nesnelerin konumu ve sınıfı, düşük güvenilirlikli ve örtüşen tespitleri elemek için işlenir. Ayrıca, eğitim verilerinin çeşitliliğini artırmak ve modelin genelleme yeteneğini geliştirmek için rastgele kırpma, ölçekleme ve yansıtma gibi veri artırma teknikleri kullanılır (Alsamurai, 2023).



3. LİTERATÜR ÖZETLERİ

Uyku apne sendromu tespit ve sınıflandırılması amacıyla yapılan birçok çalışmada EEG işaretleri belirleyici olmuştur. Apne öncesi, apne esnası ve apne sonrasında incelenmesi, uyku skorlanması, sağlıklı ve hasta bireylerin sınıflandırılması gibi birçok çalışmada EEG işaretlerinden faydalanılmıştır. Yapılan bu çalışmalar genel olarak PSG kayıtlarından EEG işaretlerinin alınması, özniteliklerinin çıkarılması, belirleyici olan özniteliklerle farklı modellerde sınıflandırma yapılmasına dayanmaktadır.

Szilagy ve ark., (2002), EEG işaretlerini çoklu çözünürlük dalgacık ayrışımı yöntemiyle farklı spektral bileşenlere ayırarak yapay sinir ağı (ANN) modeline giriş olarak uygulamış ve uyku apne sınıflandırmada başarı oranı % 95 elde etmiştir (Szilagy ve ark., 2002).

Kıymık ve ark., (2004), EEG işaretlerinin altbandlarına ayırmak için ayrık dalgacık dönüşümü (DWT) yöntemini kullanmış ve uyku, uyanık ve uykulu durumların tespitinde ANN modeli geliştirmiş ve sırasıyla %96, %95 ve %94 başarıya ulaşmıştır (Kıymık ve ark., 2004).

Acır ve ark., (2004), EEG işaretlerini otomatik olarak tanımak için ANN temelli bir sistem önermiştir. Deneysel çalışmalarda %94.6 özgüllük oranı ve %4 hata oranı elde etmişlerdir (Acır ve ark., 2004).

Erdamar 2007 yılındaki çalışmasında PSG kayıtlarından uyku apne teşhisi için başarılı bir yöntem geliştirmiştir. Uyku esnasında meydana gelen ilk apnenin öngörülmesi deneklerin %60'ından fazlasında başarı ile gerçekleştirilmiştir. Fakat çoğu hastada ilk apnenin oluşmasından sonra, sık olarak tekrarlayan apnelerin öngörülmesinde aynı başarı oranı gözlenememiştir (Erdamar, 2007).

EEG işaretleri ve göz bebeği boyutları kullanılarak ANN yöntemiyle yapılan bir çalışmada Liu ve ark., (2008), dalgacık ve Fourier dönüşümlerini kullanarak %91 başarı oranına ulaşmıştır (Liu ve ark., 2008).

Yıldız ve arkadaşlarının 2009 yılında yaptığı çalışmada EEG işaretlerinin dalgacık dönüşümü ile altbandlarına ayırıştırıp entropi hesabı yapmış uyku skorlamasında %98 ortalama doğruluk değerine ulaşmıştır (Yıldız ve ark., 2009).

Álvarez ve ark., (2009), apne hipopne sendromunda apneik olayların tespiti için bulanık mantık tabanlı bir çözüm önermiş ve önerdikleri algoritmayı %86 kesinlik ve %87 geçerlilik oranları ile desteklemiştir. (Alvarez ve ark., 2009).

Balakrishnan ve ark., (2009), normal uykusu olan ve obstrüktif uyku apnesi olan kişileri ayırt etmek için bir uyku kalitesi indeksi geliştirmiştir. Bu indeks, sağlıklı ve hasta kişilerin uykuda geçirdikleri sürenin uykuda geçirilen toplam süreyle karşılaştırılmasıyla hesaplanmıştır (Balakrishnan ve ark., 2009).

Duman ve ark., (2009), EEG işaretlerinin analizinden sonra uyku içciklerini tespit etmek için karar ağacı algoritmasını kullanmışlar ve kısa zaman Fourier dönüşümü (STFT), çoklu işaret sınıflandırma (MUSIC) algoritması ve Teager enerji operatörü (TEO) yaklaşımları olmak üzere üç farklı yaklaşımı başarıyla uygulamıştır. Sonuç olarak önerilen uyku içiği tespit algoritması %96.17 duyarlılık ve %95.54 özgüllük ile başarıya ulaşmıştır (Duman ve ark., 2009).

Umut'un çalışmasında ise EEG frekans bantlarının uyku apnesi tanısında kullanılabilirliğini araştırmış ve dört farklı frekans bandı arasında Beta frekansının %97 ile en belirleyici olduğu sonucuna varmıştır (Umut, 2011).

ANN ve destek vektör makinası (SVM) yöntemlerinin kullanıldığı bir diğer çalışmada solunum işaretlerinin enerji özellikleri kullanılarak bir sınıflandırma yapılmış ve SVM yöntemi kullanılarak yapılan sınıflandırma verimlilik %97 olmuştur (Jayasri, 2013).

Uyku apne skorlaması için birçok çalışmada en belirleyici parametre olan EEG işareti kullanılırken bazı çalışmalarda da EEG işaretiyle birlikte solunum işaretleri de kullanılmıştır. Bu sınıflandırma yapılırken radyal temel fonksiyonu çok sınıflı SVM

modeline giriş olarak uygulanmış ve %81.7 doğruluk oranı elde edilmiştir (Wu ve ark., 2015).

Xie ve ark., (2017), apne ve hipoapne olaylarının sinir sistemi aktiviteleriyle ilişkilerini araştırmıştır. Şiddetli apne grubunda %57.3 olacak şekilde yüksek oranda hipertansiyon görülmüştür (Xie ve ark., 2017).

Akşahin ve arkadaşlarının çalışmasında EEG işaretindeki frekans alt bandlarının güçlerini ayrı ayrı belirlemişler ve bu güçler arasındaki oranları hesaplamışlardır. Her bir epoktaki apneler kuadratik SVM ile eğitilmiştir. Alfa ve beta frekans alt bandlarının oranlarının apne ve apne olmayan dönemlerde farklı olduğu bulunmuştur. %75.4 duyarlılık ve %75 doğru tahmin değerleri elde edilmiştir (Akşahin ve ark., 2017).

Uyku skorumu uyku esnasında alınan EEG işaretlerinin özelliklerinin sabit kaldığı durumlarda işaretlenmesidir. Uyku skorumu yapılırken işaretin tamamının ya da bir bölümünün kullanıldığı çalışmalar mevcuttur. Sors ve ark., (2018), 14 katmanlı bir evrişimsel sinir ağı (CNN) modeli geliştirerek %87 doğruluk oranına ulaşılmıştır (Sors ve ark., 2018).

Civaner ve ark., (2018), tarafından gerçekleştirilen bir uygulamada, çocuklardaki horlama seslerini ayırt etmek için derin öğrenme yöntemleri kullanılmıştır. Obstrüktif uyku apne sendromu (OSAS) ve horlaması olan çocukların ses kayıtları üzerinde çalışılmış ve Adadelta algoritması kullanılarak eğitilen bir ağı doğruluk değeri %91 olarak elde edilmiştir (Civaner ve ark., 2018).

EEG işaretleri zaman ve frekans özelliklerine göre de çeşitli öznitelikleri çıkarılarak SVM, K-en yakın komşuluk algoritması (KNN) ve ANN gibi yöntemler kullanılarak uyku skorumu yapılmıştır. Dört sınıflı gerçekleştirilen skorumda %90.8, iki sınıflı skorumda ise %83.6'lık doğru tahmin oranına ulaşmıştır. (Michiellia ve ark., 2019).

Bir başka çalışmada Yörük, (2019), uyku apnesi sırasında kaydedilen EEG işaretlerinin hızlı Fourier dönüşümü (FFT) yöntemiyle spektral güç yoğunluklarını elde etmiş ve

spektral entropilerini çıkarmıştır. Apneye girme anında entropinin minimum seviyelere düştüğünü gözlemlemiştir (Yörük, 2019).

Hafezi ve ark., (2020) PSG kayıtları ile birlikte kaydedilen trakeal solunum işaretlerini kullanarak uyku apnesini tespit etmiştir. İşaretlerden 25 özellik çıkarmışlar ve bunları CNN ve uzun-kısa süreli belleğin (LSTM) birleşiminden oluşan hibrit bir derin öğrenme algoritması kullanarak sınıflandırmıştır. Sınıflandırma sonucunda %84 doğruluk, %81 duyarlılık ve %87 özgüllük elde etmişlerdir (Hafezi ve ark., 2020).

Han ve ark., (2022), radar temelli uyku apne sendromunu tespit etmek için bir model geliştirmiştir. Bu amaçla, ultra ağırlık bandı (UWB) radar spektrogramlarının zarfını ve makine öğrenimini temel almıştır. Spektrogramın zarfı görüntü tabanlı bir yöntemle çıkarılmış, ardından varyasyonel mod ayrıştırması yoluyla işaret yumuşatılmış ve %90'ın üzerinde doğruluk sağlanmıştır (Han ve ark., 2022).

Abdulla ve ark., (2023), uyku evrelemesini sınıflandırmak için çok kanallı doku renk analizine dayalı akıllı bir model önermiştir. STFT, 30 saniyelik EEG işaretlerini bir görüntü formatına dönüştürmek için uygulanmıştır. Bu spektrogramlar çok kanallı bilgi yerel ikili modeli (MILBP) için bir girdi olarak kullanılmış ve EEG uyku aşamalarını %95 ve %96 doğruluk oranıyla sınıflandırmıştır (Abdulla ve ark., 2023).

Bu çalışmada, uyku apne sendromu tespit ve sınıflandırmasında PSG kayıtlarından alınan EEG işaretleri kullanılmıştır. EEG işaretleri uyku apne sendromu çalışmalarında sıklıkla kullanılan ve başarı oranı yüksek olan işaretlerdir. Kullanılan sınıflandırma yöntemleri ise daha önce örneğine rastlanılmış fakat uyku apne sendromu tespit ve sınıflandırmasında kullanılmamış yöntemlerdir. Öznitelik vektörlerinin MLPNN modeline giriş olarak kullanılması, spektrogramlardan elde edilen entropinin MLPNN modeline giriş olarak kullanılması, PSG kayıtlarından alınan EEG işaretlerine ait görüntü ve spektrogramların CNN modeli ile sınıflandırılması ve işaretlere ait spektrogramların YOLOv5 ve YOLOv8 modelleriyle sınıflandırılması, çalışmanın başlıca konularıdır.

4. MATERYAL ve YÖNTEM


4.1. Veri Seti

Çalışmada kullanılan EEG işaretleri uyku apne sendromu teşhisi daha önce uyku laboratuvarlarında hastaların uyutulmasıyla alınmış kayıtlarla ve hekim tarafından konulmuş farklı AHI değerleri ve sürelerle ait işaretler olup bilimsel araştırmalara açık olan Pysionet veri tabanından alınmıştır ([PhysioBank ATM \(physionet.org\)](http://PhysioBank ATM (physionet.org))). Bu işaretlere ait sınıf bilgileri Tablo 4.1’de verilmektedir.

Tablo 4.1 EEG işaretlerinin sınıf, AHI ve süre bilgileri

Sınıf	AHI değeri	Uyku süresi (sa)
Sağlıklı	2	6.8
Hafif	5	6.4
Orta	25	7.2
Şiddetli	91	5.9

PSG kayıtlarından alınan EEG işaretleri C3-A2 kanallarına ait olup hafif, orta, şiddetli ve sağlıklı sınıflara ait örnek işaretler Şekil 4.1’de verilmektedir.



Şekil 4.1 Örnek EEG işaretleri

EEG işaretleri zaman ve frekans bölgelerinde ayrı işlemlere tabi tutularak deneysel çalışmalar yapılmıştır. Zaman bölgesinde literatürde sıklıkla karşılaşılan ve EEG işaretini sınıflandırmada başarıyı artıran ön işlemler örnekleme, filtreleme, pencereleme ve normalizasyon işlemleri yapılan her deney için ortak olarak kullanılmıştır.

4.2. Önişleme


Uyku apne sendromu sınıflandırması yapabilmek için PSG kayıtlarından alınan EEG işaretlerinin önişlemlerden geçirilerek kullanılacak sınıflandırıcı modeline uygun hale getirilmesi gerekmektedir. Kullanılan önişlemler aşağıda belirtilmektedir.

4.1.1. Örnekleme

Alınan kayıtların sayısal ortamda kaydedilip işlenebilmesi için belirli aralıklarda örnek seçilip sayısallaştırılması gerekmektedir. İşlem kolaylığı açısından işaretlerin yeniden örneklenmesi sıklıkla kullanılan bir yöntemdir (Yörük, 2019). Örnekleme frekansı ile işaretin maksimum frekansı arasında Nyquist oranı sağlanmazsa örtüşme meydana gelir. Nyquist oranı işaretin maksimum frekansının iki katına eşittir. Örnekleme frekansının Nyquist frekansından büyük ya da eşit olması gerekmektedir. PSG kayıtlarından alınan EEG işaretleri 128 Hz örnekleme frekansı ile ayrıklaştırılmıştır.


4.1.2. Filtreleme

Kullanılan EEG işaretlerinin çalışma aralığı olan 0-30 Hz aralığına çekilebilmesi için filtreleme işlemi uygulanmalıdır. Bu işlem için, belirli frekans değerleri aralığındaki işaretleri geçiren sonsuz impulsu yanıt (IIR) Butterworth band geçiren filtre (BpF) kullanılmıştır. Diğer filtrelere göre daha az hesaplama gerektirdiği ve daha az bellek kullandığı için IIR Butterworth BpF tercih edilmiştir. Bu filtreye ait gösterim Şekil 4.2’de verilmektedir.



Şekil 4.2 IIR Butterworth BpF gösterimi

Şekil 4.2’de görüldüğü gibi IIR Butterworth BpF bir alçak geçiren bir de yüksek geçiren filtrenin birleşiminden oluşmaktadır. Burada w_1 alt kesim frekansı, w_2 ise üst kesim frekansıdır. Bu iki değer arasındaki değer de band genişliği anlamına gelmektedir. w_1 ve w_2 , merkez frekansı olan w_0 a eşit uzaklıktadır. Kullanılan EEG işaretleri çalışma aralığı olan 0-30 Hz aralığına böylelikle çekilmiş olmaktadır. Çalışmada kullanılan EEG işaretlerinin filtreleme işleminden sonraki durumları Şekil 4.3’te verilmektedir.



Şekil 4.3 Filtreli EEG işaretleri

4.1.3. Pencereleme


İşaretin istenilen bölgesinin analiz edilmesine olanak sağlayan işleme pencereleme denilmektedir. Pencereleme işlemi zaman uzayında işaretin pencere fonksiyonuyla çarpılmasından elde edilir. Pencere dışında kalan kısımlar sıfır kabul edilmektedir. Birçok çeşit pencereleme yöntemi bulunmaktadır (Öter, 2016). Bunlar dikdörtgen, Bartlett, Hamming, Hanning ve Blackman gibi yöntemlerdir (Rangayyan, 2002).

Bu çalışmada literatürde sıklıkla kullanılan 30 saniyelik pencereleme işlemi yapılmıştır. Pencereleme çeşidi olarak da matematiksel olarak basit olan dikdörtgen pencereleme yöntemi tercih edilmiştir. Pencereleme işleminden sonra her bir uyku apnesi sınıfı için 260 pencere elde edilmiştir.

4.1.4. Normalizasyon

Normalizasyon işlemi, ham verilere uygulanarak veriyi daha düzgün bir forma getirir ve işaretin kolay işlenebilmesini sağlamaktadır. İşaretteki çok büyük ya da çok küçük

değerler hesaplamalarda farklılıklar gösterebilmekte ve ağı yanlış yönlendirebilmektedir. Normalizasyon işlemi yapılırken farklı tekniklerden yararlanılabilir (Yavuz ark., 2012). Bu yöntemler, istatistiksel (Z-skor) normalizasyon, min-max normalizasyonu, Medyan normalizasyonu, Sigmoid normalizasyonu ve D_min max normalizasyonudur. Bu çalışmada, EEG işaretleri [0 1] aralığına normalizasyonu için min-max normalizasyonu kullanılmıştır. Normalizeli EEG işaretleri Şekil 4.4'te verilmektedir.



Şekil 4.4 Normalizeli EEG işaretleri

Şekil 4.4'te görüldüğü gibi EEG işaretlerinin genlik değerleri [0 1] aralığına çekilerek işaretler arası farklılık oluşumunun önüne geçilmiştir.

4.1.5. Frekans altbandlarına ayırıştırma


Beyin dalgaları genellikle düzensiz olduğundan genel bir bütün olarak incelemek yerine frekans altbandlarına ayırıştırılarak farklı durumlardaki değişimler daha net görülebilmektedir. EEG işaretleri 0.5 – 100 Hz aralığında geniş bir frekans bandına sahip olmakla birlikte klinikte 30 Hz üzerindeki bilgiler gürültü olarak kabul edildiğinden

fizyolojik ilgi 0.5 – 30 Hz arasına yoğunlaşmıştır (Gül, 2018). EEG frekans altbandları Tablo 4.2’de verilmektedir.

Tablo 4.2 EEG frekans altbandları

Dalga	Frekans bandı (Hz)	Genlik (μV)	Özellik
Delta	0.5- 4	20 – 400	Genellikle normal bireylerde anestezi esnasında, derin uykuda ve bebeklerde görülür.
Theta	4- 8	5- 100	Uykulu ve uyuşukluk durumlarında ortaya çıkar.
Alpha	8- 12	20- 60	Uyanık, rahatlamış, dinlenme durumlarında görülür.
Beta	12- 30	2 – 20	Korku, heyecan, stres durumlarında, merkezi sinir sistemini yoğun faaliyet gösterdiği durumlarda görülür.
Gamma	30- 100	-	Klinikte kullanılmaz.

Tablo 4.2’de görüldüğü gibi, EEG işaretlerinin frekans altbandları değişik frekans ve genlik değerlerine sahiptir. 30 Hz ve üzeri frekanstaki işaretler analizlerde kullanılmadığından altband ayrıştırma işlemlerinde Gamma bandı elde edilmemektedir. Çalışmada kullanılan örnek bir EEG işareti ve frekans altbandları Şekil 4.5’te verilmektedir.



Şekil 4.5 Frekans altbandlarına ayrıştırılmış EEG işareti


4.3. Spektrogram

EEG işaretinin dalga formu iki boyutlu iken frekans içeriğini de ekleyerek spektrogramının elde edilmesi 3 boyuta taşınması anlamına gelmektedir. Yani spektrogram, bir işaretin zaman içindeki enerji değişimin gösterir (Coşkun, 2012). Spektrogram işaretin enerjisinin maksimum olduğu frekansları ifade eder. Fourier dönüşümü uygulamasında zaman bilgisi kaybolmaktadır. Bu yüzden STFT dönüşümü geliştirilmiştir. Bu dönüşüm için öncelikle segmentlere ayrılmış olan EEG işaretlerine hızlı Fourier dönüşümü (FFT) uygulanır. Bu dönüşümün zamana karşı frekans grafiği çizilerek işaretin spektrogramı elde edilmiş olur. Bir işaretin spektrogramı STFT işleminin güç dağılımı olarak tanımlanır (Köseoğlu ve ark., 2023).

$$S(t, f) = X(t, f)^2 \quad (4.1)$$

$$X(t, f) = \int_{-\infty}^{\infty} x(t)w(t - \tau)e^{-j\omega\tau} d\tau \quad (4.2)$$

Burada, $X(t, f)$, $w(t)$ ile ağırlıklaştırılmış işaretin STFT işlemi sonucudur. Çalışmada kullanılan EEG işaretlerine ait spektrogramlar Şekil 4.6'da verilmektedir.



Şekil 4.6 EEG işaretleri ve spektrogramları (a) hafif (b) orta (c) şiddetli (d) sağlıklı

Şekil 4.6'da görüldüğü gibi, işaretlerin farklı bölgelerindeki enerji yoğunluklarına göre spektrogramlar farklı renk almaktadır. En düşük frekanslı renk kırmızı, en yüksek

frekanslı renk mor olmak üzere EEG işaretleri görselleştirilerek .png formatında kaydedilmiştir.

4.4. Öznitelik Çıkarımı

EEG işaretlerinden çeşitli öznitelikler çıkarılarak belirleyici özellikleri artırılmış ve boyut küçültme sağlanmıştır. Öznitelik çıkarma işleminde çok farklı yöntemler kullanılabileceği için EEG işaretini tanımlayan farklı özellikler elde edilebilir. Fakat elde edilen her öznitelik belirleyici olmayabilir. Yüksek sınıflandırma başarısı elde etmek için işarete ve yapılan işleme uygun öznitelik seçimi önemlidir. Çalışmada kullanılan istatistiksel parametreler minimum, maksimum, ortalama, varyans, standart sapma, medyan, basıklık, Hjorth aktivitesi, çarpıklık, ortalama enerji, Log enerji entropisi ve Shannon entropisi olup bu özniteliklere ait formüller Tablo 4.3'te verilmektedir.

Tablo 4.3 Kullanılan istatistiksel parametreler

Özellik	Formül	Özellik	Formül
Minimum	$\min \{x_i\}$	Basıklık (K)	$\frac{\sum_{i=1}^N (x_i - \mu)^4}{(N-1)\sigma^4}$
Maksimum	$\max \{x_i\}$	Hjorth Aktivitesi (HA)	σ^2
Ortalama (μ)	$\frac{1}{N} \sum_{i=1}^N x_i$	Çarpıklık (S)	$\frac{\sum_{i=1}^N (x_i - \mu)^3}{(N-1)\sigma^3}$
Varyans (σ^2)	$\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2$	Ortalama Enerji (ME)	$\frac{1}{N} \sum_{i=k-N+1}^k x[i]^2$
Standart sapma (σ)	$\sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2}$	Log Enerji Entropisi (LE)	$-\sum_{i=0}^N (\log_2(p_i(x)))^2$
Medyan (MN)	$\frac{\left(\frac{N}{2}\right)^{th} value + \left(\frac{N}{2} + 1\right)^{th} value}{2}$	Shannon Entropisi (SE)	$-\sum_{i=0}^N x_i \ln x_i$

burada, N veri uzunluğu, $i=1,2,3,...N$, x_i i . katsayıdaki değer, k penceredeki en son örnek ve p_i normalize enerjiyi ifade etmektedir.

Tablo 4.3'te görüldüğü gibi EEG işaretine ait birçok öznitelik hesaplanmıştır. Bu öznitelikler hakkında kısa bilgiler aşağıdaki şekilde özetlenebilir (Özcan, 2020).

- *Minimum-maksimum değer:* İşaretin tüm örnekleri içinde genliğin en düşük ve en yüksek değeridir.
- *Ortalama:* Zamanla değişen bir işaretin belirli bir zaman diliminde aldığı değerlerin aritmetik ortalamasıdır.
- *Varyans:* İşaretteki değişimin ortalamadan bağımsız olarak ölçüldüğü bir parametredir. Bir olasılık dağılımı için istatistiksel yayılımın, mümkün bütün değerlerinin beklenen değer veya ortalamadan uzaklıklarının karelerinin ortalaması alınarak bulunur.
- *Standart sapma:* İşaretin değerinin ortalama değerden sapması hesaplanır. Bu sapmanın karelerinin ortalaması alınarak karekökü hesaplanır.
- *Median:* Küçükten büyüğe doğru sıralanmış verilerin tam ortasında kalan değerdir.
- *Basıklık:* Rastgele bir sürecin olasılık dağılımıdır.
- *Hjorth aktivitesi:* Bir zaman serisinin varyansını tanımlamaktadır.
- *Çarpıklık:* Rastgele bir sürecin olasılık dağılımının asimetrisinin bir ölçüsüdür.
- *Ortalama enerji:* Bir işarettaki tüm enerji değerleri toplamının enerji sayısına oranıdır.
- *Log enerji entropisi:* EEG işaretinin karışıklık derecesini ifade eder.
- *Shannon entropisi:* Rastgele bir işaretin belirsizliğinin bir ölçüsüdür. Bir işaretin ne kadar bilgi taşıdığıyla ilgilidir.

4.5. Sınıflandırma

Farklı AHI değerlerine göre seçilmiş EEG işaretlerini özniteliklerine göre sınıflandırmak hem hızlı hem de doğru yapılması gereken bir durumdur. Literatürde sınıflandırma yapmak için kullanılan birçok yöntem bulunmaktadır. Elde edilen öznitelik vektörlerine göre en uygun sınıflandırıcıyı seçebilmek için yöntemlerin özellikleri, üstünlükleri ve performans analizleri bilinmesi gerekmektedir.

Çalışmada gerçekleştirilen deneylerde MLPNN, CNN ve YOLO modelleriyle sınıflandırmalar yapılmıştır. Her deneyde veri setinin %70'i eğitim, %15'i test ve %15'i doğrulama için kullanılmıştır.

MLPNN modeliyle yapılan sınıflandırmalarda 11 adet istatistiksel parametre kullanıldığından 11 girişli, 10 nöron içeren 1 gizli katman ve 1 çıkış katmanı içeren bir modeldir. MLPNN modelinin aktivasyon fonksiyonu olarak hiperbolik tanjant fonksiyonu ve eğitim algoritması olarak Levenberg–Marquardt geri-yayılım algoritması seçilmiştir. Sınıflandırma deneyleri Matlab R2022a programında gerçekleştirilmiştir.

Derin öğrenme modeli InceptionV3 seçilmiş ve transfer öğrenme ağırlıkları imageNet veri tabanından alınmıştır. Aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmıştır. Çalışmada kullanılan görseller 224x224x3 boyutundadır. Sınıflandırma deneyleri Tensorflow kütüphanesi kullanılarak gerçekleştirilmiştir.

YOLO model deneylerinde kullanılan spektrogramlar 224x224x3 boyutunda görseller olup 20 epoch değeri için eğitim işlemi yapılmıştır. YOLO modelleri işaret işleme ve öznitelik oluşturma işlemlerini kendi bünyesinde yaptığı için sadece 30 sn pencereledikten sonra EEG işaretlerinin spektrogramları giriş verisi olarak kullanılmıştır. Literatürde sıklıkla kullanılan sınıflandırma modellerinden YOLOv5 ve YOLOv8 modelleri Google Colab kullanılarak, EEG işaretlerinden uyku apne sendromu sınıflandırılması sağlanmıştır.

4.6. Performans değerlendirme metrikleri

Uyku apne sendromu sınıflandırma performansının değerlendirilmesi için yaygın olarak kullanılan toplam doğru sınıflandırma oranı (Acc), kesinlik (P), duyarlılık, özgüllük ve F1 skor gibi değerlendirme metrikleri kullanılmıştır. Acc toplam doğru sınıflandırma oranıdır ve değeri 1'e yaklaştıkça başarının arttığı anlamına gelmektedir. Kesinlik tahmin edilen değerlerin gerçek değerlere oranını ifade ederken duyarlılık ise doğru tahmin edilen değerlerin toplam değerlere oranı, özgüllük gerçek negatif değerlerin sayısı iken F1 skor ise duyarlılık ve kesinlik ifadelerinin harmonik ortalamasıdır (Yang ve ark., 2023). Bu değerler hesaplanırken kullanılan gerçek ve tahmini doğru/yanlış sayıları

karışıklık matrisi yardımıyla tespit edilir. İkili bir sınıflandırmaya ait karışıklık matrisi Tablo 4.4'te verilmektedir.

Tablo 4.4 İkili sınıflandırma için karışıklık matrisi

Tahmini değerler	Gerçek değerler	
	Pozitif	Negatif
	TP	FP
Pozitif	TP	FP
Negatif	FN	TN

Tablo 4.4'te verilen karışıklık matrisindeki değerlere göre performans değerlendirme metrikleri hesaplanmaktadır ve Eşitlik 4.3, 4.4, 4.5, 4.6 ve 4.7 ile ifade edilmektedir.

$$\text{Doğruluk (Acc)} = \frac{TP + TN}{TP + FN + FP + TN} \quad (4.3)$$

$$\text{Kesinlik (P)} = \frac{TP}{TP + FP} \quad (4.4)$$

$$\text{Duyarlılık (sens)} = \frac{TP}{TP + FN} \quad (4.5)$$

$$\text{Özgüllük (spec)} = \frac{TN}{TN + FP} \quad (4.6)$$

$$\text{F1 Skor} = \frac{2 * (P * R)}{P + R} \quad (4.7)$$

TP: doğru pozitif, doğru tespit edilen apneli sayısı

FP: yanlış pozitif, apneli tespit edilen apnesiz sayısı

TN: doğru negatif, doğru tespit edilen apnesiz sayısı

FN: yanlış negatif, apnesiz tespit edilen apneli sayısı

Elde edilen değerler, yaygın olarak kullanılan alıcı işlem karakteristiği (ROC) analiziyle incelenmektedir. Yapılan incelemelerde duyarlılık ve belirlilik değerleri hesaplanarak ROC eğrisi çizilmekte ve eğri altında kalan alanın büyüklüğü ile sınıflandırma doğru başarı oranı yorumlanabilmektedir. Eğri altında kalan alan ne kadar büyük ve 1'e yakında model o kadar başarılıdır.

5. BULGULAR VE TARTIŞMA

5.3. MLPNN modeli kullanılarak gerçekleştirilen sınıflandırmalar

Deney 1: Hafif-sağlıklı, orta-sağlıklı, şiddetli-sağlıklı apne sınıflandırma deneyleri

Bu deneyde 3 farklı sınıflandırma gerçekleştirilmiştir. Deney 1'e ait işlem adımları: aşağıdaki işlem adımlarından oluşmaktadır:

- EEG işareti
- Örnekleme (128 Hz)
- Filtreleme (30 Hz)
- Pencereleme (30 sn.)
- Özniteliklerin elde edilmesi
- MLPNN ile sınıflandırma

EEG işaretleri örnekleme, filtreleme ve pencereleme işlemlerinden sonra elde edilen 30 saniyelik her bir segment için istatistiksel değerleri kullanılarak öznitelik vektörleri elde edilmiştir. Öznitelik vektörleri, uyku apne sendromu teşhisi için MLPNN modeline giriş olarak uygulanmıştır. MLPNN modeliyle yapılan sınıflandırmalarda 11 adet istatistiksel parametre kullanıldığından 11 girişli, 10 nöron içeren 1 gizli katman ve 1 çıkış katmanı içeren bir modeldir. MLPNN modelinin aktivasyon fonksiyonu olarak hiperbolik tanjant fonksiyonu ve eğitim algoritması olarak Levenberg–Marquardt geri-yayılım algoritması seçilmiştir. Sınıflandırma deneyleri Matlab R2022a programında gerçekleştirilmiştir. Modellerin sınıflandırma sonucu elde edilen karışıklık matrisleri Tablo 5.1'de gösterilmektedir.

Tablo 5.1 Deney1'e ait karışıklık matrisleri

	Hafif	Sağlıklı		Orta	Sağlıklı		Şiddetli	Sağlıklı
Hafif	172	56	Orta	235	56	Şiddetli	243	32
Sağlıklı	88	204	Sağlıklı	25	204	Sağlıklı	17	228


Tablo 5.1'de de görüldüğü gibi hafif uyku apneyi tespit ederken toplam 520 örnekten 144 tanesini yanlış sınıflandırmıştır. Orta apneyi tespit ederken ise hatalı sınıflandırma sayısı %81'e düşerken şiddetli uyku apneyi belirlemede toplam 520 örnekten 49'u yanlış sınıflandırılmıştır. Yüksek değerdeki AHI oranlarına sahip hastaların sınıflandırılmasında

doğruluk oranı da artmaktadır. Deneyde kullanılan MLPNN modelinin geçerlik sonuçları Tablo 5.2’de verilmektedir.

Tablo 5.2 Deney 1’e ait geçerlik sonuçları

	Duyarlılık (%)	Özgüllük (%)	Acc (%)
Hafif	66	78	72
Orta	90	78	84
Şiddetli	93	87	90

Tablo 5.2’de görüldüğü gibi şiddet derecesine göre uyku apne sendromunu tespit duyarlılığı ve özgüllüğü de artmaktadır. Doğru sınıflandırma oranı da hafif apneli, orta apneli ve şiddetli apneli sınıflarda sırasıyla %72, %84 ve %90 olmuştur. Bu sonuç PSG kayıtlarından EEG işaretlerinin uyku apne sendromu teşhisinde etkin olduğunu göstermektedir. Şekil 5.1’de bu çalışma sonuçlarının ROC analizi görünmektedir. ROC eğrisi altında kalan alanlardan da anlaşılabileceği gibi uyku apne sendromunu EEG işaretleri ile tespit etmede başarı oranını AHI değeri yükseltmektedir.



Şekil 5.1 Deney 1’e ait ROC analizi

Şekil 5.1’de görüldüğü gibi şiddetli sınıfın ROC eğrisi altında kalan en büyüktür. Hafif ve orta apne sınıfında TP değerleri birbirine yakındır fakat FP değerleri farklı olduğu için orta apne sınıfında daha yüksek doğruluk değerine ulaşılmıştır. Bu sonuç EEG işaretlerinin uyku apne sendromu tespit ve sınıflandırma konusunda büyük oranda belirleyici olduğunu göstermektedir.

Deney 2: Frekans altbandlarına ayrıştırmanın etkisinin incelenmesi

Gerçekleştirilen bu deneyde, frekans altbandlarına ayrıştırmanın etkisini incelemek amacıyla ikili ve üçlü sınıflandırmalar yapılmıştır. Hafif ve orta apne sınıfına ait alt frekanslar birbirine yakın değerler içerdiğinden, aynı sınıf olarak birleştirilmiş ve orta-sağlıklı, şiddetli-sağlıklı ve orta-şiddetli-sağlıklı olmak üzere sınıflandırmalar gerçekleştirilmiştir. Deney 2, aşağıdaki adımlardan oluşmaktadır:

- EEG işareti
- Örnekleme (128 Hz)
- Filtreleme (30 Hz)
- Pencereleme (30 sn.)
- Frekans altbandlarına ayırma
- Özniteliklerin elde edilmesi
- MLPNN ile sınıflandırma


Deney 2’de EEG işaretleri Deney 1’deki ön işlemlerden geçirildikten sonra frekans altbandlarına ayrıştırılarak öznitelik çıkarımı yapılmıştır. Frekans altbandlarına ayrıştırmadan sonra her sınıf için 260 olan pencere sayısı 1040’a ulaşmıştır. Öznitelik vektörleri, uyku apne sendromu tespit ve sınıflandırması için MLPNN modeline giriş vektörü olarak uygulanmış ve üçlü sınıflandırma yapılmıştır. MLPNN çıkışında oluşan karışıklık matrisi, geçerlik ölçütleri ve toplam doğru sınıflandırma oranı Tablo 5.3’te verilmektedir.

Tablo 5.3 Deney 2’ye ait karışıklık matrisi ve geçerlik sonuçları

	Şiddetli	Sağlıklı	Orta		Duyarlılık (%)	Özgüllük (%)	Acc (%)
Şiddetli	1034	0	5	Şiddetli	99.4	99.5	
Sağlıklı	0	731	286	Sağlıklı	70.3	71.9	80.6
Orta	6	309	749	Orta	72.0	70.4	

Tablo 5.3’te görüldüğü gibi, altbandlarına ayrıştırma işlemi doğruluk oranını artırmış ve Deney 1’e göre daha yüksek başarı oranlarına ulaşılmıştır. Bu deneyde hafif ve orta apne sınıfındaki veriler birleştirilmiştir. Orta apne başarı oranı %70.4, şiddetli apne başarı oranı

%99.5 ve sağlıklı başarı oranı ise %71.9 olmuştur. Duyarlılık ve özgüllük değerlerine göre her bir sınıf için ROC eğrisi çizdirilmiş ve Şekil 5.2’de verilmektedir.



Şekil 5.2 Deney 2’ye ait ROC analizi

Şekil 5.2’de görüldüğü gibi, orta sınıf ile sağlıklı sınıf doğruluk oranlarının birbirine yakın sonuç vermektedir. Şiddetli sınıfa ait eğri altındaki alanın en büyük olduğu görülmektedir. Deney 2’de de en yüksek doğru sınıflandırma oranı şiddetli sınıfta tespit edilmiştir.

Deney 3: Hem normalizenin hem de frekans altbandlarına ayırıştırmanın etkisinin incelenmesi

Deney 3-a: Normalizesiz hafif-sağlıklı, orta-sağlıklı, şiddetli-sağlıklı ve dörtlü sınıflandırma deneyleri

Deney 3-a aşağıdaki adımlardan oluşmaktadır:

- EEG işareti
- Örnekleme (128 Hz)
- Filtreleme (30 Hz)
- Pencereleme (30 sn)
- Özniteliklerin elde edilmesi
- MLPNN ile sınıflandırma


Deney 3-a’da önışlemlerden geçirilen EEG işaretlerine ait öznitelikler, uyku apne sendromu tespit ve sınıflandırılması amacıyla MLPNN modeline giriş olarak

uygulanmıştır. Hafif-sağlıklı, orta-sağlıklı, şiddetli-sağlıklı ve dörtlü sınıflandırma deneylerinde elde edilen karışıklık matrisleri ve geçerlik ölçütleri Tablo 5.4’te verilmektedir (Tancı K., ve ark., 2022).

Tablo 5.4 Deney 3-a’ya ait karışıklık matrisleri ve geçerlik ölçütleri

	Sağlıklı	Hafif		Duyarlılık (%)		Özgüllük (%)	Acc (%)	
Sağlıklı	211	86	Sağlıklı	81.2		71	74	
Hafif	49	174	Hafif	66.9		78		
	Sağlıklı	Orta		Duyarlılık (%)		Özgüllük (%)	Acc (%)	
Sağlıklı	226	58	Sağlıklı	86.9		79.6	82.3	
Orta	34	202	Orta	77.7		85.6		
	Sağlıklı	Şiddetli		Duyarlılık (%)		Özgüllük (%)	Acc (%)	
Sağlıklı	245	32	Sağlıklı	94.2	88.4	91		
Şiddetli	15	228	Şiddetli	87.7	93.8			
	Sağlıklı	Hafif	Orta	Şiddetli		Duyarlılık (%)	Özgüllük (%)	Acc (%)
Sağlıklı	105	37	26	9	Sağlıklı	40.4	59.3	68.6
Hafif	98	216	6	0	Hafif	83.1	67.5	
Orta	30	7	167	26	Orta	64.2	72.6	
Şiddetli	27	0	61	225	Şiddetli	86.5	71.9	

Tablo 5.4’ te görüldüğü gibi uyku apne sendromu sınıflandırmasında hafif apnenin toplam doğru başarı oranı %74, orta uyku apnenin toplam doğru başarı oranı %82.3 ve şiddetli apnenin ise %91’dir. Duyarlılık ve özgüllük değerleri karışıklık matrisindeki doğru bilinen sınıfı sayılarına göre değişmektedir. Dörtlü sınıflandırma yapıldığında ise sağlıklı sınıfı tespit etmede %59.3 özgüllüğe ulaşılmıştır. Bu değer şiddetli apnede artmakta fakat toplam doğru sınıflandırma oranı %68.6 olarak elde edilmiştir. Duyarlılık ve özgüllük değerlerine göre çizdirilen ROC eğrileri Şekil 5.3’te verilmektedir.



Şekil 5.3 Deney 3-a'ya ait ROC analizi

Şekil 5.3'te görüldüğü gibi ikili sınıflandırma yapıldığında farklı AHI değerlerine sahip sınıflar ile sağlıklı sınıflar karşılaştırılmış ve eğri altında kalan alanlar sistemin doğru sınıflandırma başarısını göstermektedir. En yüksek doğruluk oranı %82.3 ile şiddetli uyku apne sınıfına aittir.

Deney 3-b: Normalizeli hafif-sağlıklı, orta-sağlıklı, şiddetli-sağlıklı ve dörtlü sınıflandırma deneyleri

Deney 3-b'de normalizasyonun sınıflandırma başarısına etkisinin incelenmesi amacıyla önışlemlerden geçirilen EEG işaretleri normalize edildikten sonra öznitelik vektörleri oluşturulmuş ve aynı sınıflandırma deneyleri tekrarlanmıştır. Deney 3-b, aşağıdaki adımlardan oluşmaktadır:

- EEG işareti
- Örnekleme (128 Hz)
- Filtreleme (30 Hz)


- Pencereleme (30 sn)
- Normalizasyon (0-1)
- Özniteliklerin elde edilmesi
- MLPNN ile sınıflandırma

Deney 3-b’de normalizeli EEG işaretlerinden elde edilen öznitelik vektörleri aynı MLPNN modeline giriş olarak uygulanmış ve normalizasyon işleminin başarıya etkisini gösteren sonuçlar Tablo 5.5’te verilmektedir.

Tablo 5.5 Deney 3-b’ye ait karışıklık matrisleri ve geçerlik ölçütleri

	Sağlıklı	Hafif		Duyarlılık (%)	Özgüllük (%)	Acc (%)	
Sağlıklı	208	93	Sağlıklı	80	69.1	72.1	
Hafif	52	167	Hafif	64.2	76.3		
	Sağlıklı	Orta		Duyarlılık (%)	Özgüllük (%)	Acc (%)	
Sağlıklı	229	55	Sağlıklı	88.1	80.6	83.5	
Orta	31	205	Orta	78.8	86.9		
	Sağlıklı	Şiddetli		Duyarlılık (%)	Özgüllük (%)	Acc (%)	
Sağlıklı	245	31	Sağlıklı	94.2	88.8	91.2	
Şiddetli	15	229	Şiddetli	88.1	93.9		
	Sağlıklı	Hafif	Orta	Şiddetli	Duyarlılık (%)	Özgüllük (%)	Acc (%)
Sağlıklı	61	14	18	8	Sağlıklı	23.5	64.7
Hafif	120	225	4	1	Hafif	86.5	
Orta	44	17	174	38	Orta	66.9	
Şiddetli	35	4	64	213	Şiddetli	81.9	

Tablo 5.5’te görüldüğü üzere her üç sınıf için de normalizenin olumlu etkisi olmuşken toplam doğru sınıflandırma başarı oranlarında pek bir iyileştirmeye sebep olmamıştır. Şekil 5.4’te bu değerlere ait ROC eğrileri gösterilmiştir.



Şekil 5.4 Deney 3-b'ye ait ROC analizi

Şekil 5.4'te görüldüğü gibi, ikili sınıflandırmalarda normalize işleminin doğruluk oranlarına olumlu katkısı olmuştur. Hafif apneli %72.1, orta apneli %83.5 ve şiddetli apneli %91.2 doğruluk değerlerine ulaşmış ve ROC eğrileri altında kalan alanların büyüdüğü gözlemlenmiştir.

Deney 3-c: Hem normalizeli hem de frekans altbandlarına ayrıştırılmış hafif-sağlıklı, orta-sağlıklı, şiddetli-sağlıklı ve dörtlü sınıflandırma deneyleri

Deney 3-c'de normalizeli EEG işaretleri frekans altbandlarına ayrıştırılarak pencerelemiş ve öznitelik vektörlerinin her altband için ayrı ayrı hesaplanarak aynı MLPNN modeline giriş olarak uygulanmıştır. Deney 3-c aşağıdaki adımlardan oluşmaktadır:

- EEG işareti
- Örnekleme (128 Hz)
- Filtreleme (30 Hz)
- Pencereleme (30 sn)


- Normalizasyon (0-1)
- Frekans altbandlarına ayırma
- Özniteliklerin elde edilmesi
- MLPNN ile sınıflandırma

Gerçekleştirilen bu deneyde de daha önceki deneylerde olduğu gibi aynı ikili ve üçlü sınıflandırmalar yapılmış olup Deney 3-c'ye ait sonuçlar Tablo 5.6'da verilmektedir.

Tablo 5.6 Deney 3-c'ye ait karışıklık matrisleri ve geçerlik ölçütleri


	Sağlıklı	Hafif		Duyarlılık (%)	Özgüllük (%)	Acc (%)	
Sağlıklı	931	101	Sağlıklı	99	90.2	94.7	
Hafif	9	1039	Hafif	91.1	99.1		
	Sağlıklı	Orta		Duyarlılık (%)	Özgüllük (%)	Acc (%)	
Sağlıklı	897	72	Sağlıklı	95.4	92.6	94.5	
Orta	43	1068	Orta	93.7	96.1		
	Sağlıklı	Şiddetli		Duyarlılık (%)	Özgüllük (%)	Acc (%)	
Sağlıklı	932	92	Sağlıklı	99.1	91	95.2	
Şiddetli	8	1048	Şiddetli	91.9	99.2		
	Sağlıklı	Hafif	Orta	Şiddetli	Duyarlılık (%)	Özgüllük (%)	Acc (%)
Sağlıklı	829	18	25	47	Sağlıklı	79.7	90.2
Hafif	83	909	0	180	Hafif	87.4	77.6
Orta	33	0	1008	1	Orta	96.9	96.7
Şiddetli	95	113	7	812	Şiddetli	78.1	79.1

Tablo 5.6'da görüldüğü gibi hafif uyku apne sınıflandırmasında toplam doğru başarı oranı %94.7'ye ulaşmış ve aynı artış %94.5 oranıyla orta uyku apneli sınıfta ve %95.2 oranıyla şiddetli uyku apneli sınıfta ulaşılmıştır. Doğru sınıflandırma oranının artması sistemin ne kadar doğrulukta çalıştığının bir ölçüsü olup sınıflandırıcının başarısını göstermektedir. Ayrıca dördü sınıflandırmada da toplam doğru başarı oranı %85.5 değerine ulaşmış ve hastalık tespitinde geçerli ölçüde başarı sağlanmıştır. Bu tablolara göre frekans altbantlarına ayrılan EEG işaretlerine ait ROC eğrileri Şekil 5.5'te verilmektedir.



Şekil 5.5 Deney 3-c'ye ait ROC analizi

Şekil 5.5'te normalizasyondan sonra frekans altbandlarına ayrıştırmanın her sınıfta da başarı oranını artırdığı görülmektedir. Deney 3'e ait her 3 durum için elde edilen sınıflandırma oranları Şekil 5.6'da gösterilmektedir.



Şekil 5.6 Deney 3'e ait Acc değerleri

Şekil 5.6’da görüldüğü gibi her üç durumda da şiddetli apne sınıfı en yüksek doğruluğa ulaşmıştır. Normalize edilerek frekans altbandlarına ayırmak büyük ölçüde sisteme katkı sağlamıştır.

Deney 4: Spektrogram tabanlı entropinin sınıflandırmaya etkisinin incelenmesi

Bu deneyde, spektrogram tabanlı entropi ve MLPNN modeli kullanılarak EEG işaretlerinden uyku apne sendromu sınıflandırması gerçekleştirilmiştir. Deneyler hafif-sağlıklı, orta-sağlıklı, şiddetli-sağlıklı ve dörtlü sınıflandırma olarak gerçekleştirilmiştir. Deney 4’e, aşağıdaki adımlardan oluşmaktadır:

- EEG işareti
- Örnekleme (128 Hz)
- Filtreleme (30 Hz)
- Pencereleme (30 sn)
- Normalizasyon (0-1)
- Frekans altbandlarına ayırma
- Spektrogramların elde edilmesi
- Entropilerin elde edilmesi
- MLPNN ile sınıflandırma

Deney 4’te normalizeli altbandların spektrogram değerlerinden Shannon entropileri hesaplanmış ve MLPNN modeline giriş olarak verilmiştir. İlk olarak her sınıf sağlıklı sınıf ile karşılaştırılmış, ikinci durumda ise dörtlü sınıflandırma yapılmıştır. Deney 4’e ait elde edilen karışıklık matrisleri ve geçerlik ölçütleri Tablo 5.7’de verilmektedir (Tancı, K. ve ark., 2023).



Tablo 5.7 Deney 4’e ait karışıklık matrisleri ve geçerlik ölçütleri


	Sağlıklı	Hafif	Duyarlılık (%)	Özgüllük (%)	Acc (%)
Sağlıklı	619	357	59.5	63.4	62.6
Hafif	421	683	65.7	61.9	
	Sağlıklı	Orta	Duyarlılık (%)	Özgüllük (%)	Acc (%)
Sağlıklı	731	509	70.3	59	60.7
Orta	309	531	51.1	63.2	

	Sağlıklı	Şiddetli	Duyarlılık (%)	Özgüllük (%)	Acc (%)
Sağlıklı	632	154	89.6	85.8	87.4
Şiddetli	108	886	85.2	89.1	

	Hafif	Orta	Şiddetli	Sağlıklı	Duyarlılık (%)	Özgüllük (%)	Acc (%)
Hafif	566	260	0	349	54.4	48.2	53.4
Orta	81	376	0	189	36.2	58.2	
Şiddetli	76	76	884	106	85	77.4	
Sağlıklı	317	328	156	396	38.1	33.1	

Tablo 5.7’de görüldüğü gibi şiddetli apne sınıfının başarı oranı diğerlerine göre yüksek çıkmıştır. AHI değerlerinin birbirine yakın olması sınıflara ait doğruluk değerini düşürebilmektedir. Doğruluk değerleri hafif, orta ve şiddetli apne sınıfları için sırasıyla %62.6, %60.7 ve %87.4 olarak elde edilmiştir. Orta ve şiddetli uyku apne sınıflandırmasında duyarlılık özgüllükten daha düşüktür. Hafif uyku apnesinde ise tam tersi bir durum söz konusudur. Dörtlü sınıflandırmanın doğruluk değeri %53.4 olarak elde edilmiştir. Sağlıklı sınıf ile hafif ve orta sınıfların değerleri birbirine yakın olduğu için hassas bir sınıflandırma yapılamamış ve başarı oranı düşük çıkmıştır. Bu durum duyarlılığı ve özgüllüğü de azaltmıştır. Sınıflandırmalara ait ROC eğrileri Şekil 5.7’de verilmektedir.





Şekil 5.7 Deney 4'e ait ROC analizi

Şekil 5.7’de görüldüğü gibi hafif ve orta apne sınıfında başarı oranları birbirine yakınken şiddetli apnede yüksek çıkmıştır. ROC eğrisi altında kalan alan 1’e daha yakındır. Bu da başarı oranının yüksek olduğu, düşük FP oranı ile yüksek hassasiyet anlamına gelmektedir. Dörtlü sınıflandırma ROC eğrisinde şiddetli uyku apne sınıfının başarı oranı diğerlerine göre daha yüksektir. FP oranının düşük olması ROC eğrisini optimize eder. Eğri altında kalan alanlar değerlendirildiğinde şiddetli apne sınıfının 1’e daha yakın olduğu görülmektedir. Bu da yüksek özgüllük ve duyarlılığa sahip olduğu anlamına gelmektedir.

5.4. CNN modeli kullanılarak gerçekleştirilen sınıflandırmalar

Deney 5: EEG işaretlerinin ham görsellerinin ve spektrogramlarının karşılaştırılması

Deney 5-a: Ham görsellerin giriş olarak kullanıldığı sınıflandırma deneyleri

Deney 5-a, aşağıdaki adımlardan oluşmaktadır:

- EEG işaretleri
- Pencereleme (30 sn)
- Ham görsellerin elde edilmesi
- CNN ile sınıflandırma

Deney 5-a’da 30 sn pencerelenen EEG işaretlerine ait ham görseller CNN modeline giriş olarak uygulanmıştır. Gerçekleştirilen deneyde hafif-sağlıklı, orta-sağlıklı, şiddetli-sağlıklı ve dörtlü sınıflandırmalara ait sonuçlar Tablo 5.8’de verilmektedir.

Tablo 5.8 Deney 5-a'ya ait sınıflandırma sonuçları

	Duyarlılık (%)	Kesinlik (%)	Acc (%)	F1 skor
Hafif	87	86	87	84
Orta	95	95	95	95
Şiddetli	96	96	96	96
Dörtlü	41	58	89	99

Tablo 5.8'de görüldüğü gibi, EEG işaretlerinin görselleri giriş olarak uygulandığında en düşük doğruluk %87 ile hafif sınıfa aittir. Orta ve şiddetli sınıf doğruluk değerleri sırasıyla %95 ve %96 olarak elde edilmiştir. Dörtlü sınıflandırmada doğruluk oranı %89 olduğu görülmektedir. Gerçekleştirilen sınıflandırmalarda duyarlılık ve kesinlik değerlerinin en düşük olduğu sınıflandırma dörtlü sınıflandırmadır. AHI değerinin en yüksek olduğu şiddetli sınıfa ait değerlerin, gerçekleştirilen bütün sınıflandırmalarda en yüksek değerde olduğu görülmektedir.

Deney 5-b: Spektrogramların giriş olarak kullanıldığı sınıflandırma deneyleri

Deney 5-b'de pencerelenen EEG işaretlerinin spektrogramları kullanılarak aynı sınıflandırmalar tekrarlanmıştır. Deney 5-b aşağıdaki adımlardan oluşmaktadır:

- EEG işaretleri
- Pencereleme (30 sn)
- Spektrogramların elde edilmesi
- CNN ile sınıflandırma

Gerçekleştirilen bu deneye ait sonuçlar Tablo 5.9'da verilmektedir.

Tablo 5.9 Deney 5-b'ye ait sınıflandırma sonuçları

	Duyarlılık (%)	Kesinlik (%)	Acc (%)	F1 skor
Hafif	97	93	95	93
Orta	97	95	96	94
Şiddetli	98	98	98	88
Dörtlü	50	66	95	99

Tablo 5.9’da görüldüğü gibi Deney 5-b’de doğruluk oranlarında artış gerçekleşmiştir. Bütün sınıfların duyarlılıkları artmış, orta sınıf hariç kesinlik değerleri de artış göstermiştir. F1 skor değerleri hafif sınıfta yükselme gösterirken diğer sınıflarda hemen hemen aynı değerde kalmıştır. EEG işaretlerin ham görselleri ve spektrogramları arasında gerçekleştirilen karşılaştırmada spektrogramların giriş olarak kullanıldığı deneylerde doğruluk değerleri yükselmiştir.

5.5. YOLO modeli kullanılarak gerçekleştirilen sınıflandırmalar

Deney 6: Spektrogram temelli YOLOv5 ve YOLOv8 modeli kullanılarak gerçekleştirilen sınıflandırma deneyleri

Gerçekleştirilen bu deneyde, YOLO modelleri kendi içinde öznetelik çıkarma işlemi yaptığından spektrogramlar direk modellere giriş olarak verilmiştir. Literatürde sıklıkla kullanılan sınıflandırma modellerinden YOLOv5 ve YOLOv8 modelleri kullanılarak EEG işaretlerinden uyku apne sınıflandırılması sağlanmıştır.

Deney 6-a: YOLOv5 modeli ile gerçekleştirilen sınıflandırmalar

Deney 6-a, aşağıdaki işlem adımlarından oluşmaktadır:

- EEG işareti
- Pencereleme (30 sn)
- Spektrogramların elde edilmesi
- YOLOv5 modeli ile sınıflandırma


Deney 6’da gerçekleştirilen sınıflandırma deneyleri spektrogram temelli olup hafif, orta, şiddetli ve sağlıklı olmak üzere dört sınıf için gerçekleştirilmiştir. YOLOv5 ve YOLOv8 modellerine ait eğitim sonuçları Tablo 5.10’da verilmektedir.

Tablo 5.10 Deney 6’ya ait eğitim sonuçları

Model	Katman	Parametre	GFLOPs	Top1	Top2	Süre (sa)
YOLOv5	214	7030417	16	0.882	1	0.304
YOLOv8	99	2719288	4.4	0.937	1	0.139

Tablo 5.10’da görüldüğü gibi YOLOv5 modeli daha fazla katman, daha çok parametre ve yüksek saniye başına Giga kayan nokta işlem (GFLOP) değeri kullanmasına rağmen daha uzun sürede eğitimi tamamlamıştır. GFLOP değeri performans ölçüsüdür ve kayan

nokta işlemi olarak tanımlanabilir. Top1 değeri tahmin edilen ve gerçek sınıfın eşleştiği örneklerin oranı iken Top2 değeri tahmin edilen en olası iki sınıftan birinin gerçek sınıfla eşleşmesi durumudur. YOLOv5 modelinde Top1 değeri 0.882 ve YOLOv8 modelinde 0.937 iken her iki modelde de Top2 değeri 1 olarak tespit edilmiştir. Her iki modele ait eğitim ve test kayıplarının grafiği Şekil 5.8 ‘de verilmektedir.



Şekil 5.8 YOLOv5 ve YOLOv8 modellerine ait eğitim ve test kayıpları

Şekil 5.8’de görüldüğü gibi YOLOv5 modelinin eğitim kaybı yukarı yönlü bir grafik sergilemekteyken YOLOv8 modelinde bu kayıp giderek sıfıra yaklaşmaktadır. Bu ölçüt tahminlerin gerçek değerlerden ne kadar uzak olduğunu ölçer. Eğitim kayıp değerinin giderek düşmesi modelin daha iyi öğrendiğini gösterir. Test kaybında ise YOLOv5 modelinde durağana yakın seyrederken YOLOv8 modelinde giderek azalan bir grafik

elde edilmiştir. YOLOv5 ve YOLOv8 modellerine ilişkin toplam doğruluk oranı sırasıyla %88.2 ve %93.7 olarak elde edilmiştir.

Deney 6-a'da EEG işaretlerine ait spektrogramlar YOLOv5 modeline giriş olarak uygulanmış ve hafif, orta, şiddetli ve sağlıklı olmak üzere dört sınıflandırma deneyi gerçekleştirilmiştir. Bu deneylere ait sonuçlar Tablo 5.11'de verilmektedir.

Tablo 5.11 Deney 6-a'ya ait sınıflandırma sonuçlar


	Duyarlılık (%)	Kesinlik (%)	F1 skor
Hafif	91	77	93
Orta	100	98	98
Şiddetli	100	90	94
Sağlıklı	66	94	77

Tablo 5.11'e göre, sağlıklı sınıfın duyarlılığı %66, hafif sınıfın duyarlılığı %91 ve orta ve şiddetli sınıfların duyarlılığı %100 olarak elde edilmiştir. Kesinlik değerlerinde en düşük yüzde hafif sınıfa aittir. F1 skor değeri en düşük olan sınıf ise %77 değeri ile sağlıklı sınıftır. Elde edilen bu değerler neticesinde Deney 6-a'ya ait karışıklık matrisi Tablo 5.12'de verilmektedir.

Tablo 5.12 Deney 6-a'ya ait karışıklık matrisleri

YOLOv5	Hafif	Orta	Şiddetli	Sağlıklı
Hafif	91	0	0	27
Orta	1	100	0	1
Şiddetli	4	0	100	6
Sağlıklı	4	0	0	66

Tablo 5.12'de görüldüğü gibi, YOLOv5 modelinde hafif uyku apne sınıfından 91'i doğru sınıflandırılırken 27'si yanlış sınıflara atanmıştır. Orta sınıfta ise TP değeri 100 ve 2 veri yanlış sınıflandırılmıştır. Şiddetli sınıfta 100 doğru sınıflandırma 10 hatalı sınıflandırma varken sağlıklıda 66 doğru sınıflandırma olduğu görülmektedir. Deney 6-a'ya ait ROC eğrileri Şekil 5.9'da verilmektedir.



Şekil 5.9 Deney 6-a'ya ait ROC analizi

Şekil 5.9'da görüldüğü gibi YOLOv5 modeli ile gerçekleştirilen sınıflandırmalarda en yüksek doğruluk AHI değeri en yüksek sınıf olan şiddetli sınıfa aittir. Şiddetli sınıfa ait eğri altında kalan alan en büyüktür ve değeri 1'e yakındır.

Deney 6-b: YOLOv8 modeli ile gerçekleştirilen sınıflandırmalar

Deney 6-b, aşağıdaki işlem adımlarından oluşmaktadır:

- EEG işareti
- Pencereleme (30 sn)
- Spektrogramların elde edilmesi
- YOLOv5 modeli ile sınıflandırma

Deney 6-b'de ise EEG işaretlerine ait spektrogramların aynı sınıflandırma deneyleri yapılması amacıyla YOLOv8 modeline giriş olarak uygulanmıştır. Gerçekleştirilen bu deneylere ait sonuçlar Tablo 5.13'te verilmektedir.

Tablo 5.13 Deney 6-b'ye ait sınıflandırma sonuçları

	Duyarlılık (%)	Kesinlik (%)	F1 skor
Hafif	99	94	97
Orta	95	93	94
Şiddetli	99	100	99
Sağlıklı	88	94	91


Tablo 5.13'te görüldüğü gibi, YOLOv8 modeli ile gerçekleştirilen sınıflandırma deneylerinde orta ve şiddetli sınıfların duyarlılık değerlerinde azalma görülürken, hafif ve sağlıklı sınıfların duyarlılıkları yüksek oranda artış göstermiştir. Kesinlik değeri

sağlıklı sınıfta aynı kalırken, hafif ve şiddetli sınıflarda artış göstermiştir. Bu değerlere paralel olarak F1 skor değerleri de Deney 6-b’de daha yüksek elde edilmiştir. Deney 6-b’ye ait karışıklık matrisleri Tablo 5.14’te verilmektedir.

Tablo 5.14 Deney 6-b’ye ait karışıklık matrisleri

YOLOv8	Hafif	Orta	Şiddetli	Sağlıklı
Hafif	99	0	6	0
Orta	0	95	6	1
Şiddetli	0	0	99	0
Sağlıklı	1	5	0	88

Tablo 5.14’te görüldüğü gibi, en düşük doğru sınıflandırma 88 doğru 6 yanlış sınıflandırma ile sağlıklı sınıfına aittir. Diğer sınıflarda yüksek oranda doğruluk değerlerine ulaşılmıştır. Karışıklık matrisinde elde edilen bu değerlere göre Deney 6-b’ye ait ROC eğrileri Şekil 5.10’da verilmektedir.



Şekil 5.10 Deney 6-b’ye ait ROC analizi

Şekil 5.10’da görüldüğü gibi YOLOv8 modelinde her sınıf için yüksek başarı oranları elde edilirken en yüksek değer şiddetli apne sınıfına aittir. Hafif, orta ve şiddetli sıralamasıyla devam ettiği görülmektedir. ROC eğrisi altında kalan alanın büyüklüğü sınıflandırma başarısının ne kadar yüksek olduğunu göstermektedir. Şiddetli apnenin Acc değerinin yüksek olması AHI değerinin yüksek olmasıyla orantılıdır.

Çalışmada 6 adet deney gerçekleştirilmiş ve her deneyde farklı araştırmaların etkileri incelenmiştir. Deney 1, öz niteliklerin MLPNN modeline giriş olarak uygulandığı sınıflandırma, Deney 2, frekans altbandlarına ayrıştırmanın etkisini incelemek amacıyla

MLPNN modeli ile sınıflandırma, Deney 3, normalize ve frekans altbandlarına ayırıştırmanın etkisini incelemek amacıyla MLPNN modeli ile sınıflandırma, Deney 4, spektrogram tabanlı entropilerin etkisini incelemek için MLPNN modeli ile sınıflandırma, Deney 5, EEG işaretlerine ait görselleri ve spektrogramları CNN modeli ile sınıflandırma ve Deney 6 ise, EEG işaretlerine ait spektrogramların YOLOv5 ve YOLOv8 modelleri ile sınıflandırma deneyleridir. Çalışmada gerçekleştirilen deneylerin doğruluk oranları aşağıdaki tablolarda özetlenmiştir.

Deney 1'e ait Acc değerleri Tablo 5.15'te verilmektedir.

Tablo 5.15 Deney 1'e ait Acc değerleri

	Hafif	Orta	Şiddetli
Deney 1	72	84	90

Tablo 5.15'te görüldüğü gibi, Deney 1'e ait gerçekleştirilen ikili sınıflandırmalarda en yüksek doğruluk değeri %90 ile şiddetli şiddetli sınıfa aittir.

Deney 2'ye ait Accdeğerleri Tablo 5.16'da verilmektedir.

Tablo 5.16 Deney 2'ye ait Acc değerleri

	Orta	Şiddetli	Sağlıklı	Üçlü
Deney 2	72	99.5	71.9	80.6

Tablo 5.16'da görüldüğü gibi, AHI değeri en yüksek olan şiddetli sınıfta en yüksek başarı oranı elde edilmiştir. Üçlü sınıflandırmada ise doğruluk değeri %80.6 olarak kaydedilmiştir.

Deney 3'e ait Acc değerleri Tablo 5.17'de verilmektedir.

Tablo 5.17 Deney 3'e ait Acc değerleri

	Hafif	Orta	Şiddetli	Dörtlü
Deney 3-a	74	82.3	91	68.6
Deney 3-b	72.1	83.5	91.2	64.7
Deney 3-c	94.7	94.5	95.2	85.5

Tablo 5.17’de görüldüğü gibi, Deney 3-a’da şiddetli sınıf %91 doğruluk ile en yüksek değerde başarı sağlamıştır. Gerçekleştirilen dörtlü sınıflandırma deneyinde ise doğruluk oranı %68.6’dır. Deney 3-b’de şiddetli doğruluk değerlerinde ciddi bir artış sağlanmadığı görülmektedir. Frekans altbandlarına ayrıştırılarak tekrarlanan sınıflandırma deneylerine ait doğruluk sonuçları Deney 3-c’ye aittir ve bütün sınıflarda yüksek başarı oranları elde edilmiştir.

Deney 4’e ait Acc değerleri Tablo 5.18’de verilmektedir.

Tablo 5.18 Deney 4’e ait Acc değerleri

	Hafif	Orta	Şiddetli	Dörtlü
Deney 4	62.6	60.7	87.4	53.4

Tablo 5.18’de görüldüğü gibi şiddetli sınıf hariç diğer sınıflandırma deneylerinde yüksek başarı sağlanamamıştır.

Deney 5’e ait Acc değerleri Tablo 5.19’da verilmektedir.

Tablo 5.19 Deney 5’e ait Acc değerleri

	Hafif	Orta	Şiddetli	Dörtlü
Deney 5-a	87	95	96	89
Deney 5-b	95	96	98	95

Tablo 5.19’da görüldüğü gibi, EEG işaretlerinde ait ham görüntülerle gerçekleştirilen sınıflandırmaların yapıldığı Deney 5-a’ya ait doğruluk değerleri Deney 5-b’deki değerlere göre daha düşük çıkmıştır. Spektrogramların giriş olarak kullanılması sınıflandırma başarısına katkı sağlamıştır.

Deney 6’ya ait Acc değerleri Tablo 5.20’de verilmektedir.

Tablo 5.20 Deney 6’ya ait Acc değerleri

	Hafif	Orta	Şiddetli	Sağlıklı
Deney 6-a	91	100	100	66
Deney 6-b	99	95	99	88

Tablo 5.20’de görüldüğü gibi Deney 6-a’da sağlıklı sınıf hariç yüksek doğruluk değerleri elde edilmiştir. YOLOv8 modeliyle gerçekleştirilen Deney 6-b’de ise bütün sınıflara ait doğruluk değerlerinde artış sağlanmış ve daha hızlı sonuç elde edilmiştir.

Sonuç olarak, normalizesiz gerçekleştirilen sınıflandırma deneylerinde Acc değerleri düşük çıkmıştır. Hem normalizeli hem de frekans altbandlarına ayrıştırılarak gerçekleştirilen deneylerde başarı oranı artış göstermektedir. Spektrogram tabanlı entropilerin sınıflandırmaya katkısı yüksektir. Ön işlem gerektirmeyen derin öğrenme modelleriyle gerçekleştirilen sınıflandırma deneylerinde, EEG işaretlerinin ham görüntülerine karşılık spektrogramlarının giriş olarak kullanılması doğruluk değerlerini artırmıştır. YOLOv5 modeli ile gerçekleştirilen sınıflandırma deneylerindeki yüksek başarı değerleri YOLOv8 modeli ile elde edilen sonuçlara yakındır, fakat YOLOv8 modeli daha az parametre ve katman kullandığından sınıflandırma deneyleri daha hızlı gerçekleştirilmiştir.

6. SONUÇ ve ÖNERİLER

Uyku apnesi günümüzde giderek artan bir sağlık sorunu haline gelmiştir. Bu hastalığın farklı türlerini sınıflandırmak, doğru ve hızlı bir teşhis koymak, etkili bir tedavi uygulamak ve potansiyel ölüm vakalarını engellemek açısından son derece önemlidir. Bu çalışmada, hafif, orta ve şiddetli uyku apne sendromu olan hastalar ve sağlıklı birey tespiti için PSG kayıtlarından alınan C3-A2 kanalı EEG işaretleri altı ayrı deney halinde çalışılmıştır. İlk olarak önışlemlerden sonra öznitelik vektörleri oluşturularak MLPNN modeline giriş olarak uygulanmıştır. Deney 2’de frekans altbandlarına ayrıştırmanın etkisi araştırılmıştır. Deney 3’te normalizasyon ve frekans altbandlarına ayrıştırmanın üstünlükleri incelenmiştir. Deney 4’te ise aynı MLPNN modeline spektrogram temelli entropiler giriş olarak uygulanmıştır. Deney 5’te EEG işaretlerinin ham görselleri ve spektrogramları ayrı ayrı CNN modeline giriş verisi olarak uygulanmış ve karşılaştırması yapılmıştır. Son olarak Deney 6’da YOLO mimarileri kullanılarak EEG işaretlerinin spektrogramları YOLOv5 ve YOLOv8 modellerine giriş verisi olarak uygulanmıştır. Gerçekleştirilen deneylerde önerilen yaklaşımın özellikle şiddetli uyku apne sendromu tespitinde yüksek doğru sınıflandırma oranlarına ulaştığı görülmektedir. ROC analizlerine bakıldığında en yüksek başarı oranı AHI değeri en yüksek olan şiddetli apne sınıfına aittir. Sonuç olarak, PSG kayıtlarından alınan EEG işaretlerinin uyku apne sendromu sınıflandırılmasında frekans alt bandlarına ayrıştırılması, normalize edilmesi, spektrogram tabanlı entropi kullanılması ve CNN modeli ile yapılan sınıflandırmalar belirleyici olmuş ve modelin başarısına katkı sağlamıştır. Spektrogram tabanlı entropi yaklaşımının uyku apne sendromu sınıflandırmasında daha önce kullanılmamış olması, derin öğrenme modellerinin önışlem gerektirmemesi ve işlem hızının yüksek olması gibi sonuçlar neticesinde biyomedikal uygulamalara bir ışık tutacağı düşünülmektedir. Gerçekleştirilen deneyler içerisinde en yüksek başarı oranlarına YOLOv8 modeli ile ulaşılmıştır. Daha az parametre ve katman kullanması, diğer modellere kıyasla daha hızlı sonuç üretmesi ve en yüksek doğruluk ile sınıflandırma yapmasından dolayı YOLOv8 modeli, EEG işaretleri kullanılarak uyku apne sendromu teşhis ve sınıflandırmasında yüksek başarılarla ulaşmıştır.

7. KAYNAKLAR

- Abdulla, S., Diykh, M., Siuly, S. and Ali, M., 2023. An intelligent model involving multi-channels spectrum patterns based features for automatic sleep stage classification. *International Journal of Medical Informatics*, 171: 105001.
- Acır, N., Guzelis, C., 2004. Automatic recognition of sleep spindles in EEG by using artificial neural networks, *Expert Systems with Applications*. 27: 451–458.
- Akdağ, A., 2017. Derin öğrenme algoritmaları kullanılarak gerçek zamanlı silah tanıma uygulaması. (Yüksek lisans tezi), Necmettin Erbakan Üniversitesi. Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, Konya.
- Akşahin, F., Oltu, B., & Karaca, B. K., 2018. Sleep apnea detection using blood pressure signal. In 2018 26th Signal Processing and Communications Applications Conference (SIU). IEEE.
- Alsamurai, M. Q.F., 2023. Development and implementation of YOLOv8-based model for human and animal detection during forest fires. (Master's Thesis). Altınbaş Üniversitesi. Elektrik ve Bilgisayar Mühendisliği, İstanbul
- Alvarez, D., R. Hornero, J. V. Marcos, F. del Campo, and M. Lopez, 2009. Spectral analysis of electroencephalogram and oximetric signals in obstructive sleep apnea diagnosis. *Proc. IEEE Annual Engg. Medicine and Biology Society*.
- Aydin, B., Singha S., 2023. Drone Detection Using YOLOv5. *Eng.*
- Aydoğan, O., 2023. Polisomnografi işaretleri kullanılarak yapay sinir ağları ve uyarlamalı sinirsel bulanık mantık sistemi ile uyku ve uyku apnesinin skorlanması. (Doktora Tezi), Erciyes Üniversitesi. Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı, Kayseri.
- Balakrishnan, G., Burli, D., Burk J.R., Lucas E. A., and Behbehani K., 2005. Comparison of a sleep quality index between normal and obstructive sleep apnea patients, *Engineering in Medicine and Biology*, pp 1154–1157, Shanghai, China
- Civaner, O. F. and Kamsak, M., 2018. Classification of pediatric snoring episodes using deep convolutional neural networks. 26th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4), IEEE.
- Coşkun M., İstanbullu A., 2012. EEG işaretlerinin FFT ve dalgacık dönüşümü ile analizi. Akademik Bilişim'12- XIV. Akademik Bilişim Konferansı Bildirileri 1- 3 Şubat 2012 Uşak Üniversitesi.
- Çiçek, Y., 2021. Standart polisomnografik parametrelerin uyku apnesinin teşhisine etkisinin makine öğrenmesi yöntemleriyle araştırılması. (Yüksek Lisans Tezi), Fırat Üniversitesi. Yazılım Mühendisliği Anabilim Dalı, Elazığ.
- Duman, F., Erdamar A., Eroğlu O., Telatar Z., Yetkin S., 2009. Efficient sleep spindle detection algorithm with decision tree, *Expert System with Application* 36: 9980-9985.
- Erdamar, A., 2007. Model development for prediction of sleep apnea and tongue muscle stimulation. (Doktora Tezi), Hacettepe Üniversitesi, Ankara.
- Fang, Y., X Guo, K Chen, Z Zhou, Q Ye., 2021. Accurate and automated detection of surface knots on sawn timbers using YOLO-V5 model *BioResources*.
- Gül, E., 2018. EEG sinyallerinin wavelet yöntemiyle dönüştürülerek yapay sinir ağları ile sınıflandırılması. (Yüksek Lisans Tezi), Eskişehir Osmangazi Üniversitesi Sağlık Bilimleri Enstitüsü Biyoistatistik Anabilim Dalı, Eskişehir.

- Hafezi, M., Montazeri, N., Saha, S., Zhu, K., Gavrilovic, B., Yadollahi, A., & Taati, B., 2020. Sleep apnea severity estimation from tracheal movements using a deep learning model, *IEEE Access*, 8, 22641–22649.
- Han, Y., Yarovsky, A. and Fioranelli, F., 2022. An approach for sleep apnea detection based on radar spectrogram envelopes, *Proceedings of the 18th European Radar Conference*, 5–7 April 2022, London, UK.
- Jayasri, T., Hemalatha M., 2013. Categorization of respiratory signal using ANN and SVM based on feature extraction algorithm. *Indian Journal of Science and Technology*.
- Karamustafaoğlu, G., 2014. Polisomnografi sinyallerinin işlenmesi ile uyku apnesinin otomatik teşhisi. (Yüksek Lisans Tezi), İstanbul Üniversitesi, Biyomedikal Mühendisliği, İstanbul.
- Kırca, S., 2021. Derin öğrenme yöntemi ile araç ve plaka tanıma. (Yüksek Lisans Tezi), Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü. Bilişim Sistemleri Mühendisliği, Kocaeli.
- Kıymık, M.K., Akin M, Subaşı. A, 2004. Automatic recognition of alertness level by using wavelet transform and artificial neural network. *Journal of Neuroscience Methods*, vol. 139, 231–240.
- Köseoğlu, M., Uyanık H., 2023. Effect of spectrogram parameters and noise types on the performance of spectro-temporal peaks based audio search method, *Gazi University Journal of Science*, 36(2): 624-643.
- Liu, D., Pang, Z. ve Lloyd, S. R., 2008. A neural network method for detection of obstructive sleep apnea and narcolepsy based on pupil size and EEG, *IEEE Transactions on Neural Networks*, 19(2), 308-318.
- Michiellia, N., Acharya, U. R., Molinari, F., 2019. Cascaded LSTM recurrent neural network for automated sleep stage classification using single-channel EEG signals. *Computers in Biology and Medicine*, 106:71-81.
- Nasıfoğlu, H., 2022. Obstrüktif uyku apnesinin derin öğrenme kullanılarak tahmin edilmesi. (Doktora Tezi), TOBB Ekonomi ve Teknoloji Üniversitesi, Fen Bilimleri Enstitüsü. Biyomedikal Mühendisliği Anabilim Dalı, Ankara.
- Nazlı, B., 2021. EKG sinyallerinden yapay zekâ yöntemleri kullanılarak uyku apnesi teşhisinin yapılması. (Yüksek Lisans Tezi), Kastamonu Üniversitesi, Fen Bilimleri Enstitüsü Biyomedikal Mühendisliği Ana Bilim Dalı, Kastamonu.
- Orhan, U., Hekim, M., Özer, M., 2010. EEG işaretlerinin çok katmanlı algılayıcı yapay sinir ağı modeli ile sınıflandırılmasında ayrıklaştırma yaklaşımı. *BIYOMUT 2010* 15. Yayın No:401535.
- Öter, A., 2016. Modern Parametrik Yöntemler ile Akıllı Sistemler Kullanarak Uyku Apnesinin Teşhisi ve Sınıflandırılması. (Doktora Tezi), Kahramanmaraş Sütçü İmam Üniversitesi Fen Bilimleri Enstitüsü, Kahramanmaraş.
- Özcan, A. R., 2020. EEG işaretlerinde evrişimli sinir ağları ile epileptik nöbet tahmini. (Doktora Tezi), Kocaeli Üniversitesi, Elektronik ve Haberleşme Mühendisliği Anabilim Dalı, Kocaeli.
- Özol, D., 2013. Elektrotlar, sensörler, hastanın kayıt için hazırlanması. *Solunum* 2013; 15 (Supplement 2): 5-9
- Papila, İ., Acioğlu, E., 2005. Obstrüktif uyku apne sendromu. *Klinik gelişim*, 18(1):42–50.
- Rangayyan R.M., 2002. *Biomedical signal analysis*, IEEE Press.

- Resi, D., Kupec J., Hong J., Daoudi A., 2023. Real-time flying object detection with YOLOv8. arXiv:2305.09972v1.
- Sors, A., Bonnet, S., Mirek, S., Vercueil, L., Payen, J. F., 2018. A convolutional neural network for sleep stage scoring from raw single-channel EEG. *Biomedical Signal Processing and Control*, 42:107-114.
- Szilagyi, L., Benyo Z., Szilagyi S. M., 2002. A new method for epileptic waveform recognition using wavelet decomposition and artificial neural networks, *Proceeding of the Second Joint EMBS/BMES Conference*, 3, 2025–2026.
- Tancı K., Hekim M., 2022. Çok katmanlı algılayıcı sinir ağı modeli ile uyku apne teşhisinde normalizasyon ve frekans altbantlarına ayırıştırmanın etkisi. *ISSRIS'22*.
- Tancı K., Hekim M., 2023. Classification of sleep apnea syndrome from EEG signals using spectrogram-based entropy and MLPNN model, *Yayın Yeri:Gaziosmanpaşa Bilimsel Araştırma Dergisi (GBAD)* , 12(3), 197-207.
- Umut, I., 2011. Developing digital signal processing software and using Electroencephalography records with this software to distinguish individuals with obstructive sleep apnea from individuals without apnea. (Doktora Tezi), Trakya Üniversitesi, Edirne.
- Übeyli, E. D., 2008. Analysis of EEG signals by combining eigenvector methods and multi-class support vector machines. *Computers in Biology and Medicine*, Cilt 38, No 1, 14–22.
- Yang, G., Wang J., Nie Z., Yang H., Yu S., 2023. A lightweight YOLOv8 tomato detection algorithm combining feature enhancement and attention. *Agronomy*, 13, 1824.
- Yavuz, S., Deveci, M., 2012. İstatiksel normalizasyon tekniklerinin yapay sinir ağı performansına etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, Sayı: 40, Haziran-Aralık 2012 ss. 167-187.
- Yıldız, A., Akın M., Poyraz M., Kirbas G. 2009. Application of adaptive neuro-fuzzy inference system for vigilance level estimation by using wavelet-entropy feature extraction. *Expert Systems with Applications*, 7390–7399.
- Yörük, A., 2019. Uyku apnesinde EEG verilerinin spektral analizi. (Yüksek Lisans Tezi), Kütahya Dumlupınar Üniversitesi, Fen Bilimleri Enstitüsü İleri Teknolojiler Anabilim Dalı, Kütahya.
- Wu, H., Talmon, R., Lo, Y., 2015. Assess sleep stage by modern signal processing techniques. *IEEE Transactions on Biomedical Engineering*, 6(4):1159-1168.
- Xie, J. Yu, W., Wan, Z., Han, F., Wang, Q., Chen, R., 2017. Correlation analysis between obstructive sleep apnea syndrome (OSAS) and heart rate variability, *Iran J Public Health*. 2017 Nov, 46(11): 1502–1511.